

أنموذج شبكة عصبية صناعية للتنبؤ بالتبخر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة الشهرية

الدكتورة بادية حيدر *
الدكتور غطفان عمّار **

(تاريخ الإيداع 23 / 11 / 2014. قُبِلَ للنشر في 19 / 1 / 2015)

□ ملخّص □

يشكّل التبخر أحد عناصر الدورة الهيدرولوجية، الذي يصعب قياس كمياته الفعلية في الشروط الحقلية، لذلك يجري تقديره اعتماداً على الحسابات بعلاقات تجريبية تعتمد على بيانات عناصر المناخ. يهدف البحث إلى بناء أنموذج رياضي لتقدير التبخر الشهري في المنطقة السهلية من الساحل السوري، وذلك باستخدام الشبكات العصبية الصناعية اعتماداً على درجة الحرارة فقط. وإجراء دراسة مقارنة بين نتائج أنموذج الشبكة ونتائج نماذج أخرى معروفة. بُني الأنموذج الرياضي باستخدام NN-tool box إحدى أدوات MATLAB حيث شكّلت شبكة عصبية صناعية متعددة الطبقات لخوارزمية الانتشار العكسي للخطأ، وحُدّدت خوارزمية التعلم الملائمة، وعدد الطبقات الخفية المستخدمة، بالإضافة إلى عدد العصبونات ونوع دوال التفعيل المستخدمة في كل طبقة.

وقد أظهرت النتائج أن الشبكة العصبية الصناعية ذات الهيكلية (1-9-1) تعطي أقل قيمة لمربع متوسط الخطأ لمجموعة التحقق ويساوي 0.0032، مع استخدام دالتي التفعيل Logsigmoid و Linear على الترتيب في الطبقة الخفية وطبقة الإخراج.

كما طُوّر أنموذج المحاكاة للنتائج المستحصلة من الشبكة العصبية الصناعية المقترحة مع نماذج أخرى مثل معادلة إيفانوف وذلك باستخدام تقانة (Simulink). تبين أن الشبكة العصبية الصناعية المعتمدة على درجة الحرارة فقط تعطي نتائج أكثر دقة من معادلة إيفانوف في تقدير التبخر.

الكلمات المفتاحية: التبخر، درجة الحرارة، الشبكة العصبية الصناعية، المحاكاة، الماتلاب.

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

Neural Network Model for Evaporation Prediction in Plain Area of Syrian Coastal Region Depending on Monthly Temperature

Dr. Badia Haidar*
Dr. Ghatfan Ammar **

(Received 23 / 11 / 2014. Accepted 19 / 1 / 2015)

□ ABSTRACT □

Evaporation forms one of the hydrology cycle elements that it's hard to measure its actual amounts in the field conditions, so it's estimated by calculations of experimental relations, which depend on climatic elements data. So the research goal is to build a mathematical model to estimate monthly evaporation amount in plain area of Syrian Coast, using Artificial Neural Network (ANN), and depending on dry air temperature, and produce comparison study between the results of network and other models. The mathematical model was built by the (NN-tool box), which is one of the v tools. A multilayer ANN architecture of error Back-propagation algorithm was built. The suitable training algorithms, number of hidden layers, number of neurons in each hidden layer, were determined.

The results showed that the ANN (1-9-1) was the best model with MSE of 0.0032 for validation group, using Transfer Function Logsigmoid and Linear in hidden and output layers, respectively.

A comparison model for the results obtained from the proposed ANN with EVANOV model by using SIMULINK technique was developed. This indicated that the ANN using temperature only gives results more accurate than EVANOV equation in determining evaporation.

Keywords: Evaporation, Temperature, Artificial Neural Network, Simulation, Matlab.

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

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

مقدمة:

إنَّ استمرار زيادة النمو السكاني في العالم يستدعي تحقيق استغلال أمثل للموارد المائية المتاحة لمواجهة المتطلبات المتزايدة على الغذاء، فضلاً عن التحديات التي تفرضها محدودية هذه الموارد، فدراسة الموارد المائية في سورية هي إحدى العوامل الرئيسية المحددة لاتساع الرقعة الزراعية، وتُعدُّ من الأمور الملحة في الوقت الراهن لغرض تحقيق التوازن المطلوب بين النمو السكاني المتصاعد والأمن الغذائي الذي يُعدُّ هدفاً استراتيجياً لجميع شعوب العالم. تُشكِّل عملية التبخّر إحدى المركبات الأساسية للدورة الهيدرولوجية في الطبيعة، وعلى هذا الأساس فقد اجتذبت دراسة هذه العملية اهتمام الكثير من الباحثين، لاسيما في المناطق التي تعاني من شح الموارد المائية، حيث استُخدمت طرائق مباشرة وغير مباشرة لمحاولة تقدير كميات المياه المفقودة بهذه الفعالية.

وقد حاول العديد من الباحثين تقويم التبخّر في مناطق مختلفة من العالم باستخدام العديد من الطرائق غير المباشرة. فعلى سبيل المثال درس Sudheer et.al (2003) إمكانات الشبكات العصبية الصناعية (ANN) في تقدير التبخّر - نتج الفعلي من المحاصيل اعتماداً على بيانات مناخية محدودة. استخدمت الدراسة الشبكات العصبية الصناعية ذات الدوال قطرية الأسس (الأساس الشعاعي) (RBF) لحساب القيم اليومية للتبخّر-نتج لمحصول الأرز حيث تم تدريب واختبار ست شبكات RBF، كل منها يعتمد تراكيب مختلفة من المدخلات (المتغيرات المناخية)، وتمت مقارنة النتائج مع نتائج جهاز Lysimeter. أظهرت نتائج الدراسة بوضوح أن الشبكات العصبية الصناعية تعطي نتائج جيدة [1].

كما قام كل من Keskin and Terzi (2006) بدراسة نماذج من الشبكات العصبية الصناعية (ANN) واقتراحها كنهج بديل لتقدير التبخّر من بحيرة Eirdir. هدفت هذه الدراسة إلى تطوير نماذج ANN لتقدير التبخّر اليومي اعتماداً على بيانات الأرصاد الجوية ومقارنة نتائجها مع نتائج نموذج بنمان، بالإضافة إلى تقييم قدرة الشبكة العصبية الصناعية على تقدير قيم التبخّر بمقارنة نتائجها مع قيم حوض التبخّر، 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 العصبية الصناعية تعطي نتائج أكثر دقة من نموذج بنمان في تقدير التبخّر من بحيرة Eirdir [2].

كما قامت افتخار عبد الجواد (2007) بتشكيل أنموذج لشبكة عصبية صناعية لتقدير التبخّر - نتج المرجعي اليومي في منطقة الموصل بالاعتماد على كل من درجة الحرارة والإشعاع الشمسي وسرعة الرياح والرطوبة النسبية. وتوصلت إلى أنّ أداء الشبكة الصناعية يزداد دقةً عندما تترافق درجة الحرارة مع سرعة الرياح والسطوع الشمسي، في حين يكون للرطوبة النسبية تأثير محدود ولا سيما عندما تترافق مع درجة الحرارة [3].

أجرى MOGHADDAMNIA, A. et. (2009) تقويماً للتبخّر في منطقة Zabol في إيران، وذلك باستخدام ANN والنظام الضبابي العصبي التّكفي، كما أُجريت مقارنة بين نتائج الطريقتين السابقتين ونتائج تقويم التبخّر باستخدام الصيغ التجريبية. فأظهرت النتائج أن كل من ANN والنظام الضبابي العصبي التّكفي يعطي نتائج أفضل من الصيغ التجريبية في تقويم التبخّر [4].

وفي دراسة قام بها Ariapour et al. (2010) في إيران، استخدم الباحث ANN لتقويم التبخّر اليومي اعتماداً على الحرارة اليومية، سرعة الرياح، الرطوبة النسبية وساعات السطوع الشمسي بالإضافة إلى القياسات الفعلية

للتبخر المقيسة بوساطة حوض التبخر، حيث أظهرت النتائج أن الشبكة العصبونية تعطي نتائج جيدة في تقويم التبخر اليومي [5].

وهدف البحث الذي أجراه Hormozi et al. (2012) إلى تقدير التبخر باستخدام الشبكة العصبونية الصناعية في ثلاث محطات مناخية وهي Ahvaz, Abadan و Dezful واقعة في إقليم خوزستان جنوب غرب إيران بالاعتماد على مجموعة من المعطيات المناخية (درجة الحرارة الصغرى والعظمى، الرطوبة النسبية الصغرى والعظمى، ساعات السطوح الشمسي وسرعة الرياح)، ومن ثم دراسة المعامل الأكثر تأثيراً في تقدير التبخر باستخدام هذه التقنية. أظهرت الدراسة أن درجة الحرارة العظمى كان لها التأثير الأكبر على أداء الشبكة في محطتي Ahvaz & Dezful، بينما كان لدرجة الحرارة الصغرى، ومن ثم العظمى التأثير الأكبر في محطة Abadan [6].

وفي دراسة قام بها عمار، حيدر (2013) لنموذج التبخر - نتج مرجعي في منطقة صافيتا في سورية باستخدام الشبكة العصبونية الصناعية. أظهرت النتائج أن نمّة توافقاً خطياً بين مخرجات الشبكة وبيانات التبخر المقيسة، مما يبين إمكانية استخدام هذه التقنية في التنبؤ بالتبخر - نتج المرجعي الشهري وذلك بضرب مخرجات الشبكة (التبخر) بمعامل الحوض. كما طُوّر أنموذج المحاكاة للنتائج المستحصلة من الشبكة العصبونية الصناعية المقترحة مع نماذج أخرى مثل معادلة إيفانوف وذلك باستخدام تقانة (Simulink) المتاحة في حزمة برمجية الماتلاب. وتم التوصل إلى أن الشبكة العصبونية الصناعية تعطي نتائج أكثر دقة من معادلة إيفانوف في تقدير التبخر - نتج المرجعي [7].

كما قام عمار، حيدر، عليان (2014) بتشكيل أنموذج شبكة عصبونية صناعية لتقدير التبخر 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 التبخر - نتج الشهري في المنطقة السهلية من الساحل السوري بمتوسط خطأ يساوي إلى 0.00292 [8].

أهمية البحث وأهدافه:

يعد التبخر ظاهرة معقدة وغير خطية لأنها تعتمد على تفاعل العديد من العوامل المناخية مثل درجة الحرارة، الرطوبة، سرعة الرياح، ساعات السطوح الشمسي ... إلخ. إن التنبؤ بالتبخر من الأحواض المائية لاسيما في تخطيط وتصميم وتنفيذ مشاريع الموارد المائية هو ذو أهمية قصوى، لذلك فإن هدف هذه الدراسة هو بناء أنموذج رياضي لتقدير التبخر باستخدام الشبكة العصبونية الصناعية (ANN) والتي هي أدوات فعالة في نمذجة النظم غير الخطية اعتماداً على درجة الحرارة الجافة.

منطقة البحث:

تشكّل منطقة الدراسة جزءاً من السهل الساحلي السوري وهي تقع في الجهة الغربية من القطر العربي السوري، على الساحل الشرقي للبحر المتوسط، حيث يحدها من الشمال تركيا ومن الجنوب لبنان، ويحدها من الشرق المنطقة التلالية. ترتفع المنطقة السهلية ما بين (0-100) م عن مستوى سطح البحر وتضم عدّة محطات مناخية هي محطة طرطوس، محطة حميميم ومحطة سد 16 تشرين كما يبين الشكل (1).

استخدم في هذه الدراسة قياسات شهرية لدرجة الحرارة والتبخر متوافرة للفترة ما بين (1961-2004) لمحطة طرطوس المناخية، وللأعوام (1957-1996) لمطار حميميم ومحطة 16 تشرين للأعوام (2005-2009). كما

ينطلب عمل الشبكات الصناعية إجراء عملية التقييس لكل من قيم متجهات المدخلات والهدف، وذلك لجعل قيم عنصريهما قريبة من بعضها البعض؛ أي ضمن مدى قصير نسبياً لتقليل قيمة الخطأ بين القيم المحسوبة من الشبكة والقيم المأمولة، وهذا يحسّن كفاءة العمليات الحسابية وأداء الشبكة. لذلك قيست كافة البيانات باستخدام طريقة (Kumare et al. 2002) [9]، كما هو موضح في المعادلة (1):

$$p_{(norm)} = 0.5 \left[\frac{(p - p_{(mean)})}{p_{(max)} - p_{(min)}} \right] + 0.5 \dots \dots \dots (1)$$

حيث p قيمة القراءة للعنصر المناخي



الشكل (1) منطقة الدراسة

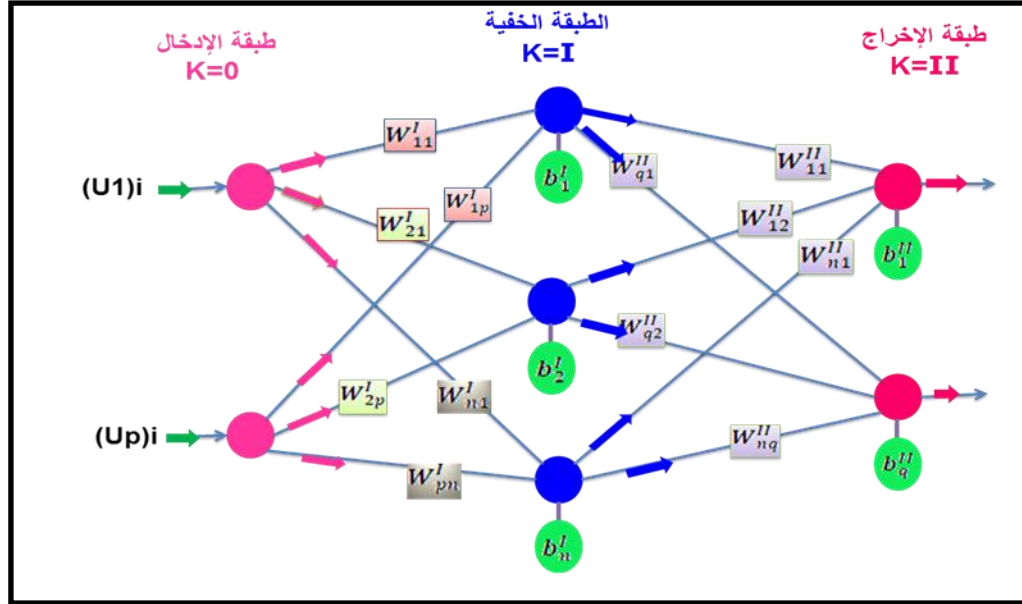
طرائق البحث ومواده:

تعتمد هذه الدراسة على إنشاء نموذج رياضي للشبكة العصبية الصناعية، حيث تعرّف الشبكة العصبية الصناعية بأنها إحدى طرائق الذكاء الصناعي Artificial intelligence، وهي عبارة عن نظام لمعالجة البيانات بشكل يحاكي وبشابه 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. وجدت الشبكات العصبية الصناعية تطبيقات ناجحة في مجالات العلوم، الهندسة، الصناعة، الأعمال، الاقتصاد والزراعة. وتم تطبيقها مؤخراً في مجال النمذجة وتطبيقات الأرصاد الجوية (التنبؤ بالمناخ). تهتم معظم التطبيقات المتوفرة في الأدبيات بمسائل التصنيف، التنبؤ والتقدير. انتشرت تطبيقات الشبكات العصبية الصناعية بسرعة عالية بسبب خصائصها الوظيفية والتي توفر العديد من المزايا التي تتفوق بها على الطرائق التحليلية التقليدية. 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. إضافة إلى ذلك فإن الشبكة العصبية الصناعية ترسم خريطة العلاقات الضمنية بين المدخلات والمخرجات من خلال التدريب اعتماداً على الملاحظات الحقلية.

يتطلب نموذج الشبكة العصبية الصناعية مدخلات أقل من تلك اللازمة لنموذج رياضي تقليدي مشابه، بما أن المتغيرات التي تبقى ثابتة من محاكاة إلى أخرى لا تحتاج إلى اعتبارها كمدخلات. كما أن الشبكات العصبية الصناعية تتطلب عدداً أقل من المدخلات والجهد والوقت اللازمين للحساب. ويمكن لها أن تبدي استجابة حساسة لإدخال تغييرات صغيرة في البيئة الديناميكية.

تتكون الشبكات العصبية بشكل عام من نظام من الخلايا العصبية، التي تم ترتيبها في طبقات (الشكل (2))، حيث تتلقى هذه الشبكات الإشارات من خلال وحدات الإدخال، ثم يتم معالجتها وإعادة بثها باتجاه عصبونات الخرج.



الشكل (2): الشبكة العصبية الصناعية ذات التغذية الأمامية بطبقة خفية واحدة فقط

تعتمد هذه الدراسة على إنشاء أنموذج رياضي للشبكة العصبية الصناعية ذات التغذية الأمامية، ويُقصد بالتغذية الأمامية للشبكات انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من طبقة الإدخال باتجاه طبقة الإخراج، ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ Artificial Neural Network of Error Back Propagation، المستخدمة في هذه الدراسة. ويسمى هذا النوع من الشبكات شبكات الانتشار العكسي للخطأ؛ لأن المخرجات الحقيقية للشبكة تُقارن مع المخرجات المأمولة (الهدف)، كما أن الفرق في قيمهما يدعى بالخطأ، إذ تقوم الشبكة بنشر هذا الخطأ من طبقة المخرجات مروراً بالطبقة (الطبقات) الخفية باتجاه طبقة المدخلات؛ أي بآلية معكوسة لما يحدث في مرحلة احتساب المخرجات. وفيما يأتي شرح لآلية عمل الشبكات العصبية ذات الانتشار العكسي للخطأ [10].

أولاً: مرحلة التغذية الأمامية:

يرتبط الخرج Y_i^{k-1} للخلية العصبية (i) في الطبقة (k-1) لشبكة التغذية الأمامية مع الدخل من الخلية العصبية z في الطبقة اللاحقة k بوساطة 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 Y_j^k فإن الخلية العصبية z للطبقة k [k=I,II] ينجز العملية الحسابية الآتية:

$$Y_j^k = f^k \left[\sum_{i=1}^N (W_{ji}^k \cdot Y_i^{k-1}) + b_j \right] \dots \dots \dots (2)$$

$$Y_j^0 = u_j$$

$$Y_j = Y_j^H$$

حيث:

N : عدد الخلايا أو الوحدات في الطبقة k-1

f^k : دالة التحويل (Transfer Function)

يعد شعاع الانحياز (bj) بمثابة الحد الثابت في المعادلات الرياضية كثيرات الحدود الذي يساعد في حل تلك المعادلات بصورة أسهل وأسرع.

هناك عدة أنواع من دوال التفعيل f^k ذات وظائف مختلفة، نسردها بعضاً منها بما فيها تلك التي تم استخدامها في البحث الحالي:

(a) دالة سيغمويد اللوغاريتمية Log-Sigmoid Transfer Function: تعد هذه الدالة واحدة من الدوال الواسعة الاستخدام؛ لأنها تقوم بمعالجة القيم بمدى يتراوح بين (0) و(1) بشكل انسيابي مما يوفر توزيعاً ملائماً لهذه القيم.

(b) دالة سيغمويد لظل الزاوية (Tan-Sigmoid Transfer Function): وهي مشابهة لدالة سيغمويد اللوغاريتمية، وتتمتع بالمزايا نفسها من حيث الانسيابية، إلا أن القيم الخارجة تكون بمدى يتراوح بين (1) و(-1).

(c) الدالة الخطية (Linear Transfer Function): تقع قيم المخرجات بين (0) و (1) ولذلك تدعى بدالة التحفيز الثنائي.

ثانياً: مرحلة الانتشار العكسي للخطأ: يتم احتساب الخطأ في وحدة المخرجات ومعدل مربع الخطأ (MSE) ومعامل تصحيح الخطأ (δ) وفقاً للمعادلتين الآتيتين:

$$MSE = err = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (y_i - a_2)^2 \dots \dots \dots (6)$$

$$\delta = - \frac{\partial err}{\partial a_{(2)}} \dots \dots \dots (7)$$

حيث:

err: معدل مربع الخطأ في وحدة المخرجات؛ Y : المخرجات المأمولة Target؛ δ : معامل تصحيح الخطأ.

وبما أنَّ تصغير الخطأ Error Minimization يتطلب تغيير الوزن باتجاه الانحدار التدريجي لمنحنى الخطأ Gradient Descent of Error لذلك يعبر عن تغيير الوزن وتغيير عامل الانحياز بالمعادلتين الآتيتين:

$$\Delta w = -Ir \frac{\partial \text{err}}{\partial Iw} \dots \dots \dots (8)$$

$$\Delta b = Ir \frac{\partial \text{err}}{\partial b} \dots \dots \dots (9)$$

حيث: Ir : تمثل مقدار معدل التعلم Learning Rate والاختيار المناسب لها يعتمد على المشكلة المطلوب حلها ويزيد من قابلية الشبكة على التدريب، كما يجعل هذه العملية تجري بشكل متماثل طوال مدة التدريب. وباستخدام قاعدة السلسلة Chain Rule وجد أنَّ معامل تصحيح كلِّ من الوزن وعامل الانحياز لطبقة المخرجات هو كالاتي:

$$\Delta lw = Ir \cdot a_{(2)} \cdot (1 - a_{(2)}) \cdot (a_{(2)} - Y) \cdot a_{(1)} \dots \dots \dots (10)$$

$$\Delta b_{(2)} = Ir \cdot a_{(2)} \cdot (1 - a_{(2)}) \cdot (a_{(2)} - Y) \dots \dots \dots (11)$$

في حين يكون معامل تصحيح كلِّ من الوزن وعامل الانحياز للطبقة الخفية هو كالاتي:

$$\Delta IW = Ir \cdot \delta_{(2)} \cdot p \dots \dots \dots (12)$$

$$\Delta b_{(1)} = Ir \cdot \delta_{(2)} \dots \dots \dots (13)$$

حيث: $\delta_{(2)}$: معامل التصحيح للطبقة الخفية؛ $a_{(1)}$: هي مخرجات لوحدة خفية؛ $a_{(2)}$: هي ناتج لوحدة المخرجات.

ثالثاً: مرحلة تحديث الأوزان : يتم تحديث الأوزان وعامل الانحياز كما هو معطى أدناه:

$$W_{(New)} = W_{(old)} + \Delta W \dots \dots \dots (14)$$

$$b_{(New)} = b_{(old)} + \Delta b \dots \dots \dots (15)$$

وهناك طريقتان مختلفتان لعملية تحديث أوزان الشبكة العصبية الصناعية، وذلك بافتراض أن مدخلات الشبكة تكون على شكل مصفوفة رياضية مكونة من صفوف وأعمدة، وكل صف من هذه الصفوف يمثل متجهاً يحتوي على جميع المتغيرات المراد إدخالها إلى الشبكة.

• طريقة تجزئة المدخلات Increment Model: يتم في هذه الطريقة إدخال المصفوفة صفافاً صفافاً ومن ثم تُحدَّث الأوزان لتلك الصفوف تباعاً، لذلك تمتاز هذه الطريقة بحاجتها إلى ذاكرة محدودة.

$$\Delta W = \sum_{i=1}^{i=q} Ir \cdot \delta \cdot p_i \dots \dots \dots (16)$$

• طريقة الدفعة الواحدة للمدخلات Batch Model: تتضمن هذه الطريقة إدخال المصفوفة كاملةً ودفعةً واحدةً حيث تحدث الأوزان لمرة واحدة وفقاً لذلك، وتمتاز هذه الطريقة بسرعة تنفيذها غير أنها تحتاج إلى ذاكرة أكبر من الطريقة السابقة. وهي الطريقة المعتمدة في هذه الدراسة.

$$\Delta W = \sum_{i=1}^{i=nd} Ir \cdot \delta \cdot \sum_{i=1}^{i=q} p_i \dots \dots \dots (17)$$

حيث: nd: عدد أسطر البيانات. Pi : مدخلات الشبكة.

كما اعتمد تدريب شبكات الانتشار العكسي للخطأ في هذه الدراسة على مجموعة خوارزميات نذكر منها الآتي: [11]

- i. خوارزمية (Variable Learning Rate (GDA,GDX)): وهي خوارزمية تعلم متغير لشبكة الانتشار العكسي للخطأ التي تعد من أسرع طرائق تدريب الشبكات العصبية.
- ii. خوارزمية ((Resilient Back Propagation(RP)): وهي خوارزمية تدريب بسيطة تحتاج إلى ذاكرة خزن قليلة، وتتميز هذه الخوارزمية بالسرعة الفائقة في عملية الاقتراب من الهدف.
- iii. خوارزمية ((Scaled Gradient (CGF)): وهي خوارزمية تدريب تستلزم متطلبات خزن صغيرة من الذاكرة.
- iv. خوارزمية ((Scaled Conjugate(SCG)): وهي خوارزمية تدريب جيدة للأغراض العامة.
- v. خوارزمية ((Levenberg Marquardt(LM)): وهي خوارزمية تدريب سريعة لشبكة ذات حجم قابل للتحديث وذات ذاكرة مختزلة، ويمكن الإفادة منها في التدريبات التي تتطلب بيانات ضخمة.

إن عملية تحديث الأوزان يمكن أن تعاد آلاف المرات في التطبيقات القياسية، ويتوقف التدريب عادةً عند الوصول إلى مستوى مقبول للخطأ، أو عند الوصول إلى عدد المكررات المحددة مسبقاً من المدرب. أما طريقة إيقاف غير الاعتيادية فتتم في أثناء عدم وجود تناقص في قيمة (MSE) إلى المستوى المرغوب فيه مع زيادة عدد المكررات Iterations، أو عند حصول ظاهرة المغالاة؛ أي عند الزيادة في التدريب Overtraining، إذ تستمر الشبكة بالتدريب إلى أن يتم الحصول على نتائج مقبولة في مرحلة التدريب، غير أن النتائج تصبح غير مقبولة في مرحلة الاختبار. إن الأدبيات المتعلقة بالشبكات العصبية الصناعية تشير إلى عدم وجود أسلوب قياسي في تحديد عدد الطبقات الخفية أو عدد عصبوناتها وإنما يجري اختيار هذا العدد حسب رؤية القائم على بناء النموذج. ومما تجدر الإشارة إليه، أنه عند بناء الشبكة العصبية الصناعية يُحدد نوع دالة التفعيل المستخدمة في كل وحدة، علماً أنه ليس من الضروري امتلاك جميع الوحدات لدالة التفعيل نفسها.

بُنيت الشبكة العصبية الصناعية في هذه الدراسة بالاعتماد على برنامج MATLAB والأدوات الملحقة به nntool Box و nntool 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. [12]

القياسات الأكثر أهمية في محاكاة أداء النموذج المستخدمة في هذه المقالة هي متوسط مربع الخطأ (MSE).

$$MSE = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (Y_i - a_2)^2 \dots \dots \dots (18)$$

Y : المخرجات الهدف Target؛ a_2 : قيمة خرج الشبكة المحسوبة calculated.

في بداية كل محاولة تدريب للشبكة، يجب إعادة إدخال القيم الأولية لكل من أوزان الشبكة وانحيازاتها. الطريقة الأكثر تطبيقاً هي التهيئة المبدئية بشكل عشوائي. الهدف من هذه العشوائية هو إجبار خوارزمية التدريب على البحث عن أجزاء أخرى لفضاء البارامترات، وذلك بهدف الوصول إلى ناتج أمثلة عام قوي وزيادة الفرصة بشكل عام لإيجاد الخطأ الأصغر. تسبب هذه الطريقة اختلافاً في أداء الشبكة عند كل محاولة تدريب، حتى لو استخدمت نفس خوارزمية التدريب. حيث تتواجد ثلاثة أسباب لعدم قدرة خوارزمية التدريب على إيجاد نفس مجموعة البارامترات لكل محاولة تدريب عندما يبدأ التدريب بجزء مختلف من الفضاء البارامترية. السبب الأول هو تواجد أكثر من نقطة أمثلة عامة لمجموعة التدريب. والسبب الثاني هو عدم قدرة خوارزمية التدريب على إيجاد نقطة الأمثلة العامة والتصاقها بنقطة الأمثلة المحلية، وذلك في المساحات المسطحة والتلالية لمستوي الخطأ. ويمكن السبب الثالث في حالة تطبيق

مجموعة التحقق لمنع ظاهرة فوق التوافق، قد لا تتوافق نقطة الأمثلة لمجموعة بيانات التدريب مع نقطة الأمثلة لمجموعة بيانات التحقق، وذلك بسبب توقف الخوارزمية قبل إيجاد نقطة الأمثلة العامة نتيجة تزايد خطأ مجموعة التحقق.

النتائج والمناقشة:

1- إدخال البيانات وبناء الشبكة العصبية الصناعية

بغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية، أدخلت البيانات المتوفرة لمحطات طرطوس للأعوام (1961-2004)، مطار حميميم للأعوام (1957-1996) ومحطة 16 تشرين للأعوام (2005-2009) على شكل مصفوفة مكونة من صف واحد يمثل درجة حرارة الهواء و 973 عموداً، كما أدخلت بيانات على شكل مصفوفة مكونة من صف واحد يتضمن قيم التبخر الشهري المقيسة و 973 عموداً. ثم شُكِّلت شبكة عصبية صناعية تتضمن طبقة مدخلات مكونة من عصبون واحد يمثل درجة حرارة الهواء، وطبقة مخرجات مكونة من عصبون واحد يمثل التبخر الشهري، 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).

2- تدريب الشبكة العصبية الصناعية المقترحة

إنّ الهدف من تدريب الشبكة هو تغيير أوزان الشبكة للحصول على الإخراج المأمول للمدخلات المعطاة. ولتحقيق هذا الهدف لابد من الوصول إلى حالة من التوازن بين قابليتها على الاستجابة الصحيحة لبيانات المدخلات المستخدمة في عملية التدريب التي يجري تخزينها في الشبكة لعملية التذكير، وقابليتها على إعطاء استجابة جيدة لمدخلات مشابهة، لكنها غير مطابقة لتلك المدخلات المستخدمة في عملية التدريب (عملية التنبؤ). لذلك تم الاعتماد على طريقة التوقف المبكر، بغية التوصل إلى صفة التعميم الكفؤ، وذلك بتقسيم البيانات إلى ثلاث مجموعات كما ذكر سابقاً.

وبعد إجراء عدد كبير من التجارب تم التوصل إلى أن الشبكة العصبية الصناعية ذات الهيكلية (1-9-1) تعطي أقل قيمة لمتوسط الخطأ ويساوي (0.0033) لمجموعة التدريب و(0.00456) لمجموعة التحقق و(0.00627) لمجموعة الاختبار و (0.0032) للمجموعات الثلاث، كما هو موضح في الجدول (1).

الجدول (1): أداء معايير مختلفة للشبكة العصبية الصناعية

test*10 ⁻³ (MSE)	val*10 ⁻³ (MSE)	train*10 ⁻³ (MSE)	All (MSE)	عدد العصبونات الخفية
4.48	5.52	3.51	0.00351	3
4.23	5.12	3.62	0.0036	4
5.45	5.18	3.87	0.00351	5
4.6	6.57	3.27	0.00328	6
5.16	4.24	3.599	0.00359	7

5.25	4.18	3.98	0.0036	8
6.27	4.56	3.33	0.0032	9
5.99	3.68	3.6	0.00352	10
4.64	5.34	3.49	0.00345	11
3.35	5.9	3.61	0.00358	12
4.48	5.21	3.48	0.00349	13
3.7	6.1	3.6	0.00346	14
4.5	6	3.32	0.00331	15

كما جرى اختبار لتوابع التفعيل، وذلك من أجل الشبكة العصبية الصناعية ذات المعمارية (1-9-1)، وبالاعتماد على مكتبة nntool تبين أنّ أفضل أداء للشبكة العصبية الصناعية يكون باستخدام دالة التفعيل Transfer Function Logsigmoid في الطبقة الخفية تُتبع بدالة تفعيل Linear Transfer Function في طبقة الإخراج، كما هو مبين في الجدول (2).

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

All (MSE)	طبقة الخفية	الخرج
0.00358	logsig	Tansig
0.014	logsig	Logsig
0.0143	tansig	Logsig
0.00364	logsig	Purelin
0.0032	tansig	Purelin
0.00366	tansig	Tansig

درت الشبكات العصبية الصناعية باستخدام خوارزميات تدريب تحاول تصغير قيمة تابع الأداء أي متوسط مربع الخطأ (MSE). يظهر الجدول (3) أداء هذه الخوارزميات من حيث MSE. حيث أجريت المقارنة بين عدة شبكات صناعية تملك نفس المواصفات وذلك باستخدام مكتبة nntool المتاحة في حزمة برمجيات الماتلاب.

الجدول (3): أداء الشبكة العصبية الصناعية عند استخدام خوارزميات تدريب مختلفة

ALL(MSE)	تابع التدريب	عدد العصبونات الخفية
0.00367	Bfg	9
0.00356	Br	9
0.00355	Cgb	9
0.0035	Cgf	9
0.00359	Cgp	9

0.00882	Gd	9
0.0067	Gdm	9
0.00358	Gda	9
0.0038	Gdx	9
0.0032	Lm	9
0.0038	Oss	9
0.00356	Rp	9
0.00362	Scg	9

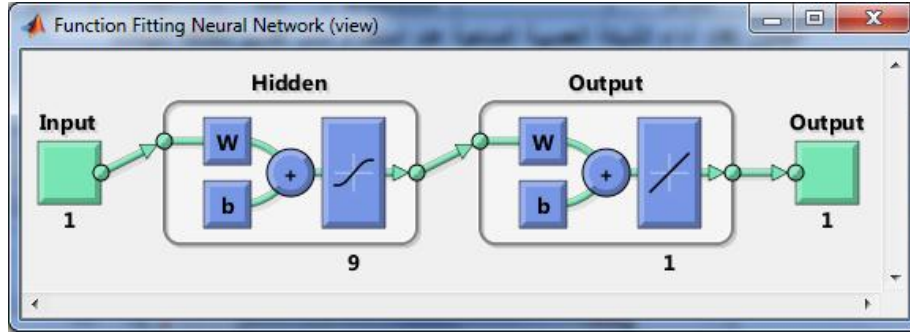
يتفوق إنجاز خوارزمية L-M algorithm على الخوارزميات الأخرى من ناحية الدقة في كل حالات الاختبار. تظهر النتائج في الجدول (3) أنّ أداء الشبكة العصبية الصناعية قادر على الاعتماد وبشكل كبير على خوارزميات الأمثلة لإيجاد مجموعة جيدة من الأوزان والانحيازات. حيث تتواجد ثلاث مزايا من استخدام خوارزمية جيدة: أولاً دقة جيدة تقود إلى أداء شبكة عصبية صناعية أفضل، ثانياً تقارب أسرع يقود إلى زمن حساب أقل، وثالثاً سرعة منخفضة في الأداء تجعل منه أسهل وأكثر مصداقية لمحاكاة ومقارنة الشبكات العصبية الصناعية.

ثم قُسمت هذه البيانات من خلال مكتبة nftool المتاحة في حزمة برمجيات الماتلاب إلى ثلاث مجموعات هي مجموعة التدريب ومجموعة التحقق ومجموعة الاختبار وذلك بنسب مختلفة لتحديد النسبة التي تعطي التقارب الأفضل. وكانت الشبكة المقسمة على الشكل التالي: 70% لمجموعة التدريب و15% لمجموعة التحقق و15% لمجموعة الاختبار هي الشبكة الأفضل، كما هو مبين في الجدول(4).

الجدول (4): أداء الشبكة العصبية الصناعية عند استخدام نسب تقسيم مختلفة للبيانات


test(%)	val(%)	train(%)	all (MSE)	عدد العصبونات الخفية	train*10 ⁻³ (MSE)	val*10 ⁻³ (MSE)	test*10 ⁻³ (MSE)
15	15	70	0.00326	9	3.27	5.31	5.69
15	20	65	0.00344	9	3.46	5.54	3.85
15	10	75	0.00354	9	3.56	4.96	5.11
10	10	80	0.00359	9	3.58	5.2	4.74
10	20	70	0.00336	9	3.36	6.2	3.24
5	15	80	0.0036	9	3.59	4.15	8.25
5	25	70	0.00356	9	3.65	4.73	5.23
20	20	60	0.00345	9	3.54	5	4.07
20	15	65	0.00333		3.35	5.97	4.53

وبالتالي تكون أفضل معمارية للشبكة العصبية الصناعية للبيانات قيد الدراسة هي 1_9_1 . الشكل (6)



الشكل (6): يبين أفضل معمارية للشبكة العصبية الصناعية للبيانات قيد الدراسة

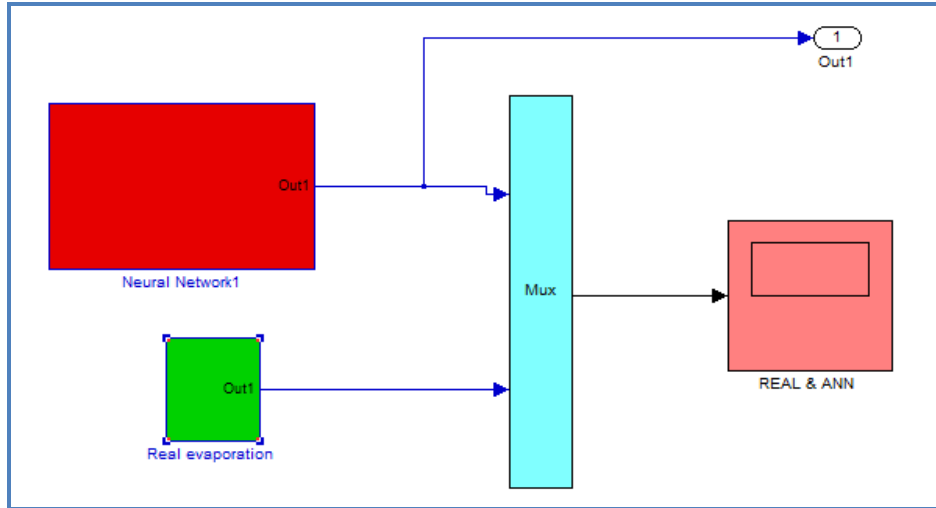
يوضح الشكل (7) أداء الشبكة العصبية الصناعية للمجموعات الثلاثة، حيث يبين نقطة توقف التدريب لدورات تكرارية عددها (3) وبمتوسط خطأ يساوي إلى (0.0053135) لمجموعة التحقق.



الشكل (7) يبين أداء الشبكة العصبية الصناعية للمجموعات الثلاثة

3- تقييم أداء الشبكة العصبية الصناعية المقترحة

يعدُّ فحص أداء أي نموذج رياضي مقترح من التطبيقات الاعتيادية والتقليدية في عملية النمذجة الرياضية، حيث يُقيّم حسنُ الأداء باستخدام الأساليب الإحصائية المعروفة. ولغرض الاستفادة من التقانات الحديثة في إظهار المقارنة على شكل مرسمات، اقترح بناء نموذج المحاكاة بالاستفادة من تقانة SIMULINK المتاحة في حزمة برمجيات MATLAB، حيث اختُصرَ نموذج المقارنة بوضع الشبكة العصبية الصناعية على شكل قالب جاهز بسيط BLOCK، يحتوي على جميع مفردات الشبكة المقترحة في حزمة قوالب ثانوية يمكن إظهارها بسهولة. وأجريت عملية المحاكاة بشكل متزامن وذلك باعتبار درجة الحرارة كمتغير، وبهذا يمكن مراقبة عملية المحاكاة من خلال قوالب الإظهار Display التي يمكن إضافتها إلى أي جزء من أجزاء النموذج. كما هو مبين في الشكل (8):

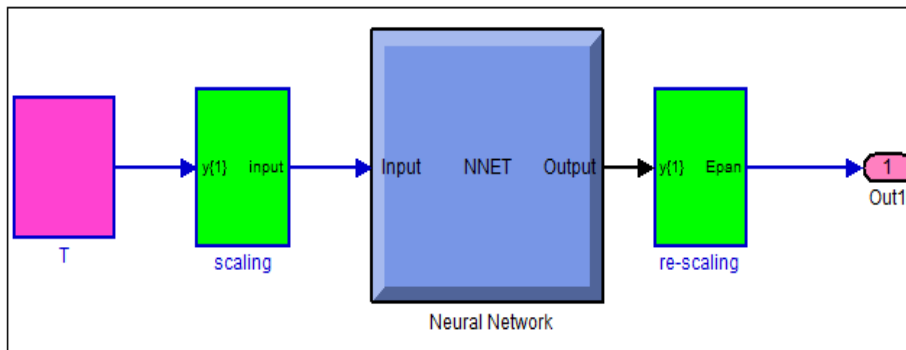


الشكل(8) يبين تركيب وبناء أنموذج المحاكاة باستخدام تقانة Simulink

4 - الأنظمة الثانوية لأنموذج المحاكاة

• قالب الشبكة العصبية الصناعية

يبين الشكل(9) النظام الثانوي لقالب الشبكة العصبية الصناعية، كما يظهر الشكل ربط الشبكة بالمدخلات عن طريق قالب scaling الذي يمثل عملية التقييس التي تم التطرق إليها سابقاً. كما يبين أيضاً ربط المخرجات بقالب إرجاع البيانات إلى أصلها re-scaling.



الشكل (9) يبين قالب الشبكة العصبية الصناعية

نتائج أنموذج المحاكاة

تم اختبار نموذج الشبكة العصبية الصناعية المشكل باستخدام مجموعة الاختبار التي تشكل نسبة 15% من البيانات، وذلك للتحقق من أداء الشبكة ومقارنة مخرجات الشبكة المشكلة مع القيم المقيسة، حيث بلغت قيمة متوسط الخطأ (مجموع الأخطاء/ عددها) -0.15832 مم/شهر، وهي أصغر من قيمة الخطأ الناتج من مقارنة القيم المحسوبة من معادلة إيفانوف المستخدمة في الساحل السوري مع القيم المقيسة حيث بلغ متوسط الخطأ -27 مم/شهر. الأمر الذي يبين مدى تفوق نماذج الشبكة العصبية على إيفانوف.

ومقارنة قيم مخرجات الشبكة مع قيم مخرجات شبكة عصبية صناعية مستخدمة للتنبؤ بالتبخر في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة والرطوبة حيث كان متوسط الخطأ مساوياً لـ 1.76 مم/شهر [8] ، يتبين لدينا أن نتائج نموذج الشبكة العصبية المشكل اعتماداً على درجة الحرارة فقط في التنبؤ بقيم التبخر

الشهري في المنطقة السهلية من الساحل السوري، هي نتائج ممتازة. الأمر الذي يعطي استخدام نموذج الشبكة لحساب التبخر اعتماداً على درجة الحرارة فقط أهمية كبيرة لاسيما أننا في الكثير من المحطات نعاني من مشكلة توفر البيانات المناخية.

الاستنتاجات والتوصيات:

- ✓ يمكن استخدام الشبكات العصبية الصناعية متعددة الطبقات وذات الانتشار العكسي للخطأ في تقدير التبخر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة فقط وبمتوسط خطأ يبلغ 0.0032.
- ✓ إن التوافق الأدائي بين نتائج الشبكة الصناعية المشكلة اعتماداً على درجة الحرارة والقيم الحقيقية للتبخر يعد ميزة للشبكة العصبية في أنه يمكن استخدامها بثقة في المحطات المناخية التي لا تتوفر فيها سوى قياسات درجة الحرارة.
- ✓ إن استخدام تقانة Simulink في بناء أنموذج المقارنة يتميّز بفائدة هندسية كبيرة من حيث السرعة والكفاءة العالية في بناء النماذج.
- ✓ واعتماداً على نتائج البحث يمكن وضع التوصيات الآتية:
- ✓ مقارنة أداء الشبكات العصبية الصناعية ذات التغذية الأمامية والشبكات العصبية الصناعية ذات التغذية الراجعة في التنبؤ بقيم التبخر اعتماداً على درجة الحرارة.
- ✓ توسيع بناء شبكة عصبية صناعية لتقدير التبخر اعتماداً على درجة الحرارة بافتراض أسلوب التدريب دون إشراف.
- ✓ التوسع في استخدام الشبكات العصبية لدراسة مسائل متنوعة تتعلق بالإدارة الكفوءة للموارد المائية في سورية.

المراجع:

1. SUDHEER, M.E. et, al. *Estimating actual evapotranspiration from limited climatic data using neural computing technique*. J. Irr. Drain. Engg. ASCE. 129(3), 2003, 214-218.
2. KESKIN, K.P. TERZI, O. *Artificial Neural Network Models of Daily Pan Evaporation*. J. Hydrologic Engrg. 11(1), 2006, 65-70.
3. عبد الجواد، افتخار؛ العاني، عبد الحميد. *أنموذج شبكة عصبية اصطناعية لتقدير التبخر نتح المرجعي اليومي لمنطقة الموصل*. رسالة دكتوراه، 2007، بإشراف أ. د. عبد الستار يونس الدباغ، أ. د. كامل علي عبد المحسن الجبوري. جامعة الموصل.
4. MOGHADDAMNIA, A. et, al. *Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques*. Science Direct U. S. A. Vol.32, 2009, 88-97.
5. ARIAPOUR, A.; ZAVAREH, M. *Estimation of Daily Evaporation Using of Artificial Neural Networks (Case study; Borujerd Meteorological Station)*. 2010, 1-10.
6. 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.

7. AMMAR, G.; HAIDAR, B. *Monthly Reference Evapotranspiration Model using Artificial Neural Network in Safita Area - SYRIA*, The third Water International Conference **Ci.Eau 2013**. 28-30 October 2013, Algeria.

8. عمار، غطفان؛ حيدر، باديّه؛ عليان، ميس. تقدير التبخّر من سطح الماء في المنطقة السهلية من الساحل السوري باستخدام الشبّكة العصبية الصناعيّة- المؤتمر الدولي الأول للهندسة المدنية - جامعة تشرين 4-6 آب 2014م.

9. KUMAR, M. et, al. *Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering ASCE U.S.A. Vol. 128, N°. 4, 2002, 224-233.

10. TAYLOR, J.G. 1996, *Neural Network and Their Applications*. John Wiley and Sons England.

11. DEMUTH, H.; BEALE, M. *Neural Network Toolbox*, U. S. A, 2002, 840.

12. MATLAB/R2012b/Help/Historical Networks (Neural Network Toolbox).