

## Using a Feed Forward Neural Network to Predict External Corrosion in Oil Pipelines

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

(Received 30 / 1 / 2022. Accepted 15 / 5 / 2022)

### □ ABSTRACT □

This study aims to predict external corrosion in oil pipelines using feed forward neural networks, based on the Smart Pig data, which oil companies resort to technical inspections to have a detailed data on the current corrosion reality in oil pipelines. Most important external corrosive factors applied to the oil pipeline linking the Baniyas and Tartous estuaries where data was divided into two groups: 80 points to train the network, and 25 points to test the results.

The study showed that using feed forward neural networks in the prediction process gives high-accuracy results, and matching between the prediction data and the technical inspection data with high rate, which allows pipeline operators to know the weakest sites in these pipes and the most vulnerable to external corrosion. Thus, the appropriate cathodic protection and isolation prevent the occurrence of corrosion which reduces wastage in time and costs.

**Keywords:** prediction, The external corrosion in oil pipelines, feed forward neural networks, inspection device (Smart Pig).

---

\* Associate Professor; Faculty of Mechanical & Electrical Engineering; Tishreen University; Lattakia; Syria. [salamahahmad@gmail.com](mailto:salamahahmad@gmail.com)

\*\* Associate Professor; Faculty of Mechanical & Electrical Engineering; Al-Baath University; Homs; Syria. [hamed-h1985@hotmail.com](mailto:hamed-h1985@hotmail.com)

\*\*\* Researcher; General Organization of Remote Sensing; Coastal Branch; Lattakia; Syria. [rabiemah@yahoo.com](mailto:rabiemah@yahoo.com)

\*\*\*\*Postgraduate Student (PhD.); Faculty of Mechanical & Electrical Engineering; Tishreen University; Lattakia; Syria. [tarek.aiashee@gmail.com](mailto:tarek.aiashee@gmail.com)

## استخدام شبكة عصبونية أمامية للتنبؤ بالتآكل الخارجي في أنابيب نقل النفط

د. أحمد سلامة \*

د. حسان حامد \*\*

د. ربيع محمود \*\*\*

طارق عياشي \*\*\*\*

(تاريخ الإيداع 30 / 1 / 2022. قُبِلَ للنشر في 15 / 5 / 2022)

### □ ملخص □

تهدف هذه الدراسة إلى التنبؤ بالتآكل الخارجي في أنابيب النفط، باستخدام الشبكات العصبونية الأمامية، بالاعتماد على بيانات القاشط الذكي (Smart Pig)، الذي تلجأ له شركات النفط في عمليات التفتيش الفني، والذي يعطي بيانات تفصيلية لواقع التآكل الحالي في أنابيب النفط، مع الأخذ بعين الاعتبار أهم العوامل المسببة للتآكل الخارجي، حيث تم تطبيق الدراسة على أنبوب النفط الواصل بين مصبي بانياس وطرطوس، فتم تقسيم البيانات إلى قسمين: الأول يضم 80 نقطة تم استخدامها لتدريب الشبكة، والثاني يضم 25 نقطة لاختبار النتائج.

لقد بينت الدراسة أن استخدام الشبكات العصبونية الأمامية في عملية التنبؤ تعطي نتائج عالية الدقة، حيث أظهرت النتائج تطابق كبير بين بيانات التنبؤ وبيانات التفتيش الفني وبنسبة عالية جداً، مما يسمح لمشغلي خطوط الأنابيب بمعرفة المواقع الأضعف في هذه الأنابيب والأكثر عرضة للتآكل الخارجي، 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.

**الكلمات المفتاحية:** التنبؤ، التآكل الخارجي في أنابيب النفط، الشبكات العصبونية الأمامية، القاشط الذكي (Smart Pig).

\* أستاذ مساعد- كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية. [salamahahmad@gmail.com](mailto:salamahahmad@gmail.com)

\*\* أستاذ مساعد- كلية الهندسة الميكانيكية والكهربائية- جامعة البعث - حمص - سورية. [hamed-h1985@hotmail.com](mailto:hamed-h1985@hotmail.com)

\*\*\* باحث -الهيئة العامة للاستشعار عن بعد - اللاذقية - سورية. [rabiemah@yahoo.com](mailto:rabiemah@yahoo.com)

\*\*\*\* طالب دكتوراه - كلية الهندسة الميكانيكية والكهربائية- جامعة تشرين - اللاذقية - سورية. [tarek.aiashee@gmail.com](mailto:tarek.aiashee@gmail.com)

**مقدمة:**

يعرف التآكل حسب ASTM G15 بأنه عملية تؤدي إلى تخریب المعدن وانهيائه نتيجة تفاعل كيميائي أو كهرو كيميائي بين المعدن والوسط المحيط به.

والتآكل في أنابيب النفط هو عملية التآكل أو التآكل أو الاهتراء الذي يصيب الأنابيب من الداخل أو الخارج، ويؤدي إلى تخریبه وتقليل سماكته والإساءة إلى خواصه الكيميائية والميكانيكية، وإلى إحداث ثقب فيه تخرجه عن التشغيل والخدمة في وقت مبكر [1].

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 بالمثل"، وتم تطبيقها من أجل إعطاء التنبؤات الصحيحة لبيانات غير مسبوقة، 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 [2].

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 الأنابيب، ويتم تحريكها عن طريق ضخ النفط ورائها فتقوم بالكشف على كامل الأنابيب، وتعطي بيانات تفصيلية عن مقدار التآكل (الداخلي والخارجي) ونوعه وموقعه وعمقه، كما تقوم بإزالة العوالق من جدار الأنابيب الداخلي التي يمكن أن تعيق أو تؤخر التدفق عبر خط الأنابيب. 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، ولذلك فمن الضروري الاستعانة بتقنيات قادرة على التنبؤ بأماكن التآكل المستقبلية المحتمل حدوثها في أنابيب النفط.

للبحث عن أفضل التقنيات المستخدمة في موضوع التنبؤ بأماكن التآكل المستقبلية المحتمل حدوثها في أنابيب نقل النفط، كان لابد من الاطلاع على الدراسات المرجعية السابقة، فقد استخدم Sumarni وآخرون في عام 2012، الشبكة العصبونية الاصطناعية (ANN) للتنبؤ بمعدل التآكل في خطوط أنابيب الغاز، فأعطت نتائج عالية الدقة [3]، وفي عام 2013، قامت Parvizedghy و Zayed بإنشاء نموذج للتنبؤ بالفشل في أنابيب نقل النفط والغاز، بالاعتماد على محاكاة مونت كارلو، وقد أظهرت النتائج أداء جيد للنموذج عندما تكون الأنابيب في عمرها الأولي أو المتوسط [4]، كما قام De Masi وآخرون في عام 2014، باقتراح نموذج شبكة عصبونية للتنبؤ بالتآكل الداخلي لمقاطع الأنابيب، يهدف إلى التنبؤ الصحيح لمقدار المعدن المفقود ومعدل التآكل على طول الأنابيب، وذلك بناء على بيانات

حقلية حقيقية مأخوذة من عمليتي تفتيش فني للخط في عام 2002 وعام 2005، وتم مقارنة النموذج مع نموذج De Waard وNORSOK، فتبين أن نموذج FNN (Fitting Neural Network) يتفوق على النماذج الحتمية القياسية [5]، وفي عام 2014 أيضاً، 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 [6]، كما أنشأ Mazura Mat Din وآخرون في عام 2015، 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 (Internal Line Inspections) (ILI) وقياسها بواسطة التحليل الإحصائي، وقد تبين أن النموذج المطور قادر على التنبؤ بعمق التآكل وطوله الذي يمكن استخدامه لحساب معدل التآكل أو النمو [7]. كما 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 و12 للاختبار، ولقد أثبت النموذج دقة كبيرة في عملية التنبؤ بنسبة وصلت إلى 90% [8]، وفي عام 2016، قام Nosa وBolaji بتصميم نموذج لحساب معدل التآكل في الأنابيب المدفونة باستخدام الشبكات العصبونية الاصطناعية المعدلة ومحاكاة مونتني كارلو، وقد أعطى النموذج نتائج عالية الدقة [2]، كما قام Oladipo وآخرون، في عام 2017، بتقييم التآكل لبعض الأنابيب المعدنية المدفونة باستخدام خوارزمية الشبكات العصبونية، 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 [9]، ونظراً لأهمية الشبكات العصبونية في مجال التنبؤ، قام Obaseki وآخرون، في عام 2017 أيضاً، بإنشاء نموذج محاكاة شبكة عصبونية اصطناعية للتنبؤ بمعدل تآكل أنابيب 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 [10]، وفي عام 2018، قامت Dr. Hanan وآخرون بتصنيف تسرب النفط بناءً على الذكاء الصناعي، حيث تم إنشاء نموذج لشبكة عصبونية خلفية 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 [11]، وفي عام 2018 أيضاً، قام Wang وآخرون بإنشاء خوارزمية محسنة للتنبؤ بالتآكل في الأنابيب غير الملحومة بناءً على امتداد الشبكات العصبونية، تم استخدام لغة بايثون لتطبيق خوارزمية الشبكة العصبونية، وقد تبين أن النموذج التي تم التوصل إليه، له قيمة هندسية جيدة للتعرف على الأنماط، وتشخيص الأخطاء، وتصنيف المجموعات مع سرعة تدريب أفضل [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 [13].

من خلال الدراسات المرجعية السابقة نجد أن تقنيات الذكاء الصناعي باتت تستخدم كثيراً في عملية التنبؤ، وبت 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.

### أهمية البحث وأهدافه:

- 1- أهمية البحث: تأتي أهمية هذا البحث، من أن استخدام الشبكات العصبونية في التنبؤ بالتآكل الخارجي في أنابيب نقل النفط، سيؤدي إلى تقليل التكاليف الناتجة عن التلف والاهتراء، وما يتبعها من عمليات حفر وتوقف الانتاج، وبالتالي التقليل من الهدر في الأموال والجهد والوقت. كما أنه يقدم تقنية علمية جديدة تعد أحد أساليب الذكاء الصناعي الذي بات يستخدم كثيراً في عصرنا الحالي.
- 2- أهداف البحث: يهدف هذا البحث إلى إنشاء شبكة عصبونية للتنبؤ بأماكن التآكل الخارجي المستقبلية الأكثر خطورة في أنبوب نقل النفط بالاعتماد على بيانات التفتيش الفني Smart Pig، مع الأخذ بعين الاعتبار أهم العوامل المسببة للتآكل الخارجي لأنابيب نقل النفط، مما يسمح بأخذ كافة الاحتياطات اللازمة ومنع حدوث التآكل والتسرب، مما يحقق الإدارة السليمة لأنابيب النفط، ويقلل التكاليف ويمنع وقوع الكوارث.

### طرائق البحث ومواده:

- البيانات التي تعطيها أجهزة التفتيش الفني (Smart Pig).
- برنامج MATLAB.
- الأكسل Excel.

### النتائج والمناقشة:

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

لقد تم في هذه الدراسة إنشاء شبكة عصبونية 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 (أي ما يعادل 60.69 cm)، وهو مصنوع من مجموعة من الأجزاء طول كل جزء منها حوالي 12 متر. الأنبوب مصمم حسب مواصفات ASTM، وهو من الفولاذ الكربوني له التركيب الكيميائي التالي:

| ASTM Spec      | طريقة صنع الأنابيب | الكربون (C) | المنغنيز (Mn) | الفوسفور (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 الأنابيب. فتم تزويد الشركة بكامل بيانات نقاط التآكل الداخلي والخارجي للأنبوب المدروس، وتشمل بيانات كاملة عن طول وعرض وعمق بقعة التآكل ومدى خطورتها وموقعها وبعدها عن بداية الأنبوب. ويظهر الشكل (1) البيانات التي قَدَمها جهاز التفتيش الفني Smart Pig عملية مسح أنبوب نقل النفط الواصل بين مصبي بانياس. وطرطوس النفطيين في عام 2009.



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 (حيث أن الأنبوب عبارة عن مجموعة من الأجزاء طول كل منها 12 متر تم لحامها مع بعضها البعض لتشكل الأنبوب بالكامل) Girth Weld، بعد نقطة التآكل عن بداية الأنبوب بالمتر Absolute Distance (m)، بعد نقطة التآكل عن بداية الجزء الخاضع للحام من الأنبوب، وطول الوصلة (الجزء الخاضع للحام من الأنبوب) بالمتر Joint length (m)، نوع السمة التي تعرف إليها جهاز التفتيش الفني Feature Type، وتعريف هذه السمة Feature Identification، نوع التآكل داخلي أو خارجي Surface Location، وتصنيفه Anomaly Class،

وطوله بالميليمتر (mm) Length، وعرضه (mm) Width، والنسبة المئوية لمدى خطورته (% Peak Depth)، وموقعه على الأنبوب (hh:mm Orientation)، ونوع الأنبوب (Pipe Type)، ومعامل الإصلاح (ERF).

| Pipeline Tally |                       |                       |                  |                   |              |                          |                |                  |             |            |                |                   |       |           |         |
|----------------|-----------------------|-----------------------|------------------|-------------------|--------------|--------------------------|----------------|------------------|-------------|------------|----------------|-------------------|-------|-----------|---------|
| Cath. Weld     | Absolute Distance (m) | Relative Distance (m) | Joint length (m) | Nominal Wall (mm) | Feature Type | Feature Identification   | Assembly Class | Surface Location | Length (mm) | Width (mm) | Peak Depth (%) | Orientation hh:mm | ERF   | Pipe Type | Comment |
| 210            | 23.885                | 0.051                 | 9.8              | 9.52              | GROUP        | -                        | PITT           | EXT              | 27          | 40         | 19             | 05:28             | 0.732 | ERW       |         |
| 210            | 24.065                | 0.290                 | 9.9              | 9.52              | GROUP        | -                        | PITT           | EXT              | 21          | 24         | 16             | 05:10             | 0.730 | ERW       |         |
| 210            | 25.906                | 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            | 45.837                | 8.387                 | 10.8             | 9.52              | GROUP        | -                        | OISL           | INT              | 9           | 16         | 11             | 05:40             | 0.728 | ERW       |         |
| 230            | 45.820                | 8.379                 | 10.8             | 9.52              | GROUP        | -                        | PITT           | INT              | 19          | 24         | 11             | 05:32             | 0.729 | ERW       |         |
| 230            | 46.462                | 9.021                 | 10.8             | 9.52              | GROUP        | -                        | GENE           | INT              | 57          | 32         | 16             | 05:32             | 0.744 | ERW       |         |
| 230            | 46.549                | 9.108                 | 10.8             | 9.52              | GROUP        | -                        | OISL           | INT              | 9           | 16         | 15             | 05:34             | 0.728 | ERW       |         |
| 230            | 46.615                | 9.174                 | 10.8             | 9.52              | GROUP        | -                        | PITT           | INT              | 24          | 24         | 18             | 05:38             | 0.731 | ERW       |         |
| 230            | 46.884                | 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 الأنبوب، 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.

الشكل (3): بيانات Smart Pig بعد أن أضيف 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). لملأمتها لعدد البيانات المدخلة، حيث تم الاستفادة من بيانات التنقيش الفني Smart Pig، واعتبار نتائجه كخرج للشبكة. والشكل (4) يوضح المدخلات في الشبكة العصبونية، وعدد الطبقات المخفية والمخرجات حيث تم اعتبار الدخل للشبكة:

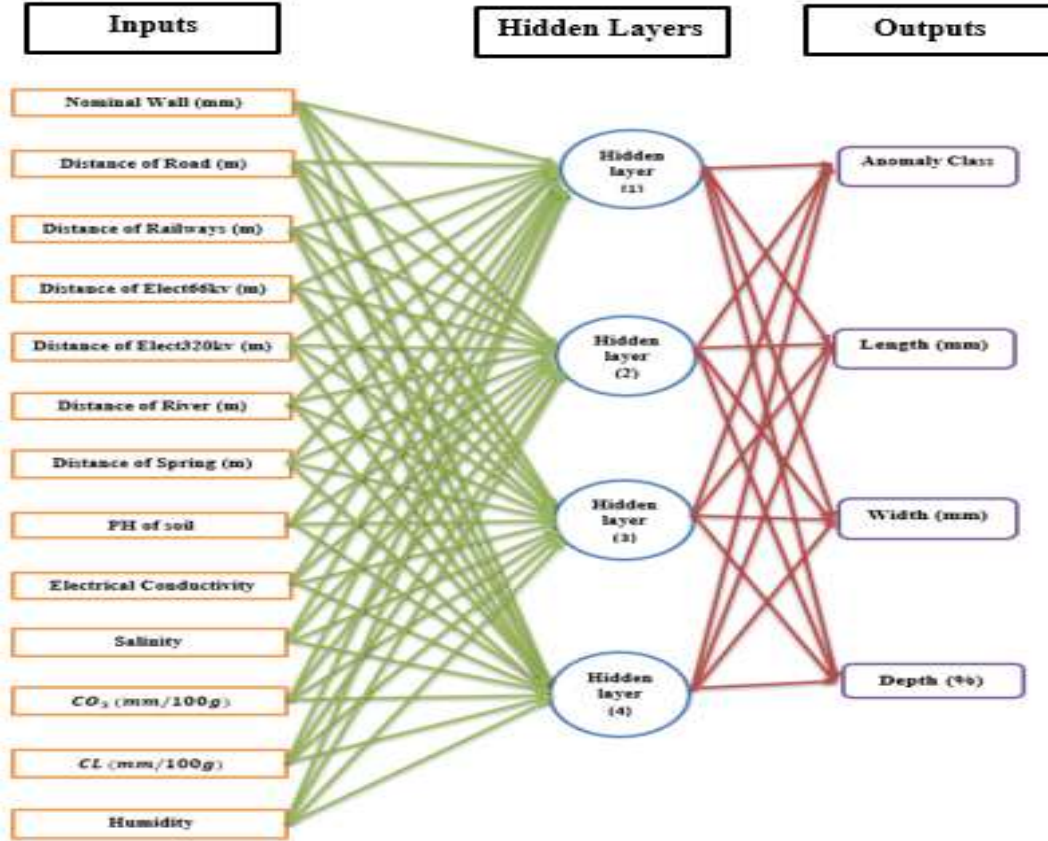
- 1- سماكة جدران الأنبوب (Nominal Wall (mm)).
- 2- البعد عن طرق المواصلات ذات الاتجاه الواحد (Distance of Road (m)).
- 3- البعد عن السكك الحديدية (Distance of Railways (m)).
- 4- البعد عن خطوط الكهرباء ذات التوتر المتوسط (66kv) (Distance of Elect66kv (m)).
- 5- البعد عن خطوط الكهرباء ذات التوتر العالي (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 ( $CO_3$  (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 (%)).

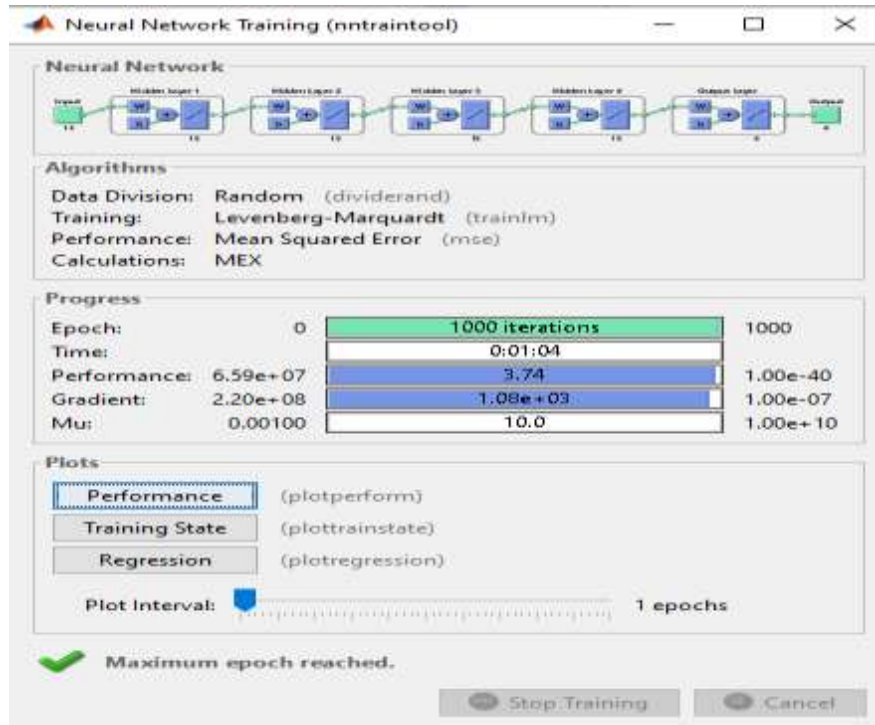


الشكل (4): عدد المدخلات في الشبكة العصبونية، وعدد الطبقات المخفية وعدد المخرجات

#### مرحلة تدريب الشبكة واختبار النتائج:


تم تقسيم بيانات التفتيش الفني إلى قسمين:

- القسم الأول: وعددها 80 نقطة تآكل خارجي، تم سبرها على أنبوب النفط، أثناء عملية التفتيش 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.



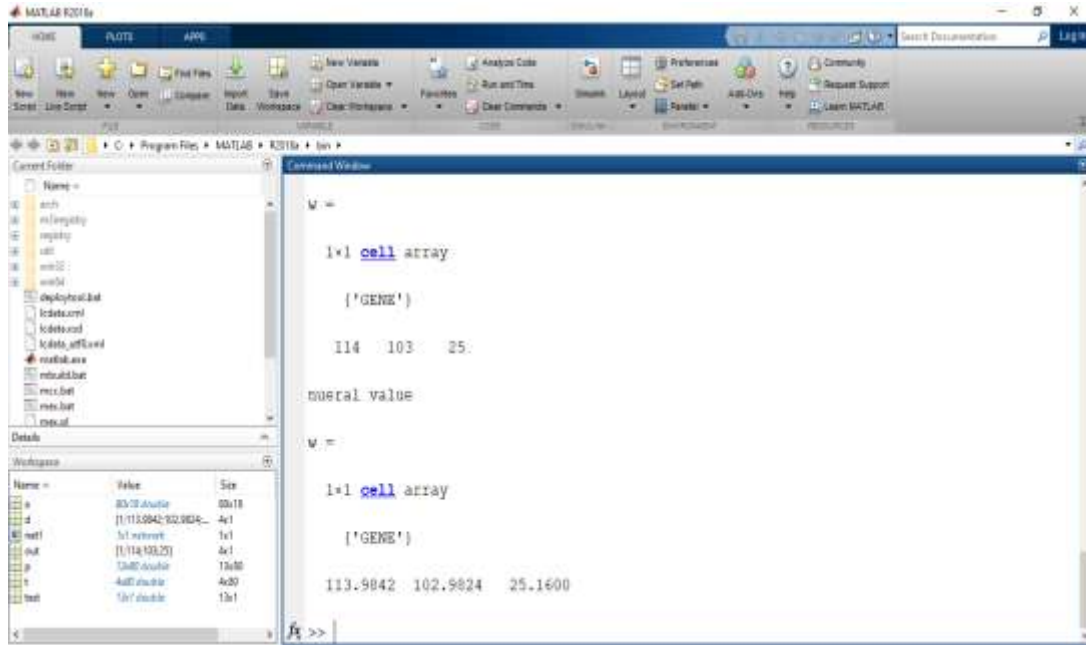
الشكل (5): إتمام عملية التدريب للشبكة العصبونية

حيث يظهر في هذا الشكل أنه تم تكرار عملية التدريب 1000 مرة، خلال زمن 1 دقيقة و4 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 متقاربة 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%.

### النتائج والمناقشة:

لقد تبين من خلال هذه الدراسة، أن استخدام الشبكات العصبونية في عملية التنبؤ بأماكن التآكل الخارجي في أنابيب نقل النفط، بالاعتماد على بيانات القاشط الذكي Smart Pig مع الأخذ بعين الاعتبار أهم العوامل المسببة للتآكل الخارجي، عملية فعالة وتعطي نتائج عالية الدقة، 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 الشبكات العصبونية 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.

## الاستنتاجات والتوصيات:

### الاستنتاجات:

- 1- استخدام الشبكات العصبونية ذات التغذية الأمامية، للتنبؤ بأمكان التآكل الخارجي في أنابيب نقل النفط، يعطي نتائج عالية الدقة.
- 2- بيانات التفتيش الفني smart pig لها دور كبير ومهم جداً لدى الفنيين العاملين في خطوط أنابيب النفط، ويمكن الاستفادة منها لكشف التآكل الحالي والمستقبلي.
- 3- إن التنبؤ بأمكان التآكل الخارجي في أنابيب النفط باستخدام الشبكات العصبونية، 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 بأمكان التآكل الخارجي في أنابيب النفط باستخدام الشبكات العصبونية، يساعد في تحقيق عملية الإدارة السليمة والفعالة لأنابيب نقل النفط، مما يقلل من عمليات الإصلاح، ويمنع حدوث الاهتراء والتسرب، فيحافظ على الأموال ويمنع الهدر في الجهد والوقت والتكاليف.

### التوصيات:

- 1- ضرورة تطبيق هذه الدراسة من قبل الشركة السورية لنقل النفط على الخط الواصل بين مصيبي بانياس وطرطوس النفطيين.
- 2- ضرورة تعميم هذه الدراسة لتشمل كافة خطوط أنابيب النفط في سورية، مما يتيح استخدام البرنامج على جميع خطوط أنابيب النفط، لأننا بذلك نكون قد شملنا وحلنا جميع الترب، وبالتالي نحصل على شبكة عصبونية أكثر شمولية.
- 3- ضرورة تدريب كادر فني من الشركة على أنظمة الذكاء الاصطناعي وتعليم الآلة، حتى يكون قادراً ومؤهلاً بشكل كامل على التعامل مع هذه الأنظمة وتكاملها مع بيانات أجهزة التفتيش، كي تتحقق الفائدة العظمى من الدراسة.
- 4- يمكن استخدام أنظمة الذكاء الاصطناعي وتعليم الآلة في تطبيقات كثيرة في مجال المنشآت النفطية، فعلى سبيل المثال يمكن من خلالها إنشاء شبكة عصبونية للتنبؤ بأمكان التآكل الداخلي في أنابيب نقل النفط.

## References:

- 1- BADMOS, A.Y; AJIMOTOKAN, H.A; EMMANUEL, E.O. *Corrosion in petroleum pipelines*. New York Science Journal, ISSN 1554-0200, London, Vol.2, No .5.2009.
- 2- NOSA, I; BOLAJI, A. *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, 2016, 1-8.
- 3- SUMARNI; SUPRIYATMAN, D; SIDARTO, K; SURATMAN, R; DASILFA, R. *Artificial Neural Networks for Corrosion Rate Prediction in Gas Pipelines*. Thirty-Sixth Annual Convention & Exhibition, Proceedings, Indonesian Petroleum Association. IPA12-E-148. 2012
- 4- PARVISEDGHY, L; ZAYED, T. *Failure prediction model of oil and gas pipelines*. Proceedings of the Fourteenth International Conference on Civil, Structural and Environmental Engineering Computing. Scotland: Stirlingshire. 2013.

- 5- DE MASI, G; VICHI, R; GENTILE, M; GABETTA, G. *A neural network predictive model of pipeline internal corrosion profile*. First International Conference on Systems Informatics, Modelling and Simulation, 2014.
- 6- LAYOUNI, M; TAHAR, S; HAMDI, M.S. *A survey on the application of neural networks in the safety assessment of oil and gas pipelines*. IEEE. 2014.
- 7- MAT DIN, M; ITHNIN, N; ZAIN, A; NOOR, N; SIRAJ, M; RASOL, R. *An Artificial Neural Network Modeling for Pipeline Corrosion Growth Prediction*. ARPN Journal of Engineering and Applied Sciences. Vol. 10, NO.1,2015.
- 8- ALNAQI, A; REDDY, N.S; ALAWADHI, K; MURAD, A; ALI, H. *A Neural Network Predictive Model for Welded Marine Pipeline Internal Corrosion*. Research Journal of Applied Sciences, Engineering and Technology. Vol. 13, No. 7, 2016, 585-592.
- 9- 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,2017, 27-42.
- 10- OBASEKI, M; NWANKWOJIKE, B. N; ABAM, F.I. *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, 2017, ISSN:2579-1129.
- 11- AKKAR, H; HADI, W; AL-DOSARI, I. *Pipelines leak classification based on artificial intelligence*. international journal of engineering research and management (IJERM). Vol. (05), NO. 07, 2018, ISSN: 2349- 2058.
- 12- WANG, C; TONG, C; YAO, S. *An improved prediction algorithm of seamless tubing corrosion based on an extension neural network*. Wiley. 2018.
- 13- LIU, H; LIU, Z; TAYLOR, B; DONG, H. *Matching pipeline In-line inspection data for corrosion characterization*. NDT and E International 101. 2019, 44-52.
- 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.