

تصميم واجهة برمجية للتنبؤ بالتآكل الخارجي في أنابيب نقل النفط باستخدام الذكاء الاصطناعي

د.م. أحمد سلامة *

د.م. حسان حامد **

د. ربيع محمود ***

م. طارق عياشي ****

(تاريخ الإيداع 2022/ 3/7 . قبل للنشر في 2022/9/1)

□ ملخص □

يهدف هذا البحث إلى تصميم واجهة برمجية باستخدام برنامج الماتلاب، بالاعتماد على أساليب الذكاء الاصطناعي، للتنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط، مع الأخذ بعين الاعتبار أهم العوامل المسببة للتآكل الخارجي في أنابيب نقل النفط، وذلك بالاستفادة من بيانات القاشط الذكي Smart Pig، الذي تلجأ له شركات النفط في عمليات التفتيش الفني، والذي يعطي بيانات تفصيلية عن واقع التآكل الحالي في الأنابيب، حيث تم تطبيق الدراسة على أنبوب النفط الواصل بين مصبي بانياس وطرطوس النفطيين.

لقد بينت الدراسة أن استخدام هذه الواجهة للتنبؤ بالتآكل الخارجي تعطي نتائج عالية الدقة، حيث أظهرت النتائج تطابق كبير بين بيانات التنبؤ وبيانات التفتيش الفني ونسبة عالية جداً، مما يسمح لمشغلي خطوط الأنابيب بمعرفة المواقع الأضعف في هذه الأنابيب والأكثر عرضة للتآكل الخارجي بكل سهولة وبمنتهى السرعة، وبالتالي اتخاذ الإجراءات المناسبة من حماية مهبطية ووسائل عزل، مما يمنع حدوث التآكل، وما يتبعها من عمليات حفر وتوقف الإنتاج، مما يقلل الهدر في الوقت والتكاليف.

كلمات مفتاحية: التنبؤ، واجهة برمجية، ذكاء اصطناعي، تآكل خارجي، القاشط الذكي Smart Pig.

* أستاذ مساعد- كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

** أستاذ مساعد- كلية الهندسة الميكانيكية والكهربائية- جامعة البعث - حمص - سورية.

*** باحث -الهيئة العامة للاستشعار عن بعد - اللاذقية - سورية.

****طالب دكتوراه - كلية الهندسة الميكانيكية والكهربائية- جامعة تشرين - اللاذقية - سورية.

Designing a software interface to predict external corrosion in oil pipelines using artificial intelligence

Dr. Ahmad Salamah*
Dr. Hassan Hamed **
Dr. Rabie Mahmoud***
Tarek Aiashee****

(Received 7/3/ 2022 . Accepted 1/9/ 2022)

□ ABSTRACT

This research aims to design a programming interface using Matlab, relying on artificial intelligence methods, to predict the places of external corrosion in oil pipelines, taking into account the most important factors causing external corrosion, by benefiting of Smart Pig data, which oil companies resort to, In the technical inspections, which gives detailed data on the current state of corrosion, where the study was applied to the oil pipeline connecting Banias and Tartous estuaries.

The study showed that using this interface gives high-accuracy results, as showed a great match with the inspection data at a very high rate, which allows pipeline operators to know the weakest sites and the most vulnerable to external corrosion with ease and speed. Thus, appropriate measures are taken in terms of cathodic protection and others, which prevents the occurrence of corrosion, and the subsequent drilling and production stops, which reduces wastage in time and costs.

Keywords: prediction, programming interface, artificial intelligence, external corrosion, Smart Pig.

* Professor Assistant; Faculty of Mechanical & Electrical Engineering; Tishreen University; Lattakia: Syria.

** Professor Assistant; Faculty of Mechanical & Electrical Engineering; Al-Baath University; Homs: Syria

*** Researcher; General Organization of Remote Sensing; Coastal Branch; Lattakia: Syria.

****Doctoral student; Faculty of Mechanical & Electrical Engineering; Tishreen University; Lattakia: Syria.

مقدمة:

يعتبر التآكل سرطان المعادن، ولعله المشكلة الأكبر التي تواجه مشغلي خطوط أنابيب النفط والغاز، لما يترتب عنه من خسائر مادية كبيرة، نتيجة عمليات الصيانة واستبدال القطع المتآكلة، فضلاً عن توقف الإنتاج، بالإضافة إلى إمكانية حدوث انفجارات وكوارث تؤدي بحياة الكثيرين.

إن شبكات خطوط الأنابيب، التي تمتد لمسافات كبيرة عادةً ما تكون مطمورة داخل الأرض أو مغمورة، وبالتالي فإن عملية الكشف والتفتيش الفني لمعرفة حالتها عملية معقدة ودقيقة، وخاصة أثناء الاستمرار في تشغيلها، وإن توقف شبكة الخطوط عن العمل في نقل النفط ومشتقاته بقصد التفتيش، سوف يؤدي إلى خسائر كبيرة ولموسة في توقف المنظومة، وخاصةً عندما تكون مشتقات بترولية تمون مناطق سكنية وصناعية.

تعد عملية التنبؤ بالتآكل من أفضل الطرق المتبعة للوقاية منه، على الرغم من التعقيد الكبير لهذه العملية بسبب العوامل الكثيرة المسببة للتآكل بنوعيه الداخلي والخارجي، حيث يتجه العالم للاستفادة من عمليات النمذجة والذكاء الصناعي بطرقه المتعددة في التنبؤ بالتآكل، هناك العديد من الباحثين الذين طوروا نماذج للتنبؤ بمعدل التآكل في البنى المدفونة باستخدام الشبكات العصبونية الاصطناعية (Artificial Neural Networks) ANN، وحصلوا على نتائج جيدة، لقد استخدمت الشبكات العصبونية الاصطناعية بشكل كبير في مختلف مجالات الصناعة والتجارة، وذلك بفضل قدرتها على "التعلم بالمثال"، وتم تطبيقها من أجل إعطاء التنبؤات الصحيحة لبيانات غير مسبقة، وجعلها فعالة للغاية. وقد بذلت محاولات كثيرة لتطبيق هذه الطريقة للتنبؤ بالتآكل، حيث يمكن للشبكات العصبونية الاصطناعية تعلم سلوك المواد في مختلف مواقع التربة المسببة للتآكل والتنبؤ بسلوكها، ومع ذلك فإن الشبكات العصبونية الاصطناعية تجد بعض القيود، فعند تطبيقها دون الأخذ بعين الاعتبار الأخطاء في المصادر المحتملة، يتم استخلاص إجابات غير دقيقة من الشبكات العصبونية التي تميل إلى أن تكون مضللة للغاية في البحث عند استخدامها بدون حذر [1].

تقوم الشركة السورية لنقل النفط في بانياس، على فترات متباعدة من الزمن، بالاستعانة بشركات أجنبية تملك أجهزة ذكية لكشف التآكل، تسمى القاشط الذكي (Smart Pig)، يتم وضعها داخل الأنبوب، ويتم تحريكها عن طريق ضخ النفط ورائها، فتقوم بالكشف على كامل الأنبوب، وتعطي بيانات تفصيلية عن مقدار التآكل (الداخلي والخارجي) ونوعه وموقعه وعمقه، كما تقوم بإزالة العوالق عن جدار الأنبوب الداخلي التي يمكن أن تعيق أو تؤخر التدفق عبر خط الأنابيب، حيث يوجد 8 شركات في العالم تملك جهاز Smart Pig، تلجأ لهم الشركات النفطية على فترات متباعدة من الزمن لسبر خطوط الأنابيب، وكشف مواقع التآكل، وهي عملية مكلفة جداً وباهظة الثمن بالنسبة للشركات النفطية، فضلاً عن توقف الإنتاج خلال فترة السبر، وفي ظل الظروف الراهنة، كان من الصعب على الشركة السورية لنقل النفط، الاستعانة بهذه الشركات لكشف التآكل الحالي والمستقبلي، فكانت آخر عملية سبر في الخطوط عام 2009.

وبناءً على ما تقدم، فإن عملية التنبؤ بأماكن التآكل المستقبلية تعتبر حاجة ملحة لشركات النفط ومنها الشركة السورية لنقل النفط، نظراً لأن أجهزة التفتيش Smart Pig تقوم بتوصيف الحالة الراهنة لخطوط أنابيب النفط عند القيام بعملية التفتيش الفني، دون التطرق إلى أماكن التآكل المستقبلية، على الرغم من أنه يمكن للفنيين العاملين في مجال قراءة بيانات عملية التفتيش الفني، وضع تصور ذهني لعملية التآكل المستقبلية، لكن ذلك يكون محدود دون الاستعانة ببرمجيات توصف الحالة المستقبلية بدقة فائقة، كما أن هذه الأجهزة غير قادرة على تحديد أسباب التآكل، ولذلك فمن الضروري الاستعانة بتقنيات قادرة على التنبؤ بأماكن التآكل المستقبلية المحتمل حدوثها في أنابيب النفط.

الدراسة المرجعية:

هناك العديد من الباحثين الذين اتجهوا إلى استخدام أساليب الذكاء الاصطناعي في التنبؤ بأمكان التآكل في أنابيب نقل النفط والغاز، وتحليل أسباب الفشل، نذكر بعضها:

1- في عام 2012، قام Sumarni وآخرون بإجراء دراسة حول استخدام الشبكات العصبونية الاصطناعية للتنبؤ بمعدل التآكل في أنابيب الغاز، فتبين أن استخدام الشبكة العصبونية الاصطناعية (ANN) للتنبؤ بمعدل التآكل على خطوط أنابيب الغاز، يعطي نتائج عالية الدقة، كما يمكن تطوير النموذج الذي تم إنشاؤه بشكل دائم للحصول على مستوى عالٍ من الدقة، إذا كان النموذج مدعوماً ببيانات كافية من الحقول الميدانية [2].

2- في عام 2013، قامت Parvizsedghy و Zayed بإنشاء نموذج للتنبؤ بالفشل في أنابيب نقل النفط والغاز، وذلك بالاستفادة من تقنية التحليل اللاخطي للتنبؤ بفشل خطوط الأنابيب وإجراء محاكاة مونت كارلو، وقد أظهرت النتائج أداء جيد للنموذج عندما تكون الأنابيب في عمرها الأولي أو المتوسط [3].

3- في عام 2014، قام De Masi وآخرون بنشر بحث علمي في المؤتمر الأول لأنظمة المعلومات والنمذجة والمحاكاة، بعنوان نموذج الشبكة العصبونية للتنبؤ بالتآكل الداخلي لمقاطع الأنابيب، حيث تم اقتراح نموذج يهدف إلى التنبؤ الصحيح لمقدار المعدن المفقود ومعدل التآكل على طول الأنبوب، كما تم مناقشة حالة دراسية بناءً على بيانات حقلية حقيقية مأخوذة من عمليتي تفتيش فني للخط في عام 2002 و عام 2005، وتم مقارنة النموذج مع نموذج De Waard و NOROK، فتبين أن نموذج FNN (Fitting Neural Network) يتفوق على النماذج الحتمية القياسية، علماً أن مقدار الخطأ المطلق في النسبة المئوية للمتوسط الحسابي يعادل 30٪، لكن يمكن اعتبار ذلك نتيجة جيدة [4].

4- في عام 2014، قام Mohamed Layouni وآخرون بإجراء دراسة استقصائية عن تطبيق الشبكات العصبونية في تقييم سلامة خطوط أنابيب النفط والغاز، قاموا من خلالها بشرح أهم التقنيات المستخدمة في هذا المجال، وقد توصلوا إلى أنه في الحالات التي تتوفر فيها معرفة مسبقة عن شكل العيب، قد يكون من المناسب استخدام تقنية رسم الخرائط الفضائية، ومن الأفضل الاعتماد على الشبكات العصبونية، إذ أن نهج الشبكة العصبونية هو أكثر عمومية، ويمكن أن يكون أكثر ملاءمة للعمل في بيئة واقعية [5].

5- في عام 2015، قام Mazura Mat Din وآخرون بإنشاء نموذج شبكة عصبونية اصطناعية للتنبؤ بنمو تآكل أنابيب النفط والغاز، حيث قاموا بتصميم النموذج بالاعتماد على الزمن، وبناءً على بارامترات العيوب المستخلصة من بيانات التفتيش الفني للخط (ILI) (Internal Line Inspections) وقياسها بواسطة التحليل الإحصائي، وقد تبين أن النموذج المطور قادر على التنبؤ بعمق التآكل وطوله الذي يمكن استخدامه لحساب معدل التآكل أو النمو، كما توصلوا إلى أن نتائج هذه الدراسة يمكن أن تساعد مشغلي خطوط الأنابيب على التنبؤ بمصدقية بنية خط الأنابيب من حيث احتمالية الفشل أو تقدير عمر الأنابيب [6].

6- قام Alnaqi وآخرون في عام 2016، بإنشاء نموذج شبكة عصبونية للتنبؤ بالتآكل الداخلي للأنابيب البحرية الملحومة، حيث أخذوا البيانات لـ 42 نقطة مستمدة من البيانات التجريبية، تم تقسيمها لـ

30 نقطة لتدريب الشبكة العصبونية و 12 للاختبار، ولقد أثبت النموذج دقة كبيرة في عملية التنبؤ بنسبة 90%، حيث تم التحقق من صحة نتائج الاختبار لتأكيد نجاح نموذج ANN المطور للتنبؤ بمعدل التآكل وقد لوحظ الأداء الجيد. وبما أن نتائج النموذج أظهرت توافقاً جيداً مع معدلات التآكل التي تم الحصول عليها تجريبياً، فإنه يمكن تطبيقها على نطاق واسع في دراسات التآكل [7].

7- في عام 2016، قام Bolajzi و Nosa بتصميم نموذج لحساب معدل التآكل في الأنابيب المدفونة باستخدام الشبكات العصبونية الاصطناعية المعدلة ومحاكاة مونتني كارلو. البارامترات المقاسة هي PH التربة، درجة حرارة التربة، درجة حرارة الجو لترب مختلفة مأخوذة من موقع إنتاج النفط في ولاية دلتا في نيجيريا. تم حساب معدل التآكل لكل سيناريو باستخدام طريقة الوزن المفقود، وقد أعطى النموذج نتائج عالية الدقة [1].

8- قام Oladipo وآخرون، في عام 2017، بتقييم التآكل لبعض الأنابيب المعدنية المدفونة باستخدام خوارزمية الشبكات العصبونية، كانت بيانات الإدخال هي درجة حرارة التربة، ودرجة حرارة المحيط المباشر، ودرجة حموضة (PH) التربة في حين أن بيانات الخرج كانت الوزن المفقود للمعدن، فتوصلوا إلى أن درجات حرارة التربة والظروف المحيطة ودرجة الحرارة المحيطة مباشرة لها تأثير أقوى على معدل تغلغل التآكل في حين أن درجة الحرارة المحيطة المباشرة وقيمة درجة الحموضة (PH) مجتمعة كان تأثيرها أقل على معدل تغلغل التآكل [8].

9- ونظراً لأهمية الشبكات العصبونية في مجال التنبؤ، قام Obaseki وآخرون، في عام 2017، بإنشاء نموذج محاكاة شبكة عصبونية اصطناعية للتنبؤ بمعدل تآكل أنابيب نقل النفط والغاز في دلتا النيجر النيجيرية، حيث أخذوا عينات من البيانات التشغيلية لـ 60 خط من خطوط أنابيب نقل النفط والغاز، وقد أظهرت النتائج أن التنبؤات بمحاكاة ANN التي طورت في هذه الدراسة والتي تقارب معدلات التآكل الفعلية بأكثر من 99% أكبر من تلك التي تستخدمها المحاكاة التقليدية المستندة إلى De-Waard والتي تستخدمها حالياً معظم شركات النفط والغاز النيجيرية [9].

10- في عام 2018، قامت Dr. Hanan وآخرون بتصنيف تسرب النفط بناء على الذكاء الصناعي، حيث تم إنشاء نموذج لشبكة عصبونية مع خوارزمية الانتشار الخلفي لاكتشاف التسرب في خط أنابيب النفط لتصنيف حجم وموقع التسرب، وتبين من خلال هذه الدراسة أن جميع نماذج ANN المطورة في العمل الحالي دقيقة في تصنيف التسرب الموجود وتقدير حجمه، وبالتالي يمكن استخدام ANN بكفاءة في تطوير نموذج رياضي يمكن استخدامه كمصنف للبيانات التي قد تكون متاحة للحقل الصناعي في الظروف العادية أو المعطوية من أنابيب النفط والغاز [10].

11- وفي عام 2018 أيضاً، قام Wang وآخرون بإنشاء خوارزمية محسنة للتنبؤ بالتآكل في الأنابيب غير الملحومة بناء على امتداد الشبكات العصبونية، تم استخدام لغة بايثون لتطبيق خوارزمية الشبكة العصبونية، وتم بناء الشبكة بناء على ثلاث عوامل رئيسية مسببة للتآكل وهي تركيز H_2S وتركيز CO_2 وتركيز شوارد الكلوريد Cl^- وتم تدريب الشبكة على 400 مجموعة من البيانات المرتبطة بالتآكل، يمكن ملاحظة أن النموذج التي تم التوصل له لا يمتلك مزايا النموذج البسيط، والتقارب السريع، وخطأ التدريب الصغير فحسب، بل له أيضاً قيمة هندسية جيدة للتعرف على الأنماط، وتشخيص الأخطاء، وتصنيف المجموعات مع سرعة تدريب أفضل، وما إلى ذلك، والتي تشبه مشكلة التنبؤ بنظام تعقيد متعدد الأهداف ومتعدد المعايير [11].

12- ونظراً لأهمية بيانات التفتيش الفني في عملية التنبؤ، قام Huan Liu وآخرون في عام 2019 بإجراء دراسة بعنوان مطابقة بيانات التفتيش الفني لخطوط الأنابيب من أجل خصائص التآكل، حيث أكدوا على أن استراتيجية الإدارة السليمة الاستباقية تعتمد على القدرة على التنبؤ بمعدل نمو التآكل مع مرور الوقت، حيث قاموا بدراسة نماذج التعلم الآلي الفردية والمجمعة. وتوصلوا إلى أنه يمكن تحقيق مطابقة دقيقة مع طريقة التعلم المجمعة مما يساهم بشكل أكبر في عملية الإدارة السليمة لخطوط الأنابيب وتحليل المخاطر [12].

من خلال الدراسات المرجعية السابقة نجد أن تقنيات الذكاء الصناعي باتت تستخدم كثيراً في عملية التنبؤ، ويات تطوير النماذج المستخدمة في عملية التنبؤ هو الهم الشاغل لكثير من الباحثين، والكثير منهم استخدم تقنية الشبكات العصبونية واستفاد من بيانات التفتيش الفني لكنهم لم يأخذوا عدداً كافياً من العوامل المسببة للتآكل فكانت نماذجهم ينقصها الدقة، ومن هنا كان بحثنا بأخذ أكبر عدد ممكن من العوامل المسببة للتآكل الخارجي، للوصول إلى عملية تنبؤ بغاية الدقة والتحقق من صحتها من خلال بيانات التفتيش الفني Smart Pig.

مشكلة البحث:

يعتبر تآكل المعادن من أحد أهم المشاكل في العمليات الصناعية، ولأخذ الحذر والحيطه وتجنب الوقوع ببرائثه في مجال مهم واقتصادي كمجال الصناعات النفطية وبعد الاطلاع على الدراسات المرجعية السابقة أتت مشكلة البحث الآتية:

- كيف يمكن التنبؤ بأماكن التآكل الخارجي المستقبلية الأكثر خطورة في أنبوب نقل النفط؟ وما هو الدور الذي تلعبه عملية النمذجة في هذا المجال؟
- ينتج عن هذه المشكلة الإشكاليات التالية:
- كيف يمكن الاستفادة من بيانات Smart Pig في عملية التنبؤ؟ وما هو الدور الذي تلعبه الشبكات العصبونية في هذا المجال؟
- كيف يمكن التحقق من صحة عملية التنبؤ الناتجة؟

فرضية البحث:

سنفترض في هذا البحث أن استخدام أساليب الذكاء الاصطناعي سيساعد في تصميم واجهة برمجية للتنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط.

أهمية البحث وأهدافه:

يهدف هذا البحث إلى تصميم واجهة برمجية باستخدام برنامج الماتلاب بالاعتماد على أساليب الذكاء الاصطناعي، للتنبؤ بالتآكل الخارجي في أنابيب نقل النفط، مع الأخذ بعين الاعتبار أهم العوامل المسببة للتآكل الخارجي لأنابيب نقل النفط، وذلك بالاستفادة من بيانات التفتيش الفني Smart Pig، مما يسمح بأخذ كافة الاحتياطات اللازمة ومنع حدوث التآكل والتسرب، ويساهم في تحقيق عملية الإدارة السليمة لأنابيب النفط، ويقلل التكاليف ويمنع وقوع الكوارث، كما أنه يقلل الحاجة إلى عمليات السبر والتفتيش الفني التي تتطلب معدات وأموال كثيرة، بالإضافة إلى أنه يطرح تقنية علمية جديدة، تعتمد على استخدام برمجيات متطورة، باتت تستخدم كثيراً في عصرنا الحالي.

مواد البحث:

البيانات التي تعطيها أجهزة التفتيش الفني (Smart Pig).

برنامج MATLAB.

برنامج الاكسل Excel.

الشبكات العصبونية وبنيتها الهندسية:

يعرف الذكاء الاصطناعي بأنه سلوك وخصائص معينة تتسم بها البرامج الحاسوبية تجعلها تحاكي القدرات الذهنية البشرية وأنماط عملها، ومن أهم هذه الخصائص القدرة على التعلم والاستنتاج وردّ الفعل على أوضاع لم تبرمج في الآلة، كما يعرف بأنه محاكاة عمل الجسم البشري أو الظواهر الطبيعية، ومحاولة برمجتها لخدمة أهداف معينة في مجالات الحياة كافة.

وتعد الشبكات العصبونية أحد أساليب الذكاء الاصطناعي، والتي تعرف على أنها نظام حاسوبي لمعالجة المعلومات يحاكي عمل الخلايا العصبية الطبيعية بحيث يكون قادر على التعلم والاستنتاج واتخاذ القرار، لها العديد من الأنواع والتصنيفات، من أشهرها الشبكات العصبونية الاصطناعية ANN (Artificial Neural Networks)، والتي لها البنية الهندسية الآتية:

- المدخل Inputs: البيانات التي يتم إدخالها إلى الشبكة.
- الخرج (الاستجابة) outputs: النتائج التي يتم الحصول عليها.
- الطبقة: مجموعة من العصبونات.
- العصبون: المكون الأساس في الشبكة العصبونية.
- الأوزان: مهمتها الأساسية تضخيم إشارة الدخل أو تقليلها، أي تعديل قيمتها، وتمثل مبدأ السيالة العصبية في الخلية الطبيعية (الجزء التي ستتعلم الشبكة من خلاله).
- تابع التفعيل: الشروط التي تحدد متى تعطي الخلية العصبونية قيمة على خرجها، وماهي هذه القيمة

[13].

النتائج والمناقشة:

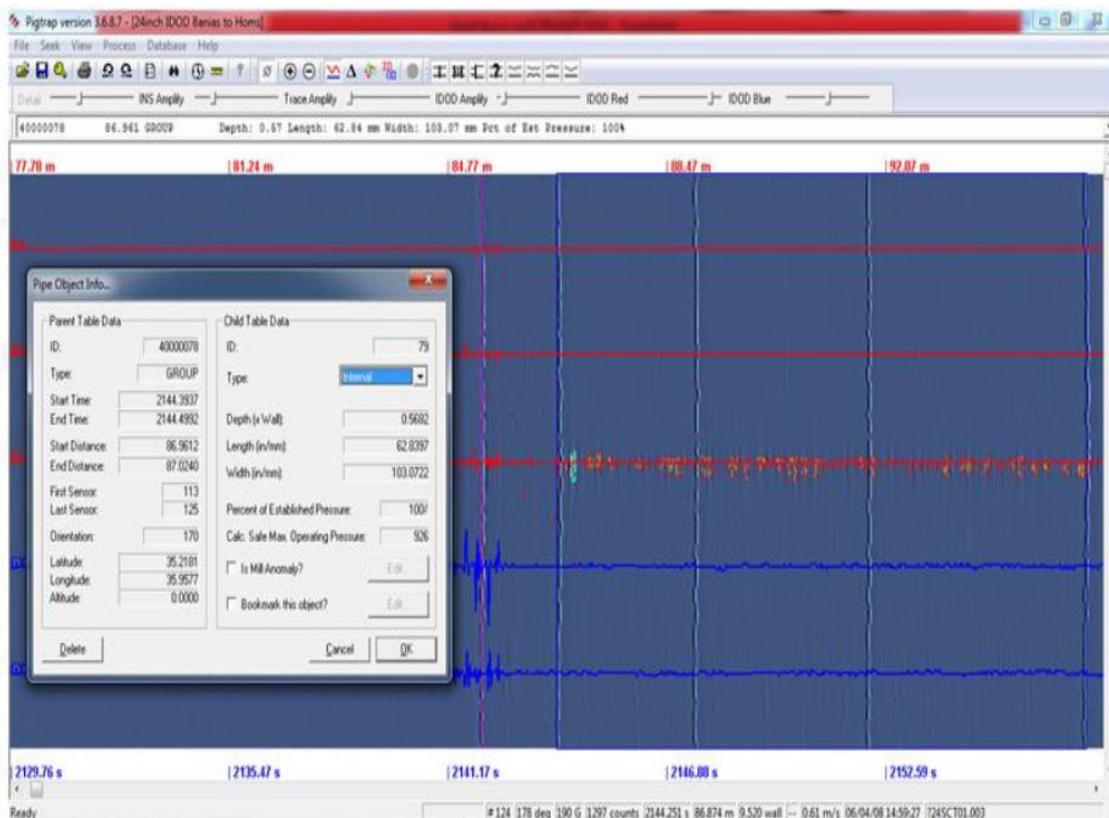
حالة دراسية: أنبوب نقل النفط الواصل بين مصبي بانياس وطرطوس النفطيين

حقل الدراسة:

لقد تم في هذه الدراسة، تصميم واجهة برمجية حاسوبية بالاعتماد على شبكة عصبونية أمامية باستخدام الماتلاب، للتنبؤ بالتآكل الخارجي في أنبوب نقل النفط الواصل بين مصبي بانياس وطرطوس النفطيين. إن طول خط الأنابيب الواصل بين مصبي بانياس وطرطوس النفطيين بحدود 35 كم، وهو مدفون في التربة على عمق 1 متر، وقطره 24 إنش، وهو مصنوع من مجموعة من الأجزاء طول كل جزء منها حوالي 12 متر. الأنابيب مصمّم حسب مواصفات ASTM، وهو من الفولاذ الكربوني له التّركيب الكيميائي التالي:

ASTM Spec	طريقة صنع الأنابيب	الكربون (C)	المنغنيز (Mn)	الفسفور (P)	الكبريت (S)
5L B	لحام	0.26	1.15	0.03	0.03
5L X42	لحام	0.28	1.25	0.03	0.03
5L Gr X46, X52	لحام على البارد	0.28	1.25	0.03	0.03

لقد قامت الشركة السورية لنقل النفط في عام 2009 بالاستعانة بشركة أجنبية، لإجراء عملية كشف وتفتيش فني على الأنابيب بواسطة جهاز Smart Pig، وتم تزويد الشركة بالبيانات المطلوبة بعد عملية المسح والكشف على طول الأنبوب. فتم تزويد الشركة بكامل بيانات نقاط التآكل الداخلي والخارجي للأنبوب المدروس، وتشمل بيانات كاملة عن حجم بقعة التآكل ومدى خطورتها وموقعها وبعدها عن بداية الأنبوب. ويظهر الشكل (1) البيانات التي قدّمها جهاز التفتيش الفني Smart Pig عملية مسح أنبوب نقل النفط الواصل بين مصبي بانياس وطرطوس النفطيين في عام 2009، وهي آخر عملية تفتيش فني قامت به الشركة السورية لنقل النفط.



الشكل (1): البيانات التي تعطيها أجهزة التفتيش الفني Smart Pig

حيث يظهر في الشكل (1) مجسم الأنبوب باللون الأزرق تتوضع عليه تعرجات صغيرة بلون برتقالي تشكل بؤر التآكل، وعند النقر على أي منها تظهر بيانات التآكل الخاصة بها كما هو موضح في الشكل. كما تم تزويد الشركة بتقرير فني يوضح كافة نقاط التآكل مع كامل بياناتها، كما هو موضح في الشكل (2). حيث شملت البيانات رقم الجزء الخاضع للحام من الأنبوب Girth Weld، بعد نقطة التآكل عن بداية الأنبوب بالمتر (Absolute Distance (m)، بعد نقطة التآكل عن بداية الجزء الخاضع للحام من الأنبوب (Relative Distance (m)، وطول الوصلة (الجزء الخاضع للحام) بالمتر (Joint length (m)، نوع السمة التي تعرف إليها جهاز التفتيش الفني (Feature Type، وتعريف هذه السمة (Feature Identification، نوع التآكل (Surface Location، وتصنيفه (Anomaly Class، وطوله (Length (mm)، وعرضه (Width (mm)، والنسبة المئوية لمدى خطورته (Peak Depth (%، وموقعه على الأنبوب (Orientation hh:mm، ونوع الأنبوب (Pipe Type، ومعامل الإصلاح ERF.

Pipeline Tally

Girth Weld	Absolute Distance (m)	Relative Distance (m)	Joint length (m)	Nominal Wall (mm)	Feature Type	Feature Identification	Anomaly Class	Surface Location	Length (mm)	Width (mm)	Peak Depth (%)	Orientation h:mm	ERF	Pipe Type	Comments
210	23.855	0.051	9.8	9.52	GROUP	-	PITT	EXT	27	40	19	05:28	0.732	ERW	
210	24.095	0.290	9.8	9.52	GROUP	-	PITT	EXT	21	24	16	05:10	0.730	ERW	
210	25.986	2.181	9.8	9.52	LOCATION	Bend up	-	-	-	-	-	-	-	ERW	
210	33.616	-	3.8	9.52	WELD	-	-	-	-	-	-	-	-	ERW	
220	37.449	-	10.8	9.52	WELD	-	-	-	-	-	-	-	-	ERW	
230	44.835	7.385	10.8	9.52	GROUP	-	GENE	INT	66	63	19	05:34	0.750	ERW	
230	45.011	7.562	10.8	9.52	GROUP	-	PITT	INT	30	40	14	05:40	0.731	ERW	
230	45.164	7.714	10.8	9.52	GROUP	-	GENE	INT	81	79	15	05:40	0.749	ERW	
230	45.436	7.987	10.8	9.52	GROUP	-	PITT	INT	27	48	20	05:38	0.732	ERW	
230	45.613	8.163	10.8	9.52	GROUP	-	PITT	INT	12	16	11	05:40	0.728	ERW	
230	45.637	8.187	10.8	9.52	GROUP	-	CISL	INT	9	16	11	05:40	0.728	ERW	
230	45.828	8.379	10.8	9.52	GROUP	-	PITT	INT	18	24	11	05:32	0.729	ERW	
230	46.462	9.013	10.8	9.52	GROUP	-	GENE	INT	57	32	18	05:32	0.744	ERW	
230	46.549	9.100	10.8	9.52	GROUP	-	CISL	INT	9	16	15	05:34	0.728	ERW	
230	46.615	9.166	10.8	9.52	GROUP	-	PITT	INT	24	24	18	05:38	0.731	ERW	
230	46.684	9.234	10.8	9.52	GROUP	-	PITT	INT	12	16	11	05:38	0.728	ERW	
230	48.219	-	0.7	9.52	WELD	-	-	-	-	-	-	-	-	ERW	
240	48.219	0.000	0.7	9.52	PIPE	Change in Wall Thickness	-	-	-	-	-	-	-	ERW	
240	48.940	-	1.4	12.70	WELD	-	-	-	-	-	-	-	-	ERW	

الشكل (2): البيانات التي تعطيها أجهزة التفتيش الفني Smart Pig

مرحلة إعداد البيانات:

يعتبر التآكل الخارجي من الأخطار التي تهدد أنابيب نقل النفط، وهو يتأثر بمجموعة من العوامل التي تزيد من خطر تآكل الأنابيب، وهي:

طرق المواصلات ذات الاتجاه الواحد - السكك الحديدية - خطوط التوتر العالي 320 kv - خطوط التوتر المتوسط 66 kv - المسيلات المائية (الأنهار والينابيع) - الخصائص الفيزيائية والكيميائية للتربة. لذلك عند مد خطوط أنابيب نفط جديدة يوصى بأن يكون لهذه الخطوط حرم حماية، 500 متر من كل جانب، للابتعاد قدر المستطاع عن تأثير العوامل السابقة، حيث كلما كان الأنبوب قريب من تأثير العوامل السابقة، كان أكثر عرضة للتآكل، لذلك تم الاستفادة من بيانات Smart Pig وتم إضافة بعد كل نقطة منها عن أقرب طريق أو سكة حديدية أو خط توتر عالي ومتوسط بالإضافة إلى الأنهار والينابيع، وتم إضافة خصائص التربة الفيزيائية والكيميائية لكل نقطة وهي:

قيمة الـ PH - الناقلية الكهربائية للتربة - الملوحة - تركيز الكربونات - تركيز الكلوريد - نسبة الرطوبة.

حيث تم قياس المسافات بين نقاط التآكل والعوامل السابقة عن طريق نظام المعلومات الجغرافي (GIS)، والميزات التي يتيحها هذا النظام، وبالنسبة لخصائص التربة، تم أخذ مقاطع من التربة من عدة مواقع في منطقة الدراسة، وتحليلها وإضافة خصائصها إلى بيانات Smart Pig، عن طريق نظام الـ GIS [14].

ويظهر الشكل (3) البيانات لكل نقطة من نقاط التآكل المأخوذة من بيانات Smart Pig بعد أن أضيف لها العوامل المسببة للتآكل الخارجي حيث تم إعدادها على برنامج الاكسل.

	M	L	K	J	I	H	G	F	E	D	C	B			
	Cl mm 100g	تذكر الكوبد	CO3 mm 100g	كبر الكربونات	الطوحة	EC ds m	النقلية الكهربائية	PH	distance_river	distance_spring	distance_elect320	distance_elect66kv	distanc_railways	distanc_road	Nominal_Wall mm
0.09	27	قليل الملوحة	0.95	7.69	485.2006013	580.249995	1611.615509	84.0693696	1711.664688	191.2530514	12.7	9.52			
0.03	22	قليل الملوحة	0.94	7.62	448.7958258	549.3054462	1617.474202	82.98985468	1728.443286	155.9184207	7.92	4			
0.03	22	قليل الملوحة	0.94	7.62	423.6238491	528.3159172	1621.526768	82.24300885	1740.320293	131.8512364	7.92	6			
0.03	22	قليل الملوحة	0.94	7.62	412.3654461	519.0484843	1623.339819	81.90885201	1745.637582	121.24036	7.92	7			
0.03	22	قليل الملوحة	0.94	7.62	378.7647626	491.8836501	1628.753268	80.91124079	1761.513857	90.55446428	7.92	8			
0.03	22	قليل الملوحة	0.94	7.62	35.95584222	302.5500169	1684.544178	74.50644906	1847.554548	14.30328365	7.92	9			
0.03	22	قليل الملوحة	0.94	7.62	228.7634856	508.9144876	1756.953905	196.1957933	1637.353607	30.38031826	7.92	10			
0.03	22	قليل الملوحة	0.94	7.62	262.3438472	551.416802	1765.505533	247.8585612	1607.115597	28.11911355	7.92	11			
0.03	22	قليل الملوحة	0.94	7.62	337.3467038	636.2529945	1783.263771	347.1597806	1550.136265	39.83570098	7.92	12			
0.03	22	قليل الملوحة	0.94	7.62	378.2542278	678.3666053	1766.036377	396.0368383	1523.978382	48.37533124	7.92	13			
0.03	22	قليل الملوحة	0.94	7.62	411.1647704	712.3005869	1749.879635	434.7096238	1503.281584	55.94956811	7.92	14			
0.03	22	قليل الملوحة	0.94	7.62	499.8559673	803.1796329	1708.997914	536.8495857	1448.98417	70.62108283	7.92	15			
0.04	25	قليل الملوحة	0.94	7.63	979.8838451	1290.559226	1494.868107	582.8829787	1165.204256	169.7186752	7.92	16			
0.04	25	قليل الملوحة	0.94	7.63	1045.604438	1357.120688	1466.561129	576.9218707	1128.21632	183.520699	7.92	17			
0.04	25	قليل الملوحة	0.94	7.63	1118.614001	1430.852405	1435.34452	570.3007143	1087.412562	198.763657	7.92	18			
0.04	25	قليل الملوحة	0.94	7.63	1231.0638	1544.024269	1387.799636	559.9436892	1025.185877	220.6645504	7.92	19			
0.04	25	قليل الملوحة	0.94	7.63	1337.337324	1589.011366	1343.06357	550.4046969	966.6549547	242.9580184	7.92	20			
0.04	25	قليل الملوحة	0.94	7.63	1362.599357	1563.6792	1332.443982	549.3152429	952.7659388	248.3548528	7.92	21			
0.04	25	قليل الملوحة	0.94	7.63	1420.263825	1506.005395	1308.235229	551.3988207	921.1057605	260.3817119	7.92	22			
0.04	25	قليل الملوحة	0.94	7.63	1453.582148	1085.067942	1131.146386	602.0313663	686.7162882	338.7670026	7.92	23			
0.06	27	قليل الملوحة	0.95	7.64	770.232002	267.2504092	904.146166	142.6783997	247.4122285	300.4079973	7.92	24			
0.06	27	قليل الملوحة	0.95	7.64	573.8712531	61.26162371	953.2146489	90.17470027	143.4416535	179.2642895	7.92	25			
0.06	27	قليل الملوحة	0.95	7.64	368.4150974	230.8013698	1058.951848	74.61686927	63.281126	101.5463021	7.92	26			
0.06	27	قليل الملوحة	0.95	7.64	117.6801485	507.2967504	1150.005395	74.16241469	34.8164443	65.99770829	7.92	27			
0.06	27	قليل الملوحة	0.95	7.64	59.88342072	578.1128738	1194.381455	97.63641808	58.4095795	90.0478738	7.92	28			
0.06	27	قليل الملوحة	0.95	7.64	50.29608571	589.0899577	1201.49642	101.5532755	62.33496191	94.08494761	7.92	29			
0.06	27	قليل الملوحة	0.95	7.64	43.64806936	596.2712583	1206.430075	104.2693095	65.0569074	96.88434182	7.92	30			

الشكل (3): بيانات Smart Pig بعد أن أُضيف لها العوامل المسببة للتآكل الخارجي

مرحلة بناء الشبكة العصبونية:

تم في هذا البحث تصميم شبكة عصبونية ذات تغذية أمامية (Feed Forward Neural Network) مكونة من 4 طبقات مخفية (Hidden Layer)، و 15 عصبون (Neuron)، و 0.1 كمعدل للتعلم (Learning Rate)، مع عدد مرات تكرار التدريب 1000 مرة (Epoch). لملائمتها لعدد البيانات المدخلة، حيث تم الاستفادة من بيانات التفتيش الفني Smart Pig، واعتبار نتائجه كخرج للشبكة. والشكل (4) يوضح المدخلات في الشبكة العصبونية، وعدد الطبقات المخفية والمخرجات حيث تم اعتبار الدخل للشبكة:

- 1- سماكة جدران الأنبوب (Nominal Wall (mm)).
- 2- البعد عن طرق المواصلات ذات الاتجاه الواحد (Distance of Road (m)).
- 3- البعد عن السكك الحديدية (Distance of Railways (m)).
- 4- البعد عن خطوط الكهرباء ذات التوتر المتوسط (66kv) (Distance of Elect66kv (m)).
- 5- البعد عن خطوط الكهرباء ذات التوتر العالي (320kv) (Distance of Elect320kv (m)).
- 6- البعد عن الأنهار (Distance of River (m)).
- 7- البعد عن ينابيع المياه (Distance of Spring (m)).
- 8- درجة حموضة التربة (PH).
- 9- الناقلية الكهربائية للتربة ((Electrical Conductivity (EC) (ds/m)).
- 10- درجة الملوحة (Salinity).
- 11- تركيز الكربونات في التربة ((CO₃ (mm/100g)).

-12 تركيز الكلوريد في التربة (CL (mm/100g)).

-13 رطوبة التربة (Humidity).

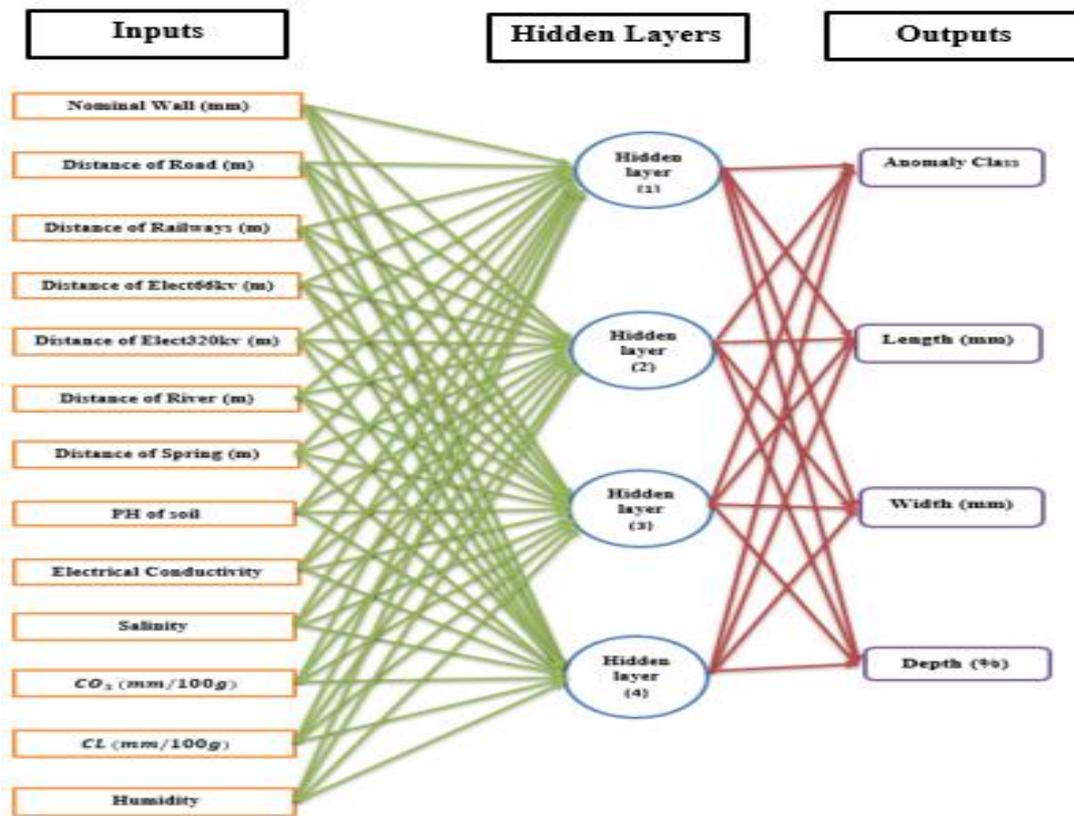
وتم اعتبار خرج الشبكة:

-1 تصنيف التآكل (Anomaly Class).

-2 طول التآكل (Length (mm)).

-3 عرض التآكل (Width (mm)).

-4 عمق التآكل (Depth (%)).



الشكل (4): عدد المدخلات في الشبكة العصبونية، وعدد الطبقات المخفية وعدد المخرجات

مرحلة تدريب الشبكة واختبار النتائج:

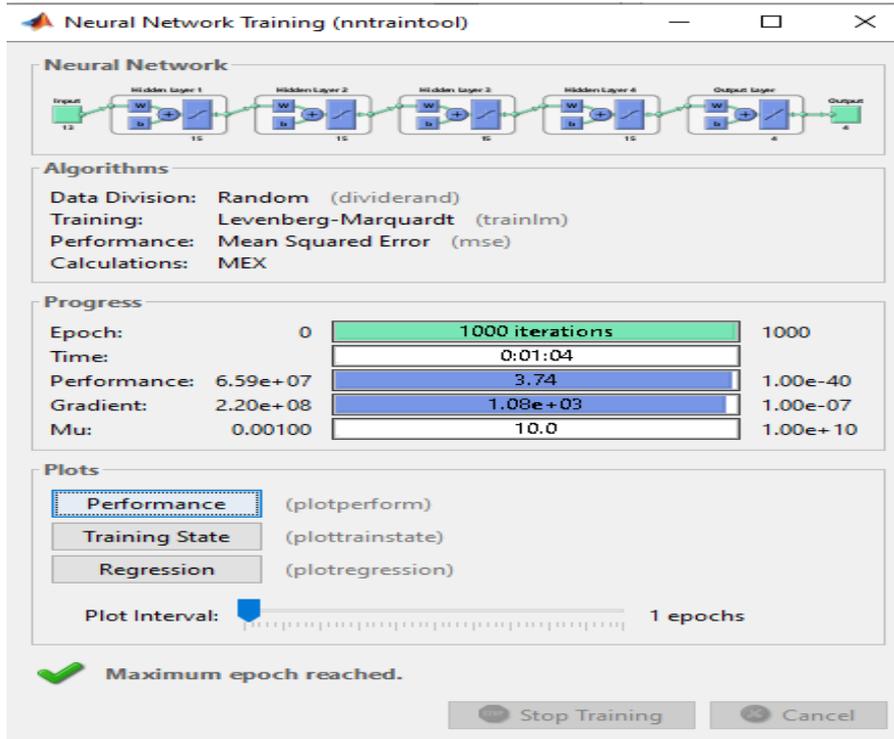
تم تقسيم بيانات التنقيش الفني إلى قسمين:

- القسم الأول: وعددها 80 نقطة تآكل خارجي، تم سبرها على أنبوب النفط، أثناء عملية التنقيش الفني بواسطة القاشط الذكي Smart Pig، تم استخدامها لتدريب الشبكة العصبونية، ولقد تم اختيارها في مواقع متعددة على طول الأنبوب، وفي أنواع مختلفة التربة، بحيث تشمل جميع العوامل المسببة للتآكل الخارجي.

• القسم الثاني: عددها 25 نقطة تآكل خارجي، تم استخدامها لاختبار النتائج التي حصلنا

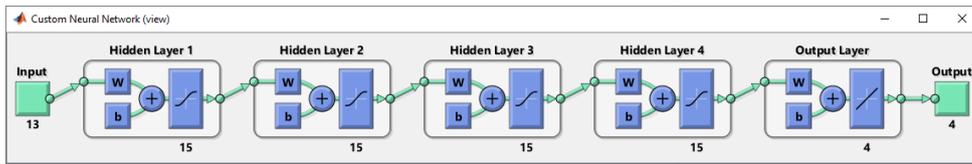
عليها بعد عملية بناء الشبكة العصبونية وتدريبها على بيانات القسم الأول.

تم تطبيق الشبكة العصبونية المصممة وتدريبها للتنبؤ بالتآكل الخارجي على برنامج MATLAB، ويوضح الشكل (5) إتمام عملية التدريب للشبكة العصبونية.



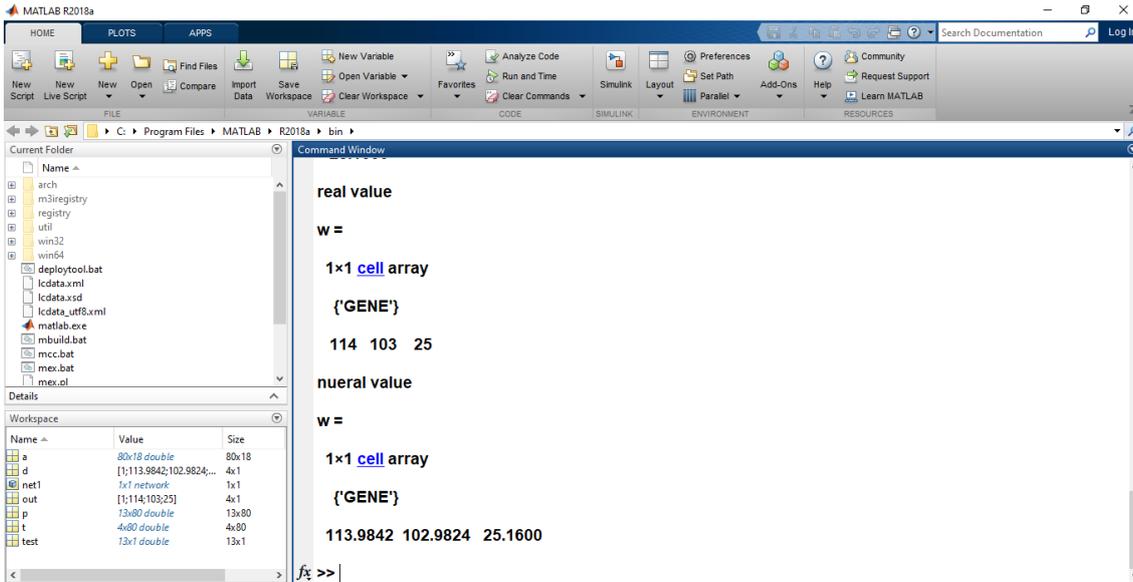
الشكل (5): إتمام عملية التدريب للشبكة العصبونية

حيث يظهر في هذا الشكل أنه تم تكرار عملية التدريب 1000 مرة، خلال زمن 1 دقيقة و 4 ثوانٍ، وبأداء جيد ضمن الحدود المطلوبة. ويظهر الشكل (6) عدد المدخلات في الشبكة العصبونية، وعدد الطبقات الخفية وعدد المخرجات أثناء عملية التدريب.



الشكل (6): عدد المدخلات في الشبكة العصبونية، وعدد الطبقات الخفية وعدد المخرجات أثناء عملية التدريب

وكانت نتائج الاختبار مطابقة تقريباً لنتائج التفتيش الفني، حيث يظهر الشكل (7) نتائج الاختبار لأحد نقاط التآكل باستخدام الشبكة العصبونية.

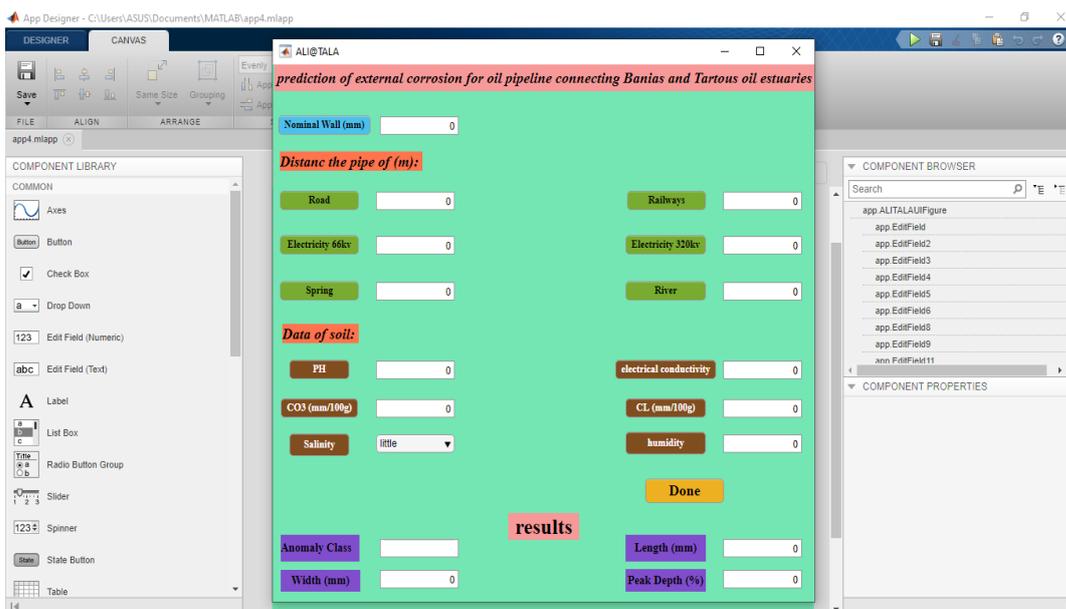


الشكل (7): نتائج الاختبار لأحد نقاط التآكل باستخدام الشبكة العصبونية

حيث يظهر الشكل (7) نتائج مقارنة بشكل كبير وبنسبة عالية جداً بين بيانات Smart Pig ونتائج التنبؤ باستخدام الشبكات العصبونية، حيث تطابقت النتائج من حيث نوع التآكل وهو GENE، وكان طول رقعة التآكل في بيانات Smart Pig هو 114 mm، وعرضها 103 mm، وعمقها 25% من سماكة جدار الأنبوب، في حين كان طول رقعة التآكل في نتائج التنبؤ باستخدام الشبكة العصبونية هو 113.98mm، وعرضها 102.98mm، وعمقها 25.16%.

تصميم الواجهة البرمجية وتجربتها:

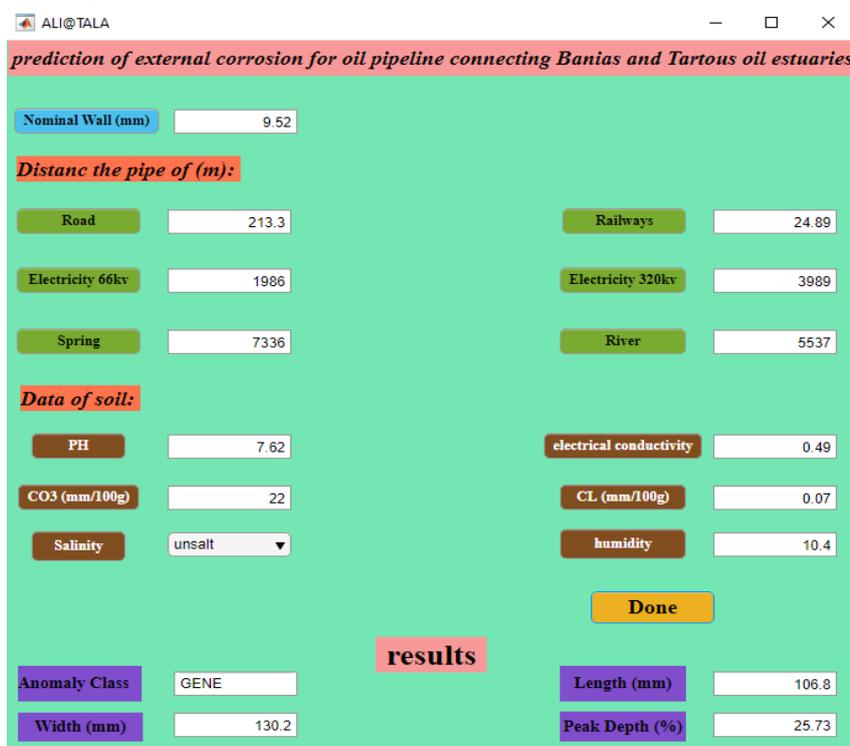
تم تصميم الواجهة البرمجية على برنامج الماتلاب عن طريق App Designer، بناءً على الكود البرمجي السابق المستخدم في بناء الشبكة العصبونية، والتي تم تدريبها واختبار صحتها، فشملت الواجهة بيانات الدخل والتي ضمت: سماكة جدران الأنبوب (Nominal wall (mm)، وكافة العوامل المسببة للتآكل الخارجي، حيث تم تقسيمها إلى قسمين هما: البعد عن الأنبوب، وبيانات التربة. حيث يقوم المستخدم بإدخال البيانات إلى الواجهة البرمجية والنقر على DONE، فيقوم البرنامج بإعطاء الخرج الذي يشمل نوع التآكل الخارجي الناتج عام GENE أو نقري PITTING أو أي نوع آخر، بالإضافة إلى طول وعرض وعمق (مدى خطورة) التآكل المتوقع حدوثه. ويظهر الشكل (8) الواجهة البرمجية التي تم تصميمها للتنبؤ بالتآكل الخارجي.



الشكل (8): الواجهة البرمجية التي تم تصميمها للتنبؤ بالتآكل الخارجي

كما تم تصميم الواجهة بحيث تعمل حتى ولو كان هناك نقص في أحد بيانات الدخل، حيث يقوم المستخدم بوضع القيمة صفر مكانها فيقوم البرنامج بتجاهلها، ويعطي قيم الخرج بناءً على بيانات الدخل المتوفرة. تشغيل الواجهة البرمجية واختبار صحتها:

تم اختبار صحة الواجهة البرمجية بالاعتماد على بيانات Smart Pig، فتم اختيار أحد النقاط وإدخال بياناتها إلى الواجهة البرمجية، ثم تم تشغيل الواجهة بالنقر على Done، فأعطت تنبؤ بحدوث التآكل الخارجي وبشكل مطابق بنسبة كبيرة لبيانات Smart Pig، ويظهر الشكل (9) البيانات المدخلة إلى الواجهة البرمجية ونتائج التنبؤ.



الشكل (9): البيانات المدخلة إلى الواجهة البرمجية ونتائج التنبؤ

حيث يظهر في الواجهة أن نتائج التنبؤ: طول التآكل 106.8 mm، وعرض منطقة التآكل 130.2mm، وعمق التآكل 25.73%، ونوع التآكل عام GENE.

وهي نتائج مطابقة إلى حد كبير لبيانات Smart Pig التي كانت: طول التآكل 107 mm، وعرض منطقة التآكل 131 mm، وعمق التآكل 26%، ونوع التآكل عام GENE. ويظهر الشكل (10) نتائج Smart Pig.

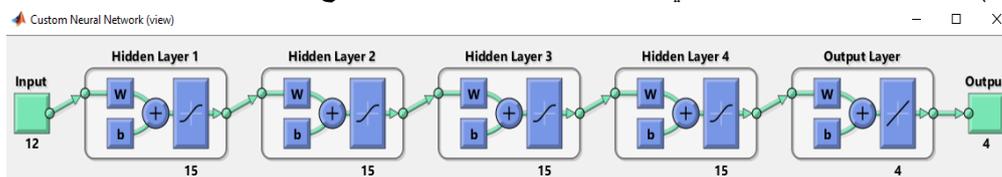
Depth	Length	Anomaly Class	...
27	135	GENE	...
28	19	GENE	...
26	120	GENE	...
29	487	PITT	...
27	138	GENE	...
26	131	GENE	...
18	820	GENE	...
19	103	PITT	...
27	136	GENE	...
30	132	GENE	...
19	103	GENE	...
20	71	GENE	...
29	139	CIGR	...
32	170	AKGR	...
28	139	GENE	...
58	1840	8650	PITT
29	131	180	PITT
27	129	109	PITT
28	67	226	CIGR
30	152	133	GENE
27	138	104	PITT
74	2070	8538	GENE
28	135	118	GENE
30	60	288	GENE

الشكل (10): نتائج Smart Pig

كما تم تجريب الواجهة البرمجية المصممة في حال كانت أحد البيانات غير موجودة، في هذه الحالة تم تصميم الواجهة بأن نضع مكان البيانات الناقصة 0، فتم تشغيل الواجهة على النقطة السابقة نفسها، فتم إدخال بياناتها إلى الواجهة ولكن بعد تجاهل البعد عن الينابيع Spring، وتم الحصول على النتائج التي تظهر في الشكل (11).

الشكل (11): تشغيل الواجهة البرمجية في حال عدم توافر أحد البيانات

ونلاحظ من الشكل (11) أن الواجهة البرمجية أعطت تنبؤ بحدوث تآكل خارجي عند النقطة السابقة بنتائج قريبة جداً من النتائج الحقيقية، ولكن بدقة أقل نوعاً ما بنسبة ضئيلة جداً من النتائج التي حصلنا عليها في حال توافر جميع البيانات، كما نجد أن الواجهة البرمجية قد أهملت البيانات الناقصة، وتعاملت مع باقي المدخلات فقط، فيظهر في الشكل (12) أن عدد المدخلات هو 12 في حين كان 13 عندما توافرت جميع البيانات.



الشكل (12): عدد المدخلات في الواجهة البرمجية في حال عدم توافر أحد البيانات

حيث نجد في الشكل (12) أن الواجهة البرمجية قد تعاملت مع البيانات التي تم إدخال قيم عددية لها وعددها 12، أما البيانات التي تم إعطاؤها القيمة 0 فقامت الواجهة بتجاهلها، فيظهر في الشكل أن عدد المدخلات هو 12، في حين أن عدد المدخلات الأصلي هو 13، وبقي عدد الطبقات المخفية 4 وطبقات وعدد نتائج الخرج 4، وذلك كما في الأصل.

كما تم تشغيل الواجهة على بيانات عشوائية لتجربة مدى دقة النتائج التي تعطيها، فتم إدخال مجموعة من البيانات التي تعتبر أحد أهم العوامل المسببة للتآكل، فتم إدخال: بعد الأنبوب عن الطرق 10 m، والبعد عن السكك الحديدية 12 m، والبعد عن خطوط التوتر المتوسط 40 m، والبعد عن خطوط التوتر العالي 30 m، وتم إعطاء قيمتين ليس لهما تأثير على التآكل وهما: البعد عن الينابيع 5231 m، والبعد عن الأنهار 5645 m. بالإضافة إلى بيانات تربة تزيد من التآكل، فأعطت الواجهة البرمجية نسبة تآكل منطقية جداً وعلمية، كما يظهر في الشكل (13).

ALI@TALA

prediction of external corrosion for oil pipeline connecting Banias and Tartous oil estuaries

Nominal Wall (mm)

Distanc the pipe of (m):

Road Railways

Electricity 66kv Electricity 320kv

Spring River

Data of soil:

PH electrical conductivity

CO3 (mm/100g) CL (mm/100g)

Salinity humidity

Done

results

Anomaly Class Length (mm)

Width (mm) Peak Depth (%)

الشكل (13): تنبؤ الواجهة البرمجية بحدوث تآكل خارجي على بيانات عشوائية

مناقشة النتائج:

لقد تبين من خلال هذه الدراسة، أن الواجهة البرمجية المصممة باستخدام الماتلاب بناء على الشبكات العصبونية، تعطي نتائج عالية الدقة في عملية التنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط، عملية فعالة، حيث تظهر النتائج تطابق كبير بين بيانات التنبؤ وبيانات التفتيش الفني وبنسبة عالية جداً، وتم اختبار النتائج على 25 نقطة تآكل خارجي، أعطت جميعها نتائج ذات موثوقية عالية، وصلت نسبة التطابق إلى أكثر من 85%، ونفسر هذه النسبة العالية، لأن الدراسة شملت معظم العوامل المسببة للتآكل الخارجي، بالإضافة إلى دقة البيانات التي تم إدخالها إلى الشبكة العصبونية، كما أظهرت النتائج أهمية بيانات القاشط الذكي Smart Pig في كشف مواقع التآكل الحالية والمستقبلية، إذا ما تم استثمارها بشكل جيد.

كما أظهرت النتائج أن استخدام الواجهة البرمجية المصممة في عملية التنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط، تساعد في عملية تحقيق الإدارة السليمة والفعالة لأنابيب النفط، حيث تسمح لمشغلي خطوط أنابيب النفط بمعرفة المواقع الأضعف في خطوط أنابيب النفط والأكثر عرضة للتآكل الخارجي، وبالتالي اتخاذ الإجراءات المناسبة من حماية مهبطية ووسائل عزل وكشف مبكر على هذه المواقع، مما يقلل من عمليات الصيانة، ويمنع حدوث التآكل والتسرب، وما يتبعها من تلوث للتربة وفقد في المادة المنقولة وعمليات حفر وتوقف الإنتاج، فيحافظ على الأموال ويمنع الهدر في الجهد والوقت والتكاليف.

كما بينت الدراسة أهمية استخدام أساليب الذكاء الاصطناعي وتطبيقاتها في مجال صناعي ومهم كالنفط، وتكاملها مع بيانات القاشط الذكي Smart Pig، التي تعتبر الوسيلة الأساسية والعالمية في عمليات الصيانة وكشف التآكل، حيث تم استثمار البيانات في تدريب الشبكة العصبونية واختبار صحتها، وتم تصميم الواجهة البرمجية بناء على هذه الشبكة.

الاستنتاجات:

- 1- استخدام الواجهة البرمجية المصممة على الماتلاب، والمبنية على الشبكات العصبونية ذات التغذية الأمامية، للتنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط، أعطت نتائج عالية الدقة.
- 2- بيانات التفتيش الفني smart pig في غاية الأهمية لمشغلي خطوط أنابيب النفط، ويمكن استثمارها لكشف التآكل الحالي والمستقبلي.
- 3- إن التنبؤ بأماكن التآكل الخارجي في أنابيب النفط باستخدام الواجهة البرمجية المصممة، يعطي معلومات شاملة عن كافة نقاط التآكل في خطوط الأنابيب، مما يتيح للفنيين معرفة النقاط الأكثر خطورة، وبالتالي اتخاذ إجراءات الحماية المناسبة.
- 4- تفيد نتائج دراسة تأثير العوامل المختلفة التي تزيد من خطر تآكل أنابيب نقل النفط والغاز، في تحديد المسارات الأفضل لمد هذه الخطوط مستقبلاً بعيداً عن العوامل المختلفة المسببة للتآكل.
- 5- إن التنبؤ بأماكن التآكل الخارجي في أنابيب النفط باستخدام الواجهة البرمجية، يساعد في تحقيق عملية الإدارة السليمة والفعالة لأنابيب نقل النفط، مما يقلل من عمليات الصيانة، ويمنع حدوث التآكل والتسرب، وما يتبعها من عمليات حفر وتوقف الإنتاج، فيحافظ على الأموال ويمنع الهدر في الجهد والوقت والتكاليف.

المراجع:

- 1- NOSA, I; BOLAJI, A. 2016. *Modelling the Corrosion Rate of Buried Pipes Using Modified Artificial Neural Network (MANN) Coupled with Monte Carlo Simulation*. Archives of Current Research International. Vol.4, NO.2, 1-8.
- 2- PARVIZEDGHY, L; ZAYED, T. 2013. Failure prediction model of oil and gas pipelines. Proceedings of the Fourteenth International Conference on Civil, Structural and Environmental Engineering Computing. Scotland: Stirlingshire.
- 3- SUMARNI; SUPRIYATMAN, D; SIDARTO, K; SURATMAN, R; DASILFA, R. 2012. *Artificial Neural Networks for Corrosion Rate Prediction in Gas Pipelines*. Thirty-Sixth Annual Convention & Exhibition, Proceedings, Indonesian Petroleum Association. IPA12-E-148.
- 4- MAT DIN, M; ITHNIN, N; ZAIN, A; NOOR, N; SIRAJ, M; RASOL, R. 2015. An Artificial Neural Network Modeling for Pipeline Corrosion Growth Prediction. ARPN Journal of Engineering and Applied Sciences. Vol. 10, NO.1.
- 5- ALNAQI, A; REDDY, N.S; ALAWADHI, K; MURAD, A; ALI, H. 2016. A Neural Network Predictive Model for Welded Marine Pipeline Internal Corrosion. Research Journal of Applied Sciences, Engineering and Technology. Vol. 13, No. 7, 585-592.
- 6- OLADIPO, B. A; AJIDE, O. O; MONYEI, C. G. 2017. Corrosion assessment of some buried metal pipes using neural network algorithm. I.J. Engineering and Manufacturing, 27-42.
- 7- OBASEKI, M; NWANKWOJIKE, B. N; ABAM, F.I. 2017. *Artificial neural network simulation model for predicting oil and gas pipeline corrosion rate in Nigerian Niger Delta*. FUPRE Journal of Scientific and Industrial Research. Vol. 1, NO.1, ISSN:2579-1129.
- 8- AKKAR, H; HADI, W; AL-DOSARI, I. 2018. *Pipelines leak classification based on artificial intelligence*. international journal of engineering research and management (IJERM). Vol. (05), NO. 07, ISSN: 2349- 2058.
- 9- WANG, C; TONG, C; YAO, S. 2018. *An improved prediction algorithm of seamless tubing corrosion based on an extension neural network*. Wiley.
- 10- DE MASI, G; VICHI, R; GENTILE, M; GABETTA, G. 2014. *A neural network predictive model of pipeline internal corrosion profile*. First International Conference on Systems Informatics, Modelling and Simulation.
- 11- LAYOUNI, M; TAHAR, S; HAMDI, M.S. 2014. A survey on the application of neural networks in the safety assessment of oil and gas pipelines. IEEE.
- 12- LIU, H; LIU, Z; TAYLOR, B; DONG, H. 2019. *Matching pipeline In-line inspection data for corrosion characterization*. NDT and E International 101. 44 - 52.
- 13- الشرفاوي، محمد، علي. 1996. *النكاه الاصطناعي والشبكات العصبية*. مركز الذكاء الاصطناعي للحاسبات، مصر، 352.
- 14- AIASHEE, T; SALAMAH, A; HAMED, H; MAHMOUD, R. The role of remote sensing techniques in achieving the proper management of oil pipeline corrosion. Journal of AL Baath University. Vol.4, 2022.