

## Artificial Neural Network Model to Estimat Daily Evaporation in AL-BASEL Reservoir Station

Dr. Ghatfan Abdalkareem Ammar<sup>\*</sup>

Dr. Sharif Badr Hayek<sup>†</sup>

Mais Mayassah<sup>‡</sup>

(Received 27 / 5 / 2018. Accepted 10 / 2 / 2019)

### □ ABSTRACT □

Evaporation process is one of the basic components of the hydrological cycle, and the exact estimation of evaporation has great importance in water resources systems management and water balance studies. This research aims to study the efficiency of using artificial neural networks (ANNs) in estimation of daily evaporation from AL-BASEL reservoir located in Tartous by using daily meteorological data. The mathematical model was built based on four meteorological parameters as the network inputs (i.e. the mean air temperature, mean relative humidity, solar radiation, mean wind speed), and the data of daily evaporation, which measured from the American pan class A used as the network output for checking its performance accuracy. A multilayer artificial neural network has been built by using error Back-propagation algorithm, and the number of hidden layers was selected and the number of neurons and activation functions which used in each layer of them. The study found that the artificial neural network ANN of structure (4-28-1) able to predict the daily evaporation with high accuracy in the study area as the value of the correlation coefficient is (0.844), and the value of the root mean square error is (1.15 mm/day) of testing data set. This clearly indicates the possibility of using ANN technique of error back-propagation for estimating the daily evaporation.

**Keywords:** Evaporation, Artificial Neural Networks, Back-propagation, Prediction.

---

<sup>\*</sup> Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

<sup>†</sup> Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

<sup>‡</sup> Postgraduate student, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria, [mayassah.mais@gmail.com](mailto:mayassah.mais@gmail.com).

## أنموذج شبكة عصبية صناعية لتقدير التبخر اليومي في محطة سد الباسل

د. غطفان عبد الكريم عمار \*

د. شريف بدر حايك †

ميس مياسة ‡

(تاريخ الإيداع 27 / 5 / 2018. قُبِلَ للنشر في 10 / 2 / 2019)

### □ ملخص □

تُشكّل عملية التبخر إحدى المكونات الأساسية للدورة الهيدرولوجية، والتقدير الدقيق للتبخر له أهمية كبيرة في إدارة أنظمة الموارد المائية ودراسات الموازنة المائية. يهدف هذا البحث إلى دراسة كفاءة استخدام الشبكات العصبية الصناعية (Artificial Neural Networks) في تقدير التبخر اليومي في محطة سد الباسل الواقعة في محافظة طرطوس باعتماد بيانات مناخية يومية. حيث بُني الأنموذج الرياضي باعتماد أربعة بارامترات جوية كمدخلات للشبكة العصبية الصناعية، وهي درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي، سرعة الرياح الوسطية، في حين استُخدمت قيم التبخر اليومي المقيسة من حوض التبخر الأمريكي صنف A كمخرجات مأمولة للشبكة المقترحة لغرض التحقق من صحة أدائها. تمّ بناء شبكة عصبية صناعية متعددة الطبقات باستخدام خوارزمية الانتشار العكسي للخطأ، وحُدّد عدد الطبقات الخفية وعدد العصبونات ودوال التفعيل المستخدمة في كل طبقة منها. توصلت الدراسة إلى أن الشبكة العصبية الصناعية ANN ذات الهيكلية (1-28-4) قادرة على التنبؤ بالتبخر اليومي بدقة عالية في منطقة الدراسة حيث بلغت قيمة معامل الارتباط (0.844)، وقيمة جذر متوسط مربع الخطأ (1.15 mm/day) وذلك في مرحلة الاختبار. ممّا يبيّن فعالية تقانة الشبكات العصبية الصناعية ذات الانتشار العكسي للخطأ في تقدير التبخر اليومي.

الكلمات المفتاحية: التبخر، الشبكات العصبية الصناعية، الانتشار العكسي، التنبؤ.

\* أستاذ في قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

† أستاذ في قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

‡ طالبة ماجستير في قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية سورية

. [mayassah.mais@gmail.com](mailto:mayassah.mais@gmail.com)

## مُقَدِّمَةٌ

تعدُّ المياه أحد أهم عناصر البيئة، كما أنَّها مورد اقتصادي مهم رغم محدوديته لذلك يجب المحافظة عليها من الشُّح في أوقات الجفاف واستثمارها على نطاق واسع للمساهمة في عملية التنمية الاقتصادية، حيث إنَّ الاستغلال الأمثل للموارد المائية يُسهم في تحقيق التوازن بين النمو السكاني المتصاعد والأمن الغذائي [1].

تُشكِّل عملية التَّبخر إحدى المكونات الأساسية للدورة الهيدرولوجية، حيث تتعرَّض المياه المتجمَّعة في المحيطات والأنهار والتجمعات المائية فوق اليابسة للتَّبخر. تُمثِّل فوَّاد التَّبخر جزءاً كبيراً من الموازنة المائية للبحيرات أو الخزانات [2]، ومن ثَمَّ فإنَّ التَّقدير الدقيق للتَّبخر المُحتمل له أهمية كبيرة في إدارة أنظمة الموارد المائية ودراسات الموازنة المائية في المستجمعات المائية وتصميم الخزانات وأنظمة الرِّي [3]، حيث استُخدمت طرائق مباشرة وغير مباشرة تجريبية لتقدير كمية المياه الضائعة من المسطحات المائية الحرة [4]. إذ يعتمد معدل التَّبخر على عدد من العوامل الجوية مثل درجة حرارة الهواء، الرطوبة النسبية، الإشعاع الشمسي، سرعة الرياح وإلى حد ما الضغط الجوي [5].

لقد قام العديد من الباحثين بدراسات لتقدير التَّبخر، منهم من قام بدراسة العلاقة بين التَّبخر والبارامترات المقيسة في محطات الأرصاد الجوية، ومنهم من استخدم العلاقات التجريبية للتنبؤ وتقدير التَّبخر اعتماداً على بيانات مناخية مختلفة. فقد اختبر (Dawson and Wilby, 1998) طريقة الشبكات العصبية الصناعية للنمذجة في مجال الموارد المائية وكشفت النتائج أنَّ النهج المُعتمَد في تقدير البارامترات الهيدرولوجية يعطي تنبؤات أفضل [6].

بينما طوَّر وطبَّق (Trajkovic et al., 2003) نموذج الشبكة العصبية للانحدار المعمَّم متضمناً الخوارزمية الجينية من أجل تقدير وحساب التَّبخر من حوض التَّبخر PE والتَّبخر-نتح المرجعي ET0 [7].

استخدم (Terzi et al., 2005) نماذج ANN لنمذجة التَّبخر اليومي المحسوب من حوض التَّبخر من بحيرة Eğirdir في الجزء الجنوبي الغربي من تركيا [8].

اقترح (Keskin and Terzi, 2006) نماذج من الشبكات العصبية الصناعية ANN كنهج بديل لتقدير التَّبخر من بحيرة Eirdir. هدفت الدراسة إلى تطوير نماذج ANN لتقدير التَّبخر اليومي بالاعتماد على بيانات الأرصاد الجوية المقيسة، ومقارنة نتائج هذه النماذج مع نتائج نموذج بنمان، بالإضافة إلى تقييم قدرة الشبكة العصبية الصناعية على تقدير قيم التَّبخر بمقارنة نتائجها مع قيم حوض التَّبخر. تضمنت بيانات الأرصاد الجوية المستخدمة القيم اليومية المقيسة لكل من درجة حرارة الهواء والماء، ساعات سطوع الشمس، الإشعاع الشمسي، الضغط الجوي، الرطوبة النسبية وسرعة الرياح. أظهرت النتائج أن نماذج الشبكة العصبية الصناعية لتقدير التَّبخر من بحيرة Eirdir توافق قياسات التَّبخر اليومية وذلك بالمقارنة مع نموذج بنمان [9].

كما طبَّق (Zanetti et al., in 2007) نماذج ANN للتنبؤ بالتَّبخر-نتح المرجعي في ولاية (Rio de Janeiro) ريو دي جانيرو في البرازيل وذلك بالاعتماد على درجات الحرارة الصغرى والعظمى [10].

استخدم (Goel, 2009) نماذج الشبكات العصبية الصناعية ANN ونماذج الانحدار الخطي LR لتقدير التَّبخر اليومي من الخزان وأظهرت النتائج نجاحاً للتنبؤ بالتَّبخر [11].

قام (Chuang et al., 2010) بتقويم قدرة ثلاثة نماذج للانحدار الخطي المحلي LLR، آلة الدَّعم الموجه Support Vector Machine (SVM) والشبكات العصبية الصناعية ANN لتقدير التَّبخر من الخزانات [12].

اختبر (Hormozi et al., 2012) نموذج شبكة عصبية صناعية لتقدير التبخر في ثلاث محطات مناخية وهي Dezful Ahvaz. Abadan واقعة في إقليم خوزستان جنوب غرب إيران وذلك بالاعتماد على ست عوامل مناخية (درجة الحرارة الصغرى والعظمى، الرطوبة النسبية الصغرى والعظمى، ساعات السطوح الشمسي وسرعة الرياح). وأجرى أيضاً دراسة للمعامل الأكثر تأثيراً في تقدير التبخر باستخدام هذه التقنية. أشارت نتائج الدراسة إلى أن درجة الحرارة العظمى كان لها التأثير الأكبر على أداء الشبكة في محطتي Dezful & Ahavaz، بينما كان لدرجة الحرارة الصغرى، ومن ثم العظمى التأثير الأكبر في محطة Abadan [13].

تحقق (Kisi, 2013), (Guo et al., 2011) من تطبيق نماذج المنطق الضبابي LS-SVR لتقدير التبخر-تحت المرجعي اليومي للمحصول في موقعين في جنوب ولاية كاليفورنيا حيث اشتملت الدراسة على الأساليب التجريبية (بريستلي تايلور، هارجريفز وطرائق رينشي)، واتبعت نمط التغذية الأمامية لنماذج ANNs للمقارنة مع نماذج LS-SVR [14,15].

يتبين من استعراض الدراسات السابقة الاهتمام الكبير في إيجاد نماذج قادرة على التنبؤ بقيم التبخر كونه يشكل أحد المكونات الأساسية للدورة الهيدرولوجية، ولما له من تأثير مهم على عملية الموازنة المائية، حيث وجد في هذه الدراسات:

- ❖ تفوق الشبكات العصبية الصناعية وتقانات الذكاء الصناعي Artificial Intelligence على الطرائق الرياضية والإحصائية الأخرى المعتمدة في تقدير التبخر.
- ❖ تطبيق تقانات الذكاء الصناعي مؤخراً في الدراسات الحديثة للتنبؤ بالتبخر حيث أعطت نتائج أدق بالمقارنة مع النماذج التجريبية.
- ❖ فعالية نماذج الشبكات العصبية الصناعية ذات الدوال قطرية الأسس في تقدير التبخر من حيث سهولة البناء والسرعة العالية في التدريب وتفوقها على شبكة الانتشار العكسي.
- ❖ أجريت بعض الدراسات في سورية لتقدير التبخر باستخدام نماذج (ANNs)، لكن لم يتم إعداد أي نموذج رياضي لمنطقة البحث محطة سد الباسل.

### أهمية البحث وأهدافه :

تبرز أهمية التقدير الدقيق للتبخر في تخطيط وتنمية الموارد المائية ولعلاقته بتصميم شبكات الري وإدارة النظم الهيدرولوجية والهيدروليكية والزراعية.

يهدف البحث إلى التنبؤ بالتبخر اليومي في محطة سد الباسل عن طريق بناء نموذج رياضي بالاعتماد على تقانة الشبكات العصبية الصناعية، وباستخدام القيم اليومية للعوامل المناخية: درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي وسرعة الرياح الوسطية.

### موقع منطقة البحث

يقع سد الشهيد باسل الأسد على نهر الأبرش في محافظة طرطوس، وتم بناؤه عند قرية اليازبية ويبعد 7km عن مدينة صافيتا، و20km جنوب شرق مدينة طرطوس (الشكل 1)، و(الشكل 2). تقع محطة سد الباسل جنوب منطقة صافيتا في محافظة طرطوس، وقد جمعت البيانات من محطة سد الباسل المناخية الواقعة على خط عرض (34°76'28") شمالاً، وعلى خط طول (36°08'66") شرقاً، وترتفع عن مستوى سطح البحر 141م كما يبين الشكل (3).



الشكل 1. موقع بحيرة سد الباسل.



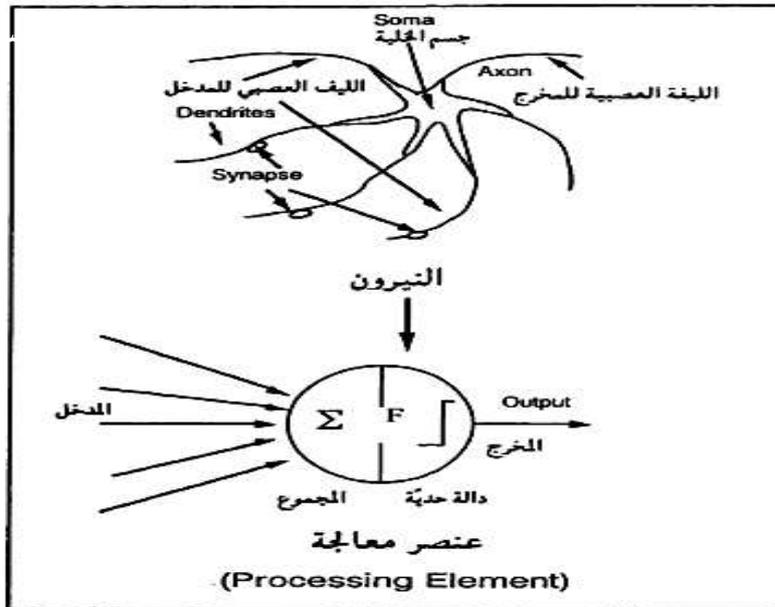
الشكل 2. سد الباسل في طرطوس.



الشكل 3. صورة فضائية للموقع العام لمنطقة البحث.

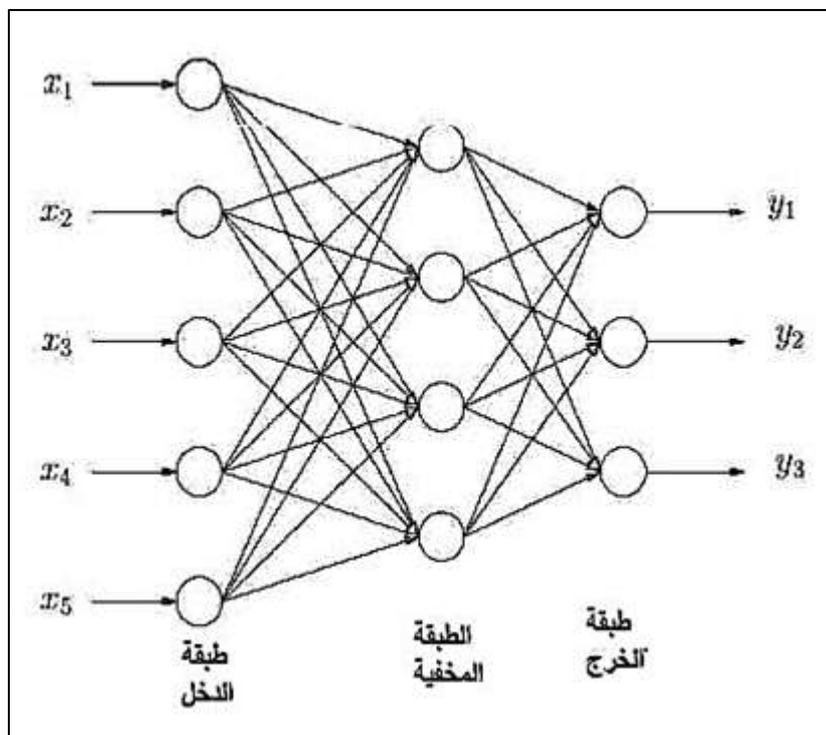
### طرائق البحث ومواده

تعتمد هذه الدراسة على بناء أنموذج رياضي للشبكة العصبية الصناعية، التي تُعرّف بأنها نظام حاسوبي يُحاكي بآلية عمله وشكله ومضمونه الشبكة العصبية الحيوية الموجودة في دماغ الإنسان كما في الشكل (4)، حيث إنّها تكتسب المعرفة بالتدريب، وتُخزّن هذه المعرفة باستخدام قوى وصل داخل العصبونات تُسمّى الأوزان التشابكية. نستطيع تدريب الشبكة لحل مسألة ما عن طريق ضبط قيم الأوزان التشابكية بين العناصر [16].



الشكل 4. التمثيل المبسط للخلية العصبية والنموذج الحسابي المكافئ [17].

تتكوّن الشبكات العصبية ذات التغذية الأمامية من عدة وحدات معالجة هي الخلايا العصبية، وتُرتب كل شبكة بشكل طبقات من العصبونات الصناعية، طبقة دخل وطبقة خرج يتوضع بينهما طبقة واحدة أو أكثر من الطبقات الخفية الشكل (5).



الشكل 5. الشبكة العصبية الصناعية ذات التغذية الأمامية المتعددة الطبقات.

تُبيّن الخطوات الآتية كيفية معالجة المعلومات من خلال مكونات الشبكة العصبية الصناعية [18].

- تتم معالجة المعلومات في عناصر معالجة بسيطة تُدعى العصبونات.
- تمرّ الإشارات بين العصبونات عبر خطوط ربط.
- يُرفق كل خط ربط بوزن معين (قيمة عددية) ويُضرب بالإشارات الداخلة إلى العصبون.
- يُطبّق على كل عصبون تابع تنشيط (عادةً غير خطّي) إلى داخل الشبكة (مجموع إشارات الدّخل الموزونة) ليُحدّد إشارة الخرج الناجمة عنها.

يُفصّد بالتغذية الأمامية للشبكات انتشار البيانات من طبقة لأخرى بشكل متسلسل وفق مسار أمامي فقط؛ أي من طبقة الدّخل إلى الطبقة الخفية الأولى ومنها إلى الثانية، وهكذا حتى الوصول إلى طبقة الخرج، ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ (Artificial Neural Network of Error Back Propagation). وتُسمى بشبكة الانتشار العكسي للخطأ، لأنّ كل قيمة خرج يتم طرحها من القيمة المقابلة لها في شعاع الهدف وناتج الطرح يُمثّل الخطأ، يُستخدم هذا الخطأ لضبط أوزان الشبكة عن طريق نشر هذا الخطأ وفق مسار عكسي لمرحلة حساب الخرج؛ أي من طبقة الخرج عبر الطبقات الخفية إلى طبقة الدّخل [19].

وتُورد فيما يلي آلية عمل الشبكات العصبية الصناعية ذات الانتشار العكسي للخطأ [20].

أولاً: مرحلة التغذية الأمامية (Feedforward)

يرتبط الخرج  $i^{k-1}$  للخلية العصبية (i) في الطبقة (k-1) لشبكة التغذية الأمامية مع الدّخل من الخلية العصبية z في الطبقة اللاحقة k بواسطة عامل تحميل حقيقي  $(w_{ji}^k)$ .

حيث: k: دليل الطبقة (k= I, II)؛ i: دليل الخلية في الطبقة (k-1)؛ z: دليل الخلية في الطبقة (k).  
لحساب الخرج  $j^k$  فإن الخلية العصبية z للطبقة k [k= I, II] يُنجز بالعملية الحسابية الآتية:

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

$$Y_j^0 = u_j$$

$$Y_j = Y_j^{II}$$

حيث: N: عدد الخلايا أو الوحدات في الطبقة k-1؛  $f^k$ : دالة التحويل (Transfer function)؛  $b_j$ : شعاع الانحياز.

ثانياً: مرحلة الانتشار العكسي للخطأ (Back Propagation of Error)

يتم احتساب الخطأ في وحدة المخرجات ومُعدّل مربع الخطأ (MSE) ومعامل تصحيح الخطأ ( $\delta$ ) وفق المعادلتين الآتيتين:

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

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

حيث: err: معدل مربع الخطأ في وحدة المخرجات؛  $Y_i$ : المخرجات المأمولة (Target)؛  $\delta$ : معامل تصحيح الخطأ (Delta).

ثالثاً: مرحلة تحديث الأوزان (Reinitialize Weights)

يتم تحديث الأوزان وعامل الانحياز كما هو معطى أدناه:

$$W_{(net)} = W_{(old)} + \Delta W \quad (4)$$

$$b_{(new)} = b_{(old)} + \Delta b \quad (5)$$

حيث:  $\Delta W$ : معامل تصحيح الوزن؛  $\Delta b$ : معامل تصحيح عامل الانحياز.

تصميم الشبكات العصبية يمرّ بنفس المراحل التي تتطلبها عملية النمذجة التقليدية، إذ يتضمّن المراحل التالية [21]:

1. اقتراح هيكلية الشبكة (البنية الهندسية) المناسبة (Transformation) وخوارزمية التعلّم المناسبة (Topology)
2. مرحلة التدريب (Training)
3. مرحلة التحقق وتشخيص الأخطاء إن وجدت (Validation)
4. مرحلة الاختبار والفحص (Testing)

يحتاج أسلوب الشبكات العصبية الصناعية لإجراء عملية تقييس للبيانات (Reinitialize Weights)، حيث يُنصح دائماً بمعايرة مدخلات ومخرجات الشبكة، وذلك لأجل أن تكون قيمها متقاربة أي ضمن مدى قصير لتقليل قيمة الخطأ بين نتائج الشبكة والنتائج المقيسة، كما أنّ القيم المُقيسة تجعل التدريب سريعاً وتُحسّن أداء الشبكة [22,23].  
توجد عدّة طرائق لإجراء عملية التقييس نذكر منها:

• طريقة (Kumar) [24]

$$p_{(norm)} = 0.5 \left[ \frac{(p-p_{mean})}{(p_{max}-p_{min})} \right] + 0.5 \quad (6)$$

• طريقة (AL-Hatem) [21]

$$p_{(norm)} = \left[ \frac{(p-p_{mean})}{p_{max}-p_{min}} \right] \quad (7)$$

حيث:  $p$ : القيم الأصلية؛  $p_{(norm)}$ : القيم المعدلة؛  $p_{(mean)}$ : معدّل القيم الداخلة؛  $p_{(min)}$ : أدنى قيمة داخلة؛  $p_{(max)}$ : أقصى قيمة داخلة.

اعتمدت هذه الدراسة على بيانات مناخية يومية لمحطة سد الباسل جُمعت من محطة سد الباسل المناخية في محافظة طرطوس بين عامي (2009-2015)، وتتضمن هذه البيانات 1473 قيمة يومية لكل من درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي وسرعة الرياح الوسطية بالإضافة إلى التبخر الإنثائي (Class A) حيث استخدم برنامج MINITAB لغرض التحليل الإحصائي لهذه البيانات.

استخدم برنامج MATLAB والأدوات الملحقة به (NN-Toolbox) لمحاكاة الشبكة العصبية الصناعية وتدريبها واختبارها. توجد معايير مختلفة للتحقق من الأداء الأفضل للشبكة العصبية، وفي هذه الدراسة تمّ استخدام معامل الارتباط R ومتوسط مربع الخطأ RMSE.

### النتائج والمناقشة

أجريت دراسة إحصائية للبيانات باستخدام برنامج MINITAB الذي يتميز بقدرته على معالجة المعطيات، وتم الحصول على قيم مقاييس الإحصاء الوصفي وهي:

المتوسط الحسابي (Mean)

الانحراف المعياري (Standard deviation)

التباين (Variance)

القيمة الصغرى (Minimum)

الوسيط (Median)

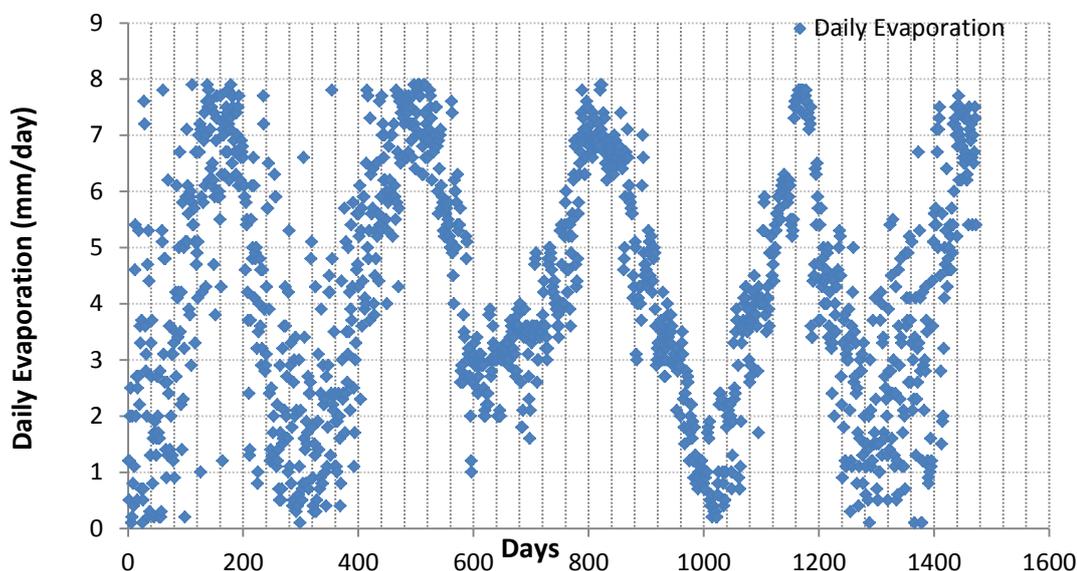
القيمة العظمى (Maximum)

وذلك لكل من درجة حرارة الهواء الوسطية  $T_{av}$ ، الرطوبة النسبية الوسطية  $RH_{av}$ ، الإشعاع الشمسي  $SH_{av}$ ، سرعة الرياح الوسطية  $WS_{av}$ ، التبخر  $E$  كما في الجدول رقم (1)، ويبين الشكل (6) قيم التبخر الإنثائي اليومي للعدد الكلي للبيانات المستخدمة في الدراسة.

الجدول (1): بعض المؤشرات الإحصائية للعوامل المناخية المستخدمة.

المؤشرات الإحصائية المتغيرات المناخية	المتوسط الحسابي	الانحراف المعياري	التباين	الوسيط	القيمة الصغرى	القيمة العظمى
درجة حرارة الهواء (C)	9.4201	6.130	37.575	19.050	5.900	32.450
الإشعاع الشمسي (h)	7.836	4.275	18.276	8.500	0.000	96.000

سرعة الرياح (mm/sec)	2.2557	1.6074	2.7903	1.6000	0.3000	13.0000
الرطوبة النسبية (%)	68.603	9.227	85.135	70.000	22.500	91.000
التبخّر (mm/day)	4.0712	2.1238	4.5106	3.9000	0.1000	7.9000



الشكل 6. بيانات التبخّر الإثنائي اليومي المستخدمة في الدراسة.

بغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية، أدخلت البيانات على شكل مصفوفة مكونة من أربعة صفوف تمثل درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي، سرعة الرياح الوسطية و1473 عموداً، كما أدخلت بيانات المخرجات لمجموعة التدريب على شكل مصفوفة مكونة من صف واحد يتضمن قيم التبخّر اليومي المقيسة، ثم قسّمت البيانات إلى ثلاث مجموعات للتدريب والتحقق والاختبار بنسبة 70% لمجموعة التدريب و15% لمجموعة التحقق و15% لمجموعة الاختبار، وذلك لقياس كفاءة الشبكة العصبية الصناعية وللتأكد إذا تمّ تدريب الشبكة بشكل صحيح.

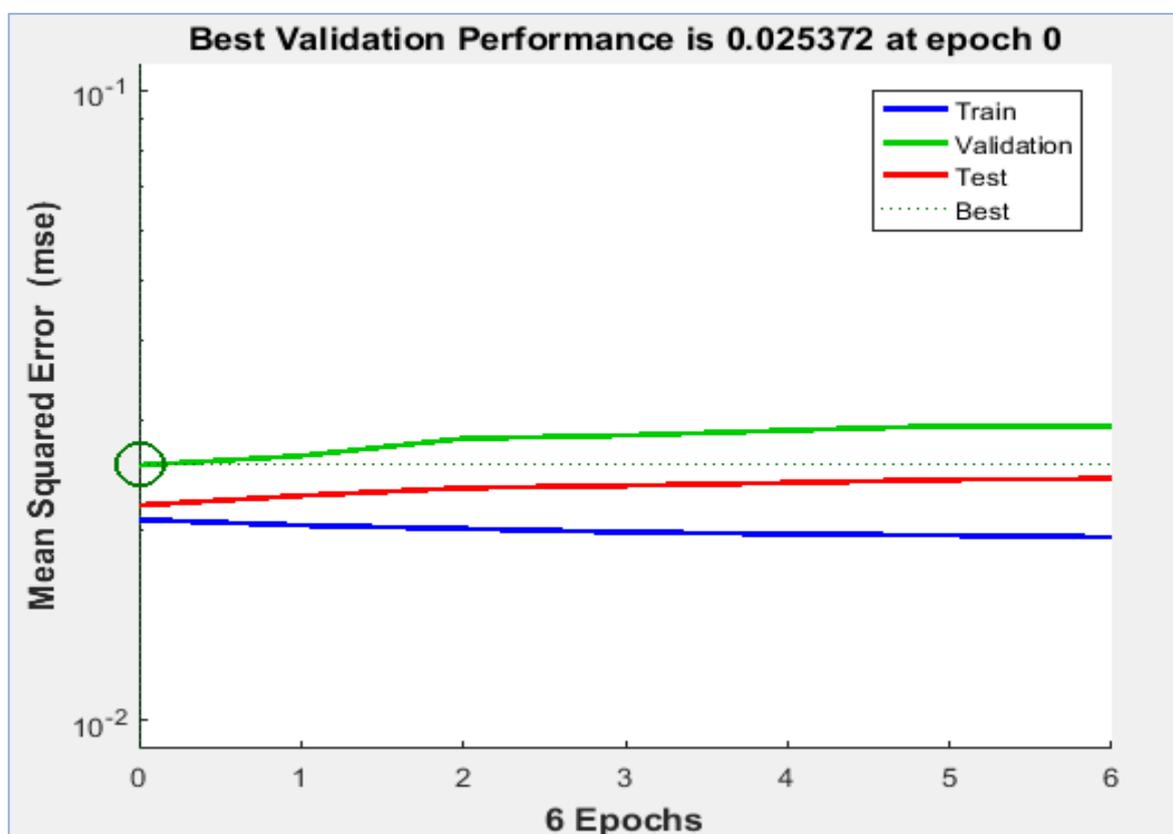
شكّلت الشبكة العصبية الصناعية بحيث تتضمن طبقة مدخلات مكونة من أربعة عصبونات تمثل درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي و سرعة الرياح الوسطية. وطبقة مخرجات مكونة من عصبون واحد يمثل التبخّر اليومي، في حين حدّد عدد العصبونات في الطبقة الخفية بالتجريب وذلك بتغيير عدد العصبونات في الطبقة الخفية مع تثبيت خوارزمية التدريب ودوال التفعيل وتقييم البيانات باستخدام إحدى طرائق التقييم حيث اعتمدنا في هذا البحث طريقة (Kumar)، ومن ثمّ تدريب الشبكة حتى الحصول على أقل قيمة لمتوسط مربع الخطأ لعدد ثابت من الدورات التكرارية مقداره 1000.

وقد تمّ التوصل إلى أن الشبكة العصبية الصناعية ذات الهيكلية (1-28-4) (4 عصبونات لطبقة المدخلات- 28 عصبون للطبقة الخفية- عصبون واحد لطبقة المخرجات) هي الشبكة الأفضل مع استخدام دالة تفعيل Transfer Function Tansigmoid في الطبقة الخفية وفي طبقة الخرج، وبالاعتماد على خوارزمية التعلم (Levenberg Marquardt (LM)).

الجدول (2): المعايير الإحصائية لنموذج الشبكة العصبية الصناعية الذي تم التوصل إليه.

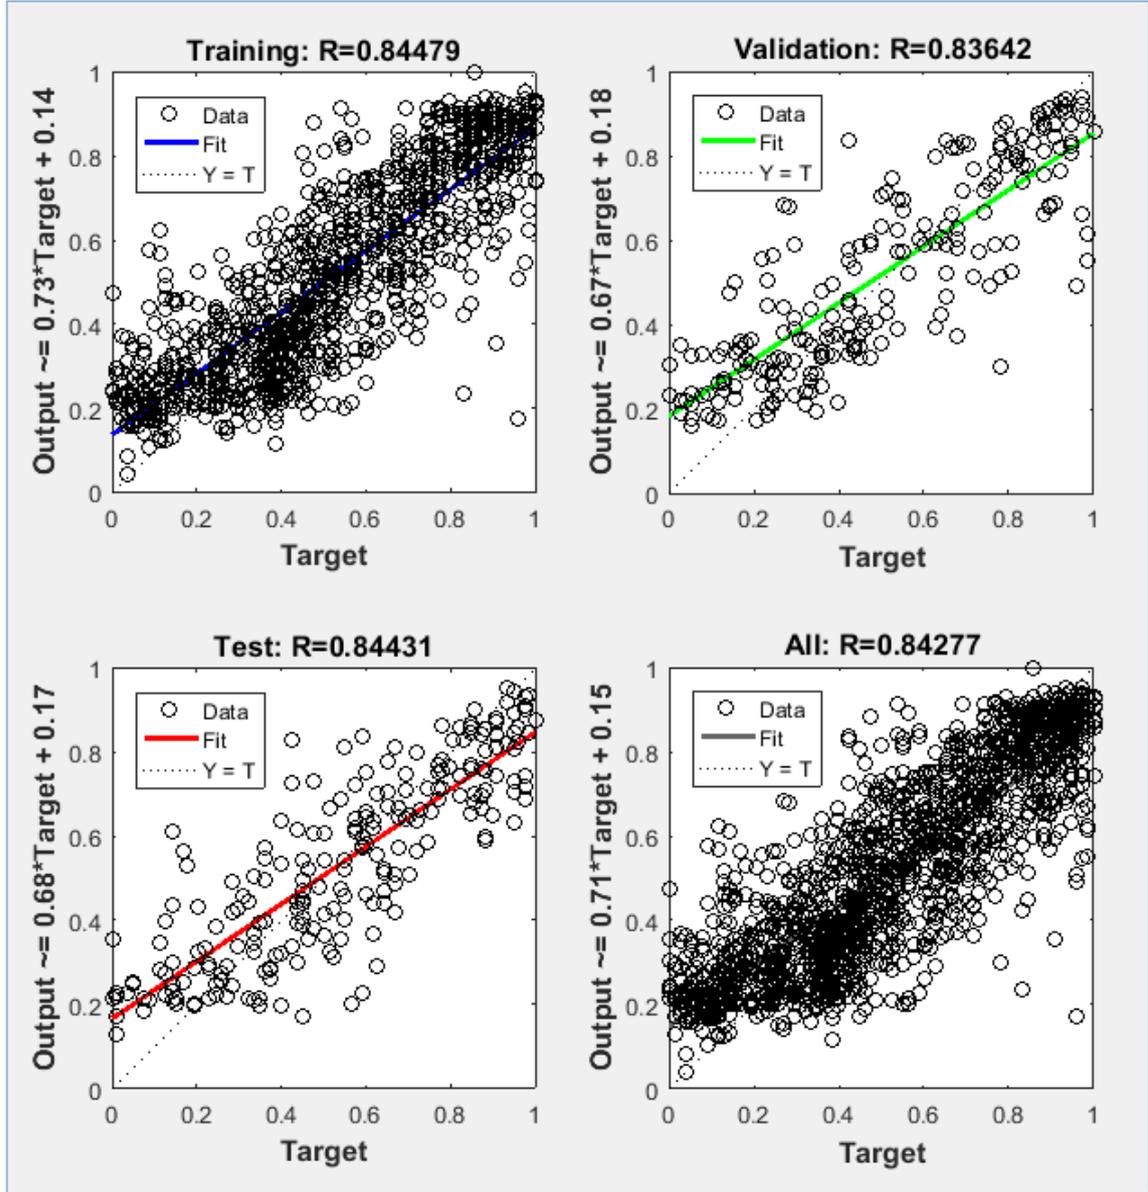
بنية الشبكة	دالة التفعيل في الطبقات الخفية	دالة التفعيل في طبقة الخرج	المعايير الإحصائية	كامل البيانات	مجموعة التدريب	مجموعة التحقق	مجموعة الاختبار
(4-28-1)	Tansig	Tansig	R	0.842	0.844	0.836	0.844
			RMSE	1.14	121.	1.24	1.15

يبين الشكل (7) أداء الشبكة العصبية الصناعية للمجموعات الثلاث حيث يظهر نقطة توقف التدريب لدورات تكرارية أقل عدداً من الدورات التكرارية في حال الاعتماد على مجموعة التدريب فقط وبمعدل متوسط مربع الخطأ 0.025372.



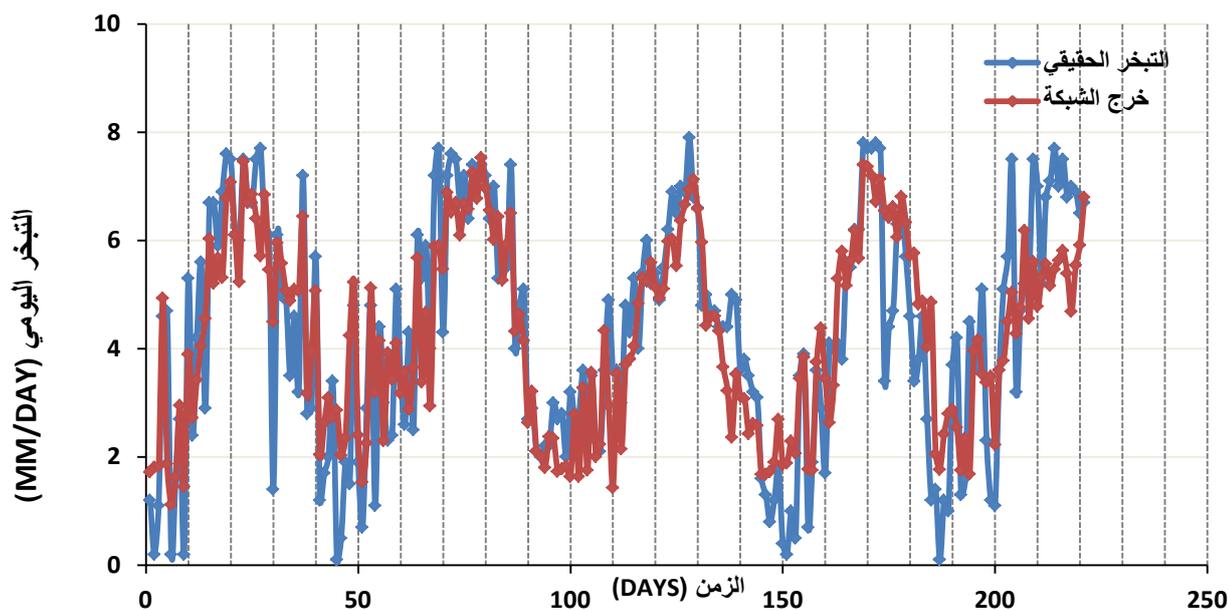
الشكل 7. أداء الشبكة العصبية الصناعية المقترحة في المراحل الثلاث (التدريب، التحقق، الاختبار).

تم إجراء تحليل إحصائي باستخدام تحليل الارتباط لإيجاد التوافق الخطي بين مخرجات الشبكة المقترحة وبيانات التنبؤ الإنشائي الحقيقية، فكانت معاملات الارتباط للمجموعات الثلاث هي: (0.844) لمجموعة التدريب و(0.836) لمجموعة التحقق و(0.844) لمجموعة الاختبار، ومعامل الارتباط الكلي (0.842) للعدد الكلي للبيانات كما هو مبين في الشكل (8)، حيث نلاحظ اقتراب معظم القيم الناتجة عن النموذج من خط وهذا يدل على مقدار ارتباط وموائمة النموذج للبيانات الحقيقية.



الشكل 8. معاملات الارتباط في المراحل الثلاث (التدريب، التَحْقِيق، الاختبار).

يوضح الشكل (9) مقارنة بين القيم الحقيقية للتبخر اليومي والقيم المنتبأ بها باستخدام الشبكة العصبية الصناعية المقترحة خلال مرحلة الاختبار، ويظهر توافق معظم القيم الحقيقية مع القيم الناتجة عن نموذج الشبكة، حيث اختيرت القيم المستخدمة في هذه المرحلة بشكل عشوائي من البيانات الأساسية، وهي لم تدخل في عمليتي التدريب والتحقق.



الشكل 9. مقارنة بين القيم المقيسة والمنتبأ بها خلال مرحلة الاختبار.

### الاستنتاجات والتوصيات

- ✓ أثبتت الشبكة العصبية الصناعية ذات الهيكلية (1-28-4) قدرتها على التنبؤ بالتبخر الإنائي اليومي في محطة سد الباسل المناخية، حيث بلغت قيمة معامل الارتباط (0.844) وقيمة جذر متوسط مربع الخطأ (1.15 mm/day) في مرحلة الاختبار للشبكة؛
- ✓ يوجد توافق خطي بين مخرجات الشبكة العصبية الصناعية وبيانات التبخر المقيسة بوساطة حوض التبخر بمعامل ارتباط كلي بين القيم المقيسة والمنتبأ بها مقداره (0.842) وجذر متوسط مربع خطأ كلي مقداره (1.14 mm/day) وذلك لمجموعة البيانات الكلية، مما يبين إمكانية استخدام هذه التقنية لتقدير التبخر اليومي في محطة سد الباسل بكفاءة عالية اعتماداً على قيم درجة حرارة الهواء الوسطية، الرطوبة النسبية الوسطية، الإشعاع الشمسي وسرعة الرياح الوسطية؛
- ✓ إجراء تحليل حساسية لدراسة تأثير كل من درجة الحرارة والرطوبة النسبية والإشعاع الشمسي وسرعة الرياح على تقدير التبخر في محطة سد الباسل باستخدام الشبكة العصبية الصناعية للحصول على أكبر دقة ممكنة في عملية التنبؤ؛
- ✓ مقارنة نماذج الشبكات العصبية الصناعية مع تطبيقات الذكاء الاصطناعي الأخرى مثل المنطق الضبابي والخوارزميات الجينية.

## المراجع

1. عليان، ميس. تقدير التبخر-نتح المرجعي الشهري في منطقة طرطوس باستخدام الشبكة العصبية الصناعية. مجلة جامعة تشرين للبحوث والدراسات العلمية، المجلد 33، العدد 7، 2011، 119-136.
2. CHOW, V.T.;MAIDMENT, D.R.;MAYS, L.W. *Applied Hydrology*. illustrate. ed.Mcgraw-Hill Higher Education, New York,1988, 588.
3. YASHAR, F.;NARGES, P.;YUK, F. H.;TEANG, S.L. *Estimating evapo-transpiration from temperature and wind speeddata using artificial and wavelet neural networks (WNNs)*. Agricultural Water Management, No. 140, 2014, 26-36.  
< <http://dx.doi.org/10.1016/j.agwat.2014.03.014>>
4. DOORENBOS, J.;PRUITT, W. O. *Guide lines for Predicting Crop Water Requirement*. Irrigation and Drainage Paper No. 24, Food and Agriculture Organization of the United Nations (FAO), Rome, 1977, 156.
5. KUMAR, P. D.;KUMAR, JAIPAU, A. K.;TIWARI. *Evaporation Estimation Using Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Techniques*. Pakistan Journal of Meteorology, Vol. 8, No. 16, 2012, 81-88.
6. DAWSON, W. C.;WILBY, R. *An artificial neural networks approach to rainfall-runoff modeling*. Hydrological Sciences Journal, Vol. 43, No.1, 1998, 47-66.
7. TRAJKOVIC, S.;TODOROVIC, B.;STANKOVIC, M. *Forecasting Reference Evapo-transpiration by Artificial Neural Networks*. Journal of Irrigation and Drainage Engineering, ASCE, 129, 2003, 454-457.  
< [http://dx.doi.org/10.1061/\(ASCE\)0733-9437\(2003\)129:6\(454\)](http://dx.doi.org/10.1061/(ASCE)0733-9437(2003)129:6(454))>
8. TERZI O.;EROL, K. M.;ELIEK, T. E. *Estimating Evaporation using ANFIS*. Journal of Irrigation and Drainage Engineering, Vol. 132, No. 5, 2006, 503-507.
9. KESKIN, K.P. TERZI, O. *Artificial Neural Network Models of Daily Pan Evaporation*. J. Hydrologic Engrg. 11(1), 2006, 65-70.
10. ZANETTI, S.;SOUSA, E. F.;OLIVEIRA, V. P. S.;ALMEDIA, F. T.;BERNARDO, S. *Estimating Evapotranspiration Using Artificial Neural Network and Minimum Climatological Data*. Journal of Irrigation and Drainage Engineering, VOL. 133. NO. 2, 2007, 83-89.  
< [http://dx.doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:2\(83\)](http://dx.doi.org/10.1061/(ASCE)0733-9437(2007)133:2(83))>
11. GOEL, A. *ANN Based Modeling for Prediction of Evaporation in Reservoirs*. Archive of Sid, Vol. 22, No. 4, 2009, 351-358.
12. CHANG, F. J.;CHANG, L. C.;KAO, H. S.;WU, G.R. *Assessing the Effort of Meteorological Variables for Evaporation Estimation by Self-Organizing Map Neural Network*. Journal of Hydrology, No. 384, 2010, 118-129.

13. HORMOZI, H.A. *Evaluation of effective parameters in the estimation of evaporation using artificial neural network model*. International Journal of Agriculture and Crop Sciences. 4 (8), 2012, 461-467.
14. KISI, O. *Least squares support vector machine for modeling daily reference evapotranspiration*. Irrigation Science, Vol. 31, No. 4, 2013, 611-619.
15. GUO, X.;SUN, X.;MA, J. *Prediction of daily crop reference evapotranspiration (ET<sub>o</sub>) values through a least-square support vector machine model*. Hydrology Research, Vol. 42, No. 4, 2011, 268-274.
16. GOHARI, S.A.;ESLAMIAN, S. S.;MALEKIAN, R.;BIABANAKI, M. *Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines*. Journal of Applied Sciences Iran, Vol. 8, No. 19, 2008, 3497-3502.
17. الشرفاوي، علي. محمد. النكاء الاصطناعي والشبكات العصبية. مركز الذكاء الاصطناعي للحاسبات، 1996، 356.
18. FREEMAN, J.;SKAPURA, D. *Neural Networks Algorithms, Applications, and Programming Techniques*. ISBN 0-201-51376-5, 1991, 414.
19. ARCA, B.;BENINCASA, F.;VINCENZI, M.;VENTARA, A. *Evaluation of Neural Network Techniques for Estimating Evapotranspiration*. National Research Council Research Institute for the Monitoring of Agroecosystems Italy, ISBN 9251042195 187 0254-5284, 2001.
20. عمار، غطفان؛ حيدر، بادية. تقدير التبخر-نتح المرجعي الشهري في منطقة صافيتا باستخدام الشبكة العصبية الصناعية. مجلة جامعة تشرين للبحوث والدراسات العلمية، سورية، المجلد 35، العدد 4، 2013، 27-43.
21. العاني، افتخار، عبد الجواد. تقدير التبخر-النتح المرجعي اليومي لمنطقة الموصل باستخدام الشبكات العصبية الاصطناعية. مجلة جامعة الموصل العراق، 2007.
22. ZURADA, J. M. *Introduction to Artificial Neural System*. Jaico Publishing House, Mumbai, ISBN 0-3 14-93391 -3, 1996.
23. SHI, J. *Reducing Prediction Error by Transforming Input Data for Neural Networks*. Journal of Computing in Civil Engineering, Vol. 14, No. 2, 2000, 109-116.
24. KUMAR, M.;RAGHUWANSH, S.;SINGH, R.;WALLENDER, W. W.;PRUITT, W. O. *Estimating Evapotranspiration Using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering, ASCE, Vol. 128, No. 4, 2002, 224- 233.