

استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة لتقدير التبخر اليومي لمدينة الموصل بدلالة بعض المعلومات المناخية*

سوزان خالد ابراهيم

مدرس مساعد، المعهد التقني، الموصل

المستخلص

تم في هذا البحث تطبيق نموذج الشبكة العصبية لتقدير التبخر اليومي لمدينة الموصل بدلالة بعض المعلومات المناخية (درجة الحرارة العظمى والصغرى، والأمطار، والرطوبة النسبية، وسرعة الرياح والإشعاع الشمسي) لأي يوم من السنة باستخدام شبكة الانتشار العكسي للخطأ Cascade Forward Back Propagation (FFBPNN)، وشبكة Cascade Forward Back Propagation (CFBPNN) Back Propagation، وشبكة الملائمة FitNet Neural Network ولكل شبكة معماريتين: معمارية بـ (٤) طبقات و (٥) خلايا في الطبقات الخفية، ومعمارية بـ (٥) طبقات و (٥) خلايا في الطبقات الخفية. تم استخدام خوارزميات مختلفة للتدريب خوارزمية ليفن بيرك ماركودت (LM)، وخوارزمية نيوتن (BFGS)، وخوارزمية الميل الصرفية (CFG)، وخوارزمية الانحدار التدريجي (GD) وخوارزمية الانحدار التدريجي المعجل (GDM). استخدمت البيانات المأخوذة من محطة الأنواء الجوية في منطقة الرشيدية في محافظة نينوى للفترة من (١٩٩٥-٢٠٠٨) إذ استخدمت بيانات (١٠) أعوام والفترة من (١٩٩٥-٢٠٠٤) لتطوير النماذج وبيانات أربعة أعوام والفترة من (٢٠٠٥-٢٠٠٨) لتقييم النماذج ومقارنة مخرجاتها مع البيانات المقاسة. استخدمت مقاييس معامل التحديد R^2 وجذر متوسط مربع الأخطاء RMSE في الحكم على مدى تطابق البيانات المقاسة ومخرجات الشبكات العصبية لاختيار أفضل نموذج تنبؤي من بين النماذج المطبقة، بينت النتائج إن شبكة الملائمة FitNet وبخوارزمية (LM) ذات كفاءة في تحسين نموذج تنبؤي لتقدير التبخر اليومي إذ وصلت قيمة معامل التحديد إلى (٠,٩٨)، وهي أفضل وأسرع خوارزمية عند توفر درجات حرارة الأمطار، الرطوبة النسبية، سرعة الرياح والإشعاع الشمسي لأي يوم من أيام السنة.

الكلمات المفتاحية: شبكة الانتشار العكسي للخطأ، شبكة الملائمة، الانحدار التدريجي، الانحدار التدريجي المعجل، الميل الصرفية، خوارزمية نيوتن، خوارزمية ليفن بيرك ماركودت.

(*) تم استلام البحث في ٢٧/٥/٢٠١٣ وحصل على قبول النشر في ١١/١١/٢٠١٣.

Using the Artificial Neural Networks with different algorithms to estimate the daily evaporation in Mosul city by using climate Information

Suzan Khalid Ibrahim

Asst. Lect., Mosul technical Institute

Abstract

In this research a model of Neural Networks was applied to estimate the daily Evaporation of Mosul city using certain climate parameters (the maximum and the minimum temperature, rain, relative humidity, wind speed and the sun shine) for any day in the year using the Feed Forward Back Propagation (FFBPNN), Cascade-Forward Back Propagation (CFBPNN) and the FitNet network. Each of these networks has two architectures: architecture with four layers and five cells in the hidden layers from one hand, and architecture with five layers and five cells in the hidden layers from the other.

Different algorithms were used for the training: Levenberg-Marquardt algorithm (LM), Quasi-Newton algorithm (BFGS), Conjugate Gradient algorithm (CFG), Gradient Descent algorithm (GD) and Gradient Descent with Momentum algorithm (GDM). Data were obtained from the forecast Directorate in AlRashedeyyah district in Nineveh Province for the period (1995-2008) are used in the research. Data of ten years for the period (1995-2004) were employed to develop the models and the data of four years were used to evaluate the models, to compare their outputs with the data measured. R2 and the RMSE methods were used to estimate the level of correspondence for the measured data and NN outputs to select the best prediction model from the models applied.

Results show that the FitNet with (LM) algorithm is efficient in improving a prediction model to estimate the daily Evaporation as the value of coefficient estimation was (0.98), and this is considered the best and the fastest algorithm if temperature, rain, relative humidity, wind speed and sunshine data available for any day in the year.

Keywords: BPNN, Gradient Descent, Gradient Descent with Momentum, Conjugate Gradient Quasi-Newton, Levenberg-Marquardt.

المقدمة:

في العقود الأخيرة طورت العديد من نماذج التنبؤ اللاخطية مثل أنظمة الذكاء الاصطناعي، الذي يمكن ان يلائم البيانات وبشكل أفضل من النماذج الخطية التي غالباً ما يكون التنبؤ بها ضعيفاً، إن أنظمة الذكاء الاصطناعي ذات تقنيات واسعة وتوفر طرق بديلة لمعالجة المشاكل المعقدة، وهي قادرة على معالجة البيانات غير المتكاملة والتي تحتوي على ضوضاء وكذلك حل المشاكل اللاخطية التنبؤية بسرعة عالية. استخدمت التقنيات الذكائية في تطبيقات متنوعة مثل الإنسان الآلي، وتمييز الأنماط، والتنبؤ، والطب، والأنظمة الكهربائية، والتصنيع، والامثلية، ومعالجة الإشارة، وأنظمة الذكاء الاصطناعي تشمل الأنظمة الخبيرة، والشبكات العصبية الاصطناعية (Kalogirou, 2003, 515).

الخوارزميات الجينية، المنطق المضطرب، وأنظمة هجينية أخرى تجمع بين واحد أو أكثر من التقنيات أعلاه (سنوس، ٢٠١١، ٢٣). إن الشبكات العصبية الاصطناعية (ANN) تعدّ من أنظمة الذكاء الاصطناعي التي تعالج بيانات هائلة بشكل متوازٍ لتدريبها وإكسابها معرفة ملائمة لغرض التطبيق (De Jesus & Hagan, 2007, 14) (Beigy & Meybodi, 2009, 101)، والفائدة الأكبر قدرة الشبكات العصبية على تشكيل العلاقات اللاخطية المعقدة من دون فرضيات استنتاجية عن طبيعة العلاقة (De Jesus & Hagan, 2001, 2638) (Medsker & Jain, 2000, 1).

تشكل عملية التبخر إحدى المركبات المهمة للدورة الهيدرولوجية للمياه في الطبيعة وعلى هذا الأساس اهتم الكثير من الباحثين في دراسة هذه العملية وذلك بتخمينها بطرائق مختلفة منها استخدام الأحواض ومعاملات الأنواء الجوية وهي الأكثر شيوعاً، وأخرى تجريبية التي معظمها تم استنتاجها بالطرائق الإحصائية التقليدية، إذ إن معاملاتها الثابتة لمناطق محددة تجعل تطبيقها على مناطق أخرى مصحوباً بالخطأ فضلاً عن عدم إمكانية استخدامها لتقدير التبخر اليومي (Kumar & Tiwari, 2012, 1)، (Ariapour & Zavareh, 2008, 1)، (افتخار وكامل، ٢٠٠٧، ١)، وكان التوجه إلى استخدام الشبكات العصبية الاصطناعية لتقدير التبخر اليومي لأية منطقة وبدقة

عالية عند توفر المعلمات المناخية من درجات الحرارة، والرطوبة، والسطوع الشمسي، والامطار وسرعة الرياح (Rahimikhoob, 2009, 101).

إن التجارب في السنوات الأخيرة أثبتت كفاءة الشبكات العصبية الاصطناعية في بناء النماذج لتقدير التبخر للحصول على قياسات متوقعة ذات دقة عالية مع القياسات الحقيقية، فقد استخدم الباحث (Kalogirou, 2003, 515) شبكة BPNN لتقدير التبخر ووصل إلى معامل تحديد (٠,٩١).

في حين استخدم الباحثون (Ariapour & Zavareh, 2008, 1) درجات الحرارة، الرطوبة، سرعة الرياح والسطوع الشمسي لقياس التبخر باستخدام شبكة التغذية الأمامية (FFBPNN) وبمعماريات مختلفة وتوصلوا إلى معامل تحديد R^2 يساوي (٠,٧٢)، ومربع خطأ MSE يساوي (٠,٠٧)، أما الباحث (Rahimikhoob, 2009, 101) فقد استخدم شبكة البيرسبترون المتعددة الطبقات MultiLayers Perceptron (MLP) بخوارزمية التغذية العكسية (BP) لتقدير التبخر من خلال بعض المعلمات المناخية المتمثلة بدرجات الحرارة العظمى والصغرى والاشعاع الشمسي وتوصل إلى معامل تحديد أكبر من (٠,٨٨). وقام الباحثون (Tabari, Marofi & Sabziparvar, 2010, 399) باستخدام عدة معاملات من درجات حرارة الهواء، الاشعاع الشمسي، سرعة الرياح وكمية الامطار لتقدير التبخر من خلال شبكة MultiLayers Perceptron، واستخدم الباحثون (Jahanbani & Hussein, 2010, 207) شبكة (BPNN) لتقدير التبخر اليومي باستخدام درجات الحرارة العظمى والصغرى وتوصلوا إلى معامل تحديد يساوي (٠,٩٥). أما الباحثون (Ozkan, Kisi & Akay, 2010, 431) قاموا باستخدام الشبكات العصبية مع مستعمرة النحل الاصطناعية (ABC) لتقدير التبخر اليومي لمدينة لوس انجلوس وتوصلوا إلى معامل تحديد (٠,٩٥). وتوصل الباحث (Archana, 2010, 4210) إلى معامل تحديد مساوٍ لـ (٠,٩٦) من خلال استخدام شبكة (FFBPNN) لتقدير التبخر الشهري لبعض المعلمات المناخية.

في حين قام الباحثون (Kumar & Tiwari, 2010, 1) باستخدام شبكة (BPNN) لتقدير التبخر اليومي وكانت قيمة معامل التحديد (٠,٩٢٣)، أما الباحث (Jadeja, 2011, 3) استخدم شبكة البيرسبترون متعددة الطبقات (MLP) لتقدير التبخر اليومي مستخدماً درجات الحرارة العظمى والصغرى وتوصل إلى معامل تحديد (٠,٩٢).

وقام الباحثون (Diamantopoulou & Georgiou, 2011, 18) باستخدام شبكة MLP بخوارزمية (BP) وشبكة (CCBPNN) بخوارزمية كالمن لتقدير التبخر في اليونان باستخدام درجات الحرارة العظمى والصغرى وأظهرت النتائج أن شبكة (CCBPNN) أفضل من شبكة (FFBPNN) إذ توصلوا إلى معامل تحديد (٠,٩٥).

أما الباحث (سنوس، ٢٠١١، ٢٣) استخدم نظام الاستدلال المضطرب لتقدير التبخر اليومي وكانت قيمة معامل التحديد أكثر من (٠,٩).

وفي عام ٢٠١٢ قام الباحثون (Moasheri, Afrasiab & Sarani, 2012, 83) باستخدام شبكة MLP لنماذج متعددة لتقدير التبخر اليومي وتوصلوا إلى معامل تحديد (٠,٩٧).


والباحثون (Nourani & Fard, 2012, 127) فقد استخدموا أنواعاً مختلفة من الشبكات كانت قيمة معامل التحديد (٠,٩٥).

أما الباحثون (Kumar & Tiwari, 2012, 51) قاموا باستخدام نماذج متعددة من الشبكات العصبية لتقدير التبخر اليومي وكان أفضلها شبكة البيرسبترون المتعددة الطبقات إذ كانت قيمة معامل التحديد (٠,٩٣).

الهدف من هذا البحث هو بناء نماذج من الشبكات العصبية المختلفة بخوارزميات متعددة لتقدير التبخر اليومي لمدينة الموصل بدلالة بعض المعلمات المناخية سهلة القياس. ما تبقى من البحث كما يلي: القسم الثاني يتضمن تفاصيل الطريقة المستخدمة في البحث. القسم الثالث يشرح المواد ومنهجية البحث المقترحة. القسم الرابع النتائج ومناقشتها. القسم الخامس الاستنتاجات.

٢- الشبكات العصبية:

الشبكات العصبية تمتلك فائدة رئيسة هي قابليتها للاخطية المرنة لصياغة النماذج وليس هناك حاجة لتحديد نموذج قياسي ثابت، بالاحرى النموذج يتكيف على وفق ميزات البيانات. قادت هذه النظرة إلى صياغة العديد من البحوث التجريبية وبناء النماذج لمعالجة البيانات بطرق ملائمة. والأنواع الأكثر شيوعاً من نماذج الشبكات العصبية نراها في الشكل (١) (Haoffi, Guoping, Fagting & Han, 2007, 347)



شكل (١)


الشبكات العصبية الاصطناعية الأكثر شيوعاً

١-٢ الشبكات العصبية ذات التغذية الأمامية:

الشبكات العصبية ذات التغذية الأمامية هي نوع من الشبكات التي لا تحتوي على روابط رجوع بصورة عكسية ولا تحتوي على عناصر تأخير، الإخراج يحسب مباشرة من الإدخال باتجاه تغذية أمامية من خلال روابط الشبكة منها شبكة الانتشار العكسي أو ما تسمى الشبكة ذات التغذية الأمامية Feed Forward Back Propagation (FFBPNN) يوضحها الشكل (٢) شبكة Cascade Forward Back Propagation (CFBPNN)، وشبكة الملاءمة (Function Fitting (Fitnet). شبكة الانتشار العكسي استعملت على نحو واسع في الكثير من المجالات، وبمرور الوقت

استعملت في السلاسل الزمنية التنبؤية لأنها قادرة على حل انواع عديدة ومختلفة من المشاكل.

شبكة الانتشار العكسي بتغذية امامية FFBPNN مكونة عادة من عدة طبقات: طبقة الإدخال، طبقة الإخراج وواحدة أو أكثر من الطبقات الخفية كما موضح في الشكل (٢). أما شبكة CFBPNN فإنها شبكة ذات انتشار عكسي بروابط إضافية من الإدخالات باتجاه الطبقات الخفية وطبقات الإخراج لتسريع عملية التدريب يوضحها الشكل (٣). أما شبكة الملائمة FitNet فهي شبكة انتشار عكسي بتغذية امامية وتعدّ أسرع من شبكة FFBPNN (Math Work, 2010).




شكل (٢)

شبكة الانتشار العكسي المثالية

الإدخالات في الشبكة لها وزن (w) weight، تجمع الإدخالات الموزونة مع انحيازاتها (b) bias، بعدها تطبق دالة التنشيط (Activation Function (AF). الخلايا العصبية يمكن أن تستعمل انواعاً من دوال التنشيط لتوليد الإخراج وبشكل عام دوال التنشيط اللاخطية تعدّ ملائمة ومثالية لأكثر التطبيقات، والشبكات ذات التغذية الامامية والتي تمتلك طبقة (طبقات) خفية في أغلب الاحيان تكون طبقاتها الخفية بدالة السيكمويد (Sigmoid AF)، وطبقة الإخراج بدالة خطية (Purline AF). شبكة الانتشار العكسي تمر بمرحلتين: مرحلة التغذية الامامية التي تدخل فيها أنماط التدريب (البيانات) إلى الشبكة وترسل خلال الطبقات المتعاقبة وصولاً إلى الإخراج، ومرحلة التدريب أو ما تسمى (التعليم) تعدل من خلالها الاوزان أو الباراميترات بشكل تكراري

لكل انماط التدريب (إدخال-إخراج) على اساس تقليل الاخطاء بين مخرجات الشبكة والمخرجات الحقيقية بانحدار تدريجي للأخطاء (GD) Gradient Descent أو ما تسمى نشر الأخطاء العكسي بواسطة خوارزمية التدريب (Beigy & Meybodi, 2009, 101). (MathWork, 2010)



شكل (٣)

شبكة CFBPNN

٢-٢ خوارزميات التدريب:

هذا البحث مستند على الخوارزميات التكرارية المختلفة لتعليم شبكة الانتشار العكسي إذ استخدمت خوارزمية الانحدار التدريجي (GD) Gradient Descent، الانحدار التدريجي المعجل (GDM) Gradient Descent with Momentum، خوارزمية الميل الصرفية (CGF) Conjugate Gradient BP، خوارزمية نيوتن (BFGS) Quasi-Newton، خوارزمية ليفن بيرك ماركودت (Levenberg Marquardt (LM) وكالاتي:

• خوارزمية الانحدار التدريجي (GD) Gradient Descent:

خوارزمية الانحدار التدريجي تسمح لأوزان الشبكة ان تتحرك على الجانب العكسي من دالة التنشيط، ودور الانتشار العكسي يعود إلى الطريقة التي يتم بها حساب الميل

لطبقات الشبكة المتعددة اللاحقية ويتم خلاله ضبط اوزان الشبكة والذي يحقق سرعة للخوارزمية، وتمثل الخوارزمية لتكرار واحد لتعديل الاوزان بالمعادلة (١):

$$W_{k+1} = W_k - \alpha_k g_k \dots\dots\dots (1) \square$$

إن إن:

α_k : معدل التعلم Learning Rate

g_k : الميل الحالي

W_k : الوزن القديم

W_{k+1} : الوزن الجديد

• خوارزمية الانحدار التدريجي المعجل Gradient Descent with Momentum (GDM):

شبكة الانتشار العكسي تتطلب العديد من التكرار، ولتخفيف هذه المشكلة يمكن أن تضاف معلمة تعجيل Momentum إلى التدريب بواسطة جعل الوزن مساوياً لمجموع جزء صغير من الوزن في الأوزان الأخيرة، ويكون تعديل الاوزان فيها على وفق المعادلة (٢):

$$W_{k+1} = W_k - \alpha_k g_k + \mu(W_k - W_{k-1}) \dots\dots\dots (2) \square$$

إن إن:

μ : التعجيل Momentum والذي تكون قيمته بين (٠ - ١)

W_{k-1} : الوزن السابق للوزن القديم

أما المتغيرات (α_k , g_k , W_k , W_{k+1}) موضحة في المعادلة (١)

□. (Zayani, Bouallegue & Roviras, 2008, 25).

• خوارزمية الميل الصرفية (CGF) Conjugate Gradient BP:

خوارزمية BP القياسية تعدل الاوزان باتجاه هبوط حاد للميل الذي ليس بالضرورة ينتج عنه استقرارية للشبكة. وهو حساس جداً لمعدل التعلم الذي قد يسبب

عدم استقرارية للشبكة أو تأخذ وقتاً طويلاً للوصول إلى الحل. مؤخراً استعمل عدة خوارزميات للميل لتعليم الشبكات العصبية (De Jesus & Hagan, 2001, 2640) وفي كل تكرار للخوارزمية لمختلف الاتجاهات بطريقة ما ينتج عنه تسريع للوصول إلى الحل. ففي خوارزمية الميل الصرفية التي اقترحت من Fletcher and Reeves، تبدأ بالبحث عن الهبوط الحاد في التكرار الأول:

$$P_0 = -g_0$$

واتجاه البحث في كل تكرار يحدد بواسطة تغيير الأوزان بالمعادلة (٣):

$$W_{k+1} = W_k - \alpha_k g_k + \mu_k P_k \dots\dots\dots (3) \square$$

إذ إن:

$$P_k = -g_k + \beta_k P_{k-1}$$

وأن Fletcher and Reeves يغير الثابت β_K بالمعادلة التي هي نسبة تربيع الميل الحالي على تربيع الميل السابق وعلى وفق المعادلة (٤):

$$\beta_k = \frac{g_K^T g_k}{g_K^T g_{k-1}} \dots\dots\dots (4) \square$$

g_0 : الميل الابتدائي

g_k : الميل الحالي

g_{k-1} : الميل السابق

μ_k : التعجيل Momentum

أما المتغيرات (α_k , g_k , W_k , W_{k+1}) موضحة في المعادلة (١).

• خوارزمية نيوتن (BFGS) Quasi-Newton:

طريقة نيوتن غالباً ما تكون أسرع من GD ولكن حساباتها مكلفة للغاية نظراً لحسابات واسعة لمصفوفة Hessian الآتية من المشتقات الثنائية (Second

(Derivatives) الأسلوب الأكثر نجاحاً في الدراسات هو خوارزمية BFGS المحدثة والتي تتغير الأوزان بها على وفق المعادلة (٥):

$$W_{k+1} = W_k - H^{-1}_k g_k \dots\dots\dots (5) \square$$

إن إن:

H_k : Hessian Matrix (Second Derivatives) مصفوفة محسوبة بالطريقة الرياضية Hessian.

أما المتغيرات (g_k , W_k , W_{k+1}) موضحة في المعادلة (١).

• خوارزمية ليفن بيرك ماركودت (Levenberg-Marquardt (LM):

مشابهة لطريقة نيوتن، لكنه صمم على نهج سرعة التدريب من دون الحاجة لحساب مصفوفة Hessian في ظل فرضية أن دالة الخطأ هي مجموع المربعات، وأن مصفوفة Hessian تكون بصورة تقريبية بالطريقة:

$$H = J^T J \square$$

ويمكن حساب الميل على النحو الآتي:

$$g = J^T e \square$$

إن إن:

e : هي متجه الأخطاء للشبكة

J : هي مصفوفة Jacobian التي تحتوي على الأخطاء التي تتعلق بأوزان الشبكة، مصفوفة Jacobian هي أقل حساب وكلفة من مصفوفة Hessian، لذا الأوزان في الخوارزمية تتعدل على وفق المعادلة (٦):

$$W_{k+1} = W_k - [JJ^T + \mu I]^{-1} J^T e \dots\dots\dots (6) \square$$

إن إن:

μ : هو ثابت للسيطرة على سلوك الخوارزمية، فعندما $\mu=0$ تتبع خوارزمية طريقة نيوتن وتستعمل مصفوفة Hessian، لكن عندما μ ذات مستوى عالٍ يصبح هبوط الميل عالياً لحجم خطوات صغير.

أما المتغيرات (w_k, w_{k+1}) موضحة في المعادلة (١) (MathWork, 2010)
(Zayani, Bouallegue & Roviras, 2008: 25).

٣- مواد البحث وطرائقه:

تم استخدام البيانات اليومية المأخوذة من محطة الأنواء الجوية في منطقة الرشيدية في محافظة نينوى للفترة من ١٩٩٥-٢٠٠٨ والتي تضمنت (درجة الحرارة العظمى T_{max} والصغرى T_{min} ، والأمطار R ، والرطوبة النسبية Rh ، وسرعة الرياح W ، والإشعاع الشمسي S) ولكل يوم من السنة إذ كانت عدد القراءات (٥١١٠). تم بناء النماذج باستخدام (٥) خوارزميات لتدريب الشبكات، وقسمت البيانات المستخدمة إلى مجموعتين: مجموعة التدريب وكانت بنسبة ٧٠٪ من البيانات الكلية فكانت عدد القراءات (٣٦٥٠) أي بيانات عشرة أعوام، ومجموعة الاختبار بنسبة ٣٠٪ من البيانات الكلية فكانت عدد القراءات (١٤٦٠) أي بيانات الأربعة أعوام الباقية. ولقياس كفاءة أداء النماذج المستخدمة تم استخدام معامل التحديد R^2 ، وجذر متوسط مربع الأخطاء RMSE (Kalogirou, 2003: 520).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - T_i)^2}{n}} \dots \dots \dots (7) \quad \square$$

إذ إن:

O_i : الإخراج المحسوب من الشبكة.

T_i : الإخراج الحقيقي.


n : هو عدد البيانات المستخدمة في التدريب.

واستخدمت هذه المعايير في مقارنة البيانات الحقيقية (المقاسة) والبيانات المحسوبة من اختبار نماذج الشبكات العصبية المستخدمة لبيانات أربعة أعوام كاملة من

(٢٠٠٥ - ٢٠٠٨) وذلك لضمان تطابق النماذج لجميع المراحل السنوية وظروفها، (علما أن هذه البيانات لم تدخل في عملية بناء نماذج الشبكات العصبية).


تم استخدام Matlab 2010b لتصميم نماذج الشبكات العصبية المستخدمة في تقدير التبخر اليومي، هذه النماذج تمثل شبكات ذات تغذية أمامية وهي شبكة FFBPNN، CFBPNN وشبكة FitNet وبمعماريتين لكل شبكة: معمارية (١-٥-٦) المكونة من أربع طبقات (طبقة الإدخال والتي تحوي ستة مدخلات بعدد المعلمات المناخية المستخدمة، الطبقة الخفية الأولى والمكونة من خمسة عناصر، الطبقة الخفية الثانية والمكونة من خمسة عناصر وطبقة الإخراج والمكونة من إخراج واحد والذي يمثل التبخر) والموضحة بالشكل (٤) لشبكة FFBPNN والشكل (٥) لشبكة CFBPNN. ومعمارية (١-٥-٥-٥-٦) المكونة من خمسة طبقات (طبقة الإدخال، ثلاثة طبقات خفية وطبقة الإخراج) وبالخوارزميات الآتية لكل معمارية:

- 1- Levenberg-Marquardt algorithm (TRAINLM).
- 2- Algorithm TRAINBFG.
- 3- TRAINCGF algorithm.
- 4- Gradient descent algorithm (TRAINGD).
- 5- Gradient descent with momentum (TRAINGDM).



شكل (٤)

شبكة FFBPNN (1-5-5-6)



شكل (٥)

شبكة CFBPNN (1-5-5-6)

٤- النتائج والمناقشة:

تشير النتائج التي تم الحصول عليها من تطبيق نماذج الشبكات العصبية على بيانات أربعة أعوام (٢٠٠٥ - ٢٠٠٨) والتي لم تدخل ضمن عملية بناء النماذج، بإمكانية تقدير التبخر اليومي باستخدام بيانات الإدخال (درجة الحرارة العظمى والصغرى، الرطوبة النسبية، الأمطار، سرعة الرياح والإشعاع الشمسي) والتبخر كإخراج، كما ومن خلال العمل تبين أن استخدام درجة الحرارة العظمى والصغرى، الأمطار، الرطوبة النسبية أو الإشعاع الشمسي كل عامل لوحده غير كافٍ لإعطاء تقديرات صحيحة وإن نسبة الخطأ فيها كبيرة جداً. فعند بناء النماذج المستخدمة بمعدل تعلم ثابت بمقدار (٠,٠٠٠١) وباستخدام العوامل المناخية جميعها تم الحصول على نتائج دقيقة وكانت دقتها متفاوتة من نموذج إلى آخر وكما موضحة في الجدول (١)، الذي يبين المقارنة ما بين أداء النماذج المستخدمة ولكل الخوارزميات لكل نموذج وبمعيارية (١-٥-٥-٦)، من خلال استخدام المعيارين معامل التحديد R^2 وجذر مربع متوسط الأخطاء RMSE المحسوبة من البيانات المقاسة وبيانات اختبار النماذج لاختيار أفضل نموذج منها.

لوحظ من النتائج أن معامل التحديد للنموذج الذي استخدم شبكة FFBPNN يتراوح بين (٠,٩١ - ٠,٩٥) وجذر متوسط مربع الأخطاء تراوح بين (٠,٢٢ - ٠,٠٨) وعلى

وفق خوارزميات التدريب المستخدمة، أما النموذج الذي استخدم شبكة CFBPNN ازداد معامل التحديد إلى (٠,٩٦) وانخفض معه جذر متوسط مربع الأخطاء إلى (٠,٠١) عند استخدام خوارزمية (LM)، وكذلك ازدادت قيمة معامل التحديد للنموذج الذي استخدم شبكة FitNet إذ وصل إلى (٠,٩٦) مع انخفاض ملحوظ لجذر متوسط مربع الخطأ إلى (٠,٠٠٠٦) عند استخدام خوارزمية (LM).

ولقياس كفاءة النماذج واختيار أفضل نموذج لتقدير التبخر تم تطبيق جميع النماذج السابقة وبالإدخال والإخراج أنفسهما ولكل الخوارزميات وبمعمارية مختلفة من خلال زيادة عدد الطبقات الخفية (١-٥-٥-٥-١٦) وكما موضحة في الجدول (٢)، إذ لوحظ زيادة في دقة النتائج باستخدام خوارزمية (LM) لكل نماذج الشبكات فقد تراوحت قيمة معامل التحديد بين (٠,٩٥ - ٠,٩٨) وانخفاض قيمة متوسط مربع الخطأ الذي تراوح بين (٠,٠٠١٢ - ٠,٠٧).

جدول (١)

اداء النماذج بمعمارية (١-٥-٥-٦)

النماذج				
FitNet	CFBP	FFBP	الخوارزميات	
٠,٩٦	٠,٩٦	٠,٩٥	LM	معامل التحديد R^2
٠,٩٣	٠,٩٢٣	٠,٩١	BFGS	
٠,٩٤٦	٠,٩٢٥	٠,٩٢	CGF	
٠,٩٤٣	٠,٩٣٤	٠,٩٣	GD	
٠,٩٥٧	٠,٩٤٤	٠,٩٤	GDM	
٠,٠٠٠٦	٠,٠١	٠,٠٨	LM	جذر متوسط مربع الأخطاء RMSE
٠,٠٠٩	٠,٠٨	٠,١٢	BFGS	
٠,٠٠٨	٠,٠٩	٠,١٥	CGF	
٠,٠٠٤	٠,٠٧	٠,٢٢	GD	
٠,٠٠٢	٠,٠٥	٠,١٩	GDM	

جدول (٢)


أداء النماذج المعمارية (١-٥-٥-٦)

النماذج				
FitNet	CFBP	FFBP	الخوارزميات	
٠,٩٨	٠,٩٦٧	٠,٩٥٥	LM	معامل التحديد R^2
٠,٩٤	٠,٩٣٨	٠,٩٢	BFGS	
٠,٩٤٨	٠,٩٣٧	٠,٩٣	CGF	
٠,٩٤٧	٠,٩٤٢	٠,٩٤	GD	
٠,٩٥٧	٠,٩٥٣	٠,٩٥	GDM	
٠,٠٠٠١٢	٠,٠٠٦	٠,٠٧	LM	جذر متوسط مربع الأخطاء RMSE
٠,٠٠٠٩	٠,٠٥	٠,١١	BFGS	
٠,٠٠٠٨	٠,٠٦	٠,١٢	CGF	
٠,٠٠٠٦	٠,٠٣	٠,١٨	GD	
٠,٠٠٠٤	٠,٠١	٠,١٦	GDM	

يلاحظ من النتائج ان خوارزمية التدريب لها تأثير واضح على دقة النتائج فمع بقاء عدد الخلايا الخفية بعدد (٥) لكل نموذج من نماذج التدريب المعمارية (١-٥-٥-٦) كانت قيم معامل التحديد متفاوتة من نموذج إلى آخر باختلاف خوارزميات التدريب إذ كان أفضلها عند استخدام خوارزمية LM لنموذج شبكة الملاءمة FitNet إذ وصلت قيمة R^2 إلى (٠,٩٦)، لكن عند تغيير المعمارية بزيادة عدد الطبقات الخفية من (٢) إلى (٣) طبقات خفية من خلال معمارية (١-٥-٥-٥-٦) فمع زيادة الحسابات وبطء التدريب لكل نموذج كان هناك دقة عالية في الحصول على النتائج أفضلها عند استخدام خوارزمية LM لنموذج شبكة الملاءمة FitNet الذي وصل معامل التحديد فيها إلى (٠,٩٨).

ولوحظ أيضاً ان الخوارزمية لها تأثير واضح في سرعة الحصول على النتائج فقد كانت خوارزمية GD أبطأ خوارزمية إذ تراوحت عدد الدورات التدريبية فيها بين (٣٥-٤١) دورة يوضحها الجدول (٣) للنماذج في معمارية (١-٥-٥-٦)، لكن عند استخدام

خوارزمية GDM وبقيمة تعجيل فرضت (٠,٣) قلت سرعة التدريب وتراوح بين (٣٣-٣٩) دورة تدريبية، أما عند استخدام خوارزمية CGF تراوح عدد الدورات التدريبية بين (٣١-٣٧) دورة تدريبية وذلك بسبب طبيعة الخوارزمية التي تبدأ بالبحث عن الهبوط الحاد للميل من التكرار الأول للخوارزمية والذي يسرع التدريب، في حين تراوحت عدد الدورات التدريبية لخوارزمية نيوتن BFGS بين (٢٦-٣٠) دورة تدريبية فعلى الرغم من الحسابات الواسعة لمصفوفة Hessian إلا أنه كان هناك سرعة في التدريب، أما خوارزمية LM كانت أسرع خوارزمية تدريبية فقد تراوحت عملية التدريب فيها بين (٢٢-٢٧) دورة تدريبية هذه السرعة جاءت من خلال دخول مصفوفة Jacobian في حساب الأوزان والتي تسرع عملية التدريب مقارنة بمصفوفة Hessian وذات كلفة أقل. لكن عند زيادة عدد الطبقات الخفية من خلال معمارية (١-٥-٥-٥-٦) وزيادة الحسابات وبطء التنفيذ لاستقرارية كل نموذج لوحظ أن هناك تسريعاً لكل نماذج الاختبار وكان أسرعها باستخدام خوارزمية (LM) فقد تراوحت عملية التدريب فيها بين (١٥-٢٠) دورة تدريبية لكل الشبكات والتي يوضحها الشكل (٦)، كما بينت النتائج أن شبكة الملاءمة FitNet بخوارزمية (LM) أفضل وأسرع خوارزمية بمعامل تحديد (٩٨,٠) وسرعة لم تتجاوز (١٥) دورة تدريبية لتقدير التبخر اليومي إذا ما توفرت العوامل المناخية المستخدمة جميعها.



شكل (٦)

تسريع خوارزمية (LM) للنماذج ANN المقترحة

جدول (٣)

عدد الدورات التدريبية للنماذج

الشبكات العصبية				
FitNet	CFBP	FFBP	الخوارزميات	
٢٢	٢٦	٢٧	LM	معمارية (6-5-5-1)
٢٦	٢٩	٣٠	BFGS	
٣١	٣٤	٣٧	CGF	
٣٥	٣٩	٤١	GD	
٣٣	٣٧	٣٩	GDM	
١٥	١٨	٢٠	LM	معمارية (6-5-5-5-1)
٢٣	٢٦	٢٨	BFGS	
٢٦	٢٩	٣٢	CGF	
٣٢	٣٥	٣٨	GD	
٣٠	٣٢	٣٥	GDM	

٥- الاستنتاجات:

الشبكات العصبية الاصطناعية أثبتت نجاحها في عملية بناء نموذج لتقدير التبخر اليومي باستخدام (درجة الحرارة العظمى والصغرى، والأمطار، والرطوبة النسبية، وسرعة الرياح والاشعاع الشمسي) لأي يوم من أيام السنة. أعطت النتائج تقديرات ذات دقة عالية للتبخر اليومي إذ وصلت قيمة معامل التحديد فيها إلى (٠,٩٨)، وجاءت هذه الدقة من القراءات الحقيقية للبيانات والتي استخدمت في عملية التدريب والاختبار، وهذه الدقة تكون مقبولة كبديل عن القياسات الحقلية المكلفة في الوقت والجهد والكلفة المادية بقيم تزيد أو تقل عن قيمة واحدة لقيم التبخر اليومي المقاس، ولوحظ من خلال المقارنة بين نماذج الشبكات العصبية الاصطناعية وخوارزمياتها ان جميعها يمكن استخدامها لاغراض تنبؤية تعتمد على طبيعة البيانات، وان شبكة الملاءمة FitNet بخوارزمية LM اعطت أفضل نموذج وأسرع يمكن الاعتماد عليه لتقدير التبخر اليومي إذا ما توفرت العوامل المناخية جميعها التي تم استخدامها ولجميع أيام السنة. ونوصي في

البحوث المستقبلية أنه يمكن استخدام شبكة FitNet بخوارزمية LM لبناء نماذج تنبؤية لأنواع أخرى من البيانات، كما ويمكن استخدام الشبكات العصبية ذات السلاسل الزمنية لبناء نموذج تنبؤي لتقدير التبخر اليومي.

٦-المصادر:

- [1] العاني، افتخار والحسن، كامل (٢٠١١)، "تقدير التبخر- النتح المرجعي اليومي لمنطقة الموصل باستخدام الشبكات العصبية الاصطناعية".
- [2] الشلاوي، سنوس (٢٠١١)، "مقارنة تطبيقات الشبكات العصبية الاصطناعية والنظام المضرب لتقدير التبخر الانائي اليومي لمدينة الموصل"، مجلة الكوفة للرياضيات والحاسبات، المجلد ١، العدد ٣، ص ٢٣-٣٢.
- [3] A. Ariapour, M. N. Zavareh (2008), "Estimation of Daily Evaporation Using of Artificial Neural Networks", Islamic Azad University.
- [4] A. Rahimikhoob (2009), "Estimating Daily Pan Evaporation Using Artificial Neural Network in a Semi-Arid Environment", Springer-Verlag, pp. 101-105.
- [5] C. Archana (2010), "Reference Crop Evapotranspiration Estimation Using Artificial Neural Networks", International Journal of Engineering Science and Technology, Vol.2(9), pp. 4205-4212.
- [6] C. Ozkan, O. Kisi, B. Akay (2010),"Neural Network with Artificial Bee Colony Algorithm for Modeling Daily Reference Evapotranspiration", pp. 431- 441.
- [7] De Jesús O., M.T. Hagan (2001), "Backpropagation through Time for a General Class of Recurrent Network". Proceedings of the IJCNN, Vol. 4, pp. 2638-2643.
- [8] D. Kumar, A. K. Tiwari (2012), "Evaporation Estimation Using Artificial Neural Network and Adaptive Neuro-Fuzzy Interface Techniques", Pakistan Journal of Meteorology, Vol. 8, Issue 16.

-
- [9] Haoffi Z., X. Guoping, Y. Fagting, Y. Han, A. (2007), "Neural Network Model Based on the Multi-Stage Optimization Approach for Short-Term Food Price Forecasting in China, Expert Systems with Applications, pp 347-356.
- [10] H. Beigy & M. R Meybodi (2009). "A learning Automata-Based Algorithm for Determination of the Number of Hidden Units for Three-layer Neural Networks," International Journal of Systems Science, vol. 40, No. 1, pp.101–118.
- [11] H. Jahanbani, A. Hussein (2010), "Application of Artificial Neural Network in Estimating Monthly Time Series Reference Evapotranspiration with Minimum and Maximum Temperatures", Vol. 9, pp. 207-220.
- [12] H. Tabari, S. Marofi, A. Sabziparvar (2009), "Estimation of Daily pan Evaporation Using Artificial Neural Network and Multivariate Non-Linear Regression", pp. 399- 406.
- [13] L.R.Medsker, L.C. Jain (2000), "Recurrent neural networks: Design and applications", Boca Raton, FL: CRC Press.
- [14] MathWorks (2010), Neural Network Toolbox 7.0, MathWorks Announces Release 2010a of the MATLAB and Simulink Product Families, www.mathworks.com/trademarks.
- [15] M.J.Diamantopoulou, P.E. Georgiou (2011), "Performance Evaluation of Artificial Neural Networks in Estimating Reference Evapotranspiration with Minimal Meteorological Data", Global NEST Journal, Vol. 13, No. 1, PP. 18-27.
- [16] O. De Jesus and M. T. Hagan (2007), "Backpropagation Algorithms for a Broad Class of Dynamic Networks" IEEE Transactions on Neural Networks, vol.18, No.1, pp.14 -27.
- [17] P. Kumar, A.K.Tiwari (2010), "Evaporation Estimation Using Artificial Neural Network", International Journal of Computer Theory and Engineering, Vol. 4, No. 1.
- [18] R.Zayani, R.Bouallegue, D.Roviras (2008), "Levenberg-Marquardt Learning Neural Network for Adaptive Predistortion

- for Time– Varying HPA with Memory In OFDM Systems" EUSIPCO, Lausanne, Switzerland, pp. 25-29.
- [19] S.A.Kalogirou (2003), "Artificial intelligence for the modeling and control of combustion processes: a review", Progress in Energy and Combustion Science, Vol. 29, Issue 6, pp. 515–566.
- [20] S.A. Moasheri, P.Afrasiab, S. Sarani (2012), "Estimating of Reference Evapotranspiration by Using Artificial Neural Networks", ICTECE.
- [21] V. Jadeja (2011), "Artificial Neural Network Estimation of Reference Evapotranspiration from Pan Evaporation in a Semiari Environment", B.V.M. Engineering College, V.V.Nagar, Gujarat, India.
- [22] V.Nourani, M.S.Fard (2012), "Sensitivity Analysis of the Artificial Neural Network Outputs in Simulation of the Evaporation Process at Different Climatologic Regimes", Advances in Engineering Software Journal, Vol. 47, pp. 127-146.