

Artificial Neural Network for Estimating of Monthly Pan Evaporation in Qattinah Meteostation Based on only Temperature Data

Dr. Gatfan Abd al-Kareem Ammar*

Alaa Ali Sleiman**

Amer al-Darwish***

(Received 8 / 3 / 2021. Accepted 30 / 10 / 2022)

□ ABSTRACT □

Evaporation losses from the water of Lake Qattinah form a large part of the losses of storage in this dam, which are greatly affected by climate change in the region, Besides that, the precise knowledge of these losses is very useful for the management of the water source which is important to irrigating of large area of agricultural land, therefore, this study investigates the potential of artificial neural networks (ANNs) in estimating of monthly evaporation in Qattinah meteostation using temperature data only. The models based on monthly air temperature data only as inputs, and the monthly measured pan evaporation data, used as outputs of the networks. This data was split into three datasets for training and validation and testing in the ratios 70:15:15 respectively. The network was trained and verified using a back-propagation algorithm with different learning methods, number of processing elements in the hidden layer(s), and the number of hidden layers. models were able to well estimating of monthly evaporation values in study meteostation with high reliability. Results shown good ability of (3-14-1) ANN to predict of monthly pan evaporation with correlation coefficient 96.41%, and the value of root mean square error 9.88 mm/month for the validation datasets. This study Recommend using artificial neural networks models in the forecasting of evaporation time series in Lake Qattinah, which have great importance in completing of the missing data.

Keywords: Pan evaporation, Artificial neural networks, Back-propagation algorithm, Estimation.

* Professor, Department of Water and Irrigation Engineering, Faculty of Civil Engineering, Tishreen University, Latakia, Syria. ghatfan62@gmail.com

** Academic Assistant, Department of Engineering and Managing water Resources, Faculty of Civil Engineering, Al-Baath University, Homs, Syria. alaa-sleiman@hotmail.com

*** Academic Assistant, Department of Engineering and Managing Water Resources, Faculty of Civil Engineering, Al-Baath University, Homs, Syria.

نموذج شبكة عصبية اصطناعية لتقدير التبخر الإنائي الشهري في محطة قطينة المناخية باستخدام بيانات درجات الحرارة فقط

د. غطفان عبد الكريم عمار*

علاء علي سليمان**

عامر الدرويش***

(تاريخ الإيداع 8 / 3 / 2021. قبل للنشر في 30 / 10 / 2022)

□ ملخص □

تشكل الفواقد بالتبخر من مياه بحيرة سدّ قطينة جزءاً كبيراً من فواقد التخزين في هذا السد، وهي تتأثر بشكل كبير بالتغيرات المناخية الحاصلة في المنطقة، وإن المعرفة الدقيقة لهذه الفواقد يساعد بشكل كبير في إدارة هذا المورد المائي المهم المستخدم لإرواء مساحات كبيرة من الأراضي الزراعية، ولذلك فإن هدف هذه الدراسة هو البحث في إمكانية استخدام الشبكات العصبية الاصطناعية في تقدير التبخر الإنائي الشهري في محطة قطينة المناخية باستخدام بيانات درجات الحرارة فقط. حيث اعتمدت النماذج على القيم الشهرية لدرجة حرارة الهواء فقط كمدخلات للشبكات العصبية، في حين استخدمت قيم التبخر الإنائي الشهري المقاسة كمخرجات للشبكات العصبية الاصطناعية. قُسمت هذه البيانات إلى ثلاث مجموعات للتدريب والتحقق والاختبار بالنسب 15:15:70 على الترتيب. واستخدمت خوارزمية الانتشار العكسي في عملية تدريب وتحقيق الشبكة مع تغيير طرائق التدريب وعدد الطبقات الخفية وعدد العصبونات في كل طبقة منها. أثبتت نتائج الدراسة قدرة الشبكة العصبية الاصطناعية متعددة الطبقات ذات التغذية الأمامية والانتشار العكسي للخطأ على التنبؤ بقيم التبخر الشهري في محطة الدراسة بموثوقية عالية. وقد أظهرت النتائج القدرة الجيدة للشبكة العصبية الاصطناعية ذات الهيكلية 1:14:3 على التنبؤ بقيم التبخر الإنائي الشهري حيث بلغت قيمة معامل الارتباط للنموذج المقترح 96.41%، وبلغت قيمة جذر متوسط مربعات الأخطاء 9.88 mm/month خلال مرحلة التحقق من النموذج. توصي هذه الدراسة إلى الاستفادة من مميزات نماذج الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية للتبخر في بحيرة قطينة لما له من أهمية كبيرة في استكمال البيانات المفقودة.

الكلمات المفتاحية: التبخر الإنائي، الشبكات العصبية الاصطناعية، خوارزمية الانتشار العكسي، التقدير.

* أستاذ، قسم الهندسة المائية والري، كلية الهندسة المدنية، جامعة تشرين، اللاذقية. سورية ghatfan62@gmail.com

** قائم بالأعمال، قسم هندسة وإدارة الموارد المائية، كلية الهندسة المدنية، جامعة البعث، حمص، سورية. alaa-sleiman@hotmail.com

*** قائم بالأعمال، قسم هندسة وإدارة الموارد المائية، كلية الهندسة المدنية، جامعة البعث، حمص، سورية.

مقدمة:

تعتبر الموارد المائية في أي بلد أحد أهم عوامل التطور والنمو فيه، وذلك كون هذه العوامل تؤثر وتتحكم بتوزيع السكان ونشاطاتهم الاقتصادية والزراعية والصناعية المختلفة، ولهذا السبب فإنه من الضروري البحث عن وسائل للحفاظ على هذه الموارد والإدارة المتكاملة لها [1].

ويشكل التبخر أحد أهم مكونات الدورة الهيدرولوجية، وهو عنصر أساسي من عناصر الموازنة المائية في الأحواض السابكة، يتأثر بالكثير من العوامل مثل : درجة الحرارة، الرطوبة النسبية للهواء، سرعة الرياح، تغيرات الضغط الجوي ودرجة الملوحة، تتداخل هذه العوامل مع بعضها بحيث يصعب فصلها [2].

وهدفنا من الأبحاث إلى إيجاد طريقة تقدير دقيقة للتبخر ، حيث قام عدد من الباحثين بدراسة إمكانية تقدير التبخر نتج باستخدام حوض التبخر صنف (A) ووضعوا معادلات تعطي نتائج مقبولة وضمن الحدود المسموحة للخطأ [3,4]. بينما قارن باحثون آخرون بين مجموعة من النماذج الرياضية لحساب التبخر نتج، ووجدوا اختلاف دقة هذه النماذج باختلاف المحطة المدروسة ونوع البيانات المستخدمة في الحساب [5,6]، واختبر آخرون قدرة النماذج الإحصائية ونماذج بوكس جنكز على تقدير التبخر، واستنتجوا أن هذه النماذج هي طريقة مناسبة لتقدير التبخر نتج [7,8].

وقد اكتسبت تقنيات الذكاء الاصطناعي بشكل عام والشبكات العصبية الاصطناعية (ANNs) بشكل خاص اهتماماً متزايداً في هذا المجال، حيث طبق (Moasheri, et al., 2012) نماذج الـ (ANNs) لتقدير التبخر نتج في خراسان في إيران، واستنتج إمكانية اعتمادها نظراً للقيمة العالية لمعامل الارتباط الناتج [9].

وقام آخرون بوضع أنموذج شبكة عصبية اصطناعية لتقدير التبخر كتابع لدرجة الحرارة العظمى والدنيا فقط ووجدوا أنها تعطي نتائج أكثر دقة من الطرائق التقليدية التي تحتاج أيضاً إلى سرعة الرياح والرطوبة النسبية [10,11,12]. وفي دراسات أخرى أجريت مقارنة بين نماذج الـ (ANNs) والنماذج التجريبية الأخرى المستخدمة في تقدير التبخر ، وتبين أن نماذج الشبكات العصبية الاصطناعية هي الأكثر دقة في تقدير التبخر [13,14].

كما قام عدد من الباحثين بمقارنة نماذج الـ (ANNs) مع نماذج M5 الشجرية في تقدير التبخر نتج المرجعي فحصلوا على نتائج متباينة، حيث كانت نماذج الـ (ANNs) هي الأفضل في المقارنة التي أجراها (Sattari, et al., 2013) [15] ، في حين كانت نماذج M5 الشجرية هي الأكثر دقة في المقارنة التي أجراها (Ghahreman, Sameti, 2014) [16]. أما (Alipour, et al., 2014) فقد أظهر القدرة الجيدة لكل من الأنموذجين على تقدير الـ ET_0 [17].

وقارن (Reddy, et al., 2011) بين نماذج الـ (ANNs) والانحدار الخطي في تقدير التبخر نتج المرجعي الأسبوعي، واستنتج أن نماذج الـ (ANNs) تحسن دقة التقدير للتبخر نتج بشكل بسيط [18]. أما (Al-Abodi, Ali H . 2014) فكارن بين نظام الاستدلال العصبي الضبابي التكييفي (ANFIS) ونماذج الانحدار الخطي في تقدير التبخر ، وبينت النتائج أن أنموذج الـ (ANFIS) يعطي نتائج أكثر دقة من نماذج الانحدار الخطي [19].

وقارن (Kumar, et al., 2012) بين نماذج الشبكات العصبية الاصطناعية ونظام الاستدلال العصبي الضبابي التكييفي (ANFIS) فأظهرت النتائج وجود تقارب كبير بين الأنموذجين مع أفضلية بسيطة لأنموذج الـ (ANFIS) [20].

في حين قارنت (الشلاوي، 2011) بين نماذج الشبكات العصبية الاصطناعية والنظام الضبابي لتقدير التبخر الإنشائي اليومي لمنطقة الموصل، واستنتجت إمكانية استخدام كل من الطريقتين في عملية تقدير التبخر الإنشائي بمعامل ارتباط جيد بين النتائج والقيم المقيسة [21].

وقامت (عبد المحسن، العاني، 2009) بوضع أنموذج شبكة عصبية اصطناعية من النوع (LQV) لتقدير التبخر الإنائي لمنطقة الموصل لاحتاج إلى إشراف مباشر في المراحل الأولية من تهيئة الشبكة للعمل كما هو الحال في الشبكات التقليدية وأوضحت النتائج توافقاً خطياً جيداً بين مخرجات الشبكة المقترحة والقيم المقاسة للتبخر الإنائي [22]. في حين وضع (Khoshhal, Mokarram, 2012) أنموذج شبكة عصبية اصطناعية متعددة الطبقات (MLP) لتقدير التبخر نتج في إيران وأظهرت النتائج دقة عالية للأنموذج المقترح في عملية التقدير والتنبؤ [23]. واستخدم (Awchi, Taymoor A, 2007) الشبكات العصبية ذات الدوال قطرية الأسس (RBF) للتنبؤ بقيم التبخر، وأظهرت النتائج أن شبكات الـ (RBF) ضاهت شبكات الـ (FF-BP) من حيث الأداء وتفوقت عليها من حيث سهولة البناء والسرعة العالية في التدريب [24]، أما (Patel, et al., 2007) فقد استخدم الخوارزميات الجينية في عملية تدريب الشبكة العصبية الاصطناعية والتحقق منها [25].

وطور (Chung, et al., 2012) أنموذج هجين يدمج بين الشبكات العصبية الضبابية التكيفية وطريقة الـ Kriging للاستيفاء المكاني من أجل تقدير التبخر في المناطق التي لا تحتوي على محطات قياس، وقد أظهرت النتائج موثوقية عالية لهذا الأنموذج في تقدير التوزيع المكاني للتبخر [26].

أما (Merambell et al., 2017) فقد استخدم تقنية الشبكات العصبية الاصطناعية لتقدير التبخر نتج المرجعي، واعتمد على طريقة بنمان مونتيث في حساب قيم الهدف للنماذج، في حين استخدم درجات الحرارة الصغرى والعظمى، الإشعاع الشمسي، الرطوبة النسبية وسرعة الرياح كمدخلات للنماذج المختلفة، وتبين أن الشبكات العصبية الاصطناعية والتي تحتوي على طبقة خفية واحدة بعدد عصبونات لا يزيد على 20، وتابع تفعيل Tangent Sigmoid، وخوارزمية تعليم L-M، هي الأمثل بتوافق يزيد على 93% مع القيم الهدف، ومتوسط مربع خطأ يقل عن 0.13 mm/day [27].

أهمية البحث وأهدافه:

تأتي أهمية البحث من العلاقة المباشرة لقيم التبخر بعملية تخطيط وتنمية الموارد المائية، وخاصة كون الفوائد بالتبخر من مياه بحيرة سد قطينة تشكل جزءاً كبيراً من فواقد التخزين في هذا السد، وهي تتأثر بشكل كبير بالتغيرات المناخية الحاصلة في المنطقة، وإن المعرفة الدقيقة لهذه الفواقد يساعد بشكل كبير في إدارة هذا المورد المائي المهم المستخدم لإرواء مساحات كبيرة من الأراضي الزراعية، ولذلك فإن هدف هذه الدراسة هو البحث في إمكانية استخدام الشبكات العصبية الاصطناعية في تقدير التبخر الإنائي الشهري في محطة سد قطينة المناخية باستخدام بيانات درجات الحرارة فقط.

طرانق البحث ومواده:

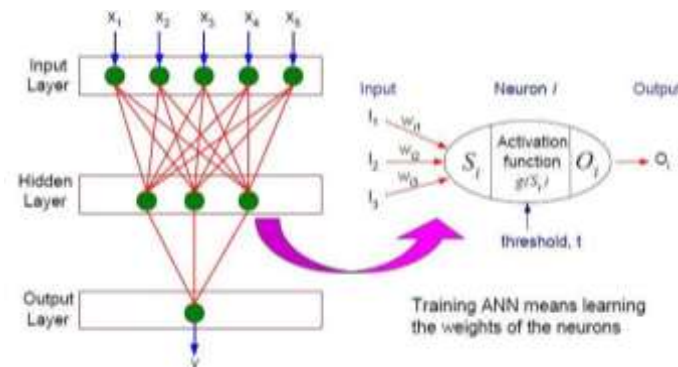
تعد الشبكات العصبية الاصطناعية من أهم مجالات الذكاء الاصطناعي، وهي عبارة عن أنموذج رياضي مبني على مفهوم الشبكات العصبية الحيوية، حيث تتكون من مجموعة من العصبونات الاصطناعية التي تحاكي سير ومعالجة المعلومات في العقل البشري. وتعرف بأنها تركيبات للمعالجة المتوازية الموزعة Parallel Distribute Processing Structure والتي تعتمد بشكل أساسي على عناصر المعالجة Processing Elements القادرة على العمل كذاكرة محلية Local Memory بالإضافة إلى إجراء عمليات المعالجة المختلفة، ويكون لعنصر المعالجة مخرجاً واحداً يتفرع إلى الكثير من التفرعات التي تحمل نفس الإشارة الخارجة منه مع بقاء المعالجة المحلية، أي أنها تعتمد على القيم المدخلة وكذلك القيم المخزنة في الذاكرة المحلية لهذه العناصر الحسابية [1].

تختلف الشبكات العصبية من ناحية البنية الهندسية أي الطريقة التي ترتبط بها العصبونات في كل طبقة من طبقات الشبكة مع بعضها البعض لتشكل الشبكة العصبية حيث تؤثر هذه البنية على مخرجات الشبكة. وقد وجد أن الشبكات العصبية متعددة الطبقات (Multiple Layer Neural Networks) تكون ذات فعالية أكبر في الحسابات لذا فهي واسعة الاستخدام، ويمكن لهذا النوع من الشبكات حل العديد من المشاكل المعقدة غير أن تدريبها يستغرق وقتاً أطول، ويتم تحديد عدد طبقات الدخل والخرج وعدد الطبقات المخفية وعدد العصبونات في كل طبقة من هذه الطبقات بحسب طبيعة المسألة المراد دراستها [1].

يقسم عمل العصبون الاصطناعي إلى مرحلتين أساسيتين، في المرحلة الأولى تتم معالجة المدخلات، حيث يقوم العصبون بضرب كل مدخل من المدخلات بوزن معين يتم تحديده عشوائياً كمرحلة أولية للتدريب، ومن ثم تتم عملية جمع المدخلات الموزونة ويضاف إليها عامل انحياز (b) وذلك للحصول على قيم موجبة للمرحلة الأولى. أما المرحلة الثانية فيتم فيها معالجة مخرجات المرحلة الأولى من خلال دوال رياضية تدعى بدوال التفعيل (Activation Function) حيث تحتوي كل من الطبقات المخفية وطبقة الخرج على دالة تفعيل يتم اختيارها تبعاً لطبيعة المسألة وهناك العديد من دوال التفعيل التي تحدد ما هي قيمة المخرجات الممكنة استنتاجها من قيم المدخلات، تصلح كل واحدة من هذه الدوال لنوع معين من التطبيقات بالاعتماد على المجال المحدد لها، وتعتبر دوال التفعيل (tan- sigmoid, log-sigmoid, pure) من أكثر دوال التفعيل المستخدمة في بناء الشبكات العصبية الاصطناعية [1]. إن الشبكات العصبية لا تُبرمج وإنما تُدرَّب، ويمكن أن يتم ذلك من خلال العديد من خوارزميات التدريب (Training Algorithms) التي تتولى تعديل أوزان الشبكة لتقليل الأخطاء فيها، وتعتبر خوارزمية الانتشار العكسي للخطأ (Back Propagation Algorithm) من أهم تلك الخوارزميات وأكثرها انتشاراً [28].

تقسم الشبكات العصبية الاصطناعية من حيث اتجاه اجراء الحسابات المطلوبة إلى:

1. الشبكات العصبية الاصطناعية ذات التغذية الأمامية (Feedforward ANNs): ويقصد بالتغذية الأمامية أن انتشار البيانات في الشبكة يكون دائماً باتجاه الأمام من طبقة الدخل إلى طبقة الخرج.
2. الشبكات العصبية الاصطناعية ذات التغذية الخلفية (Feedbackward ANNs): وفي هذا النوع من الشبكات العصبية تعاد البيانات الخارجة من الشبكة لتصبح من المدخلات. ويبين الشكل (1) البنية الأساسية للشبكة العصبية الاصطناعية ذات التغذية الأمامية:



الشكل (1): البنية الأساسية للشبكات العصبية الاصطناعية ذات التغذية الأمامية.

يتطلب عمل الشبكات العصبية الاصطناعية إجراء عملية التقييس لكل من متجهات المدخلات والهدف، وذلك لجعل قيم عناصرها قريبة من بعضها البعض لتقليل الخطأ بين القيم المحسوبة من الشبكة والقيم الهدف، وهذا يحسن كفاءة العمليات الحسابية وأداء الشبكة، وفي هذا البحث تم استخدام المعادلة الآتية [28]:

$$x_{norm} = 0.5 \cdot \left(\frac{x_0 - \bar{x}}{x_{max} - x_{min}} \right) + 0.5 \quad (1)$$

حيث أن x_{norm} : القيمة المقيسة، x_0 : القيمة الأصلية، \bar{x} : القيمة الوسطية، x_{max} : أعلى قيمة، x_{min} : أدنى قيمة. اعتمدت هذه الدراسة على معامل الارتباط (R)، وجذر متوسط مربعات الأخطاء (RMSE) في المقارنة بين النماذج المختلفة للشبكات العصبية الاصطناعية، وتحديد الأفضل بينها.


النتائج والمناقشة:

جُمعت البيانات المناخية المستخدمة في هذه الدراسة من محطة سد قطينة المناخية، وتضمنت 214 قيمة شهرية للتبخر الإنائي ودرجات حرارة الهواء (العظمى والصغرى والوسطية) (T_{max} , T_{min} , T_{av}) بين عامي 1966 و 1986، حيث استخدمت قيم التبخر الإنائي كمخرجات للنماذج العصبية، في حين اعتمدت هذه النماذج على قيم درجات الحرارة فقط كمدخلات. قُسمت البيانات إلى ثلاث مجموعات: مجموعة التدريب Training Set، مجموعة التحقق Validation Set، مجموعة الاختبار Testing Set. استخدمت مجموعة التدريب لبناء النموذج، في حين استخدمت مجموعة التحقق للتأكد من صحة أداء الشبكة أثناء التدريب، استخدمت مجموعة الاختبار لاختبار أداء الشبكة بعد الانتهاء من التدريب، وعموماً لا توجد قاعدة عامة لتقسيم البيانات، وإنما يعود لنوع المشكلة والغرض من النموذج، وفي هذه الدراسة اعتمدت النسبة 70% لمجموعة التدريب و 15% لكل من مجموعتي التحقق والاختبار، وفق تابع التقسيم Divideblock بحيث لا تتغير قيم أو ترتيب البيانات المستخدمة بتغيير النموذج أو دورة التدريب أو عدد العصبونات. ثم دُرِّبَت الشبكات العصبية بعدد عصبونات من 2 حتى 40 في الطبقة (الطبقات) الخفية، باستخدام مختلف توابع التفعيل والتدريب وخوارزميات ونسب التعليم، وبعد كل عملية تدريب تم حساب قيمة RMSE و R لكل مرحلة من مراحل التدريب والتحقق والاختبار لتحديد عدد العصبونات الأمثل في الطبقة الخفية بطريقة المحاولة والخطأ. وقد أظهرت النتائج أن الشبكات العصبية الاصطناعية ذات التغذية الأمامية والانتشار العكسي للخطأ هي الأفضل بين أنواع النماذج العصبية. ويبين الجدول 1 معايير تقويم الأداء لأفضل النماذج العصبية الناتجة بمختلف الهيكليات.

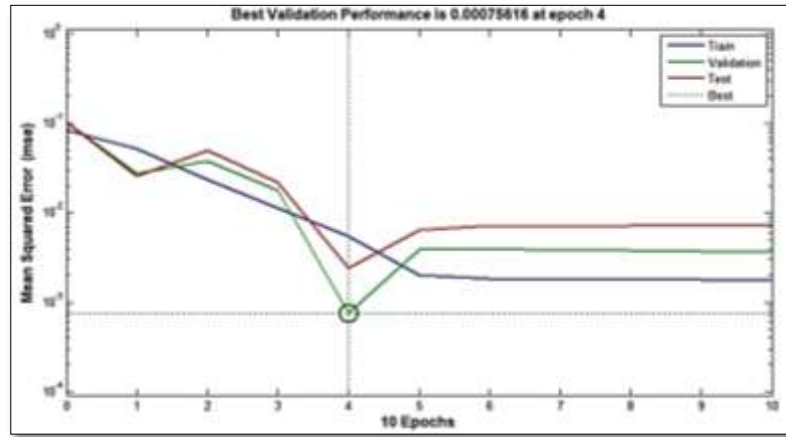
الجدول 1: معايير تقويم الأداء لأفضل النماذج العصبية الناتجة بمختلف الهيكليات.

| بنية الشبكة | تابع التفعيل المستخدم | نسبة التعلم | مرحلة التدريب Training | | مرحلة التحقق Validation | | مرحلة الاختبار Testing | |
|-------------|-----------------------|-------------|------------------------|-------|-------------------------|-------|------------------------|-------|
| | | | R | RMSE | R | RMSE | R | RMSE |
| 3:7:1 | Tansig | 0.06 | 95.14 | 15.76 | 96.20 | 17.87 | 86.27 | 25.20 |
| 3:12:1 | Tansig | 0.09 | 94.53 | 24.65 | 96.62 | 9.92 | 85.91 | 18.70 |
| 3:14:1 | Tansig | 0.03 | 93.88 | 24.95 | 96.60 | 10.00 | 86.42 | 18.15 |
| 3:14:1 | Tansig | 0.1 | 93.30 | 26.45 | 96.41 | 9.88 | 87.09 | 17.70 |

أظهرت النتائج أن الهيكلية الأكثر ملاءمة تحتوي على طبقة خفية واحدة مع 14 عصبون، والتي تستخدم تابع التفعيل tan sigmoid وخوارزمية التدريب Levenberg – Marquardt ، مع اعتماد نسبة التعلم 0.1 خلال تدريب هذه الشبكة. وقد أظهرت هذه الشبكة فعالية عالية تمثلت بجذر متوسط مربعات أخطاء يساوي 9.88 mm/month ، ومعامل ارتباط 96.41% خلال مرحلة التحقق من بناء الشبكة. ويبين الشكل 2 بنية الشبكة المقترحة ، في حين يبين الشكل 3 أداء هذه الشبكة خلال مراحل التدريب والتحقق والاختبار.

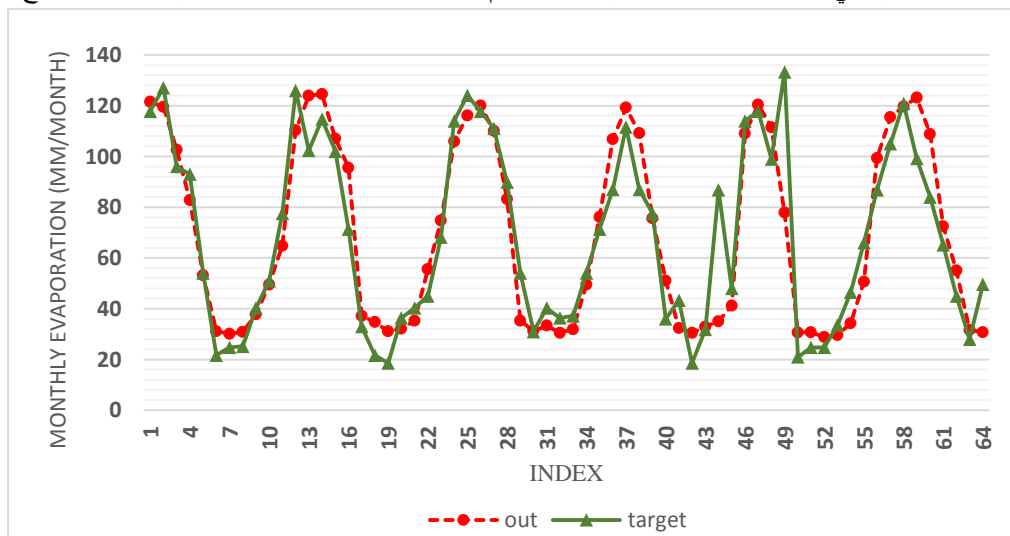


الشكل 2: بنية الشبكة (3,14,1) التي أعطت أفضل النتائج خلال مرحلة التحقق.

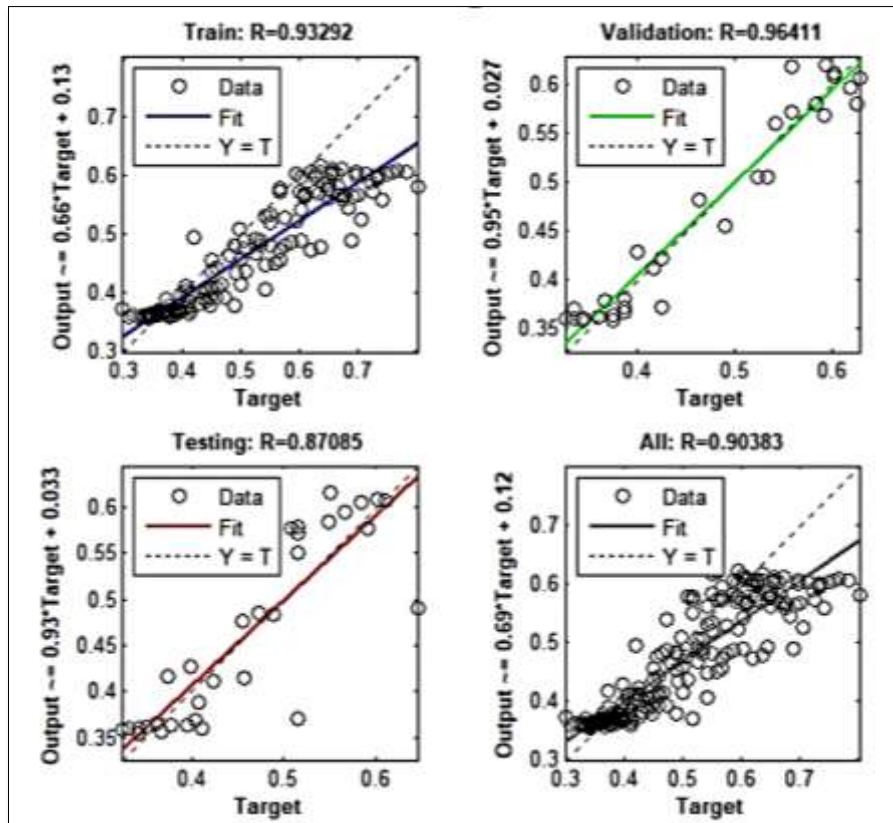


الشكل 3: أداء الشبكة (3,14,1) خلال مراحل التدريب والتحقق والاختبار وآلية اختيار الدورة التكرارية الأمثل.

ويظهر الشكل 4 مقارنة بين قيم التبخر المقاسة والمحسوبة باستخدام نموذج الشبكة العصبية الاصطناعية خلال مرحلتي التحقق والاختبار، في حين يبين الشكل 5 الارتباط بين القيم المقاسة والمحسوبة خلال كافة مراحل بناء النموذج.



الشكل 4: مقارنة بين قيم التبخر المقاسة (target) والمحسوبة باستخدام الشبكات العصبية الاصطناعية (out) خلال مرحلتي التحقق والاختبار.



الشكل 5 : الارتباط بين قيم التبخر المقیسة والمحسوبة باستخدام الشبكات العصبية الاصطناعية خلال كافة مراحل بناء الشبكة.

الاستنتاجات والتوصيات :

- ✓ أظهرت النتائج القدرة الجيدة للشبكة العصبية الاصطناعية ذات الهيكلية 3:14:1 على التنبؤ بقيم التبخر الإنثائي الشهري حيث بلغت قيمة معامل الارتباط للنموذج المقترح 96.41%، وبلغت قيمة جذر متوسط مربعات الأخطاء 9.88 mm/month خلال مرحلة التحقق من النموذج.
- ✓ يمكن اعتماد الشبكات العصبية الاصطناعية ذات التغذية الأمامية والانتشار العكسي للخطأ لتقدير التبخر الشهري في محطة سد قطينة المناخية بموثوقية عالية.
- ✓ توصي هذه الدراسة إلى الاستفادة من مميزات نماذج الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية للتبخر في بحيرة قطينة لما له من أهمية كبيرة في استكمال البيانات المفقودة.
- ✓ مقارنة نماذج الشبكات العصبية الاصطناعية مع التطبيقات الأخرى للذكاء الاصطناعي مثل المنطق الضبابي والخوارزميات الجينية.

References:

1. Abdul Mohsen, Kamel Ali; Tawfiq, Ayman Rafi Muhammad. An artificial neural network to run a single storage system. AL-Rafidain Engineering, Volume 22, Issue 2, 2013, 29-37.
2. Leos, Elias Ibrahim; Hamdan, Yasser Muhammad. Hydrology 1. Al-Baath University, 2008, first semester.
3. The student, Anmar Abdel Aziz; Dhanoun, Ahmed Azhar. Estimation of reference evapotranspiration using a class A evapotranspiration basin for the city of Mosul, Iraq. 2011.
4. Al-Ani, Iftikhar Abdul-Jawad; Abd, Muzahem Mahmoud; Jacob, Alaa Abdullah. Estimation of daily potential evapotranspiration from pothole evapotranspiration data, class (A), for the Mosul region. Tikrit Journal of Engineering Sciences, Volume 16, Issue 4, 2009, 13-19.
5. Al-Rajabo, Walid Asmir; Jasim, Khader; Shallal, Mukhallaf. Evapotranspiration reference study in Nineveh governorate using several mathematical models. Journal of Rafidain Sciences, Volume 19, Issue 3, 2008, 154-173.
6. ALJUMAILI, K. K; AL-KHAFIJI, M. S; AL-AWADI, A. T. Assessment of Evapotranspiration Estimation Models for Irrigation Projects in Karbala, Iraq. Eng. & Tech. Journal, Vol.32, Part (A), No.5, 2014, 1149-1157.
7. Abdullah. Ehab Khaled; Hamdan. Yasir; Raad. Tammam Muhammad. Prediction of future evaporation from the surface of Qattina Lake using statistical models. Al-Baath University Journal of Engineering Sciences, Volume 34, Issue 2, 2012, 9-32.
8. VALIPOUR, M. Ability of Box-Jenkins Models to Estimate of Reference Potential Evapotranspiration (A Case Study: Mehrabad Synoptic Station, Tehran, Iran). Journal of Agriculture and Veterinary Science (IOSR-JAVS), Vol 1, Issue 5, 2012 .
9. MOASHERI, S, A; AFRASIAB, P; SARANI, S; SARANI, N. Estimation of Reference Evapotranspiration by Using Artificial Neural Networks. International Conference on Transport, Environment and Civil Engineering (ICTECE), Kuala Lumpur (Malaysia), 2012, 80-84.
10. JADEJA, V. Artificial neural network estimation of Reference Evapotranspiration from pan evaporation in a semi-arid environment. National Conference on Recent Trends in Engineering & Technology , 2011 .
11. KARIYAMA, I. D. Temperature-Based Feed-Forward Backpropagation Artificial Neural Network For Estimation Reference Crop Evapotranspiration In The Upper West Region. International Journal of Scientific & Technology Research, Volume 3, Issue 8, 2014, 357-364.
12. WANG, Y. M; TRAORE, S; KERH, T. Neural Network Approach for Estimating Reference Evapotranspiration from Limited Climatic Data in Burkina Faso. Wseas Transactions on Computers, Vol 7, Issue 6, 2008, 704-713.
13. ARCA, B; BENINCASA, F; VINCENZI, M. D. Evaluation of neural network techniques for estimating evapotranspiration. National Research Institute for the Monitoring of Agroecosystems (IMAs), 2004.
14. BENZAGHTA, M. A; MOHAMMED, T. A; GHAZALI, A. H; SOOM, M. A. M. Prediction of evaporation in tropical climate using artificial neural network and climate based models. Scientific Research and Essays, Vol 7(36), 2012, 3133-3148.
15. SATTARI, M. T; PAL, M; YUREKLI, K; UNLUKARA, A. M5 model trees and neural network based modeling of ET_0 in Ankara, Turkey. Turkish Journal of Engineering & Environmental Sciences, 37, 2013, 211-219.

16. GHAHREMAN, N; SAMETI, M. Comparison of M5 Model Tree and Artificial Neural Network for Estimating Potential Evapotranspiration in Semi-arid Climates. DESERT, 2014, 75-81.
17. ALIPOUR, A; YARAHMADI, J; MAHDAVI, M. Comparative Study of M5 Model Tree and Artificial Neural Network in Estimating Reference Evapotranspiration Using MODIS Products. Hindawi Publishing Corporation, Journal of Climatology, 2014.
18. REDDY, K. C. S; JYOTHY, S. A; MALLIKARJUNA, P. Estimation of Weekly Referene Evapotranspiration using Linear Regression and ANN Models. ACEE Int. J. on Civil and Environmental Engineering, Vol. 01, No. 01, 2011, 30-35.
19. AL-ABBODI, A. H. Evaporation Estimation Using Adaptive Neuro-Fuzzy Inference System and Linear Regression. Eng.&Tech. Journal, Vol.32, Part(A), No.10, 2014, 2465-2474.
20. KUMAR, P ; KUMAR, D ; JAIPAL, A ; TIWARI, K . Evaporation Estimation Using Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System techniques. Pakistan Journal of Meteorology, Vol. 8, Issue 16, 2012, 81-88 .
21. Al-Shalawi, Senus Khalil Hassan. Comparison of applications of artificial neural networks and fuzzy system to estimate daily evapotranspiration for the Mosul region. Kufa Journal of Mathematics and Computers, Volume 1, Issue 3, 2011, 23-32.
22. Abdul Mohsen, Kamel Ali; Al-Ani, Ifikhar Abdul-Jawad. Using a learning vector quantization network to estimate evapotranspiration. Tikrit Journal of Engineering Sciences, Volume 16, Issue 2, 2009, 43-50
23. KHOSHHAL, J; MOKARRAM, M. Modae for Prediction of Evapotranspiration Using MLP Neural Network. International Journal of Environmental Sciences. Vol 3, No 3, 2012, 1000-1009.
24. AWCHI, T. A. Application of Radial Basis Function Neural Networks for Reference Evapotranspiration Prediction. 2007.
25. PATEL, K; ANNAMALI, R; KRISHNAN, P; RITTER, W.F. Estimation Reference Evapotranspiration Using Artificial Neural Network, 2007.
26. CHUNG, C. H; CHIANG, Y. M; CHANG, F.J. A Spatial neural fuzzy network for estimating pan evaporation at ungauged sites. Hydrology and Earth System Sciences, 16, 255-266, 2012.
27. MIRAMBELL, A.B; DA SILVA, C.F; SARBOSA, F.D; RIBEIRO, C.B. A Methodological Proposal Based on Artificial Neural Networks for Evapotranspiration Assessment. Journal of Agricultural Science; Vol. 9, No. 5; 2017, 142-157.
28. Al-Sharqawi, Muhammad Ali. Artificial intelligence and artificial networks. The first book in the series of future computer science and technology, Center for Artificial Intelligence for Computers, 356.
29. ALLEN, R. G; PEREIRA, L. S; RAES, D; SMITH, M. FAO Irrigation and Drainage Paper, No. 56. Crop Evapotranspiration (guidelines for computing crop water requirements), 1998.