

# أنموذج شبكة عصبونية صناعية للتنبؤ بالتبخّر

## الشهري

### من محطة سد الرستن

طالبة الدكتوراه: م. فاطمة مردود

كلية الهندسة المدنية - جامعة البعث

إشراف الدكتور: معن سلامة + د. عمار زقزوق

#### ملخص

يعتبر التبخّر مكوناً أساسياً في الدورة الهيدرولوجية، وهو يلعب دوراً مؤثراً في تطوير وإدارة الموارد المائية. الهدف من الدراسة إلى التنبؤ بالتبخّر الإنائي الشهري في محطة حمص المناخية باستخدام الشبكات العصبونية الصناعية. وقد اعتمدت الدراسة من أجل ذلك على القيم الشهرية لدرجة حرارة الهواء والرطوبة النسبية فقط كمدخلات، واعتمدت التبخّر الإنائي الشهري كمخرج للشبكة. استُخدمت خوارزمية الانتشار العكسي في عملية تدريب وتحقيق الشبكة مع تغيير طرائق التدريب وعدد الطبقات الخفية وعدد العصبونات في كل طبقة منها، وقد أظهرت النتائج القدرة الجيدة للشبكة العصبونية الصناعية ذات الهيكلية 1-12-2 على التنبؤ بقيم التبخّر الإنائي الشهري وبمعامل الارتباط الكلي (R) 96.4% وبجذر متوسط مربعات الأخطاء (RMSE) 34.52 mm/month لمجموعة البيانات الكلية، وقد أوصت الدراسة باستخدام تقنية الشبكات العصبونية الصناعية لتحديد العناصر الأكثر تأثيراً على التبخّر.

الكلمات المفتاحية: التبخّر الإنائي، الشبكات العصبونية الصناعية، خوارزمية الانتشار العكسي، التنبؤ.

# Artificial Neural Network Model to Estimat Monthly Evaporation in AL- RASTAN Reservoir Station

## ABSTRACT

Evaporation is a major meteorological component of the hydrologic cycle, and it plays an influential role in the development and management of water resources. The aim of this study is to predict of the monthly pan evaporation in Homs meteostation using Artificial Neural Networks (ANNs), which based on monthly air temperature and relative humidity data only as inputs, and monthly pan evaporation as output of the network.

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. Results shown good ability of

(2-12-1) ANN to predict of monthly pan evaporation with total correlation coefficient equals 96.4 % and root mean square error equals

34.52 mm/month for the total data set. This study recommends using the artificial neural networks approach to identify the most effective parameters to predict evaporation.

**Keywords:** Pan Evaporation, Artificial neural networks, Back-propagation algorithm, Prediction

## مقدمة

تتسم الموارد المائية بأهمية متميزة قد تفوق باقي الموارد الاقتصادية الأخرى، حيث أنها تعدّ حجر الزاوية في تطوير النشاطات الزراعية والصناعية والاقتصادية المختلفة، وتمثل المعلومات الهيدرولوجية العامل الأساس لتقويم الوضع المائي ووضع دراسات الموازنة المائية التفصيلية في أية منطقة. يعتبر التبخر أحد أهم العوامل الهيدرولوجية، ويعرّف بأنه فقدان جزيئات الماء من السطح المائي إلى الغلاف الجوي [1]، وقد نالت دراسة هذا العامل اهتمام العديد من الباحثين بغرض إيجاد طريقة غير مباشرة لتقديره بالاعتماد على العوامل المناخية الأخرى المرتبطة به، فأجريت العديد من الدراسات لهذا الغرض.

حيث قام كل من (Keskin and Terzi (2006 بدراسة نماذج من الشبكات العصبونية الصناعية (ANN) واقتراحها كمنهج بديل لتقدير التبخر من بحيرة Eirdir . هدفت هذه الدراسة إلى تطوير نماذج ANN لتقدير التبخر اليومي اعتماداً على بيانات الأرصاد الجوية ومقارنة نتائجها مع نتائج نموذج بنمان، بالإضافة إلى تقييم قدرة الشبكة العصبونية الصناعية على تقدير قيم التبخر بمقارنة نتائجها مع قيم حوض التبخر، وتضمنت بيانات الأرصاد الجوية المستخدمة في الدراسة قيم القياسات اليومية لكل من درجة حرارة الهواء والماء، وساعات سطوع الشمس، والإشعاع الشمسي، والضغط الجوي، والرطوبة النسبية وسرعة الرياح . وأظهرت النتائج أن نماذج الشبكة العصبونية الصناعية تعطي نتائج أكثر دقة من نموذج بنمان في تقدير التبخر من بحيرة Eirdir [13].

حيث قارن (Eslamian, S.S. et al. 2008) بين النوعين من نماذج الشبكات العصبونية الصناعية (FFNNs , SMVs) في تقدير التبخر الشهري في خمس محطات في إيران وذلك بالاعتماد على القيم الشهرية للرطوبة النسبية والإشعاع الشمسي ودرجة الحرارة وسرعة الرياح، بالإضافة إلى الهطول المطري، وكانت نتائج كل من الأسلوبين جيدة مع أفضلية لنماذج SVMs حيث بلغت قيمة معامل الارتباط 0.94 و0.936 في

نماذج FFNNs ونماذج SVMs على الترتيب، أما قيمة متوسط مربعات الأخطاء فقد بلغت 1265.22 و 40.98 في الأنموذجين على الترتيب أيضاً [8].

وأجرى (Boroomand. et al. 2011) دراسة لتقدير التبخر الإنائي الشهري باستخدام الشبكات العصبونية الصناعية في إيران، حيث دُرِّبَت الشبكة باستخدام القيم الشهرية للإشعاع الشمسي ودرجة الحرارة الصغرى والعظمى والرطوبة النسبية الصغرى والعظمى وسرعة الرياح، وكانت معاملات الارتباط خلال مرحلتي التدريب والاختبار 97.4% و 97.3% على الترتيب، وكان الخطأ النسبي الأعظمي في المرحلتين على الترتيب 18% و 24%، وقد تم الاستنتاج على أن أسلوب الشبكات العصبونية الصناعية هو أسلوب ملائم لتمثيل الظاهرة وقادر على تقدير قيمها بشكل دقيق [5].

أما (Kumar, P. et al 2012) فقد أجرى دراسة مشابهة لتقدير التبخر الإنائي الشهري في الهند باستخدام الشبكات العصبونية الصناعية اعتماداً على قيم الرطوبة النسبية والإشعاع الشمسي ودرجة الحرارة وسرعة الرياح، واستنتج القدرة الجيدة لهذه النماذج في عملية التقدير، حيث بلغ معامل الارتباط 0.9311 خلال مرحلة التدريب و0.9863 خلال مرحلة الاختبار، أما قيمة جذر متوسط مربعات الأخطاء فقد بلغت 1.07 mm/day خلال مرحلة التدريب، 0.9326 mm/day خلال مرحلة الاختبار [12].

في حين قام (Singh, S.K. et al.2013) بدراسة لتقدير التبخر نتح اليومي في مجموعة من المحطات المناخية في الهند باستخدام الشبكات العصبونية الصناعية، بالاعتماد على قيم درجات الحرارة الصغرى والعظمى، الرطوبة النسبية الصغرى والعظمى، الإشعاع الشمسي وسرعة الرياح كمدخلات لمشبكات العصبونية، أما المخرجات فكانت قيم التبخر نتح اليومي المقيسة باستخدام الليزيمتر، وقد أظهرت النتائج إمكانية استخدام نماذج الشبكات العصبونية الصناعية بمعامل ارتباط 0.9824 خلال مرحلة التدريب و 0.9448 خلال مرحلة الاختبار [16].

وقارن (Al-Aboodi, Ali.2014) بين نظام الاستدلال العصبي الضبابي التكيّفي ANFIS والانحدار الخطّي في تقدير التبخّر الإنائي الشهري، ووجد أن نظام ANFIS يحسّن من الدقّة بحدود 5 % حيث بلغت قيمة جذر متوسط مربّعات الأخطاء RMSE في نموذجي ANFIS والانحدار الخطّي 63.596 و 64.42 mm/month أما معامل الارتباط R فقد بلغ 0.987 و 0.938 في نموذجي ANFIS والانحدار الخطّي على الترتيب [4].

في حين قارن (Dalkilic, Y. et al.2014) بين نماذج الشبكات العصبونية الصناعية ومعادلة بنمان التجريبيّة في تقدير التبخّر الإنائي اليومي، وأظهرت النتائج أفضليّة نماذج الشبكات العصبونية من النوع LMANN التي تعتمد على خوارزمية Levenberg-Marquardt في عمليّة التدريب حيث بلغت قيمة متوسط مربّعات الأخطاء لهذا النوع من الشبكات خلال مرحلة الاختبار 2.27 mm<sup>2</sup>/day [7].

كما قام عمار، حيدر، عليان (2014) بتشكيل نموذج شبكة عصبونية صناعية لتقدير التبخّر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة الجافة والرطوبة، حيث تبين أنه يمكن استخدام الشبكات العصبونية الصناعية متعددة الطبقات وذات الانتشار العكسي للخطأ في تقدير التبخّر نتح الشهري في المنطقة السهلية من - الساحل السوري بمتوسط خطأ يساوي إلى 0.00292 [3] أما (Pakhale, G.k. et al.2015) فقد قام بدراسة لتقدير التبخّر نتح المرجعي اليومي في حوض Ameleke في أثيوبيا باستخدام الشبكات العصبونية الصناعية مستخدماً فيها الأداة MARS في تحديد الهيكلية وعدد العصبونات الأكثر ملاءمة لمشبكة العصبونية، وقارن النتائج مع طريقة بنمان مونتيتش، فتبيّن أن الشبكات العصبونية هي الطريقة الأفضل، ويمكن اعتمادها من أجل السيناريوهات المستقبلية [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 الشبكة العصبونية ال و تقانات الذكاء الصناعي Artificial Intelligence على الطرائق الرياضية والاحصائية الأخرى المعتمدة في تقدير التبخر.
- تطبيق تقانات الذكاء الصناعي مؤخراً في الدراسات الحديثة للتنبؤ بالتبخر حيث أعطت نتائج أدق بالمقارنة مع النماذج التجريبية.

### أهمية البحث وأهدافه:

تبرز أهمية التقدير الدقيق للتبخر في تخطيط وتنمية الموارد المائية ولعلاقته بتصميم شبكات الري وإدارة النظم الهيدرولوجية والهيدروليكية والزراعة يهدف البحث إلى التنبؤ بالتبخر الشهري من محطة سد الرستن في محافظة حمص عن طريق وضع نموذج شبكة عصبونية صناعية بالاعتماد على القيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية فقط، وبالتالي إمكانية إجراء دراسات الموازنة المائية التفصيلية ووضع الخطط المستقبلية في سبيل تنمية وإدارة الموارد المائية المتاحة في المنطقة والإفادة منها بالشكل الأمثل.

### موقع منطقة البحث:

جُمعت البيانات من المحطة المناخية في سد الرستن في محافظة حمص التي تقع في المنطقة الوسطى من الجمهورية العربية السورية، على ارتفاع 300 متر عن مستوى سطح البحر، وعلى خط عرض ( 45 ' 34 ° ) شمالاً وخط طول ( 43 ' 36 ° ) شرقاً. ويبين الشكل ( 1 ) موقع المحطة المدروسة.




الشكل (1): موقع المحطة المدروسة

## المواد وطرائق البحث:

### الشبكات العصبونية الصناعية (Artificial Neural Networks) ANNs:

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، ومكونة من وحدات معالجة بسيطة هذه الوحدات عبارة عن عصبونات (Neurons) أو عُقد (Nodes)، والتي لها خاصية عصبونية، حيث أنها تقوم بتخزين المعرفة العلمية والمعلومات التجريبية لجعلها متاحة للاستخدام وذلك عن طريق ضبط الأوزان [14].

يوضح الشكل (2) آلية عمل عصبون صناعي ومكوناته الأساسية، حيث تقوم (ANN) بمعالجة البيانات على التوازي (Parallel) مما يوفر سرعة عالية في الأداء تمكنها من حل المشاكل المعقدة التي تضم فرضيات كثيرة ومعلومات متغيرة بشكل سريع وفعال.



الشكل (2): كيفية عمل العصبون الاصطناعي

هناك العديد من الشبكات العصبونية الصناعية المستخدمة في معالجة أنماط البيانات، وكل نوع من هذه الأنواع له خصوصية في البنية وآلية معالجة المعلومات من خلال عدد ونوع العقد في كل طبقة بالإضافة إلى نوع دوال التنشيط وآلية تعديل الأوزان، وقد تم اختيار الشبكة العصبونية أمامية التغذية ذات الانتشار العكسي للخطأ (Backpropagation Feedforward) التي اكتسبت الكثير من الاهتمام في مجال التنبؤ بالطقس [17].

### 1- المكونات الأساسية للشبكة العصبونية الصناعية:

تتألف الشبكات العصبونية من المكونات الأساسية الآتية أو بعضاً منها على الأقل [20]، وهذه المكونات هي: طبقة الدخل -طبقة الخرج- الطبقات الخفية-الوصلات البينية (الأوزان).

#### 1. طبقة الدخل (Input Layer):

تتكون طبقة الدخل من مجموعة من الوحدات أو عناصر المعالجة (Nodes) التي تعمل على توزيع القيم المدخلة إليها من الوسط الخارجي إلى الطبقة الخفية التي تليها عبر الارتباطات والتي بناءً عليها ستكون النتائج.

#### 2. طبقة الخرج (Output Layer):

هي الطبقة الأخيرة التي تقع عند المخرج، حيث تقوم عناصر المعالجة فيها باستلام الإشارات من الطبقة الخفية السابقة لتعالجها حسابياً بشكل مشابه تماماً للطبقات الخفية، حيث يتم الحصول على النتائج النهائية، وهي تساهم مع الدخل في تكوين ذاكرة الشبكة.




### 3. الطبقات الخفية (Hidden Layers):

وهي مجموعة الطبقات البينية التي تقع بين طبقتي الدخل والخرج، وتكون مكونة من طبقة واحدة أو أكثر وذلك حسب حجم المشكلة وطبيعتها، وتعد العنصر الأساسي في حفظ واستعادة ذاكرة الشبكة، والأبحاث المتعلقة بالشبكات العصبونية تشير إلى عدم وجود أسلوب قياسي في تحديد عدد الطبقات الخفية أو عدد العصبونات في كل منها، وعادةً يتم بالتجريب حتى الوصول إلى الأداء الأفضل [18].

### 4. الوصلات البينية (الأوزان) (Weights):

هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها أو الوحدات داخل كل طبقة مع الوحدات الأخرى عبر الأوزان التي تكون مصاحبة أو مرافقة مع كل وصلة بينية، ومهمة هذه الوصلات نقل البيانات أو الإشارات الموزونة بين وحدات المعالجة أو الطبقات، الشكل (2) يوضح المكونات الأساسية لشبكة عصبونية صناعية.



الشكل (3): نموذج معماري لشبكة عصبونية صناعية.

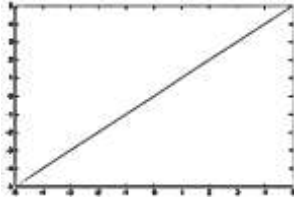
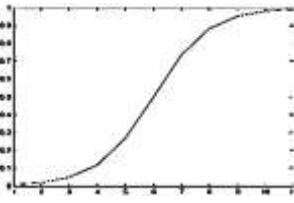
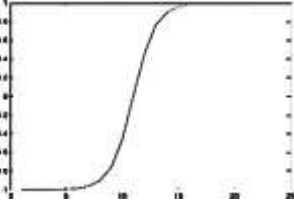
يعتبر تعيين القيم الابتدائية للأوزان (Initializing weights) عملية بالغة الأهمية، فالتخمين الأولي الأقرب إلى القيم المثلى للأوزان يساعد على تعميم أسرع للشبكة؛ مع هذا لا توجد طريقة معينة للقيام بتخمين أولي جيد للأوزان، لذا فإنها تعتمد على تعيين قيم ابتدائية عشوائية بشكل آلي [10].

2-3-2-2 توابع التحويل (Transfer Function):

إن تابع التحويل يطبق على خرج العصبون، ويجب أن يمتلك الخواص التالية: أن يكون تابعاً مستمراً؛ أن يكون قابلاً للاشتقاق ومشتقه سهل الحساب؛ أن يكون انسيابياً غير متناقصاً [19].

ويوضح الجدول (1) أهم توابع التحويل (Transfer Function) أو توابع التنشيط (Activation Function) المتوفرة في برنامج (Matlab).

الجدول (1): دوال التحويل ضمن بيئة برنامج (Matlab)

اسم التابع	الرسم البياني	الصيغة الرياضية
التابع الخطي Linear (Purelin): يعطي خرجاً يحمل نفس قيمة الدخل المقدم إليه.		$F(net) = net$
تابع السيغمويد المنطقي Sigmoid Logistic (logsig) يعطي خرجاً ثنائياً [0, 1].		$F(net) = \frac{1}{1 + e^{(-net)}}$
تابع السيغمويد ثنائي القطبية أو تتابع الظل القطعي Tangent Sigmoid (tansig): يعطي		$F(net) = \frac{2}{1 + e^{-2*net}} - 1$

خرجاً ثنائي القطبية [-1,+1].		
------------------------------	--	--

### تقييس البيانات

يتم بعد تجميع البيانات تحويل جميع القيم إلى قيم بين ال 0 وال 1 وذلك قبل إدخالها إلى الشبكة من خلال عملية التقييس التي يمكن إجراؤها بعدة طرق، وفي هذه الدراسة تم اعتماد المعادلة الآتية في عملية التقييس [ 11 ] :

$$P_{norm} = 0.5 \left[ \frac{P - P_{mean}}{P_{max} - P_{min}} \right] + 0.5 \quad (1)$$

حيث:

$P$  : القيمة الأصلية  $P_{mean}$  : متوسط القيم  $P_{max}$  أعلى قيمة  $P_{min}$  أدنى قيمة  $P_{norm}$  القيمة بعد التقييس

تستخدم هذه القيم خلال مراحل بناء الشبكة العصبونية الاصطناعية، ثم تُعاد القيم التي تنتج بعد إجراء عملية المحاكاة Simulation إلى حالتها الأصلية قبل التقييس .

### طريقة معادلة ايفانوف:

وتستخدم معادلة ايفانوف في حساب التبخر من السطوح المائية الحرة بالاعتماد على القيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية وفق ما يلي [9]:

$$E = 0.0018. (T + 25)^2 (100 - RH) \quad (2)$$

حيث أن:

T: القيمة الوسطية الشهرية لدرجة حرارة الهواء .

RH : الرطوبة النسبية % .

E: التبخر في الشهر mm.

### معايير التقييم

يوجد العديد من المعايير لمقارنة بين الشبكات العصبونية وتحديد الشبكة ذات الدقة الأفضل، وفي هذه الدراسة تم اعتماد قيم جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R والتي تعطى بالعلاقات كما يلي [4]:

$$RMSE = \left[ \frac{\sum_{i=1}^n (P_i - O_i)^2}{N} \right]^{0.5} \quad (3)$$

$$R = \frac{\sum_{i=1}^n (P_i - \bar{P}) \cdot (O_i - \bar{O})}{\left[ \sum_{i=1}^n (P_i - \bar{P})^2 \cdot \sum_{i=2}^n (O_i - \bar{O})^2 \right]^{0.5}} \quad (4)$$

حيث أن:

$P_i$ : القيمة المتنبأ بها.  $\bar{P}$ : المتوسط الحسابي لمقيم المتنبأ بها. N: عدد البيانات  
 $O_i$ : القيمة المقيسة.  $\bar{O}$ : المتوسط الحسابي للقيم المقيسة.

### النتائج والمناقشة:


جُمعت البيانات المتوفرة في محطة سد الرستن المناخية موضوع البحث في الفترة الممتدة بين عامي (1980-1999) ثم قُيست باستخدام المعادلة (1) وأدخلت إلى الشبكة العصبونية الصناعية المكونة من عصبونين في طبقة الدخل لمشبكة ممثّين لمقيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية، يقابلها عصبون واحد في طبقة الخرج ممثل لقيمة التبخر الشهري، وتضمنت هذه البيانات 240 قيمة شهرية تم تقسيمها إلى ثلاث مجموعات للتدريب والتحقق والاختبار وفق عدة نسب من خلال مجموعة من التجارب، وتبين أنّ التقسيم الأفضل والذي يعطي النتائج الأكثر دقة هو: 70% لمجموعة التدريب و 20% لمجموعة التحقق و 10% لمجموعة الاختبار وذلك لتقارب المؤشرات الإحصائية (المتوسط الحسابي والانحراف المعياري) بين المجموعات الثلاث بالاعتماد على نسب التقسيم هذه،

وبالتالي تضمّنت مجموعة التدريب على 168 قيمة شهرية وعلى 48 قيمة في مجموعة التحقق 24 قيمة لمجموعة الاختبار .

استخدمت في هذه الدراسة، خوارزمية الانتشار العكسي (BP) من النوع LM (Levenberg-Marquardt) في تدريب الشبكات العصبونية ذات التغذية الأمامية (Feedforward)، حيث تعد خوارزمية LM من التقنيات المثالية التي عادة ما تكون أسرع وأكثر موثوقية من خوارزميات الانتشار العكسي الأخرى ويحتوي الجدول ( 1 ) على بعض المؤشرات الإحصائية للعوامل المناخية المستخدمة ، ويبين الشكل ( 4 ) قيم التبخّر الشهري في كلّ مجموعة من المجموعات.

الجدول ( 2 ) : بعض المؤشرات الإحصائية لعوامل المناخية المستخدمة

	الرطوبة النسبية %	درجات الحرارة °C	التبخّر mm/month
المتوسط الحسابي	60.2	17.9	91.99
الانحراف المعياري	11.1	7.61	62.27
أكبر قيمة max	238.9	96.1	30.7
أصغر قيمة min	11.6	43.1	4.1



الشكل: (4) بيانات التبخّر الشهري المستخدمة في الدراسة

استُخدم برنامج MATLAB وحزم الأدوات الملحقة به في عملية بناء الشبكات العصبونية وتدريبها، حيث أُجري عدد كبير جداً من التجارب على شبكات عصبونية ذات بُنى مختلفة من خلال التغيير في عدد العصبونات في الطبقة الخفية وتوابع التفعيل المستخدمة في كل من الطبقة الخفية وطبقة الخرج لمشبكة، وكذلك من خلال التغيير في الخوارزميات المستخدمة في تدريب الشبكة، حيث تُرَبِّت كل شبكة من هذه الشبكات 1000 مرة ثم حسبت قيمة جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R لكل مجموعة من المجموعات .

بيّنت النتائج أن توابع التفعيل ذات الدالة القطعية Sigmoid Function هي الأفضل وتناسب طريقة التقييس المستخدمة، وأن خوارزمية التدريب (LM) Levenberg–Marquardt تساعد في الوصول إلى أقل قيمة لجذر متوسط مربعات الأخطاء RMSE

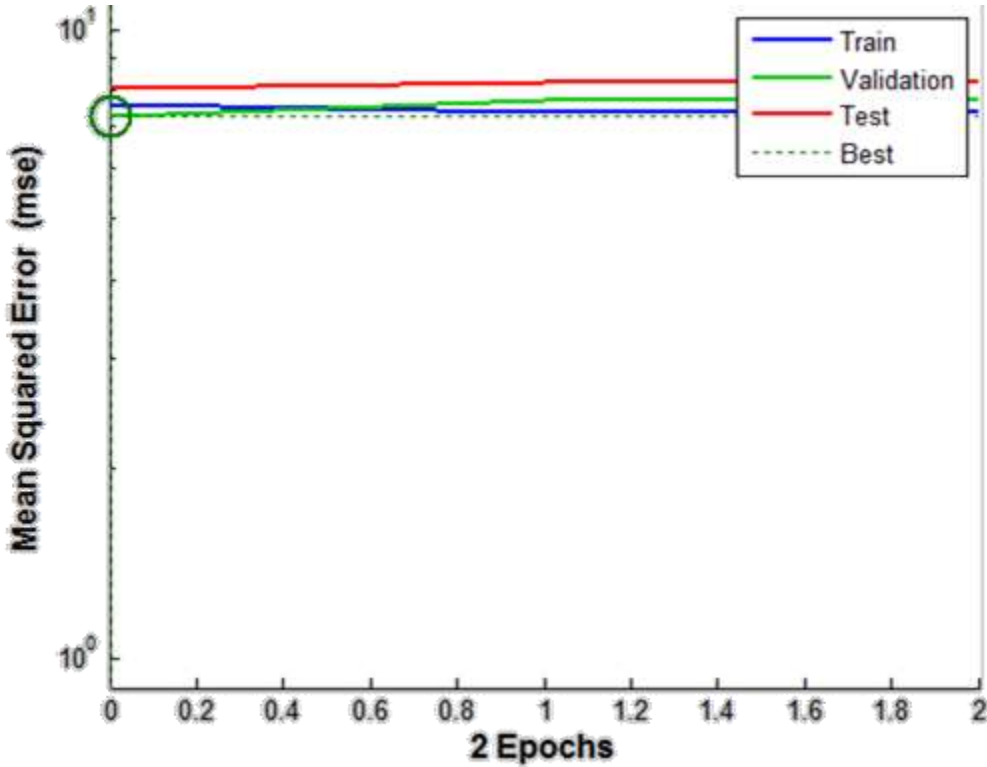
نلاحظ أن الشبكة العصبونية الصناعية التي تحتوي على اثنا عشر عصبون في الطبقة الخفية  
ANN(2,12,1)

التي تعتمد على تابع التفعيل Tan Sigmoid هي الأفضل، حيث كانت قيم جذر متوسط  
مربعات الأخطاء RMSE

الكلية خلال المراحل الثلاث 34.52mm/month

ويظهر الشكل (5) أداء هذه الشبكة والتناقص في قيمة متوسط مربع الخطأ خلال مرحلة

تدريب الشبكة Train



الشكل (5): أداء الشبكة ( 2,12,1 ) خلال مراحل التدريب والتحقق والاختبار


وبالإضافة إلى ذلك فقد أعطت الشبكة العصبونية الصناعية ذات الهيكلية (2-12-1) قيمة عالية  
لمعامل

الارتباط بين القيم المقيسة والقيم الناتجة عن الشبكة، حيث كانت خلال مراحل التدريب والتحقق  
والاختبار على الترتيب: 96.7%, 95.4%, 95.6%, أما قيمة الارتباط الكلية فقد بلغت


96.4% وذلك كما هو موضح في الشكل (6). في حين يظهر الشكل (7) مقارنة بين القيم الحقيقية والقيم المنتبأ بها الناتجة عن الشبكة خلال المراحل المختلفة من عملية بناء الشبكة.

ومن جهة أخرى حُسبت بغرض المقارنة قيم التبخر الإنائى الشهري باستخدام معادلة ايفانوف التي تعتمد على القيم ذاتها المستخدمة كمدخلات للشبكة العصبونية الصناعية، أي القيم الشهرية لدرجة الحرارة والرطوبة النسبية، فأظهرت النتائج ضعفاً في تمثيل قيم الظاهرة، حيث بلغت قيمة جذر متوسط مربعات الأخطاء RMSE على كامل مجموعة البيانات 62.3 mm/month، ومعامل الارتباط الكلي 95.4 % ، ومثلت نتائج المقارنة مع نتائج الشبكة العصبونية الصناعية في الشكل ( 8 ) ، وذلك على قيم فترتي التحقق والاختبار لمشبكة العصبونية الاصطناعية، أي على قيم لم تستخدم في عملية تدريب الشبكة.






الشكل (6): الارتباط بين القيم المقيسة والمتنبأ بها.



الشكل (7): مقارنة بين قيم التَّبَحْر الحقيقية والقيم الناتج عن الشبكة خلال مراحل التدريب والتحقّق والاختبار



الشكل (8): مقارنة بين القيم الحقيقية للتبخّر الشهري والقيم الناتجة عن الشبكة العصبونية الصناعية

والقيم الناتجة عن (معادلة ايفانوف) خلال مرحلتي التحقّق والاختبار فقط.

### الاستنتاجات والتوصيات:

- 1- أثبتت ال شبكة العصبونية الاصطناعية ذات الهيكلية 1-12-2 وبمعامل الارتباط الكلي 96.4% ويجذر متوسط مربعات الأخطاء 34.52 mm/month لمجموعة البيانات الكلية، قدرتها على التنبؤ بالتبخّر الشهري في محطة الرستن المناخية.
- 2- بينت المقارنة بين طريقتي الشبكات العصبونية الصناعية ومعادلة ايفانوف أن الشبكات العصبونية هي الأفضل في عملية التقدير والتنبؤ بقيم التبخر الشهري، حيث بلغ جذر متوسط مربعات الأخطاء لمجموعة البيانات الكاملة 34.52 و 62.3 mm/month في طريقتي الشبكة العصبونية الصناعية ومعادلة ايفانوف على الترتيب،

- في حين بلغ معامل الارتباط الكلي 96.4% و 95.4% في الشبكة العصبونية الصناعية ومعادلة ايفانوف على الترتيب.
- 3- أظهرت النتائج الموثوقة العالية لمشبكات العصبونية الصناعية في عملية التقدير والتنبؤ بالتبخر الشهري بالاعتماد على قيم درجة الحرارة والرطوبة النسبية فقط.
- 4- يوصى بإجراء دراسة تحليل حساسية قيم التبخر للعوامل المناخية باستخدام الشبكات العصبونية الصناعية، وتحديد أكثر العناصر تأثيراً على قيمة التبخر لم الحصول على أكبر دقة ممكنة في عملية التنبؤ.

## المراجع:

- 1- بكر، ذر انتصار. *إستخدام نموذج (ARIMA) في استكمال السمسمة الزمنية لقيم التبخر في مدينة بغداد*. مجلة جامعة ديالى، العدد 10، 2014.
- 2 - رشد، صفوان ناظم؛ رشيد، خيرى بدل؛ زكي، عزة حازم. *مقارنة بين اسلوبي الشبكات العصبونية الاصطناعية والمربعات الصغرى للنماذج الخطية وغير الخطية مع التطبيق*. المجلة العراقية للعلوم الاحصائية (21). 2012، 246 - 265.
- 3- عمار، غطفان؛ حيدر، باديه؛ عليان، ميس. *تقدير التبخّر من سطح الماء في المنطقة السهلية من الساحل السوري باستخدام الشبّكة العصبونية الصناعيّة المؤتمر الدولي الأول للهندسة المدنية جامعة تشرين 4-6 آب 2014*.
- 4-AL-ABOODI, A.H. *Evaporation Estimation Using Adaptive Neuro-Fuzzy Inference System and Linear Regression*. Eng. &Tech. Journal, Vol. 32, Part (A), No.10, 2014.
- 5-BOROOMAND-NASAB, B; JOORABIAN, M. *Estimating Monthly Evaporation Using Artificial Neural Networks*. Journal of Environmental Science and Engineering, 5, 2011, 88-91.
- 6- BASHEER, I, A ; HAJMEER, M . *Artificial neural networks: fundamentals, computing, design, and application*. Journal of Microbiological Methods 43, 2000, 3-31.
- 7-DALKILIC, Y; OKKAN, U; BAYKAN, N. *Comparison of Different Approaches in Daily Pan Evaporation Prediction*. Journal of Water Resource and Protection, 6, 2014, 319-326.

- 8-ESLAMIAN, S. S; GOHARI, S. A; BIABANKI, M; MALEKIAN, R;  
*Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines*. Journal of Applied Sciences 8 ,19, 2008, 3497-3502.
- 9- FILIMONOVA, M; TRUBETSKOVA, M. *Calculation of evaporation from the Caspian Sea surface*. International Symposium on Stochastic Hydraulics, 2005.
- 10- JAIN, S. K; SINGH, V. P 2003- Applications of artificial neural networks to water resources. Water and Environment International Conference (WE-2003), Bhopal, India.
- 11- KUMAR, M; RAGHUWANSHI, N. S; SINGH, R; WALLENDER, W. W;  
PRUITT, W. O. *Estimating Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering, 2002.
- 12-KUMAR, P; TIWARI, A. K. *Evaporation Estimation Using Artificial Neural Network*. International Journal of Computer Theory and Engineering, Vol. 4, No. 1, 2012.
- 13-KESKIN, K.P. TERZI, O. *Artificial Neural Network Models of Daily Pan Evaporation*. J. Hydrologic Engrg. 11(1), 2006, 65-70.
- 14- MAKRIDAKIS, S; WHEELWRIGHT, S. C; HYNOMAN, R. J  
1998- **Forecasting Methods and Application**. New York: John Wiley & Sons
- 15-PAKHALE, G. K; NALE, J. P; TEMESGEN, W. B; MULUNEH, W. D.  
*Modelling Reference Evapotranspiration Using Artificial Neural Network: A Case Study of*

*Ameleke watershed, Ethiopia*. International Journal of Scientific and Research Publications, Volume 5, Issue 4, 2015.

16-SINGH, S.K; LAI, C; SHARMA, D.K; MATHUR, S; SHAGI, N.C; CHAND, K. *Comparison of measured and predicted Evapotranspiration using Artificial Neural Network model*. Journal of Academia and Industrial Research. Vol. 1, No 12, 2013, 816-819.

17- VANRULLEN, R. *The power of the feed-forward sweep*. *Advances in Cognitive Psychology*, vol. 3, no. 1-2, 2007, 167-176.

18- WILMOT, C.G; MEI, B 2005- *Neural Network Modeling of Highway Construction Costs*. Journal of Construction Engineering and Management ASCE.

19- ZUPAN, J 1994- *Introduction to Artificial Neural Network (ANN) Methods*. Department of Chemistry, University Rovira Virgili, Tarragona, Spain.

20- ZURADA, J. M 1992. *Introduction to Artificial Neural Systems*. West Publishing Company, U.S.A.

