

Application of Non-Linear Autoregressive Neural Networks for Predicting the Drinking Water Turbidity of Al-Sin Water Purification Plant

Dr. Adel Awad*
Dr. Raed Jafar**
Aziz Adel Osekrieh ***

(Received 14 / 8 / 2017. Accepted 21 / 12 / 2017)

□ ABSTRACT □

Drinking water turbidity measuring is significant indicator of water quality, and represents a primary test to evaluate the stability of drinking water purification plant. Artificial neural networks (ANN) provide efficient tool to deal with the complex, dynamic and non-linear nature of purification processes. They have the ability to response to various instant changes in parameters influencing water purification.

In this research a feed-forward back-propagation non-linear autoregressive neural networks with exogenous variables (NARX) were tested to predict the effluent turbidity from Al-Sin drinking water purification plant, which considered as a case study. The models were built based on daily turbidity, pH and conductivity of raw water data as well as daily rainfall over the reservoir while the daily effluent turbidity data were used for verify the performance accuracy of each network. The results of this research confirm that NARX models offers good results in modeling and simulating the non-linearity behavior of water turbidity as well as to predict its values. These models can be used in a permanently evaluation of the performance of Al-Sin drinking water purification in order to achieve the stabilization and supply a significant sector of the Syrian coast with drinking water.

Key words: Turbidity, Water Purification Plant, Prediction, Artificial Neural Networks.

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

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

*** Postgraduate Student, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

تطبيق نموذج الانحدار الذاتي غير الخطي للشبكات العصبونية للتنبؤ بعكارة مياه الشرب في محطة تنقية السن

الدكتور عادل عوض*

الدكتور راند جعفر**

عزيز عادل عسيكريه***

تاريخ الإيداع 14 / 8 / 2017. قُبِلَ للنشر في 21 / 12 / 2017

□ ملخص □

يعدّ قياس عكارة مياه الشرب مؤشراً هاماً على جودة المياه، ويمثل اختباراً أساسياً لتقييم استقرار عمل محطة تنقية مياه الشرب. توفّر الشبكات العصبونية الصناعية أداةً فعالة للتعامل مع الطبيعة المعقدة، والديناميكية، وغير الخطية لعمليات التنقية، ولديها القدرة على الاستجابة للتغيرات الآنية المختلفة للبارامترات المؤثرة في تنقية المياه. تم في هذا البحث اختبار شبكات الانحدار الذاتي غير الخطي مع متغيرات خارجية Non-Linear Autoregressive Neural Networks with Exogenous Variables (NARX)، وذات التغذية الأمامية، والانتشار العكسي للخطأ للتنبؤ بعكارة المياه الخارجة من محطة تنقية مياه الشرب في السن التي اعتمدت كحالة دراسة. بُنيت النماذج بالاعتماد على بيانات عكارة، وناقلية، و pH مياه بحيرة السن الخام الداخلة إلى المحطة بالإضافة إلى بيانات الهطول المطري فوق حوض التغذية، واستخدمت بيانات عكارة المياه الخارجة من المحطة المقاسة يومياً للتحقق من دقة أداء الشبكة العصبونية الصناعية. أثبتت نتائج الدراسة أن النموذج المستخدم يُعطي نتائج جيدة في نمذجة ومحاكاة السلوك غير الخطي للعكارة، والتنبؤ بقيمها، ويمكن استخدامه في التقييم المستمر لأداء محطة تنقية مياه الشرب في السن بما يحقق استقراراً في عملها، وفي تزويد قطاع كبير من الساحل السوري بمياه الشرب.

الكلمات المفتاحية: عكارة، محطة تنقية مياه، تنبؤ، شبكات عصبونية صناعية.

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

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

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

مقدمة:

تمثل العكارة مؤشراً هاماً لجودة المياه في نظام الإمداد بالمياه، وتعتبر مؤشراً تقديرياً هاماً في عمليات معالجة مياه الشرب [1]. كما تعد مؤشراً شائع الاستخدام لوصف الحالة العامة لمياه الشرب فهي تعبر عن الناحية الفيزيائية عن مقدار انخفاض نقاوة المياه بسبب وجود جزيئات معلقة أو غروية [2].

يمكن اعتبار العكارة أهم البارامترات اللازمة للتحقق من حالة مياه الشرب فهي من جهة مؤشراً استدلالياً للتأثير العام لبقية البارامترات لأنها تتأثر بشكل كبير بها، وهي من جهة أخرى بارامتر متكامل لأن القيم العالية منها تشير إلى القيم العالية لبارامترات أخرى متعلقة بجودة المياه كالطلب الكيميائي للأوكسجين المنحل، أو تراكيز المواد المختلفة المتعلقة بالتلوث كالألمونيوم والكبريتات والنترات وغيرها، كما أن قياسات العكارة تمثل اختباراً أساسياً لتقييم جودة المياه طالما أن المياه النقية لها قيمة عكارة مساوية للصفر لذلك يعد بارامتر العكارة بالنتيجة مؤشراً جيداً لجودة المياه [3].

إن الهدف الأساسي لمحطة معالجة مياه الشرب هو إنتاج مياه آمنة للاستهلاك لا تحتوي كائنات حية دقيقة ممرضة أو مركبات سامة، وإنتاج مياه شرب سائغة خالية من الطعم، واللون، والرائحة، وبما يحول دون تراكم المواد الصلبة، وحدوث التآكل، والنمو اللاحق للبكتريا في أنابيب النقل والتوزيع. ويجب أن يتم ذلك بأقل كلفة، وأقل تأثير على البيئة حيث تتطوي عمليات معالجة المياه عادةً على مرحلتين التنقية والتطهير [4].

تعد محطة تنقية مياه الشرب في السن المصدر الرئيسي للمياه في محافظة اللاذقية، وتقع أمام هذه المحطة تحديات كبيرة لإنتاج مياه الشرب بالجودة المطلوبة، والكلفة الأقل حيث يفرضُ ازدياد الطلب على المياه في الساحل السوري، وقدم العديد من التجهيزات، وازدياد التلوث في حوض السن على مشغلي المحطة إجراء تحاليل دورية دائمة للبارامترات المؤثرة في جودة مياه الشرب لمراقبة نوعية المياه والحفاظ على استقرار أداء المحطة، وهو ما يسبب زيادة في كلفة تشغيل المحطة بسبب الكلفة العالية للمراقبة، والتحاليل الكيميائية اللازم إجراؤها.

تتم التنقية في محطة السن لأغراض الشرب بالترشيح السريع دون تخثير، حيث تمر المياه عبر مرشحات رملية سريعة للتخلص من المواد العالقة فيها. لذلك تتم مراقبة أداء عملية الترشيح من حيث مستويات العكارة لضمان مياه شرب آمنة [5].

تقاس العكارة بوحدة Nephelometric Turbidity Units (NTU)، ويجب ألا تزيد في مياه الشرب عن 1 NTU لضمان كفاءة عملية التطهير، ويفضل أن تكون أقل بكثير منها [6]. ووفقاً للمواصفات القياسية السورية لمياه الشرب فإن الحد المسموح به لعكارة مياه الشرب هو 1 NTU أما الحد الأقصى فهو 5 NTU [7].

رغم إمكانية تحديد البارامترات المؤثرة على عملية معالجة المياه فإن التفاعلات، والعلاقات بين مدخلات، ومخرجات هذه العملية تبقى غير مفهومة في أغلب الأحيان، ولا يمكن تحديدها بسهولة [8]. لذلك باتت العديد من مرافق مياه الشرب تستثمر في مجال التحكم المتقدم بالعمليات، وتقنيات الأتمتة بهدف تحسين جودة مياه الشرب مع تقليل تكاليف تشغيل المنشآت [9].

يزداد استخدام تقنيات الذكاء الصناعي لاسيما الشبكات العصبونية الصناعية Artificial Neural Networks (ANNs) في محطات معالجة مياه الشرب انطلاقاً من كونها تسمح بتطوير نماذج لا خطية موثوقة لعمليات المعالجة المعقدة [10].

توفر الشبكات العصبونية الصناعية مزايا عديدة مقارنة بالطرق التقليدية للنمذجة مثل الانحدار الخطي فهي تتعلم الارتباطات بين المدخلات والمخرجات من خلال البيانات التاريخية دون الحاجة إلى تحديد شكل النموذج، ويتميز

بقوتها تجاه البيانات غير المرغوب بها أو غير المستمرة كما أن الزيادة في سرعة المعالجة الحاسوبية قللت من الزمن اللازم لتدريب وتقييم هذه النماذج [10]. وتتميز الشبكات العصبونية الصناعية أيضاً بقدرتها على التنبؤ بأشكال غير خطية دون الحاجة لمعرفة التابع الذي يصف المتغير المراد نمذجته باستخدام الشبكة [11].

استعملت الشبكات العصبونية الصناعية في مجالات عديدة متعلقة بمعالجة المياه كأتملة العمليات في محطات معالجة المياه [4]، وتقييم وتحسين كفاءة منشآت التنقية [12,13]، ونمذجة إزالة الملوثات من المياه [11].

صمّم باحثون شبكة عصبونية صناعية للنتبؤ بقيمة عكارة المياه الخارجة من المرسب في محطة معالجة لمياه الشرب في نيجيريا بهدف أتملة عمليات المعالجة، وكلفة تشغيل المحطة من خلال حساب تابع كلفة التشغيل الأدنى لها. أظهرت نتائج تطبيق أسلوب الشبكات العصبونية انخفاضاً في كلفة التشغيل، واستقراراً عالياً لتثبيت بذلك أنها أداة مناسبة لتحسين كفاءة عمليات المعالجة، والكلفة في محطات معالجة مياه الشرب [4].

واستُخدمت الشبكات العصبونية الصناعية في دراسة أخرى لأتملة أداء المرشحات في محطة تجريبية رائدة لمعالجة مياه الشرب في العراق من خلال نمذجة بارامترات عملية الترشيح، والتي شملت عكارة المياه المرشحة، وفاقد الضغط، ودورة الترشيح. أظهرت النتائج قدرة النماذج على التنبؤ بدرجة كبيرة وصلت إلى أكثر من 95% لقيمة عكارة المياه المرشحة وفاقد الضغط، ولأكثر من 85% بالنسبة لدورة الترشيح مما يمكنها من مساعدة الفنيين في تشغيل المرشحات العاملة في محطة معالجة المياه، وتحسين عمليات المعالجة، وهو ما أثبت أن استخدام أسلوب الشبكات العصبونية يساعد في رفع كفاءة أنظمة معالجة المياه مما يحسّن نوعية المياه الناتجة عن المحطة، ويقلل كلفة تشغيلها [12].

كما استخدم باحثون أسلوب الشبكات العصبونية لبناء نموذج للنتبؤ بفاعلية المرشحات المضغوطة في إزالة عكارة المياه تحت تأثير مجموعة من الظروف المتغيرة المدروسة، وهي عكارة المياه الخام، ومعدل الترشيح، وضغط المرشح، والتي مثلت إشارات الدخل للشبكة العصبونية. اعتمد الباحثون على بيانات لعينات بلغ عددها 1300 عينة من نموذج مخبري رائد لحساب قيم العكارة الدنيا والعظمى للمياه الخارجة من المرشح بالاعتماد على التحاليل الإحصائية، ومن ثم تطبيق الشبكات العصبونية الصناعية للنتبؤ بهذه القيم. أظهرت النتائج كفاءة تطبيق الشبكات العصبونية لنمذجة فعالية المرشح المضغوط في إزالة العكارة، وإمكانية تعميم النموذج المبني على حالات أخرى تحقق نفس الشروط المعتبرة في الدراسة [13].

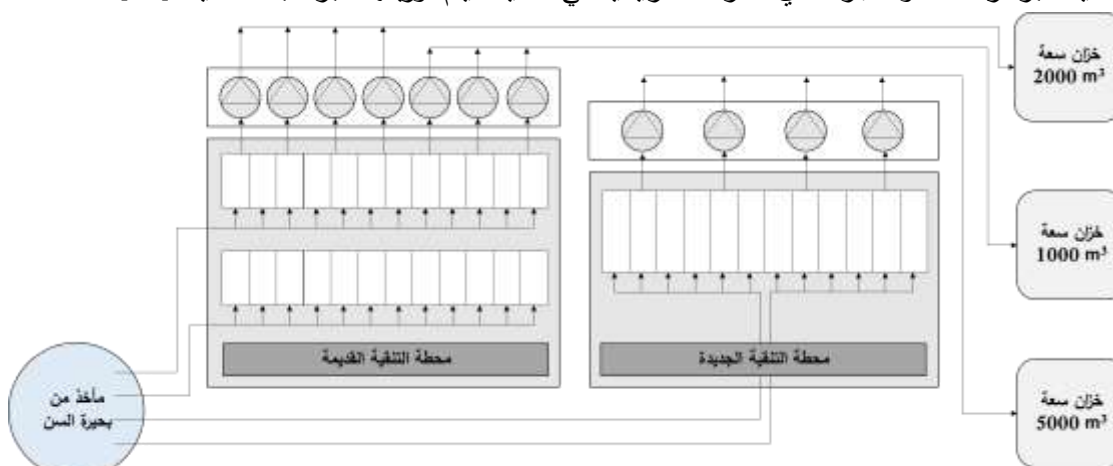
في دراسة أخرى استُخدمت الشبكات العصبونية الصناعية في نمذجة عكارة المياه أثناء معالجة المياه في محطة معالجة للمياه السطحية، والمخزنة في خزان سوسنوكا في بولندا. تضمنت مدخلات النموذج كلاً من حرارة، وPH، وعكارة، وناقلية المياه الخام، ومخرجاته عكارة المياه المعالجة. بلغ الارتباط بين قيم عكارة المياه المعالجة المتوقعة، والحقيقية 84% مما أثبت قوة الشبكات العصبونية الصناعية في التنبؤ بعكارة المياه قبل البدء بمعالجة المياه [11].

وسنقوم في هذا البحث بتصميم نموذج للنتبؤ بعكارة المياه المرشحة في محطة تنقية مياه الشرب في السن باستخدام إحدى شبكات عصبونية صناعية ديناميكية.

منطقة البحث:

تقع محطة تنقية مياه الشرب في السن على بحيرة السن في أقصى جنوب محافظة اللاذقية، وتتميز مياه البحيرة بعكارة قليلة نسبياً (1-3) NTU، وتزداد لتبلغ قيمة أعلى من 6 NTU بحسب الظروف المناخية والتلوث، وتتألف محطة التنقية من محطتين قديمية، وجديدة تعملان على التوازي، وتتم التنقية فيهما باستخدام المرشحات الرملية السريعة بدون استخدام المخثرات، ويبين الشكل (1) مخططاً عاماً لمراحل التنقية في المحطة.

تضم محطة التنقية القديمة 24 حوض ترشيح، أبعاد الحوض (4*11) m ويتألف من طبقة رمل كوارتزي بارتفاع 120 cm ثم طبقة بلاطات بيتونية تحتوي الفلاتر، بينما تضم محطة التنقية الجديدة 12 حوض ترشيح، أبعاد الحوض (4*12) m ويتألف من طبقة فحم انتراسيت عليا بارتفاع 40 cm، وطبقة رمل كوارتزي سفلى بارتفاع 60 cm [14]. تزيد سرعة الترشيح في محطتي التنقية القديمة والجديدة عن 7 m/h، ويمرر كل حوض ترشيح في المحطة القديمة 8100 m³/d من المياه، بينما يمرر كل حوض ترشيح في المحطة الجديدة 10080 m³/d من المياه. بعد أن تمر المياه عبر المرشحات الرملية السريعة في المحطتين القديمة والجديدة تعبر المياه إلى بيارات السحب، ومنها تضخ باتجاه ثلاثة خزانات في قرفيص ترتفع عن سطح البحر حوالي 90 m، وبعد ذلك تجر المياه إلى مدينة اللاذقية عبر أربعة خطوط جر تغذي الخزانات الرئيسية في المدينة ليتم توزيعها عبر شبكة المدينة [14].



الشكل (1): مخطط لعملية التنقية في محطة تنقية مياه الشرب في السن

أهمية البحث، وأهدافه:

إن الوصول إلى نموذج تنبؤي موثوق لعكارة المياه في محطة التنقية باستخدام الشبكات العصبونية الصناعية الديناميكية يقدم أداة قوية وفعالة للتنبؤ بنوعية المياه مقدماً، وبالتالي تقييم أداء محطة التنقية بشكل مسبق، وهو ما يخفض تكاليف تشغيل المحطة، ويؤدي إلى استقرار أدائها.

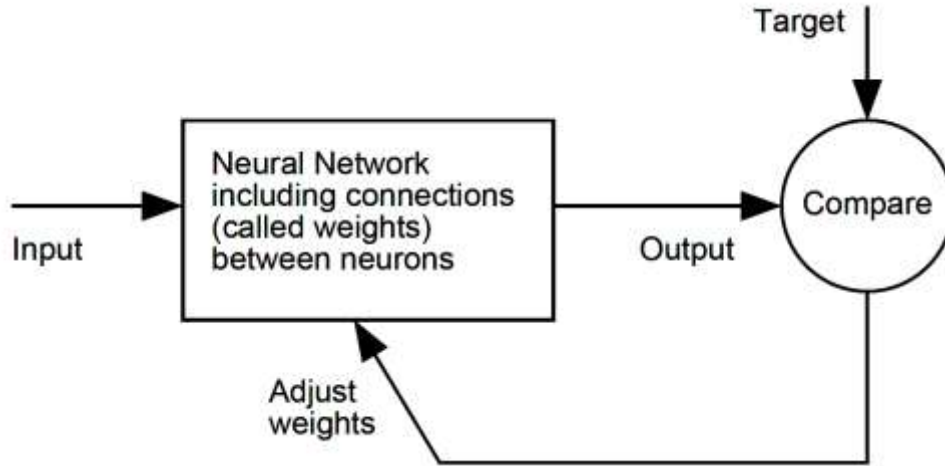
يهدف البحث إلى إيجاد نموذج تنبؤي موثوق لعكارة المياه في محطة تنقية مياه الشرب في السن باستخدام الشبكات العصبونية الديناميكية، واعتماداً على القياسات الدورية اليومية في محطة التنقية لبارمترات عكارة، وناقلية، و pH المياه الخام بالإضافة إلى كمية الهطول المطري اليومي فوق حوض التغذية، ومن ثم تقييم أداء النموذج المصمم باستخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب.

طرائق البحث ومواده:

الشبكات العصبونية الصناعية:

تعمل الشبكات العصبونية الصناعية بطريقة تحاكي عمل النظم العصبية الحيوية، وتتكون من عناصر بسيطة تدعى العصبونات Neurons أو العقد Nodes ترتبط فيما بينها بارتباطات موزونة، وترتب ضمن عدد من الطبقات هي طبقة الدخل Input Layer، وطبقة الخرج Output Layer، والطبقات المخفية Hidden Layer بينهما.

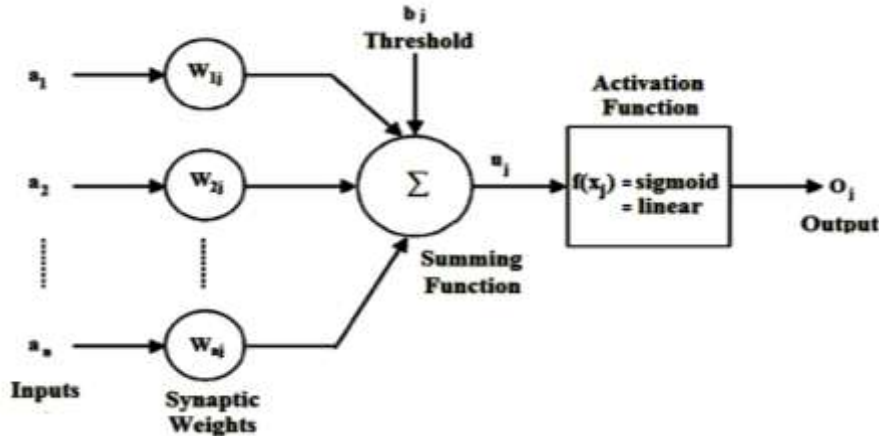
يتم تدريب الشبكة من خلال خوارزميات تدريب متخصصة Training Algorithms، وتعتبر خوارزميات التعلم تحت الإشراف Supervised Learning Algorithms من أكثرها استخداماً في تطبيقات تابع التقارب التي تنتمي إليها مشكلة البحث، وفيها تدرّب الشبكة على سلسلة من أزواج المدخلات، والمخرجات المأمولة المرتبطة بها حيث تعدل أوزان الشبكة اعتماداً على الفرق بين مخرجات الشبكة Output، والمخرجات المأمولة الهدف Target، ويتم تغذية الشبكة بالفرق بين Output-Target ليتم على أساسه تعديل اوزان الشبكة للحصول على أقل خطأ ممكن حيث يوضح الشكل (2) آلية تدريب الشبكة العصبونية.



الشكل (2): آلية تدريب الشبكات العصبونية [16]

يتم انتشار البيانات الداخلة إلى الشبكات العصبونية الصناعية ذات التغذية الأمامية Feed Forward ANNs باتجاه الأمام دائماً من طبقة الدخل إلى طبقة الخرج، وتعتبر خوارزمية الانتشار العكسي للخطأ Back Propagation Algorithm (BP) إحدى أكثر خوارزميات تدريبها شيوفاً حيث يتم حساب الخطأ بين الخرج المحسوب، والخرج المرغوب ثم يمرر الخطأ خلفاً من طبقة الخرج إلى طبقة الدخل ليتم استخدامه في تعديل الأوزان.

يمثل كل عصبون في الشبكة عنصر معالجة Process Element، ويوضح الشكل (3) آلية عمل العصبون حيث يتم معالجة المدخلات بضرب كل منها بوزن معين W ثم تجمع المدخلات الموزونة، ويضاف إليها عامل انحياز b ، ومن ثم يطبق على الناتج تابع تفعيل خاص بالعصبون Activation Function يعطي قيمة وحيدة تمثل خرج العصبون، والتي يعاد انتشارها إلى العصبونات التالية.



الشكل (3): آلية عمل العصبون في الشبكة العصبونية الصناعية [15]

الشبكات العصبونية الديناميكية:

يمكن تصنيف الشبكات العصبونية إلى شبكات ستاتيكية، وأخرى ديناميكية، ويكمن الفرق الأساسي بين الصنفين أن الشبكات الستاتيكية ذات التغذية الأمامية لا تملك عناصر تغذية راجعة، ولا تأخيرات زمنية لذلك يحسب خرج الشبكة مباشرة من المدخلات التي تمر عبر وصلات تغذية أمامية أما في الشبكات الديناميكية لا يعتمد خرج الشبكة على المدخلات الحالية فقط للشبكة، وإنما على مدخلات الشبكة الحالية أو السابقة، وكذلك على المخرجات أو حالات الشبكة [16].

تم في هذا البحث تقييم استخدام شبكة الانحدار الذاتي غير الخطي مع مدخلات خارجية The Nonlinear Autoregressive Network with Exogenous Inputs (NARX) للتنبؤ بعكارة المياه المرشحة الخارجة من محطة تنقية مياه الشرب في السن.

شبكة NARX هي شبكة ديناميكية إرجاعية Recurrent Dynamic Network ذات وصلات تغذية راجعة تغلق عدة طبقات في الشبكة، ويعتمد نموذج NARX على نموذج ARX الخطي، والذي يستخدم بشكل شائع في نمذجة السلاسل الزمنية، ويعرّف من خلال المعادلة التالية:


$$Y(t) = f[y(t-1), y(t-2), \dots, y(t-d), x(t-1), x(t-2), \dots, x(t-d)] \quad (1)$$

حيث تعتمد القيمة التالية لإشارة الخرج التابعة $Y(t)$ على القيم السابقة لإشارة الخرج، والقيم السابقة لإشارة دخل خارجية مستقلة [16].

تمتلك هذه الشبكات تطبيقات عديدة حيث يمكن استخدامها للتنبؤ بالقيمة التالية لإشارة الدخل. كما يمكن استخدامها في الفلترة غير الخطية بحيث تنتج خرجاً خالٍ من البيانات غير المرغوبة في إشارة الدخل كذلك في نمذجة الأنظمة غير الخطية الديناميكية [16].

يتم في شبكة NARX تغذية خرج الشبكة خلفاً باتجاه مدخلات الشبكة العصبونية أمامية التغذية، ولأن الخرج الحقيقي متوفر أثناء عملية تدريب الشبكة فيمكن إنشاء معمارية سلاسل متوازية Series-Parallel Architecture الشكل (4-b) يتم فيها استخدام القيمة الحقيقية للخرج، وذلك بدلاً من إنشاء معمارية متوازية Parallel Architecture الشكل (4-a) تتم فيها التغذية الراجعة باستخدام قيمة خرج الشبكة المقدر حيث تستخدم هذه المعمارية في إنجاز التنبؤ بالسلسلة الزمنية لعدة خطوات. تستخدم معمارية السلاسل المتوازية للتنبؤ بسلاسل زمنية بخطوة واحدة، ولها فائدتين أساسيتين تكمن الأولى في أن مدخلات الشبكة ذات التغذية الأمامية تكون أكثر دقة، والثانية في إمكانية استخدام خوارزمية الانتشار العكسي الستاتيكية في عملية تدريبها [16].

تقسم البيانات المتاحة أثناء تدريب الشبكة إلى ثلاثة مجموعات مجموعة التدريب Training Set، ومجموعة التحقق Validation Set، ومجموعة الاختبار Test Set حيث يستخدم خطأ مجموعة التدريب لتحديث أوزان الشبكة، والانحيازات بينما يستخدم خطأ مجموعة التحقق لإيقاف عملية التدريب عندما يبدأ هذا الخطأ بالازدياد لعدد محدد من الدورات التكرارية، أما خطأ مجموعة الاختبار فيستخدم للمقارنة بين النماذج المختلفة [16].



الشكل (4): معماريتي شبكات NARX [16]

a - معمارية متوازية؛ b - معمارية سلاسل متوازية

البيانات المستخدمة:

تم الحصول على البيانات الخام المستخدمة في النمذجة من المؤسسة العامة لمياه الشرب في اللاذقية، ومن مديرية الموارد المائية، وذلك على مدى أكثر من ثلاثة أعوام (2013-2016) حيث تعد هذه الفترة كافية لتغطية كل التغيرات الفصلية المحتملة في البارامترات المستخدمة في البحث.

تقاس في محطة التنقية بشكل دوري يومي عكارة، وناقلية، و pH المياه الخام، وعكارة المياه المرشحة الخارجة من المحطة كما تتوفر من محطة رصد الهطول المطري في المنطقة بيانات اليومية للهطول المطري فوق حوض التغذية. تم استقراء القيم المفقودة في البيانات باستخدام الطريقة الخطية Linear Interpolation، وبلغ عدد البيانات الإجمالي المستخدمة لتدريب الشبكة، واختبارها 1171.

بدراسة الارتباط الخطي بين عكارة المياه المرشحة، وبقية البارامترات لم يلاحظ وجود علاقة خطية بينها كما يتضح من الجدول (1)، وقد تكون العلاقة غير خطية بينها لذلك لتحديد المدخلات الأفضل لشبكة NARX تم تجريب مجموعة من النماذج ذات مدخلات مختلفة، وتم تحديد النموذج الذي يعطي النتائج الأفضل بينها.

الجدول (1): قيم الارتباط الخطي بين عكارة المياه المرشحة، والبارامترات الأخرى المستخدمة في البحث

	عكارة المياه الخام	ناقلية المياه الخام	pH المياه الخام	الهطول المطري
عكارة المياه المرشحة	83.1 %	- 6.1 %	- 2.8 %	9.4 %

تمت دراسة مجموعة من النماذج بالاعتماد على المدخلات، وذلك وفق التالي:

- النموذج M_1 : مدخلاته: عكارة المياه الخام، وناقلية المياه الخام.
 - النموذج M_2 : مدخلاته: عكارة المياه الخام، وناقلية المياه الخام، و pH المياه الخام.
 - النموذج M_3 : مدخلاته: عكارة المياه الخام، والهطول المطري.
 - النموذج M_4 : مدخلاته: عكارة المياه الخام، وناقلية المياه الخام، والهطول المطري.
 - النموذج M_5 : مدخلاته: عكارة المياه الخام، وناقلية المياه الخام، و pH المياه الخام، والهطول المطري.
- بينما كانت مخرجات جميع النماذج هي عكارة المياه المرشحة.

لا تستخدم عادةً البيانات الخام مباشرة في الشبكة العصبونية الصناعية رغم إمكانية ذلك حيث تتمثل سلبات استخدامها في زيادة زمن تدريب الشبكة بشكل ملحوظ بسبب اختلاف مجالات المتغيرات [15]. لذلك تم تقييس بيانات الدخل، والخرج ضمن المجال [0-1] وفقاً للمعادلة التالية، وذلك لأن المكتبة المستخدمة تعتمد على تابع التحويل السيجمويدي في الطبقة المخفية:

$$X_{norm} = \frac{X - X_{average}}{X_{max} - X_{min}} \quad (2)$$

حيث أن: $X_{average}$: القيمة المتوسطة لسلسلة البيانات.

X_{max} : القيمة العظمى لسلسلة البيانات.

X_{min} : القيمة الصغرى لسلسلة البيانات.

ولمحاكاة أداء النموذج، والتحقق منه استخدم في هذا البحث كل من متوسط مربع الخطأ Mean Squared Error (MSE)، ومعامل الارتباط Correlation Coefficient (R) بين الخرج المتوقع، والخرج الحقيقي.

يعبر عن متوسط مربع الخطأ MSE بالمعادلة التالية:

$$MSE = \frac{1}{2 \cdot q} * \sum_{i=1}^{i=q} (Y_i - a_i)^2 \quad (3)$$

حيث: Y_i : المخرجات الهدف Target

a_i : قيمة خرج الشبكة المحسوبة calculated.

ويمكن حساب معامل الارتباط R بين الخرج المتوقع، والخرج الحقيقي من خلال المعادلة التالية:

$$R = \sqrt{1 - \frac{F}{F_0}} \quad (4)$$

حيث أن: F : تباين النموذج المتنبى.

F_0 : التباين الأول قيم التصريف.

ويحسب كل منهما من المعادلات التالية:

$$F = \sum_{k=1}^k (Q_k - Q'_k)^2 \quad (5)$$

$$F_0 = \sum_{k=1}^k (Q_k - \bar{Q}_k)^2 \quad (6)$$

حيث أن: k : العدد الكلي لعناصر البيانات.

Q_k, Q'_k : قيم التصريف المراقبة، والمحسوبة عند الفاصل الزمني k^{th} على التوالي.

\bar{Q}_k : هو متوسط التصريف على امتداد الزمن.

يتم غسل المرشحات عندما تزداد ضياعات الضغط في الحشوة عن مترين، أو عندما تسوء نوعية المياه المرشحة، وعادة لا تتجاوز دورة الترشيح الأسبوع الواحد، لذلك اعتمدت قيم التأخير الزمني من يوم حتى سبعة أيام.

النتائج والمناقشة:

بُنيت النماذج باستخدام شبكة NARX، وهي شبكة ذات تغذية أمامية مع انتشار عكسي للخطأ، وتتألف من طبقة مدخلات، وطبقة مخرجات، وطبقة مخفية واحدة.

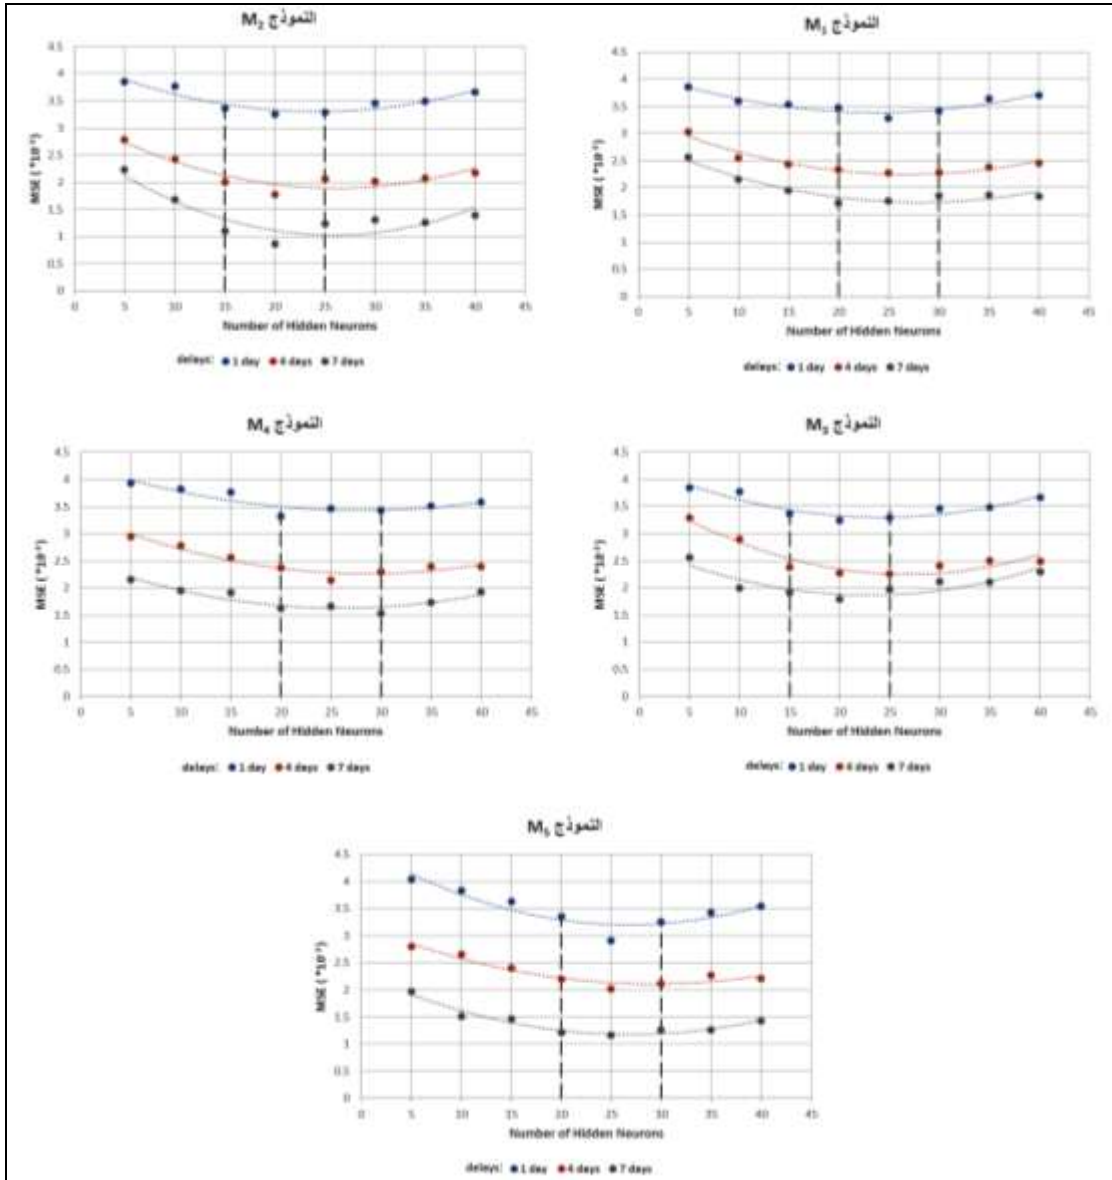
دربت الشبكة باستخدام تابع trainLM أي باستخدام خوارزمية Levenberg-Marquardt، واستخدم تابع تحويل سيغمويد غير الخطي Sigmoid Transfer Function كتابع تفعيل في الطبقة المخفية، وتابع التحويل الخطي Linear Transfer Function كتابع تفعيل في طبقة المخرجات بينما اعتمد تابع MSE لقياس أداء الشبكة.

تمت دراسة كل نموذج من النماذج الخمسة (M_1, M_2, M_3, M_4, M_5) لتحديد النموذج الذي يحقق الأداء الأفضل اعتماداً على تابع الخطأ MSE، وتم العمل وفق ثلاثة مراحل.

في المرحلة الأولى تم تحديد المجال الأفضل لكل نموذج من النماذج الخمس المدروسة بالاعتماد على القيم الأدنى لتابع الخطأ MSE بعد تصميم مجموعة من الشبكات للنموذج الواحد، ولكل منها عدد مختلف لعصبونات الطبقة المخفية (40-35-30-25-20-15-10-5)، وتأخيرات زمنية مختلفة (7, 4, 1)، حيث يظهر الشكل (6) النتائج التي تم الحصول عليها في المرحلة الأولى حيث وجد أن المجالات الأمثل لعدد عصبونات الطبقة المخفية، والتي تعطي القيم الأدنى لتابع الخطأ MSE من أجل النماذج الخمسة هي (20-30) للنماذج M_1 ، M_4 ، و M_5 ، و (15-25) للنموذجين M_2 ، و M_3 .

وتم في المرحلة الثانية تحديد عدد العصبونات، والتأخير الزمني اللذان يحققان الأداء الأفضل لكل نموذج من النماذج الخمس، وذلك بتصميم عدد من الشبكات للنموذج الواحد، ولكل منها عدد متزايد من عصبونات الطبقة المخفية ضمن المجال الأمثل الذي تم تحديده في المرحلة السابقة، ومن أجل تأخيرات زمنية متتالية (7, 6, 5, 4, 3, 2, 1) حيث تم تحديد الأداء الأفضل من خلال تحديد الشبكة التي تعطي القيمة الأدنى لتابع الخطأ MSE.

تم تجريب نسب تقسيم مختلفة في المرحلة الثالثة لتحديد النسبة الأمثل لكل شبكة NARX تم تحديدها في المرحلة السابقة، واختيرت النسبة التي تحقق أصغر قيمة لتابع الخطأ MSE، حيث وجد أن نسبة التقسيم التي تعطي أفضل نتائج لكل نموذج من النماذج هي 15-15-70 لكافة النماذج (M_1, M_2, M_3, M_4, M_5)، ويلخص الجدول (2) هيكلية شبكة NARX المثلى لكل نموذج من النماذج المدروسة، والتي تم الحصول عليها في نهاية المرحلتين الثانية والثالثة. كما يبين الجدول (3) النتائج التي تم الحصول عليها في المراحل الثلاث من أجل النموذج M_1 .



الشكل (6): تحديد المجالات الأمثل لعدد عصبونات الطبقة المخفية لكل نموذج من النماذج الخمس المدروسة

الجدول (2): هيكلية شبكة NARX المثلى لكل نموذج من النماذج الخمس المدروسة

النموذج	العدد المثالي لعصبونات الطبقة المخفية	التأخير الزمني	النسبة المثلى لتقسيم البيانات	تابع الخطأ الكلي MSE (*10 ⁻³)	معامل الارتباط الكلي R (%)
M ₁	23	6	70-15-15	1.45	86.595
M ₂	20	7	70-15-15	0.86	88.298
M ₃	21	7	70-15-15	1.73	85.840
M ₄	27	7	70-15-15	1.51	87.523
M ₅	22	6	70-15-15	1.06	87.578

الجدول (3): النتائج التي تم الحصول عليها في المراحل الثلاث من أجل النموذج M_1

المرحلة الأولى				المرحلة الثانية																
1	d (day)	H N	MSE (*10 ⁻³)	R (%)	d (day)	H N	MSE (*10 ⁻³)	R (%)	H N	MSE (*10 ⁻³)	R (%)	H N	MSE (*10 ⁻³)	R (%)	H N	MSE (*10 ⁻³)	R (%)			
		5	3.86	81.634	1	20	3.48	78.659	2	3	3.48	79.903	2	6	3.53	82.974	2	9	3.47	80.532
		10	3.60	78.858	2	20	2.92	83.317	2	3	3.03	82.886	2	6	2.70	82.918	2	9	3.02	81.220
		15	3.54	79.631	3	20	2.47	83.064	2	3	2.89	82.801	2	6	2.20	85.518	2	9	2.33	81.508
		20	3.48	78.659	4	20	2.33	84.799	2	3	2.34	81.768	2	6	2.17	83.385	2	9	2.34	84.800
		25	3.28	82.510	5	20	2.19	81.868	2	3	2.47	83.660	2	6	2.14	86.431	2	9	2.28	85.264
		30	3.42	80.746	6	20	1.74	85.445	2	3	1.45	86.595	2	6	1.81	85.940	2	9	2.08	85.368
		35	3.64	82.905	7	20	1.72	86.602	2	3	1.75	86.244	2	6	1.79	82.381	2	9	1.80	85.103
	40	3.70	80.074																	

4	5	3.03	83.509	1	21	3.49	79.012	2	4	3.47	78.030	2	7	3.46	81.032	3	0	3.42	80.746
	10	2.55	84.303	2	21	3.32	82.737	2	4	3.12	80.485	2	7	3.01	80.041	3	0	3.02	84.208
	15	2.43	82.796	3	21	2.90	84.275	2	4	2.72	83.046	2	7	2.63	83.599	3	0	2.59	84.652
	20	2.33	84.799	4	21	2.38	84.020	2	4	2.06	86.829	2	7	2.31	83.198	3	0	2.29	83.870
	25	2.28	82.060	5	21	2.15	84.722	2	4	2.32	86.497	2	7	2.29	82.850	3	0	2.15	84.303
	30	2.29	83.870	6	21	2.12	84.821	2	4	2.19	83.762	2	7	2.00	84.971	3	0	1.95	83.816
	35	2.38	82.210	7	21	1.75	84.358	2	4	1.77	86.961	2	7	1.73	85.520	3	0	1.86	84.609
	40	2.45	82.920																

المرحلة الأولى				المرحلة الثانية											
----------------	--	--	--	-----------------	--	--	--	--	--	--	--	--	--	--	--

d (day)	H N	MSE (*10 ⁻³)	R (%)	d (day)	H N	MSE (*10 ⁻³)	R (%)	H N	MSE (*10 ⁻³)	R (%)	H N	MSE (*10 ⁻³)	R (%)
---------	-----	--------------------------	-------	---------	-----	--------------------------	-------	-----	--------------------------	-------	-----	--------------------------	-------

7	5	2.56	85.768	1	22	3.45	77.423	2	5	3.28	82.510	2	8	3.29	82.974
	10	2.16	85.441	2	22	3.13	82.240	2	5	2.92	83.921	2	8	2.93	82.918
	15	1.95	84.844	3	22	2.88	83.593	2	5	2.55	81.779	2	8	2.60	85.518
	20	1.72	86.602	4	22	2.34	82.641	2	5	2.28	82.060	2	8	2.38	83.784
	25	1.76	84.497	5	22	2.52	84.276	2	5	2.27	82.535	2	8	2.21	83.105

30	1.86	84.609	6	22	1.97	81.419	25	1.66	86.312	28	1.95	85.886
35	1.87	87.543	7	22	1.73	87.894	25	1.76	84.497	28	1.78	84.361
40	1.84	86.806										

المرحلة الثالثة


نسب تقسيم البيانات	HN= 23; d=6	
	MSE (*10 ⁻³)	R (%)
70-15-15	1.45	86.595
60-20-20	1.61	80.935
50-25-25	1.62	78.681

مواصفات الشبكة العصبونية المثلى:

يبين الجدول (4) شبكتي NARX اللتين حققنا أفضل أداء في حالة كون مدخلات النماذج هي بارامترات مقاسة في محطة التنقية فقط، وفي حالة إضافة بارامتر الهطول المطري إلى مدخلات النماذج، ويبين الشكل (7) مخططاً لهاتين الشبكتين، والشكل (8) الارتباط الكلي بين القيم المتوقعة لعكارة المياه المرشحة من خلال الشبكتين، والقيم الحقيقية لها، كما يبين الشكل (9) استجابة كلا الشبكتين.

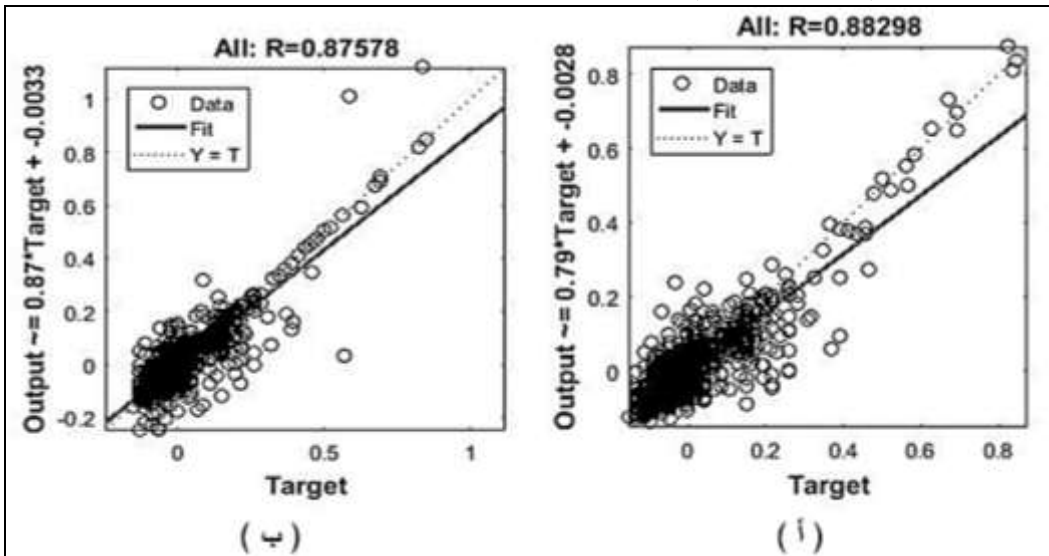
الجدول (4): شبكتي NARX اللتان حققنا أفضل أداء

معامل الارتباط الكلي R (%)				تابع الخطأ MSE (*10 ⁻³)				هيكلية الشبكة	مدخلات الشبكة ومخرجاتها	الحالة والنموذج
مجموعة الاختبار	مجموعة التحقق	مجموعة التدريب	الكل	مجموعة الاختبار	مجموعة التحقق	مجموعة التدريب	الكل			
88.30	83.47	77.85	91.86	0.86	4.08	5.89	2.12	3-20-1 التأخير: 7 نسب تقسيم البيانات: 70-15-15 %	المدخلات: عكارة، وناقلية، و pH المياه الخام الخروج: عكارة المياه المرشحة	استخدام بارامترات مقاسة في محطة M ₂
87.58	67.94	79.18	94.85	1.06	6.84	9.30	1.30	4-22-1 التأخير: 6 نسب تقسيم البيانات: 70-15-15 %	المدخلات: عكارة، وناقلية، و pH المياه الخام + الهطول المطري الخروج: عكارة المياه المرشحة	استخدام بارامترات مقاسة في محطة + الهطول المطري M ₅

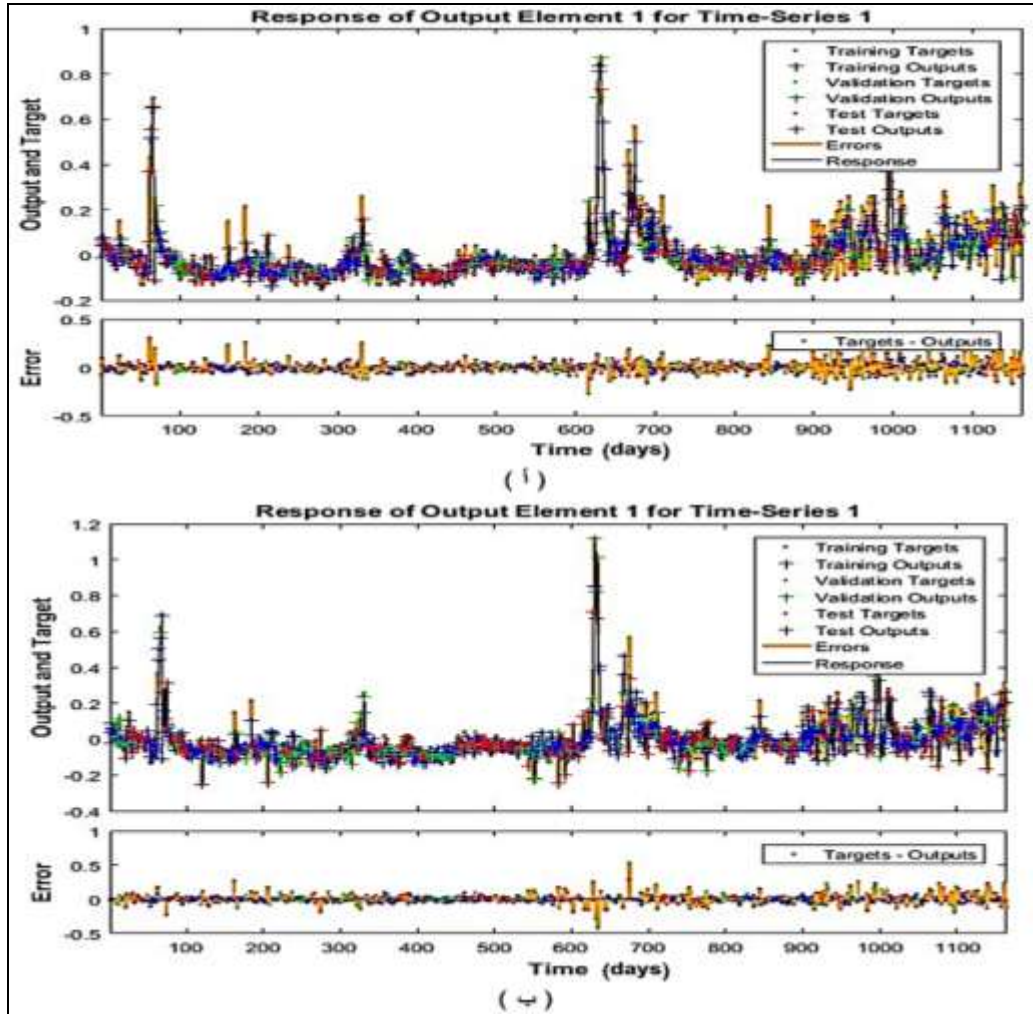


الشكل (7): مخطط شبكة NARX المثلى في حالتها:

أ- المدخلات هي بارامترات مقاسة في محطة التنقية فقط ب- إضافة بارامتر الهطول المطري إلى مدخلات النموذج



الشكل (8): الارتباط الكلي بين القيم المتوقعة، والقيم الحقيقية في شبكة NARX المثلى في حالتها: أ- المدخلات هي بارامترات مقاسة في محطة التنقية فقط ب- إضافة بارامتر الهطول المطري إلى مدخلات النموذج



الشكل (9): استجابة شبكة NARX المثلى في حالتها:

أ- المدخلات هي بارامترات مقاسة في محطة التنقية فقط ب- إضافة بارامتر الهطول المطري إلى مدخلات النموذج

تقييم فعالية الترشيح في محطة تنقية مياه الشرب في السن:

يبين الجدول (5) أمثلة عن فعالية الترشيح في المحطة من أجل قيم تقع في مجالات متفاوتة لعكارة مياه البحيرة الخام خلال الفترة التي تغطيها الدراسة، حيث تم حساب الفعالية بالاعتماد على القيم الحقيقية لعكارة المياه الخارجة، وعلى القيم التي تعطيها الشبكة العصبونية الصناعية المثلى الناتجة عن النموذج M2 والتي حققت الأداء الأفضل كما يتضح من الجدول (4)، وذلك اعتماداً على العلاقة:

$$E(\%) = \frac{Turbidity_{in} - Turbidity_{out}}{Turbidity_{in}} * 100 \quad (7)$$

الجدول (5): أمثلة عن قيم فعالية الترشيح في المحطة باستخدام البيانات الحقيقية والنتيجة عن النموذج لعكارة المياه الخارجة

باستخدام قيم النموذج		باستخدام القيم الحقيقية		Tur _{in} (NTU)	تاريخ القياس
E (%)	Tur _{out} (NTU)	E (%)	Tur _{out} (NTU)		
28.90	14.22	10.00	18.00	20.00	2013/06/22
60.63	1.24	52.38	1.50	3.15	2014/03/14
36.67	0.57	44.44	0.50	0.90	2014/10/20
56.00	4.18	58.95	3.90	9.50	2015/01/11
28.92	2.63	32.97	2.48	3.70	2015/02/16
36.25	0.51	37.50	0.50	0.80	2015/08/26
55.75	1.77	50.00	2.00	4.00	2016/03/20
70.78	0.71	69.96	0.73	2.43	2016/04/20

إن فعالية الترشيح في محطة تنقية مياه الشرب في السن في مختلف الفترات قليلة، وهي غالباً لا تتجاوز 70% كما يتضح من الأمثلة المذكورة، ويعزى ذلك إلى أن المرشحات تعمل بدون إضافة المخثرات، وبسرعات ترشيح عالية.

تأثير بنية شبكات NARX المدروسة على أدائها:

تم تحديد شبكة NARX المثلى في حالتها باستخدام بارامترات مقاسة في محطة التنقية فقط كمدخلات، واستخدام بارامتر الهطول المطري كمدخل إضافي للنماذج، وذلك بالاعتماد على قيمة تابع الخطأ MSE، وعلى الارتباط بين قيم عكارة المياه المرشحة المتوقعة في الشبكة، وقيمها الحقيقية، كما اعتمدت قيمة تأخير زمني أعظمي تبلغ 7 أيام، وتم تجريب عدد كبير من شبكات NARX متغيرة المدخلات، وعدد عصبونات الطبقة المخفية فيها، والتأخير الزمني.

تأثير عدد المدخلات:

لوحظ أنه بزيادة عدد المدخلات تزداد دقة النتائج مما يشير إلى أن عكارة المياه المرشحة تتعلق ببارامترات عديدة للمياه الخام حيث وجد أنه بإضافة pH المياه الخام (النموذج M₂) إلى بيانات عكارة، وناقلية المياه الخام (النموذج M₁) انخفضت قيمة MSE الكلية للشبكة الأمثل لهذين النموذجين من 1.45×10^{-3} إلى 0.86×10^{-3} ، وبمعنى أن النموذج M₂ الذي يحتوي ثلاثة مدخلات كانت نتائجه أفضل من النموذج M₁ الذي يحتوي مدخلين فقط. كما أدت إضافة بيانات pH المياه الخام (النموذج M₅) إلى بيانات عكارة، وناقلية المياه الخام، والهطول المطري (النموذج M₄) إلى انخفاض قيمة MSE الكلية للشبكة الأمثل للنموذجين من 1.51×10^{-3} إلى 1.06×10^{-3} ، وهذا يعني أن النموذج M₅ الذي يحتوي أربعة مدخلات حقق نتائجاً أفضل من النموذجين M₃، وM₄ اللذان يحويان مدخلين، وثلاثة مدخلات على الترتيب.

ورغم زيادة عدد المدخلات بإضافة قيم الهطول المطري إلى النموذجين M₁، وM₂ لتشكيل النموذجين M₄، وM₅ على الترتيب، إلا أن دقتهم بقيت أكبر من دقة النموذجين الأخيرين، ويعزى ذلك تأثير نوع المدخل الإضافي (الهطول المطري)، والذي لم تؤد إضافته إلى زيادة دقة نتائج النماذج.

تأثير التأخير الزمني:

أعطت زيادة قيمة التأخير الزمني في جميع النماذج نتائج أفضل من حيث قيمتي MSE، ومعامل الارتباط حيث كان التأخير الزمني الأفضل للشبكات المتلى فيها ضمن المجال (7-6 days) أي أن مواصفات المياه الخام في المحطة تؤثر على قيمة عكارة المياه المرشحة من المرشحات بعد أسبوع.

تأثير عدد عصبونات الطبقة المخفية، ونسبة تقسيم البيانات:

أعطت الشبكات التي عدد عصبونات الطبقة المخفية فيها ضمن المجال (21-27) نتائج أفضل في جميع النماذج المدروسة. ولوحظ أنه مع تناقص عدد بيانات التدريب تتخفف قيمة معامل الارتباط بين النتائج المتوقعة، والنتائج الحقيقية، وهذا يشير إلى أنه زيادة عدد بيانات التدريب فإن أداء الشبكة العصبونية الصناعية يتحسن.

تأثير البارامترات المدروسة على أداء شبكات NARX المدروسة:

يعزى استخدام بيانات عكارة المياه الخام في جميع النماذج إلى وجود علاقة أساسية بين عكارة المياه الخام الداخلة إلى المرشحات، والمياه المرشحة منها، ويتضح هذا من قيمة الارتباط الخطي بينهما، والتي بلغت 83.1%. وأعطت جميع النماذج الحاوية على بارامتر ناقلية المياه الخام في مدخلاتها (M_1, M_2, M_4, M_5) نتائج أفضل من النموذج M_3 الذي لا يحتوي على بارامتر ناقلية المياه الخام في مدخلاته.

كما أن النموذجين الحاويين على بارامتر pH المياه الخام في مدخلتهما (M_2, M_5) أعطيا نتائج أفضل من النماذج (M_1, M_3, M_4) التي لا تحتوي على بارامتر pH المياه الخام في مدخلاتها.


رغم أن للهطول المطري تأثيراً فيزيائياً على عكارة مياه بحيرة السن حيث تزداد عكارة المياه في البحيرة في اليوم الذي يلي الهطول المطري الكبير، إلا أن إضافة قيم الهطول المطري لم يحسن من دقة نماذج الشبكات العصبونية المبنية، ويعزى ذلك إلى أن تأثير الهطول المطري على عكارة مياه البحيرة هو تأثير لاحق ولا تؤثر القيم الحالية للهطول على قيم عكارة المياه الحالية وإنما اللاحقة، كما أن تأثير الهطول يكون مضمناً بقيم عكارة مياه البحيرة الخام التي اعتمدت مدخلاً أساسياً لكافة النماذج.

حيث قد أعطى النموذج M_3 الذي احتوى في مدخلاته إضافة إلى بارامتر عكارة المياه الخام على قيم الهطول المطري فقط القيم الأقل دقة بين النماذج الخمس، وأدت إضافة قيم الهطول المطري إلى النموذج M_1 لتشكيل النموذج M_4 لزيادة قيمة MSE في الشبكة المتلى من 1.45×10^{-3} إلى 1.51×10^{-3} ، كما أدت إضافة قيم الهطول المطري إلى النموذج M_2 لتشكيل النموذج M_5 لزيادة قيمة MSE في الشبكة المتلى من 0.86×10^{-3} إلى 1.06×10^{-3} .

محاكاة نموذج الشبكة العصبونية الصناعية المقترح:

يعتبر فحص أداء أي نموذج رياضي مقترح من الخطوات المعتادة المتبعة في عملية النمذجة الرياضية، ويقم حسن الأداء باستخدام الأساليب الإحصائية المعروفة كحساب قيمة معامل الارتباط (R)، وغيرها لكن يمكن الاستفادة بهذا الخصوص من المزايا التي توفرها التقنيات الحديثة من خلال بناء نموذج المحاكاة بالاستفادة من تقانة Simulink التي توفرها حزم برمجيات Matlab.

حيث اختصر نموذج المقارنة بوضع الشبكة العصبونية الصناعية على شكل قالب جاهز بسيط Block يحتوي على جميع مفردات الشبكة المقترحة في حزمة قوالب ثانوية يمكن إظهارها بسهولة، ويبين الشكل (10) كيفية تركيب، وبناء نموذج المحاكاة باستخدام تقانة Simulink.

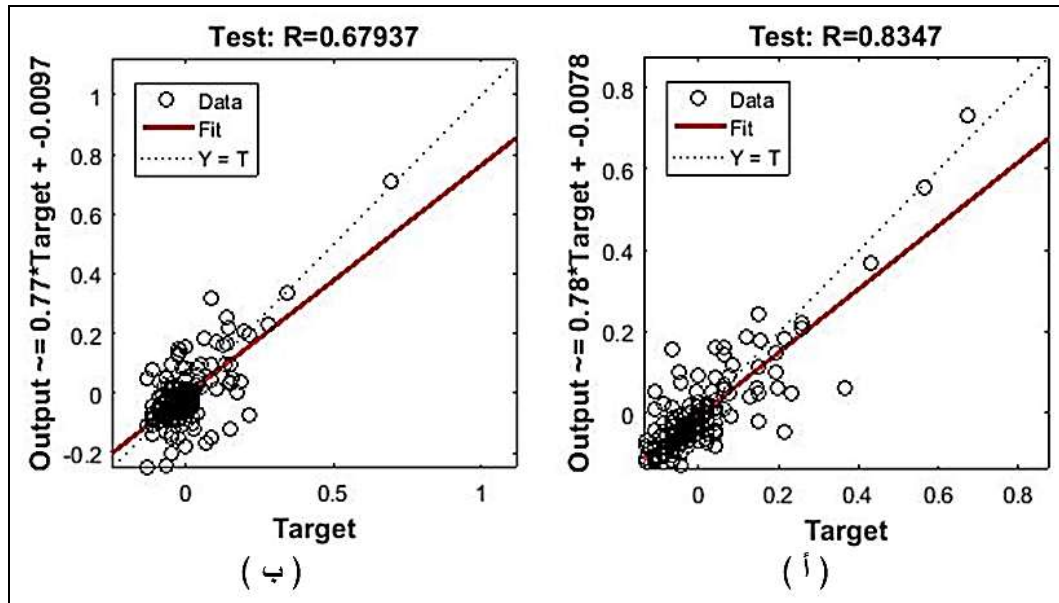


الشكل (10): قالب الشبكة العصبونية الصناعية NARX المقترحة

تقييم أداء الشبكة ونتائج الاختبار:

بهدف التحقق من أداء الشبكة، وقابليتها للاستجابة بشكل جيد للبيانات التي لم تتدرب عليها تم اختبار نموذجي شبكة NARX للذاتان حققا النتائج الأفضل باستخدام مجموعة بيانات الاختبار التي تشكل نسبة 15% من البيانات الكلية المستخدمة في الدراسة (176 قيمة من أصل 1171 قيمة)، وبمقارنة مخرجات الشبكتين مع القيم الحقيقية نلاحظ أن معامل الارتباط الخطي بين القيم المتوقعة، والقيم الحقيقية بلغ 83.47% للنموذج M_2 ، و 67.93% للنموذج M_5 كما يظهر في الشكل (11)، وقد بلغ متوسط مربع الخطأ لمجموعة الاختبار 4.08×10^{-3} للنموذج M_2 ، و 6.84×10^{-3} للنموذج M_5 .

تشير هذه النتائج إلى أن النموذج M_2 الذي لا يحتوي في مدخلاته على بيانات الهطول المطري أعطى أفضل النتائج في بناء الشبكة، وفي اختبارها.



الشكل (11): نتائج اختبار الشبكة المثلى في حالتها:

أ- المدخلات هي بارامترات مقاسة في محطة التنقية فقط ب- إضافة بارامتر الهطول المطري إلى مدخلات النماذج

الاستنتاجات والتوصيات:

- أظهرت النتائج وجود علاقة غير خطية بين بارامترات جودة مياه الشرب وعكارة المياه المرشحة، ويمكن التحقق من ذلك باستخدام الأساليب غير الخطية للنمذجة مثل شبكات NARX.
- وفقاً لنتائج النموذج، فإن بارامترات المياه الخام الداخلة إلى المرشحات العاملة في محطة التنقية تؤثر بشكل كبير على قيمة عكارة المياه الخارجة من المرشحات بعد (6-7) أيام.
- رغم وجود تأثير فيزيائي للهطول المطري فوق حوض التغذية على قيم عكارة مياه البحيرة، إلا أن إضافة قيمه لم تزد من دقة نموذج شبكة NARX المبني لتحليل السلسلة الزمنية لعكارة المياه المرشحة، لذلك يمكن الحصول على نموذج دقيق لتحليل السلسلة الزمنية لعكارة مياه الشرب في السن بدون استخدام قيم الهطول المطري فوق حوض التغذية في مدخلات النموذج.
- يعطي النموذج المستخدم نتائج جيدة في نمذجة، ومحاكاة السلوك غير الخطي للعكارة، والتنبؤ بقيمها، حيث يدل التوافق الخطي بين مخرجات شبكة NARX المقترحة، وقيم عكارة المياه المرشحة الحقيقية على إمكانية استخدام هذه الشبكات في التنبؤ بقيم عكارة المياه المرشحة في الأيام التالية.
- أظهرت قيم عكارة المياه المرشحة الناتجة من الشبكة المثلى المبنية انخفاضاً لفعالية أداء المرشحات بشكل مماثل للنتائج التي أظهرتها البيانات الحقيقية لعكارة المياه المرشحة، ويعزى ذلك لكون المرشحات تعمل بسرعة عالية وبدون استخدام المخثرات.
- واعتماداً على نتائج البحث يمكن، وضع التوصيات التالية:
- دراسة تأثير المتغيرات الأخرى المقاسة في محطة التنقية على عكارة المياه المرشحة، وإجراء تحاليل الحساسية لاختبار المدخلات الأكثر تأثيراً على نتائج الشبكة العصبونية.
- تجريب نماذج أخرى للشبكات العصبونية الديناميكية لتحليل السلسلة الزمنية للعكارة.
- استخدام أسلوب الشبكات العصبونية في التقييم المستمر لأداء محطة تنقية مياه الشرب في السن فقد أثبتت قدرتها في تحليل السلسلة الزمنية لعكارة المياه المرشحة والتنبؤ بقيمها، مما يساعد في تحقيق استقرار عمل المحطة، وفي تزويد محافظة اللاذقية بمياه الشرب.

المراجع:

- [1]. YANG, T-M; FAN, S-K; FAN, S-K. *Establishment of Turbidity Forecasting Model and Early-Warning System for Source Water Turbidity Management Using Back-Propagation Artificial Neural Network Algorithm and Probability Analysis*. Springer Environmental Monitoring and Assessment, Switzerland, Vol. 186, 2014, 4925-4934.
- [2]. World Health Organization. *Guidelines for Drinking-Water Quality*. Vol. 1, Recommendations, 3rd Ed., 2006, 515.
- [3]. MUÑIZ, C. D; NIETO, P. J. G; FERNÁNDEZ, J. R. A; NIETO, P. J. G; FERNÁNDEZ, J. R. A. *Detection of outliers in water quality monitoring samples using functional data analysis in San Esteban estuary (Northern Spain)*. Science of the Total Environment, Vol. 435, 2012, 54-61.

- [4]. OGWUELEKA, T. C; OGWUELEKA, F. N. *Optimization Of Drinking Water Treatment Processes Using Artificial Neural Network*. Nigerian Journal of Technology, Nigeria, Vol. 28, No. 1, 2009, 16-25.
- [5]. GRIFFITHS, K. A; ANDREWS, R. C. *Application of Artificial Neural Networks for Filtration Optimization*. Journal of Environmental Engineering, Vol. 137, 2011, 1040-1047.
- [6]. World Health Organization. *Guidelines for Drinking-Water Quality*. 4th Ed., 2011, 541.
- [7]. هيئة المواصفات والمقاييس العربية السورية. *المواصفات القياسية السورية رقم 45/ لمياه الشرب*. المراجعة الثانية، وزارة الصناعة، 2007.
- [8]. BAXTER C. W; STANLEY S. J; ZHANG Q; SMITH D. W. *Developing Artificial Neural Network Models Of Water Treatment Processes: A Guide For Drinking Water Utilities*. J. Environ. Eng. Sci., Vol. 1, 2002, 201-211.
- [9]. KRITI, S; SMITA, J. *Artificial Neural Network Modelling Of Shyamala Water Works, Bhopal Mp, India: A Green Approach towards the Optimization of Water Treatment Process*. Research Journal of Recent Sciences, Vol. 2, 2013, 26-28.
- [10]. BAXTER C. W; ZHANG Q.; STANLEY S. J.; SHARIFF R; TUPAS R. R. T; STARK H. L. *Drinking Water Quality And Treatment, The Use Of Artificial Neural Networks*. Can. J. Civil Engg, Vol. 28, No. 1, 2001, 26–35.
- [11]. RAK, A. *Water Turbidity Modelling During Water Treatment Processes Using Artificial Neural Networks*. International Journal of Water Sciences, Vol. 2, No. 3, 2013, 1-10.
- [12]. ALSAQQAR, A. *Filtration Modeling Using Artificial Neural Network (Ann)*. Journal of Engineering, Vol. 17, No. 1, 2011, 1-11.
- [13]. TASHAOUIE, H. R; GHOLIKANDI, G. B; GHOLIKANDI, G. B. *Artificial Neural Network Modeling For Predict Performance Of Pressure Filters In A Water Treatment Plant*. Desalination and Water Treatment, Vol. 39, No. 1, 2012, 192-198.
- [14]. الحطاب، رنيم سلمان. *إدارة إمداد المنطقة الساحلية بمياه الشرب من نبع السن باستخدام البرمجة الخطية*. رسالة علمية أعدت لنيل درجة الماجستير في الهندسة المدنية - اختصاص الهندسة البيئية، جامعة تشرين، كلية الهندسة المدنية، سورية، 2013، 140.
- [15]. SOLAIMANY-AMINABAD, M; MALEKI, A; MALEKI, A. *Application of Artificial Neural Network (Ann) For the Prediction of Water Treatment Plant Influent Characteristics*. Journal of Advances in Environmental Health Research, Vol. 1, No. 2, 2013, 89-100.
- [16]. BEALE, M. H; HAGAN M. T; DEMUTH H. B. *Neural Network Toolbox 7 User's Guide*. Version 7, Math works Inc, 2010, 951.