

نمذجة عكارة مياه شرب محطة السن باستخدام شبكات عصبونية ديناميكية

عزيز عادل عسيكريه*

(تاريخ الإيداع 22 / 1 / 2018. قُبِلَ للنشر في 10 / 7 / 2018)

□ ملخص □

إن نمذجة العلاقة بين عكارة مياه الشرب في محطة تنقية مياه الشرب في السن، وبقية بارامترات جودة المياه باستخدام أسلوب الشبكات العصبونية الصناعية الديناميكية يساعد على تحقيق الاستقرار في أداء محطة تنقية مياه الشرب، حيث توفر هذه الشبكات أداة فعالة للتعامل مع الطبيعة المعقدة، والديناميكية، وغير الخطية لعمليات التنقية، ولديها القدرة على الاستجابة للتغيرات الآنية المختلفة للبارامترات المؤثرة في تنقية المياه. صمم في هذا البحث أربعة نماذج للشبكات العصبونية الديناميكية ذات التغذية الأمامية والانتشار العكسي للخطأ للتنبؤ بعكارة المياه المرشحة الخارجة من محطة تنقية مياه الشرب في السن، بالاعتماد على بارامترات عكارة وناقلية و pH المياه الخام الداخلة إلى المحطة، بينما استخدمت بيانات عكارة المياه الخارجة من المحطة للتحقق من دقة أداء الشبكة العصبونية الصناعية، حيث أثبتت نتائج الدراسة قدرة الشبكات العصبونية الصناعية الديناميكية في نمذجة ومحاكاة السلوك غير الخطي للعكارة والتنبؤ بقيمتها، وهو ما يدعم استخدامها في محطة تنقية مياه الشرب في السن للمساهمة في تحقيق الاستقرار في عمل المحطة.

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

* قائم بالأعمال /معاون في قسم الهندسة البيئية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Modelling the drinking Water Turbidity of Al-Sin Purification Plant using Dynamic Neural Networks

Aziz Adel Osekrieh *

(Received 22 / 1 / 2018. Accepted 10 / 7 / 2018)

□ ABSTRACT □

Modelling the relationship between drinking water turbidity and other indicators of water quality in Al-Sin drinking water purification plant using Dynamic Artificial neural networks could help in the implementation of the stabilization for the performance of the plant because these neural networks 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, four models of feed-forward back-propagation dynamic neural network were designed to predict the effluent turbidity from Al-Sin drinking water purification plant. The models were built based on turbidity, pH and conductivity of raw water data while the effluent turbidity data were used for verify the performance accuracy of each network. The results of this research confirm the ability of dynamic neural networks in modeling and simulating the non-linearity behavior of water turbidity as well as to predict its values. They can be used in Al-Sin drinking water purification plant in order to achieve the stabilization of its performance.

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

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

مقدمة:

تعتبر العكارة فيزيائياً مقدار انخفاض نقاوة المياه بسبب وجود جزيئات معلقة أو غروية [1]، وتقاس بوحدة Nephelometric Turbidity Units (NTU)، وتعد مؤشراً استدلالياً عن الحالة العامة للمياه، فالقيم العالية منها تشير إلى القيم العالية لبارامترات أخرى متعلقة بجودة المياه كالطلب الكيميائي للأوكسجين المنحل، أو تركيز النترات وغيرها، وعندما تكون قيمتها مساوية للصفر فهذا يعني أن المياه نقية ولذلك يمكن اعتبار العكارة اختباراً أساسياً لتقييم جودة المياه [2]، ووفقاً للمواصفات القياسية السورية لمياه الشرب فإن الحد المسموح به لعكارة مياه الشرب هو 1 NTU أما الحد الأقصى فهو 5 NTU [3].

تهدف محطات معالجة مياه الشرب إلى إنتاج مياه شرب خالية من الطعم واللون والرائحة، وأمنة للاستهلاك من الناحية الجرثومية، وذلك بأقل كلفة وأقل تأثير على البيئة [4].


تعد محطة تنقية مياه الشرب في السن المصدر الرئيسي للمياه في الساحل السوري، وتقع أمامها تحديات كبيرة لإنتاج مياه الشرب بالجودة المطلوبة، والكلفة الأقل، حيث أن ازدياد الطلب على المياه وقدم تجهيزات المحطة وازدياد التلوث في حوض السن يستلزم إجراء تحاليل دورية لمراقبة جودة المياه، والحفاظ على استقرار أداء المحطة، مما يزيد في كلف استثمار هذه المحطة بسبب الكلفة العالية للمراقبة، والتحليلات الكيميائية اللازم إجراؤها [5].

تقع محطة تنقية مياه الشرب في السن على بحيرة السن في أقصى جنوب محافظة اللاذقية، وتتألف من محطتين قديمة، وجديدة تعملان على التوازي، ويتم التنقية فيهما باستخدام المرشحات الرملية السريعة بدون استخدام المخثرات. تتم في المحطة مراقبة أداء عملية الترشيح من حيث مستويات العكارة لضمان مياه شرب آمنة [5]. يبين الشكل (1) مخططاً عاماً لمراحل التنقية في المحطة.

تضم المحطة القديمة 24 حوض ترشيح يمرر كل منها $8100 \text{ m}^3/\text{day}$ ، أبعاد الحوض $11 \times 4 \text{ m}$ ويتألف من طبقة رمل كوارتزي بارتفاع 120 cm ثم طبقة بلاطات بيتونية تحتوي الفلاتر بينما تضم المحطة الجديدة 12 حوضاً يمرر كل منها $10080 \text{ m}^3/\text{day}$ ، أبعاد الحوض $12 \times 4 \text{ m}$ ويتألف من طبقة فحم انتراسيت عليا بارتفاع 40 cm، وطبقة رمل كوارتزي سفلى بارتفاع 60 cm. ترفع المياه إلى خزانات في قفص ترتفع عن سطح البحر 90 m، لتجر المياه بعد ذلك نحو مدينة اللاذقية عبر أربعة خطوط جر، ومن ثم توزع عبر شبكة المدينة.

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، 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 [6].

يزداد استخدام تقنيات الذكاء الصناعي لاسيما الشبكات العصبونية الصناعية (ANNs) Artificial Neural Networks في محطات معالجة مياه الشرب لكونها تسمح بتطوير نماذج غير خطية موثوقة لعمليات المعالجة المعقدة، فهي تتعلم الارتباطات بين المدخلات، والمخرجات من خلال البيانات التاريخية دون الحاجة إلى تحديد شكل النموذج، وقد قللت الزيادة في سرعة المعالجة الحاسوبية من الزمن اللازم لتدريب وتقييم هذه النماذج [7]، لذلك انتشر استخدام الشبكات العصبونية الصناعية في مجالات عديدة تتعلق بأمثلة عمل محطات معالجة المياه [4, 10]، ونمذجة بارامترات الجودة فيها [8,9]، وغيرها.



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

ففي محطة معالجة لمياه الشرب نيجيريا، استخدم باحثون بنجاح أسلوب الشبكات العصبونية الصناعية لتصميم نموذج قادرٍ على التنبؤ بقيمة عكارة المياه الخارجة من حوض الترسيب، وقد ساعد النموذج في تحقيق انخفاضٍ في كلفة استثمار المحطة، واستقرارٍ عالٍ في أدائها [4].

ونجح باحثون بنمذجة أداء أغشية الترشيح الدقيق في محطة معالجة تجريبية رائدة في بولندا تتم فيها المعالجة بالتخثير والترشيح من خلال تصميم عدد من نماذج الشبكات العصبونية للتنبؤ بمعامل احتجاز عكارة المياه ضمن تلك الأغشية بالاعتماد على إشارات دخل شملت مجموعة من بارامترات المياه والمرشح، وبلغ الارتباط بين الخرج المتوقع من خلال النماذج والخرج الحقيقي 82%، ولم تتجاوز قيمة الخطأ المتوسط التربيع 2.16×10^{-2} وهو ما أثبت قدرة الشبكات العصبونية على التنبؤ بشكل دقيق جداً بسلوك النظام الحقيقي [8].

واستخدم باحثون نموذجاً من الشبكات العصبونية الديناميكية لتحليل السلاسل الزمنية والتنبؤ بمجموعة من بارامترات جودة المياه الداخلة إلى محطة سانداج لمعالجة مياه الشرب في إيران بالاعتماد على بيانات جمعت على مدى عامين. وبلغت قيمة معامل الارتباط لنموذج العكارة بين الخرج المتوقع من خلال النماذج، والخرج الحقيقي 84%، مؤكداً قدرة هذه الشبكات على فهم ومحاكاة السلوك غير الخطي لبارامترات جودة المياه [9].

كما صمم باحثون نموذجاً للتنبؤ بجرعة المخثر اللازمة لمياه خام ذات عكارة مختلفة والتي حُدثت مخبرياً ضمن محطة معالجة تجريبية في العراق. بلغ عدد البيانات المستخدمة لتصميم النموذج 200. وصلت قيمة الارتباط بين جرعة المخثر اللازمة الحقيقية وجرعة المخثر المتوقعة باستخدام النموذج حتى 96% وهو ما يثبت إمكانية الشبكات العصبونية في النمذجة حتى بوجود عدد قليل من البيانات التجريبية [10].

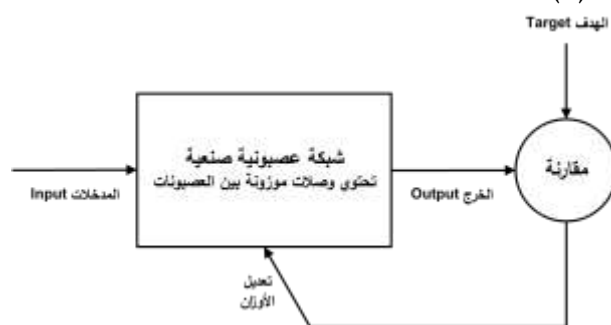
أهمية البحث، وأهدافه:

يهدف البحث إلى تصميم نموذج تنبؤي موثوق لعكارة مياه الشرب المرشحة بالاعتماد على القياسات الدورية اليومية للمياه الخام الداخلة إلى محطة التنقية، حيث تكمن أهمية تصميم هذا النموذج ليساعد بالتقييم المسبق لأداء المحطة مما يقلل تكاليف استثمار المحطة ويساهم في استقرار أدائها. قدم في هذا البحث مقارنة استخدام نموذجين من نماذج الشبكات العصبونية الديناميكية لنمذجة عكارة مياه الشرب في محطة تنقية مياه الشرب في السن.

طرائق البحث ومواده:


1. الشبكات العصبونية الصناعية الديناميكية:

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 عدة طبقات هي طبقة الدخل Input Layer، وطبقة الخرج Output Layer، والطبقات المخفية Hidden Layer بينهما. يتم انتشار البيانات الداخلة إلى الشبكات العصبونية الصناعية ذات التغذية الأمامية Feed Forward ANNs باتجاه الأمام دائماً من طبقة الدخل إلى طبقة الخرج، ويتم تدريب الشبكة من خلال خوارزميات تدريب متخصصة Training Algorithms، من أشهرها خوارزمية الانتشار العكسي للخطأ Back Propagation Algorithm (BP) حيث تدرّب الشبكة على سلسلة من أزواج (المدخلات-المخرجات الهدف المرتبطة بها)، ثم يتم حساب الخطأ بين الخرج المحسوب، والخرج الهدف، ثم يمرر الخطأ خلفاً من طبقة الخرج إلى طبقة الدخل ليتم استخدامه في تعديل الأوزان للحصول على أقل خطأ ممكن. يوضح الشكل (2) آلية تدريب الشبكة العصبونية.



الشكل (2): آلية تدريب الشبكات العصبونية

يوضح الشكل (3) آلية عمل العصبون، حيث يمثل كل عصبون في الشبكة عنصر معالجة Process Element، وتتم 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

تقسم البيانات المتاحة أثناء تدريب الشبكة إلى ثلاثة مجموعات للتدريب 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 هذه الخطأ بالازدياد لعدد محدد من الدورات التكرارية، أما خطأ مجموعة الاختبار فيستخدم للمقارنة بين النماذج المختلفة [11].

تصنف الشبكات العصبونية عموماً إلى ستاتيكية، وأخرى ديناميكية، ويمكن الفرق الأساسي بينهما أن الأولى لا تملك عناصر تغذية راجعة ولا تأخيرات زمنية لذلك يحسب خرج الشبكة مباشرة من المدخلات التي تمر عبر وصلات تغذية أمامية، أما خرج الشبكة الديناميكية فيعتمد على كل من مدخلات الشبكة الحالية، والمدخلات السابقة، وكذلك المخرجات [11].

استخدم البحث نوعين من الشبكات العصبونية الصناعية الديناميكية للتنبؤ بعكارة المياه المرشحة الخارجة من محطة تنقية مياه الشرب في السن هما شبكات عصبونية ذات تأخر زمني مركز Focused Time-Delay Neural network (FTDNN) الشكل (4-أ)، و شبكات الانحدار الذاتي غير الخطي مع مدخلات خارجية The Nonlinear Autoregressive Network with Exogenous Inputs (NARX) الشكل (4-ب).

شبكة FTDNN هي شبكة ذات تغذية أمامية مع خطوط تأخر زمنية للمدخلات فقط. تعرّف رياضياً كالتالي:

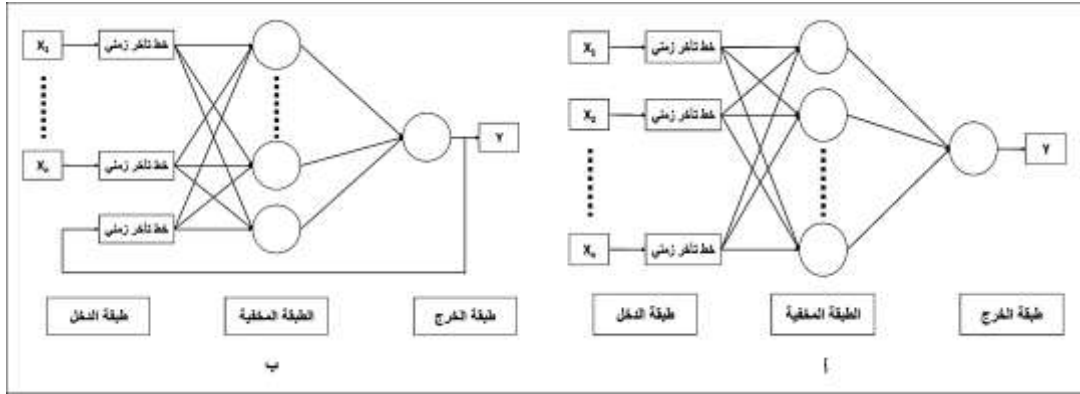
$$Y(t) = f[x(t-1), x(t-2), \dots, x(t-d)] \quad (1)$$

حيث تعتمد القيمة التالية لإشارة الخرج التابعة $Y(t)$ على القيم السابقة لإشارة الدخل فقط [11].

أما شبكة NARX فهي 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 [11].

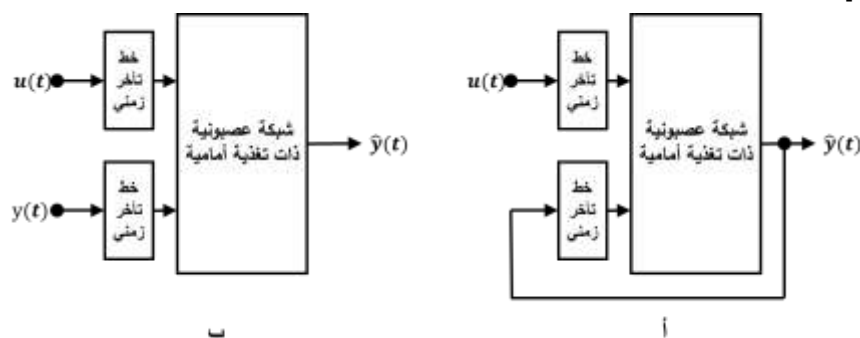


الشكل (4): بنية الشبكات العصبونية الديناميكية المستخدمة: أ- نوع FTDNN؛ ب- نوع NARX

تعد شبكات FTDNN مناسبة للتنبؤ بالسلاسل الزمنية، وتستخدم شبكات NARX في تطبيقات عديدة للتنبؤ بالقيمة التالية لإشارة الدخل، أو الفلترة غير الخطية لإنتاج خرج خالٍ من البيانات غير المرغوبة في إشارة الدخل كذلك في نمذجة الأنظمة غير الخطية الديناميكية [11].

هناك معماريتين أساسيتين لشبكات NARX موضحتين في الشكل (5)، في المعمارية المتوازية Parallel Architecture الشكل (5-أ) تتم تغذية قيم خرج الشبكة المقدّر خلفاً لاستخدامه في تدريب الشبكة وهو ما يمكن الشبكة من إنجاز التنبؤ بالسلسلة الزمنية لعدة خطوات، بينما تستخدم القيم الحقيقية للخرج في معمارية السلاسل المتوازية Series-Parallel Architecture الشكل (5-ب)، وبالتالي لا تنجز الشبكة سوى تنبؤ بخطوة واحدة

للسلسلة الزمنية إلا أن مدخلاتها تكون أكثر دقة، كما أنها تسمح باستخدام خوارزمية الانتشار العكسي الستاتيكية في عملية تدريبها [11].



الشكل (5): معماريتي الشبكات من نوع NARX: أ- معمارية متوازية؛ ب- معمارية سلاسل متوازية

3. 2. مجموعة البيانات:

تم الحصول على البيانات الخام من المؤسسة العامة لمياه الشرب في اللاذقية، وذلك على مدى أكثر من ثلاثة أعوام (2013-2016)، وتعد هذه الفترة كافية لتغطية كل التغيرات الفصلية المحتملة في البارامترات المستخدمة في البحث، حيث تقاس في محطة التنقية بشكل دوري يومي عكارة، وناقلية، و pH المياه الخام، وعكارة المياه المرشحة، وبلغ عدد البيانات الإجمالي المستخدمة لتدريب الشبكة واختبارها 1171، علماً أن القيم المفقودة في البيانات استُقرت باستخدام الطريقة الخطية Linear Interpolation.

تغسل المرشحات عندما تزداد ضياعات الضغط في الحشوة عن مترين، أو عندما تسوء نوعية المياه المرشحة ولا تتجاوز دورة الترشيح عادةً أسبوعاً واحداً لذا درست قيم التأخير الزمني ضمن مجال (1-7) يوم.

بدراسة الارتباط الخطي بين عكارة المياه المرشحة، وبقية البارامترات لم يلاحظ وجود علاقة خطية بينها كما يتضح من الجدول (1)، لكن يمكن تكون العلاقة غير خطية، ولذلك لتحديد المدخلات الأفضل للشبكات العصبونية الديناميكية المعتمدة صممت مجموعة من النماذج الخاصة لنوعي الشبكات العصبونية الديناميكية المستخدمة وفق ما هو مبين في الجدول (2)، وذلك لتحديد بارامترات الشبكة العصبونية التي تعطي الأداء الأفضل من حيث نوع الشبكة، والمدخلات، وعدد عصبونات الطبقة المخفية، والتأخر الزمني، ونسبة التقسيم الأفضل للبيانات المتاحة.

لا تستخدم عادةً البيانات الخام مباشرة في الشبكة العصبونية الصناعية رغم إمكانية ذلك فمن الممكن أن يتسبب ذلك بزيادة ملحوظة في زمن تدريب الشبكة بسبب اختلاف مجالات المتغيرات [9]، لذلك قيست بيانات الدخل، والخرج ضمن المجال [0-1] وفقاً للمعادلة التالية، وذلك لأن المكتبة المستخدمة تعتمد على تابع التحويل السيغمودي 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.

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

عكارة المياه المرشحة	عكارة المياه الخام	ناقلية المياه الخام	pH المياه الخام
83.1 %	- 6.1 %	- 2.8 %	

الجدول (2): نماذج الشبكات العصبونية المصممة

رقم النموذج	نوع الشبكة	المدخلات	المخرجات
MF ₁	FTDNN	عكارة المياه الخام، وناقلية المياه الخام.	عكارة مياه الشرب
MF ₂		عكارة المياه الخام، وناقلية المياه الخام، و pH المياه الخام.	
MN ₁	NARX	عكارة المياه الخام، وناقلية المياه الخام.	المرشحة
MN ₂		عكارة المياه الخام، وناقلية المياه الخام، و pH المياه الخام.	

ولمحاكاة أداء النموذج، والتحقق استُخدم كل من متوسط مربع الخطأ (MSE) Mean Squared Error، ومعامل الارتباط (R) Correlation Coefficient 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 المتبقي.

F_0 : التباين الأول لقيم قيم عكارة المياه المرشحة.

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 عكارة المياه المرشحة المراقبة، والمحسوبة عند الفاصل الزمني k^{th} على التوالي.

\bar{Q}_k : هو متوسط قيم عكارة المياه المرشحة على امتداد الزمن.

النتائج والمناقشة:

يوضح الجدول (3) بارامترات الشبكات العصبونية المستخدمة في إنشاء النماذج وتدريبها، لشبكتي FTDNN، وNARX، حيث حدّد النموذج الأفضل من النماذج الأربع المدروسة (MF₁, MF₂, MN₁, MN₂) والبارامترات المثلى له اعتماداً على تابع الخطأ MSE، وقد تم العمل وفق ثلاثة مراحل.

في المرحلة الأولى صمّمت مجموعة من الشبكات لكل نموذج، ولكل منها عدد مختلف عصبونات الطبقة المخفية (5-10-15-20-25-30-35-40)، وتأخيرات زمنية مختلفة (1, 4, 7)، ومن ثم تحديد المجال الذي يحقق الأداء الأفضل لكل نموذج، وهو المجال ذو القيم الأدنى لتابع الخطأ MSE، كما يتضح في الشكل (6).

في المرحلة الثانية صممت عدد من الشبكات لكل نموذج لكل منها عدد متزايد من عصبونات الطبقة المخفية ضمن المجال الأمثل المحدد في المرحلة الأولى، ومن أجل تأخيرات زمنية متتالية (1, 2, 3, 4, 5, 6, 7)، حيث حدد عدد العصبونات، والتأخير الزمني اللذان يحققان الأداء الأفضل لكل نموذج، اعتماداً على الشبكة التي تعطي القيمة الأدنى لتابع الخطأ MSE، ويظهر الجدول (4) نتائج هذه المرحلة.

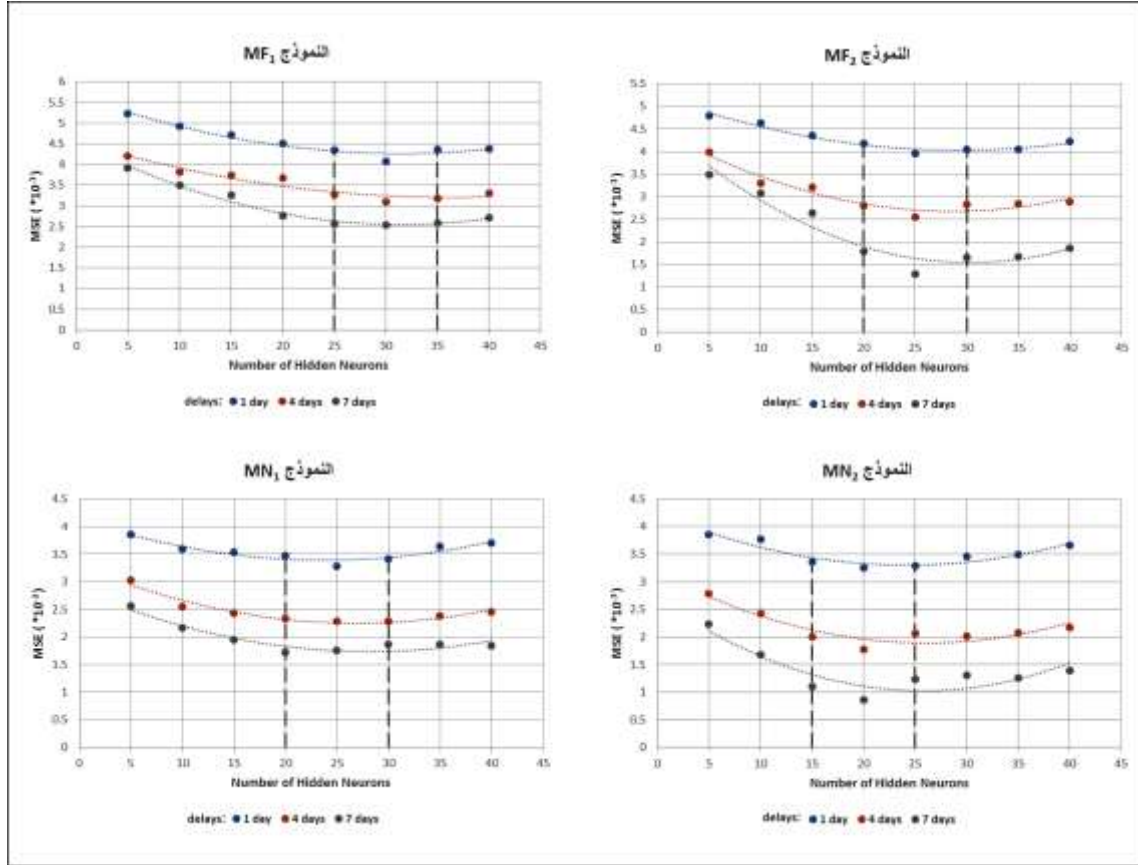
في المرحلة الثالثة جريت نسب تقسيم مختلفة للبيانات المستخدمة في تصميم النماذج والتي عددها 1171 إلى مجموعات تدريب، وتحقق واختبار وهي (15-15-70) و(20-20-60) و(25-25-50) % لتحديد نسبة التقسيم الأمثل لكل شبكة محدّدة في المرحلة السابقة، واختيرت النسبة التي تحقق أدنى قيمة لتابع الخطأ MSE، كما يظهر في الجدول (5).

الجدول (3): البارامترات المستخدمة في تصميم نماذج الشبكات العصبونية وتدريبها

نوع الشبكة	NARX	FTDNN
المعمارية	Series-Parallel Architecture	-
النماذج	MF ₁ , MF ₂	MN ₁ , MN ₁
الطبقات	طبقة مدخلات، وطبقة مخفية واحدة، وطبقة خرج واحدة	
خوارزمية التدريب	Levenberg-Marquardt	
تابع التدريب	traimLM	
تابع التحويل في الطبقة المخفية	تابع تحويل سيغمويد Sigmoid Transfer Function	
تابع التحويل في طبقة المخرجات	تابع التحويل الخطي Linear Transfer Function	
تابع قياس أداء الشبكة	الخطأ المتوسط التربيع MSE	
عدد عصبونات الطبقة المخفية	من 5 حتى 40	
التأخير الزمني	1-7 أيام	

1. مواصفات الشبكة العصبونية المثلى:

وجد في المرحلة الأولى أن المجال الأمثل لعدد عصبونات الطبقة المخفية التي تعطي القيم الأدنى لتابع الخطأ MSE لنموذجي شبكة FTDNN هي (25-35) للنموذج MF₁، و(20-30) للنموذج MF₂، ولنموذجي شبكة NARX هي (20-30) للنموذج MN₁، و(15-25) للنموذج MN₂، كما حددت في المرحلة الثانية عدد عصبونات الطبقة المخفية، والتأخير الزمني اللذان يحققان الأداء الأفضل لكل نموذج، وفي نهاية المرحلة الثالثة وجد أن نسبة تقسيم البيانات المثلى لكافة النماذج هي % (15-15-70)، ويبين الجدول (6) شبكتي FTDNN، وNARX اللتين حققتا الأداء الأفضل وبارامتراتها، كما يبين الشكل (7) مخططاً لهاتين الشبكتين، ويبين الشكل (8) الارتباط الكلي بين القيم المتوقعة لعكارة المياه المرشحة من خلال الشبكتين، والقيم الحقيقية لها.



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

الجدول (4): تحديد عدد عصبونات الطبقة المخفية والتأخير الزمني الأمثلين للنماذج في المرحلة الثانية لتدريب الشبكات العصبونية

delays	HN	MSE (*10 ⁻³)	R (%)	HN	MSE (*10 ⁻³)	R (%)	HN	MSE (*10 ⁻³)	R (%)	HN	MSE (*10 ⁻³)	R (%)
	شبكات نوع FTDNN						شبكات نوع NARX					
	النموذج MF ₁			النموذج MF ₁			النموذج MN ₁			النموذج MN ₂		
1	25	4.34	75.56	20	4.17	77.06	20	3.48	78.66	15	3.36	80.96
2		3.81	80.04		3.94	77.09		2.92	83.32		3.08	80.65
3		3.56	80.13		2.96	79.68		2.47	83.06		2.80	82.91
4		3.27	80.69		2.80	79.00		2.33	84.80		2.00	84.10
5		3.05	81.04		2.89	80.27		2.19	81.87		1.69	83.02
6		3.03	82.35		2.73	81.48		1.74	85.45		1.75	83.84
7		2.57	80.38		1.78	84.51		1.72	86.60		1.10	87.09
1	26	4.44	76.67	21	4.04	74.61	21	3.49	79.01	16	3.46	79.18
2		3.91	80.43		3.54	78.06		3.32	82.74		2.94	77.25
3		3.65	77.96		3.44	79.06		2.90	84.28		2.90	82.17
4		3.26	79.15		2.68	80.07		2.38	84.02		1.77	8.70
5		3.15	80.46		2.64	82.40		2.15	84.72		1.73	80.45
6		3.06	80.24		2.20	82.00		2.12	84.82		2.14	83.95

7		2.98	80.45		2.29	82.34		1.75	84.36		1.29	85.39
1	27	4.25	77.35	22	4.19	72.16	22	3.45	77.42	17	3.21	81.07
2		3.95	75.39		3.98	77.61		3.13	82.24		3.16	84.44
3		3.79	80.21		3.28	80.10		2.88	83.59		2.86	81.64
4		3.50	79.75		2.98	79.52		2.34	82.64		2.04	82.59
5		3.13	79.89		2.75	77.60		2.52	84.28		2.11	84.00
6		2.80	80.36		2.26	80.87		1.97	81.42		1.76	85.75
7		3.07	83.00		2.15	80.27		1.73	87.89		1.24	82.25
1	28	4.61	76.62	23	4.18	74.84	23	3.48	79.90	18	3.34	78.86
2		3.91	78.10		3.84	74.64		3.03	82.89		3.39	80.39
3		3.37	74.02		3.28	76.67		2.89	82.80		2.89	83.55
4		3.30	78.07		3.02	79.14		2.34	81.77		1.87	82.12
5		3.02	79.43		2.26	77.01		2.47	83.66		2.18	81.87
6		2.92	73.15		1.45	82.73		1.45	86.60		1.85	84.91
7		2.82	80.74		2.12	81.45		1.75	86.24		1.25	85.17
1	29	4.26	74.68	24	4.11	77.71	24	3.47	78.03	19	3.32	71.68
2		3.90	77.88		3.84	75.30		3.12	80.49		3.31	82.54
3		3.67	80.54		3.44	78.61		2.72	83.05		2.54	84.69
4		3.25	80.81		3.01	79.67		2.06	86.83		2.14	85.00
5		3.02	78.81		2.45	80.64		2.32	86.50		2.14	83.17
6		2.88	82.73		2.17	80.54		2.19	83.76		1.64	86.20
7		2.57	80.77		1.18	82.55		1.77	86.96		1.35	83.43
1	30	4.07	77.71	25	3.96	77.32	25	3.28	82.51	20	3.25	87.68
2		3.72	79.53		3.50	77.48		2.92	83.92		3.23	82.32
3		3.33	75.22		3.30	79.14		2.55	81.78		2.74	82.86
4		3.09	79.65		2.55	79.16		2.28	82.06		1.78	82.06
5		2.90	78.83		2.27	81.30		2.27	82.54		2.20	82.32
6		2.73	83.72		2.35	81.38		1.66	86.31		1.84	82.07
7		2.53	84.13		1.28	85.36		1.76	84.50		0.86	88.30
1	31	4.15	72.42	26	4.43	76.39	26	3.53	82.97	21	3.29	8.16
2		4.12	77.46		3.90	77.27		2.70	82.92		2.99	82.00
3		3.60	77.84		3.30	78.57		2.20	85.52		2.85	84.58
4		3.33	78.65		2.57	82.20		2.17	83.39		2.06	85.98
5		3.05	76.62		2.54	80.11		2.14	86.43		1.88	82.47
6		2.71	81.47		1.82	82.57		1.81	85.94		1.75	85.19
7		2.68	82.47		1.79	79.26		1.79	82.38		1.07	86.17
1	32	3.99	76.44	27	4.03	74.88	27	3.46	81.03	22	3.13	76.80
2		3.90	75.57		2.58	80.73		3.01	80.04		3.04	83.16
3		3.61	78.62		3.25	80.06		2.63	83.60		2.54	82.64


4		3.29	80.89		2.64	80.81		2.31	83.20		1.82	85.47
5		2.55	80.11		2.27	80.47		2.29	82.85		2.04	83.75
6		2.95	81.19		1.72	84.22		2.00	84.97		1.69	85.93
7		2.40	79.84		1.86	83.80		1.73	85.52		1.34	86.97
1	33	4.09	77.73	28	4.31	76.07	28	3.29	82.97	23	3.26	80.20
2		3.88	79.25		3.80	76.53		2.93	82.92		3.09	78.29
3		3.54	77.68		3.22	72.93		2.60	85.52		2.26	82.50
4		3.24	74.04		2.38	72.89		2.38	83.78		2.07	84.69
5		3.05	79.83		1.66	78.38		2.21	83.11		1.76	85.64
6		2.73	75.89		1.67	83.10		1.95	85.89		1.85	86.03
7		2.49	82.37		1.83	85.73		1.78	84.36		1.15	84.57
1	34	4.33	76.00	29	4.29	72.89	29	3.47	80.53	24	3.46	81.44
2		3.94	76.16		3.74	78.42		3.02	81.22		3.12	82.30
3		3.61	78.60		2.99	78.58		2.33	81.51		3.41	83.03
4		3.54	76.42		2.96	80.76		2.34	84.80		1.83	81.17
5		3.14	79.40		2.36	79.45		2.28	85.26		2.11	84.44
6		2.83	81.45		1.67	85.24		2.08	85.37		1.88	83.26
7		2.47	78.62		1.62	84.34		1.80	85.10		1.26	87.11
1	35	4.37	79.45	30	4.04	77.28	30	3.42	80.75	25	3.29	77.57
2		3.94	80.48		3.41	76.59		3.02	84.21		3.05	81.99
3		3.58	79.48		3.37	78.95		2.59	84.65		2.36	84.20
4		2.58	82.28		2.83	80.97		2.29	83.87		2.06	81.44
5		2.74	76.27		2.34	81.50		2.15	84.30		1.63	85.51
6		2.94	83.32		2.08	82.39		1.95	83.82		1.37	83.98
7		3.18	81.51		1.65	81.82		1.86	84.61		1.23	85.75

الجدول (5): تحديد نسبة تقسيم البيانات الأفضل للشبكات المثلى الناتجة في نهاية المرحلة الثانية

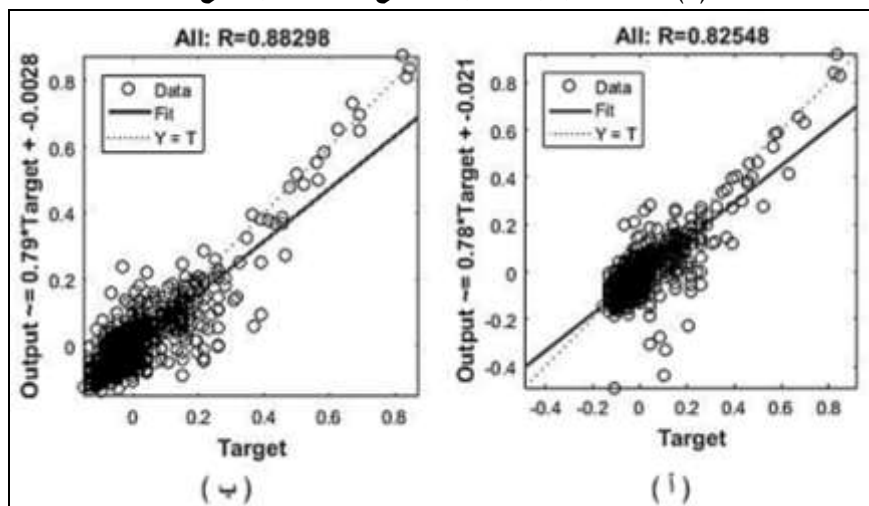
نسبة التقسيم	شبكات نوع FTDNN				شبكات نوع NARX			
	النموذج MF ₁		النموذج MF ₂		النموذج MN ₁		النموذج MN ₂	
	HN= 32; d=7		HN= 24; d=7		HN= 23; d=6		HN= 20; d=7	
	MSE (*10 ⁻³)	R (%)	MSE (*10 ⁻³)	R (%)	MSE (*10 ⁻³)	R (%)	MSE (*10 ⁻³)	R (%)
70-15-15	2.40	79.84	1.18	82.55	1.45	86.60	0.86	88.30
60-20-20	2.66	80.46	1.57	82.16	1.61	80.94	1.32	84.90
50-25-25	2.53	75.87	1.26	78.16	1.62	78.68	1.17	82.99

الجدول (6): شبكتي FTDNN و NARX اللتان حققنا أفضل أداء

الحالة والنموذج	مدخلات الشبكة ومخرجاتها	هيكلية الشبكة	تابع الخطأ ($*10^{-3}$) MSE			معامل الارتباط الكلي (%) R		
			مجموعة التدريب	مجموعة التحقق	مجموعة الاختبار	مجموعة التدريب	مجموعة التحقق	مجموعة الاختبار
FTDNN	المدخلات: عكارة، وناقلية، و pH المياه الخام الخرج: عكارة المياه المرشحة	3-24-1 التأخير: 7 نسب تقسيم البيانات: 70-15-15 %	2.90	10.32	8.95	90.40	53.00	70.82
NARX	المدخلات: عكارة، وناقلية، و pH المياه الخام الخرج: عكارة المياه المرشحة	3-20-1 التأخير: 7 نسب تقسيم البيانات: 70-15-15 %	2.12	5.89	4.08	91.86	77.85	83.47



الشكل (7): مخطط الشبكتين المثلتين: أ- نوع FTDNN؛ ب- نوع NARX



الشكل (8): الارتباط الكلي بين القيم المتوقعة، والقيم الحقيقية في الشبكتين المثلتين: أ- نوع FTDNN؛ ب- نوع NARX

4. 2. تأثير بنية الشبكات العصبونية على أدائها:

حدّدت شبكتي FTDNN، وNARX المثلتين اعتماداً على قيمة تابع الخطأ MSE، وعلى الارتباط بين قيم عكارة المياه المرشحة المتوقعة في الشبكة، وقيمها الحقيقية، حيث درست بارامترات الشبكة ضمن المجالات المحددة في الجدول (3) لتحديد القيم الأفضل لها من خلال تجريب عدد كبير من الشبكات العصبونية مختلفة النوع، والمدخلات، وعدد عصبونات الطبقة المخفية فيها، والتأخير الزمني، ونسبة تقسيم البيانات.

أعطت الشبكات العصبونية من النوع NARX أداءً أفضل من الشبكات العصبونية من نوع FTDNN في التنبؤ بعكارة المياه المرشحة في محطة تنقية مياه الشرب في السن، وذلك من أجل ذات المدخلات، حيث بلغت قيمة MSE في الشبكة المثلى للنموذج MN_1 $1.45 \cdot 10^{-3}$ مقابل $2.4 \cdot 10^{-3}$ في الشبكة المثلى للنموذج MF_1 ، وبلغت قيمتها في الشبكة المثلى للنموذج MN_2 $0.86 \cdot 10^{-3}$ مقابل $1.18 \cdot 10^{-3}$ في الشبكة المثلى للنموذج MF_2 .

لوحظ أنه بزيادة عدد المدخلات تزداد دقة النتائج مما يشير إلى أن عكارة المياه المرشحة تتعلق ببارامترات عديدة للمياه الخام حيث أدت إضافة بارامتر pH المياه الخام (النموذجين MF_2 ، و MN_2) إلى بيانات عكارة، وناقلية المياه الخام (النموذجين MF_1 ، و MN_2) لانخفاض قيمة MSE الكلية للشبكة الأمثل لهذين النموذجين من $2.4 \cdot 10^{-3}$ إلى $1.18 \cdot 10^{-3}$ في حالة شبكة FTDNN، ومن $1.45 \cdot 10^{-3}$ إلى $0.86 \cdot 10^{-3}$ في حالة شبكة NARX، كذلك فإن استخدام قيم عكارة المياه المرشحة في مدخلات شبكات NARX أعطى هذه النماذج قدرة أكبر على التنبؤ بقيم عكارة المياه المرشحة التالية مقارنة بشبكات FTDNN، وبالتالي فإن زيادة عدد المدخلات، أدى إلى زيادة دقة الشبكات العصبونية الديناميكية المصممة.

أعطت زيادة قيمة التأخير الزمني في النماذج الأربعة للنوعين المدروسين للشبكات FTDNN، وNARX نتائج أفضل من حيث قيمتي MSE، ومعامل الارتباط حيث كان التأخير الزمني الأفضل للشبكات المثلى فيها ضمن المجال (6 - 7 days)، وهذا يعني أن مواصفات المياه الخام الداخلة إلى المرشحات في المحطة تؤثر على قيمة عكارة المياه المرشحة من المرشحات بعد أسبوع.

أعطت الشبكات التي عدد عصبونات الطبقة المخفية فيها أكبر من 20 نتائج أفضل في جميع النماذج المدروسة، وبلغ العدد الأفضل لعصبونات الطبقة المخفية في شبكات NARX قيماً أقل من مثيلاتها في شبكات FTDNN، حيث بلغ القيمتين 23، و20 للنموذجين MN_1 ، و MN_2 على التوالي مقابل القيمتين 32، و24 للنموذجين MF_1 ، و MF_2 على التوالي.

ولوحظ أنه مع تناقص عدد بيانات التدريب تتخفص قيمة معامل الارتباط بين النتائج المتوقعة، والنتائج الحقيقية، حيث بلغت نسبة تقسيم البيانات الأفضل في كافة النماذج المدروسة % (15-15-70)، وهو ما يؤكد أن زيادة عدد بيانات التدريب يحسّن من أداء الشبكة العصبونية الصناعية.

4. 3. تأثير البارامترات المدروسة على أداء الشبكات العصبونية 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 التي بلغت %83.1. وأعطى النموذجين الحاويين على بارامتر pH المياه الخام في مدخلتهما (MF_2 ، و MN_2) نتائج أفضل من النموذجين (MF_1 ، و MN_1) اللذان لا يحويانه في مدخلتهما، كما أعطت النماذج من النوع NARX والتي تستخدم عكارة المياه المرشحة كمدخل إضافي فيها أداءً أفضل من مثيلاتها من النوع FTDNN.

بالتالي فإن استخدام بارامترية ناقلية، و pH المياه الخام، كذلك قيم عكارة المياه المرشحة السابقة يزيد من دقة نماذج الشبكات العصبونية الديناميكية، وهو ما يدل على قوة هذه الشبكات في محاكاة السلوك غير الخطي للعكارة.

4.4. محاكاة نموذج الشبكة العصبونية الصناعية المقترح:

يعد فحص أداء أي نموذج رياضي مقترح من الخطوات المعتادة المتبعة في عملية النمذجة الرياضية، ويقوم 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 (9) كيفية تركيب، وبناء نموذج المحاكاة باستخدام تقانة Simulink من أجل شبكتي FTDNN، و NARX.

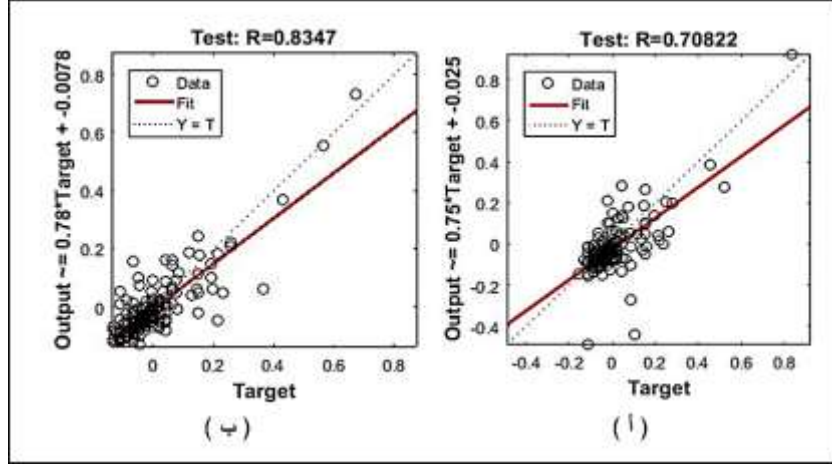


الشكل (9): قالب الشبكة العصبونية الصناعية المقترحة: أ- نوع FTDNN؛ ب- نوع NARX

4.5. تقييم أداء الشبكة ونتائج الاختبار:

بهدف التحقق من أداء الشبكة، وقابليتها للاستجابة بشكل جيد للبيانات التي لم تتدرب عليها اختبر نموذجي شبكتي FTDNN، و NARX اللذان 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 70.82% للنموذج MF₂، مقابل 83.47% للنموذج MN₂، كما يظهر في الشكل (10)، وقد بلغ متوسط مربع الخطأ MSE لمجموعة الاختبار 8.95×10^{-3} للنموذج MF₂، مقابل 4.08×10^{-3} للنموذج MN₂.

وهو ما يؤكد أن شبكات NARX تعطي أداءً أفضل من شبكات FTDNN في التنبؤ بعكارة مياه الشرب المرشحة في محطة تنقية مياه الشرب في السن.



الشكل (10): نتائج اختبار الشبكة المثلى: أ- نوع FTDNN؛ ب- نوع NARX.

الاستنتاجات والتوصيات:

- إن استخدام البارامترات المؤثرة فيزيائياً على قيم عكارة مياه الشرب المرشحة يحسن أداء الشبكات العصبونية الصناعية الديناميكية، حيث تبين النتائج وجود علاقة غير خطية بين هذه البارامترات وعكارة المياه المرشحة، ويمكن الأساليب غير الخطية للنمذجة مثل شبكات FTDNN و NARX من تأكيد ذلك.
- تؤثر بارامترات المياه الخام الداخلة إلى المرشحات العاملة في محطة التنقية على عكارة المياه المرشحة الخارجة من المرشحات بعد (6-7) أيام.
- تعطي نماذج الشبكات العصبونية الديناميكية نتائج جيدة في نمذجة ومحاكاة السلوك غير الخطي للعكارة والتنبؤ بقيمتها، حيث يدل التوافق الخطي بين مخرجات الشبكات المصممة، وقيم عكارة المياه المرشحة الحقيقية على إمكانية استخدام هذه الشبكات في التنبؤ بقيم عكارة المياه المرشحة في الأيام التالية.
- تعطي الشبكات العصبونية الصناعية من النوع NARX أداءً أفضل من مثيلاتها من النوع FTDNN في مسألة التنبؤ بقيم عكارة مياه الشرب المرشحة.
- واعتماداً على نتائج البحث يمكن، وضع التوصيات التالية:
- تقليل دورة عمل المرشحات في محطة التنقية في السن لضمان عدم وصول العكارة المحتجزة بين طبقات الرمل إلى المياه المرشحة والتي تزيد من عكارتها، وتساهم في عدم استقرار أداء محطة التنقية.
- دراسة تأثير بارامترات أخرى مؤثرة فيزيائياً في عكارة مياه بحيرة السن كدرجة الحرارة وتراكيز النتراة والفوسفات كمدخلات إضافية لنماذج الشبكات العصبونية الصناعية الديناميكية المستخدمة للتنبؤ بعكارة المياه المرشحة.
- تطبيق أسلوب الشبكات العصبونية الديناميكية في تقييم أداء محطة تنقية مياه الشرب في السن بسبب قدرتها الكبيرة على تحليل السلسلة الزمنية لعكارة المياه المرشحة والتنبؤ بقيمتها، وهو ما يساعد في تحقيق استقرار عمل المحطة وتقليل تكاليف التشغيل.
- تجريب نماذج أخرى للشبكات العصبونية الديناميكية لتحليل السلسلة الزمنية للعكارة، ودراسة تأثير متغيرات أخرى مقيسة في محطة التنقية على عكارة المياه المرشحة على أداء هذه الشبكات.

المراجع:

- [1]. World Health Organization. *Guidelines for Drinking-Water Quality*. Vol. 1, Recommendations, 3rd Ed., 2006, 515.
- [2]. 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.
- [3]. هيئة المواصفات والمقاييس العربية السورية. المواصفات القياسية السورية رقم /45/ لمياه الشرب. المراجعة الثانية، وزارة الصناعة، 2007.
- [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]. 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.
- [7]. 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.
- [8]. KABSCH-KORBUTOWICZ, M; KUTYŁOWSKA, M. *Use of Artificial Intelligence in Predicting the Turbidity Retention Coefficient during Ultrafiltration of Water*. Environment Protection Engineering, Vol. 37, No. 2, 2011, 75-84.
- [9]. 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.
- [10]. Al-Baidhani, J. H; Alameedee, M. A. *Optimal Alum Dosage Prediction Required to Treat Effluent Water Turbidity using Artificial Neural Network*. International Journal of Current Engineering and Technology, Vol. 7, NO. 4, 2017, 1552-1558.
- [11]. BEALE, M. H; HAGAN M. T; DEMUTH H. B. *Neural Network Toolbox 7 User's Guide*. Version 7, Math works Inc, 2010, 951.