

نموذج شبكة عصبية صناعية للتنبؤ بالتبخر الشهري في منطقة حماه

ماريا عباس*

(تاريخ الإيداع 18 / 1 / 2017. قُبل للنشر في 11 / 5 / 2017)

□ ملخص □

التبخّر هو أحد العناصر الأساسية للدورة الهيدرولوجية وضروري للعديد من الدراسات مثل الموازنة المائية، تصميم أنظمة الري وإدارة الموارد المائية، ويتطلب تقديره معرفة العديد من العناصر المناخية. على الرغم من أن هناك صيغاً تجريبية متوفرة لتقدير التبخّر، ولكن أداء هذه الصيغ غير دقيق بسبب الطبيعة المعقدة لعملية التبخّر. لذلك فإن هذا البحث يهدف لوضع نموذج شبكة عصبية صناعية للتنبؤ بالتبخّر الشهري في منطقة حماه باستخدام ثلاثة عناصر مناخية هي درجة الحرارة، الرطوبة النسبية وسرعة الرياح. من أجل ذلك فقد بُني النموذج باستخدام مكتبة nntool-box إحدى أدوات الـ MATLAB. استُخدمت الشبكة العصبية الصناعية ذات التغذية الأمامية و الانتشار العكسي للخطأ بطريقة خفية واحدة لبناء النموذج. وتم تقييم شبكات مختلفة بعدد مختلف من العصبونات وبتغيير دوال التفعيل المستخدمة في كل طبقة. واستُخدم جذر متوسط مربع الخطأ (RMSE) لتقييم دقة النموذج المقترح. وقد بينت الدراسة أن الشبكة العصبية الصناعية ذات الهيكلية (1-14-3) هي الأفضل للتنبؤ بالتبخّر في منطقة حماه حيث كانت قيمة RMSE تساوي (21.5mm/month) وقيمة R^2 مساوية (0.97).

توصي الدراسة باستخدام أنواع أخرى من الشبكات العصبية لتقدير التبخّر.

الكلمات المفتاحية: التبخّر، الشبكات العصبية الصناعية، الماتلاب.

* قائم بالأعمال - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Forecasting Of Monthly Evaporation In Hama Using Artificial Neural Network

Maria Abbas*

(Received 18 / 6 / 2017. Accepted 11 / 5 / 2017)

□ ABSTRACT □

The evaporation is one of the basic components of the hydrologic cycle and it is essential for studies such as water balance, irrigation system design and water resource management, and it requires knowledge of many climatic variables. Although, there are many empirical formulas available for evaporation estimate, but their performances are not all satisfactory due to the complicated nature of the evaporation process. Accordingly, this paper is an attempt to assess the potential and usefulness of ANN based modeling for evaporation prediction from HAMA by using temperature, relative humidity and wind velocity. The mathematical model was built by the (nntool-box), which is one of the MATLAB tools. The feed forward back propagation network with one hidden layer has been utilised to construct the model. Different networks with different number of neurons were evaluated. Root Mean Squared Error (RMSE) was employed to evaluate the accuracy of the proposed model. The study shows that ANN (3-14-1) was the best model with RMSE (21.5mm/month) and R^2 (0.97).

This study suggests using other types of neural networks for estimation of evaporation

Keywords: Evaporation, Artificial Neural Network, MATLAB.

* Academic Assistant, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

إن نقصان توافر الماء خلال العقود القليلة الماضية هو أحد المشاكل البيئية الرئيسية والتي يمكن أن تحد من الزراعة والتنمية الصناعية في العالم. إن التنبؤ بكمية المياه المطلوبة للري يتضمن حساب العديد من عناصر الموازنة المائية مثل الهطل المطري، الجريان، مستوى المياه الجوفية والتبخر.

يؤثر التقدير الدقيق للتبخر على دراسة التوازن المائي والذي يؤثر بدوره على كفاءة التخطيط وإدارة الموارد المائية، وهذه الخسائر يجب أن تؤخذ بعين الاعتبار عند تصميم مصادر المياه وأنظمة الري [1]، حيث يُقدَّر التبخر بطرائق مباشرة وغير مباشرة، لكن مع ازدياد الصعوبات التقنية وتعقيدها برز أسلوب الشبكات العصبية الصناعية ذات التغذية الأمامية والانتشار العكسي للخطأ ضمن إطار النمذجة وتقانات الذكاء الاصطناعي، مما حفَّز الباحثين على استخدام هذه التقانة في عمليات النمذجة الرياضية لمختلف المشكلات الهندسية. [2]

قام العديد من الباحثين بتقدير التبخر في مناطق مختلفة من العالم باستخدام تقانات الذكاء الاصطناعي. فعلى سبيل المثال اعتمد A. Goel (2009) على الشبكات العصبية الصناعية للتنبؤ بالتبخر من خزان بالاعتماد على التبخر اليومي، درجة الحرارة، الإشعاع الشمسي، الرطوبة النسبية وسرعة الرياح. تمت مقارنة أداء نموذج الشبكة العصبية ذات التغذية الأمامية والانتشار العكسي للخطأ مع الارتداد الخطي. بينت نتيجة الدراسة أن النمذجة اعتماداً على ANN ذات التغذية الأمامية والانتشار العكسي للخطأ أعطت نتائج أفضل ويمكن أن تُطبق كطريقة بديلة لتقدير التبخر اليومي من الأحواض [3].

طوّر Kumar, P , D. Kumar, Jaipaul , A. K. Tiwari (2012) نموذج شبكة عصبية صناعية (ANN) ونظام استدلال عصبي ضبابي تكيفي (ANFIS) للتنبؤ بالتبخر الشهري المحتمل في Pantagar, U.S. Nagar (الهند) استناداً على أربعة عناصر مناخية هي الرطوبة النسبية، الإشعاع الشمسي، الحرارة وسرعة الرياح لـ 19 عاماً و 8 أشهر سابقة (236 شهراً). بينت النتائج أن النماذج كانت قادرة على تعلم الأحداث جيداً والتي دُرِّبت للتمييز. كما أنها قادرة على تعميم تدريبها بشكلٍ فعال من خلال التنبؤ بالتبخر لمجموعة حالات غير مُدرَّبة [4]. استخدم Singh et al. (2013) نموذج الشبكة العصبية الصناعية لتقدير التبخر-نتح (ET). تضمنت بيانات الأرصاد الجوية المُستخدمة في هذه الدراسة درجة الحرارة العظمى، درجة الحرارة الصغرى، الرطوبة النسبية، سرعة الرياح وساعات السطوع الشمسي. النتائج المُلاحظة من نموذج ANN والمُدرَّب بخوارزمية الانتشار العكسي للخطأ كانت على توافق جيد مع قيم ET المُقاسة بواسطة الليزومتر [5].

قام Saad SH. Sammen (2013) باستخدام الشبكات العصبية الصناعية (ANN) للتنبؤ بالتبخر من خزان Hemren باستخدام درجة الحرارة اليومية، الرطوبة النسبية، سرعة الرياح، ساعات السطوع الشمسي وبيانات التبخر في محطة الأرصاد لـ Hemren. أظهرت النتائج إمكانية استخدام ANN للتنبؤ بالتبخر من الأحواض في مشاريع الموارد المائية [6].

طوّر Javed Ali and Sakshi Saraf (2015) نموذج لتقدير التبخر باستخدام الشبكات العصبية الصناعية لـ Rajasthan، Udaipur، في الهند. كما استخدمت هذه الدراسة تقنية الارتدادات الخطية المتعددة (MLP) لتقدير التبخر. وُجد أن تقدير التبخر باستخدام ANN أفضل بالمقارنة مع تقدير التبخر باستخدام (MLR) [7]. كما قام عمار، حيدر (2015) ببناء نموذج لشبكة عصبية صناعية لتقدير التبخر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة فقط. وإجراء مقارنة بين نتائج نموذج الشبكة ونتائج نماذج أخرى

معروفة. تبين أن نتائج الشبكة العصبية الصناعية المعتمدة على درجة الحرارة فقط تعطي نتائج أكثر دقة من معادلة إيفانوف في تقدير التبخر [8].

وهدفنا الدراسة التي قام بها Kharat Pallavi , Shetkar Rajeev (2016) إلى تطوير نموذج شبكة عصبية صناعية لتقدير التبخر من خزان NathSagar المتوضع في منطقة Marathwada في Maharashtra. استعملت شبكة ذات تغذية أمامية وانتشار عكسي للخطأ بطبقة خفية واحدة لبناء النموذج. وبينت النتائج أن استخدام درجة الحرارة العظمى والدنيا والرطوبة النسبية وساعات الإشعاع الشمسي كمدخلات للنموذج أعطت أداءً أفضل للتنبؤ بالتبخر. كما أن استخدام درجة الحرارة العظمى والرطوبة النسبية يعطي تنبؤاً جيداً في حال عدم توفر باقي البيانات [9].

أهمية البحث وأهدافه:

التبخّر ظاهرة معقدة وغير خطية وتتأثر بالعديد من العناصر المناخية مثل درجة الحرارة والرطوبة النسبية وسرعة الرياح وساعات السطوح الشمسي.... الخ. التقدير الدقيق للتبخّر ضروري لدراسة التوازن المائي والذي يؤثر بدوره على كفاءة التخطيط وإدارة الموارد المائية. لذلك فإن هدف هذه الدراسة هو بناء نموذج رياضي للتنبؤ بالتبخّر الشهري في منطقة حماة باستخدام الشبكة العصبية الصناعية (ANN) وذلك اعتماداً على درجة الحرارة والرطوبة النسبية وسرعة الرياح.

منطقة البحث

تشكل منطقة الدراسة جزءاً من المنطقة الوسطى من القطر العربي السوري. ممتدة على جانبي نهر العاصي، متاخمة من الشمال لمحافظة إدلب وحلب، ومن الشمال الشرقي لمحافظة الرقة ومن الشرق والجنوب لمحافظة حمص وتتاخم من الغرب محافظتي اللاذقية وطرطوس. وتقدر مساحة المحافظة بحوالي 8861 كم² يمر بها خط عرض 35 درجة و 7 دقيقة شمالاً وخط طول 36 درجة و 44 دقيقة شرقاً. تحيط بها هضاب من الأطراف، يتراوح ارتفاعها عن سطح البحر بين 310-325 م. يبين الشكل (1) منطقة الدراسة.

استُخدم في هذه الدراسة قياسات شهرية متوافرة لدرجة الحرارة والرطوبة النسبية وسرعة الرياح والتبخّر للفترة الممتدة بين (1957-1991) لمحطة حماه المناخية. ويتطلب عمل الشبكات العصبية إجراء عملية التقييس لكل متجهات الإدخال والهدف، وذلك لجعل القيم قريبة من بعضها البعض، أي ضمن مدى قصير نسبياً لتقليل قيمة الخطأ بين القيم المحسوبة من الشبكة والقيم الفعلية، وهذا يحسن كفاءة العمليات الحسابية وأداء الشبكة. قُيِّست كافة البيانات باستخدام المعادلة (1) [10] [11]:

$$y = \frac{x - x_{(min)}}{x_{(max)} - x_{(min)}} \dots \dots \dots (1)$$

حيث y القيمة المقيّسة، x القيمة الحقيقية، x_{max} القيمة العظمى للقيم الحقيقية، x_{min} القيمة الصغرى للقيم الحقيقية. وتدعى هذه الطريقة بطريقة التقييس الخطية المحلية.



الشكل (1) منطقة الدراسة

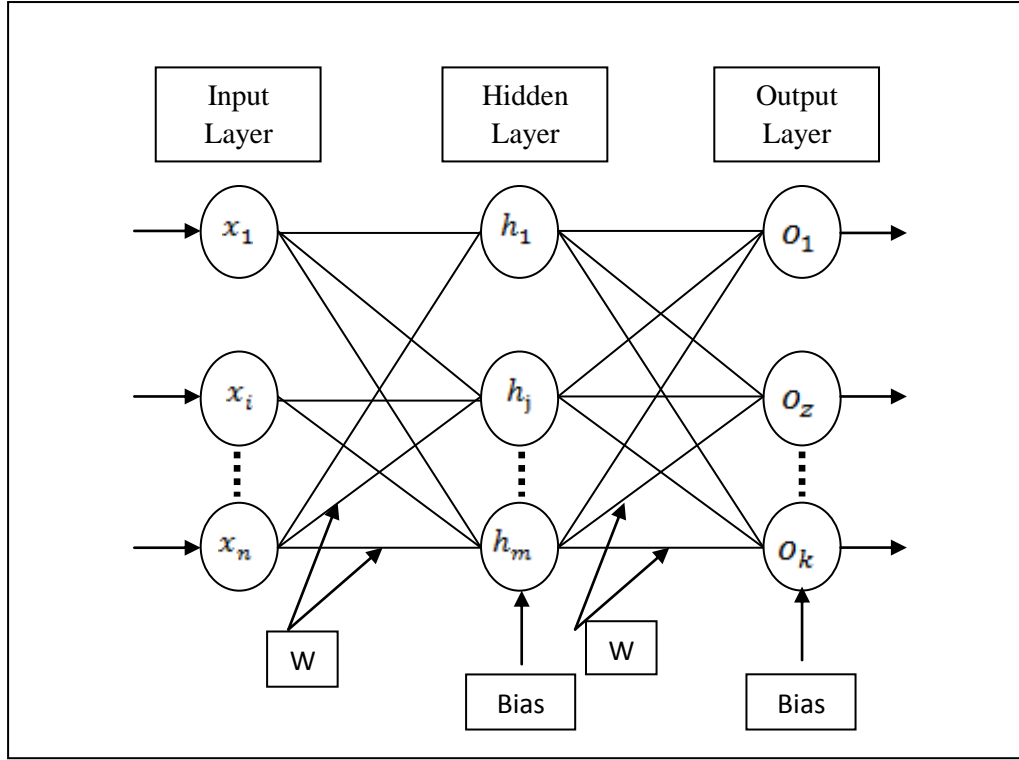
طرائق البحث ومواده:

تعتمد هذه الدراسة على إنشاء نموذج لشبكة عصبية صناعية (ANN). حيث تعرف الشبكات العصبية الصناعية بأنها إحدى أدوات الذكاء الاصطناعي وقادرة على التعلم واكتساب المعرفة بالتدريب [3] [12]، وتحاكي الطريقة التي يؤدي بها الدماغ البشري مهمة معينة [6]، وذلك عن طريق نظام لمعالجة البيانات موزع على التوازي مكون من وحدات معالجة بسيطة (عصبونات اصطناعية) والتي تحسب بتوابع رياضية معينة (عادةً غير خطية) [12]. وتتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب وتخزن هذه المعرفة العملية والمعلومات التجريبية باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية لتجعلها متاحة للمستخدم عن طريق ضبط الأوزان [8].

زاد الاهتمام في السنوات الأخيرة نحو تطوير استخدام الشبكات العصبية، واستخدامها كبديل عن النماذج التقليدية. ولقد أثبتت نماذج الشبكات العصبية قدرتها على التنبؤ بحل المشكلات بدقة وسهولة مقارنة بالأساليب الإحصائية التقليدية. حيث يمكن تطبيق أسلوب الشبكات دون النظر إلى فرضيات معينة عن طبيعة المتغيرات وعلاقتها مع بعضها البعض وذلك على العكس من الطرائق التقليدية العادية في التنبؤ. وكان لها الفضل في حل العديد من المشاكل حيث دخلت في مجالات عديدة كالعلوم والهندسة والطب والاتصالات والاقتصاد والأعمال [13].

إن الشبكات العصبية الصناعية هي بنية رياضية مرنة قادرة على تعريف العلاقات المعقدة غير الخطية بين مجموعات بيانات المدخلات والمخرجات، حيث وُجد أن نماذج الشبكات العصبية الصناعية تكون مفيدة وفعالة خاصة في المسائل التي يصعب وصف خواص العمليات فيها بمعادلات فيزيائية. وتُعد هذه النماذج مناسبة جداً في الحالات التي تكون فيها العلاقة بين متغيرات المدخلات والمخرجات غير صريحة. إضافةً إلى ذلك فإن الشبكة العصبية الصناعية ترسم خريطة العلاقات الضمنية بين المدخلات والمخرجات من خلال التدريب اعتماداً على الملاحظات الحقلية [8] [13].

تتكون الشبكة العصبية من مجموعة مركبة من عدة عناصر معالجة (عصبونات) تتصل مع بعضها بوساطة أوزان الاتصال، حيث تتعلم الشبكة من خلال تعديل أوزان الاتصال [3]. الشبكة العصبية الأكثر استخداماً في دراسة الموارد المائية هي الشبكة العصبية الصناعية ذات التغذية الأمامية [3] [14]. يوضح الشكل (2) البنية العامة للشبكة العصبية الصناعية ذات التغذية الأمامية، بطبقة خفية واحدة [3].



الشكل (2) نموذج لشبكة عصبية صناعية ذات تغذية أمامية

تهدف هذه الدراسة إلى إنشاء نموذج رياضي لشبكة عصبية صناعية ذات تغذية أمامية، ويُقصد بالتغذية الأمامية أنها تنتقل العمليات الحسابية في اتجاه واحد للأمام من طبقة المدخلات إلى طبقة المخرجات عبر الطبقات الخفية. ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ Feed Forward Back Propagation Artificial Neural Network، المستخدمة في هذه الدراسة. وسُميت بالشبكات ذات الانتشار العكسي للخطأ لأن المخرجات الحقيقية للشبكة تُقارن مع المخرجات الفعلية، والفرق في قيمهما يدعى بالخطأ، حيث تقوم الشبكة بنشر هذا الخطأ من طبقة المخرجات مروراً بالطبقات الخفية إلى طبقة المدخلات، أي بآلية معكوسة لعملية حساب المخرجات [15].

وفيما يأتي شرح لآلية عمل الشبكات العصبية ذات الانتشار العكسي للخطأ.

أولاً- مرحلة التغذية الأمامية

تستقبل كل وحدة دخل إشارة دخلها ثم تنتشرها إلى جميع وحدات الطبقة الخفية. ثم تجمع كل وحدة خفية قيم وإشارات دخلها الموزونة، حيث ترتبط الخلية العصبية i في طبقة المدخلات لشبكة التغذية الأمامية مع الدخل من الخلية العصبية j في الطبقة الخفية بوساطة الوزن (w_{ji}) [16] الشكل (2):

حيث i دليل الخلية في طبقة المُدخلات.

j : دليل الخلية في الطبقة الخفية.

لحساب الخرج y_j فإن الخلية العصبية j للطبقة الخفية تنجز العملية الحسابية التالية [12]:

$$y_j = f \left[\sum_{i=1}^N (w_{ji} x_i) + b_j \right] \dots \dots \dots (2)$$

حيث N العدد الكلي للمُدخلات إلى العقدة j .

f : دالة التنفيع (transfer function).

يعد شعاع الانحياز (b_j) bias بمثابة الحد الثابت في المعادلات الرياضية الذي يساعد في حل تلك المعادلات

بصورة أسرع وأسهل [15] [16].

هناك عدة أنواع من دوال التنفيع f^k ، نسردها بعضاً منها والتي تم استخدامها في هذا البحث [8] [15] [16]:

1- دالة السيغمويد اللوغاريتمية Log-Sigmoid Transfer Function: يجعل هذا التابع قيم الخرج

محصورة بين (0) و (1) بشكل انسيابي.

2- دالة السيغمويد لظل الزاوية Tan-Sigmoid Transfer Function: يجعل هذا التابع قيم الخرج بين (1)

و (-1).

3- الدالة الخطية Linear Transfer Function: يجعل هذا التابع قيم المخرجات بين (0) و (1).

ثانياً- مرحلة الانتشار العكسي للخطأ

في هذه المرحلة يتم مقارنة الخرج المحسوب مع الخرج الفعلي لتحديد قيمة الخطأ [14] [11]، الشكل (3).

تُستعمل هذه الأخطاء مداخل لوصلات التغذية العكسية، حيث تنتشر أخطاء الخرج النهائي في الاتجاه الخلفي طبقة

بعد أخرى مع القيام بتعديل أو تصحيح لأوزان الطبقة الموافقة بطريقة تكرارية. تتكرر العملية مرات عديدة لكل نموذج

في مجموعة التدريب حتى يتقارب الخطأ الكلي إلى قيمة صغرى، أو حتى الوصول إلى عدد محدد من مرات التكرار

[11].

يُعرّف متوسط خطأ النظام E_{tot} كمتوسط أخطاء الخرج عبر كل أخطاء نماذج التدريب E_p كما يلي [16]:

$$E_{tot} = \frac{1}{P} \sum_{p=1}^P E^p = \frac{1}{2P} \sum_{k=1}^m (t_k^p - z_k^p)^2 \dots \dots \dots (3)$$


$$E^p = \frac{1}{2} \sum_{k=1}^m (t_k^p - z_k^p)^2 \dots \dots \dots (4)$$

حيث: p حجم مجموعة التدريب.

t_k^p الخرج المأمول للوحدة k في طبقة الخرج.

z_k^p الخرج المحسوب للوحدة k في طبقة الخرج.

E^p مربع الخطأ لنموذج دخل P .



الشكل (3) شبكة عصبية ذات انتشار عكسي للخطأ بثلاث طبقات

إن خطأ النموذج سينخفض إذا انخفض خطأ كل نموذج تدريب E^P ، ويمكن أن يُنجز ذلك بتعديل الأوزان تعديلاً متناسباً مع تناقص قيمة الخطأ.

$$\Delta W = -\eta \frac{\partial E^P}{\partial W} \dots \dots \dots (5)$$

حيث: η عامل التعلیم الثابت.
يُعطى تدرج خطأ النظام بالمعادلة:

$$\frac{\partial E_{tot}}{\partial W} = \frac{1}{P} \sum_{P=1}^P \frac{\partial E^P}{\partial W} \dots \dots \dots (6)$$

يتم تحديث الأوزان وعامل الانحياز كما يلي:

$$W_{(new)} = W_{(old)} + \Delta W \dots \dots \dots (7)$$

$$b_{(new)} = b_{(old)} + \Delta b \dots \dots \dots (8)$$

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

النتائج والمناقشة:

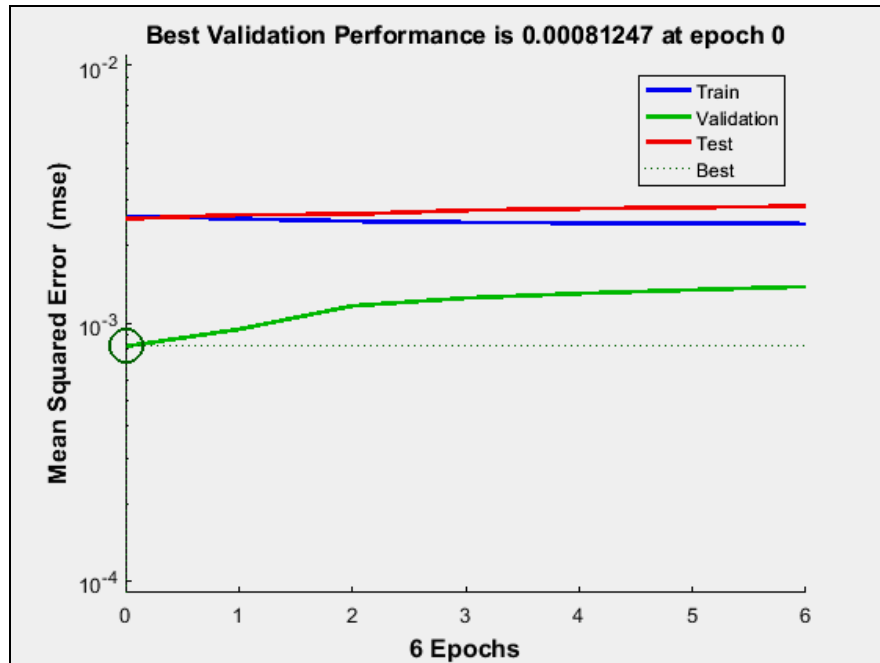
1- إدخال البيانات وبناء الشبكة العصبية

بغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية، أُدخلت البيانات المتوافرة لمحطة حماة للأعوام (1957-1991)، باستثناء بيانات الأعوام (1989-1991) والتي استُخدمت لاختبار الشبكة على بيانات لم تُدرّب عليها، على شكل مصفوفة مكونة من ثلاثة صفوف تمثل درجة حرارة الهواء والرطوبة النسبية وسرعة الرياح و 384 عموداً، وأدخلت البيانات على شكل مصفوفة مكونة من صف واحد تمثل قيم التبخر الشهري المُقاسة و 384 عموداً. شكّلت الشبكة العصبية الصناعية متضمنةً طبقة المُدخلات المكونة من ثلاثة عصبونات تمثل درجة حرارة الهواء والرطوبة النسبية وسرعة الرياح، وطبقة المخرجات المكونة من عصبون واحد يمثل التبخر الشهري، وحُدّد عدد

0.0592	0.0436	0.0479	0.0492	3-9-1
0.0541	0.0542	0.0497	0.051	3-10-1
0.0586	0.06	0.0458	0.0502	3-11-1
0.0446	0.0447	0.0521	0.05	3-12-1
0.0608	0.052	0.05	0.052	3-13-1
0.0388	0.0375	0.0522	0.0483	3-14-1
0.0492	0.0377	0.0535	0.0509	3-15-1
0.0379	0.0353	0.0537	0.0494	3-16-1

الجدول (2) أداء الشبكة العصبية الصناعية عند استخدام عدة توابع تفعيل

All (RMSE)	طبقة الخرج	الطبقة الخفية
0.0483	Tansig	Tansig
0.148	Logsig	Tansig
0.0488	Purelin	Tansig
0.153	Logsig	Logsig
0.0499	Tansig	Logsig
0.0521	Purelin	Logsig



الشكل (5) أداء الشبكة العصبية الصناعية للمجموعات الثلاث

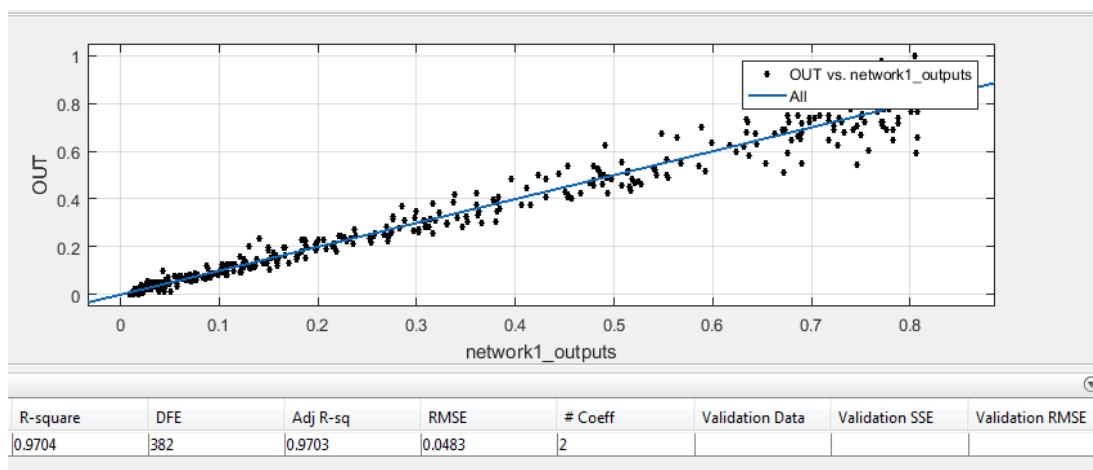
3- تقويم أداء الشبكة العصبية الصناعية المقترحة

تم تقويم أداء الشبكة العصبية المقترحة من خلال مقارنة النتائج التي تم الحصول عليها من النموذج مع القيم الهدف لكل من مجموعة التدريب والاختبار والتحقق، وذلك عن طريق أداة *curve fitting tool* في الماتلاب، باستخدام قيم معامل التحديد R^2 وقيم جذر متوسط مربع الخطأ *RMSE*. توضح الأشكال (6) و (7) و (8) و (9) النتائج باستخدام أداة *curve fitting*. و يوضح الجدول (3) نتائج المقارنة من خلال قيم *RMSE* للبيانات المقيسة وقيم *RMSE* بعد رد التقييس وقيم R^2 .

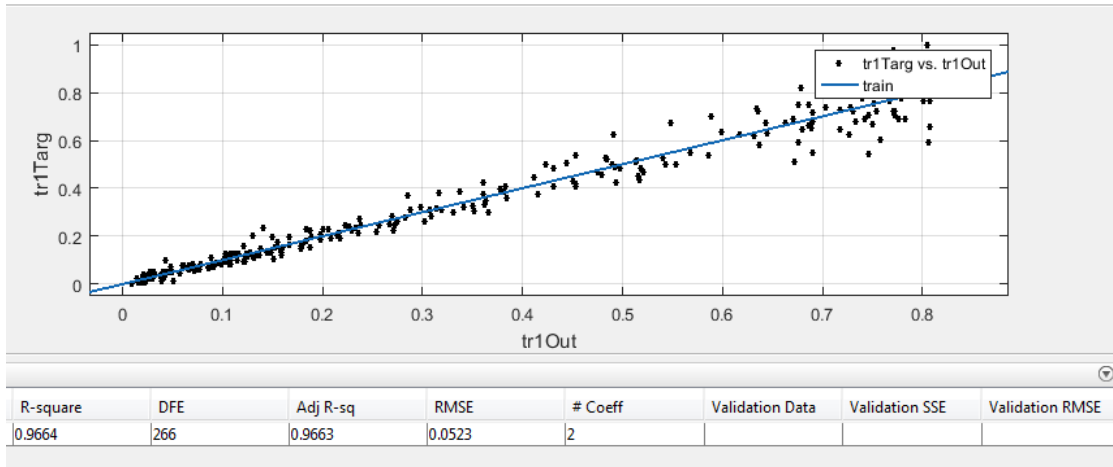
هذا وتم اختبار أداء نموذج الشبكة العصبية من خلال القيام بعملية *SIMULATE* للتنبؤ بالتبخر لمُدخلات لم تتدرب عليها الشبكة من قبل، للأعوام (1989-1991)، حيث تم التنبؤ لثلاث سنوات وسنتين وسنة وثلاثة أشهر. وكانت نتائج التنبؤ مرضية لثلاثة أشهر، حيث بلغت قيمة *RMSE* لثلاثة أشهر 5.64 مم/شهر. يبين الجدول (4) قيم *RMSE* للتنبؤ بالتبخر للفترات السابقة. يبين الجدول (5) قيم التبخر الفعلية وقيم التبخر المحسوبة من الشبكة للسنوات الثلاث (1989-1991) والفرق بين هذه القيم.

الجدول (3) قيم *RMSE* وقيم R^2 نتيجة المقارنة بين القيم المحسوبة بالنموذج والقيم الهدف

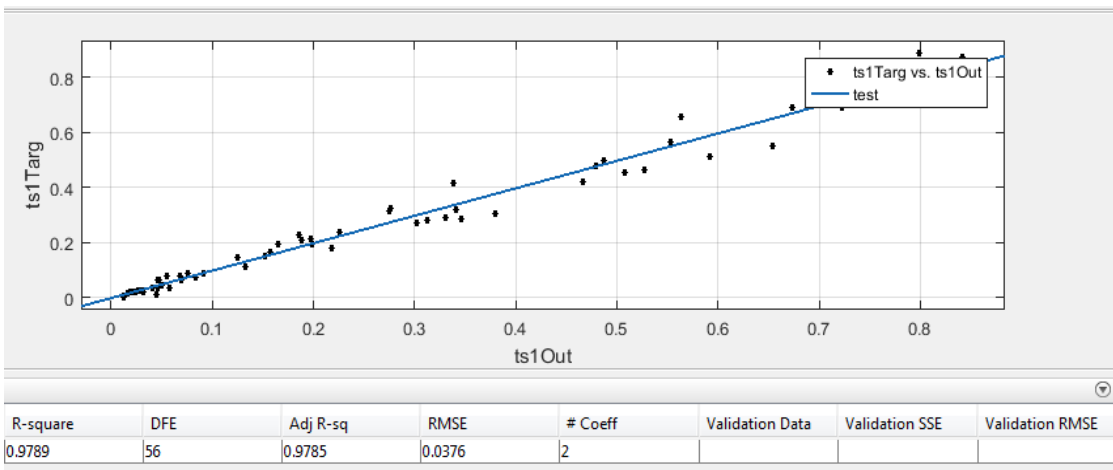
R^2	<i>RMSE</i> بعد رد التقييس (mm/month)	<i>RMSE</i> المقيس	المجموعة
0.9664	23,26	0.0523	مجموعة التدريب
0.9789	16.53	0.0376	مجموعة الاختبار
0.981	17.05	0.0388	مجموعة التحقق
0.9704	21.5	0.0483	المجموعات الثلاث




الشكل (6) نتائج *curve fitting tool* لكافة البيانات



الشكل (7) نتائج curve fitting tool لمجموعة التدريب



الشكل (8) نتائج curve fitting tool لمجموعة الاختبار



الشكل (9) نتائج curve fitting tool لمجموعة التحقيق

الجدول (4) قيم RMSE للتنبؤ بالتبخر لفترات مختلفة

فترة التنبؤ	RMSE (mm/month)
ثلاثة أشهر	5.64
سنة (1989)	18.83
سنتين (1989-1990)	27.15
ثلاث سنوات (1989-1991)	27.22

الجدول (5) قيم التبخر الفعلية والقيم المحسوبة من الشبكة للسنوات (1989-1991)

التاريخ	قيم التبخر الفعلية (mm/month)	قيم التبخر المحسوبة (mm/month)	الفرق بين القيمتين (mm/month)	نسبة الفرق بين القيمتين %
1989/1	37.2	30.17	7.03	18.9
1989/2	56	55.09	0.91	1.625
1989/3	102.3	95.57	6.73	6.58
1989/4	168	149.76	18.24	10.86
1989/5	251.1	237.24	13.86	5.52
1989/6	363	318.17	44.83	12.35
1989/7	409.2	375.21	33.99	8.3
1989/8	362.7	363.14	-0.44	-0.12
1989/9	264	259.4	4.6	1.74
1989/10	161.2	141.62	19.58	12.15
1989/11	84	76.05	7.95	9.46
1989/12	27.9	29.75	-1.85	-6.63
1990/1	43.4	27.86	15.54	35.8
1990/2	58.8	55.32	3.48	5.92
1990/3	127.1	89.7	37.4	29.42
1990/4	210	149.45	60.55	28.83
1990/5	297.6	242.96	54.64	18.36
1990/6	369	339.47	29.53	8
1990/7	458.8	407.01	51.79	11.29
1990/8	378.2	375.54	2.66	0.7
1990/9	243	242.44	0.56	0.23
1990/10	186	154.11	31.89	17.14
1990/11	96	72.94	23.06	24.02

11.52	5	38.4	43.4	1990/12
11.39	3.53	27.47	31	1991/1
4.93	2.07	39.93	42	1991/2
3	1.77	57.13	58.9	1991/3
40.85	73.53	106.47	180	1991/4
15.63	33.43	180.47	213.9	1991/5
-14.32	-43.82	349.82	306	1991/6
4.94	19	365.4	384.4	1991/7
1.42	5.24	363.66	368.9	1991/8
0.0084	0.02	236.98	237	1991/9
-5.81	-7.75	141.05	133.3	1991/10
-15.5	-8.37	62.37	54	1991/11
2.72	0.76	27.14	27.9	1991/12

الاستنتاجات والتوصيات:

يمكن اعتماد الشبكة العصبية الصناعية ذات التغذية الأمامية والانتشار العكسي للخطأ وذات الهيكلية (1-14-3) كطريقة للتنبؤ بالتبخر الشهري في منطقة حماة اعتماداً على قيم درجة الحرارة والرطوبة النسبية وسرعة الرياح بقيمة RMSE تساوي 21.5mm وقيمة R^2 مساوية 0.97.

بمقارنة القيم المحسوبة من النموذج مع القيم المأمولة، باستخدام أداة curve fitting tool، كانت النتائج جيدة حيث بلغت قيمة RMSE لمجموعة الاختبار 16.53 مم/شهر.

باستخدام عملية SIMULATE لبيانات لم تتدرب عليها الشبكة، كانت نتائج التنبؤ بالتبخر مرضية بقيمة 5,64 مم/شهر لـ RMSE وذلك لفترة ثلاثة أشهر.

واعتماداً على نتائج البحث نوصي بما يلي:

بناء نموذج للتنبؤ بالتبخر باستخدام نظام هجين من الشبكات العصبية الصناعية والخوارزميات الجينية.

للتوسع باستخدام الشبكات العصبية الصناعية لدراسة العديد من المسائل المتنوعة بغرض تحقيق الإدارة المثلى للموارد المائية.

المراجع:

- [1] DALKILIC, Y.; OKKAN, U. and BAYKAN, N. *Comparison of Different Ann Approaches in Daily Pan Evaporation Prediction*. Journal of Water Resource and Protection, Vol. 6, 2014, 319-326.
- [2] ESLAMIAN, S. S.; GOHARI, S. A.; BIABANAKI, M. and MALEKIAN, R. *Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines*. Journal of Applied Sciences, Vol. 8, 2008, 3497-3502.

[3] GOAL, A. *ANN Based Modeling for Prediction of Evaporation in Reservoirs*. Vol. 22, No. 4, November, 2009, 351-358.

[4] KUMAR, P; KUMAR, D; JAIPAL, A; and TIWARI, K. *Evaporation Estimation Using Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Techniques*. Pakistan Journal of Meteorology, Vol. 8, No. 16, Jan, 2012, 81-88.

[5] SINGH et al. *Comparison of Measured and Predicted Evapotranspiration Using Artificial Neural Network Model*. J. Acad. Indus. Res. Vol. 1(12), May, 2013, 816-819.

[6] SAAD SH. SAMMEN. *Forecasting of Evaporation from HEMREN Reservoir by Using Artificial Neural Network*. Diyala Journal of Engineering Sciences, Vol. 6, No. 4, December, 2013, 38-53.

[7] ALI, J; SARAF, S. *Evaporation Modeling by Using Artificial Neural Network and Multiple Linear Regression Technique*. International Journal of Agricultural and Food Science, 5(4), 2015, 125-133.

[8] عمار، غطفان؛ حيدر، بادية. *أ نموذج شبكة عصبية صناعية للتنبؤ بالتبخّر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة الشهرية*. مجلة جامعة تشرين للبحوث والدراسات العلمية. المجلد (37)، العدد (1)، 2015، 55-70.

[9] PALLAVI, K.; RAJEEV, S. *Prediction Reservoir Evaporation Using Artificial Neural Network*. International Journal of Innovative Research in Science Engineering and Technology, Vol. 5, No. 4, April, 2016, 5851-5857.

[10] KHOSHHAL, J.; MOKARRAM, M. *Model for Prediction of Evapotranspiration Using MLP Neural Network*. International Journal of Environmental Sciences, Vol. 3, No. 3, November, 2012, 1000-1009.

[11] ZHANG, T.; YOU, X. *Improvement Of The Training and Normalization Method of Artificial Neural Network in The Prediction of Indoor Environment*. Procedia Engineering, 121, 2015, 1245-1251.

[12] SANTOS, R.; RUPP, M. BONZI, S.; FILETI, A.M. *Comparison Between Multilayer Feedforward Neural Networks and a Radial Basis Function Network to Detect and Locate Leaks in Pipelines Transporting Gas*. Chemical Engineering Transactions, vol. 32, 2013, 1375-1380.

[13] SHIRGURE, P.S. *Evaporation Modeling with Artificial Neural Network: A Review*. Scientific Journal of Review, 2(2), February, 2013, 73-84.

[14] SINGH, S.; JAIN, S.; BARDOSSY, A. *Training of Artificial Neural Networks Using Information-Rich Data*. Hydrology, 1, July, 2014, 40-62.

[15] عمار، غطفان؛ حيدر، بادية. *تقدير التبخّر - نتج المرجعي الشهري في منطقة صافيتا باستخدام الشبكة العصبية الصناعية*. مجلة جامعة تشرين للبحوث والدراسات العلمية. المجلد (35)، العدد (4)، 2013، 27-43.

[16] الكرمو، أحمد. *الشبكات العصبية الصناعية بين النظرية والتطبيق*، الجزء الأول. المركز العربي للتعريب والترجمة والتأليف والنشر بدمشق، 2001، 351.