

## Modeling Soil Temperature at different depths and times as a function of some climatic data Using Artificial Neural Network

### نمذجة درجات حرارة التربة على اعماق واوقات مختلفة بدلالة بعض المعلومات المناخية باستخدام الشبكات العصبية الاصطناعية

1م. د. عصام محمود محمد م.م. شهلة عبدالوهاب عبدالقادر م.م. نجم عبدالله عبدالقادر

هيئة التعليم التقني

1 الكلية التقنية الزراعية / الموصل

2، 3 المعهد التقني / الموصل

#### الملخص:

تم في هذا البحث تطبيق نموذج الشبكة العصبية لتخمين درجات حرارة التربة على اعماق مختلفة وباوقات قياس مختلفة بدلالة درجة حرارة الهواء وعدد ساعات السطوع والاشعاع الشمسي لاي يوم من السنة باستخدام شبكة الانتشار العكسي، وشبكة الملاءمة ذات خوارزمية الانتشار العكسي للخطا. تم استخدام البيانات الماخوذة من دائرة بحوث التربة والمياه/ محافظة نينوى للفترة من 1980 - 1983 وهي تشمل درجات حرارة التربة اليومية على اعماق 5،10،20،30،50،100 سم ولثلاث فترات عند الساعة 9، 12، 15 لترب مزروعة وغير مزروعة. استخدمت بيانات عامين لتطوير النماذج، واستخدمت بيانات عام واحد (1983) لتقييم النماذج ومقارنة مخرجاتها مع البيانات المقاسة، استخدمت مقاييس معامل التحديد  $R^2$ ، جذر متوسط مربع الاخطاء RMSE في الحكم على مدى تطابق البيانات المقاسة ومخرجات الشبكات العصبية لاختيار افضل نموذج تنبوي من بين النماذج المطبقة، حيث تراوحت قيم معامل التحديد بين 0.86 - 0.97 وظهرت قيم جذر مربع الاخطاء انخفاضاً ملحوظاً لجميع نماذج التخمين. اظهرت النتائج امكانية استخدام الشبكات العصبية في تكوين نموذج يتم استخدامه في تخمين درجات حرارة اعماق التربة عن طريق استخدام درجات حرارة الهواء وعدد ساعات السطوع والاشعاع الشمسي ولازمته القياس الثلاثة. امكانية تكوين نماذج شبكات عصبية صناعية ثنائية البعد تعطي تنبؤات ذات دقة عالية لدرجة حرارة اعماق التربة اليومية، مع امكانية اضافة بعد الزمن وبعد عمق التربة.

**الكلمات المفتاحية:** الشبكات العصبية، خوارزمية الانتشار العكسي للخطا، شبكة الانتشار العكسي، شبكة الملاءمة.

#### Abstract:

In this study, implementation of artificial neural network model has been used to estimate soil temperatures at various depths and different measuring times, as a function of mean air temperature, number of sunshine hours, radiation, for any day of the year. ANN (artificial neural network) of back propagation and fitness algorithms models. The data of soil temperature is taken from research department of soil and water / Nineveh province for the period from 1980 to 1983 and it include daily measurements of soil at depths of 5, 10, 20, 30, 50 and 100 cm and for three periods at 9, 12 and 15 clock for cultivated and bare soil. The data of two years was used to learn the network and the data of one year was used to test the network and compare its output with the measured data, three performance functions, namely root mean square errors (RMSE) and determination coefficient ( $R^2$ ), were used to evaluate the neural model, to find the adequacy between estimated data and the outputs of neural network for one year, the values of  $R^2$  ranging between 0.95 - 0.99 and the values of RMSE decreased significantly for all cases of estimation. The results shows the possibility of using neural networks in the composition of the model that can be used in the estimation of deep soil temperatures through the use of surface soil temperature for three times of measurement, the successful use of neural networks in the composition of the model that can be used to estimate the deep soil temperatures through the use of soil-surface temperatures, which are measured at different time periods. Successful construction of General ANN model that predict soil temperature at any depth and time from soil surface temperature of any time have been made. The ability of constructing ANN of two dimension could estimate soil temperature with very high accuracy by adding time dimension and soil depth dimension.

Key words: ANN, modeling, soil temperature, back propagation, RMSE, matlab

## المقدمة :

في الأنظمة البيئية الزراعية والتربة يمكن لدرجة حرارة التربة ان تؤثر على نمو النباتات والكائنات الحية ، وحركة محلول التربة الذي يحتوي على العناصر الغذائية ، وغيرها من الظواهر الطبيعية . ولذلك فان عملية المحاكاة لدرجة حرارة التربة أمر أساسي لدعم العديد من النماذج الزراعية .

في العقود القليلة الأخيرة طورت العديد من نماذج التنبؤ اللاخطية [17] مثل الذكاء الاصطناعي ، الذي يمكن ان يلائم البيانات وبشكل أفضل من النماذج الخطية التي غالبا ما يكون التنبؤ بها ضعيف [19] . انظمة الذكاء الاصطناعي ذات تقنيات واسعة وتوفر طرق بديلة لمعالجة المشاكل المعقدة [13] ، وهو قادر على معالجة البيانات الغير متكاملة والتي تحتوي على ضوضاء وكذلك حل المشاكل اللاخطية التنبؤية بسرعة عالية [14]. استعملت هذه التقنيات في تطبيقات متنوعة مثل الانسان الالي ، تمييز الانماط ، التنبؤ ، الطب ، الانظمة الكهربائية ، التصنيع ، الامثلية ، معالجة الاشارة ، وعلوم اجتماعية ونفسية. انظمة الذكاء الاصطناعي تشمل الأنظمة الخبيرة، الشبكات العصبية الاصطناعية، الخوارزميات الجينية، المنطق المصنوب ، وانظمة هجينة اخرى تجمع بين واحد او اكثر من التقنيات اعلاه [14]. الشبكات العصبية الاصطناعية تعتبر من انظمة الذكاء الاصطناعي ، التي تعالج بيانات هائلة بشكل متوازي لتدريبها واكسابها معرفة ملائمة لغرض التطبيق، والفائدة الاكبر قدرة الشبكات العصبية على تشكيل العلاقات اللاخطية المعقدة بدون فرضيات استنتاجية عن طبيعة العلاقة [15].

الشبكات العصبية طبقت في المتواليات التسلسلية التنبؤية حيث كان هناك عدة عروض مختلفة على سبيل المثال اجرى الباحثين [10] [25] [26] دراسات من حيث مقارنة بين الشبكات العصبية والطرق التنبؤية التقليدية اثبتت تجاربهم ان الشبكات العصبية تعطي نتائج تنبؤية افضل من تلك التي تعطيها الطرق التقليدية. دراسات كثيرة اجريت في مجال تنبؤ درجات حرارة التربة اليومية حيث عمل الباحث [2] على تخمين درجة حرارة سطح التربة باستعمال درجة حرارة الهواء. اما الباحث [4] عمل في بحثه على بناء شبكة عصبية ذات انتشار امامي لتخمين درجة حرارة عمق معين لشهر معين باستعمال درجة حرارة الهواء ودرجة حرارة العمق لشهر سابق. في حين قام الباحثين [8] ببناء نموذج لتنبؤ درجة حرارة اعماق التربة اليومية باستعمال عامل المطر والتبخر اليومي لاي يوم من ايام السنة .

تهدف الدراسة الى:

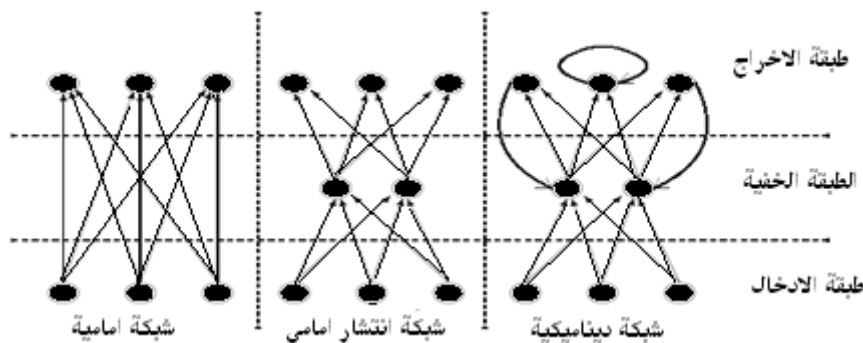
1. بناء نموذج لشبكة عصبية كفو لتخمين درجات حرارة التربة على اعماق مختلفة باستخدام المعلومات المناخية سهلة القياس.
2. بناء نموذج لشبكة عصبية كفو لتخمين درجات حرارة التربة على اعماق مختلفة ولاي زمن تقدير باستخدام المعلومات المناخية سهلة القياس وازمنة القياس.
3. بناء نموذج لشبكة عصبية كفو لتخمين درجات حرارة التربة لاي عمق ولاي زمن تقدير باستخدام المعلومات المناخية سهلة القياس وازمنة القياس واعماقها.

## الاساس النظري: 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 [11]. قادت هذه النظرة الى صياغة العديد من البحوث التجريبية وبناء النماذج لمعالجة البيانات بطرق ملائمة . والانواع الاكثر شيوعا من نماذج الشبكات العصبية نراها في الشكل رقم (1) .

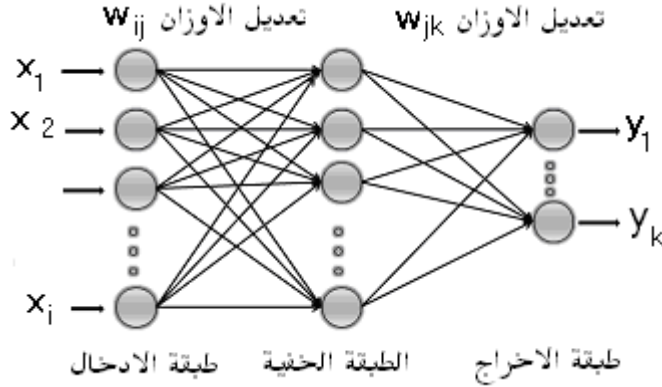
### الشبكات العصبية ذات التغذية الامامية

الشبكات العصبية ذات التغذية الامامية هي نوع من الشبكات لاحتوي على روابط رجوع بصورة عكسية ولاحتوي 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، شبكة الملاعبة Fitnet .



الشكل رقم (1) الشبكات العصبية الاصطناعية الاكثر شيوعا

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 [24].  
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 الادخالات الموزونة مع انحيازاتها bias (b)، بعدها تطبق دالة التنشيط (f) activation function. الخلايا العصبية يمكن ان تستعمل انواع من دوال التنشيط لتوليد الاخراج وبشكل عام دوال التنشيط اللاخطية تعتبر ملائمة ومثالية لاكثر التطبيقات، والشبكات ذات التغذية الامامية والتي تمتلك طبقة ( طبقات ) خفية في اغلب الاحيان تكون طبقاتها الخفية بدالة السيكمويد (sigmoid activation function)، وطبقة الاخراج بدالة خطية (purline activation function).



الشكل رقم (2) نموذج مثالي لشبكة الانتشار العكسي

شبكة الانتشار العكسي تمر بمرحلتان : 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 الحقيقية بانحدار تدريجي للاخطاء gradient descent او ماتسمى نشر الاخطاء العكسي [23]. الاخراج  $Y_k$  يقارن مع الاخراج الحقيقي حسب معادلة الخطا لطبقة الاخراج (1) [28] :

$$\delta_k = (T_k - y_k) y_k (1 - y_k) \quad \dots \dots (1)$$

حيث ان  $y$  هي اخراج الشبكة،  $T$  هو الاخراج الحقيقي ، كذلك يحسب الخطا العكسي للطبقة الخفية حسب المعادلة (2)

$$\delta_k = y_k (1 - y_k) \sum \delta_k w_k \quad \dots \dots (2)$$

حيث ان  $\delta_k$  هو معدل الخطا بين طبقة الاخراج والطبقة الخفية ، في حين تعدل اوزان الشبكة في كل مرحلة من خلال المعادلة (3)

$$w_{jk}(t+1) = w_{jk}(t) + \eta \delta_k y_k + \alpha (w_{jk}(t) - w_{jk}(t-1)) \quad \dots \dots (3)$$

$\eta$  : هي معامل التدريب [28].

شبكة الملازمة شبكة ذات تغذية امامية وذات خوارزمية انتشار خلفي ثلاثم البيانات المحددة (ادخال-اخراج) أي تعطي اخراج مطابق الى درجة كبيرة للمخرجات الحقيقية [27].

### مواد البحث وطرائقه:

تم استخدام البيانات الماخوذة من دائرة بحوث التربة والمياه / محافظة نينوى للفترة من 1980 - 1983 وحسب الجدول رقم (1) وهي تشمل درجة حرارة الهواء ، الاشعاع عدد ساعات السطوح الشمسي، درجات الحرارة لاعماق التربة اليومية كانت على التوالي للاعماق 5 ، 10 ، 20 ، 30 ، 50 ، 100 سم واطقات مختلفة الساعة 9 ، 12 ، 15 لترب مزروعة وغير مزروعة. تم بناء عدة نماذج باستخدام الشبكات لتخمين درجة حرارة اعماق التربة اليومية بالاعتماد على درجة حرارة الهواء، عدد ساعات السطوح والاشعاع ، الوقت وتسلسل اليوم من السنة. وبنيت مدخلات ومخرجات هذه النماذج كما موضح في الجدول (2). البيانات قسمت بصورة عشوائية الى مجموعتين ، مجموعة التدريب وكانت بنسبة 70% من البيانات. ومجموعة الاختبار كانت بنسبة 30 % من البيانات. ولقياس اداء الشبكات واختبار افضل شبكة تنبؤية تم استخدام معامل التحديد  $R^2$  ، جذر متوسط مربع الاخطاء RMSE [1].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - T_i)^2}{n}} \quad \dots\dots \quad (4)$$

واستخدمت هذه المعايير في مقارنة البيانات الحقيقية المقاسة والمحسوبة من نماذج الشبكة العصبية لسنة كاملة بدأ من 1-1-1983 ولغاية 31-12-1983 وذلك لضمان انطباق النماذج لجميع المراحل السنوية وظروفها، علما بان هذه البيانات لم تدخل في عملية بناء نماذج الشبكات العصبية. لتحديد نموذج الشبكة العصبية الاصطناعية الذي يعطي تنبؤ جيد لدرجة حرارة اعماق التربة اليومية، تم تصميم النماذج باستخدام MATLAB 2010b، وكانت هذه النماذج تمثل شبكة Artificial Neural Network ذات الانتشار الامامي feedforwardnet من نوع الشبكة الملاءمة Best Fitt net.

جدول رقم (1) البيانات الحقيقية المستخدمة في بناء نماذج الشبكات العصبية

البيانات الحقيقية	
T	اوقات القياس في الساعة (9، 12، 15)
D	تسلسل ايام السنة Day
Av	درجة حرارة الهواء Air temperature
S	عدد ساعات السطوع الشمسي Sunshine
R	الاشعاع الشمسي Radiation
Depth	عمق التربة سم
De	درجة حرارة العمق 5
	درجة حرارة العمق 10
	درجة حرارة العمق 20
	درجة حرارة العمق 30
	درجة حرارة العمق 50
	درجة حرارة العمق 100

جدول (2) يبين نماذج شبكات الادخال والاخراج وعدد الطبقات للترب المزروعة وغير المزروعة

النموذج	الادخال	الاخراج	عدد الخلايا في الطبقة الخفية	عدد لدورات التدريبية
M1(feedforward)	D, Av	De <sub>(5,10,20,30,50,100)</sub>	25	35
M2(feedforward)	D, Av, S	De <sub>(5,10,20,30,50,100)</sub>	25	39
M3(feedforward)	D, Av, S, R	De <sub>(5,10,20,30,50,100)</sub>	20	15
M4(fitnet)	D, Av	De <sub>(5,10,20,30,50,100)</sub>	25	34
M5(fitnet)	D, Av, S	De <sub>(5,10,20,30,50,100)</sub>	25	20
M6(fitnet)	D, Av, S, R	De <sub>(5,10,20,30,50,100)</sub>	25	20
M7( feedforward)	T, D, Av, S, R	De <sub>(5,10,20,30,50,100)</sub>	25	18
M8( fitnet)	T, D, Av, S, R	De <sub>(5,10,20,30,50,100)</sub>	25	14
M9(fitnet)	T, D, Depth, Av, S, R	De <sub>(5,10,20,30,50,100)</sub>	25	150

### النتائج والمناقشة:

تشير النتائج التي تم الحصول عليها من تطبيق نماذج الشبكات العصبية على بيانات عام كامل لم تدخل ضمن عملية بناء النموذج بإمكانية التنبؤ بحرارة التربة على اعماق مختلفة باستخدام بيانات الادخال (تسلسل ايام السنة ، معدل درجة حرارة الهواء ، عدد ساعات السطوع الشمسي، الاشعاع الشمسي ) ودرجات حرارة التربة للاعماق 30،50،100،5،10،20 سم ، الجدول(3) يبين مقاييس المقارنة ما بين بيانات درجات الحرارة التربة الحقلية المقاسة عند الساعة التاسعة والساعة الثانية عشر والخامسة عشر والمحسوبة من استخدام النماذج M1 ولغاية M6. فقد اعطى النموذج M1 قيم لمعامل التحديد R<sup>2</sup> تراوحت ما بين 0.82 - 0.86 وقيم RMSE من 1.2 ولغاية 4.8 في الترب المزروعة وذلك في حالة ادخال تسلسل اليوم ومعدل درجة حرارة الهواء ، وعند اضافة عامل عدد ساعات السطوع الشمسي مع النموذج M2 ارتفعت قيم R<sup>2</sup> وانخفضت معها قيم RMSE ، وتم الحصول

على نفس الاتجاه مع ادخال عامل الاشعاع الشمسي ، فقد حصلت ايضا زيادة في قيم  $R^2$  حيث وصلت الى قيمة 0.89 ، وهذا ماتم الحصول مع استخدام خوارزمية **feedforward**. اما عند استخدام خوارزمية **fitnet** فقد ارتفعت درجة دقة نماذج الشبكات التي تم الحصول عليها (M4, M5, M6) والتي استخدمت نفس معلمات الادخال للنماذج (M1, M2, M3). كما لوحظ ايضا زيادة دقة التقدير للنماذج مع زيادة عمق التربة حيث كانت قيم  $R^2$  ترتفع مع العمق لنفس النموذج. من الجدول رقم 4 يتضح ايضا بان النتائج كانت متطابقة بشكل كبير في حالة الترب غير المزروعة. وعلى ذلك نستطيع القول بشكل عام بانه يمكن تقدير درجة حرارة التربة لاي عمق مطلوب من معرفة تسلسل اليوم من ايام السنة ودرجة حرارة الهواء او/و عدد ساعات السطوع او/و درجة الاشعاع الشمسي بدقة تقدير تتراوح من 85% ولغاية 97% ، وهذه الدقة مقبولة كبديل عن القياسات الحقلية المكلفة في الوقت والجهد والكلفة المادية، سواء ان كانت الترب مزروعة او غير مزروعة بقيم تزيد او تقل عن درجة او درجتين لقيم درجات الحرارة المقدره عن درجات الحرارة المقاسة وهذه النتائج تتفق مع ما وجدته [8] و[4].

من الجدول (5) يتبين بان ادخال عامل زمن القياس T الساعة (9، 12، 15) كعامل ادخال اضافة الى بقية عوامل بناء النموذج (تسلسل اليوم D، معدل درجة الحرارة  $A_v$ ، عدد ساعات السطوع الشمسي S، درجة الاشعاع الشمسي R)، سواء للترب المزروعة وغير المزروعة مع كلا الخوارزميتين **feedforward** و **fitnet**، نموذج (M7, M8) ، اعطى نتائج مطابقة بشكل كبير جدا ما بين النتائج المقاسة والمقدرة عن طريق هذه النماذج . وبذلك نستطيع ان نخمن درجة حرارة اعماق التربة (5،10،20،30،50،100) عند أي وقت من اوقات اليوم لاي يوم من ايام السنة بمعرفة البيانات المناخية لذلك اليوم. ويظهر من الجدول بان دقة التقدير لهذه النماذج تراوحت ما بين 94% للاعماق السطحية ولغاية 97% للاعماق 50 و100 سم ، وتعتبر هذه الدقة عليا جدا اذ ان نسبة الخطأ بالتقديرات الحقلية تكون مقبولة ضمن 5% . والشكل رقم 3 يؤكد هذا التطابق ما بين النتائج المقدره والمحسوبة في علاقة 1:1 لجميع مراحل التدريب والتطبيق وقيم  $R^2$  لكل منها لنموذج M8 .

لاجل صناعة نموذج يدعم تقدير حرارة التربة بالاتجاهين زمن وعمق التقدير (two dimension) ، وهذا ماتسعى اليه النماذج الرياضية لاجل دعم وتوسعة المدى الذي يعمل عليه النموذج وزيادة كفاءة التخمين، فقد تم صناعة نموذج M9 الذي يستخدم بيانات تسلسل اليوم D، معدل درجة الحرارة  $A_v$ ، عدد ساعات السطوع الشمسي S، درجة الاشعاع الشمسي R وعامل زمن التقدير كبعد زمني وعامل عمق التربة Depth كبعد ثاني. وقد جاءت النتائج مطابقة بدرجة ثقة عالية مع خوارزمية صناعة الشبكة التي تحكم هذا النموذج **fitnet** ووصلت دقة التقدير الى درجة 98% مع كلا حالتي التربة المزروعة وغير المزروعة ، وهذا التقارب ما بين النتائج المقاسة والمقدرة يظهر بوضوح في الشكل رقم 5 في العلاقة ما بين 1:1 وقيم عالية ومتقاربة لجميع مراحل بناء النموذج. واعطت قيم RMSE قليلة بالمقارنة مع النماذج السابقة ، اضافة للامكانية العالية في تطبيق النموذج باتجاهين زمن القياس وعمق التربة . لذا يقترح ان تتم مقارنة هذه النماذج مع نتاج النماذج الرياضية الحاسوبية التي تعنى بهذا الموضوع مثل HYDRUS2D و GEOSTUDIO .

جدول (3): اداء النماذج ( معامل التحديد وجذر متوسط مربع الاخطاء) للاراضي المزروعة

الاعماق/الاراضي المزروعة						الوقت	النموذج	المقاييس
100	50	30	20	10	5			
0.86	0.85	0.847	0.83	0.83	0.82	9	M1	معامل التحديد
0.86	0.86	0.856	0.84	0.84	0.824	12		
0.86	0.85	0.85	0.842	0.84	0.84	15		
0.87	0.86	0.85	0.85	0.84	0.83	9	M2	
0.87	0.86	0.86	0.86	0.85	0.84	12		
0.89	0.88	0.88	0.88	0.88	0.87	15		
0.90	0.89	0.89	0.89	0.87	0.87	9	M3	
0.90	0.90	0.88	0.88	0.88	0.88	12		
0.91	0.91	0.91	0.91	0.90	0.89	15		
0.95	0.92	0.91	0.88	0.87	0.86	9	M4	
0.98	0.96	0.96	0.94	0.94	0.94	12		
0.97	0.96	0.96	0.94	0.93	0.94	15		
0.96	0.93	0.95	0.94	0.93	0.91	9	M5	
0.95	0.96	0.95	0.94	0.94	0.94	12		
0.93	0.95	0.93	0.93	0.92	0.93	15		
0.96	0.95	0.96	0.95	0.94	0.94	9	M6	
0.97	0.96	0.95	0.95	0.94	0.94	12		
0.97	0.97	0.96	0.95	0.95	0.94	15		
2.10	2.43	2.57	2.9	2.8	2.89	9	M1	جذر متوسط مربع الاجزاء
1.98	2.00	2.32	2.45	2.77	2.78	12		
2.00	2.20	2.30	2.45	2.65	2.70	15		
1.56	2.55	2.96	3.77	3.84	4.89	9	M2	
1.10	1.7	2.20	2.66	2.76	2.88	12		
1.55	2.73	2.67	2.96	3.50	3.40	15		
1.40	1.98	2.34	2.50	2.30	2.40	9	M3	
1.65	1.90	2.0	2.21	2.63	2.54	12		
1.35	1.60	2.11	2.13	2.35	2.40	15		
1.26	2.37	2.86	3.43	3.70	4.83	9	M4	
0.93	1.63	2.05	2.54	2.61	2.75	12		
1.10	1.50	1.90	2.45	3.10	2.70	15		
1.24	2.17	2.15	2.50	2.72	3.00	9	M5	
1.41	1.77	2.15	2.50	2.70	2.61	12		
1.60	1.90	2.50	2.72	3.30	3.00	15		
1.32	2.1	2	2.3	2.5	2.5	9	M6	
1.03	1.63	2.1	2.37	2.63	2.63	12		
1.15	1.74	2	2.39	3.12	2.8	15		

جدول (4) : اداء النماذج ( معامل التحديد وجذر متوسط مربع الاخطاء) للاراضي الغير مزروعة

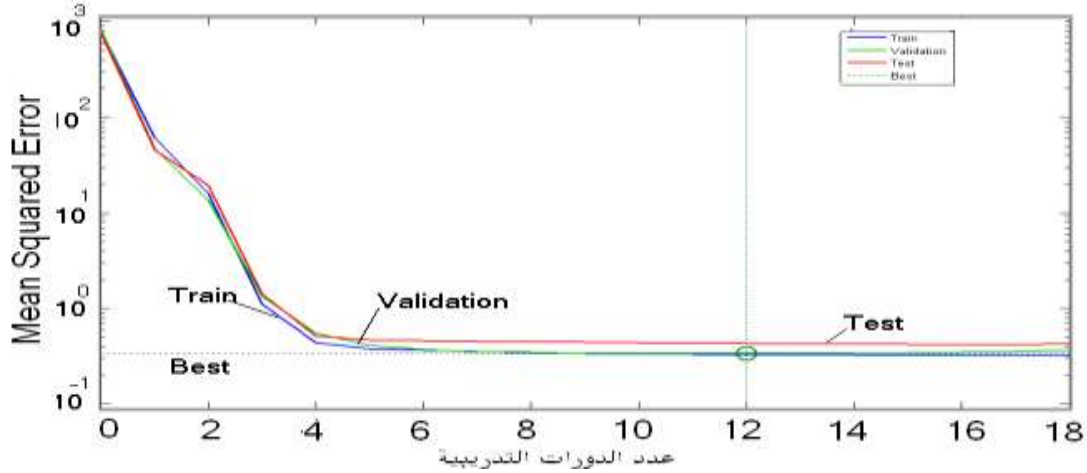
الاعماق/الاراضي الغير مزروعة						الوقت	النموذج	المقاييس
100	50	30	20	10	5			
0.87	0.86	0.85	0.837	0.83	0.83	9	M1	معامل التحديد
0.87	0.86	0.85	0.85	0.84	0.83	12		
0.86	0.86	0.85	0.85	0.85	0.85	15		
0.87	0.86	0.85	0.85	0.85	0.84	9	M2	
0.88	0.87	0.87	0.86	0.86	0.85	12		
0.90	0.89	0.89	0.88	0.88	0.87	15		
0.90	0.89	0.89	0.88	0.87	0.87	9	M3	
0.91	0.91	0.91	0.90	0.90	0.90	12		
0.92	0.91	0.91	0.91	0.91	0.90	15		
0.94	0.94	0.92	0.92	0.91	0.91	9	M4	
0.96	0.96	0.95	0.95	0.94	0.92	12		
0.97	0.96	0.96	0.96	0.96	0.94	15		
0.95	0.95	0.95	0.95	0.93	0.93	9	M5	
0.95	0.95	0.94	0.93	0.93	0.93	12		
0.96	0.96	0.95	0.95	0.95	0.94	15		
0.94	0.94	0.93	0.93	0.93	0.93	9	M6	
0.96	0.96	0.96	0.95	0.95	0.94	12		
0.97	0.97	0.96	0.96	0.95	0.95	15		
2.00	2.40	2.45	2.67	2.75	2.77	9	M1	جذر متوسط مربع الاخطاء
1.87	2.11	2.21	2.44	2.45	2.70	12		
1.87	2.19	2.24	2.51	2.52	2.50	15		
1.34	2.43	2.67	3.66	3.81	4.76	9	M2	
1.1	1.6	2.15	2.43	2.65	2.76	12		
1.23	2.65	2.54	2.76	3.23	3.21	15		
1.1	1.56	2.23	2.35	2.1	2.3	9	M3	
1.64	1.66	1.88	2.21	2.34	2.24	12		
1.32	1.20	2.17	2.1	2.22	2.30	15		
1.70	2.10	2.80	3.01	3.13	3.06	9	M4	
1.50	1.83	2.29	2.42	2.64	3.08	12		
1.21	1.92	1.92	2.14	2.34	2.90	15		
1.62	1.98	2.53	2.35	2.46	2.83	9	M5	
1.60	1.98	2.5	2.75	2.87	2.72	12		
1.30	2.30	2.30	2.50	2.60	3.02	15		
1.67	2.22	2.64	2.72	2.82	4.40	9	M6	
1.42	1.66	2.07	2.20	2.30	2.60	12		
2.07	2.23	2.23	2.46	2.66	2.08	15		

جدول (5) : اداء النماذج للاراضي المزروعة وغير المزروعة بوجود عامل الزمن كادخال اضافة للعوامل المناخية

الاعمق/الاراضي المزروعة							النموذج	المقاييس
100	50	30	20	10	5			
0.97	0.96	0.95	0.95	0.94	0.94	M7	معامل التحديد	
0.97	0.97	0.96	0.96	0.95	0.95	M8		
1.10	2.15	2.2	2.15	2.75	2.75	M7	جذر متوسط مربع الاخطاء	
1.12	1.30	2.00	2.3	2.30	2.60	M8		
الاعمق/الاراضي الغير مزروعة							النموذج	المقاييس
100	50	30	20	10	5			
0.97	0.96	0.95	0.95	0.95	0.94	M7	معامل التحديد	
0.97	0.97	0.97	0.96	0.96	0.95	M8		
1.50	2.11	2.10	2.72	2.72	2.73	M7	جذر متوسط مربع الاخطاء	
1.04	1.20	1.80	2.20	2.20	3.50	M8		

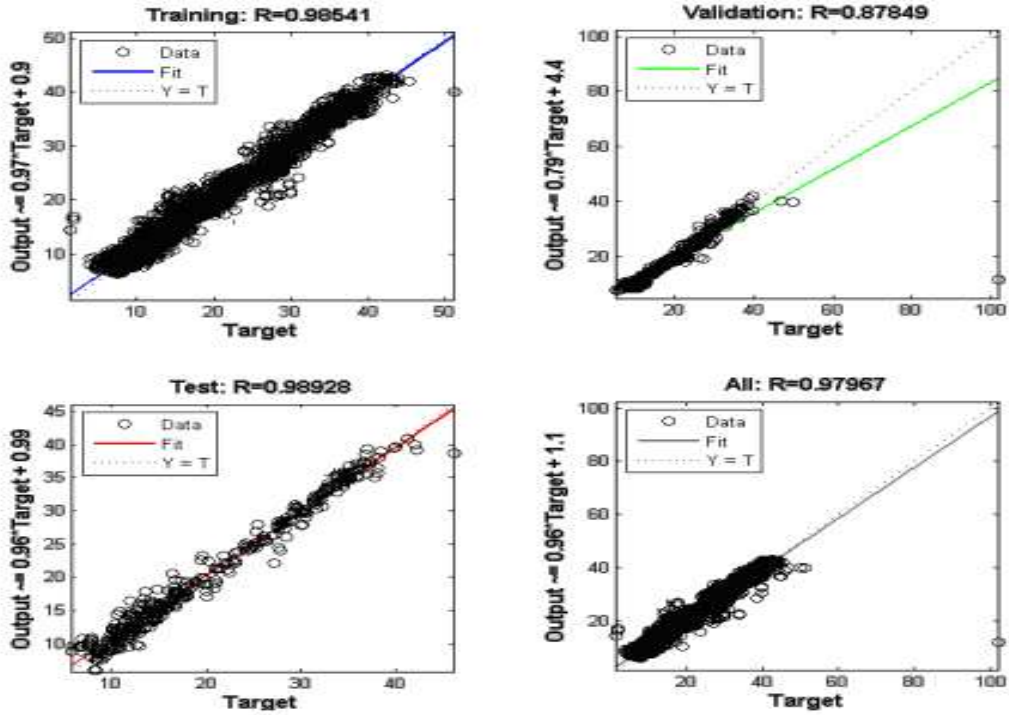
جدول (6) : اداء النموذج ( معامل التحديد وجذر متوسط مربع الاخطاء) للاراضي المزروعة وغير المزروعة بوجود عامل الزمن وعامل عمق التربة كادخال

الاراضي الغير مزروعة	الاراضي المزروعة	النموذج	المقاييس
0.985	0.98	M9	معامل التحديد
1.21	1.23	M9	جذر متوسط مربع الاخطاء

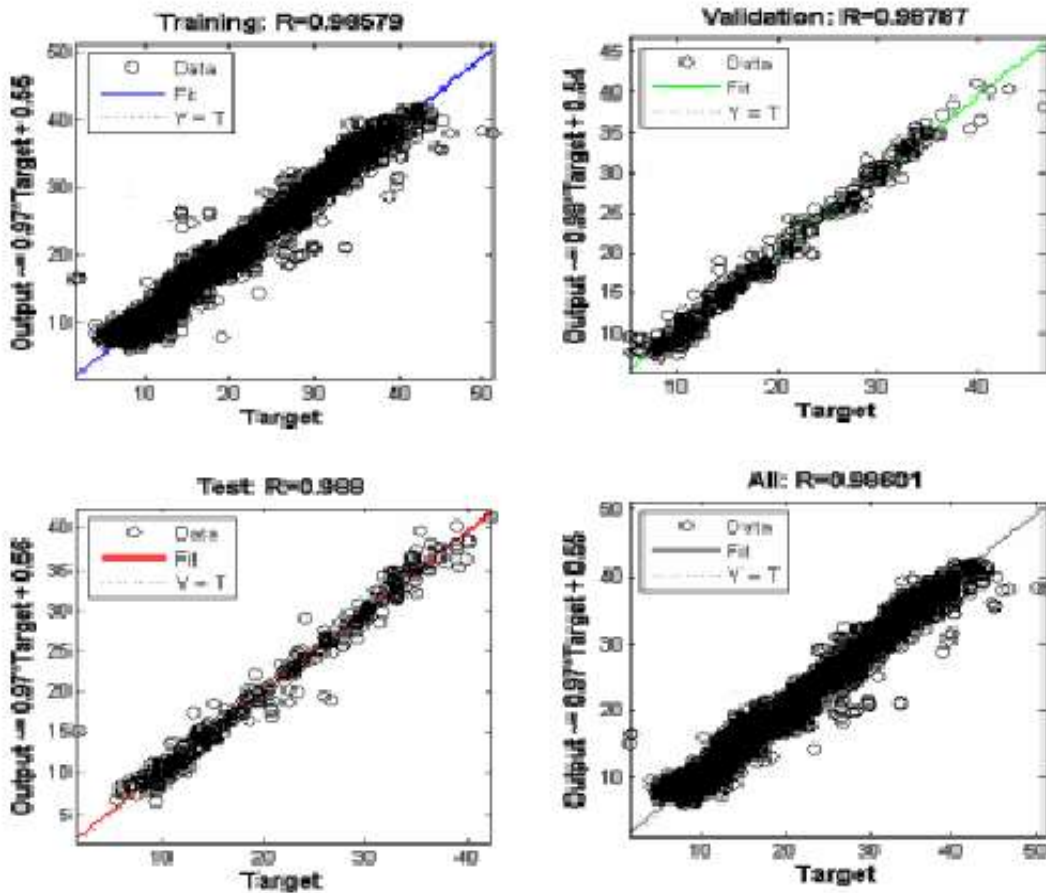


الشكل (3) المراحل التدريبية للنموذج (M7)





الشكل (4) نتائج التدريب والاختبار للنموذج (M8)



الشكل (5) نتائج التدريب والاختبار للنموذج (M9)

**الاستنتاجات:**

- 1- تفوق الخوارزمية **fitnet** على خوارزمية **feedforward** في صناعة نماذج شبكات تعكس واقع تطبيقي بدرجة عالية.
- 2- اثبتت الشبكات العصبية الاصطناعية نجاحها في عملية بناء نموذج تنبؤي يستخدم للتنبؤ بدرجة حرارة اعماق مختلفة للتربة اليومية باستخدام درجة حرارة الهواء ، عدد ساعات السطوع والطاقة الشمسية لاي يوم من ايام السنة.
- 3- امكانية تكوين نماذج تعطي تنبؤات ذات دقة عالية لدرجة حرارة اعماق التربة اليومية، مع امكانية اضافة بعد الزمن لهذه النماذج .
- 4- امكانية التعامل مع نماذج شبكات عصبية صناعية ثنائية البعد اضافة الى امكانية التنبؤ العالية لهذه النماذج بغض النظر عن عدد محاولات صناعة هذه الشبكات.

**المصادر:**

- [1] George W. Snedecor and William G. Cochran (1974)."Statistical Method" The Iowa State University press Ames, Iowa, U.S.A
- [2.] Mihalakakou G. , (2002) " On Estimating Soil Surface Temperature Profiles".Energy and Building,34:251-259
- [3.] Chengyu G., K. Danai, (1999)." Fault diagnosis of the IFAC Benchmark Problem with a modelbased recurrent neural network. Proceedings of the 1999 IEEE International Conferenceon Control Applications 21755–1760.
- [4] Mehmet B. G. , (2010)."The use of artificial neural networks for forecasting the monthly mean soil temperatures in Adana, Turkey,Jan ,18,2010.
- [5.] De Jesús O., M.T. Hagan, (2001)" 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.
- [6.] De Jesús O., M.T. Hagan. (2001)." Forward Perturbation Algorithm for a General Class of Recurrent Network. Proceedings of the International Joint Conference on Neural Networks, Washington, DC, July 15–19 2626–2631.
- [7.]Feng J., C.K. Tse, F.C.M. Lau. (2003)." A neural-network-based channel-equalization strategy for chaos-based communication systems". IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications 50(2003)954–957.
- [8] Yang , C.-C., Prasher, S. O. and Mehuys, G. R.. (1997)."An artificial neural network to estimate soil temperature". 1997, Can. J. Soil Sci. 77: 421–429
- [9.] Gianluca P. , D. Przybylski, B. Rost, P. Baldi, (2002)."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.
- [10.]Hann T. H., E. Steurer, (1996)."Much ado about nothing? Exchange rate forecasting: Neural networks vs. linear models using monthly and weekly data". Neurocomputing10 : 323–339.
- [11.] 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 33347-356.
- [12.] Jayadeva, S. A. Rahman, (2004) ." 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.
- [13.] Kalogirou S.A., (2003) ."Artificial intelligence for the modeling and control of combustion processes: a review". Progress in Energy and Combustion Science 29515–566.
- [14.] Kamwa I, R. Grondin, V. K. Sood, C. Gagnon, V. T. Nguyen, J. Mereb,. (1996) "Recurrent neural networks for phasor detection and adaptive identification in power system control and protection. IEEE Transactions on Instrumentation and Measurement 45657–664.

- [15.] Karayiannis N.B., A.N. Venetsanopoulos, (1993). "Artificial Neural Networks: Learning Algorithms. Performance Evaluation and Applications". Kluwer Academic Publishers, Boston, USA.
- [16.] Lapedes A., R. Farber, (1987). "Nonlinear signal processing using neural networks: Prediction and system modeling". Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM,.
- [17.] Markridakis S. e., (1982). "The accuracy of extrapolation (time series) methods: Results of a forecasting competition. Journal of Forecasting". 11:1-153
- [18.] Medsker L.R., L.C. Jain, (2000). "Recurrent neural networks: design and applications". Boca Raton, FL: CRC Press,.
- [19.] Racine J. S., (2001). "On The Nonlinear Predictability of Stock Returns Using Financial and Economic Variables, forthcoming. Journal of Business and Economic Statistics 19 :80-382.
- [20.] Robinson A.J., (1994). "An application of recurrent nets to phone probability estimation". IEEE Transactions on Neural Networks 5:298-305.
- [21.] 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.
- [22.] Rosenblatt F., (1961). "Principles of Neurodynamics". Washington, D.C.: Spartan Press,.
- [23.] D. E. Rumelhart, G. E. Hinton, R. J. Williams, (1986). "Learning internal representations by error propagation. In D. E. Rumelhart, & J. L. McClelland (Eds.), Parallel distributed processing (pp. 318-362). Cambridge, MA: MIT Press,.
- [24.] Sarle W.S., (2003). "Neural network FAQ". Retrieved 11 February 2003, from <ftp://ftp.sas.com/pub/neural/FAQ.html>.
- [25.] Wu B., (1995). "Model-free forecasting for non-linear time series (with application to exchange rates). Computational Statistics and Data Analysis 19 :433-459.
- [26.] Zhang G., M.Y. Hu., (1998). "Neural Network Forecasting of the British Pound/US Dollar Exchange Rate. International Journal of Management Science 26 :495-506.
- [27.] Hagan, M.T., H.B. Demuth, and M.H. Beale, (1996). "Neural Network Design". Boston, MA: PWS Publishing,.
- [28.] Elminir H. K., Y.A. Azzam, and F. I. Younes, (2007). "Prediction of Hourly and Daily Diffuse Fraction Using Neural Network as Compared to Linear Regression Models," Energy, vol.32, pp.1513-1523.