

التنبؤ بقيم الألمنيوم المتبقي في محطات تنقية مياه الشرب التقليدية باستخدام تقنيات الذكاء الصناعي

م. ربا دحام السعيد⁽¹⁾

أ. د. بسام العجي⁽²⁾

أ. د. مازن ابراهيم⁽³⁾

الملخص

تستخدم الشبنة بكثرة كمادة كيميائية للتخثير. إن الجرعة العالية منها تسبب على الأقل خطراً صحياً طفيفاً وتشير بعض الدراسات إلى أن الألمنيوم يمكن أن يزيد من خطر الإصابة بمرض الزهايمر. وبالتالي فمن المهم تقليل كمية الألمنيوم المتبقي في مياه الشرب. ركزت هذه الدراسة على علاقة الألمنيوم المتبقي بالبارامترات المختلفة المتعلقة بعملية تنقية المياه، تم استخدام البيانات الفعلية لمحطة تنقية المياه في القصور في مدينة حمص على مدى ثلاث أعوام، وتحليل الألمنيوم المتبقي في مياه الشرب عن طريق نماذج الشبكة العصبونية الاصطناعية - الجينية (GA- ANN). وإنشاء نموذج تنبؤ بسيط وموثوق يمكن استخدامه في الإنذار المبكر نظام (EWS). تم بناء النماذج باستخدام بيانات المياه الخام وذلك للتنبؤ بقيم ألمنيوم المتبقي للمياه الخارجة من المحطة، كما تم بناء عدة نماذج دخل ودراسة اللياقة لكل نموذج واختيار الشبكة ذات تابع اللياقة الأعلى. أظهرت النتائج أنه من الممكن التنبؤ بقيم الألمنيوم المتبقي بدرجة عالية من الدقة باستخدام خوارزمية (LM) ذات البنية الهيكلية (4-7-1). وكانت المتغيرات ذات التأثير الأكبر على الألمنيوم المتبقي هي عكارة البدعو جرعة المخثر. كانت الشبكة المختارة قادرة على التنبؤ بقيم الألمنيوم المتبقي بدقة عالية بمعامل ارتباط (R) (0.93) وقيمة الخطأ المطلق (AE) 0.024.

كلمات مفتاحية: تنقية مياه الشرب - التخثير - الألمنيوم المتبقي - العكارة - شبكة هجينة - الشبكات العصبونية - خوارزميات جينية.

⁽¹⁾ طالبة دكتوراه في كلية الهندسة المدنية، قسم الهندسة الصحية والبيئية، جامعة دمشق

⁽²⁾ أستاذ مساعد في كلية الهندسة المدنية، قسم الهندسة الصحية والبيئية، جامعة دمشق

⁽³⁾ أستاذ مساعد في كلية الهندسة المدنية، قسم الإدارة الهندسية والتشييد، جامعة دمشق

Predicting the residual aluminum in traditional drinking water purification plants using artificial intelligence techniques

Abstract

Alum is widely used in water purification as a chemical coagulant. A high dose of it causes at least a slight health risk, and some evidence suggests that aluminum can increase the risk of developing Alzheimer's disease. Hence, it is important to reduce the amount of residual aluminum in drinking water.

In this study, the relation between residual aluminum and various parameters related to the treatment process was studied, by using a hybrid neural network models.

The actual data of the water purification plant in Al Qusayr in Homs over a period of three years was used, and the residual aluminum in drinking water was analyzed by artificial-genetic neural network (GA-ANN) models.

To create simple and reliable prediction models that can be used in the Early Warning System (EWS).

Models were constructed using the data of raw water: turbidity of the raw water, pH, temperature and coagulant dose in order to predict the residual aluminum values for the water leaving the plant. And the effect of preprocessing data was studied by comparing results with previous studies.

Several models were built, and a network with a higher fitness was selected.

The results showed that it is possible to predict the residual aluminum values with a high accuracy using the structured (4-7-1) with (LM) algorithm. The variables with the greatest influence on the residual amount of aluminum were turbidity of raw water, coagulant dose, respectively.

The results of the selected network were able to predict the aluminum of the output with high accuracy with a correlation coefficient (R) (0.93) and absolute errors (AE) 0.024.

Keywords: Water purification- coagulation- Residual aluminum – Turbidity -hybrid network- neural networks genetic algorithm.

1-1- المقدمة:

تشكل المياه المورد الرئيسي للنظام البيئي، وتلعب الموارد المائية دوراً حيوياً في قطاعات اقتصادية مختلفة. أدى تدهور نوعية المياه في الجسم المائي للأنهار والبحيرات إلى خلق حالة سيئة بحيث لا يمكن استخدام هذه المياه في العديد من الأنشطة أو كمصدر لإمداد المياه بدون معالجة.

الهدف الأساسي لمحطة تنقية مياه الشرب هو إنتاج مياه آمنة للاستهلاك لا تحتوي كائنات ممرضة أو مركبات سامة، وإنتاج مياه شرب سائغة، ويجب أن يتم ذلك بأقل كلفة، وأقل ضرر على البيئة. [1]

تحتوي المياه السطحية على مواد عالقة، تسعى هذه المواد للترسب في قاع السرير المائي، إلا أن الجزيئات الدقيقة ذات الأبعاد الصغيرة تبقى في المياه بالحالة المعلقة. إن الجزيئات المناسبة لتكنولوجيا الترسيب الطبيعي هي الجزيئات ذات الأبعاد أكبر من 50-30 ميكرون. [2]

استخدمت عملية التثخير (Coagulation) والتليد (Flocculation) لشوائب المياه منذ زمن بعيد. [3]

إن عملية التثخير هي عملية زيادة حجوم الجزيئات المشتتة باستخدام مواد قادرة على توحيد هذه الجزيئات. تسمى هذه المواد بالمخثرات، وتعطي المخثرات منتجات قليلة الانحلال قادرة على الاندماج في الندف الضخمة.

- عملية التثخير في معالجة المياه الخام هي عملية تحييد الشحنة للجسيمات الغروية عن طريق إضافة مخثر كيميائي وذلك لتعزيز تكتلها وبالتالي تنتج جزيئات أكبر يمكن إزالتها بسهولة أكبر في عمليات المعالجة اللاحقة. إن لعملية التثخير علاقة وثيقة بكلفة المعالجة لذا يجب ضبطها لتكون ضمن الكلف الاقتصادية والشروط المثلى.

[4]

بدأ استخدام الشبة في أوروبا في أواسط القرن الثامن عشر، وقد جرى التعامل مع هذا المخثر بحذر شديد نظراً لعدم السماح في ذلك الحين بإدخال مواد جديدة إلى التركيب الكيميائي للمياه خلال عملية تنقيتها، إضافة إلى السعر العالي للشبة في ذلك الوقت.

المخثرات الأكثر استخداماً في معالجة مياه الشرب هي مخثرات الألومنيوم، كبريتات الألومنيوم ($Al_2(SO_4)_3$) أو الشبة. يتفاعل المخثر مع القلوية الموجودة في المياه مثل الكربونات والبيكربونات كما يتفاعل مع الهيدروكسيد أو الفوسفات لتكوين أملاح الألومنيوم غير القابلة للذوبان.

قد يؤدي الحقن المفرط لهذه المادة إلى زيادة كمية الألومنيوم الحر المتبقية في الماء.

يزيد الألومنيوم المتبقي من عكارة المياه، وقد يكون له بعض التأثيرات الصحية على المستهلكين.

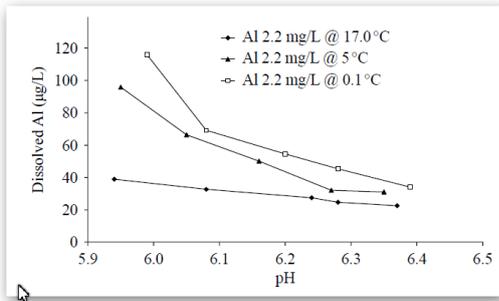
تم الإبلاغ عن أعراض الغثيان والقيء والإسهال عند المستوى العالي من بقايا الألومنيوم في مياه الشرب، كذلك أعراض مثل تقرحات الفم والجلد والطفح الجلدي وآلام المفاصل. [5]

تمت دراسة الآثار الصحية الخطيرة للألومنيوم في مياه الشرب

على نطاق واسع وكانت النتائج متضاربة. إجمالي مستوى متبقي الألومنيوم من مياه الشرب يختلف حسب مستوى الألومنيوم في الماء الخام وما إذا كانت مخثرات الألومنيوم تستخدم في معالجة المياه أم لا.

تركيز الألومنيوم في المياه يمكن أن يختلف اختلافاً كبيراً اعتماداً على المواد الفيزيائية والكيميائية المختلفة، وكون الألومنيوم يضاف للمياه كمخثر فإن كمية الألومنيوم في المياه المعالجة غالباً ما تكون أكثر منها في المياه الخام. [6]

و pH، كون درجات الحرارة للمياه الخام في منطقة الدراسة تصل الى معدلات دنيا تقارب الصفر. أوضحت الدراسة زيادة تركيز المنيوم المتبقي عند نقصان قيم pH. [4]



الشكل (1-1) العلاقة بين المنيوم المنحل و pH [4]

2-2- دراسة قامت بها الباحثة Sabba في إيران

تم في هذه الدراسة استخدام طريقة المجموعة لمعالجة البيانات Group Method of Data Handling (GMDH) وهي من أنواع الخوارزميات الاستقرائية للنمذجة الرياضية. وذلك للتنبؤ بالعاكارة والألمنيوم الحر المتبقي في مياه الشرب. للتحقق من صحة النموذج المقترح، تم إجراء دراسة حالة بناءً على مجموعات البيانات التي تم الحصول عليها من محطة غوليان Guilan. تم تقسيم البيانات التجريبية إلى قسمين تدريب واختبار (70% للتدريب و30% للاختبار).

أظهر هذه الطريقة تمثيلاً جيداً للبيانات، مع معامل التحديد (R^2) بقيمة 0.8239 للعاكارة المتبقية و0.9138 للألمنيوم المتبقي على التوالي.

وكانت نتائج متوسط الخطأ التربيعي 0.0248 للعاكارة المتبقية و0.0000438 للألمنيوم المتبقي. [1]

وتذكر الدراسات أنه نتيجة زيادة حدوث الأمطار الحمضية في السنوات الأخيرة فإن الترب في أنحاء العالم تزداد حامضية بالتالي تزداد كمية الألمنيوم التي تصل الى المياه الطبيعية. [7]

نكرت منظمة حماية البيئة الحد المسموح به من الألمنيوم

ومنظمة الصحة العالمية 0.2 mg/dm^3 .

بعد تفسير الظواهر والبحث عن أسبابها، والعوامل المؤثرة فيها، من الغايات التي يسعى إليها العلم، ونتيجة لتعدد بعض الظواهر المدروسة أصبح من الضروري استخدام أساليب متطورة تواكب هذا التعقيد والتداخل للحصول على تفسير مناسب وفق شروط من الدقة والوصول إلى نتائج أكثر علمية. [8]

- ان للشبكات العصبونية الاصطناعية (ANN)

فوائد عديدة في نمذجة البيانات التقليدية. وخاصة عندما يكون المطلوب تحديد قيمة خرج مرتبط بمدخلات مختلفة ومحاكاة العمليات الغير معروفة الترابط بشكل دقيق وواضح. [3]

في عملية تنقية مياه الشرب يمكن أن يحدث بشكل متكرر تفاعلات غير مفهومة بشكل جيد.

هذا يجعل من الصعب جداً تطوير نموذج ميكانيكي مفيد. استخدام نموذج ANN يعطي القدرة على تعديل نماذج العمليات بسرعة باستخدام عملية واسعة النطاق دون ضرورة لفهم كل المقاييس الدقيقة للتفاعلات.

2- الدراسة المرجعية:

1-2- دراسة في جامعة Glasgow في

المملكة المتحدة

قام بها الباحثان D. Berube and C. C. Dorea تم الربط بين قيم المنيوم المتبقي وبارامترات مختلفة، الحرارة

يبين الجدول (1-4) الخواص الاحصائية للبيانات المستخدمة.

الجدول (1-4) الخواص الإحصائية لعناصر الدخل والخرج.

| البارامترات | المدخلات | | | | الخرج |
|-------------------|-----------------|------|---------------|------------------------|----------------------------|
| | العكارة Mg/L | pH | الحرارة °C | جرعة المخثر Mg/L | ألمنيوم المتبقي Mg/L |
| Min | 6.9 | 6.5 | 8.2 | 0 | 0 |
| Max | 30.4 | 8.53 | 21.4 | 11.16 | 0.22 |
| Mean | 14.63 | 7.43 | 15.53 | 3.68 | 0.11 |
| Std. deviation | 4.41 | 0.32 | 2.66 | 2.31 | 0.12 |

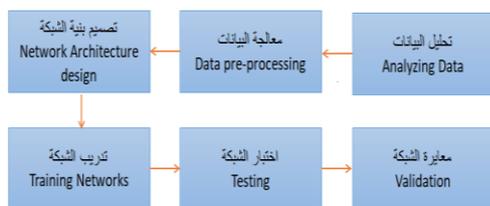
كما يبين الجدول التالي قيم معامل ارتباط بيرسون بين البيانات.

الجدول (2-4): مصفوفة معامل ارتباط بيرسون بين العناصر.

| T | pH | Tur- in | Al | |
|--------|--------|---------|--------|-----------|
| | | | | Al |
| | | | 0.458 | Tur- in |
| | | -0.005 | 0.148 | pH |
| | 0.084 | -0.383 | -0.378 | T |
| -0.455 | -0.027 | 0.704 | 0.703 | Alum dose |

يتم بناء النموذج في البرنامج وفق الخطوات الست الرئيسية لبناء نموذج شبكة عصبونية (ANN) على: تحليل البيانات (Analyzing Data) ومعالجتها (pre-processing) وتصميم بنية الشبكة، تدريب النموذج (Training)، معايرته (Validation) واختباره (Testing). [9]

وهي موضحة في الشكل (1-4).



الشكل (1-4): خطوات بناء نموذج (ANN).

2-3- بحث للباحث J. Tomperi في جامعة

Oulu في فنلندا [5]

تمت الدراسة في محطة Banson لتتقية المياه في كوريا الجنوبية، وهي محطة تقليدية باستطاعة 120,000 m3 per day.

تم الاستناد الى البيانات الفعلية من المحطة لإيجاد نموذجين يعتمد أحدهما على الانحدار المتعدد للخطأ والآخر على الشبكات العصبونية ليعطي القيمة المتبقية من الألمنيوم بالاعتماد على البيانات المقدمة للنموذج والمقارنة بين النموذجين. تم استخدام نماذج مختلفة للمدخلات، وذكرت نتيجة الدراسة أن النموذج الأفضل كان بالمدخلات التالية، بيانات الدخل: حرارة، عكارة المياه الخام، نسبة البرمنغنات الى مساعد المخثر PAC وجرعة المخثر المستخدم KMnO4.

بيانات الخرج الألمنيوم المتبقي. تمكنت الدراسة من التنبؤ بعكارة الخرج بدقة عالية حيث كانت نتائج الشبكة كالتالي:

$$RMSE = 0.70 \quad \text{للشبكة العصبونية ANN}$$

$$RMSE = 0.56 \quad \text{لنموذج الانحدار الخطي MLR}$$

3- هدف البحث:

1- التنبؤ بقيم ألمنيوم المتبقي في المياه الخارجة من محطة تتقية المياه في القصير باستخدام نموذج هجين، شبكات عصبونية - خوارزميات جينية GA-ANN.

4- منهجية البحث:

تم في هذا البحث استخدام برنامج الشبكات العصبونية (Alyuda NeuroIntelligence).

اشتملت البيانات المستخدمة والمأخوذة من محطة تتقية المياه في القصير على قيم قياسات للبارامترات التالية: عكارة الدخل، الحرارة، جرعة المخثر، pH كذلك قيم قياسات الألمنيوم المتبقي الذي استخدم كخرج للشبكة.

5 - المنطقة المدروسة:

تم العمل على بيانات محطة تنقية المياه في القصير، وهي محطة تم إنشاؤها على نهر العاصي لتزويد حماه بمياه الشرب، تبلغ طاقتها اليوم حوالي 6000 متر مكعب باليوم. ويجري حاليا العمل على توسيع المحطة.

تدخل المياه الخامية من نهر العاصي في قناة المأخذ، ويتم في المأخذ التحكم بكمية المياه المستجرة للمحطة وتصريف المياه الفائضة عن طريق أربع بوابات موجودة في المأخذ.

يتم إيصال المياه الى حوض المزج عن طريق قناة تنتهي بتضييق فنثوري من أجل زيادة سرعة المياه الداخلة لحوض المزج.

كافة الاضافات الكيميائية تضاف قبل الموزع الرئيسي، حيث تتم إضافة الشبة وجرعة الكلور الأولية.

بعد ذلك تتوزع المياه إلى 4 مرسبات دائرية الشكل بقطر 31m، ثم الى المرشحات الرملية عددها 20 مرشح من النوع المزدوج المكشوف والذي يعمل على الجاذبية والمزود بطبقة راشحة بحدود 1.5 متر.

تستجر المياه من المحطة إلى خزانات مدينة حماه بواسطة قناة بيتونية مغلقة بالراحة.



الشكل (5-1) صورة جوية للمحطة

6- النتائج والمناقشة:

بلغ عدد البيانات المستخدمة في الدراسة (450) سجل، تم أخذها على مدار 3 سنوات وكانت البيانات المتضمنة هي قيم العكارة الابتدائية، جرعة المخثر، درجة الحرارة، قيمة pH، وقيم الألمنيوم المتبقي. تم اتباع الخطوات التالية لمعالجة البيانات.

1. تحليل البيانات (Analyzing Data):

يشمل تحديد البيانات التي ستدخل في بناء النموذج عن طريق فرزها وتصفيتها.

▪ معالجة البيانات الشاذة:

يتم في هذه الخطوة تحديد عمود الهدف للشبكة العصبونية الذي سيمثل الخرج (Output)، كما يتم اكتشاف الشذوذ في البيانات، وتقسيمها إلى مجموعات، حيث يمكننا استبعاد الصفوف والأعمدة الشاذة والتي يمكن تقسيمها وفق الآتي:

القيم المتطرفة (Outliers) والقيم المفقودة (Missing Values).

القيمة المفقودة هي قيمة مجهولة تعتبر خلايا فارغة، بينما القيم المتطرفة هي قيم غير متجانسة وبعيدة عن بقية القيم في بيانات العمود، من الأفضل استبعاد كامل السجل في حال وجود قيمة متطرفة أو مفقودة في أعمدة الإدخال.

▪ تقسيم البيانات (Data Partition) بشكل

عشوائي لثلاث مجموعات، وقد قسمت البيانات بشكل عشوائي الى المجموعات التالية:

Training set، Validation set، Test set

مجموعة التدريب، التحقيق والاختبار بالنسب 70%،

15%، 15% على التوالي.

تستخدم الطرائق الأربعة السابقة الشبكات العصبية للانحدار المعمم (GRNN) لأنها تتدرب بسرعة وحساسية للمدخلات التفسيرية للمتغير التابع المعتمد في الدراسة. [10]

في هذا البحث تم اعتماد الخوارزمية الجينية في أمثلة تكوينات الإدخال وفق البارامترات المبينة بالشكل التالي.

الشكل (6-1): بارامترات الخوارزمية الجينية.

تابع الأداء (Fitness) المستخدم في المفاضلة بين التكوينات يعتمد على حساب خطأ الشبكة الناتج عن مجموعة الاختبار، والشكل التالي يوضح أبرز التكوينات المقترحة كمدخلات للنموذج.

| id | Features mask | Fitness |
|------------------------------|---------------|--------------|
| 0 | 1001 | 36.762455 |
| 1 | 1111 | 41.608677 |
| 2 | 0001 | 27.122612 |
| 3 | 1101 | 36.242722 |
| 4 | 0110 | 14.560592 |
| 5 | 1110 | 30.797778 |
| 6 | 1011 | 37.874985 |
| 7 | 0010 | 9.228344 |
| 8 | 1100 | 18.60998 |
| 9 | 1010 | 23.48774 |
| 10 | 0101 | 29.233391 |
| 11 | 0011 | 26.763607 |
| 12 | 1000 | 17.437355 |
| 13 | 0111 | 35.90976 |
| 14 | 0100 | 11.481087 |
| Best network's features mask | | Best fitness |
| 11 | 0011 | 41.858679 |

الشكل (6-2): أفضل التكوينات المقترحة للإدخال باستخدام الخوارزمية الجينية.

التكوين المقترح وفق الشكل (6-2) يشير إلى افضلية استخدام المدخلات الأربعة (عكارة الدخل، جرعة المخثر،

يتيح البرنامج امكانية تحديد عدد السجلات في كل مجموعة، ولكن الأسلوب العشوائي أكثر قدرة على البحث عن أزواج البيانات الأكثر تعبيراً عن البيانات المدروسة.

■ تحديد مدخلات نموذج (ANN) ومخرجاته

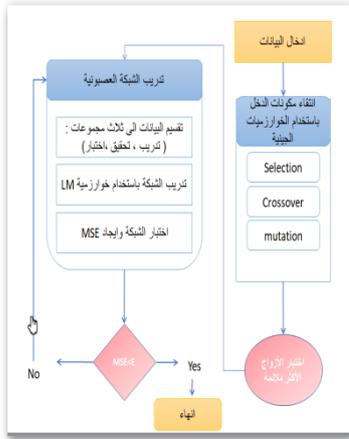
تهدف هذه الدراسة الى التنبؤ بقيم الألمنيوم في المياه الخارجة من المحطة (Aluminum)، وعليه قمنا بتحديد كعمود هدف (Target) ومخرج نموذج (ANN).

لتحديد أنماط الدخل الممكنة للنموذج لا يكفي الاعتماد على مصفوفة الارتباط (Pearson correlation) لاختيار أنماط الدخل الملائمة للتنبؤ بقيم الألمنيوم.

يمكن أن يتم استخدام احدى الطرائق التالية للانتقاء المميز للمدخلات وهي:

1. طريقة الاختيار الامامي (المباشر) Forward stepwise
2. طريق الحذف الخلفي (العكسي) Backwards stepwise
3. البحث الشامل Exhaustive search
4. الخوارزميات الجينية (Genetic algorithms): تبدأ

الطريقة بمجموعة عشوائية من مكونات الدخل للنموذج، واعتماداً على مبدأ البقاء للأفضل يتم تجاهل تكوينات الإدخال أثناء الاختبار، ويتم تكرار العملية السابقة وتوليد تكوينات إدخال جديدة تدعى (Generation) واستخدمها لتكوين مجتمع جديد (Population) حتى يتم تحديد التكوين الأفضل للمدخلات، ويتبادر للذهن ان هذه الطريقة تستغرق وقتاً أطول من الطرق الأخرى ولكنها جيدة لتحديد المدخلات المطلوبة بشكل متناوب واكتشاف الترابط فيما بينها.



الشكل (3-6) خوارزمية عمل الشبكة

3. تصميم الشبكة (Designing Network)

اعتماد التصميم النهائي لنموذج (ANN) يتكون من

جزئين هما:

- تحديد عدد الطبقات الخفية، ودوال التنغيع في كل من الطبقة الخفية وطبقة الخرج، واعتماد تابع مجموع مربعات الخطأ (MSE) لتقييم أداء النموذج وفق المجموعات الثلاثة.
- البحث عن بنية الشبكة (Architecture Network) والمتعلق بشكل أساسي بتحديد عدد العصبونات في الطبقة الخفية والمتوافق مع درجة التعقيد في المشكلة المدروسة، وهناك نمطين للبحث وهما:

❖ البحث التجريبي.

❖ البحث الشامل: يقوم على اختبار جميع الخيارات الممكنة ضمن مجال محدد لعدد العصبونات وخطوة انتقال محددة فيما بينها في الطبقة الخفية.

تم استخدام البحث التجريبي من خلال ترشيح مجموعة من التصاميم ضمن مجال محدد لعدد العصبونات في الطبقة الخفية ببيتين (10) و(50) عصبوناً، وبخطوة انتقال (2) عصبون، واعتماد معيار مقلوب الخطأ لمجموعة التحقيق (Inverse Validation Error) كمعيار حاسم (Fitness) لانتقاء بنية الشبكة بالإضافة إلى معايير

الحرارة، pH) كمدخلات للنموذج الهادف للتنبؤ بالمتغير (الألمنيوم المتبقي)

حيث كانت قيمة تابع الكفاءة بهذه الحالة 41.85677.

2. معالجة البيانات (Preprocessing Datasets)

تقوم هذه المرحلة على المعالجة المسبقة للبيانات قبل تدريب الشبكة العصبونية الاصطناعية، ويتم ذلك من خلال عملية التقييس (Normalization) للقيم الرقمية بما يتناسب مع الخلايا العصبونية التي لديها نطاق محدد من قيم التشغيل، كما هو موضح في الجدول (1-6).

الجدول (1-6): مجال التحجيم الخاص بدوال التنغيع.

[11]

| Output layer activation function | Scaling range |
|----------------------------------|---------------|
| Linear | [-1. . 1] |
| Logistic | [0. . 1] |
| Hyperbolic Tangent | [-1. . 1] |

• يتم إجراء التقييس في النموذج تلقائياً وفق المعادلة التالية:

$$S_f = \frac{(SR_{max} - SR_{min})}{(X_{max} - X_{min})} \dots \dots \dots (6 - 1)$$

$$X_p = SR_{min} + (X - X_{min}) * S_f \quad (6 - 2)$$

حيث:

X : القيمة الحقيقية & X_{min} : القيمة الصغرى الحقيقية
& X_{max} : القيمة العظمى الحقيقية & SR_{min} : الحد الأدنى الفعلي لمجال التحجيم & SR_{max} : الحد الأعظمي الفعلي لمجال التحجيم & S_f : معامل التحجيم & X_p : القيمة بعد المعالجة.

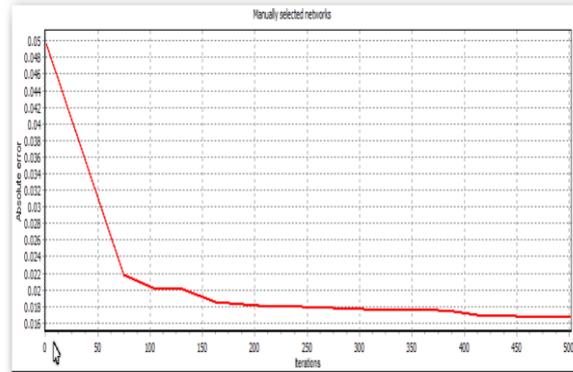
تم في هذا البحث استخدام المجال الثنائي القطب [-1,1] الخاص بدالة الظل القطعي (Hyperbolic Tangent) من أجل أعمدة الإدخال، والمجال [0,1] الخاص بالدالة اللوجستية (Logistic) لعمود الخرج.

المفاضلة الأخرى؛ مع تكرار الحسابات (Iteration=500) عند تشغيل النموذج (Retrain=1) لمرة واحدة. ويبين الجدول (6-6) النتائج التي حصلنا عليها لبنية أفضل 9 شبكات مقترحة، حيث تبين أن أفضل بنية هي (4-7-1)، أي وجود أربع عصبونات في طبقة الدخل وسبعة عصبونات في الطبقة الخفية، وعصبون واحد في طبقة الخرج.

الجدول (2-6) نتائج البحث التجريبي عن بنية الشبكة العصبونية الأفضل

| Architecture | Fitness | Train Error | Validation Error | Test Error | Correlation | R-square |
|--------------|----------|-------------|------------------|------------|-------------|----------|
| [4-8-1] | 4509 .37 | 01715 .0 | 02636 .0 | 02670 .0 | 92789 .0 | 86077 .0 |
| [4-6-1] | 6717 .37 | 02192 .0 | 02904 .0 | 02655 .0 | 87511 .0 | 76495 .0 |
| [4-5-1] | 6879 .38 | 01954 .0 | 02859 .0 | 02585 .0 | 90303 .0 | 81543 .0 |
| [4-12-1] | 5932 .40 | 01531 .0 | 02501 .0 | 02464 .0 | 94031 .0 | 88414 .0 |
| [4-4-1] | 3546 .41 | 02149 .0 | 03056 .0 | 02481 .0 | 88812 .0 | 78764 .0 |
| [4-7-1] | 3136 .44 | 01701 .0 | 0264 .0 | 02256 .0 | 9235 .0 | 85268 .0 |

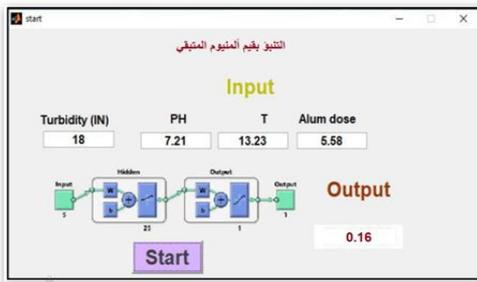
البنية الأفضل للشبكة العصبونية هي (1-4-7-1) ANN 7- وهي الشبكة التي تم اعتمادها وتمت عليها عملية التدريب. ويوضح الشكل (4-6) انحدار الخطأ المطلق للنموذج العصبوني الصناعي المقترح ANN (4-7-1).



الشكل (4-6): انحدار الخطأ للنموذج ANN

4. تدريب الشبكة العصبونية (Training Networks) بعد اختيار هيكلية الشبكة (4-7-1) ANN الأفضل تُدرّب الشبكة بتقديم بيانات التدريب، يبدأ التدريب انطلاقاً من أوزان ابتدائية وتغيير مع تكرار الحسابات باتجاه تحسين أداء الشبكة وتحقيق أقل خطأ ممكن، ومع تحديد معدل التعلم (The Learning Rates) والزخم (Momentum) واختيار معايير توقف التدريب لتجنب التدريب المفرط، سيتوقف التدريب عندما يصل متوسط مربع الخطأ (MSE) للقيمة (0.01) أو اكتمال التدريب عند 500 تكرار، أيهما يحدث أولاً. ويتم اعتماد المفاضلة بين الشبكات عن طريق حساب متوسط الخطأ المطلق (Average Absolute Error)، وخطأ الشبكة

ولسهولة تعامل المستخدم مع النموذج العصبوني المقترح (4-7-1) المقترح قمنا بإنشاء واجهة مستخدم رسومية (Graphical User Interface) GUI باستخدام لغة Matlab 2014a مع إمكانية تصديرها بلاحقة (.exe) لتعمل على جميع منصات ويندوز. بحيث يمكن استخدام هذه الواجهة من قبل المستخدم مباشرة كتطبيق منفصل.



الشكل (6-6) واجهة مستخدم رسومية GUI لتقدير الألمنيوم في محطة القصي

الاستنتاجات والتوصيات:

تم التوصل في هذا البحث إلى النتائج الآتية:

- 1- بين البحث الكفاءة العالية للشبكات الهجينة GA-ANN في التنبؤ بقيم الألمنيوم المتبقي للمياه الخارجة من محطات التنقية باستخدام نماذج تحوي على المدخلات (العكارة، الحرارة، PH، جرعة المخثر). كما أثبتت النتائج العملية كفاءة الخوارزمية المستخدمة في الوصول إلى شبكة عصبونية مثلى.
- 2- تم التوصل الى نموذج عصبوني يمكنه التنبؤ بعكارة المياه بدقة $AE = 0.024$ و $R = 0.93$.
- 3- وفقاً لنتائج النموذج فإن بارامترات المياه الخام الداخلة الى محطة التنقية تؤثر بشكل كبير على قيمة ع الألمنيوم المتبقي وهي على التوالي عكارة الدخل، جرعة المخثر، الPH، الحرارة.

(Sum-of-Squares) وفقاً لخوارزمية التدريب المختارة، والمقارنة فيما بينها من حيث الدقة والسرعة في الأداء (عدد التكرارات بالثانية).

تم تجريب عدد من الخوارزميات المتاحة وكما هو موضح في الجدول (3-6) إن نتائج خوارزميات التدريب كانت كلها جيدة ومقاربة نوعاً ما، ويبين تفوق خوارزمية (LM) على الخوارزميات الأخرى من حيث (MSE) الأقل للمجموعات الثلاثة (تدريب، تحقيق، اختبار)، ومعامل الارتباط القريب من الواحد.

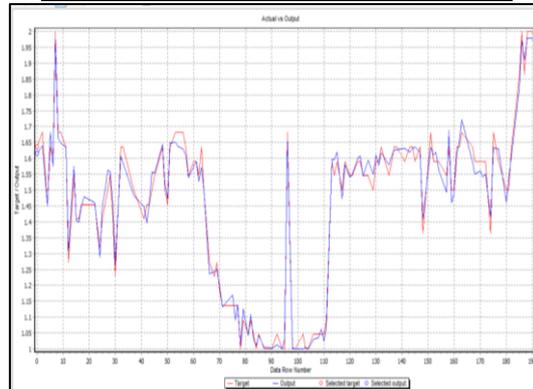
حيث كانت قيمة $R = 0.93$ وقيمة الخطأ المطلق

$$AE = 0.024$$

الجدول (3-6) معامل الارتباط، متوسط مربعات الأخطاء

(MSE) لخوارزميات التدريب

| | Statistical Indicators | All Data |
|----------------------------|------------------------|----------|
| Quivk Propagation | R | 0.804 |
| | AE | 0.03 |
| Conjugate Gradient Descent | R | 0.9 |
| | AE | 0.03 |
| Quasi-Newton | R | 0.9 |
| | AE | 0.03 |
| Levenberg - Marquardt | R | 0.93 |
| | AE | 0.024 |
| Online Back Propagation | R | 0.87 |
| | AE | 0.016 |
| Batch Back Propagation | R | 0.89 |
| | AE | 0.014 |



الشكل (5-6): مقارنة بين القيم الحقيقية للألمنيوم

المتبقي والقيم المتنبأ بها لمجموعة الاختبار

4- تم بناء واجهة مستخدم رسومية تفاعلية لسهولة استخدامها وتعامل على جميع أنظمة ويندوز .

المراجع:

- [1] Daghbandan, A. , Khalatbari, S. , & Abbasi, M. M. (2019). Applying GMDH-type neural network for modeling and prediction of turbidity and free residual aluminium in drinking water. *Desalination Water Treat*, 140, 118-131.
- [2] Haghiri, S. , Daghighi, A. , & Moharramzadeh, S. (2018). Optimum coagulant forecasting by modeling jar test experiments using ANNs. *Drinking Water Engineering and Science*, 11(1),1-8.
- [3] Kim, C. M. , & Parnichkun, M. (2017). Prediction of settled water turbidity and optimal coagulant dosage in drinking water treatment plant using a hybrid model of k-means clustering and adaptive neuro-fuzzy inference system. *Applied Water Science*, 7(7), 3885-3902. .
- [4] YANNIE ANAK BENSON (2006), EFFECT OF RAW WATER QUALITY ON COAGULANT DOSAGE AND OPTIMUM ph. Faculty of Civil Engineering,Universiti Teknologi Malaysia.
- [5]] Tomperi, J. , Pelo, M. , & Leiviskä, K. (2013). Predicting the residual aluminum level in water treatment process. *Drinking Water Engineering and Science*, 6(1), 39-46.
- [6] Osekrieh, Aziz Adel, J 1994- Application of Non-Linear Autoregressive Neural Networks for Predicting the Drinking Water Turbidity of Al-Sin Water Purification Plant. Tishreen University,
- [7] Wang, W. , Yang, H. , Wang, X. , Jiang, J. , & Zhu, W. (2010). Effects of fulvic acid and humic acid on aluminum speciation in drinking water. *Journal of Environmental Sciences*, 22(2), 211-217.
- [8] Einstein, A. ,2003. The Nature of Science and the Scientific Method. GSA Distinguished Earth Science Educator in Residence
- [9] C. L. Barajas, A. J. León-Luque P. (2015). Determination of the Optimal Dosage of Aluminum Sulfate in the Coagulation-Flocculation process using an Artificial Neural Network. Faculty of Environmental Engineer, Santo Tomás Univeristy, Bogotá, Colombia

التوصيات:

- 1- تجريب نماذج خوارزميات أخرى للشبكات للتنبؤ بقيم الألمنيوم المتبقي.
- 2- استخدام النماذج العصبونية للتنبؤ بالبارامترات لمختلفة في محطة التنقية مثل قيم العكارة وقيم pH.
- 3- استخدام الشبكات العصبونية للتقييم المستمر عمل محطات التنقية.

مسرود المصطلحات:

| | |
|----------------|------------------------------------|
| ANN | الشبكات العصبونية الصناعية |
| GA | الخوارزميات الجينية |
| Hybrid network | شبكة هجينة |
| Residual Al | الألمنيوم المتبقي |
| GMDH | طريقة المجموعة للتعامل مع البيانات |
| Cogulation | التخثير |
| RMSE | جذر مربع متوسطات الأخطاء |
| MLR | الانحدار المتعدد للخطأ |

[10] Kim, C. M. , & Parnichkun, M. (2017). MLP, ANFIS, and GRNN based real-time coagulant dosage determination and accuracy comparison using full-scale data of a water treatment plant. Journal of Water Supply: Research and Technology—AQUA, 66(1), 49-61.

[11] ZUPAN, J 1994- Introduction to Artificial Neural Networks (ANN) Methods. Department of Chemistry,

| | | |
|--------------------|-----------|------------------|
| Received | 2021/2/1 | إيداع البحث |
| Accepted for Publ. | 2021/8/11 | قبول البحث للنشر |