

## Estimation of Daily Evaporation in 16 Tishreen Dam Reservoir Using Artificial Neural Networks

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

Dr. Mais Alean<sup>\*\*</sup>

Zena Jouny<sup>\*\*\*</sup>

(Received 15 / 5 / 2019. Accepted 2 / 9 / 2019)

### □ ABSTRACT □

Accurate estimation of potential evaporation, has a great significance in many water resources applications such as management of hydrologic, hydraulic and agricultural systems. Although there are empirical formulas available for Evaporation estimation, but their performances are not all satisfactory due to the complex nature of the evaporation process and nonlinear relationship with other hydrological cycle elements. For this purpose, artificial neural network (ANN) model was developed to estimate daily potential evaporation in 16 Tishreen Dam Reservoir located in Lattakia. The feed forward back propagation network with one hidden layer has been used to construct the mode. Different networks with different number of neurons were evaluated. Daily observations of average temperature, average relative humidity, average wind speed, sunshine hours and evaporation have been used to train and test the developed models. Correlation coefficient (R) and Root mean square error (RMSE) were employed to evaluate the accuracy of the proposed model.

The study showed the best model for evaporation estimation is ANN (4-13-1) with correlation coefficient (R) of 90.5% and the root-mean-square error value (RMSE) of 0.877mm/day for validation dataset. The findings of this study suggest the usefulness of ANN technique in estimating the evaporation losses from the study area.

**Keywords:** Artificial neural network, evaporation losses, feed forward, back propagation.

---

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

<sup>\*\*</sup> Doctor, Directorate of Tartos Port, Tartous. Syria.

<sup>\*\*\*</sup> Postgraduate Student(Master), Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria. Email:zenajouny.90@gmail.com.

## تقدير التبخر اليومي من بحيرة سد 16 تشرين باستخدام الشبكات العصبية الصناعية

د. غطفان عمّار\*

د. ميس عليان\*\*

زينة فيصل جوني\*\*\*

(تاريخ الإيداع 15 / 5 / 2019. قَبْلَ للنشر في 2 / 9 / 2019)

### □ ملخص □

إن التقدير الدقيق لخواص التبخر يلعب دوراً هاماً في العديد من تطبيقات الموارد المائية كإدارة الأنظمة الهيدرولوجية والهيدروليكية والزراعية. وعلى الرغم من وجود صيغ تجريبية متاحة لتقدير التبخر إلا أن أدائها ليس مرضياً بسبب الطبيعة المعقدة لعملية التبخر، وعلاقته غير الخطية مع غيره من عناصر الدورة الهيدرولوجية. لهذا الغرض، تم تطوير نموذج لشبكة عصبية صناعية (ANN) لتقدير التبخر اليومي من بحيرة سد 16 تشرين في مدينة اللاذقية. استخدمت الشبكة العصبية الصناعية أمامية التغذية ذات الانتشار العكسي للخطأ مع طبقة خفية واحدة لإنشاء النموذج. تم تقييم شبكات مختلفة مع عدد مختلف من الخلايا العصبية. استخدمت البيانات اليومية المتوافرة لدرجة الحرارة الوسطية، الرطوبة النسبية الوسطية، سرعة الرياح الوسطية، ساعات السطوع الشمسي والتبخر لتدريب واختبار النماذج المقدمه. كما استخدم معامل الارتباط (R) وجذر متوسط مربع الخطأ (RMSE) لتقييم دقة النموذج المقترح. أظهرت الدراسة أن أفضل نموذج لتقدير التبخر هو (4-13-1) ANN مع معامل ارتباط (R=90.5%) من أجل مجموعة التحقق وجذر متوسط مربع الخطأ (RMSE=0.877mm) للمجموعة ذاتها. تشير نتائج هذه الدراسة إلى الكفاءة الكبيرة للشبكة العصبية الصناعية في تقدير خواص التبخر من منطقة الدراسة.

**الكلمات المفتاحية:** شبكة عصبية صناعية، فواقد التبخر، تغذية أمامية، انتشار عكسي.

### مقدمة:

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

\*\* دكتورة - مديرة مرفأ طرطوس - سورية.

\*\*\* طالبة دراسات عليا (ماجستير) - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

البريد الإلكتروني: zenajouny.90@gmail.com

يعتبر التبخر من العوامل الهامة في الدورة الهيدرولوجية، وعنصراً أساسياً من عناصر الموازنة المائية لأية منطقة. ويعدّ تقديره الدقيق مطلباً أساسياً للمهندسين والباحثين في العديد من المجالات كتصميم وإدارة مشاريع الري وتخطيط الموارد المائية وخاصةً في المناطق التي تعاني من نقص في مواردها المائية المتاحة. وتتأثر عملية التبخر بالعديد من المتغيرات الجوية التي تتفاعل مع بعضها البعض مما يجعل العلاقة فيما بينها معقدة جداً، وبالتالي يصعب الحصول على تقديرات موثوقة للتبخر بسبب التفاعلات بين مكونات النظام الأرضي-النباتي-الجوي [1]. من الناحية العملية، يمكن ملاحظة التبخر اليومي باستخدام حوض التبخر (Class A Pan) وهو أكثر الطرائق المباشرة المستخدمة على نطاق واسع. ولكن في بعض الأحيان، قد يتم فقدان بيانات التبخر اليومية بسبب فشل القياس أو التسجيل، يمكن تقدير هذه البيانات المفقودة بشكل غير مباشر باستخدام بيانات الأرصاد الجوية المتوفرة اعتماداً على بعض المعادلات التجريبية [2]. وقد وجد العديد من الباحثين أن دقة هذه الأساليب في العديد من المناطق مشكوك فيها لأنها أكثر ملاءمة في البلدان التي تم تطويرها فيها وذلك نظراً لاختلاف المناخ بين منطقة وأخرى [5]، [3]، [4].

ولذلك أجريت العديد من الدراسات لتحديد العلاقة الموثوقة بين التبخر وعوامل الأرصاد الجوية، اكتسبت من بينها الشبكات العصبية الصناعية (Artificial Neural Networks) ANN انتشاراً كبيراً على مدى السنوات القليلة الماضية بسبب قدرتها على نمذجة العمليات المعقدة بدقة عالية. اعتمدت أغلب الدراسات، كما هو الحال في هذه الدراسة، على المعيارين الآتيين للحكم على دقة النتائج وهما: جذر متوسط مربع الأخطاء RMSE والذي يعتبر مثالياً عندما تتناهى قيمته إلى الصفر، وهذا غير ممكن عملياً وفي معظم الدراسات السابقة تراوحت قيمته بين 1mm و 2mm في اليوم. أما المعيار الثاني فهو معامل الارتباط R والذي يعتبر جيداً ويمكن اعتماده عندما تكون قيمته محصورة بين (1-0.75).

فعلى سبيل المثال، قام Chaudhari, N et al بنمذجة التبخر في منطقة Nasik في الهند باستخدام الشبكة العصبية الصناعية ANN. وشملت البيانات المستخدمة كل من الرطوبة العظمى والصغرى، درجة الحرارة العظمى والصغرى، سرعة الرياح وساعات الإشعاع الشمسي. أظهرت النتائج أنّ الشبكة العصبية تعطي نتائج أفضل بالمقارنة مع الطرائق التجريبية. وكانت نتائج الشبكة هي  $R=0.89$  و  $RMSE=1.03mm/day$  من أجل هذه المنطقة هذه المنطقة [6].

كما قارن Dalkılıç, Y et al أداء أربعة نماذج للتنبؤ بالتبخر اليومي. وهذه النماذج هي معادلة بنمان التجريبية، الشبكة العصبية الصناعية مع خوارزمية تدريب Levenberg-Marquard (LMANN)، الشبكة العصبية ذات الأساس الشعاعي والشبكة العصبية ذات الانحدار المعمم. توصلت الدراسة إلى أنّ نماذج الشبكة العصبية تعطي نتائج أفضل من نتائج معادلة بنمان. كما تتفوق شبكة LMANN على باقي النماذج في تقدير التبخر اليومي مع قيمة  $RMSE=1.51mm/day$  ومعامل ارتباط  $R=0.853$  [7].

أما الدراسة التي أجراها Benzaghta, M فقد تضمنت تطبيق كل من الشبكات العصبية الصناعية ANN والمعادلات التجريبية (بنمان، بريستلي تايلور، ستيفنز ستيوارت) لتقدير التبخر من خزان Algardabiya في ليبيا. تضمنت متغيرات الأرصاد الجوية المقاسة الرصد اليومي لدرجة حرارة الهواء، الرطوبة النسبية وسرعة الرياح. وبإجراء المقارنة بين نتائج النماذج السابقة وقيم التبخر المقاسة، تبين أنّ الشبكات العصبية تعطي أداءً أفضل من المعادلات التجريبية في تقدير التبخر من هذه المنطقة [8].

كما طور Pallavi and Rajeev نموذجاً للشبكة العصبية الصناعية لتقييم التبخر اليومي في الهند. استخدمت الشبكة أمامية التغذية ذات الانتشار العكسي للخطأ لإنشاء النموذج. أظهرت الدراسة أن أفضل نموذج لتقدير التبخر هو ANN (1-9-4) مع معامل ارتباط ( $R=0.987$ ) وجذر متوسط مربع أخطاء (RMSE=1.276mm/day) [9]. كما استخدم Banhatti and Dubey الشبكة العصبية الصناعية لتقدير التبخر اليومي من بحيرة Abaya في إثيوبيا. وكانت البيانات المستخدمة كمدخلات للشبكة هي درجة الحرارة، الأمطار، الرطوبة النسبية، ساعات السطوح الشمسي وسرعة الرياح. أظهرت النتائج أن القيم التي تنتبأ بها ANN تتطابق بشكل وثيق جداً مع القيم المرصودة فعلياً. كما أنها أفضل دقة من نتائج معادلة بنمان في حساب التبخر من هذه البحيرة [10].

#### مشكلة البحث:

يعدّ قياس التبخر بدقة واستمرار عمليةً صعبة، ولا تزال توجد مشاكل كبيرة في قياس التبخر حيث لا تتوفر بيانات التبخر الموثوقة في كثير من الأحيان. ورغم توافر العديد من المعادلات التجريبية لتقدير التبخر، إلا أن هذه المعادلات تمثل ظروفاً محلية ومناخية مختلفة بشكل كبير مما يؤثر على دقة النتائج عند تطبيقها في أماكن أخرى. وبما أنه لا يوجد نموذج واحد ملائم عالمياً في جميع الظروف المناخية، فمن الصعب اختيار أنسب نموذج للتبخر في منطقة معينة. وفي ظل غياب معدل التبخر المقيس لفترات طويلة كما هو الحال في منطقة الدراسة، يأتي التساؤل عن إمكانية توافر طريقة حديثة قادرة على نمذجة العلاقات المعقدة وغير الخطية وتمكننا من وضع تقديرات دقيقة وموثوقة للتبخر اليومي اعتماداً على عدد محدد من البارامترات المتوافرة في محطات الرصد التابعة للمنطقة المدروسة.

#### أهمية البحث وأهدافه:

نظراً للاحتياج المائي المتزايد والنقص في الموارد المائية المتوافرة حيث تفقد كميات ضخمة من المياه سنوياً بسبب التبخر، تأتي أهمية التقدير الدقيق لفوائد التبخر من الأحواض المائية وخزانات السدود كعامل أساسي ومهم في إدارة واستثمار وتنمية الموارد المائية، مما يستدعي البحث عن طرائق بديلة أكثر دقة لتقدير هذه الفوائد. لذلك تهدف هذه الدراسة إلى إيجاد نموذج لشبكة عصبية صناعية لتقدير التبخر اليومي من بحيرة سد 16 تشرين اعتماداً على البيانات المتوافرة في منطقة الدراسة.

#### طرائق البحث ومواده:

▪ البيانات المناخية المستخدمة في عملية بناء النموذج (Metrological Data):  
جمعت البيانات المناخية من محطة سد 16 تشرين للأرصاد الجوية، تقع بحيرة سد 16 تشرين شمال غرب سورية، في محافظة اللاذقية، على مجرى نهر الكبير الشمالي، تبعد حوالي (16 Km) عن مدينة اللاذقية تقدر سعتها التخزينية بحوالي (210) مليون م<sup>3</sup> من المياه، وتبلغ مساحة سطح البحيرة بحدود (11.2km<sup>2</sup>)، تستخدم مياه البحيرة لري الأراضي الزراعية وتربية الأسماك، يبين الشكل (1) موقع منطقة الدراسة.



الشكل (1): موقع منطقة سد 16 تشرين

تضمنت هذه البيانات القياسات اليومية لكل من سرعة الرياح الوسطية ( $WS_{av}$  (m/s) ، درجة حرارة الهواء الوسطية ( $T_{av}$  (C°) ، الرطوبة النسبية (RH(%)) وساعات السطوع الشمسي (SS(hour)). وذلك لفترة الزمنية الممتدة من (2005–2009)، حيث استخدمت هذه البيانات كمدخلات للنموذج (Input). كما تضمنت البيانات القياسات اليومية للتبخر (E (mm) المقيس باستخدام حوض التبخر من الصنف A، والتي استخدمت كمخرجات للنموذج (Output) كما تم الاعتماد عليها للتأكد من صحة أداء النموذج.

#### تقييم للبيانات (Data normalization):

يتطلب عمل الشبكة العصبية الصناعية إجراء عملية التقييم للبيانات وذلك لجعل قيم عناصرها قريبة من بعضها البعض مما يحسن كفاءة وفعالية العمليات الحسابية وجودة أداء الشبكة ويقلل قيمة الخطأ. واستخدمت لهذا الغرض المعادلة التالية حيث تبين بالتجريب أنها تعطي نتائج أفضل من غيرها من المعادلات [11]:

$$X_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

حيث:

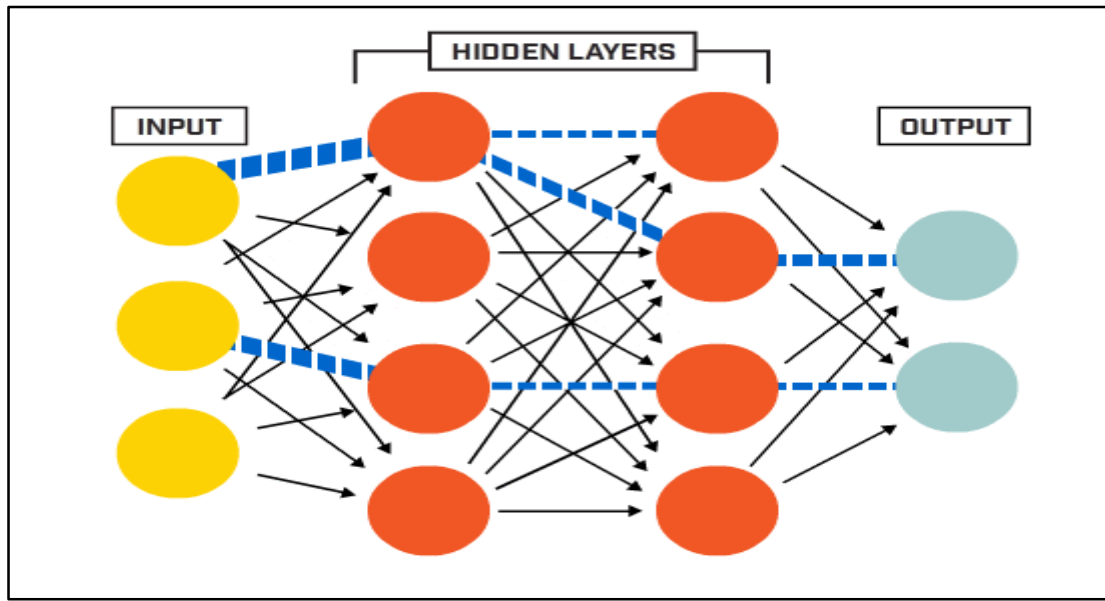
$X_{norm}$ : القيمة المقيسة.  $X_{max}$ : القيمة العظمى.  
 $X$ : القيمة الحقيقية المراد تقييمها.  $X_{min}$ : القيمة الصغرى.

#### الشبكة العصبية الصناعية ANN (Artificial Neural Network):

تعد الشبكات العصبية الصناعية من أهم مجالات الذكاء الاصطناعي الذي يعكس تطوراً هاماً ولموساً في طريقة التفكير الإنساني، وتدور فكرة الشبكات العصبية الصناعية حول محاكاة العقل البشري باستخدام الحاسوب [12]. وتعرف بأنها نموذج معالجة المعلومات المستوحى من الطريقة التي تعمل بها الأنظمة العصبية البيولوجية، مثل

الدماغ. يتكوّن هيكّل الشبّكة العصبية الصنعية من عدد كبير من عناصر المعالجة المترابطة للغاية (العصبونات) التي تعمل معاً لحل مشكلة معينة بالإضافة إلى وصلات بينية فيما بينها لكل منها قيمة محددة تدعى الوزن. يعتمد التعلّم في النظم البيولوجية على التكيف مع الروابط الشبكية الموجودة بين العصبونات، ويحدث نفس الشيء في ANN حيث تتلقّى العصبونات مدخلات من مصادر مفردة أو متعددة وتنتج مخرجات وفقاً لوظيفة غير خطية محددة سلفاً تسمى وظيفة التنشيط [13]. السمات الأساسية الثلاثة للشبّكة العصبية هي بنية الشبّكة، الوظيفة الحسابية وتدريب الشبّكة:

✓ **بنية الشبّكة (Network Topology):** هي عدد وتنظيم وحدات المعالجة (العصبونات)، ونوع الوصلات بين العصبونات واتجاه تدفق المعلومات في الشبّكة. عدد العصبونات في طبقة الإدخال هو عدد المتغيرات المستقلة في حين أن عدد عصبونات طبقة الإخراج يتوافق مع عدد المتغيرات التي يمكن التنبؤ بها. يتميز نموذج ANN البسيط بشبّكة تتكوّن من ثلاث طبقات من وحدات المعالجة: طبقة إدخال (input layer) وطبقة خفية (hidden layer) وطبقة إخراج (Output layer) والتي تكون متصلة مع بعضها البعض كما هو موضح في الشكل (2). يختلف عدد الطبقات والعصبونات المستخدمة داخل الطبقة الخفية وفقاً لتعقيد المهمة التي يجب أن تؤديها الشبّكة.



الشكل (2): بنية الشبّكة العصبية الصنعية

كما أنه لا توجد قاعدة صارمة تحدّد التكوين الأمثل للشبّكة العصبية لحل مشكلة معينة [14].

✓ **الوظيفة الحسابية (Computational Functions):** هي ميزة أخرى للشبّكة العصبية التي تتكوّن من عمليات الخلايا العصبية الفردية والطريقة التي ترتبط بها. يتم نقل المعلومات من خلال الوصلات بين العصبونات في الطبقات بمساعدة الأوزان المتصلة ( $w_{ij}$  و  $w_{jk}$ )، حيث يعبر الوزن عن شدة الترابط بين عصبون قبله وعصبون بعده. وهذا العصبون ينقسم إلى قسمين:

-الجامع أو دالة التجميع (Summation Function) لجمع الإشارات في الدخّل الموزون.

- تابع النقل أو تابع التفعيل (Activation Function): وهذا التابع يحد من خرج العصبون لذا يسمى بتابع التخميد (Squashing) حيث يجعل الخرج ضمن المجال  $\{1,0\}$  أو  $\{-1,1\}$ .

✓ **تدريب الشبكة (Training of the Network):** يهدف إلى تحديد بارامترات التحكم الرئيسية لـ ANN والتي تسمى الأوزان. تُعرف عمليات تقدير هذه البارامترات بالتدريب حيث يتم تحديد أوزان التوصيل المثلى عن طريق تقليل قيمة تابع الخطأ [15]. هناك نوعان أساسيان من آليات التدريب: التدريب الخاضع للإشراف وغير الخاضع للإشراف. يتضمن التدريب الخاضع للإشراف: تزويد الشبكة بمتجهات الدخل والخرج وتعليم الشبكة كيفية ربط قيم الدخل مع القيم المقابلة للخروج المطلوب، ويعتبر هذا الأسلوب مفيداً في حل مشاكل التصنيف أو تعلم سلوك محدد، وذلك عندما تكون القيم أو الأنماط المرغوب بها موجودة. أما في التدريب غير الخاضع للإشراف يتم تزويد الشبكة بمتجهات الدخل فقط، وتتعلم الشبكة بعض المميزات الداخلية لمجموعة البيانات الكلية من خلال مجموعة متجهات الدخل المقدّمة لها [16].

الخطوات الرئيسية المتضمنة في التدريب هي كالتالي [13]:

- (1) تهيئة قيمة أوزان الشبكة، عادةً باستخدام أعداد صغيرة تولّد بشكل عشوائي.
- (2) القيام بنشر متجه الإدخال الأول عبر الشبكة بأكملها، أي: إشارات الإدخال تضرب في الأوزان المقابلة ثم يتم جمعها عند كل عصبون، ومن ثم يتم تحويل قيمة الجمع هذه بواسطة وظيفة التنشيط وإرسالها إلى طبقة الخرج.
- (3) حساب الخطأ بمقارنة ناتج النموذج بالبيانات المستهدفة.
- (4) إعادة نشر معلومات الخطأ من خلال الشبكة.
- (5) تحديث الأوزان.
- (6) تكرار الخطوات السابقة لعدة تكرارات حتى يصبح الخطأ ضمن نطاق مقبول.

استخدمت في هذه الدراسة الشبكة العصبية الصناعية أمامية التغذية (Feedforward Neural Network) وهي الشبكة التي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكوّنة لها، وتعد هذه الشبكات من أكثر الشبكات استخداماً، حيث تتكون الشبكة من هذا النوع من طبقتين على الأقل، كما تتواجد في كثير من الأحيان طبقات خفية (Hidden layers) بين طبقة المدخلات وطبقة المخرجات وتنتقل العمليات الحسابية في اتجاه واحد إلى الأمام من طبقة المدخلات إلى طبقة المخرجات عبر الطبقات الخفية [12].

تعد خوارزمية الانتشار العكسي للخطأ (Error Backpropagation) من أهم خوارزميات تدريب الشبكات العصبية ذات التغذية الأمامية، والتي تعمل بالشكل الآتي [17]:

- بعد انتقال القيم إلى طبقة المخرجات، يتم إجراء مقارنة بين القيم المحسوبة والقيم الفعلية (حساب الخطأ) من خلال معادلة الخطأ التالية:

$$E = (X_i - Y_i) \quad (2)$$

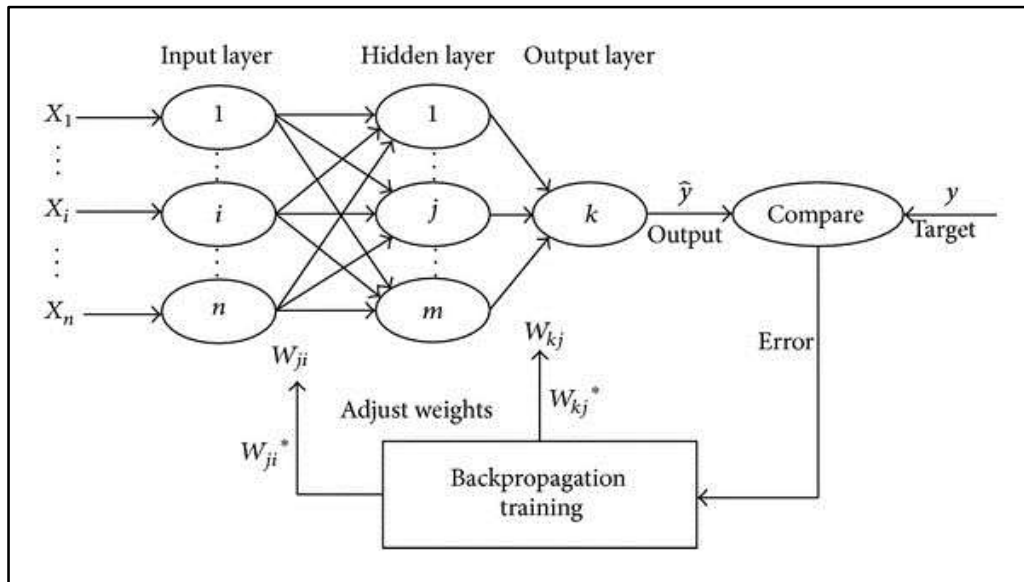
حيث:  $(X_i)$ : المخرجات الهدف،  $(Y_i)$ : المخرجات المحسوبة من الشبكة.

- تصحيح الوزن وتعديله من خلال عملية التعلم التي تتم على الشبكة، وذلك من خلال المعادلة الآتية:

$$W_i(\text{final}) = W_i + \alpha \cdot \beta \cdot X_i$$

حيث:  $(\alpha)$  تعبر عن معدل التعلّم، بينما تعبر  $(\beta)$  عن الفرق بين القيمة المحسوبة والقيمة الهدف وذلك لحساب الخطأ. وتسمى هذه الانتشار العكسي (backpropagation) حيث يتم نشر هذه القيم باتجاه عكسي نحو طبقة الإدخال.

- تكرر هذه الخطوات في الشبكة لعدة مرات بخطوة أمامية وخطوة تراجعية (مرحلة التغذية الأمامية-مرحلة الانتشار العكسي) والتي يطلق عليه دورة أو Epoch. يبين الشكل (3) آلية عمل خوارزمية الانتشار العكسي



للخطأ.

الشكل (3): آلية عمل خوارزمية الانتشار العكسي للخطأ

- معايير تقييم أداء النموذج (Model performance evaluation):  
يوجد العديد من المؤشرات الإحصائية المستخدمة لاختبار مدى ملائمة الشبكة لحل مشكلة ما، وتحديد النماذج الأفضل والأكثر دقة. نذكر منها جذر متوسط مربعات الأخطاء RMSE (Root Mean Square Error) ومعامل الارتباط (R) (Correlation Coefficient)، والتي تعطى بالمعادلات الآتية [18]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}}$$

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{[\sum_{i=1}^N (O_i - \bar{O})^2]^{0.5} [\sum_{i=1}^N (P_i - \bar{P})^2]^{0.5}}$$

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

النتائج والمناقشة:



في هذا البحث، تم بناء نماذج الشبكة العصبية الصناعية ذات التغذية الأمامية والانتشار العكسي للخطأ FFBPANN لتقدير التبخر اليومي من بحيرة سد 16 تشرين وباستخدام بيانات محطة الأرصاد الجوية الموجودة في منطقة الدراسة. وتشمل هذه البيانات القياسات اليومية لكل من درجة الحرارة  $T_{av}$ ، الرطوبة النسبية  $RH_{av}$ ، سرعة الرياح  $WS_{av}$ ، ساعات الإشعاع الشمسي  $SH$  والتبخر  $E$ . وذلك لفترة الزمنية الممتدة بين (2005-2009) حيث بلغ عدد البيانات اليومية الإجمالية قيمة 1691، يعرض الجدول (1) ملخص التحليل الإحصائي للبيانات مثل المتوسط والانحراف المعياري والحد الأدنى والحد الأقصى.

الجدول (1): التحليل الإحصائي للبيانات

مجموعة البيانات	الوحدة	المتوسط الحسابي	القيمة العظمى	القيمة الصغرى	الانحراف المعياري
$T_{av}$	(C°)	18.93	30.6	2.7	6.64
$WS_{av}$	(m/s)	2.86	8	1	1.12
$RH_{av}$	(%)	65.87	94.6	23.4	12.58
$SH$	hour (h)	8.021	14	0	3.66
$E$	(mm/day)	3.76	11	0	2.7

وبعد إجراء عملية التقييم للبيانات باستخدام المعادلة المذكورة سابقاً، استخدم برنامج MATLAB والأدوات الملحقة به NNTOOL لبناء نماذج الشبكات العصبية الصناعية. تضمنت مدخلات الشبكة قيم ( $T_{av}, WS_{av}, RH_{av}, SH$ )، بينما استخدمت بيانات التبخر اليومية  $E$  كمخرجات للشبكة. قسمت البيانات إلى ثلاث مجموعات: مجموعة تدريب (Training dataset)، مجموعة تحقق (Validation dataset) ومجموعة اختبار (Testing dataset) وذلك بنسبة (10%, 15%, 75%) على التوالي. استخدمت مجموعة التدريب لتدريب الشبكة في حين تم استخدام مجموعة التحقق من الصحة لرصد أو اختبار أداء الشبكة في مراحل منتظمة أثناء التدريب حيث يتوقف التدريب عندما تصل الأخطاء في مجموعة التحقق إلى الحد الأدنى. وأخيراً، يتم تقييم أداء الشبكة على مجموعة بيانات الاختبار التي لم تشارك في عملية التدريب.


بعد الانتهاء من إدخال البيانات، تم إنشاء شبكة عصبية صناعية بأربعة مدخلات ومخرج واحد، أما عدد العصبونات في الطبقة الخفية تم تحديده عن طريق التجريب للحصول على أقل قيمة لجذر متوسط مربع الأخطاء RMSE. تم إجراء عدد كبير جداً من التجارب على شبكات عصبية بهيكلية مختلفة وذلك بتغيير عدد العصبونات في الطبقة الخفية وكذلك توابع التفعيل المستخدمة في كل من الطبقة الخفية وطبقة الخرج، بالإضافة إلى التغيير في الخوارزميات المستخدمة لتدريب الشبكة. حيث درّبت كل شبكة من هذه الشبكات 1000 مرة ثم حسب قيمة RMSE و R في كل مرة لكل مجموعة من المجموعات، يبين الجدول (2) معايير تقييم الأداء لأفضل النماذج الناتجة بمختلف الهيكليات.

A (2): معايير تقويم الأداء لأفضل النماذج الناتجة بمختلف الهيكليات.


تابع التفعيل		هيكلية الشبكة العصبية الصناعية	جذر متوسط مربع الخطأ RMSE				معامل الارتباط R			
الطبقة الخفية	طبقة الإخراج		مجموعة الاختبار	مجموعة التحقق	مجموعة التدريب	المجموعة الكلية	مجموعة الاختبار	مجموعة التحقق	مجموعة التدريب	المجموعة الكلية
log sigmoid	tan sigmoid	4-6-1	0.965	1.005	1.009	1.002	0.879	0.868	0.880	0.878
		4-7-1	0.960	0.986	1.023	1.008	0.883	0.866	0.877	0.876
		4-8-1	1.132	0.898	0.991	1.000	0.853	0.905	0.879	0.879
		4-9-1	0.985	1.074	0.997	1.007	0.888	0.862	0.878	0.877
		4-10-1	0.928	0.921	0.992	0.972	0.882	0.904	0.878	0.882
		4-11-1	0.995	0.973	1.058	1.037	0.856	0.884	0.868	0.869
		4-12-1	0.935	0.978	1.012	0.996	0.888	0.891	0.876	0.880
		4-13-1	0.929	0.877	1.022	0.988	0.896	0.905	0.879	0.886
		4-14-1	0.887	1.111	1.007	1.007	0.915	0.861	0.874	0.879
		4-15-1	0.941	1.006	1.032	1.015	0.887	0.867	0.875	0.876
		4-16-1	1.029	0.908	0.985	0.980	0.882	0.907	0.880	0.884
		4-17-1	0.949	1.045	0.962	0.973	0.896	0.879	0.886	0.886
		4-18-1	0.990	0.928	1.047	1.022	0.881	0.900	0.865	0.873
		4-19-1	0.962	0.943	0.999	0.985	0.902	0.896	0.874	0.883
4-20-1	0.991	0.922	1.034	1.012	0.890	0.895	0.869	0.876		
tan sigmoid	tan sigmoid	4-6-1	0.979	0.941	1.098	1.058	0.888	0.873	0.856	0.864
		4-7-1	1.088	0.930	1.036	1.029	0.867	0.904	0.865	0.871
		4-8-1	1.020	0.898	1.011	0.996	0.893	0.903	0.871	0.880
		4-9-1	0.966	0.899	1.085	1.042	0.880	0.886	0.862	0.867
		4-10-1	1.098	0.955	0.995	1.005	0.836	0.891	0.883	0.877
		4-11-1	0.964	0.944	0.968	0.964	0.878	0.896	0.888	0.888
		4-12-1	1.037	0.892	0.984	0.979	0.869	0.882	0.888	0.884
		4-13-1	1.001	0.911	1.029	1.008	0.876	0.907	0.871	0.877
		4-14-1	1.086	0.933	1.001	1.004	0.854	0.892	0.881	0.879
		4-15-1	0.993	0.911	1.027	1.005	0.881	0.891	0.874	0.877
		4-16-1	0.975	0.946	1.007	0.993	0.895	0.881	0.877	0.880
		4-17-1	0.972	0.921	0.993	0.979	0.895	0.898	0.878	0.884
		4-18-1	0.964	0.937	0.969	0.963	0.887	0.899	0.886	0.888
		4-19-1	1.032	0.949	1.011	1.005	0.877	0.881	0.877	0.877
4-20-1	0.988	0.937	0.960	0.961	0.870	0.887	0.893	0.889		

نجد من الجدول السابق أنّ الشبكة العصبية الصناعية ذات الهيكلية 4-13-1 والتي تحتوي على طبقة خفية واحدة مع 13 عصبون الشكل (4)، والتي تستخدم تابع التفعيل logsigmoid في الطبقة الخفية و Tansigmoid في طبقة الخرج تعطي أفضل النتائج والأكثر ملائمة لقيم الظاهرة المدروسة، وهي تستخدم خوارزمية التدريب (LM) Levenberg-Marquardt. بلغت قيم جذر متوسط مربعات الأخطاء 0.929, 0.877, 1.022 mm/day من أجل مراحل التدريب والتحقق والاختبار على الترتيب، ومعاملات الارتباط 0.896, 0.905, 0.879 للمراحل نفسها

على الترتيب. ومن أجل مجموعة البيانات الكلية فقد أعطت الشبكة قيمة ل  $RMSE=0.988mm/day$  و  $R=0.886$ . ويبين الشكل (5) أداء الشبكة خلال المراحل الثلاث وآلية اختيار الدورة التكرارية الأفضل.

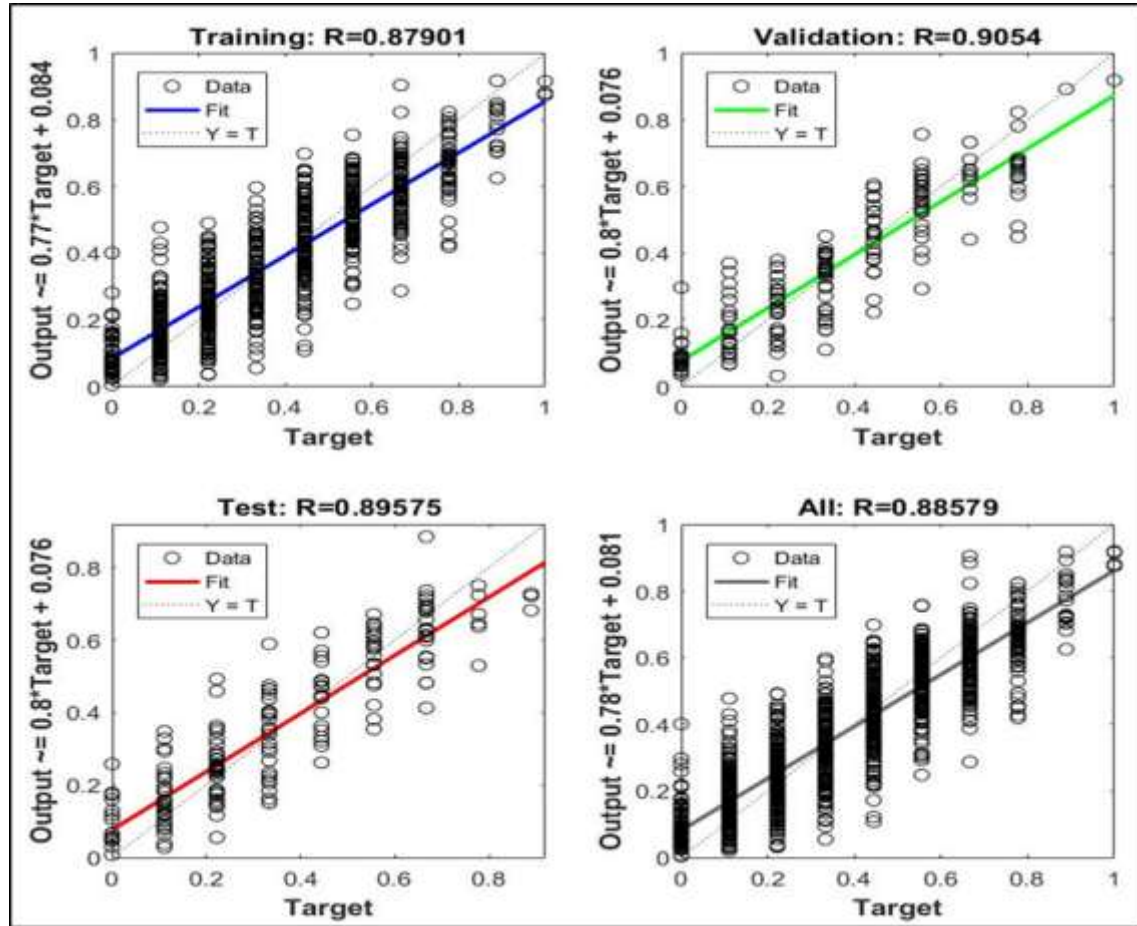


الشكل (4): أفضل معمارية للشبكة العصبية الصناعية



الشكل (5): أداء الشبكة (4-13-1) خلال المراحل الثلاث وآلية اختيار الدورة التكرارية الأفضل

كما يبين الشكل (6) قيم معاملات الارتباط بين القيم المحسوبة من قبل الشبكة وقيم التبخر المأخوذة من حوض التبخر وذلك للمراحل الثلاث ولمجموعة البيانات الكلية وهي قيم عالية مما يدل على قدرة النموذج المختار على محاكاة الظاهرة المدروسة.



الشكل (6): الارتباط بين قيم التبخر الإجمالي E والقيم الناتجة من الشبكة العصبية الصناعية من أجل مختلف المجموعات

### الاستنتاجات والتوصيات:

- أظهرت الشبكة العصبية الصناعية ذات الهيكلية (1-13-4) قدرتها على تقدير التبخر اليومي من محطة سد تشرين في الساحل السوري اعتماداً على درجة حرارة الهواء، الرطوبة النسبية، سرعة الرياح وساعات السطوع الشمسي وبجذر متوسط مربع خطأ 0.877mm/day ومعامل ارتباط 90.5% من أجل مجموعة التحقق.
- استناداً إلى نتائج الدراسة يمكن استخدام الشبكة العصبية الصناعية التي تم التوصل إليها في استكمال بيانات التبخر المفقودة لفترات طويلة في بحيرة سد تشرين.
- يوصى بدراسة إمكانية تقدير التبخر من بحيرة سد تشرين اعتماداً على درجة الحرارة فقط.
- التوسع في استخدام الشبكات العصبية الصناعية وأساليب الذكاء الاصطناعي للتنبؤ بالظواهر الهيدرولوجية والعمليات المتعلقة بالموارد المائية في سورية.

## المراجع:

1. SHIRGURE, S.P. *Evaporation modeling with artificial neural network: A review. Scientific Journal of Review*, 2013, Vol.2, No.2:73-84.
2. WU, C.M.; LIN, F.G.; LIN, Y. H. *The Effect of Data Quality On Model Performance with Application to Daily Evaporation Estimation. Stoch Environ Res Risk Assess*, 27, 2013: 1661-1671.
3. WANG, Y. M., Traore, S., & Kerh, T. (2007). *Assessment of evapotranspiration based on data information models at production sites in Burkina Faso. WSEAS Transactions on Computers*, 6, 880-887.
4. KHOOB, A. R. (2008). *Comparative study of Hargreaves and artificial neural networks methodologies in estimating reference evapotranspiration in a semiarid environment. Irrigation Science*, 26(3), 253-259.
5. SUDHEER, K. P., GOSAIN, A. K., & RAMASATRI, K. S. (2003). *Estimating actual evapotranspiration from limited climatic data using neural computing technique. Journal of Irrigation and drainage engineering, ASCE*, 129(3), 214-218.
6. CHAUDHARI, N.; LONDHE, S.; KHARE, K. *Estimation of Pan Evaporation Using Soft Computing Tools. Int. J. Hydrology Science and Technology*, Vol. 2, No. 4, 2012, 373-390.
7. 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.
8. BENZAGHTA, A.M. *Estimation of Evaporation from a Reservoir in Semi-Arid Environments Using Artificial Neural Network and Climate Based Models. British Journal of Applied Science & Technology*, 2014, Vol .4, No. 24, 3501-3518.
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. BANHATTI, A.; DUBEY, N. *Estimation of Daily Pan Evaporation for Lake Abaya using Artificial Neural Networks. International Journal of Computer Applications* 9758887 ,2016,15-19.
11. IZADBAKHS, A, M.; JAVADIKIA, H. *Application of Hybrid FFNN-Genetic Algorithm for Predicting Evaporation in Storage Dam Reservoirs. Journal of Agriculture Communications*, Vol.2, No. 4, 2014, 57-62.
12. العباسي، عبد الحميد. مقدمة في الشبكات العصبية الصناعية وتطبيقاتها في العلوم الاجتماعية باستخدام SPSS. مصر: معهد الدراسات والبحوث الإحصائية، جامعة القاهرة (2013).
13. ABDULKADIR, S. T.; SALAMI, W.A.; SULE, F.B.; ADEYEMO, A. J. *Neural Network Based Model for Forecasting Reservoir Storage for Hydropower Dam Operation. International Journal of Engineering Research and General Science*, Vol.3, No.5, September-October, 2015:639-647.
14. Kristen B. D.- Lee, W. L. *Artificial Neural Networks for the Management Researcher: The State of the Art. Department of Organizational Leadership and Strategy, Marriott School of Management Brigham Young University Provo*, 2003, UT 84602.
15. SOMVANSHI, V. K. - PANDEY, O. P. - AGRAWAL, P. K. - KALANKER, N. V. - PRAKASH, M. R. - RAMESH, C. *Modelling and Prediction of Rainfall Using Artificial Neural Network and ARIMA Techniques. J. Ind. Geophys. Union*, Vol. 10, No. a2, 2006, pp. 141-151.
16. KASABOV, N. K. *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering. Massachusetts Institute of Technology*, 1996.

17. العنبي، فوزي. استخدام السلاسل الزمنية والشبكات العصبية في التنبؤ بالأرقام القياسية " رسالة ماجستير في الإحصاء التطبيقي، جامعة قناة السويس، بورسعيد.

18. IZADIFAR, Z.; ELSHORBAGY, A. *Prediction of Hourly Actual Evapotranspiration Using Neural Networks, Genetic Programming, And Statistical Models*. Hydrological Processes, 2010, 24, 3413–3425.