

## تأثير إضافة معامل الزمن على أداء الشبكة العصبية الاصطناعية في تقدير التبخر اليومي في المنطقة الجبلية من الساحل السوري

الدكتور غطفان عبد الكريم عمار \*

الدكتورة بادية يوسف حيدر \*\*

(تاريخ الإيداع 8 / 11 / 2015. قُبل للنشر في 2 / 3 / 2016)

### □ ملخص □

يلعب التبخر دوراً بارزاً في الدورة الهيدرولوجية والتوازن المائي، وتعد عملية حساب كمية المياه المتبخرة من أكثر المسائل التي تهتم بها الدراسات الهيدرولوجية الحديثة، حيث تم مؤخراً تطبيق الشبكات العصبية الاصطناعية كأداة قوية لزيادة القدرة على التنبؤ بالعلاقات الخطية وغير الخطية في المشاكل الهندسية المعقدة. تهدف هذه الدراسة إلى بناء أنموذج رياضي لتقدير التبخر من المنطقة الجبلية من الساحل السوري، باستخدام الشبكة العصبية الصناعية وذلك اعتماداً على أربعة بارامترات جوية، وهي درجة الحرارة، الرطوبة النسبية، سرعة الرياح والسطوح الشمسي، ومن ثم دراسة تأثير إضافة معامل الزمن على تقدير التبخر. بني الأنموذج الرياضي باستخدام Neural Fitting Tool إحدى أدوات الماتلاب، وقد اعتمد على البيانات اليومية للبارامترات المذكورة في منطقة الدراسة بالإضافة إلى معامل الزمن، كما استُخدمت بيانات التبخر اليومي المقیسة بوساطة حوض التبخر الأميركي صنف A كمخرجات مأمولة لغرض التحقق من صحة أداء الشبكة. وتظهر النتائج تفوق الشبكة المضاف لها معامل الزمن حيث بلغ معامل الارتباط فيها لمجموعة التحقق 0.8919 ومتوسط مربع الخطأ 0.02166 بينما كانت قيمة معامل الارتباط للشبكة المستخدمة للتنبؤ بقيمة التبخر اعتماداً على المعطيات المناخية بدون إدخال معامل الزمن 0.8324 ومتوسط مربع الخطأ 0.0327.

الكلمات المفتاحية: تبخر، محاكاة، خوارزمية التعلم، شبكة عصبية صناعية.

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

## The Effect Of Adding Time Factor On The Artificial Neural Network Performance In Estimating Daily Evaporation In Mountainous Region From Syrian Coast

Dr. Ghatfan Abdalkareem Ammar \*  
Dr. Badia Youcef Haidar \*\*

(Received 8 / 11 / 2015. Accepted 2 / 3 / 2016)

### □ ABSTRACT □

Evaporation plays a prominent role in the hydrological cycle and water balance, where the computation of evaporated water amount is considered one of the more practical issues of interest to the modern hydrological studies. The artificial neural networks have been applied as a powerful tool to increase the predictability of linear and non-linear relationships in complex engineering problems. This study is aiming at building a mathematical model to estimate evaporation from Mountainous region in Syrian Coast, using an artificial neural network, based on four metrological parameters (i.e. temperature, relative humidity, wind speed and sun hours), then studying the effect of adding time variable on evaporation estimation. The mathematical model was built by the (NN-tool box), which is one of the MATLAB tools, using the daily value of the above mentioned parameters in addition to time, as the network inputs and the evaporation measured from the American pan class A as the network output . The results show that ANN4+T model which have 5 inputs (temperature, relative humidity, wind speed, sun hours, time) is the best in estimation evaporation with correlation factor of 0.8919 and Mean square error of 0.02166 for the validation set where the correlation factor in ANN4 (without time) was 0.8324 and MSE of 0.0327for the validation set.

**Key words:** Evaporation, simulation, learning algorithm, Artificial Neural Network.

---

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

\*\* Assistant Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

**مقدمة:**

يعد التبخر أحد أهم عناصر الدورة الهيدرولوجية التي تؤثر على تخزين المياه ودرجة الحرارة. مما يجعل تقدير قيمته الدقيقة أمراً حاسماً في إدارة الري الزراعي والموازنة المائية والمحافظة على التربة. ونتيجة للتغيرات الناجمة عن التأثيرات المعقدة المتبادلة بين الأنظمة الأرضية والجوية، يكون من الصعب إجراء محاكاة دقيقة له. تستخدم العديد من الطرائق المباشرة وغير المباشرة لحساب التبخر. إحدى الطرائق المباشرة كانت استخدام إناء التبخر من أجل تجميع كمية التبخر الكلية في موقع محدد خلال فترة التجربة، في حين أن الطرائق غير المباشرة مثل المعادلات التجريبية يوجد فيها صعوبة في تحديد المعادلة الأكثر ملائمة والتي تناسب أكبر مجال من أنواع البيانات. هذه المشاكل يجب أن تؤخذ بعين الاعتبار من أجل إيجاد أفضل النماذج التي هي أساساً تمثل الأنظمة اللاخطية .

قامت (الشلاوي، 2011) بتصميم نظام حاسوبي مضرب يقوم بتقدير التبخر الإنثائي اليومي بحوض التبخر صنف A مستخدمة دالات عضوية مختلفة وبعتماد بيانات مناخية يومية متضمنة (درجة الحرارة، الإشعاع الشمسي، سرعة الرياح على ارتفاع مترين، الرطوبة النسبية والتبخر الإنثائي صنف A). حيث تم مقارنة النظام الحاسوبي المضرب بأنموذج شبكة عصبية اصطناعية وقد أظهرت النتائج إمكانية اعتماد التطبيقين في تقدير التبخر الإنثائي بدلاً من استخدام معادلات معقدة تحتاج إلى معلومات لعناصر مناخية كثيرة من الممكن أن تكون مفقودة أو غير متوفرة. [1] وفي بحث أجراه (Jedeja, 2011) حول استخدام الشبكات العصبية الصناعية لتقدير التبخر نتج المرجعي اعتماداً على التبخر الإنثائي في البيئات نصف الجافة، وبمقارنة التنبؤات اليومية مع القيم المعطاة من خلال معادلة بنمان - مونثيث (PM)، والتي استخدمت كمعيار. فقد أعطت طريقة الـ ANN نتائج أفضل من الطرائق التقليدية التي تتطلب بيانات للرطوبة وسرعة الرياح. [2]

وتوصل (Kumar, 2012) في دراسة أجراها لتقدير التبخر باستخدام الشبكات العصبية الصناعية ANN وتقنية نظام الاستدلال الضبابي الصناعي التكيفي ANFIS، إلى أن نموذج الـ ANFIS أفضل قليلاً ولو أن الاختلاف بسيط. [3]

وفي دراسة قام بها عمار، حيدر (2013) لنموذج التبخر - نتج مرجعي في منطقة صافيتا في سورية باستخدام الشبكة العصبية الصناعية. أظهرت النتائج أن ثمة توافقاً خطياً بين مخرجات الشبكة وبيانات التبخر المقاسة، مما يبين إمكانية استخدام هذه التقانة في التنبؤ بالتبخر - نتج المرجعي الشهري وذلك بضرب مخرجات الشبكة (التبخر) بمعامل الحوض. كما طُوّر أنموذج المحاكاة للنتائج المستحصلة من الشبكة العصبية الصناعية المقترحة مع نماذج أخرى مثل معادلة إيفانوف وذلك باستخدام تقانة ( Simulink ) المتاحة في حزمة برمجية الماتلاب. وتم التوصل إلى أن الشبكة العصبية الصناعية تعطي نتائج أكثر دقة من معادلة إيفانوف في تقدير التبخر - نتج المرجعي [4].

كما أجرى (سمين، 2013) بحثاً للتنبؤ بالتبخر من خزان حمرين باستخدام الشبكات العصبية الاصطناعية باستخدام درجة الحرارة اليومية، الرطوبة النسبية، سرعة الرياح، وساعات سطوع الشمس، وبيانات التبخر في محطة الأرصاد الجوية Hemren. تم استخدام الجذر التربيعي لمتوسط الخطأ (MSE) ومعامل الارتباط ( $R^2$ ) لتقييم دقة النموذج المقترح. وتظهر الدراسة أن أفضل نموذج لتقدير التبخر هو النموذج (1-10-4)، وفيه يكون (MSE) يساوي 0.112711 ومعامل الارتباط ( $R^2$ ) يساوي 0.999540. [5]

وقدمت (ابراهيم، 2014) بحثاً حول استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة بتقدير التبخر اليومي بمدينة الموصل بدلالة بعض المعلومات المناخية، توصلت فيه إلى أن خوارزمية LM هي أفضل وأسرع

خوارزمية عند توفر درجات حرارة الأمطار، الرطوبة النسبية، سرعة الرياح والاشعاع الشمسي لأي يوم من أيام السنة. [6]

### أهمية البحث وأهدافه

إن التبخر هو أحد المعلومات الضرورية اللازمة للإدارة المثلى للموارد المائية، حيث يعد ظاهرة معقدة وغير خطية لأنها تعتمد على تفاعل العديد من العوامل المناخية مثل درجة الحرارة، الرطوبة، سرعة الرياح، ساعات السطوح الشمسي ... إلخ. ويعتبر التنبؤ بالتبخر من الأحواض المائية ذو أهمية قصوى لا سيما في تخطيط وتصميم وتنفيذ مشاريع الموارد المائية. لذلك فإن هدف هذه الدراسة هو بناء نموذج رياضي لتقدير التبخر اليومي من المنطقة الجبلية في الساحل السوري، اعتماداً على بعض المتغيرات المناخية مثل درجة الحرارة الجافة، الرطوبة النسبية، السطوح الشمسي إضافة إلى سرعة الرياح ومن ثم دراسة تأثير إضافة معامل الزمن على أداء الشبكة المشكّلة في تقدير التبخر، حيث أن البيانات اليومية للعناصر الخمسة سابقة الذكر لم تتوفر إلا في منطقة سد المزينة التي يبلغ ارتفاعها 423 م عن سطح البحر، والتي يمكن اعتبارها تمثل المنطقة الجبلية (التي تبدأ ارتفاعاتها من 300 م فما فوق) أي أن الشبكة العصبية التي سنحصل عليها تصلح للاستخدام في المنطقة الجبلية كلها باستثناء الأيام التي تقل درجة الحرارة الوسطية فيها عن 3 درجة مئوية وتزيد عن 32 درجة مئوية وتتجاوز سرعة الرياح الوسطية فيها 14 م/ثا.

### طرائق البحث ومواده

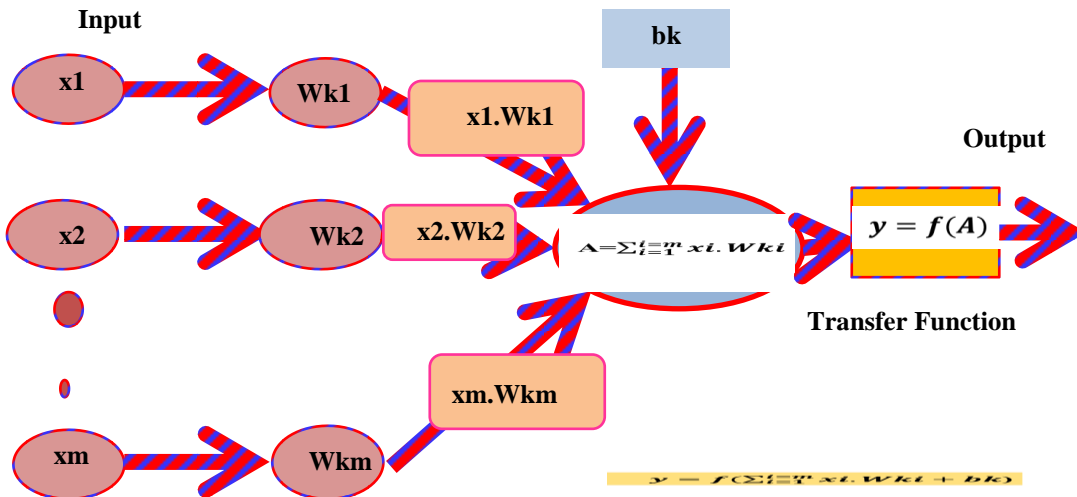
#### الشبكات العصبية الصناعية

لقد تطور علم الذكاء الاصطناعي كثيراً وهو يأخذ أهمية كبيرة في العلوم الزراعية بشكل خاص. حيث لا توجد علاقة معينة تربط بين العوامل الفعالة التي تؤثر في حدوث الظاهرة. والتبخر هو ظاهرة تستخدم العلاقات التجريبية في حساب قيمتها حتى الآن. و يتطلب استخدام هذه العلاقات حسابات معقدة والأهم من ذلك فهو يتطلب معايرة لكل منطقة. وتتغير دقة هذه العلاقات تبعاً للمناخ وموقع منطقة الدراسة [7]

تعتمد هذه الدراسة على إنشاء نموذج رياضي للشبكة العصبية الصناعية، حيث تعرف الشبكة العصبية الصناعية بأنها إحدى أقسام علم الذكاء الصناعي Artificial intelligence، وهي عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبية الطبيعية للإنسان، حيث تتشابه الشبكة العصبية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. ويمكن تدريب الشبكة على إنجاز وظائف معينة من خلال ضبط قيم الأوزان التشابكية بين العناصر. تركيب الشبكة العصبية الاصطناعية:

إن الشبكات العصبية الصناعية هي بنية رياضية مرنة قادرة على تعريف العلاقات المعقدة غير الخطية بين مجموعات بيانات المدخلات والمخرجات، حيث وجد أن نماذج الشبكات العصبية الصناعية تكون مفيدة وفعالة خصيصاً في المسائل التي يصعب وصف خواص العمليات فيها بمعادلات فيزيائية. يمكن لنموذج الشبكة العصبية الصناعية أن يحل مسائل غير خطية معقدة والتي يكون من الصعب تمثيلها بالمعادلات الرياضية التقليدية، وتعد هذه النماذج مناسبة جداً في الحالات التي تكون فيها العلاقة بين متغيرات المدخلات والمخرجات غير صريحة.

تتكون الشبكات العصبية بشكل عام من نظام من الخلايا العصبية، التي تم ترتيبها في طبقات حيث تتلقى هذه الشبكات الإشارات من وحدات الإدخال ثم يتم معالجتها وإعادة بثها باتجاه عصبونات الخرج. تتم هذه المعالجة عبر وصلات عصبية موجودة في الشبكات بين الخلايا بعضها البعض. ولكل وصلة من هذه الوصلات ترجيح بقيمة معينة تسمى الوزن، حيث يتم ضرب ذلك الوزن بقيمة إشارة خاصة بهذه الوصلة. لذا توجد لكل خلية دالة بفعيل Function Activation، والتي تقوم بتحويل صافي مدخلات خلية معينة إلى إشارات خرج (Output Signals) [8].



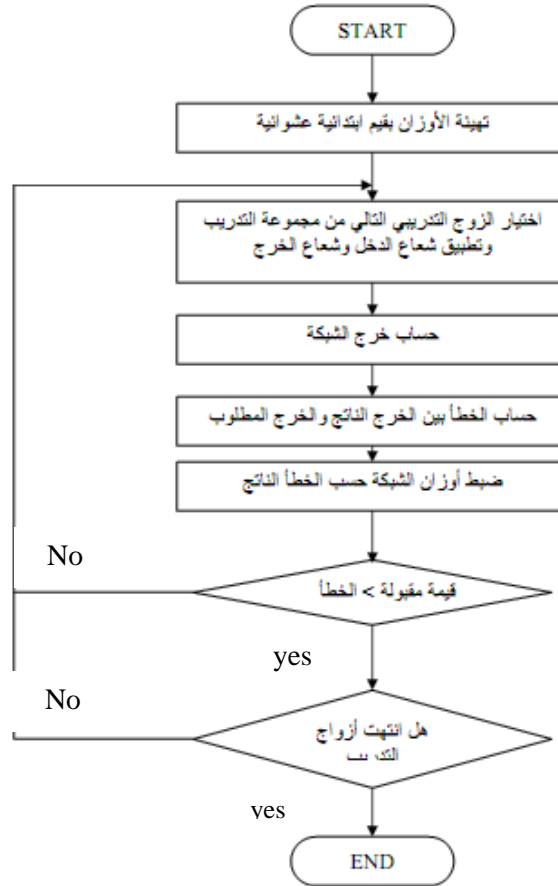
الشكل (1): الشبكة العصبية الصناعية

تصنف الشبكات العصبية الصناعية من حيث آلية انتشار البيانات إلى: [9]  
**الشبكات العصبية الاصطناعية ذات التغذية الأمامية (Feedforward ANNs):** وهي الشبكات التي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكونة لها. حيث تنتقل البيانات الداخلة إلى الشبكة باتجاه الأمام دائما من طبقة الإدخال باتجاه طبقة الإخراج، ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ والتي تم استخدامها في هذا البحث.  
**الشبكات العصبية الاصطناعية ذات التغذية الخلفية (Feedback ANNs):** وهي الشبكات التي تجد لمخرجاتها طريقاً خفياً مرة أخرى لتصبح مدخلات؛ لكي تعطى أفضل النتائج الممكنة ويسمى هذا النوع من الشبكات بالشبكات المرندة (Recurrent Networks).

#### تدريب الشبكة العصبية:

يقصد بعملية تدريب الشبكة ضبط الأوزان، حيث إن تطبيق مجموعة من قيم الدخل يؤدي إلى إنتاج مجموعة من القيم المطلوبة في الخرج. تسمى كل من مجموعات قيم الدخل والخرج شعاعاً (vector). يفترض التدريب أن كل شعاع دخل مرتبط بشعاع الخرج المطلوب حيث يشكلان زوجاً واحداً يدعى زوج التدريب. سيتم تدريب الشبكة عادة على عدد من أزواج التدريب. قبل البدء بعملية التدريب يجب تهيئة جميع الأوزان بقيم عشوائية صغيرة. هذه القيم الصغيرة تضمن عدم حدوث حالات الطفحان في الشبكة والتي تنتج عن الأوزان ذات القيم الكبيرة، حيث تمنع الأوزان العشوائية حدوث مشاكل أخرى، فمثلاً إذا تم جعل جميع الأوزان متساوية وكان الأداء المطلوب يتطلب قيماً غير متساوية فإن هذا سيؤدي إلى عدم تدريب الشبكة. [10]

يمثل المخطط الصندوقي التالي خطوات خوارزمية تدريب شبكة الانتشار الخلفي:



الشكل (2): خوارزمية تدريب شبكة الانتشار الخلفي

بُنيت الشبكة العصبية الصناعية في هذه الدراسة بالاعتماد على برنامج MATLAB والأدوات الملحقة به nftool Box نظراً لكفاءتهما العالية في هذا المجال. ولغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية يجب تحديد عدد عصبونات الطبقة الخفية، وبناء طبقات المدخلات والمخرجات والطبقات الخفية.

## النتائج والمناقشة

### إدخال البيانات وبناء الشبكة العصبية الصناعية

استخدم في تنفيذ هذه الدراسة القياسات اليومية المتوفرة في منطقة سد المزينة (الممثلة للمنطقة الجبلية موضوع الدراسة) لمدة 1312 يوماً لدرجة الحرارة الجافة، الرطوبة النسبية، السطوح الشمسي، سرعة الرياح والتبخر للأعوام 2005-2010 والتي تم الحصول عليها من مديرية الري العامة لحوض الساحل [11]، حيث تم إدخالها على شكل مصفوفة مكونة من أربعة صفوف تمثل درجة الحرارة الجافة، الرطوبة النسبية للهواء، سرعة الرياح والسطوح الشمسي و1312 عموداً، كما أُدخلت بيانات المخرجات لمجموعة التدريب على شكل مصفوفة مكونة من صف واحد يتضمن قيم التبخر اليومي المقيسة و1312 عموداً. ثم قُسمت هذه البيانات عشوائياً من خلال مكتبة nftool المتاحة في حزمة برمجيات الماتلاب إلى ثلاث مجموعات هي: مجموعة التدريب ومجموعة التحقق ومجموعة الاختبار، وذلك بنسبة

70% لمجموعة التدريب و 15% لمجموعتي التحقق والاختبار. ومن ثم شكّلت شبكة عصبية صناعية تتضمن طبقة مدخلات مكونة من أربعة عصبونات تمثل درجة الحرارة الجافة والرطوبة النسبية، سرعة الرياح والسطوح الشمسي، وطبقة مخرجات مكونة من عصبون واحد يمثل التبخر اليومي، في حين حُدد عدد العصبونات في الطبقة الخفية بالتجريب، وذلك بتغيير عدد عصبونات الطبقة الخفية وتدريب الشبكة لغاية الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية ثابتة العدد Epoches مقدارها (1000). ولتقليل قيمة الخطأ بين القيم المحسوبة من الشبكة والقيم المأمولة، مما يحسّن كفاءة العمليات الحسابية وأداء الشبكة، تم تقييس كافة البيانات، كما هو موضح في المعادلة (1):

$$(1) X_{norm} = \frac{X_{real} - X_{min}}{X_{max} - X_{min}}$$

حيث:  $X_{real}$  القيمة الحقيقية المراد تقييسها

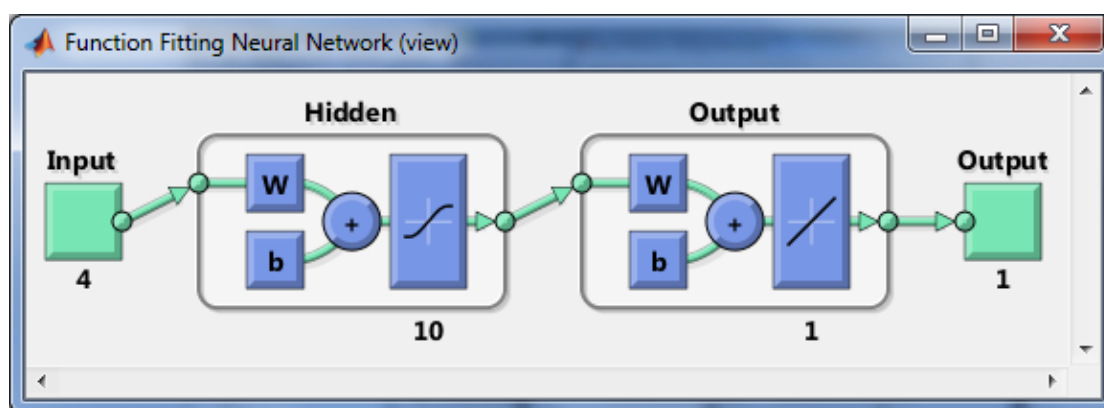
$X_{min}$  القيمة الحقيقية الدنيا

$X_{max}$  القيمة الحقيقية العظمى

تدريب الشبكة العصبية الصناعية المقترحة


1. الشبكة ANN4:

إنّ الهدف من تدريب الشبكة هو تغيير أوزانها للحصول على الخرج المأمول للمدخلات المعطاة. وبعد إجراء عدد كبير من التجارب تبين أن الشبكة العصبية الصناعية ذات الهيكلية (1-10-4)، الشكل (3)، تعطي أقل قيمة لمربع متوسط الخطأ ويساوي (0.037) لمجموعة التدريب و (0.0327) لمجموعة التحقق و (0.043) لمجموعة الاختبار، مع استخدام دالة التفعيل Logsigmoid Transfer Function في الطبقة الخفية تُتبع بدالة تفعيل Linear Transfer Function في طبقة الإخراج وبالاعتماد على خوارزمية التعلّم (Levenberg Marquardt) لتدريب الشبكة.



الشكل(3): هيكلية الشبكة ANN4

يبين الشكل (4) أداء الشبكة العصبية الصناعية للمجموعات الثلاث، حيث يوضح نقطة توقف التدريب لدورات تكرارية أقل عدداً من الدورات التكرارية في حال الاعتماد على مجموعة التدريب فقط وبمربع متوسط خطأ يساوي إلى (0.032743) لمجموعة التحقق. حيث كانت قيمة معامل الارتباط لهذه المجموعة مساوية لـ 0.8324 .




الشكل(3): يبين أداء الشبكة العصبية الاصطناعية للمجموعات الثلاث للشبكة ANN4

## 2. الشبكة ANN4+T:

لدراسة تأثير معامل الزمن على تقدير التبخر في المنطقة الجبلية قمنا بإضافة معامل الزمن إلى مدخلات الشبكة السابقة وبعد إجراء عدد كبير من التجارب تبين أن الشبكة العصبية الاصطناعية ذات الهيكلية (1-10-5) تعطي أقل قيمة لمربع متوسط الخطأ ويساوي ( 0.0272 ) لمجموعة التدريب و (0.02166) لمجموعة التحقق و (0.0402) لمجموعة الاختبار، مع استخدام دالة التفعيل Logsigmoid Transfer Function في الطبقة الخفية تُنبع بدالة تفعيل Linear Transfer Function في طبقة الإخراج وبالاعتماد على خوارزمية التعلّم ( Levenberg Marquardt).

يبين الشكل (5) أداء الشبكة العصبية الاصطناعية للمجموعات الثلاث، حيث يوضح نقطة توقف التدريب لدورات تكرارية أقل عدداً من الدورات التكرارية في حال الاعتماد على مجموعة التدريب فقط وبمربع متوسط خطأ يساوي إلى (0.02166) لمجموعة التحقق. حيث كانت قيمة معامل الارتباط لهذه المجموعة مساوية لـ 0.8919 .





الشكل(5): يبين أداء الشبكة العصبية الصنعية للمجموعات الثلاث للشبكة ANN4+T

يبين الجدول التالي قيم مربع متوسط الخطأ ومعامل الارتباط للمجموعات الثلاث لكل من الشبكتين السابقتين:

الجدول (1) قيم مربع متوسط الخطأ ومعامل الارتباط للشبكتين المدروستين

|        | MSE    |            |        | R      |            |        |
|--------|--------|------------|--------|--------|------------|--------|
|        | Train  | Validation | Test   | Train  | Validation | Test   |
| ANN4   | 0.037  | 0.0327     | 0.043  | 0.79   | 0.8324     | 0.713  |
| ANN4+T | 0.0272 | 0.02166    | 0.0402 | 0.8471 | 0.8919     | 0.7707 |

يوضح الجدول السابق تفوق الشبكة المضاف لها معامل الزمن حيث بلغ معامل الارتباط فيها لمجموعة التحقق 0.8919 ومتوسط مربع الخطأ 0.02166 بينما كانت قيمة معامل الارتباط للشبكة المستخدمة للتنبؤ بقيمة التبخر اعتماداً على المعطيات المناخية بدون إدخال معامل الزمن 0.8324 ومتوسط مربع الخطأ 0.0327.

### الاستنتاجات والتوصيات

- ✓ يمكن استخدام الشبكات العصبية الصنعية متعددة الطبقات وذات الانتشار العكسي للخطأ ذات الهيكلية (4-10) في تقدير التبخر اليومي في المنطقة الجبلية من الساحل السوري باستثناء الأيام التي تقل درجة الحرارة الوسطية فيها عن 3 درجة مئوية وتزيد عن 32 درجة مئوية وتتجاوز سرعة الرياح الوسطية فيها 14 م/ثا.
- ✓ يوجد توافق خطي بين مخرجات الشبكة العصبية الصنعية وبيانات التبخر المقاسة بوساطة حوض التبخر، مما يبيّن إمكانية استخدام هذه التقنية في تقدير التبخر اليومي في بحيرات السدود الموجودة في هذه المنطقة.
- ✓ تفوق أداء الشبكة العصبية المضاف إليها معامل الزمن بحيث أصبح معامل الارتباط 0.89 مع الزمن، بدلاً من 0.83 بدون الزمن.

### واعتماداً على نتائج البحث يمكن وضع التوصيات الآتية:

- ✓ توسيع بناء شبكة عصبية صناعية لتقدير التبخر اليومي بافتراض أسلوب التدريب دون إشراف.
- ✓ التوسع في استخدام الشبكات العصبية لدراسة مسائل متنوعة تتعلق بالإدارة الكفوءة للموارد المائية في سورية.

### المراجع :

- [1] الشلاوي، سوسن، مقارنة تطبيقات الشبكة العصبية الاصطناعية والنظام المضرب لتقدير التبخر الانائي اليومي لمنطقة الموصل. مجلة الكوفة للرياضيات والحاسبات. (2011)1(3)
- [2] 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, 13-14 May 2011
- [3] Kumar,P. et al, *Evaporation Estimation Using Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Techniques* , Pakistan Journal of Meteorology, Vol. 8, Issue 16: Jan 2012, 81-88
- [4] عمار، غطفان. حيدر، بادية . نمذجة التبخر - نتح مرجعي في منطقة صافيتا في سورية باستخدام الشبكة العصبية الصناعية. مجلة جامعة تشرين للدراسات والبحوث العلمية، (2013) Vol. 35, No. 4
- [5] SAMMEN, S. *Forecasting of evaporation from Hemeren reservoir by using artificial neural networks*. College of Engineering, Diyala University, Iraq. 2012
- [6] ابراهيم، سوزان، استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة لتقدير التبخر اليومي بمدينة الموصل بدلالة بعض المعلومات المناخية . كلية الحدباء الجامعة- مركز الدراسات المستقبلية - بحوث مستقبلية ( 45 ) (2014)، 171-191
- [7] SAYYED, M. et al, *Estimating of Reference Evapotranspiration by Using Artificial Neural Networks*. International Conference on Transport, Environment and Civil Engineering (ICTECE'2012) August 25-26, 2012 Kuala Lumpur (Malaysia)
- [8] عبد الحميد محمد العباسي. مقدمة في الشبكات العصبية الصناعية وتطبيقاتها في العلوم الاجتماعية باستخدام *spss* . معهد الدراسات والبحوث الإحصائية مصر . 2013 ، 1-39 .
- [9] DEMUTH, H.; BEALE, M. *Neural Network Toolbox*, U. S. A, 2002, 840.
- [10] James A. Freeman, *Neural Networks: Algorithms, Applications, and Programming Techniques*, Addison-Wesley, (1991) - 401 pages
- [11] سجلات مديرية الري العامة لحوض الساحل - الأعوام 2005-2010