

التنبؤ بأداء محطة معالجة الصرف الصحي في خربة المعزة باستخدام الشبكات العصبونية الصناعية

د. عادل عوض *

د. رائد جعفر **

نابغه رحال ***

(تاريخ الإيداع 2020/ 6/14 . قبل للنشر في 2020/ 9/ 16)

□ ملخص □

إن الطلب والحاجة المتزايدة إلى مياه الصرف الصحي المعالجة بجودة عالية بغرض إعادة استخدامها إضافة إلى تحقيق حماية أفضل للموارد المائية، يدفعنا إلى تحسين عمل محطات المعالجة باستمرار في كل أجزائها، وهذا يتطلب توفر القياسات المستمرة لعملية المعالجة وفي كل الأوقات مما يدفعنا إلى تقديم طريقة جديدة للتنبؤ بالمؤشرات الأساسية اعتماداً على المؤشرات سهلة القياس وذلك عند توقف أو تعطل طارئ لأجهزة التحليل الخاصة بقياس المؤشرات الأساسية. يركز هذا البحث على استخدام طريقة الشبكات العصبونية الصناعية Artificial Neural Network (ANN) 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 محطة معالجة مياه الصرف الصحي في خربة المعزة WWTP .

اعتمدت النماذج على بيانات مؤشرات التلوث التي تم جمعها على مدى ثلاثة أعوام وهي المؤشرات الرئيسية التي تشمل الطلب على الأكسجين الكيميائي (COD) ، الطلب على الأكسجين البيوكيميائي (BOD₅) ، الفوسفات PO_4^{3-} والنترات NO_3^- ، والمؤشرات المساعدة التي تضمنت درجة الحرارة (T)، الحموضة (pH)، الناقلية (EC) والمواد الصلبة المنحلة (TDS). تشير الدراسة إلى أن تطبيق طريقة ال ANN تمكن من التنبؤ بأداء محطة المعالجة مع معامل الارتباط (R) بين متغيرات الخرج المقاسة والمحسوبة (المُتنبأ بها) وصل إلى 88% بالنسبة لنموذج ال COD، 90% بالنسبة لنموذج ال BOD₅ و 87% بالنسبة لنموذج ال BOD₅&COD 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، محطة خربة المعزة.

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

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

*** طالبة دراسات عليا (ماجستير) - قسم الهندسة البيئية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Wastewater Plant Performance Prediction Using Artificial Neural Networks In Kerbt Al Maza

Dr. Adel Awad*
Dr. Raed Jafar**
Nabgha Rahhal***

(Received 14/6/2020. Accepted 16/ 9/2020)

□ ABSTRACT □

The increasing demand and need for high quality treatment wastewater effluents for re-use and at the same time for better protection of water resources, necessitates enhancing the treatment processes continuously in all parts of wastewater treatment plants. This needs the continual measurements of the treatment process availability in all times, so that we have to present a new method for basic treatment parameters depending on easily measurable parameters in the case of any unexpected breakdown of analyzers takes place in measuring the basic treatment parameters. This research 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 Kerbt Al Maza WWTP.

Models based on the pollution indicators data that have been collected during over three-year period, the main indicators that include Chemical Oxygen Demand (COD), Biochemical Oxygen Demand (BOD_5), PHosphates (PO_4^{-3}), Nitrates(NO_3^-), and auxiliary Indicators which included the Temperature (T), degree of acidity or alkalinity (pH), Electric conductivity(EC) and the Total Dissolved Solids(TDS). 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, (90%) for the BOD_5 model, (87%) for the COD& BOD_5 together model. Finally, ANN models provide 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; Kerbt Al Maza plant.

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

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

***Postgraduate Student (M.A.), Department of Environmental Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

أصبحت قضية التخلص من مياه الصرف الصحي (المجاري) من أكبر المشكلات التي تواجه العالم بأسره، لما يترتب على ذلك من أضرار صحية واقتصادية جمة. حيث يدفعنا الطلب والحاجة المتزايدة إلى مياه صرف صحي خارجة من محطة معالجة خاصة بها بجودة عالية إلى ضمان سيرورة عمل هذه المحطة بشكل مثالي لكل أجزائها [1]، [2].

يمكن مراقبة المياه الخارجة من المحطة من خلال تطوير نماذج للتنبؤ بأداء محطة المعالجة معتمدة" على قياس بارامترات هامة فيها [3]. حيث إن استراتيجية مراقبة ورصد التدفق الداخل والخارج في المحطة تتطلب فهم أداء المحطة والعوامل التي تؤثر على مواصفات المياه مثل الوقت، الفصل، ونمط حياة الناس.

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 لوحدة معالجة مياه الصرف الصحي البيولوجية Wastewater Treatment Plants (WWTP) كثيراً ما تكون صعبة بسبب التغيرات في تركيب مياه الصرف الصحي الخام، واختلاف معدلات التدفق، والطبيعة المعقدة لسيرورة عملية المعالجة [4]. 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. تستند تقنيات النمذجة التقليدية المستخدمة في العمليات الحيوية (Bioprocesses) على معادلات التوازن مع معادلات معدل نمو البكتيريا، واستهلاك الطبقة المغذية (Substratum consumption) [5]، ومنذ أن تم دمج التفاعلات الميكروبية مع التفاعلات البيئية أصبحت تلك المعادلات غير خطية، متغيرة مع الزمن وذات طبيعة معقدة [6]، فالنموذج التجريبي يقوم على اعتماد القياسات التي يبدو أنها أساسية لوصف النمط السلوكي المرغوب فيه، وربط هذه القياسات بعلاقات تجريبية تقوم على الملاحظة، أيضاً يعدُّ التنبؤ بالبارامترات التشغيلية لوحدة المعالجة باستخدام تقنيات تجريبية تقليدية خطوة تحتاج للوقت الطويل وتشكل عقبة في طريق السيطرة الفعالة لهذه العمليات [7]، [8]. يمكن استخدام تقنية الشبكات العصبونية الصناعية (Artificial Neural Network ANN) لنمذجة سيرورة عمليات المعالجة في وحدات معالجة مياه الصرف الصحي (Wastewater Treatment Plants WWTP). ويمكن استخدامها لتحسين التنبؤ بأداء عملية المعالجة وذلك بسبب الدقة العالية والملائمة الكافية في تطبيقها الواعدة جداً في مجال الهندسة البيئية [11]، [10]، [9]. تعتمد هذه التقنية عادة على البيانات النموذجية المتوفرة لسيرورة عملية المعالجة في WWTP، وهناك بعض المتغيرات الرئيسية التي يمكن استخدامها لتقييم أداء وحدة المعالجة. وتشمل هذه المتغيرات الطلب على الأكسجين البيولوجي (BOD)، الطلب على الأكسجين الكيميائي (COD)، الفوسفات (PO_4^{-3}) والنترات (NO_3^-). استخدمت معظم الدراسات المتاحة في الأبحاث السابقة عن تطبيق واستخدام الشبكات العصبونية الصناعية في نمذجة وحدات معالجة مياه الصرف الصحي هذه المتغيرات ووجدت أن هذه النماذج الأساسية ل ANN تقدم أداة فعالة وقوية في محاكاة العمليات المعقدة والأنظمة اللاخطية وبشكل خاص في التنبؤ بأداء وحدات المعالجة WWTP [12].

قام (Jami) وآخرون (2012) بوضع نماذج للشبكات العصبونية الصناعية متعددة الدخل للتنبؤ بأداء محطة معالجة مياه الصرف الصحي، حيث أعطت أكبر قيمة لمعامل الارتباط بين القيم المحسوبة والمقاسة $R=60\%$ عند التنبؤ بمؤشر التلوث COD، بينما أفضل شبكة من أجل النموذج الثاني كان مع COD، BOD و SS كمداخلات و

- BOD كخرج وطبقة خفية واحدة مؤلفة من 30 عصبون حيث أعطت أكبر قيمة لمعامل الارتباط $R=34\%$ في محطة معالجة مياه الصرف الصحي في ماليزيا [13].
- قام (Rene, R. E. and Saidutta B. M.) (2008) بالتنبؤ بقيم الـ BOD_5 و COD لمياه الصرف الناتجة عن محطة معالجة لمعمل بيتروكيميائي في الهند باستخدام الشبكات العصبونية متعددة الطبقات. حيث كان النموذج الأفضل للتنبؤ بمؤشر الـ BOD هو الذي اعطي اصغر قيمة لمعدل الخطأ النسبي $ARE=11.6614\%$ ، أما النموذج الأفضل للتنبؤ بمؤشر الـ COD هو الذي اعطي اصغر قيمة لمعدل الخطأ النسبي $ARE=6.9729\%$ ، والنموذج الأفضل للتنبؤ بمؤشر الـ BOD و COD معاً هو الذي اعطي أصغر قيمة لمعدل الخطأ النسبي $ARE=8.201\%$ [14].
- أجرى (Vyas) وآخرون (2011) في الهند دراسة للتنبؤ ببارامترات محطات المعالجة المشتركة (صرف صحي و صرف صناعي) باستخدام الشبكة العصبونية الصناعية ANN وقد تم تشكيل نموذجان باستخدام ANN مع منهجية التغذية الأمامية (3 طبقات) وخوارزمية الانتشار الخلفي للتنبؤ بتركيز BOD_5 الداخل والخارج من عمليات معالجة مياه الصرف الصحي بعد جمع بيانات الـ BOD_5 من محطة معالجة Govindpura في بوبال، الهند. وقد 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 وأنه تم استخدامها لتقديم فعالية جيدة في التنبؤ والنمذجة [15].
- قام كل من (Pakrou) وآخرون (2014) من قسم الهندسة البيئية ، جامعة طهران في إيران بنمذجة الشبكات العصبونية الصناعية للتنبؤ بكفاءة المعالجة وتأثير بارامترات الإدخال على التنبؤ في محطة معالجة مياه الصرف الصحي في تبريز، حيث توصلوا إلى أن النموذج الأفضل جَمَعَ بين متغيرات الإدخال Qinf (سرعة التدفق) و TSS_{eff} و MLSS والذي اعطى أعلى قيمة لمعامل الارتباط $R=0.898$ وأصغر قيمة لجذر متوسط مربع الخطأ $RSME=0.443$ [16].
- قام (Hamoda) وآخرون في الكويت (1999) بتقييم أداء محطة معالجة مياه صرف صحي في العارضية في مدينة الكويت باستخدام طريقة الانتشار الخلفي بواسطة الشبكة العصبونية الصناعية ANN. وأثبتت النتائج أن الشبكات العصبونية تقدم أداة مرنة في نمذجة محطات معالجة مياه الصرف وتوفر منهجية بديلة للتنبؤ بأداء المحطة. ويتم تحقيق كفاءة إزالة لـ TSS في محطة العارضية على مدى 6 أشهر حوالي 94.6% وكفاءة إزالة لـ BOD_5 حوالي 97.3%. كما أظهرت النتائج أن هناك توافق ممتاز بين البيانات المتوقعة في النموذج والبيانات الحقيقية حيث كان معامل الارتباط باستخدام أفضل نموذج $0.72 \leq TSS$ و $0.74 \leq BOD_5$. وتم استنتاج أن البنية الأفضل لـ ANN لا يعني بالضرورة عدد أكبر من الطبقات الخفية [17].

أهمية البحث وهدفه:

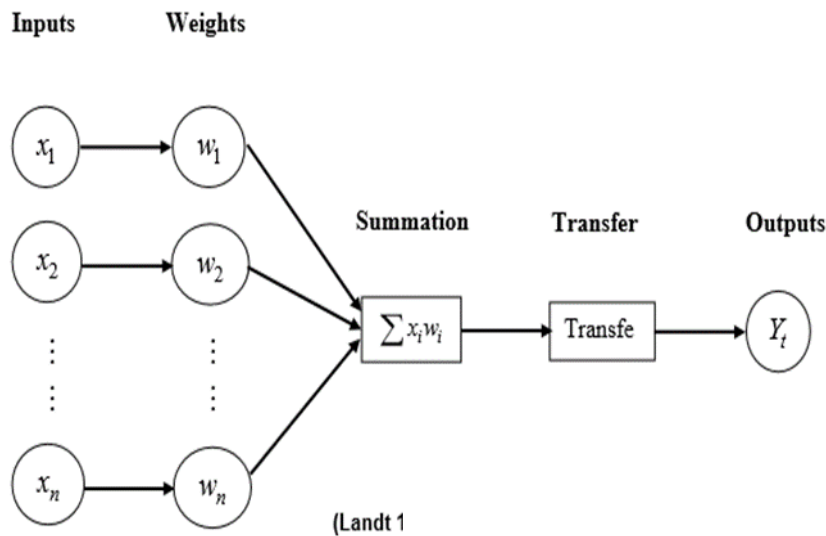
انطلاقاً من أهمية حماية الموارد المائية والحفاظ على البيئة من التلوث الناجم عن صرف مياه محطات المعالجة التي لا تعمل بشكل صحيح، الأمر الذي يدفعنا إلى مراقبة، تقييم وتحسين عمل هذه المحطات بشكل مستمر وفي كافة منشأتها. يمكن تحقيق ذلك باستخدام تقانات الذكاء الصناعي الحديثة وبدقة عالية . يهدف

هذا البحث إلى وضع نماذج رياضية للعلاقة بين مؤشرات التلوث المختلفة الرئيسية ($BOD_5, COD, PO_4^{-3}, NO_3^{-}$) والمساعدة (T,pH ,EC, TDS) في محطة معالجة خربة المعزة في طرطوس 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.

مواد البحث وطرائقه:

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 [18].

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 الأخراج (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 (1) [19].



الشكل (1) : شبكة عصبونية صناعية

سيتم إنشاء نماذج متعددة من الشبكات العصبونية الصناعية (ANN)، في دراستنا هذه تم استخدام الشبكات العصبونية الصناعية ذات التغذية الأمامية (FFNNs) Feed Forward Neural Network، يقصد بالتغذية الأمامية للشبكات انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من الإدخال بإتجاه طبقة الإخراج، من الأمثلة على هذه الشبكات، الشبكات العصبونية ذات الانتشار العكسي للخطأ Back Propagation Error ويسمى هذا النوع من الشبكات بشبكات الانتشار العكسي للخطأ، لأن المخرجات الحقيقية للشبكة تقارن مع مخرجات الهدف، والفرق بين هذه القيم يدعى بالخطأ الذي تقوم الشبكة بنشره بدءاً من طبقة المخرجات، أي بألية معكوسة لما يتم في مرحلة حساب المخرجات حيث يكون اتجاه الحساب أمامياً [20].

ولغرض التعبير عن آلية الانتشار العكسي للخطأ رياضياً يتطلب ذلك توضيح آلية التغذية الأمامية رياضياً وبشيء من التفصيل، كما هو موضح في المعادلات الآتية [21]:
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:

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

حيث:

N: عدد الخلايا أو الوحدات في الطبقة K-1

f^k : دالة التحويل (Transfer Function)

يعد شعاع الانحياز bias (bi) 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 التاليتين:

$$MSE = err = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (y_i - a_2)^2 \quad (2)$$

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

حيث:

err: معدل مربع الخطأ في وحدة المخرجات، y: مخرجات الهدف Target، δ : معامل تصحيح

الخطأ (Delta)، a_2 : المخرجات الفعلية المحسوبة.

ثالثاً-مرحلة تحديث الأوزن: حيث يتم تحديث الأوزن 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 [22].

- طريقة تجزئة المدخلات Increment input method : يتم في هذه الطريقة إدخال المصفوفة صفاً صفاً، ومن ثم تحديث الأوزان لتلك الصفوف تباعاً، لذلك تمتاز هذه الطريقة بحاجتها إلى ذاكرة محدودة.

- طريقة الدفعة الواحدة للمدخلات Batch input method: تتضمن هذه الطريقة إدخال المصفوفة كاملة دفعة واحدة، 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 هذه الدراسة.

إن 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 تكرارات (Epoch) المحددة مسبقاً من قبل المدرب.

قمنا باختيار عدة معماريات للشبكة العصبونية الصناعية بهدف الوصول إلى أفضل أداء وذلك باستخدام مكتبة NN Tool Box المضمنة في بيئة عمل ال Matlab وخوارزمية (LM Levenberg Marquardt) لتدريب الشبكة وتابع السيغمويد (Sigmoid transfer function) كتاب تحويل للطبقة الخفية الأولى وتابع الظل (Tansig transfer function) كتاب تحويل للطبقة الخفية الثانية والتابع الخطي (Linear transfer function) كتاب تحويل لطبقة المخرجات، واعتمدنا على قيم معدل مربع الخطأ (MSE Mean Squared Error) ومعامل الارتباط (Correlation Coefficient) للتحقق من أداء الشبكة.

تجميع البيانات:

تعتمد محطة معالجة خربة المعزة على طريقة المعالجة بالحماة المنشطة Activated sludge بتقنية التهوية المدينة، وهي مخصصة لتخديم مجموعة قرى يصل عدد سكانها إلى 10000 نسمة، الغزارة الوسطية 42 متر مكعب بالساعة أي 1008 متر مكعب باليوم .

استُخدمت في هذه الدراسة بيانات مأخوذة من مدخل ومخرج محطة معالجة خربة المعزة لمدة ثلاث أعوام (2016, 2017, 2018) والمتضمنة البارامترات التي استخدمت كمخرجات وهي: BOD_5 الاحتياج البيوكيميائي للأوكسجين خلال خمسة أيام (mg/l)، COD الاحتياج الكيميائي للأوكسجين (mg/l). إضافة إلى البارامترات التي استخدمت كمدخلات وهي:

درجة الحرارة (C°)، pH، المواد الصلبة المنحلة TDS (mg/l)، الناقلية EC ($\mu s/cm$)، PO_4^{-3} الفوسفات (mg/l)، NO_3^- النترات (mg/l).

حيث قسمت هذه البيانات إلى ثلاث مجموعات هي: مجموعة التدريب (Training) (70%)، مجموعة الاختبار (Testing) (15%)، مجموعة التحقق أو التصحيح (Validation) (15%).

إن إنشاء نموذج الشبكات العصبونية الصناعية يعتمد بشكل رئيسي على قواعد البيانات المتوفرة والخاصة بعوامل الظاهرة المدروسة، لذلك تم تحليل بيانات هذه العوامل (المدخلات والمخرجات) والتي تم جمعها خلال فترة البحث عن طريق تحليل التباين في اتجاه واحد من التابع ANOVA1 والموجود في بيئة عمل برنامج ال MATLAB. نشير هنا إلى أنه تم تطبيق هذا التحليل ANOVA1 قبل الشروع بتطوير نماذج ال ANN وذلك من أجل رفض واستبعاد البيانات الخام ذات القيم الشاذة وغير الدقيقة في قاعدة البيانات. بعد الانتهاء من تحقيق مرحلة التحليل


الإحصائي، تم البدء بإنشاء نماذج الشبكات العصبونية الصناعية باستخدام بيئة عمل 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):

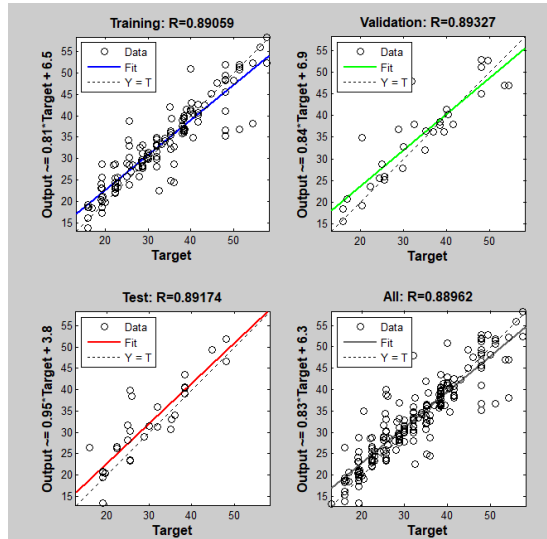
بُنيت عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكونة من 5 سيناريوهات: (4 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (5 عصبونات وهي $(NO_3^-_{in}, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (6 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in}, PO_4^{-3}_{in}, NO_3^-_{in})$ ، (7 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in}, BOD_{5in}, PO_4^{-3}in, NO_3^-_{in})$ ، (8 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in}, COD_{in}, BOD_{5in}, PO_4^{-3}in, NO_3^-_{in})$ ، في حين اقتصرت طبقة المخرجات على عصبون منفرد يمثل قيمة الـ COD_{out} ، أما الطبقة الخفية فقد حُدِّت 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 (1) نماذج الـ COD ذات الأداء الأفضل منتقاة من عدة معماريات مدروسة (الشكل (2) يمثل أفضل معمارية) ، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والأختبار بالإضافة إلى مجموعة كافة المعطيات. نوضح أداء النموذج الأفضل في الشكل (3).

الجدول (1) أداء نماذج الشبكة العصبونية الصناعية الخاصة بالـ 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	$T_{in}, pH_{in}, EC_{in}, TDS_{in}$	COD_{out}	0.6637	0.317	0.6104	0.605	60-40
2	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}$	COD_{out}	0.6859	0.6838	0.6023	0.671	55-30
3	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}$	COD_{out}	0.696	0.804	0.769	0.719	60-40
4	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}, BOD_{5in}$	COD_{out}	0.890	0.893	0.891	0.889	50-30
5	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}, BOD_{5in}, COD_{in}$	COD_{out}	0.826	0.78	0.895	0.841	50-30



الشكل(2) أفضل معمارية للشبكة العصبونية الصناعية بالنسبة للنموذج رقم(4)



الشكل(3) قيم معامل الارتباط R في كافة المراحل للنموذج رقم(4)

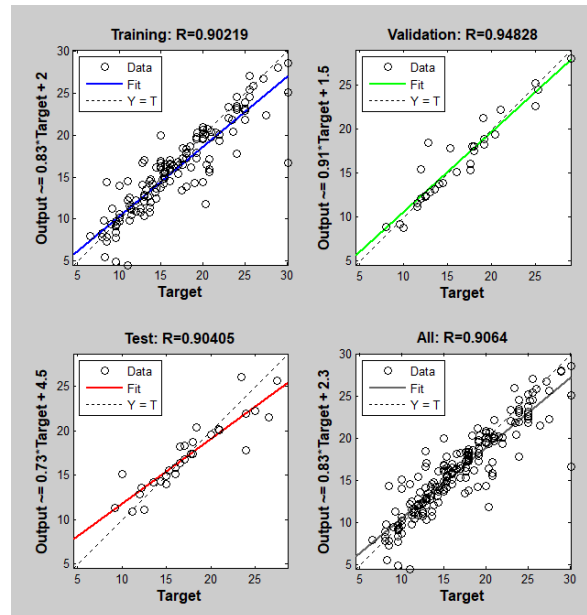
يظهر الشكل رقم(3) قيم معامل الارتباط لكافة مراحل النموذج (مرحلة التدريب، مرحلة التحقق ومرحلة الاختبار) بين القيم الحقيقية والقيم المحسوبة الناتجة عن الشبكة لمعرفة قوة العلاقة بينهما وبالتالي تقييم أداء الموديل، حيث كانت قيمته في مرحلة التدريب 0.890، في مرحلة التحقق 0.893، في مرحلة الاختبار 0.891 ومن أجل جميع البيانات حقق معامل الارتباط القيمة 0.885.

• الحالة الثانية (نموذج الـ BOD_5 Effluent):

بنينا أيضا عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكونة من 5 سيناريوهات: (4) عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (5) عصبونات وهي $(NO_3^- in, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (6) عصبونات وهي $(PO_4^{-3} in, NO_3^- in, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (7) عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (8) عصبونات وهي $(BOD_{5in}, PO_4^{-3}in, NO_3^- in, EC_{in}, BOD_{5out})$ ، في حين اقتصرت طبقة المخرجات على عصبون منفرد يمثل قيمة الـ BOD_{5out} ، أما الطبقة الخفية فقد حُدَّت بطريقة التجربة، حيث جرى تغيير عدد عصبونات 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 مدروسة، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والاختبار بالإضافة إلى مجموعة كافة المعطيات. نوضح أداء النموذج الأفضل في الشكل (4).

الجدول (2) أداء نماذج الشبكة العصبونية الصناعية الخاصة بال 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	$T_{in}, pH_{in}, EC_{in}, T_{DS_{in}}$	BOD_{5out}	0.685	0.361	0.825	0.681	60-40
2	$T_{in}, pH_{in}, EC_{in}, T_{DS_{in}}, NO_3^-_{in}$	BOD_{5out}	0.675	0.520	0.820	0.678	55-30
3	$T_{in}, pH_{in}, EC_{in}, T_{DS_{in}}, NO_3^-_{in}, PO_4^{3-}_{in}$	BOD_{5out}	0.704	0.648	0.825	0.715	60-40
4	$T_{in}, pH_{in}, EC_{in}, T_{DS_{in}}, NO_3^-_{in}, PO_4^{3-}_{in}, BOD_{5in}$	BOD_{5out}	0.902	0.948	0.904	0.906	50-30
5	$T_{in}, pH_{in}, EC_{in}, T_{DS_{in}}, NO_3^-_{in}, PO_4^{3-}_{in}, BOD_{5in}, COD_{in}$	BOD_{5out}	0.890	0.935	0.898	0.898	50-30



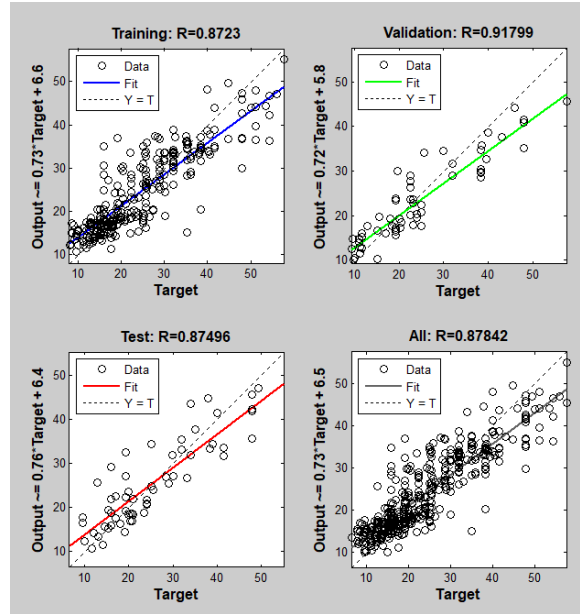
الشكل (4) قيم معامل الارتباط R في كافة المراحل للنموذج رقم (4)

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

قمنا ببناء عدة شبكات عصبونية صناعية تتضمن طبقة واحدة للمدخلات مكونة من 5 سيناريوهات: (4 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (5 عصبونات وهي $(NO_3^-_{in}, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (6 عصبونات وهي $(PO_4^{-3}_{in}, NO_3^-_{in}, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، (7 عصبونات وهي $(pH_{in}, TDS_{in}, EC_{in}, T_{in}, NO_3^-_{in}, PO_4^{-3}_{in})$ ، (8 عصبونات وهي $(BOD_{5in}, PO_4^{-3}_{in}, NO_3^-_{in}, EC_{in}, pH_{in}, TDS_{in}, EC_{in}, T_{in})$ ، في حين اقتصرت طبقة المخرجات على طبقة واحدة لكن بعصبونين يمثلان قيمتي (BOD_{5out} و COD_{out})، أما الطبقة الخفية فقد حُدِّت 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 BOD₅ ذات الأداء الأفضل منتقاة من عدة معماريات مدروسة، وكذلك معاملات الارتباط لكافة مجموعات التدريب والتحقق والأختبار بالإضافة إلى مجموعة كافة المعطيات. نوضح أداء النموذج الأفضل في الشكل (5).


الجدول (3) أداء نماذج الشبكة العصبونية الصناعية الخاصة بالـ BOD₅ و 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	$T_{in}, pH_{in}, EC_{in}, TDS_{in}$	$COD_{out} \& BOD_{5out}$	0.804	0.850	0.833	0.811	60-40
2	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}$	$COD_{out} \& BOD_{5out}$	0.74	0.756	0.837	0.756	55-30
3	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}$	$COD_{out} \& BOD_{5out}$	0.749	0.772	0.828	0.761	60-40
4	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}, BOD_{5in}$	$COD_{out} \& BOD_{5out}$	0.818	0.891	0.87	0.834	50-30
5	$T_{in}, pH_{in}, EC_{in}, TDS_{in}, NO_3^-_{in}, PO_4^{-3}_{in}, BOD_{5in}, COD_{in}$	$COD_{out} \& BOD_{5out}$	0.872	0.917	0.875	0.878	50-30



الشكل (5) قيم معامل الارتباط R في كافة المراحل للنموذج رقم (5)

الشكل (6) يبين 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 (88.9%) الأمر الذي يدل على أداء جيد لنموذج الشبكة الصناعية المقترحة لنموذج COD الخارج من محطة معالجة مياه الصرف الصحي في خربة المعزة.



الشكل (6) مقارنة بين قيم ال COD الحقيقية والمحسوبة من خلال نموذج الشبكة العصبونية الصناعية رقم (4)

الاستنتاجات:

كان لتحديد قيم معاملات الارتباط بين المؤشرات الأساسية والمؤشرات المساعدة المختلفة دوراً رئيسياً في الوصول إلى الشبكة العصبونية المثلى للتنبؤ، وكان لنوعية وعدد البيانات تأثيراً كبيراً على حسن أداء الشبكة وزيادة قدرة النموذج على التنبؤ. حيث وجد توافق خطي بين مخرجات الشبكة العصبونية الصناعية والبيانات المقاسة، مما يبيّن إمكانية استخدام هذه التقانة في التنبؤ بالقيم المستقبلية لمؤشرات المعالجة الرئيسية.

إن استخدام هيكلية الشبكة العصبونية الصناعية (1-30-50-7) (7 عصبونات في طبقة الدخل، 50 عصبون في الطبقة الخفية الأولى، 30 عصبون في الطبقة الخفية الثانية، عصبون واحد في طبقة الخرج وهو Effluent COD) أعطت أقل قيمة لمتوسط مربع الخطأ (MSE) وأكبر قيمة لمعامل الارتباط بين قيم COD الخارجة من المحطة المقاسة والمحسوبة ($R= 0.889$).

أيضاً إن استخدام هيكلية الشبكة العصبونية الصناعية (1-30-50-7) (7 عصبونات في طبقة الدخل، 50 عصبون في الطبقة الخفية الأولى، 30 عصبون في الطبقة الخفية الثانية، عصبون واحد في طبقة الخرج وهو Effluent BOD₅) أعطت أقل قيمة لمتوسط مربع الخطأ (MSE) وأكبر قيمة لمعامل الارتباط بين قيم BOD₅ الخارجة من المحطة المقاسة والمحسوبة ($R= 0.906$).

واستخدام هيكلية الشبكة العصبونية الصناعية (2-30-50-8) (8 عصبونات في طبقة الدخل، 50 عصبون في الطبقة الخفية الأولى، 30 عصبون في الطبقة الخفية الثانية، عصبونين في طبقة الخرج وهما Effluent BOD₅، COD) أعطت أقل قيمة لمتوسط مربع الخطأ (MSE) وأكبر قيمة لمعامل الارتباط بين قيم BOD₅ وCOD الخارجة من المحطة المقاسة والمحسوبة ($R= 0.878$).

في بعض النماذج عدد المدخلات كبير لأنه كلما زادت عدد البيانات كلما كان النموذج أكثر دقة، والفائدة من وجود نفس العنصر في طبقة الدخل وطبقة الخرج هو تدريب الشبكة على المدخل والمخرج وبالتالي هي قادرة على التنبؤ بالمخرج بمجرد أن نقوم بإدخال المتغيرات وبالتالي التقليل من القياسات المكلفة لأننا عملياً بحاجة الى قياس المتغير عن المدخل والنموذج يقوم بالتنبؤ بالمخرج.

التوصيات:

- 1- من الضروري إنشاء قواعد بيانات تتضمن كافة المعلومات المتعلقة بمحطة معالجة الصرف الصحي للاستفادة منها لاحقاً في بناء موديلات شبكات عصبونية صناعية أكثر دقة.
- 2- من الممكن في المستقبل تطوير الشبكة العصبونية من خلال جمع عدد أكبر من البيانات الموثوقة وإضافة متغير مهم في محطات المعالجة وهو التدفق (Q)، ووضع نماذج جديدة لمعرفة تأثير كل متغير من المتغيرات المساعدة على المتغيرات الرئيسية.
- 3- إن مثل هذه الأبحاث تتطلب جمع بيانات وغالباً ما تكون العملية مشوبة بالأخطاء التي من الممكن تقليصها إلى حدودها الدنيا كلما كانت البيانات موثوقة بشكل جيد.
- 4- من أجل تعميم الطريقة المطبقة باستخدام شبكة عصبونية صناعية ديناميكية على محطات تنقية أخرى لمياه الصرف الصحي، يجب على الباحث أن يقرر أي العوامل النوعية هو القابل للتحديد على وجه الدقة وربما يكون من الضروري اعتبار عوامل مساعدة إضافية أخرى.

5- يمكن استخدام نظام هجين من الشبكات العصبونية الصناعية والخوارزميات الجينية في النمذجة لأداء تقييم محطة معالجة صرف صحي.

المراجع:

- [1] VASSOS, D.T., *Future Directions in Instrumentation, Control and Automation in the Water and Wastewater Industry*, J. Water Science & Technology, Vol. 28, No. 11-12, pp. 9-14, 1993
- [2] VANROLLEGHEM, A.P. AND VERSTRAETE, W., *Simultaneous Biokinetic Characterization of Heterotrophic and Nitrifying Population of Activated Sludge*, J. Water Science & Technology, Vol. 28, No. 11-12, pp. 377-387, 1993
- [3] MJALLI, S. F., AL-ASHEH, S., ALFADALA, E. H., *Use of Artificial Neural Network Black-Box Modelling for the Prediction of Wastewater Treatment Plants Performance*, Journal of Environmental Management, Vol. 83, pp. 329-338, 2007
- [4] 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, pp. 55-65, 1999
- [5] 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, pp. 1608-1618, 2003
- [6] 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, pp. 229-239, 1999
- [7] CÔTÉ, M., GRANDJEAN, P.A. B., LESSARD, P., THIBAUT, J., *Dynamic modeling of the activated sludge process: improving prediction using neural networks*, Water Research, Vol. 29, No. 4, pp. 995-1004, 1995
- [8] 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, pp. 919-928, 2004

- [9] 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, pp. 124–137, 2000
- [10] 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, pp. 101–124, 2000
- [11] 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, pp. 125–132, 2001
- [12] BLAESI, J.; JENSEN, B, *Can neural networks compete with process calculations?..* In Tech Applying Technology, Vol. 39, No. 12, pp. 34–37, 1992
- [13] JAMI, S. M., HUSAIN, F.A I., KABASHI, A. N., ABDULLAH, N., *Multiple Inputs Artificial Neural Network Model For The Prediction Of Wastewater Treatment Plant Performance*. Australian Journal of Basic and Applied Sciences, Vol. 6, No. 1, pp. 62-69 , 2012
- [14] RENE, R. E. AND SAIDUTTA B. M., *Prediction Of BOD And COD Of A Refinery WasteWater Using Multilayer Artificial Neural Networks*, Journal of Urban and Environmental Engineering, Vol.2, No.1, pp.1-7, 2008
- [15] 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, PP. 38-42, 2011
- [16]. Pakrou, S., Mehrdadi, N. and Baghvand A., *Artificial Neural Networks Modeling For Predicting Treatment Efficiency And Considering Effects Of Input Parameters In Prediction Accuracy: A Case Study In TABRIZ Treatment Plant*, Indian Journal of Fundamental and Applied Life Sciences, Vol. 4, , No. 4, pp. 3732-3745 , 2014
- [17] Hamoda, F. M., Al-Ghusain, A. I., Hassan, H.A., *Integrated wastewater treatment plant performance evaluation using artificial neural networks* . Water Science and Technology, Volume 40, No. 7, pp. 55-65, 1999
- [18] 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, , PP 111–123, 1998
- [19] أ.د.د. عادل عوض. تطبيقات نظم الذكاء الصناعي في حماية البيئة. وزارة الثقافة – الهيئة العامة السورية للكتاب، دمشق، 2007.
- [20] 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, pp. 3497- 3502, 2008.
- [21] TAYLOR, J.G, *Neural Network and Their Applications*, John Wiley and Sons, England, 1996.
- [22] Principe, J. C.; Euliano, N. R.; Lefebvre, W.C, *Neural and Adaptive Systems: Fundamentals through Simulation*. John Wiley and Sons, 2000.