

تقييم أداء محطات معالجة مياه الصرف الصحي باستخدام الشبكات العصبونية الصناعية (ANN)

الدكتور رائد جعفر*

تاريخ الإيداع 6 / 2 / 2017. قُبل للنشر في 5 / 4 / 2017

□ ملخص □

يعد وضع نماذج متطورة لوحدة معالجة مياه الصرف الصحي Wastewater Treatment Plants أمر أساسي من أجل توفير أدوات لتقييم أدائها والتنبؤ به، وتشكل أساساً للتحكم في تشغيل وسيرورة عملية المعالجة. هذا من شأنه التقليل من تكاليف عملية التشغيل والمراقبة وتقييم استقرار التوازن البيئي. تركّز هذه الورقة العلمية على استخدام طريقة الشبكات العصبونية الصناعية (ANN) Artificial Neural Network ذات تقنية التغذية إلى الأمام والانتشار العكسي للخطأ، حيث بُنيت النماذج الرياضية باستخدام الأداة nntool الملحقة ببرنامج Matlab لتحديد العلاقة بين بارامترات التلوث المختلفة و للتنبؤ بأداء وحدة معالجة بلدة مرج معيربان لمعالجة مياه الصرف الصحي .WWTP

اعتمدت النماذج على بيانات مؤشرات التلوث التي تم جمعها خلال البحث على مدى ثلاثة أعوام وهي المؤشرات الرئيسية التي تشمل الطلب على الأكسجين الكيميائي (COD) والطلب على الأكسجين البيوكيميائي (BOD₅)، والمؤشرات المساعدة التي تضمنت كمية المواد الصلبة العالقة الكلية (TSS)، درجة الحرارة (T) ودرجة الحموضة (pH). تشير الدراسة إلى أن تطبيق طريقة الـ ANN تمكن من التنبؤ بأداء محطة المعالجة مع معامل الارتباط (R) بين متغيرات الخرج المقاسة والمحسوبة (المُتنبأ بها) وصل إلى (88%) بالنسبة لنموذج الـ COD، (85%) بالنسبة لنموذج الـ BOD₅ و (86%) بالنسبة لنموذج الـ COD&BOD₅. وبالنتيجة، توفر هذه النماذج أداة فعالة ومهمة لفهم وتحليل ومحاكاة سلوك الظواهر غير الخطية في عمليات المعالجة لمياه الصرف الصحي، ويمكن استخدامها كأداة قيمة ومفيدة لمشغليها وصانعي القرار في هذه المنشأة البيئية الحيوية.

الكلمات المفتاحية: الشبكات العصبونية الصناعية، MATLAB، النمذجة، التحليل الإحصائي، محطة معالجة مياه الصرف الصحي، بلدة مرج معيربان.

* مدرس - قسم الهندسة البيئية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Assessment of the Wastewater Treatment Plants Performance Using Artificial Neural Networks (ANN)

Dr. Raed Jafar*

(Received 6 / 2 / 2017. Accepted 5 / 4 / 2017)

□ ABSTRACT □

Developed models for Wastewater Treatment Plants WWTP is essential in order to provide tools for assessment and predicting there's performance and to form a basis for controlling the operation of the process. This would minimize the operation and monitoring costs, and assess the stability of environmental balance. This paper focuses on using an Artificial Neural Network (ANN) approach with a Feed-Forward Back-Propagation, mathematical models have been created by using nntool built-in MATLAB Software to determine the relationship between various parameters of pollution and to predict the performance of the Merge Mouerbain WWTP town.

Models based on the pollution indicators data that have been collected during a research over three-year period, the main indicators that include Chemical Oxygen Demand (COD), Biochemical Oxygen Demand (BOD₅), and auxiliary Indicators which included the amount of Total Suspended Solids (TSS), Temperature (T) and the degree of acidity or alkalinity (pH). The study signifies that the ANN can predict the plant performance with correlation coefficient (R) between the observed and predicted output variables reached up to (88%) for the COD model, (85%) for the BOD₅ model and (86%) for the COD&BOD₅ together model. Finally, ANN models provides an effective analyzing tool to comprehend and simulate the non-linear behavior of the plant, and it can be used as a valuable performance assessment tool for plant operators and decision makers.

Keywords: Artificial neural networks; MATLAB; Modeling; Simulation; Statistical analysis; Wastewater treatment plant.

*Assistant Professor, Department of Environmental Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

في السنوات الأخيرة، تم تطبيق أساليب تقنية حديثة تعتمد على الكمبيوتر وعلى تقانات الذكاء الصناعي في العديد من المجالات وخاصة القضايا البيئية. إن عملية التحكم التشغيلية لوحددة معالجة مياه الصرف الصحي البيولوجية (Wastewater Treatment Plants (WWTP كثيرا ما تكون صعبة بسبب التغيرات في تركيبة مياه الصرف الصحي الخام، واختلاف معدلات التدفق، والطبيعة المعقدة لسيروية عملية المعالجة [1]. بالإضافة إلى ذلك، إن عدم توفر المراقبة الدائمة وقياس متغيرات التلوث المختلفة لعملية المعالجة بشكل دوري يحد من السيطرة الفعالة على جودة مياه الصرف الخارجة [2]. تتنوع خصائص مياه الصرف الداخلة إلى وحدة المعالجة من وحدة معالجة إلى أخرى تبعا لنوع الحياة المعاشية ونمطها في المجتمع المدروس. ولذلك، فإن أداء أي وحدة معالجة WWTP يعتمد بشكل أساسي على الخبرة المحلية والعملية لمهندسي المحطة الذين يقومون بتحديد حالتها [3].

تستند تقنيات النمذجة التقليدية المستخدمة في العمليات الحيوية (Bioprocesses) على معادلات التوازن مع معادلات معدل نمو البكتريا، واستهلاك الطبقة المغذية (Substratum consumption). ومنذ أن تم دمج التفاعلات الميكروبية مع التفاعلات البيئية أصبحت تلك المعادلات غير خطية، متغيرة مع الزمن وذات طبيعة معقدة [4]، لقد أظهرت النمذجة (الحتمية) التقليدية والنمذجة التجريبية بعض القيود [5]. أيضاً يُعتبر التنبؤ بالبارامترات التشغيلية لوحددة المعالجة باستخدام تقنيات تجريبية تقليدية خطوة تحتاج للوقت الطويل وتشكل عقبة في طريق السيطرة الفعالة لهذه العمليات [6].

يمكن استخدام تقنية الشبكات العصبونية الصناعية ANN لنمذجة سيروية عمليات المعالجة في وحدات معالجة مياه الصرف الصحي WWTP. ويمكن استخدامها لتحسين التنبؤ بأداء عملية المعالجة وذلك بسبب الدقة العالية والملاءمة الكافية في تطبيقاتها الواعدة جداً في مجال الهندسة البيئية [7]، [8]، [9].

تعتمد هذه التقنية عادة على البيانات النموذجية المتوفرة لسيروية عملية المعالجة في WWTP، وهناك بعض المتغيرات الرئيسية التي يمكن استخدامها لتقييم أداء وحدة المعالجة. وتشمل هذه المتغيرات الطلب على الأكسجين البيولوجي (BOD_5)، الطلب على الأكسجين الكيميائي (COD)، والمواد الصلبة العالقة الكلية (TSS). معظم الكتابات المتاحة في الأبحاث السابقة عن تطبيق واستخدام الشبكات العصبونية الصناعية في نمذجة وحدات معالجة مياه الصرف الصحي استخدمت هذه المتغيرات ووجدت أن هذه النماذج الأساسية لـ ANN تقدم أداة فعالة وقوية في محاكاة العمليات المعقدة والأنظمة اللاخطية وبشكل خاص في التنبؤ بأداء وحدات المعالجة WWTP. ووجد مؤشر ارتباط في بعض الحالات مساوٍ إلى (0.82 - 0.8) ، لذا فقد أحرزت اهتماماً كبيراً في السنوات الأخيرة. [10] [11].

وجد Hamoda وآخرون (1999) في نمذجة وحدات معالجة مياه الصرف الصحي باستخدام الـ ANN، معامل ارتباط بين القيم المحسوبة والمقاسة مساوٍ لـ (0.74) عند التنبؤ بمؤشر التلوث BOD_5 الخارج و (0.72) لمؤشر TSS في محطة معالجة مدينة الكويت [1].

أما الدراسة التي قام بها Belanche وآخرون (1999) فقد وجدوا معامل ارتباط فقط (0.504) أثناء التنبؤ بمؤشر الـ COD لمحطة معالجة منتجج سياعي (Costa Brava (Catalonia) [12].

وجد Häck and Köhne (1996) معامل ارتباط (0.92) و (0.82) للتنبؤ بمؤشر COD والنترات على التوالي، لمحطة معالجة مياه الصرف الصحي قرب مدينة (Siegen (Germany) [13].

أجرى (Monika Vyas, Bharat Modhera, Vivek Vyas and A. K. Sharma) (2011) في الهند دراسة للتنبؤ ببارامترات محطات المعالجة باستخدام الشبكة العصبونية الصناعية ANN حيث تم تشكيل نموذجين باستخدام ANN مع منهجية التغذية الأمامية (3 طبقات) وخوارزمية الانتشار الخلفي للتنبؤ بتركيز BOD_5 الداخلة والخارج من عمليات معالجة مياه الصرف الصحي بعد جمع بيانات الـ BOD_5 من محطة معالجة Govindpura في بوبال، الهند. لقد وجدوا أن كفاءة المحطة لإزالة الـ BOD_5 هي 80% (من خلال بيانات 3 سنوات تم جمعها من التدفقات الداخلة والخارجة من المحطة). وقد أثبتت هذه الدراسة أن استخدام الشبكة العصبونية الصناعية أفضل من أسلوب النمذجة الرياضية التقليدية، نظراً لفعاليتها الجيدة في التنبؤ بمؤشرات المعالجة المختلفة [14].

قام (Mahmoud S. Nasr, Medhat A.E. Moustafa, Hamdy A.E. Seif, Galal El Kobrosy) (2012) في مصر بدراسة تطبيقات الشبكة العصبونية الصناعية ANN للتنبؤ بأداء محطة العجمي في الاسكندرية حيث اعتبروا أن وضع نموذج باستخدام ANN لأي محطة معالجة يشكل أساساً للسيطرة على عمل هذه المحطة كما من شأنه تقليل تكاليف التشغيل وتقييم استقرار التوازن البيئي وقد تم تشكيل نموذج باستخدام ANN مع خوارزمية الانتشار الخلفي للتنبؤ بتركيز COD , BOD_5 , TSS من خلال بحث أنجز خلال سنة واحدة. أشارت النتائج إلى فعالية ANN للتنبؤ بأداء المحطة مع معامل ارتباط بين المتغيرات يصل إلى 0.9، كما أنها توفر أداة فعالة لفهم السلوك غير الخطي ومحاكاته لعمليات المعالجة في المحطة [15].

يتناول هذا البحث مشكلة إيجاد وتحديد العلاقات المعقدة القائمة بين بعض متغيرات عملية المعالجة البيولوجية وتشخيص السلوك الديناميكي لوحدة معالجة مياه الصرف الصحي لبلدة مرج معيربان (WWTP) في ريف مدينة اللاذقية، من خلال تطوير تقنية الشبكات العصبونية الصناعية (ANN). حيث يمكن تحقيق عمليات معالجة أكثر أماناً والتحكم بوحدة المعالجة من خلال تطوير نماذج الـ ANN للتقييم والتنبؤ بأداء وحدة المعالجة وذلك بالاعتماد على قياسات وسجلات متوفرة لبعض بارامترات التلوث الرئيسية (COD , DOD_5) والمساعدة (TSS , T , pH) لعملية المعالجة.

أهمية البحث وأهدافه:

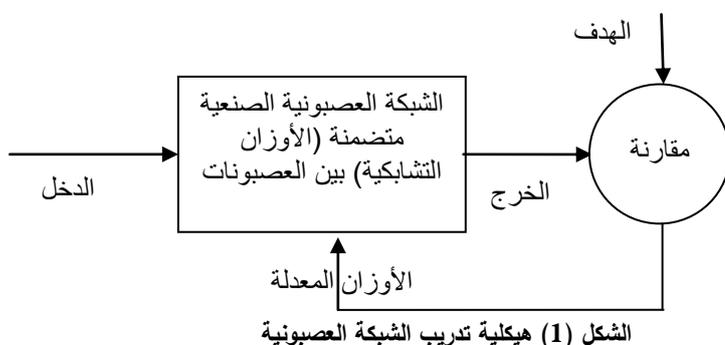
انطلاقاً من أهمية حماية الموارد المائية والحفاظ على البيئة من التلوث الناتج عن صرف مياه محطات المعالجة التي لا تعمل بشكل صحيح، الأمر الذي يدفعنا إلى مراقبة، تقييم وتحسين عمل هذه المحطات بشكل مستمر وفي كافة منشآتها. يمكن تحقيق ذلك باستخدام تقانات الذكاء الصناعي الحديثة وبدقة عالية. يهدف هذا البحث إلى وضع نماذج رياضية للعلاقة بين مؤشرات التلوث المختلفة الرئيسية والمساعدة (COD , BOD_5 , TSS , $Temperature$, pH) في محطة معالجة مرج معيربان من خلال تدريب الشبكة العصبونية الصناعية بهدف تحديد الخوارزمية ذات الأداء الأفضل، ومن ثم بناء هذه النماذج لتحديد العلاقة بين المؤشرات المختلفة باستخدام الشبكات العصبونية الصناعية، يلي ذلك تقييم أداء النماذج المقترحة باستخدام تقانة Simulink المتاحة في حزمة برمجيات Matlab.

طرائق البحث ومواد:

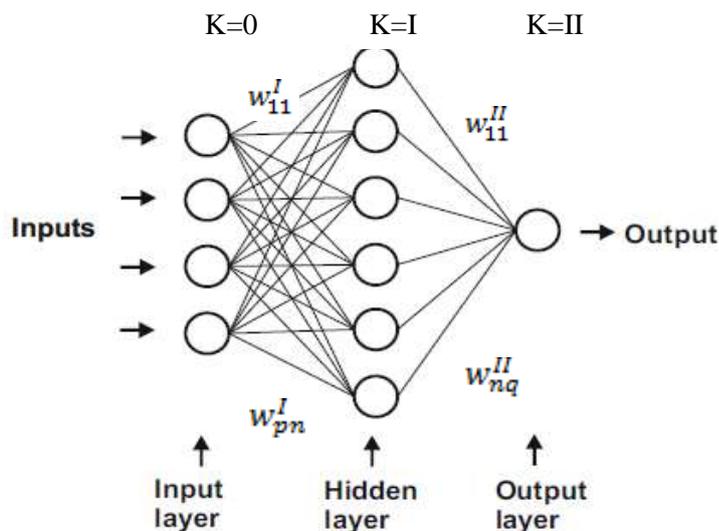
1. الشبكات العصبونية الصناعية (ANN):

تعتمد هذه الدراسة على إنشاء نماذج متعددة من الشبكات العصبونية الصناعية (ANN)، حيث تعرف هذه الشبكات بأنها نظام لمعالجة البيانات بشكل مستوحى ويحاكي طريقة معالجة البيانات عند الانسان مثل الجهاز العصبي البيولوجي على سبيل المثال الدماغ البشري. الهدف من الشبكة العصبونية هو حساب قيم الناتج من قيم الإدخال بواسطة بعض الحسابات الداخلية [16].

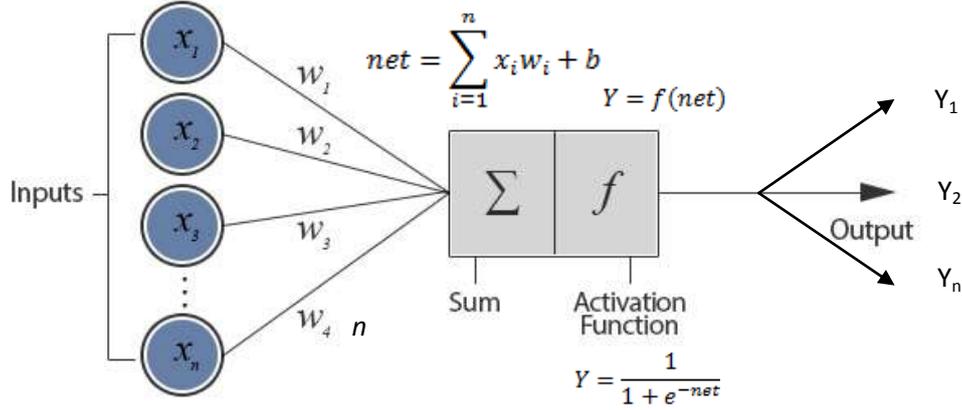
يتم تدريب الشبكة العصبونية لأداء وظيفة معينة عن طريق تعديل وضبط قيم (الاتصال بين العصبونات) أي الأوزان التشابكية بين عناصر الشبكة (على أساس عملية المقارنة بين المخرجات والهدف) حتى يطابق خرج الشبكة قيم الهدف، وبذلك يمكن للشبكة التنبؤ بالمخرجات الصحيحة لمجموعة معينة من المدخلات. الشكل (1) يوضح هذه الحالة [17].



تتكون الشبكات العصبونية ذات التغذية الأمامية (Feed-Forward) بشكل عام من نظام من الخلايا العصبونية التي يتم ترتيبها في طبقات متعددة، طبقة الإدخال (Input layer) وطبقة الإخراج (Output layer) وطبقة واحدة على الأقل من الطبقات الخفية (Hidden layer)، حيث يرتبط كل عصبون في كل طبقة مع كل عصبون في الطبقة التالية بوزن مبدئي ومن ثم يتم تعديله وضبطه أثناء عملية التدريب والتعلم، الشكل (2) [18].



يبين الشكل (3) عملية تحويل البيانات المارة في الشبكة، حيث تضرب مدخلات الشبكة (سواء قيم الدخل أو الخرج من العصبونات السابقة) بالأوزان المرافقة لاتصالاتها (W)، حيث تعبر هذه الأوزان عن قوة الاتصال بين العصبونات، ثم تجمع النتائج للقيمة الإضافية التي تدعى بالانحياز (b). يعدل ناتج الشبكة هذا بواسطة تابع التنشيط أو التفعيل (f) (Activation function) إلى قيمة فعالة للعصبون، يرمز لها بـ Y ، حيث يعاد نشر هذه القيمة الفعالة إلى العصبونات التالية.



الشكل (3) التركيب البنوي داخل عصبون الشبكة العصبونية الصناعية.

في دراستنا هذه تم استخدام الشبكات العصبونية الصناعية ذات التغذية الأمامية Feed Forward FFNNs Neural Network، يقصد بالتغذية الأمامية للشبكات انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من الإدخال باتجاه طبقة الإخراج، من الأمثلة على هذه الشبكات، الشبكات العصبونية ذات الانتشار العكسي للخطأ Error Back Propagation ويسمى هذا النوع من الشبكات بشبكات الانتشار العكسي للخطأ، لأن المخرجات الحقيقية للشبكة تُقارن مع المخرجات الهدف، والفرق بين هذه القيم يدعى بالخطأ الذي تقوم الشبكة بنشره بدءاً من طبقة المخرجات مروراً بالطبقات الخفية باتجاه طبقة المدخلات، أي بآلية معكوسة لما يتم في مرحلة حساب المخرجات حيث يكون اتجاه الحساب أمامياً. [19].

ولغرض التعبير عن آلية الانتشار العكسي للخطأ رياضياً يتطلب ذلك توضيح آلية التغذية الأمامية رياضياً

وبشيء من التفصيل، كما هو موضح في المعادلات الآتية: [20]

أولاً- مرحلة التغذية الأمامية:

حيث يرتبط الخرج Y_i^{k-1} للخلية العصبونية (i) في الطبقة (k-1) لشبكة التغذية الأمامية مع الدخل من الخلية

العصبونية z في الطبقة اللاحقة k بواسطة عامل تحميل حقيقي (W_{ji}^k).

حيث: k : دليل الطبقة (k=I,II)

i : دليل الخلية في الطبقة (K-1)

z : دليل الخلية في الطبقة (K)

لحساب الخرج Y_j^k فإن الخلية العصبونية z للطبقة k [k=I,II] تقوم بالعملية الحسابية الآتية:

$$Y_j^k = f^k \left[\sum_{i=1}^N (W_{ji}^k \cdot Y_i^{k-1}) + b_j \right] \quad (1)$$

حيث:

N : عدد الخلايا أو الوحدات في الطبقة k-1

f^k : دالة التحويل (Transfer Function)

يعد شعاع الانحياز (bj) بمثابة الحد الثابت في المعادلات الرياضية كثيرات الحدود الذي يساعد في حل تلك المعادلات بصورة أسهل وأسرع.

ثانياً- مرحلة الانتشار العكسي للخطأ : حيث يتم احتساب الخطأ في وحدة المخرجات، ومعدل مربع الخطأ (MSE) ومعامل تصحيح الخطأ (δ) وفقاً للمعادلتين الآتيتين:

$$MSE = err = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (y_i - a_{(2)})^2 \quad (2)$$

$$\delta = - \frac{\partial err}{\partial a_{(2)}} \quad (3)$$

حيث:

err: معدل مربع الخطأ في وحدة المخرجات، Y : المخرجات الهدف Target، δ : معامل تصحيح الخطأ (Delta)، $a_{(2)}$: المخرجات الفعلية المحسوبة.

ثالثاً- مرحلة تحديث الأوزان : حيث يتم تحديث الأوزان وعامل الانحياز كما يلي:

$$W_{(New)} = W_{(old)} + \Delta W \quad (4)$$

$$b_{(New)} = b_{(old)} + \Delta b \quad (5)$$

حيث: ΔW : معامل تصحيح الوزن، Δb : معامل تصحيح عامل الانحياز.

هناك طريقتان مختلفتان لعملية تحديث أوزان الشبكة العصبونية الصناعية، وذلك بافتراض أن مدخلات الشبكة تكون على شكل مصفوفة رياضية مكونة من صفوف وأعمدة، وكل صف من هذه الصفوف يمثل متجهاً يحتوي على جميع المتغيرات المراد إدخالها إلى الشبكة [21].

• طريقة تجزئة المدخلات Increment input method: يتم في هذه الطريقة إدخال المصفوفة صفافاً،

ومن ثم تُحدث الأوزان لتلك الصفوف تباعاً، لذلك تمتاز هذه الطريقة بحاجتها إلى ذاكرة محدودة.

• طريقة الدفعة الواحدة للمدخلات Batch input method: تتضمن هذه الطريقة إدخال المصفوفة كاملةً

ودفعةً واحدةً، حيث تحدث الأوزان لمرة واحدة وفقاً لذلك، وتمتاز هذه الطريقة بسرعة تنفيذها، غير أنها تحتاج إلى ذاكرة أكبر من الطريقة السابقة. وهي الطريقة المعتمدة في هذا البحث.

إنّ عملية تحديث الأوزان يمكن أن تعاد آلاف المرات في التطبيقات العملية المألوفة، ويتوقف التدريب عادةً عند

الوصول إلى مستوى مقبول للخطأ، أو عند الوصول إلى عدد التكرارات (Epochs) المحددة مسبقاً من المدرب.

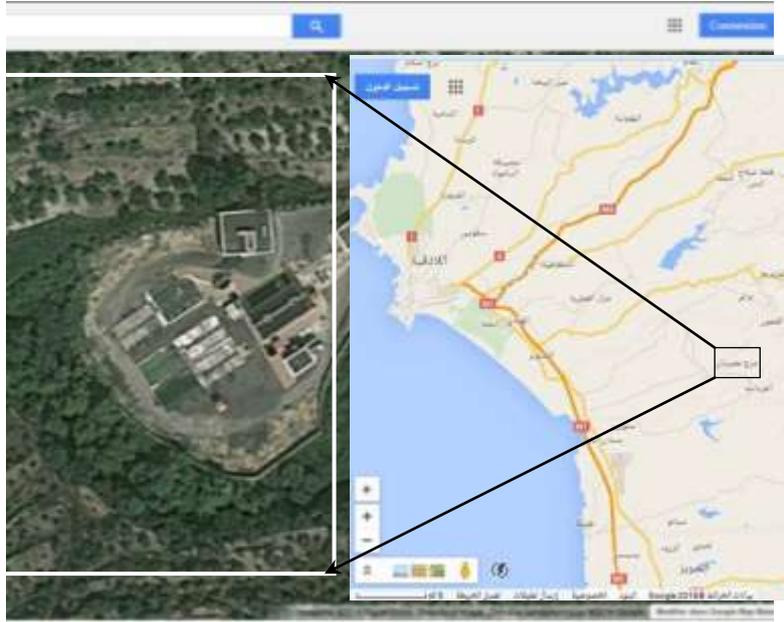
قمنا باختبار عدة معماريات للشبكة العصبونية الصناعية بهدف الوصول إلى أفضل أداء وذلك باستخدام مكتبة

NN FTool Box المضمنة في بيئة عمل الـ Matlab وخوارزمية (LM Levenberg Marquardt) لتدريب الشبكة وتابع السيغمويد (Sigmoid transfer function) كتابع تحويل للطبقة الخفية والتابع الخطي (Linear transfer

(function) كتابع تحويل لطبقة المخرجات، واعتمدنا على قيم معدل مربع الخطأ (MSE Mean Squared Error) ومعامل الارتباط (Correlation Coefficient) للتحقق من أداء الشبكة.

2 تجميع البيانات:

قمنا بتطوير الشبكة العصبونية الصناعية ANN لإنتاج نموذج يحاكي محطة معالجة مياه الصرف الصحي لبلدة مرج معيربان في ريف مدينة اللاذقية. الشكل (4) يبين الموقع العام للمحطة. تعتمد هذه المحطة على طريقة التهوية المطولة (المديدة) في عملية المعالجة البيولوجية، صُممت المحطة بسعة تصميم $500 \text{ m}^3/\text{day}$ حيث تحقق عملية المعالجة معايير النفايات السائلة وفق المواصفات القياسية السورية المعتمدة لمياه الصرف الصحي المعالجة في المدن. تم جمع القياسات المتوفرة للمؤشرات: BOD_5 , COD, TSS, Temperature, pH على مدى ثلاثة أعوام، باعتبار أن هذه الفترة كافية وتغطي جميع التغيرات الفصلية المحتملة في المتغيرات المدروسة.



الشكل (4) موقع محطة مرج معيربان لمعالجة مياه الصرف الصحي.

إن إنشاء نموذج الشبكات العصبونية الصناعية ANN يعتمد بشكل رئيسي على قواعد البيانات المتوفرة والخاصة بعوامل الظاهرة المدروسة، لذلك تم تحليل بيانات هذه العوامل (المدخلات والمخرجات) إحصائياً، والتي تم جمعها خلال فترة البحث عن طريق تحليل التباين في اتجاه واحد من التابع ANOVA1 والموجود في بيئة عمل برنامج MATLAB.

نشير هنا إلى أنه تم تطبيق هذا التحليل ANOVA1 قبل الشروع بتطوير نماذج الـ ANN وذلك من أجل رفض واستبعاد البيانات الخام ذات القيم الشاذة وغير الدقيقة في قاعدة البيانات.

النتائج والمناقشة:

أثناء عملية تحضير قاعدة البيانات تم تصنيف مجموعة البيانات إلى أربع مجموعات في مصفوفة وتحليلها إحصائياً عن طريق رسم صندوق مربع وشعيرات (Box and Whiskers) لكل متغير الشكل (5)، كل مجموعة تمثل

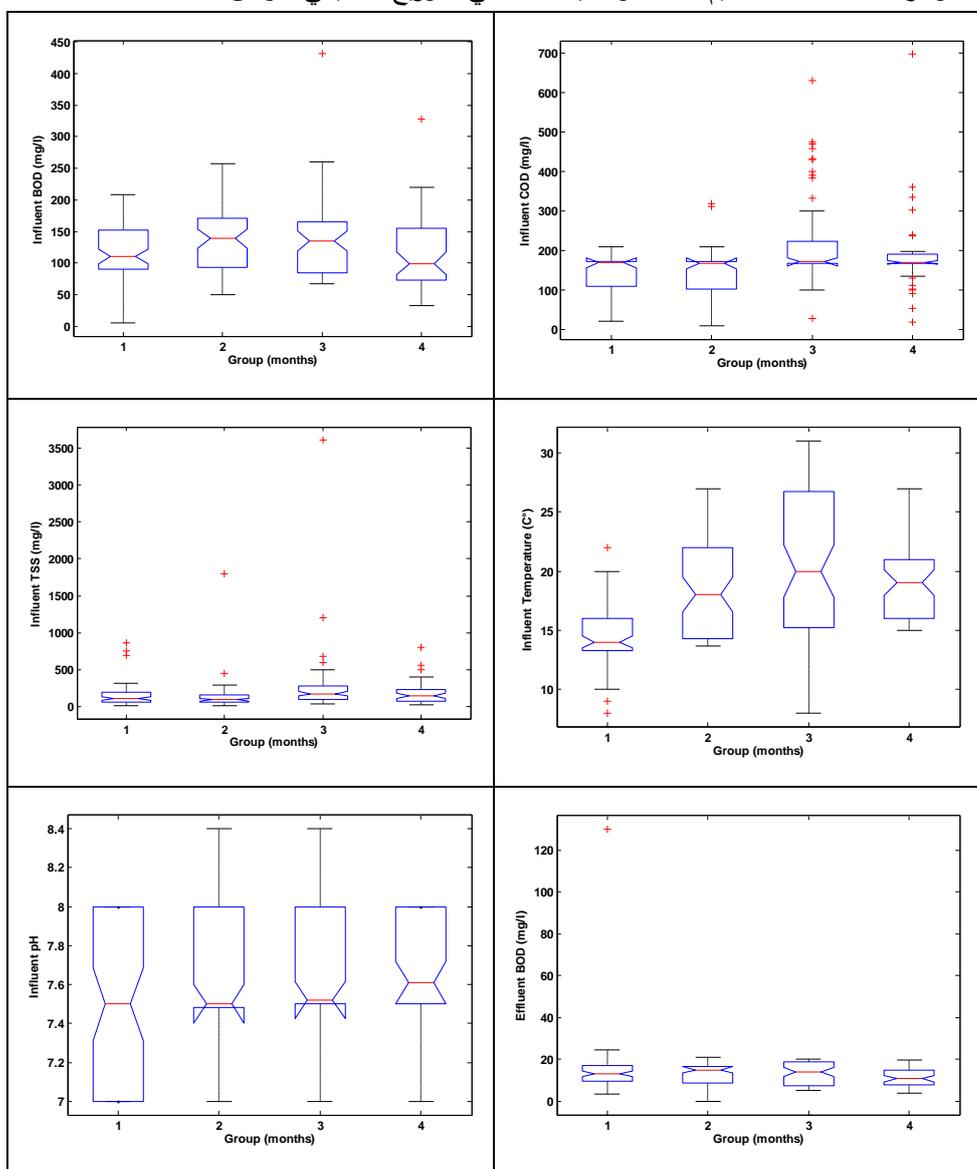
العمود في المصفوفة حيث تضم المجموعة (1) بيانات الأشهر كانون الثاني - شباط - آذار، والمجموعة (2) بيانات الأشهر نيسان - أيار - حزيران، كما تضم المجموعة (3) بيانات الأشهر تموز - آب - أيلول، وأخيراً المجموعة (4) التي تضم بيانات الأشهر تشرين أول - تشرين ثاني - كانون أول.

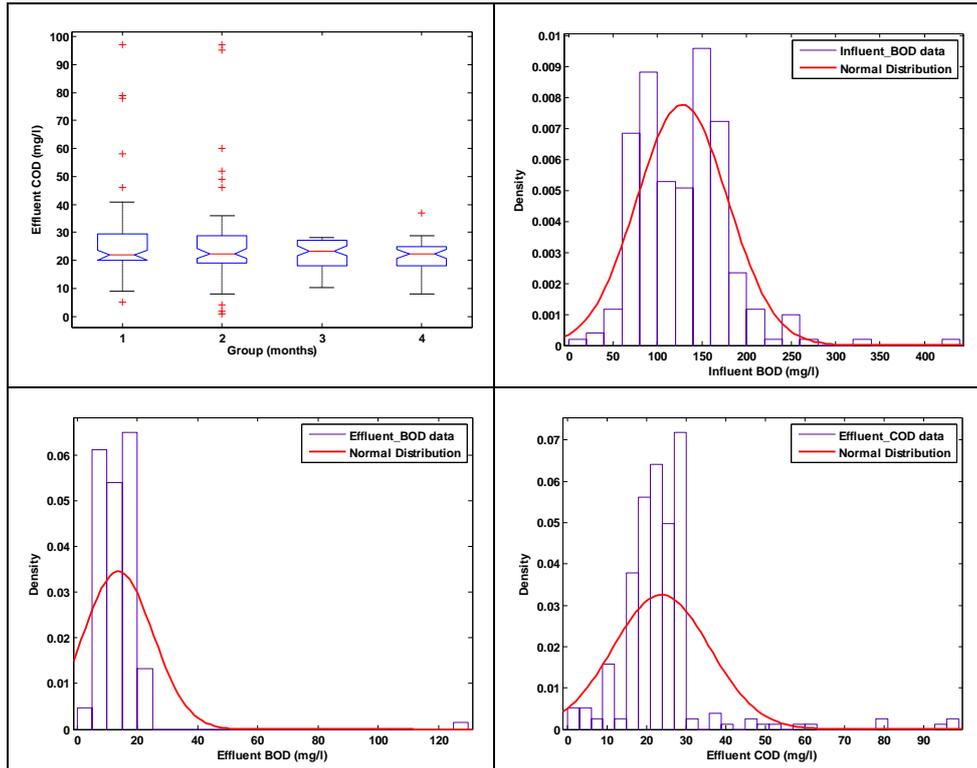
تلك الرسوم البيانية تلخص كل متغير من خلال أربعة عناصر على النحو التالي: خط وسط في كل مربع

(صندوق) هو متوسط العينة التي تشير إلى النزعة المركزية أو موقعها؛ مربع للإشارة إلى التباين حول هذه النزعة المركزية (حواف المربع هي النسب المئوية 25 و 75، شعيرات حول مربع للإشارة إلى مجال ونطاق المتغير، جميع القياسات التي تتجاوز طول الخط الطولي للشعيرة يتم عرضها كقيم منطرفة شاذة مع علامة (+) حيث تدل قيمتها على أكثر من 1.5 مرة من المدى الربيعي بعيداً عن أعلى أو أسفل المربع.

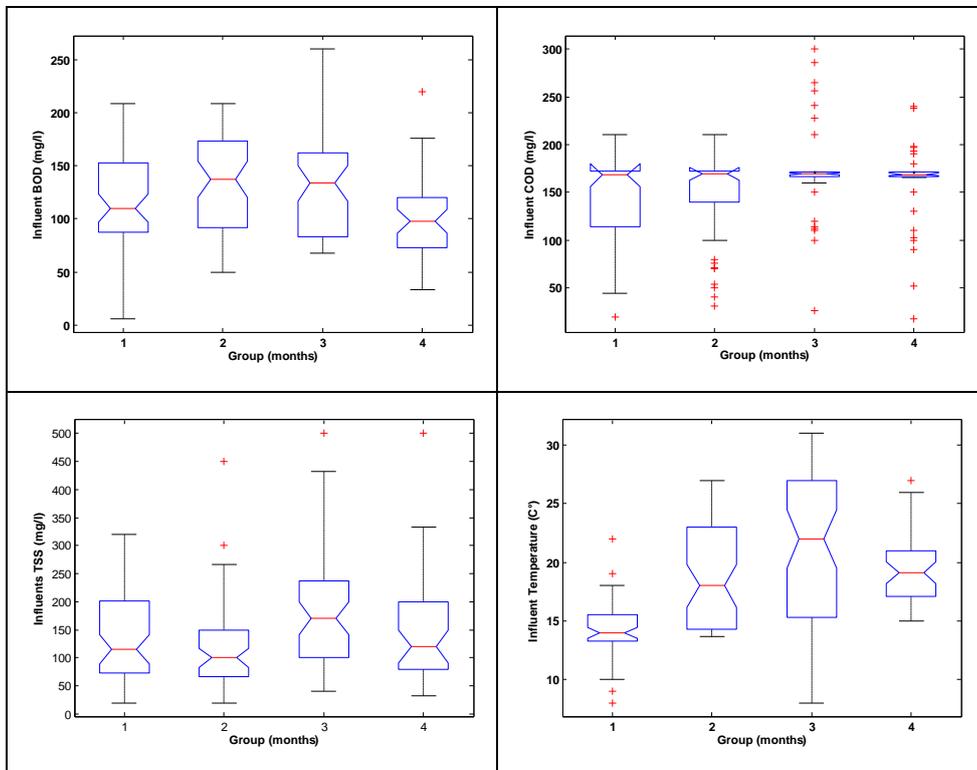
نوضح نتائج التحليل الإحصائي لقيم مؤشرات مياه الصرف المعتمدة الخام (COD, BOD₅, TSS, pH, T)

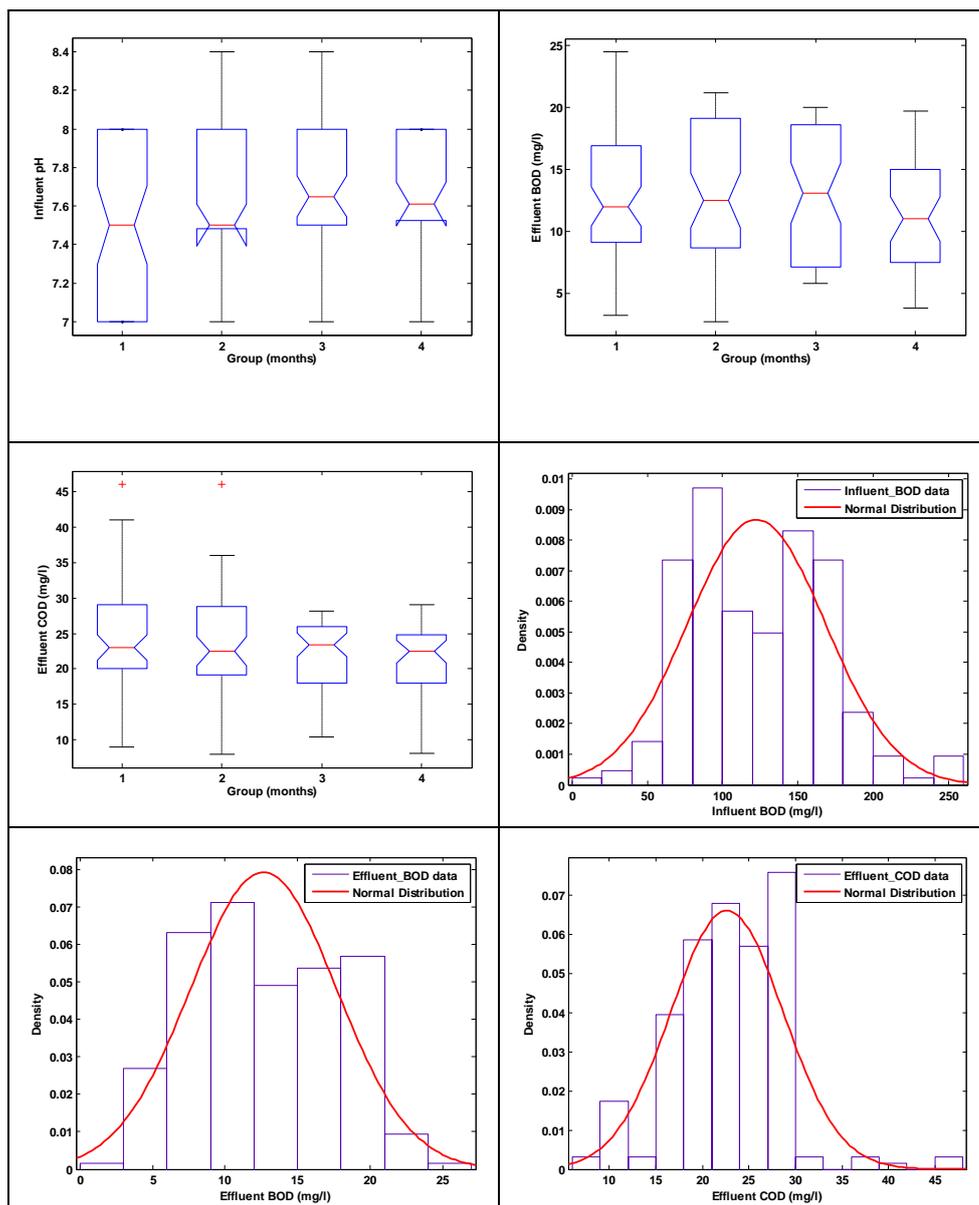
الداخلة والخارجة من محطة معالجة مياه الصرف المدروسة في الشكل (5)، ويمثل الشكل (6) نتائج التحليل الإحصائي للمؤشرات بعد استبعاد القيم الشاذة وتحقيقتها لمنحني التوزيع الطبيعي غوص.





الشكل (5) تحليل القيم الخام لمؤشرات مياه الصرف المعتمدة لمحطة معالجة مياه الصرف الصحي (مرج معياران) (COD, BOD₅, TSS, pH, T) باستخدام ANOVA1.





الشكل (6) تحليل قيم مؤشرات مياه الصرف المعتمدة لمحطة معالجة

مياه الصرف الصحي (مرج معيريان) (COD, BOD₅, TSS, pH, T) بعد استبعاد القيم الشاذة باستخدام ANOVA1.

بعد الانتهاء من تحقيق مرحلة التحليل الإحصائي، تم البدء بإنشاء نماذج الشبكات العصبونية الصناعية باستخدام بيئة عمل الـ Matlab والتي تقدم منصة هامة في تطبيق عملية النمذجة والمحاكاة. يشمل البرنامج صندوق أدوات خاص يحوي على عدة نوافذ من شأنها أن تساعد في ادارة البيانات والشبكة العصبونية حيث تسمح للمستخدم باستيراد، انشاء، استخدام، وتصدير الشبكات العصبونية والبيانات.

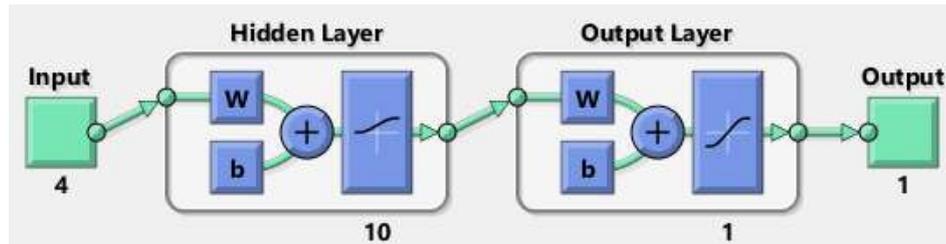
- الحالة الأولى (نموذج الـ Effluent COD):

قمنا ببناء عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكونة من أربعة سيناريوهات: (3 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in}, pH_{in}, TSS_{in}), (4 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in}, pH_{in}, TSS_{in}, BOD_{5in}), (4 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in}, pH_{in}, TSS_{in}, COD_{in}).

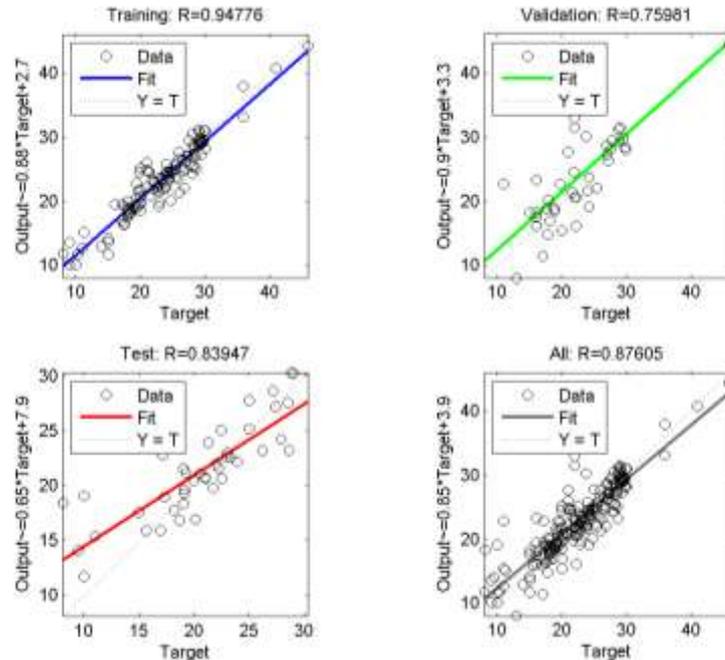
(TSS_{in})، (5 عصيونات وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، BOD_{5in} ، COD_{in})، في حين اقتضرت طبقة المخرجات على طبقة واحدة بعصبون منفرد يمثل قيمة الـ COD_{out} ، أما الطبقة الخفية فقد حُدِّت بطريقة التجربة، حيث جرى تغيير عدد عصيوناتها كما جرى تغيير تقسيم المجموعات بهدف الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية مختلفة Epochs، يظهر الجدول (1) نماذج الـ COD ذات الأداء الأفضل منتقاة من عدة معماريات مدروسة (الشكل (7) يمثل أفضل معمارية) ، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والاختبار بالإضافة إلى مجموعة كافة المعطيات. نوضح أداء النموذج الأفضل في الشكل (8).

الجدول (1) أداء نماذج الشبكة العصبونية الصناعية الخاصة بـ COD

Model No.	Network Input	Network Output	Training (Correlation Coefficient)	Validation (Correlation Coefficient)	Testing (Correlation Coefficient)	All Data (Correlation Coefficient)	No .Neurons in Hidden layers
1	$T_{in}, pH_{in}, TSS_{in}$	COD_{out}	0.753	0.608	0.738	0.717	10
2	$BOD_{in}, TSS_{in}, T_{in}, pH_{in}$	COD_{out}	0.898	0.689	0.685	0.814	10
3	$COD_{in}, TSS_{in}, T_{in}, pH_{in}$	COD_{out}	0.947	0.759	0.839	0.876	10
4	$COD_{in}, BOD_{in}, TSS_{in}, T_{in}, pH_{in}$	COD_{out}	0.825	0.827	0.896	0.833	20



الشكل (7) أفضل معمارية للشبكة العصبونية الصناعية بالنسبة للنموذج رقم (3).



الشكل (8) قيم معامل الارتباط R في كافة المراحل للنموذج رقم (3)

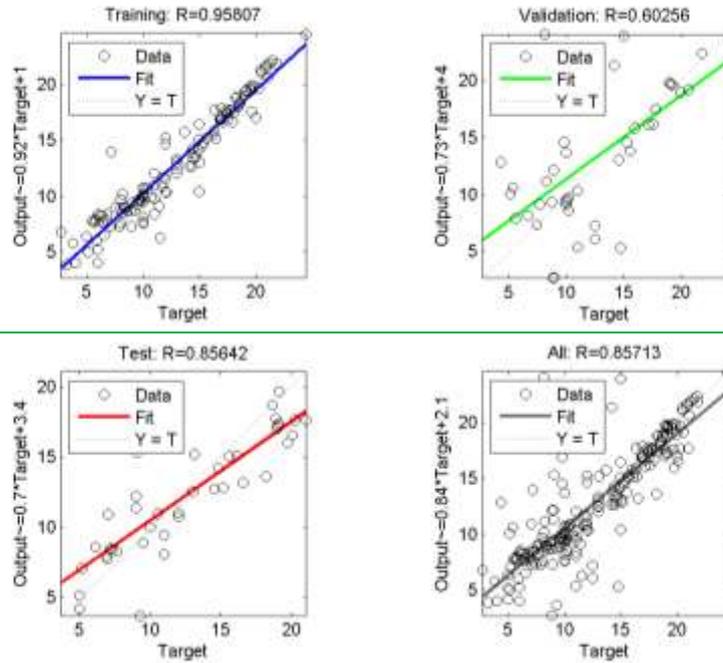
يظهر الشكل (8) قيم معامل الارتباط R لكافة مراحل النموذج (مرحلة التدريب، مرحلة التحقق ومرحلة الاختبار) بين القيم الحقيقية والقيم المحسوبة الناتجة عن الشبكة لمعرفة قوة العلاقة بينهما وبالتالي تقييم أداء الموديل، حيث كانت قيمته في مرحلة التدريب 0.947، في مرحلة التحقق 0.759، في مرحلة الاختبار 0.839 ومن أجل جميع البيانات حقق معامل الارتباط القيمة 0.876.

– الحالة الثانية (نموذج الـ Effluent BOD₅):

بنينا أيضاً عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكوّنة من أربعة سيناريوهات: (3 عصبونات وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in})، (4 عصبونات وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، BOD_{5in})، (4 عصبونات وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، COD_{in})، (5 عصبونات وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، BOD_{5in} ، COD_{in})، في حين اقتصرت طبقة المخرجات على طبقة واحدة بعصبون منفرد يمثل قيمة الـ BOD_{5out} ، أما الطبقة الخفية فقد حُدّدت بطريقة التجربة، حيث جرى تغيير عدد عصبوناتها كما جرى تغيير تقسيم المجموعات بهدف الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية مختلفة Epochs، يظهر الجدول (2) نماذج الـ BOD_5 ذات الأداء الأفضل منتقاة من عدة معماريات تم دراستها، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والاختبار والكلية. نوضح أداء النموذج الأفضل في الشكل (9).

الجدول (2) أداء نماذج الشبكة العصبونية الصناعية الخاصة بـ BOD_5

Model No.	Network Input	Network Output	Training (Correlation Coefficient)	Validation (Correlation Coefficient)	Testing (Correlation Coefficient)	All Data (Correlation Coefficient)	No. Neurons in Hidden layers
1	T_{in} , pH_{in} , TSS_{in}	BOD_{out}	0.784	0.569	0.547	0.701	10
2	BOD_{in} , TSS_{in} , T_{in} , pH_{in}	BOD_{out}	0.950	0.600	0.850	0.850	10
3	COD_{in} , TSS_{in} , T_{in} , pH_{in}	BOD_{out}	0.857	0.470	0.648	0.705	10
4	COD_{in} , BOD_{in} , TSS_{in} , T_{in} , pH_{in}	BOD_{out}	0.824	0.945	0.896	0.849	10



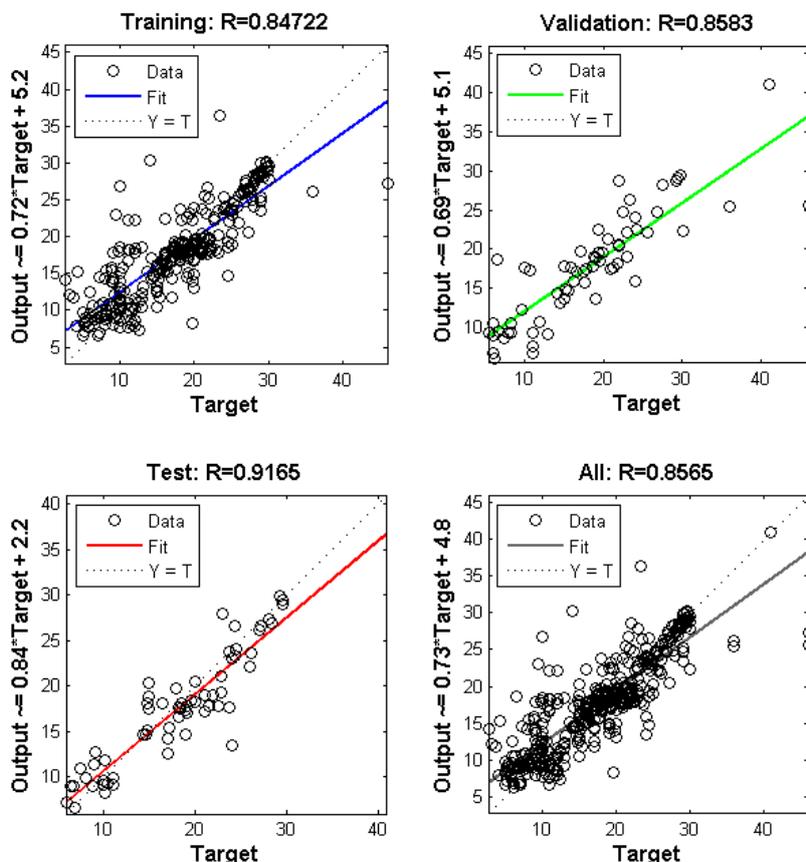
الشكل (9) قيم معامل الارتباط R في كافة المراحل للنموذج رقم (2)

- الحالة الثالثة (نموذج الـ Effluent COD & Effluent BOD₅):

قمنا أيضاً ببناء عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكوّنة من أربعة سيناريوهات: (3 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in} ، pH_{in} ، TSS_{in})، (4 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in} ، pH_{in} ، TSS_{in} ، BOD_{5in})، (4 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in} ، pH_{in} ، TSS_{in} ، COD_{in})، (5 عصبونات وهي: درجة حرارة المياه الداخلة (T_{in} ، pH_{in} ، TSS_{in} ، BOD_{5in} ، COD_{in})، في حين اقتصرت طبقة المخرجات على طبقة واحدة لكن بعصبونين يمثلان قيمتي (BOD_{5out} و COD_{out})، أما الطبقة الخفية فقد حُدّدت بطريقة التجريبية، حيث جرى تغيير عدد عصبوناتها كما جرى تغيير تقسيم المجموعات بهدف الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية مختلفة Epochs، يظهر الجدول (3) نماذج الـ COD و الـ BOD₅ ذات الأداء الأفضل منتقاة من عدة معماريات مدروسة، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والاختبار والكلية. الشكل (10) يبين أداء النموذج الأفضل.

الجدول (3) أداء نماذج الشبكة العصبونية الصناعية الخاصة بـ COD و BOD₅

Model No.	Network Input	Network Output	Training (Correlation Coefficient)	Validation (Correlation Coefficient)	Testing (Correlation Coefficient)	All Data (Correlation Coefficient)	Neurons in Hidden layers
1	T_{in} , pH_{in} , TSS_{in}	COD_{out} & BOD_{out}	0.85	0.74	0.82	0.82	10
2	BOD_{in} , TSS_{in} , T_{in} , pH_{in}	COD_{out} & BOD_{out}	0.833	0.874	0.830	0.837	10
3	COD_{in} , TSS_{in} , T_{in} , pH_{in}	COD_{out} & BOD_{out}	0.827	0.864	0.914	0.844	10
4	COD_{in} , BOD_{in} , TSS_{in} , T_{in} , pH_{in}	COD_{out} & BOD_{out}	0.847	0.858	0.916	0.856	20



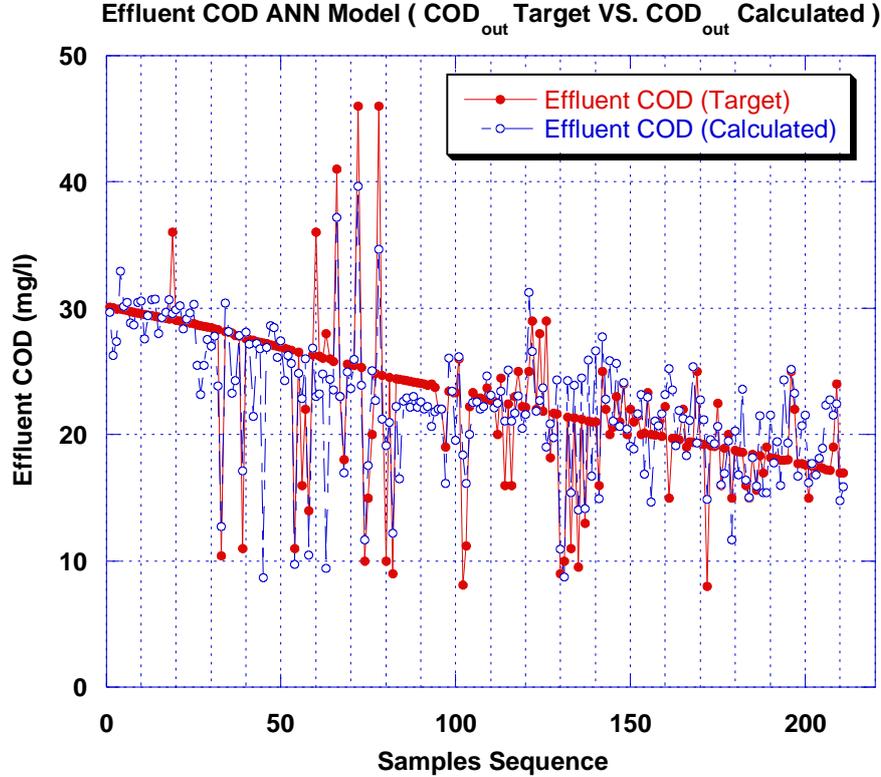
الشكل (10) قيم معامل الارتباط R في كافة المراحل للنموذج رقم (4)

ومن الجدير بالذكر أنه أثناء التطبيق تم تقسيم وبشكل عشوائي بيانات المدخلات وبيانات الهدف إلى ثلاث مجموعات على النحو التالي: يتم استخدام 60% في مرحلة التدريب؛ وتستخدم 20% من أجل مرحلة التحقق أي أن الشبكة يمكن تعميمها ويتم إيقاف مرحلة التدريب؛ تستخدم 20% الباقية في مرحلة الاختبار وتكون مستقلة تماما عن مرحلة تعميم الشبكة، أي أن هذه النسبة لا تدخل في بناء النموذج أثناء مرحلتي التعلم والتحقق.

يتم عادة تقييم أداء النماذج الرياضية المقترحة باستخدام الطرق الإحصائية المعروفة كحساب قيمة معامل الارتباط (R)، حيث يمكن الاستفادة من تقانات الذكاء الصناعي الحديثة في عملية إظهار المقارنة بين القيم الحقيقية والقيم المحسوبة الناتجة عن النماذج على شكل مخططات رسومية بيانية. يمكن الاستفادة من تقانة Simulink المُضمّنة في حزمة برمجيات Matlab في بناء نماذج المحاكاة، حيث يمكن اختصار نماذج المقارنة من خلال وضع الشبكة العصبونية الصناعية على شكل قالب جاهز Block يحوي كافة مكونات الشبكة المقترحة في حزمة قوالب ثانوية. يتم جمع كل من خرج الشبكة العصبونية الصناعية المقترحة وقيم الهدف الحقيقية في قالب جاهز يسمى MUX يسمح بربطهما بمخطط بياني ناتج واحد من أجل عملية المقارنة.

تم اختبار نماذج الشبكة العصبونية الصناعية المقترحة من خلال استخدام كافة البيانات بما فيها بيانات مجموعة الاختبار، وذلك من أجل التحقق من أداء الشبكة ومقارنة مخرجاتها مع القيم الحقيقية المقاسة، الشكل (11) يبيّن مدى

التوافق بين نتائج الشبكة العصبونية الصناعية لقيم Effluent COD والقيم الحقيقية المقاسة كمثال عن النماذج المدروسة سابقاً، حيث بلغ قيمة معامل الارتباط بين كافة القيم المحسوبة والمقاسة (87.6%) الأمر الذي يدل على أداء جيد لنموذج الشبكة الصناعية المقترحة لنموذج COD الخارج من محطة مرج معيربان للصرف الصحي.



الشكل (11) مقارنة بين قيم الـ COD الحقيقية والمحسوبة من خلال نموذج الشبكة العصبونية الصناعية رقم (3)

الاستنتاجات والتوصيات

تسمح الطريقة المطورة باستخدام الشبكة العصبونية الصناعية (ANN) المتعددة الطبقات (MLP) بتقدير مؤشرات التلوث الأساسية لسيرورة عملية المعالجة، اعتماداً على مؤشرات معالجة مساعدة والتي حُددت من خلال علاقات الارتباط الموجودة بين المؤشرات الأساسية وبين المؤشرات المساعدة المختلفة. من خلال عملية المقارنة والاختبار التي جرت على عينات بنسبة 20% لم تتدرب عليها الشبكة سابقاً، لوحظ أن نموذج الشبكة العصبونية الصناعية المثلى النهائية التي تعطي أصغر معدل مربع خطأ كانت وفق الهيكلية التالية لكل من النماذج الثلاث:

نموذج Effluent COD وفق المعمارية (4-10-1) (4 عصبونات في طبقة الدخل وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، COD_{in} - 10 عصبونات في الطبقة الخفية - عصبون واحد في طبقة الخرج وهو Effluent COD)، حيث أعطت أقل قيمة لمتوسط مربع الخطأ وأكبر قيمة لمعامل الارتباط بين قيم COD الخارجة من المحطة المقاسة والمحسوبة ($R=0.876$).

نموذج Effluent BOD₅ وفق المعمارية (4-10-1) (4 عصبونات في طبقة الدخل وهي: درجة حرارة المياه الداخلة T_{in} ، pH_{in} ، TSS_{in} ، $BOD_{5\ in}$ - 10 عصبونات في الطبقة الخفية - عصبون واحد في طبقة الخرج وهو

من المحطة المقاسة والمحسوبة ($R=0.850$). حيث أعطت أقل قيمة لمتوسط مربع الخطأ وأكبر قيمة لمعامل الارتباط بين قيم BOD_5 الخارجة من المحطة المقاسة والمحسوبة ($R=0.850$).

نموذج $Effluent COD$ & $Effluent BOD_5$ وفق المعمارية (2-20-5) (5 عصبونات في طبقة الدخل وهي: درجة حرارة المياه الداخلة T_{in} , pH_{in} , TSS_{in} , $BOD_{5\ in}$, COD_{in} - 10 عصبونات في الطبقة الخفية- في حين اقتصرت طبقة المخرجات على طبقة واحدة لكن بعصبونين يمثلان قيمتي $Effluent COD$ و $Effluent BOD_5$ حيث أعطت أقل قيمة لمتوسط مربع الخطأ وأكبر قيمة لمعامل الارتباط بين قيم BOD_5 و COD الخارجة من المحطة المقاسة والمحسوبة ($R=0.856$).

ونتيجة لذلك، نجد أن نموذج الشبكة العصبونية قد اعطى فعالية عالية لمحاكاة والتنبؤ بأداء محطة مرج معيبران للصرف الصحي المدروسة، وبالتالي فإن النموذج المطور في هذا العمل يتمتع بقدرة جيدة على التعميم ويعطي نتائج ذات دقة عالية.

ونخلص إلى أن استخدام الشبكات العصبونية الصناعية ANN يوفر لنا إمكانية تحليل فعالة وأداة تشخيص جيدة لفهم ونمذجة ومحاكاة سلوك الظواهر البيئية غير الخطية ولا سيما في محطات معالجة مياه الصرف الصحي، ويمكن استخدامها كأداة لتطوير نماذج مختلفة من أجل تقييم أداءها وبالتالي تعدّ أداة قيمة لمشغلي هذه المنشآت البيئية والحيوية الهامة وصانعي القرار فيها.

وبناءً على نتائج البحث يمكن أن نوصي بما يلي:

- 1- يمكن تقدير مؤشرات التلوث الأساسية لسيرورة عملية المعالجة بموثوقية عالية وذلك عند توقف أو تعطل أجهزة التحليل الخاصة بقياس هذه المؤشرات في محطة معالجة مياه الصرف الصحي وذلك من خلال استخدام تقنية الشبكات العصبونية الصناعية.
- 2- إن مثل هذه الأبحاث تتطلب جمع بيانات وغالبا ما تكون العملية مشوبة بالأخطاء والقيم الشاذة التي من الممكن تقليصها إلى حدودها الدنيا باستخدام طريقة ANOVA1.
- 3- يمكن استخدام نظام هجين من الشبكات العصبونية الصناعية والخوارزميات الجينية في النمذجة المثلى لتقييم أداء محطة معالجة الصرف الصحي، ومقارنتها مع نتائج هذا البحث.
- 4- ضرورة إنشاء قواعد بيانات وإغناءها بالقياسات المستمرة المتعلقة بالمحطة من أجل تضمينها في نماذج ال-ANN المختلفة والاستفادة منها لاحقا.
- 5- يمكن إضافة متغيرات أخرى إلى النماذج السابقة كالتدفق والناقلية الكهربائية وغيرها، وتقييمها.

المراجع:

- [1]. Hamoda, F. M.; Al-Gusain, A. I.; Hassan, H. A. *Integrated wastewater treatment plant performance evaluation using artificial neural network*. Water Science and Technology, Vol. 40, No. 7, 1999, 55-65.
- [3]. Hong, T. Y-S.; Rosen, R. M.; Bhamidimarri, R. *Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis*. Water Research, Vol. 37, No. 7, 2003, 1608-1618.
- [4]. Lee, S. D.; Park M. J. *Neural network modeling for on-line estimation of nutrient dynamics in a sequentially-operated batch reactor*. Journal of Biotechnology, Vol. 75, No. 2-3, 1999, 229-239.

- [5]. Côté, M.; Grandjean, P.A. B.; Lessard, P.; Thibault, J. *Dynamic modeling of the activated sludge process: improving prediction using neural networks*. Water Research, Vol. 29, No. 4, 1995, 995–1004.
- [6]. Hamed, M. M.; Khalafallah, G. M.; Hassanein A. E. *Prediction of wastewater treatment plant performance using artificial neural network*. Environmental Modeling and Software, Vol. 19, No. 10, 2004, 919–928.
- [7]. Govindaraju, S. R. *Artificial neural network in hydrology. II: hydrologic application, ASCE task committee application of artificial neural networks in hydrology*. Journal of Hydrologic Engineering, Vol. 5, No. 2, 2000, 124–137.
- [8]. Maier, R. H.; Dandy, C. G. *Neural networks for prediction and forecasting of water resources variables: a review of modeling issues and applications*. Water Resources Research, Vol. 15, No. 1, 2000, 101–124.
- [9]. Neelakantan, TR.; Brion, GM.; Lingireddy, S. *Neural network modeling of cryptosporidium and giardia concentrations in Delaware River, USA*. Water Science and Technology, Vol. 43, No. 12, 2001, 125–132.
- [10]. Blaesi, J.; Jensen, B. *Can neural networks compete with process calculations?.* InTech Applying Technology, Vol. 39, No. 12, 1992, 34–37.
- [11]. Nascimento, O. A. C.; Giudici, R.; Guardani, R. *Neural network based approach for optimization of industrial chemical process*. Computers & Chemical Engineering, Vol. 24, No. 10, 2000, 2303–2314.
- [12]. Belanche, A. L.; Valdés, J. J.; Comas, J.; Roda, R. I.; Poch, M. *Towards a model of input–output behavior of wastewater treatment plants using soft computing techniques*. Environmental Modelling and Software, Vol. 14, No. 5. 1999, 409–419.
- [13]. Häck, M.; Köhne, M. *Estimation of wastewater process parameters using neural networks*. Water Science and Technology, Vol. 33, No. 1, 1996, 101–115.
- [14]. Vyas, M.; Modhera, B.; Vyas, V.; Sharma K. A. *Performance forecasting of common effluent treatment plant parameters by artificial neural network*. ARPN Journal of Engineering and Applied Sciences. Vol. 6, No. 1, 2011, 38-42.
- [15]. Nasr, S. M.; Moustafa, A.E. M.; Seif, A.E. H.; El Kobrosy, G. *Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT*. Alexandria Engineering Journal. Vol. 51, No. 1, 2012, 37-43.
- [16]. Delgrange, N.; Cabassud, C.; Cabassud, M.; Durand-Bourlier, L.; Lainé, J.M. *Neural networks for prediction of ultrafiltration transmembrane pressure: application to drinking water production*. Journal of Membrane Science, Vol. 150, No. 1, 1998, 111–123.
- [17]. Jafar, R.; Shahrour, I.; Juran, I. *Application of Artificial Neural Networks (ANN) to model the failure of urban water mains*. Mathematical and Computer Modelling. Vol. 51, No. 9-10, 2010, 1170-1180.
- [18]. أ. د. د. عادل عوض. تطبيقات نظم النكء الصناعي في حماية البيئة . وزارة الثقافة – الهيئة العامة السورية للكتاب، دمشق، 2007، 302.
- [19]. Eslamian, S. S.; Gohari, S.A.; Biabanaki, M.; Malekian, R. *Estimation of monthly pan evaporation using artificial neural networks and support vector machines*. Journal of Applied Sciences. Vol. 8, No. 19, 2008, 3497- 3502.
- [20]. TAYLOR, J.G. *Neural Network and Their Applications*. John Wiley and Sons, England, 1996, 322.
- [21]. Principe, J. C.; Euliano, N. R.; Lefebvre, W.C. *Neural and Adaptive Systems: Fundamentals through Simulation*. John Wiley and Sons, INC, 2000, 672.