استخدام الشبكات العصبية الاصطناعية بخوارزميات مختلفة في نمذجة درجات حرارة التربة على اعماق واوقات مختلفة بدلالة بعض المعلومات المناخية

امية غانم عبدالجبار

المعهد التقني ، الموصل قسم انظمة الحاسوب ، الموصل ، العراق

omayaghanim@yahoo.com

(تاريخ الاستلام: 2012/11/24 ---- تاريخ القبول: 2013/4/22)

الملخص

تم في هذا البحث تطبيق انموذج الشبكة العصبية لتخمين درجات حرارة التربة على اعماق مختلفة وبأوقات قياس مختلفة بدلالة درجة حرارة الهواء وعدد ساعات السطوع والاشعاع الشمسي لأي يوم من السنة باستخدام شبكة الانتشار العكسي للخطا BP . تم استخدام خوارزميات مختلفة للتدريب خوارزمية الانحدار التدريجي (GD) ، خوارزمية الانحدار التدريجي المعجل (GDM) ، خوارزمية الميل الصرفية (CFG) ، خوارزمية نيوتن (BFGS) ، خوارزمية ليفن بيرك ماركودت (LM) . استخدمت البيانات الماخوذة من دائرة بحوث التربة والمياه/ محافظة نينوى للفترة من 1980-1983 وهي تشمل درجات حرارة التربة اليومية على اعماق (100,50,30,20,10,5) سم ولثلاث فترات عند الساعة (15,12,9) لترب مزروعة وغير مزروعة . استخدمت بيانات عامين لتطوير النماذج وبيانات عام واحد (1983) لتقييم النماذج ومقارنة مخرجاتها مع البيانات المقاسة ، كما استخدمت مقاييس معامل التحديد R^2 ، جذر متوسط مربع الاخطاء RMSE في الحكم على مدى تطابق البيانات المقاسة ومخرجات الشبكات العصبية لاختيار أفضل نموذج تنبؤي من بين النماذج المطبقة، بينت النتائج ان خوارزمية (LM) ذات كفاءة في تحسين نموذج تنبؤي لدرجة حرارة اعماق مختلفة من الترب اليومية ، وهي افضل واسرع خوارزمية لبناء تلك النماذج التنبؤية لأي عمق من اعماق الترب اليومية المزروعة وغير المزروعة اذا ماتوفرت درجات حرارة الهواء والاشعاع والطاقة الشمسية ولازمنة القياس الثلاثة لاي يوم من ايام السنة .

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

المقدمة

في العقود القليلة الأخيرة طورت العديد من نماذج التنبؤ اللاخطية مثل أنظمة الذكاء الاصطناعي ، الذي يمكن ان يلائم البيانات وبشكل أفضل من النماذج الخطية التي غالبا ما يكون التنبؤ بها ضعيف . أنظمة الذكاء الاصطناعي ذات تقنيات واسعة وتوفر طرق بديلة لمعالجة المشاكل المعقدة ،وهو قادر على معالجة البيانات غير المتكاملة والتي تحتوي على ضوضاء وكذلك حل المشاكل اللاخطية التنبؤية بسرعة عالية . استعملت هذه التقنيات في تطبيقات متنوعة مثل الإنسان الالي ، تمييز الأنماط ، التنبؤ ، الطب ، الأنظمة الكهربائية ، التصنيع ، الامثلية ، معالجة الإشارة، وعلوم اجتماعية ونفسية . أنظمة الذكاء الاصطناعي تشمل الأنظمة الخبيرة ، الشبكات العصبية الاصطناعية ، الخوارزميات الجينية ، المنطق المضبب ، وأنظمة هجينية أخرى تجمع بين واحد او أكثر من التقنيات أعلاه [1][2][3][4] . الشبكات العصبية الاصطناعية تعتبر من أنظمة الذكاء الاصطناعي ، التي تعالج بيانات هائلة بشكل متوازي لتدريبها وإكسابها المعرفة الملائمة لغرض التطبيق ، والفائدة الأكبر قدرة الشبكات العصبية على تشكيل العلاقات اللاخطية المعقدة بدون فرضيات استنتاجيه عن طبيعة العلاقة [5][6][7][8][9] . كذلك تعتبر الشبكات العصبية الاصطناعية أداة فعالة لبناء نماذج رياضية للعديد من المسائل التي تكون فيها العلاقات مرتبطة بمعطيات غيرمعروفة ، إذ تقدم طريقة مناسبة لتمثيل العلاقات لمعطيات المشكلة المراد حلها وبشكل يختلف عن الطرائق الإحصائية التقليدية لأنها تعتمد أسلوب المحاكاة (Simulation) في حل المشكلة بغية التوصل إلى بنية هندسية مترابطة تحقق هدفها في حل المشكلة [8][9] .

الشبكات العصبية الاصطناعية طبقت في المتواليات التسلسلية التنبؤية حيث كان هناك عدة عروض مختلفة على سبيل المثال أجرى الباحثون[10][11][12] دراسات من حيث مقارنة بين الشبكات العصبية والطرق التنبؤية التقليدية أثبتت تجاربهم ان الشبكات العصبية تعطي نتائج تنبؤية أفضل من تلك التي تعطيها الطرق الإحصائية التقليدية [13] . كما اجريت دراسات كثيرة في مجال التنبؤ لدرجات حرارة التربة اليومية حيث عمل الباحثون [15] [16] [14] واخرون على بناء نماذج باستخدام الشبكات العصبية الاصطناعية لتخمين درجة حرارة اعماق الترب وباستعمال عوامل مناخية مختلفة للحصول على تنبؤات متوقعة قريبة من القياسات الحقلية . الهدف من هذا البحث هو بناء نموذج شبكة عصبية كفوءة ذات سرعة عالية باستخدام خوارزميات متعددة لشبكة الانتشار العكسي للخطأ لتخمين درجات حرارة التربة على أعماق مختلفة باستخدام المعلومات المناخية سهلة القياس . ما تبقى من البحث كما يلي : القسم الثاني يتضمن

نمذجة درجة حرارة التربة في الابحاث السابقة . القسم الثالث تفاصيل الطريقة المستخدمة في البحث . القسم الرابع يشرح المواد ومنهجية البحث المقترحة. القسم الخامس النتائج ومناقشتها ، القسم السادس الاستنتاجات .

نمذجة درجات حرارة أعماق التربة في الابحاث السابقة

أثبتت التجارب في السنوات الأخيرة كفاءة الشبكات العصبية الاصطناعية في بناء نماذج تنبؤية لدرجة حرارة أعماق الترب اليومية للحصول على قياسات متوقعة ذات دقة عالية مع القياسات الحقلية، حيث عمل الباحثون [16]على بناء نموذج تنبؤي لدرجة حرارة أعماق التربة اليومية باستعمال عامل المطر والتبخر اليومي لأي يوم من أيام السنة للاعماق (100-1500) ملمتر بشبكة عصبية ذات انتشار عكسي BP وتراوح معامل التحديد فيها بين (0.94-0.98) . في حين عمل الباحث [14] على استخدام الشبكات العصبية الاصطناعية ذات الانتشار الامامي BP لتخمين درجة حرارة سطح التربة اليومية باستعمال درجة حرارة الهواء في المناطق اثينا Athens عاصمة اليونان ودبلن Dublin مدينة في ايرلندا وحصل في دراسته على قياسات قريبة من القياسات الحقلية وبمعامل تحديد وصل الى 0.97 .

كما قام الباحثين [32] بدراسة تنبؤية لقياس درجة حرارة أعماق الترب اليومية المزروعة لمدينة كرمنشاه غرب ايران باستخدام شبكة متعددة الطبقات(Multi-Layer Perceptron (MLP واستخدما في هذه الدراسة درجة حرارة الهواء والتبخر لقياس درجة حرارة اي عمق من الترب المزروعة وحصلا على معامل تحديد 0.98 . اما الباحث [15] فقد عمل في بحثه على بناء نموذج تنبؤي باستخدام شبكة الانتشار العكسي BP لتخمين درجة حرارة عمق معين لشهر معين وللاراضي المزروعة وغير المزروعة في مدينة Adana التركية باستخدام درجة حرارة الهواء الشهرية للأعماق(5-100) سم لأي شهر من السنة وتوصل الى معامل تحديد 0.98 للعمق (100) سم . في حين تم في هذا البحث استخدام الشبكة العصبية الاصطناعية ذات الانتشار العكسي وبخوارزميات مختلفة للتنبؤ بدرجات حرارة أعماق التـرب اليوميـة المزروعـة وغيـر المزروعـة وللأعمـاق (100,50,30,20,10,5) سم لمدينة الموصل .

الشبكات العصبية

الشبكات العصبية تمتلك فائدة رئيسية هي قابليتها اللاخطية المرنة لصياغة النماذج وليس هناك حاجة لتحديد نموذج قياسي ثابت ، بالاحرى النموذج يتكيف حسب ميزات البيانات [17] . قادت هذه النظرة الى صياغة العديدمن البحوث التجريبية وبناء النماذج لمعالجةالبيانات بطرق ملائمة.والأنواع الأكثرشيوعا من نماذج الشبكات العصبية نراها في الشكل رقم (1) [18] .

3-1 الشبكات العصبية ذات التغذية الأمامية

الشبكات العصبية ذات التغذية الامامية هي نوع من الشبكات التي لاتحتوي على روابط رجوع بصورة عكسية ولاتحتوي على عناصر تاخير ، الاخراج يحسب مباشرة من الادخال باتجاه تغذية امامية من خلال روابط الشبكة منها شبكة الانتشار العكسي BackPropagation او ماتسمى الشبكة ذات التغذية الامامية feedforward [19] . شبكة الانتشار العكسي استعملت على نحو واسع في الكثير من المجالات ، وبمرور الوقت استعملت في السلاسل الزمنية التنبؤية لانها قادرة على حل انواع عديدة ومختلفة من المشاكل [20][21] .

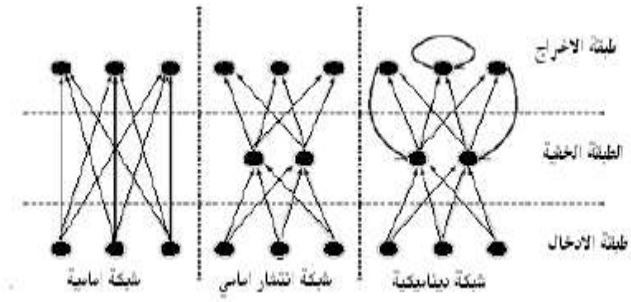

الشكل رقم (1) الشبكات العصبية الاصطناعية الاكثر شيوعا

شبكة الانتشار العكسي مكونة عادة من عدة طبقات : طبقة الادخال ، طبقة الاخراج وواحدة او اكثر من الطبقات الخفية كما موضح في الشكل رقم (2) . الادخالات في الشبكة لها وزن w ،تجمع الإدخالات الموزونة مع انحيازاتها bias(b) ، بعدها تطبق دالة التنشيط Activation Function (AF) . الخلايا العصبية يمكن ان تستعمل انواع من دوال التنشيط لتوليد الاخراج وبشكل عام دوال التنشيط اللاخطية تعتبر ملائمة ومثالية لاكثر التطبيقات ، والشبكات ذات التغذية الأمامية والتي تمتلك طبقة (طبقات) خفية في اغلب الاحيان تكون طبقاتها الخفية بدالة السيكمويد (Sigmoid AF) ، وطبقة الاخراج بدالة خطية (Purline AF) . شبكة الانتشار العكسي تمر بمرحلتين : مرحلة التغذية الامامية التي تدخل فيها انماط التدريب (البيانات) الى الشبكة وترسل خلال الطبقات المتعاقبة وصولا الى الاخراج ، ومرحلة التدريب او ماتسمى (التعليم) تعدل من خلالها الاوزان او البارامترات بشكل تكراري لكل انماط التدريب(ادخال–اخراج) على اساس تقليل الاخطاء بين مخرجات الشبكة والمخرجات الحقيقة بانحدار تدريجي للأخطاء (Gradient Descent (GD أو

ماتسمى نشر الأخطاء العكسي بواسطة خوارزمية التدريب [24] [22][23] .

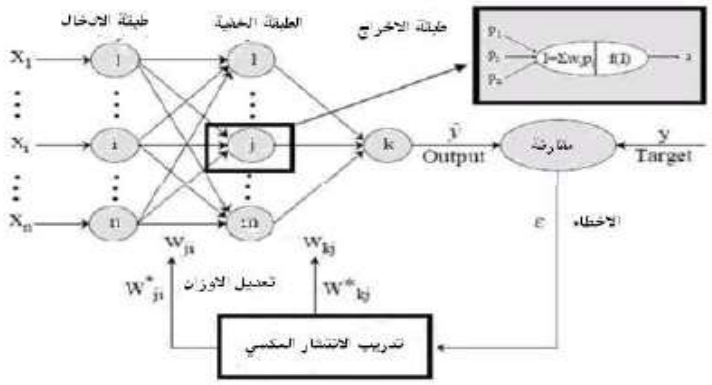

الشكل رقم (2) نموذج مثالي لشبكة الانتشار العكسي

3-2 خوارزميات التدريب

هذا البحث مستند على الخوارزميات التكرارية المختلفة لتعليم شبكة الانتشار العكسي حيث استخدمت خوارزمية الانحدار التدريجي (GD) ، الانحدار التدريجي المعجل (GDM) ، خوارزمية الميل الصرفية (CFG) ، خوارزمية نيوتن (BFGS) ، خوارزمية ليفن بيرك ماركودت (LM) وكالاتي :

حيث ان : α k : معدل التعلم learning rate

gk : الميل الحالي والمحسوب بطريقة [25] .

• خوارزمية الانحدار التدريجي المعجلGradient Descent with Momentum GDM :

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

حيث ان : μ التعجيل Momentum والذي تكون قيمته بين (0-1)

خوارزمية الميل الصرفية Conjugate gradient BP (CGF) :

خوارزمية BP القياسية تعدل الاوزان باتجاه هبوط حاد للميل الذي ليس بالضرورة ينتج عنه استقرارية للشبكة.وهو حساس جدا لمعدل التعلم الذي قد يسبب عدم استقرارية للشبكة او تاخذ وقت طويل للوصول الى الحل [26] . مؤخرا استعمل عدة خوارزميات للميل

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

حيث ان :

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

• خوارزمية نيوتنQuasi-Newton (BFGS) :

طريقة نيوتن غالبا ماتكون اسرع من GD ولكن حساباتهامكلفة للغاية نظرا لحسابات واسعة لمصفوفة Hessian الاتية من المشتقات الثنائية

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

• خوارزمية الانحدار التدريجي Gradient Descent (GD) :

خوارزمية الانحدار التدريجي تسمح لأوزان الشبكة ان تتحرك على الجانب العكسي من دالة التنشيط، ودور الانتشار العكسي يعود الى الطريقة التي يتم بها حساب الميل لطبقات الشبكة المتعددة اللاخطية ويتم خلاله ضبط اوزان الشبكة والذي يحقق سرعة للخوارزمية ، وتمثل الخوارزمية لتكرار واحد لتعديل الاوزان بالمعادلة (1) :

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

شبكة الانتشار العكسي تتطلب العديد من التكرار، ولتخفيف هذه المشكلة يمكن ان تضاف معلمة تعجيل Momentum الى التدريب بواسطة جعل الوزن مساوي لمجموع جزء صغير من الوزن في الاوزان الاخيرة ، ويكون تعديل الاوزان فيها حسب المعادلة (2) :

لتعليم الشبكات العصبية[5] وفي كل تكرار للخوارزمية لمختلف الاتجاهات بطريقة ما ينتج عنه تسريع للوصول الى الحل [27] . ففي خوارزمية الميل الصرفية التي اقترحت من Fletcher and Reeves [28][25] ، تبدا بالبحث عن الهبوط الحاد في التكرار الاول :

$P_0 = - g_0$

واتجاه البحث في كل تكرار يحدد بواسطة تغيير الاوزان بالمعادلة (3) :

وان Fletcher and Reeves يغير الثابت βK بالمعادلة التي هي نسبة تربيع الميل الحالي على تربيع الميل السابق وحسب المعادلة (4)

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

(second derivatives) [28] الاسلوب الاكثر نجاحا في الدراسات هو خوارزمية BFGS المحدثة [25] والتي تتغير الاوزان بها حسب المعادلة (5) :

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

واستخدمت هذه المعايير في مقارنة البيانات الحقيقية المقاسة والمحسوبة من نماذج الشبكة العصبية لسنة كاملة (1983) وذلك لضمان انطباق النماذج لجميع المراحل السنوية وظروفها، علما بان هذه البيانات لم تدخل في عملية بناء نماذج الشبكات العصبية . تم تصميم النماذج باستخدام Matlab 2010b لتحديد نموذج الشبكة العصبية الاصطناعية الذي يعطي تنبؤ جيد لدرجة حرارة أعماق التربة اليومية ، وكانت هذه النماذج تمثل شبكات ذات تغذية أمامية ، كشبكة الانتشار الامامي feedforwardnet .

جدول رقم (1) : البيانات الحقيقة المستخدمة في التنبؤ

البيانات الحقيقة	
اوقات القياس (15,12,9) Time	T
أيام السنة Day	D
درجة حرارة الهواء Air_temperature	Av
الاشعاع الشمسي Sunshine	S
الطاقة الشمسية Radiation	R
درجة حرارة ة العمق 5 Depth	De
درجة حرارة ة العمق 10	
درجة حرارة ة العمق 20	
درجة حرارة ة العمق 30	
درجة حرارة ة العمق 50	
درجة حرارة ة العمق 100	

جدول رقم (2) : نماذج الشبكات العصبية

النموذج	خوارزميات التدريب	الادخال	الاخراج	عدد الخلايا في الطبقة الخفية	عدد الدورات التدريبية
M1(feedforward)	GD	T,D,Av,S,R	De(5,10,20,30,50,100)	10	39
M2(feedforward)	GDM	T,D,Av,S,R	De(5,10,20,30,50,100)	10	29
M3(feedforward)	CGF	T,D,Av,S,R	De(5,10,20,30,50,100)	10	22
M4(feedforward)	BFGS	T,D,Av,S,R	De(5,10,20,30,50,100)	10	19
M5(feedforward)	LM	T,D,Av,S,R	De(5,10,20,30,50,100)	10	12
M6(feedforward)	GD	T,D,Av,S,R	Any single Depth	10	34*
M7(feedforward)	GDM	T,D,Av,S,R	Any single Depth	10	23*
M8(feedforward)	CGF	T,D,Av,S,R	Any single Depth	10	19*
M9(feedforward)	BFGS	T,D,Av,S,R	Any single Depth	10	17*
M10(feedforward)	LM	T,D,Av,S,R	Any single Depth	10	12*

*** : مجموع الدورات التدريبية لجميع النماذج للاعماق (5,10,20,30,50,100) سم**

النتائج والمناقشة

تشير النتائج التي تم الحصول عليها من تطبيق نماذج الشبكات العصبية على بيانات عام كامل لم تدخل ضمن عملية بناء النماذج بإمكانية التنبؤ بدرجة حرارة التربة على أعماق مختلفة باستخدام بيانات الإدخال (T,D,Av,S,R) ودرجات حرارة التربة للأعماق (100,50,30,20,10,5) سم كإخراج ، كما بينت النتائج ان استعمال درجة حرارة الهواء، الإشعاع ، الطاقة الشمسية او اليوم لوحده غير كافي لإعطاء تنبؤات صحيحة وان نسبة الخطأ فيها كبير جدا ، لكن عند بناء نماذج يؤثر بها أكثرمن عامل كما في النماذج (M5–M1) أعطت نتائج تنبؤية صحيحة كانت دقتها متفاوتة من نموذج إلى أخر يوضحها الجدول (3) والجدول (4) الذي بين فيها مقارنة مابين بيانات درجات الحرارة الحقلية المقاسة عند الساعة (15,12,9) للترب المزروعة والترب الغير مزروعة والمحسوبة من استخدام نماذج الاختبار لاختيار أفضل نموذج منها . لوحظ من النتائج ان معامل التحديد للنموذج M1 تراوح بين (0.89-0.91) وجذر متوسط مربع الأخطاء تراوح بين (0.968-3.126) للترب المزروعة وغير المزروعة، أما عند تغير خوارزمية التدريب في النموذج M2 ازداد معامل التحديد بحيث وصل الى 0.92 وانخفض معه متوسط مربع الأخطاء الى 0.934 للترب المزروعة وغير المزروعة ، وبنفس الوقت حصلت زيادة في معامل التحديد للنماذج (M5,M4,M3) بالتتابع وصلت الى 0.98 في النموذج M5 وكذلك انخفاض ملحوظ لمتوسط مربع الخطا حيث وصلت الى0.5 في النموذج M5 . يلاحظ من النتائج ان خوارزمية التدريب لها تاثير واضح على دقة النتائج فمع بقاء عدد الخلايا الخفية بعدد10 لكل نموذج من نماذج التدريب كانت قيم معامل التحديد تتراوح بين 0.89عند النموذج M1 الذي استخدم خوارزميةGD و0.98 في النموذج M5 الذي استخدم خوارزمية LM،أي ان خوارزمية LMفي شبكة الانتشار العكسي أعطت أدق النتائج، ولوحظ أيضا ان الخوارزمية لها تأثير واضح في سرعة الحصول على النتائج فقد كانت خوارزمية GD أبطأ خوارزمية حيث وصلت عدد الدورات التدريبية فيها الى39 دورة يوضحها الجدول (2)

، لكن عند استخدام خوارزمية GDM وبقيمة تعجيل فرضت 0.5 قلت سرعة التدريب ووصلت الى 29 دورة تدريبية ، اما عند استخدام خوارزمية CGF وصلت عدد الدورات التدريبية الى 22 دورة وذلك بسبب طبيعة الخوارزمية التي تبدأ بالبحث عن الهبوط الحاد للميل من التكرار الأول للخوارزمية والذي يسرع التدريب، في حين كانت عدد الدورات التدريبية لخوارزمية نيوتن BFGS 19 دورة تدريبية فعلى الرغم من الحسابات الواسعة لمصفوفة Hessian الا انه كان هناك سرعة في التدريب ، أما خوارزمية LM كانت أسرع خوارزمية تدريبية فقد استغرقت عملية التدريب فيها 12 دورة تدريبية هذه السرعة جاءت من خلال دخول مصفوفة Jacobian في حساب الأوزان التي هي اقل كلفة من مصفوفة Hessian والتي تسرع التدريب. كذلك بينت النتائج أن هناك تفاوت في الوقت لتدريب كل خوارزمية حيث وجدان النموذج M1 هو أبطأ نموذج الذي استغرق 39Ms في عملية التدريب في حين كانت أسرع خوارزمية تدريب في النموذج M5 التي وصلت الى 27Ms التي يوضحها الشكل(3) . ولغرض قياس كفاءة النماذج واختيار أفضل نموذج تنبؤي لدرجات حرارة أعماق التربة تم تطبيق نماذج بنفس الإدخالات السابقة وإخراج واحد(عمق معين) لأي خوارزمية من الخوارزميات الخمسة أي بواقع (6) نماذج لكل خوارزمية من M6 الى M10 التي يوضحها الجدول (2) ، حيث لوحظ زيادة في دقة النتائج فقد تراوحت قيمة معامل التحديد بين (0.92-0.99) وانخفاض قيمة متوسط مربع الخطأ الذي تراوح بين (0.011-2.65) وكما موضح في الجدول (3) والجدول(4) . كذلك انخفضت سرعة التدريب لكل نموذج يوضحها الشكل(4) حيث يلاحظ فيها انخفاض وقت التدريب لكل خوارزمية ولجميع الأعماق مع بقاء عدد الخلايا الخفية لكل النماذج مساوي (10) ، كما لوحظ ان **مجموع أوقات التدريب** لأي نموذج من النماذج (M10−M6) اقل من وقت التدريب لنفس الخوارزمية في النماذج (M5−M1) الموضحة في الشكل (5) . ولوحظ أيضا ان دقة النتائج تزداد مع زيادة عمق التربة تبين ذلك من خلال الزيادة الملحوظة في قيم معامل التحديد وفي كلا نوعيتي الترب ، أي ان النتائج كانت دقيقة عند العمق (5) سم وازدادت مع زيادة العمق بحيث وصلت الى دقة عالية عند العمق (100) سم ، أي ان العمق (100) سم كانت قياساته المتوقعة ذات دقة عالية مع القياسات الحقلية ولكل النماذج ، كذلك بينت النتائج ان النموذج M5 بخوارزمية LM هو أفضل نموذج تنبؤي لدرجة حرارة أعماق مختلفة من الترب اليومية المزروعة وغير المزروعة ، وكذلك النماذج M10 بخوارزميةLM هي أفضل وأسرع نماذج تنبؤية لدرجة حرارة أي عمق من اعماق الترب اليومية المزروعة وغير المزروعة أذاما توفر عامل الزمن ودرجة حرارة الهواء والاشعاع الشمسي وعدد ساعات السطوع .

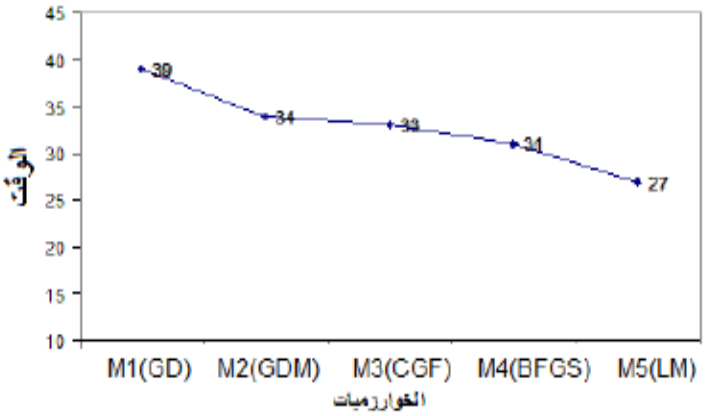

الشكل (3) وقت التدريب لخوارزميات التدريب في النماذج (M5−M1)

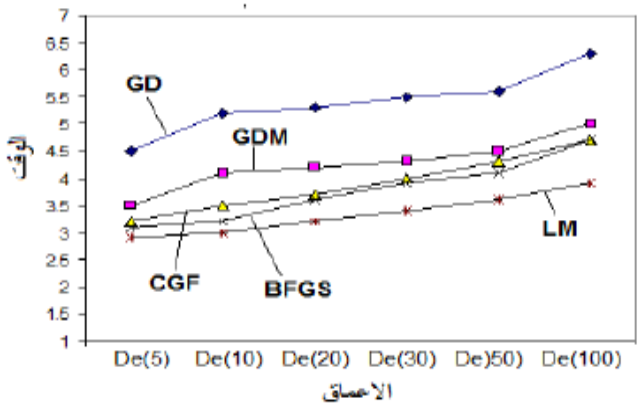

الشكل (4) وقت التدريب لخوارزميات التدريب بعمق معين

جدول رقم (3):اداء النماذج للاراضي المزروعة

الاعمـاق/الاراضي المزروعة							
100	50	30	20	10	5	النموذج	
0.91	0.91	0.90	0.898	0.897	0.894	**M1**	معامل التحديد
0.92	0.915	0.91	0.908	0.904	0.90	**M2**	
0.927	0.92	0.917	0.915	0.906	0.903	**M3**	
0.94	0.935	0.93	0.927	0.924	0.92	**M4**	
0.98	**0.976**	**0.967**	**0.96**	**0.957**	**0.95**	**M5**	
0.945	0.94	0.937	0.934	0.925	0.921	**M6**	
0.946	0.945	0.94	0.936	0.927	0.925	**M7**	
0.962	0.956	0.953	0.946	0.937	0.93	**M8**	
0.978	0.97	0.964	0.961	0.956	0.952	**M9**	
0.99	**0.99**	**0.99**	**0.99**	**0.987**	**0.98**	**M10**	
0.968	1.129	1.237	2.357	2.438	3.126	**M1**	جذر متوسط مربع الاخطاء
0.934	1.123	1.235	2.355	2.437	3.124	**M2**	
0.965	1.122	1.232	2.351	2.435	3.12	**M3**	
0.954	1.106	1.219	2.32	2.432	3.1	**M4**	
0.56	**1.23**	**1.54**	**1.87**	**2.09**	**2.21**	**M5**	
0.920	1.103	1.234	2.125	2.412	3.12	**M6**	
0.911	1.101	1.121	2.131	2.368	3.101	**M7**	
0.820	1.098	1.401	1.860	1.988	2.114	**M8**	
0.56	0.678	0.950	1.105	1.230	1.562	**M9**	
0.011	**0.013**	**0.024**	**0.025**	**0.037**	**0.076**	**M10**	

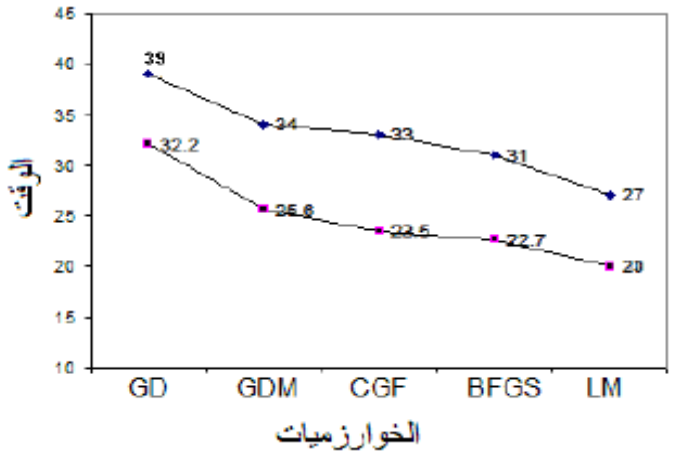

الشكل (5) مقارنة سرعة التدريب للخوارزميات

جدول (4):اداء النماذج للاراضي الغير المزروعة

		الاعمـاق/الاراضي المزروعة					
	النموذج	5	10	20	30	50	100
معامل التحديد	M1	0.897	0.899	0.899	0.907	0.937	0.938
	M2	0.906	0.907	0.91	0.915	0.918	0.92
	M3	0.907	0.91	0.917	0.919	0.924	0.929
	M4	0.921	0.926	0.929	0.935	0.938	0.943
	M5	0.952	0.96	0.966	0.969	0.978	0.984
	M6	0.927	0.928	0.937	0.94	0.944	0.947
	M7	0.926	0.929	0.937	0.945	0.946	0.949
	M8	0.933	0.937	0.948	0.955	0.957	0.964
	M9	0.956	0.957	0.964	0.967	0.972	0.98
	M10	0.984	0.99	0.99	0.99	0.99	0.99
جذر متوسط مربع الاخطاء	M1	3.111	2.421	2.33	1.212	1.112	0.933
	M2	3.119	2.422	2.335	1.222	1.119	0.935
	M3	3.11	2.411	2.344	1.223	1.116	0.954
	M4	3.011	2.411	2.17	1.20	1.101	0.932
	M5	2.07	2.01	1.56	1.44	1.17	0.46
	M6	2.650	2.321	2.104	1.221	1.098	0.912
	M7	3.098	2.231	2.101	1.112	1.079	0.890
	M8	2.106	1.976	1.832	1.367	1.088	0.760
	M9	1.302	1.198	1.098	0.896	0.620	0.51
	M10	0.067	0.034	0.021	0.017	0.014	0.012

الاستنتاجات

الشبكات العصبية الاصطناعية اثبتت نجاحها في عملية بناء نموذج تنبؤي لدرجة حرارة أعماق مختلفة للتربة اليومية باستخدام درجة حرارة الهواء ، الاشعاع والطاقة الشمسية لأي يوم من ايام السنة وباي وقت من اوقات القياس المستخدمة .اعطت النتائج تنبؤات ذات دقة عالية لدرجة حرارة اعماق التربة اليومية وصلت قيمة معامل التحديد فيها الى0.99 ، جاءت هذه الدقة من القراءات الحقيقة للبيانات والتي استخدمت في عملية التدريب والاختبار، وهذه الدقة تكون مقبولة كبديل عن القياسات الحقلية المكلفة في الوقت والجهد والكلفة المادية سواء ان كانت في الترب المزروعة وغير المزروعة بقيم تزيد او تقل عن درجة او درجتين لقيم درجات الحرارة المقدرة عن درجات الحرارة المقاسة ، ولوحظ من خلال المقارنة بين نماذج الشبكات الاصطناعية وخوارزمياتها ان جميعها يمكن استخدامها لاغراض تنبؤية تعتمد على طبيعة البيانات ، وان شبكة الانتشار العكسي للخطا بخوارزمية LM تعطي افضل واسرع نموذج يمكن اعتماده للتنبؤ بدرجات حرارة اعماق التربة اذا ماتوفر عامل الزمن ودرجة حرارة الهواء والاشعاع الشمسي وعدد ساعات السطوع لاي يوم من ايام السنة .

المصادر

[1] Kalogirou S.A.,"Artificial intelligence for the modeling and control of combustion processes: a review". Progress in Energy and Combustion Science 29:515–566, 2003 .

[2] Kamwa I., R. Grondin, V. K. Sood, C. Gagnon, V. T. Nguyen, J. Mereb,. Recurrent neural networks for phasor detection and adaptive identification In power system control and protection. IEEE Transactions on Instrumentation and Measurement 45:657–664, 1996.

[3] Markridakis S. e., "The accuracy of extrapolation (time series) methods:Results of a forecasting competition. Journal of Forecasting",1982 .

[4] Racine J. S.,. "On The Nonlinear Predictability of Stock Returns Using Financial and Economic Variables, forthcoming. Journal of Business and Economic Statistics 19 : 380-382 , 2001.

[5.] De Jesús O., M.T. Hagan, "Backpropagation through Time for a General Class of Recurrent Network". Proceedings of the International Joint Conference on Neural Networks, Washington, DC, July 15–19, 2638–2642 , 2001.

[6.] De Jesús O., M.T. Hagan.," Forward Perturbation Algorithm for a General Class of Recurrent Network. Proceedings of the International Joint Conference on Neural Networks, Washington, DC, vol.4, pp.2626–2631, July 15–19 ,2001.

[7]Gianluca P.,D. Przybylski, B. Rost, P. Baldi,,"Improving the prediction of protein secondary structure in three and eight classes using recurrent neural networks and profiles. Proteins: Structure". Function, and Genetics 47:228–235, 2002.

[8]Karayiannis N.B., A.N. Venetsanopoulos," Artificial Neural Networks:Learning Algorithms. Performance Evaluation and Applications". Kluwer

Academic Publishers, Boston, USA.1993.
[9] Medsker L.R., L.C. Jain,."Recurrent neural networks: design and applications". Boca Raton, FL: CRC Press, 2000.
[10.]Hann T. H., E. Steurer,"Much ado about nothing? Exchange rate forecasting: Neuraln networks vs. linear models using monthly and weekly data". Neurocomputing 10 : 323–339, 1996.
[11] Wu B.," Model - free forecasting for non-linear time series (with application to exchange rates). Computational Statistics and Data Analysis 19 :433–459 , 1995.
[12] Zhang G., M.Y. Hu,. "Neural Network Forecasting of the British Pound/US Dollar Exchange Rate . International Journal of Management Science 26 :495–506 , 1998.
[13] George W . Snedecor and William G. Cochran."Statistical Method" The owa State University press Ames, Iowa, U.S.A, 1974 .
[14] Mihalakakou G.," On Estimating Soil Surface Temperature Profiles"Energy and Building, vol.34,Issue 3,pp:251-259 ,March 2002 .
[15] Mehmet B. G. , "The use of artificial neural networks for forecasting the monthly mean soil temperatures in Adana, Turkey,Jan ,18,2010.
[16] Yang , C.-C., Prasher, S. O. and Mehuys, G. R.,"An artificial neural network to estimate soil temperature", Can. J. Soil Science,vol.77: 421–429,1997.
[17] Haoffi Z., X. Guoping, Y. Fagting, Y. Han, A . "Neural Network Model Based on the Multi-Stage Optimization Approach for Short-Term Food Price Forecasting in China. Expert Systems with Applications,347- 356,2007.
[18] Chengyu G., K. Danai," Fault diagnosis of the IFAC Benchmark Problem with a model based recurrent neural network. Proceedings of the,IEEE International Conference on Control Applications ,1755–1760, 1999.
[19] Jayadeva, S. A. Rahman. ." A neural network with O(N) neurons for ranking N numbers in O(1/N) time". IEEE Transactions on Circuits and Systems I:Regular Papers 51: 2044–2051,2004.
[20] Rosenblatt F.," Principles of Neurodynamics". Washington, D.C.: Spartan Press,1961.
[21] Sarle W.S .,"Neural network FAQ" . Retrieved 11 February2003 , from ftp://ftp.sas.com/pub/neural /FAQ.html .
[22]Feng J., C.K. Tse, F.C.M. Lau.," A neural-network-based channel - equalization strategy for chaos-based communication systems". IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications 50,954–957, 2003.
[23] D. E. Rumelhart, G. E. Hinton, R. J. Williams, "Learning internal representations by error propagation. In D. E. Rumelhart, & J. L. McClelland (Eds.), Parallel distributed processing pp. 318–362. Cambridge, MA: MIT Press, 1986.
[24] Elminir H. K., Y.A. Azzam, and F. I. Younes,. "Prediction of Hourly and Daily Diffuse Fraction Using Neural Network as Compared to Linear Regression Models," Energy, vol.32, pp.1513-1523, 2007.
[25] Y. Wang, S. Kim, J. C. Principe, "Comparison of TDNN Training Algorithms in Brain Machine Interfaces", International Joint Conference on Neural Networks , IJCNN 2005.
[26] R. Zayani, R. Bouallegue, "A neural Network Pre-distorter for the compensation of HPA non - linearity", International Journal of Coputer Science and Network Security, IJCSNS March 2007.
[27] E. Castillo, B. Berdinas, O. Romero and A. Betanzos, "A Very Fast Learning Method for Neural Networks Based on Sensitivity Analysis", Journal of Machine Learning Research 7 ,1159–1182,2006.
[28] Udo Seiffert, "Training of Large-Scale Feed-Forward Neural Networks",International Joint Conference on Neural Networks, IJCNN 2006.
[29] Lapedes A., R. Farber," Nonlinear signal processing using neural networks:Prediction and system modeling". Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM. 1987.
[30]Robinson A.J.,"An application of recurrent nets to phone probability estimation". IEEE Transactions on Neural Networks 5:298-305, 1994.
[31] Roman J.,A. Jameel, Backpropagation and recurrent neural networks in financial analysis of multiple stock market returns. Proceedings of the Twenty-Ninth Hawaii International Conference on System Sciences 2 :454–460.
[32] M. Hayati and Z. Mohebi, "Application of Artificial Neural Networks for Temperature Forecasting," International Journal of Engineering and Applied Sciences, vol.4, no.3, pp.164-168, 2007.

Using the ANN different algorithms in modeling soil temperature on different depths in terms of some climatic information

Omaya Ghanim Abd _Jabbar
Computer systems dept., Technical institute , Mosul , Iraq
omayaghanim@yahoo.com

(Received: 24/11 / 2012 ---- Accepted: 22/4/ 2013)

Abstract

In this research, the neural network model was applied to estimate the soil temperatures on various depths and with different times periods in terms of Air_temperature, sunshine and radiation for a given day of the year using the BackPropagation Network (BPN). Different algorithms were used including; Gradient Descent algorithm (GD) , Gradient Descent with Momentum algorithm (GDM) , Conjugate Gradient algorithm (CFG) , Quasi-Newton algorithm (BFGS) and Levenberg-Marquardt algorithm (LM) . Data was obtained from the soil and water research department / Nineveh province for the period from 1980 –1983 was used, and date included daily soil temperature on depths of (5, 10, 20, 30, 50 and 100) CM and for three time periods at (9, 12, and 15 hours) for cultivated and uncultivated soils. The data of two years was used to develop the models and the data of 1983 was used to evaluate the models and comparing the outputs with the data measured. Also, the R^2 scales and the root of mean square error (RMSE) were used in determining the match of the measured data and the neural network outputs to select the best predictive model out of the applied models. Results showed that the (LM) algorithm proves to be highly efficiency in improving a good predictive model for temperature of various depths of soil. In addition, this algorithm is also considered the best and fastest algorithm for constructing such models for any daily cultivated and uncultivated soil at different depths if Air temperature , sunshine and radiation are available at the three measuring periods for any day of the year .

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