

## توظيف الشبكة العصبية الاصطناعية المتتالية للتنبؤ بالحالة الجوية في محافظة نينوى

ضحى سعد اسماعيل\*\*

د. حذيفة حازم طه \*

### المستخلص

تم في هذه الدراسة توظيف الشبكة العصبية الاصطناعية المتتالية وتدريبها على سلسلة بيانات الحالة الجوية لمحافظة نينوى وذلك للاستفادة من تدريبها على التنبؤ بالقيم المستقبلية للحالة الجوية في هذه المدينة ، وبعد استحصال النتائج تم التعامل مع القيم المتنبأ بها من جراء استخدام الشبكة العصبية المتتالية ورسمها باستخدام برنامج *Microsoft Excel* وايجاد نسبة التطابق ما بين القيم الاصلية والقيم المتنبأ بها لثمانية متغيرات وهي (درجة الحرارة (العظمى والصغرى) وسرعة الرياح والضغط الجوي والإشعاع الشمسي والتساقط المطري ونسبة الرطوبة والتبخر). اذ تم الحصول على نسبة تطابق عالية لبعض المتغيرات ما بين القيم المتنبأ بها و البيانات الحقيقية.

### Recruitment Cascade Artificial Neural Network to Predict the Weather Situation In the Province of Nineveh

#### Abstract

In this study, recruitment Cascade Artificial neural network and training on a series weather data for the province of Nineveh, and to take advantage of training to predict values for future case of weather in this city, and after obtaining the results the values forecaste have been dealt with by the using of Cascade Artificial neural network drawn using Microsoft Excel program and find a percentage of congruence between the original values and values forecaste out of eight variables, namely, (temperature(maximum and minimum) and wind speed, barometric pressure, solar radiation and precipitation rainfall, humidity and evaporation). A high match rate for some of the variables between the values forecaste values and real data has been to obtained

\*مدرس / بحوث العمليات والتقنيات الذكائية / كلية علوم الحاسوب والرياضيات / جامعة الموصل

\*\*باحثة / بحوث العمليات والتقنيات الذكائية / كلية علوم الحاسوب والرياضيات / جامعة الموصل

## Introduction

يعد التنبؤ من المسائل المهمة منذ أمد بعيد وبقي هذا الموضوع محط اهتمام الباحثين في سائر الحقول، ونظراً لأهميته فإن الأساليب المستخدمة في تحسين التنبؤ تتطور بين الحين والآخر، فبعد أن كان التنبؤ يعتمد على الطرائق الإحصائية مثل التمهيد الآسي المنفرد والمضاعف *Single and Double Exponential Smoothing*، والمتوسطات المتحركة *Moving Average*، ونماذج بوكس - جنكنز فقد حدثت قفزة نوعية في التنبؤ من خلال استخدام التقنيات الذكائية كالشبكات العصبية *Neural Networks* والخوارزميات الجينية *Genetic Algorithms* (البدراي وحسين، 2007).

وبظهور اساليب التقنية الذكائية الحديثة، أصبح توجه اغلب الإحصائيين نحو استخدام تلك الأساليب الحديثة عوضاً عن استخدام الأساليب الكلاسيكية (التقليدية)، وذلك اختصاراً للوقت والجهد فضلاً عن الحصول على أدق النتائج وأفضلها. وتعتبر الشبكات العصبية الاصطناعية احد اهم اساليب التقنيات الذكائية الحديثة من خلال قدرتها على التدريب والتنبؤ والتعلم.

أما في المجال الإحصائي فقد حظيت العلاقة بين الإحصاء والشبكات العصبية في السنوات الأخيرة باهتمام متزايد من قبل الباحثين والعاملين في الحقلين كليهما فالكثير من الأفكار التي تراود الباحثين في الشبكات العصبية نجدها مبنية على أساسيات علم الإحصاء وكثير من الوسائل والطرائق الإحصائية يمكن برمجتها بتوظيف شبكة وبناء خوارزمية لها، ولمرونة الشبكات العصبية بوصفها بديلاً عن الطرائق الإحصائية التقليدية التي لا تتطلب افتراضات عن طبيعة السلسلة الزمنية كونها خطية أو طبيعية أو مستقرة لذا يعتقد إن استخدام هذا الأسلوب قد يكون مجزياً في معالجة مسألة التنبؤ التي نحن بصددنا في هذه الدراسة (عيسى 2000).

## The Purpose of the Research

## 1. هدف البحث

يهدف البحث الى توظيف الشبكة العصبية المتتالية *CNN* للتنبؤ بالحالة الجوية في محافظة نينوى واعتماداً على المتغيرات (درجة الحرارة (العظمى والصغرى) وسرعة الرياح والضغط الجوي والإشعاع الشمسي والساقط المطري ونسبة الرطوبة والتبخّر) بغية معرفة سلوك الحالة الجوية لمحافظة نينوى لاتخاذ القرارات المناسبة بشأنها.

## 2. الشبكات العصبية المتتالية (The Cascade Neural Network (CNN)

إن عمل شبكة الذكاء الاصطناعي *CNN* مشابه لعمل الشبكات العصبية ذات التغذية الأمامية *Feed Forward Neural Network (FFNN)* حيث أنها تستخدم خوارزمية الانتشار العكسي لتعديل الأوزان ولكن العلامة الفارقة الأساسية لهذه الشبكة هي أن كل طبقة من العقد تكون مترابطة مع كل الطبقات السابقة منه، وتستخدم هذه الشبكة دالة التحويل (*Tan-sigmoid*) أو (*log - sigmoid*) للوصول الى الحل الأمثل (*Kang Li,2000*).

### 3. وصف الشبكة العصبية المتتالية


#### Description of the Cascade Neural Network (CNN)

توصف شبكة الـ *CNN* بكونها مشابهة لشبكات التغذية الأمامية من حيث العمل ولكن تحتوي على ترابط بالأوزان من طبقة الإدخال الى كل طبقة تالية لها ومن كل طبقة الى الطبقات التالية لها. على سبيل المثال شبكة ذات ثلاث طبقات تملك ارتباطات من الطبقة 1 الى الطبقة 2 ، ومن الطبقة 2 الى الطبقة 3، ومن الطبقة 1 الى الطبقة 3. وهذه الشبكة ايضاً تملك ارتباطات من الإدخال الى الطبقات الثلاثة كلها وهذه الارتباطات الإضافية قد تحسن من سرعة تعليم الشبكة للإخراج المرغوب فيه (قبع، 2012)

### 4. هيكلية الشبكة العصبية الاصطناعية

#### Structure of the Cascade Neural Network (CNN)

يقصد بهيكلية الشبكة العصبية المتتالية أو البنية الهندسية للشبكة على أنها الترتيب الذي تأخذه خلايا الشبكة العصبية المتتالية وكذلك عمليات الاتصال بين تلك الخلايا والذي يحقق بدوره الشكل العام، الشبكات العصبية المتتالية تحوي على ثلاث طبقات : طبقة الإدخال *Input Layer*، والطبقة المخفية *Hidden Layer*، وطبقة الإخراج *Output Layer* والتي هي  $e_i, i=1,2, \dots, p$  ،  $u_i, i=1,2, \dots, m$  ، و  $y_i, i=1,2, \dots, n$  على التتابع. والشكل (1) يوضح هيكلية الشبكة المتعددة الطبقات (*Kang Li,2000*).



الشكل (1) هيكلية الشبكة العصبية المتتالية

#### Algorithm of CNN

#### 5. خوارزمية الشبكة العصبية المتتالية

ان خوارزمية شبكة *Cascade* ذات التغذية العكسية هي اساس التصميم النظري لتسريع التدريب في الشبكات العصبية الاصطناعية والتي طورها العالم *Scott Fahlman* في *Carnegie Mellon* في عام (1990) وهي مشهورة كثيراً لكونها مرتبطة بخصائص التغذية العكسية وان خوارزمية تعليم شبكة *Cascade* مشابهة تماماً لبقية خوارزميات التعليم في الشبكات العصبية الاصطناعية، وهذه الخوارزمية متخصصة في العملية التكرارية لتكون مناسبة في توليف الاوزان لعقد الاتصال بواسطة قياس نسبة الخطأ في المتغير بالنسبة لعقد الاتصال (*Kang Li, 2000*).


#### Training of CNN

#### 6. تدريب الشبكة العصبية المتتالية

إن معالجة التدريب لشبكة (*CNN*) هي معالجة تكرارية *Iterative Process* وكل تكرار *Iteration* يتكون من عدد من الخطوات *Step*. وإن تدريب الشبكات العصبية المتتالية يمكن أن يتم عن طريق الانتشار العكسي. لذا فإن هنالك اثنين من المفاهيم المعروفة لتوقف عملية التدريب للشبكة العصبية الاولى هي دورات التدريب (التكرارات) والثانية هي الحد المسموح به للخطأ واقترح العالمان (*C.w dawson and R.L wilby*) افتراضاً وضع 20000 الى 100000 دورة تدريب (تكرار)

لتدريب الشبكة العصبية عند استخدام أسلوب الانحدار الحاد *Steepest Descent* وبقيّة المفاهيم تحدد الاختلاف بين الاخراج المحسوب والخراج المرغوب بواسطة الشبكة العصبية (قبع، 2012).

إن عملية التدريب ربما تتعرض لعملية توقف اما بسبب سوء اخطاء مربع الفرق بعد العرض الكامل لجميع انماط المدخلات والمخرجات او بسبب جذر متوسط مربع الخطأ ( $MSE$ ) الذي يخص جميع الانماط. في التطبيق العملي من الضروري في بعض الاحيان تطبيق المقارنة بين كلا النهجين لضمان قدرة شبكة التدريب في تعميم اختبار العينات والتطبيق والشكل (2) يبين عملية التدريب لشبكة *CNN*.



الشكل (2) عملية التدريب لشبكة *CNN*.

## 7. الخطوات الأساسية لتدريب الشبكة العصبية المتتالية

### Mean Steps to Training of CNN

**الخطوة الأولى :** في البدء تهيأ الاوزان الابتدائية، وذلك باختيار قيم ابتدائية صغيرة وعلى نحو عشوائي لأوزان الخلايا كلها في الشبكة العصبية.

**الخطوة الثانية :** اختيار زوج التدريب من مجموعة التدريب ( $Input, Target$ )، ونحسب قيمة الإخراج لكل وحدة  $z$  في كل طبقة  $L$ . كما مبين في المعادلة (1) والمعادلة (2). فالمعادلة التي تصف اخراج الطبقة المخفية هي ( $Kang Li, 2000$ ):

$$e_i = \phi \left( \sum_{j=1}^p W_{ij}^{eu} u_j + \sum_{k=1}^{i-1} W_{ik}^{ee} e_k + b_i^e \right) \quad \dots \dots \dots (1)$$

إذ إن :

$\phi(\cdot)$  هي دالة التفعيل.

$W_{ij}^{eu}, W_{ik}^{ee}$  هما الاوزان القابلة للتعديل.

$u_j, e_k$  هما الاخراج من طبقة الادخال والطبقة المخفية (الوسطى) على التتابع.

$b_i^e$  هو الـ Bias .

والدالة التي تصف طبقة الاخراج تكون دالة خطية بحتة وهي:

$$y_i = (\sum_{j=1}^p W_{ij}^{yu} u_j + \sum_{k=1}^n W_{ik}^{ye} e_k + b_i^y) \dots\dots\dots(2)$$

إذ إن :

$y_i$  هو الاخراج من عقدة الاخراج.

$W_{ij}^{yu}, W_{ik}^{ye}$  هما الاوزان القابلة للتعديل.

$u_j, e_k$  هما الاخراج من عقد الادخال والعقد المخفية (الوسطى) على التتابع.

$b_i^y$  هو الـ Bias .

**الخطوة الثالثة :** نحسب الخطأ بين الإخراج الحقيقي للشبكة والإخراج المطلوب من زوج التدريب، ثم

نستخدم القيم المحسوبة من قبل الطبقة الأخيرة، وباعتبار مجموعة عينات التدريب  $Z$

مع  $N$  من النماذج وباستخدام دالة الكلفة وكالاتي:

$$E(Z; w) = \sum_{i=1}^N ((y_i(j) - T_i(j))^2) \dots\dots\dots(3)$$

إذ إن :

$N$  هي عدد النماذج.

$w$  هو الوزن القابل للتعديل.

$y_i, i=1,2, \dots, N$  هو اخراج الشبكة.

$T_i, i=1,2, \dots, N$  هو الهدف .

**الخطوة الرابعة:** تحديث الأوزان باستخدام المعادلة الآتية مع الأخذ بنظر الاعتبار منحنى التعديل ،

فان الخوارزمية التكرارية ستأخذ الشكل الاتي :

$$\begin{cases} w^{(i+1)} = w^{(i)} - \mu^{(i)} H^{(i)} E' (w^{(i)}) \\ w^{(0)} = w_0 \end{cases} \dots\dots\dots(4)$$

إذ إن :

$\mu$  هو نسبة التعلم ويمكن تحديده من خلال البحث على طول الخط المشار إليه.

$H$  هو مصفوفة موجبة.

$E'$  هو المشتقة الأولى من دالة الكلفة مع الأخذ بنظر الاعتبار منحني الوزن. القيمة البدائية لـ  $w$  ممكن أن تكون مسبقاً التخمين وعملياً فإن  $w_0$  يتم توليده عشوائياً. وفيما يتعلق بالمعادلة (4) فإن تحديث منحني التعديل يبنى ضمناً على اشتقاق دالة الكلفة مع الأخذ بنظر الاعتبار منحني التعديل.

**الخطوة الخامسة:** نرجع إلى الخطوة الثانية ونكررها لكل النماذج  $p$  والى أن يصل الخطأ إلى قيمة مقبولة.

من المعادلات (1) و(2) تم سرد العقد الوسطية بانتظام فإن ترابطاتها تشكل التالي *The Cascade*. وأيضاً إذا تم استخدام المصفوفة لتمثيل الترابطات بين العقد الوسطى فإن المصفوفة سوف تكون مصفوفة ثلاثية منخفضة أو مصفوفة ثلاثية علوية وتكون العناصر القطرية كلها صفراً (0). وبصورة عامة الشبكات العصبية المتتالية *Cascading Neural Network* هي شبكات تغذية أمامية ولكن في هذه الشبكات يكون مفهوم الطبقات مفقوداً فكما هو ملاحظ في الشكل (1) فكل عقد الإدخال والعقد الوسطية تكون مترابطة مع الإخراجات وكل العقد الوسطية تكون مترابطة مع بعضها (Kang, Li, 2000).

في حالة الشبكات العصبية ذات التغذية الأمامية فإن التدريب لمنحني التعديل يتم انجازه دورياً من خلال الانتشار العكسي للخطأ. وفيما يتعلق بتدريب الشبكات العصبية المتتالية فإن معظم نظريات التدريب المتوافرة هي لشبكات الانتشار العكسي (*Back Propagation (BP)*) مثل نظرية الميل *Gradient* التي يمكن أن يتم تطبيقها تحت التحديثات الآتية:

(1) في مرحلة الانتشار أماماً يتم تقديم منحني تدريب الإدخال وحساب كل إخراج عقدة ناجح لحين إيجاد إخراج العقدة الأخير.

(2) في مرحلة الانتشار خلفاً فإن الانتشار الخلفي للخطأ يتم انجازه فقط بين أنواع مختلفة من العقد، (أي بين عقد الإخراج والعقد الوسطى، وبين العقد الوسطى وعقد الإدخال) ويهمل الانتشار العكسي للخطأ بين العقد الوسطى.

(3) في مرحلة التعليم فإن معاملات الوزن والـ *Bias* للعقد التي تملك نفس النوع ممكن أن يتم تحديثها معاً مثل تدريب شبكة الـ (*Back Propagation (BP)*) التقليدية.

الفوائد من معمارية الشبكة العصبية المتتالية هو أنها تستغل بالكامل إمكانات الترابطات بين العقد.

## Modeling Performance Criterion

## 8. اداء معيار النموذج

من اجل تقييم دقة التنبؤ للشبكة العصبية الاصطناعية (ANN) ونماذج الانحدار المتعددة هنالك اربعة معايير مستخدمة لتقييم ومقارنة اداء النموذج ومن المعايير المستخدمة هي متوسط الخطأ المطلق (MAE) ومتوسط مربع الخطأ (MSE) وجذر متوسط مربع الخطأ (RMSE) ومعامل الارتباط (Atki (Cc), 2013).

### 1- متوسط الخطأ المطلق (Mean Absolute Error (MAE)

هي الكمية المستخدمة لقياس مدى دقة التوقعات او التنبؤات في تحقيق النتائج في نهاية المطاف ويعرف MAE هو متوسط مدى عينة التحقيق للقيم المطلقة للاختلافات بين التوقعات ومايقابلها وهو يعطى بالشكل الاتي :- (Atki, 2013).

$$MAE = \frac{1}{n} \sum_{i=1}^n [observed - predicted] \dots\dots\dots(5)$$

### 2- متوسط مربع الخطأ (Mean Square Error (MSE)

متوسط مربع الخطأ هو مقدار واحد من بين الطرائق العديدة لقياس الفرق بين القيم المقدرة والقيم الحقيقية للكمية التي جرى تقديرها وهو الفرق المتبقي او خطأ مجموع المربعات مقسوماً على مجموع عدد درجات الحرية وهذا يعطى تقديراً للخطأ او الفرق المتبقي والذي يعطى بالشكل الاتي :- (Atki (Cc), 2013).

$$MSE = \frac{1}{n} \sum_{i=1}^n [observed - predicted]^2 \dots\dots\dots(6)$$

### 3- جذر متوسط مربع الخطأ (Root Mean Square Error (RMSE)

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [observed - predicted]^2} \dots\dots\dots(7)$$

### 4- معامل الارتباط (Coefficient of Correlation (Cc)

هو مقياس لقوة العلاقة الخطية وهو يعرف مصطلحاً في عينة بالتباين بين المتغيرات مقسوماً على الانحرافات المعيارية في تلك العينة وهو يعطى بالشكل الاتي (Atki, 2013).

$$Cc = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \dots\dots\dots(8)$$



إذ إن :

$n$ : عدد انماط البيانات في البيانات المعتمدة.

$X$ : مجموعة من القيم الملاحظة.

$Y$ : مجموعة القيم المتوقعة .

$X'$ : متوسط القيم الملاحظة .

$Y'$ : متوسط القيم المتوقعة .

## Practical Aspect

## 9 . الجانب التطبيقي

تعد المياه العذبة من الموارد الطبيعية الحيوية التي تنصدر قائمة الاولويات في اهتمام البلدان في الوقت الحاضر وبخاصة بعد ارتفاع معدلات استهلاكها لسد المتطلبات البشرية المتزايدة والتي يكافح الناس من اجل تأمين هذه المياه. وما رافقها من تنامي صيحات القلق في دول العالم كلها بسبب عدم كفاية المياه مما يستدعي المزيد من الدراسات واتخاذ السبل الكفيلة للحد من ازمة المياه المتوقعة ، ولاسيما تلك الدول التي يسودها الجفاف الفصلي الدائم كما هي الحال في القطر العراقي ، لغرض تأمين الامن المائي والغذائي وضمانه.

كذلك تعد الحالة الجوية ذات اهمية بالغة نظرا لارتباطها بمفاصل الحياة كافة، اذ كانت التغيرات المناخية وظاهرة الاحتباس الحراري سبباً في قلة تساقط الأمطار وانحباسها خصوصا في السنوات القليلة الماضية الأمر الذي أدى إلى ظهور ظاهرتي الجفاف والتصحر.

مما سبق ذكره كان الحافز الأكبر لدراسة التنبؤ بالحالة الجوية استنادا إلى بيانات حقيقية للحالة الجوية في محافظة نينوى محاولين بناء نموذج حاسوبي باستخدام الشبكة العصبية المتتالية يمكنه تمثيل البيانات الحقيقية في مدينة الموصل للحصول على التنبؤ الصحيح بالحالة الجوية.

ولتكوين هذا الأنموذج الحاسوبي ، تم بناء برنامج باستخدام *Matlab* اصدار (*r200A*) نسخة (*V.9*) لتنفيذ عمل الشبكة العصبية المختارة من نوع *Cascade Neural Network (CNN)* للتنبؤ بحالات الطقس لثلاث سنوات جديدة وكانت البيانات المتوفرة مكونة من ثمانية متغيرات تمثل حالة الطقس لـ 31 سنة ابتداء من سنة 1980 الى 2010 كمعدلات شهرية لحالة الطقس في محافظة نينوى من محطة انواء الرشيدية اذ تم الحصول على البيانات من مركز التحسس النائي في جامعة الموصل.

تم استخدام برنامجين الاول للتدريب وتوليف الاوزان ومعرفة نسبة التطابق للبيانات المتنبأ بها عن البيانات الاصلية وذلك بقيامنا بالتنبؤ لثلاث سنوات موجودة اصلاً من ضمن البيانات الحقيقية ومقارنتها مع الاصلية وايجاد افضل نسبة تطابق من خلال توليف الاوزان الى ان حصلنا على نسبة (94% ، 87% ، 80%) للسنوات الثلاث على التوالي بعد محاولات متعددة. بعد ذلك تم اعتماد الاوزان المختارة في البرنامج الاول وتم استخدامها في البرنامج الثاني والذي لا يختلف كثيراً عن الاول للاختبار والتنبؤ لثلاث سنوات باستخدام البيانات الاصلية.

### 1.9 تطبيق خوارزمية الشبكة العصبية الاصطناعية المتتالية للتنبؤ بالحالة الجوية في مدينة

#### الموصل:

يمكن تلخيص آلية تدريب الشبكة العصبية المتتالية للتنبؤ بالقيم المستقبلية للحالة الجوية لثلاث سنوات على النحو الآتي :

الخطوة الأولى : قراءة البيانات من الملف النصي .

الخطوة الثانية : إدخال قيمة عدد المتغيرات  $NubPar=8$  و عدد سنوات التدريب  $year=28$  و عدد السنوات المراد التنبؤ بها  $Year P=3$

الخطوة الثالثة : تكوين المصفوفة  $A$  والتي ابعادها  $m$  ,  $n$  وهيا البيانات المستخدمة في التدريب.

الخطوة الرابعة : تقسيم البيانات الى بيانات تدريب وبيانات اختبار .

الخطوة الخامسة : ادخال البيانات على شبكة CNN.

الخطوة السادسة : تنفيذ الشبكة العصبية المتتالية.

الخطوة السابعة: ضبط متغيرات الشبكة وهي  $Goal=1e^{-10}$  ,  $Lr= 0.01$  ,  $epochs=5000$

والبدء في عملية تدريب الشبكة العصبية المتتالية و جعل قيمة العداد  $I=1: epochs$

الخطوة الثامنة : جعل قيمة  $E=0$

الخطوة التاسعة : جعل قيمة العداد  $J=1: Year$  ثم اذهب الى الخطوة عشرين.

الخطوة العاشرة : حساب الانتشار الامامي ونتاج الاخراجات حسب المعادلات (1) و(2)

الخطوة الحادية عشرة : ايجاد الفرق بين الاخراجات الحقيقي للشبكة والاخراج المطلوب ووضعها في

متغير  $(E)$  حسب المعادلة (3).

الخطوة الثانية عشرة : استخدام نسبة من الفرق بمقدار (Lr) في الانتشار العكسي لتغيير الاوزان كما في المعادلة (4)

$$E = E + |E_1|$$

الخطوة الثالثة عشرة : حساب قيمة

الخطوة الرابعة عشرة : زيادة قيمة المعداد بمقدار واحد  $J = J + 1$  والعودة الى الخطوة الرابعة عشرة.

$$E = E / \text{year}$$

الخطوة الخامسة عشرة : حساب قيمة

الخطوة السادسة عشرة : اذا كانت قيمة  $E < \text{Goal}$  اذهب الى الخطوة الثالثة والعشرين والا اذهب الى الخطوة الثانية والعشرين.

الخطوة السابعة عشرة : زيادة المعداد  $I = I + 1$  ثم اذهب الى الخطوة الثانية عشرة.

الخطوة الثامنة عشرة : إيقاف عملية التدريب .

الخطوة التاسعة عشرة : توليد متغيرات السنوات المتتباها بها .

الخطوة العشرون : مقارنة بين متغيرات السنوات المتتباها بها والسنوات الحقيقية .

الخطوة الحادية والعشرون : طبع النتائج.

## 2.9 شرح الخوارزمية المقترحة للتنبؤ بالحالة الجوية في مدينة الموصل

1-قراءة البيانات المخزونة في ملف *Axcel* و تخزينها في مصفوفة داخل البرنامج.

2-تحويل شكل قراءة البيانات التي كانت بصيغة مصفوفة مكونة من 12 صفا يمثل الشهور و 8 اعمدة تمثل متغيرات الطقس لكل سنة من السنوات ضمن الفترة 1981-2010، الى صف واحد لكل سنة و 96 عمودا يمثل متغيرات الطقس الثمانية لكل شهر.

3-فصل البيانات الى مجموعتين: الاولى تمثل مجموعة التدريب والتي تتمثل في اول 28 سنة والثانية تمثل مجموعة اختبار والتي تتمثل في اخر 3 سنوات وتم اختيار 3 سنوات لكونها تمثل تقريبا 10% من المجموع الكلي للبيانات.

4-توليد مصفوفة الادخال *Input Array* للشبكة العصبية والذي يمثل رقم السنة المدخلة.

5-انشاء شبكة عصبية وتم اختيار شبكة من نوع *Cascade Neural Network* لكونها توفر نتائج افضل وبوقت اقل مقارنة مع باقي الشبكات، والشبكة مكونة من ادخال واحد *Input* يمثل رقم السنة المدخلة وطبقة مخفية واحدة (منفردة) مكونة من 48 عقدة والذي يمثل عدد المتغيرات مضروبا في ستة ( $6 * \text{number of parameter}$ ) وتم اختيار هذا العدد من العقد بعد ان تم تنفيذ البرنامج لعدة مرات وفي كل مرة يتم تسجيل الوقت والتكرار ويتم تغيير عدد العقد الى ان تم الحصول على هذه النتيجة اما

اخراج الشبكة *Output* فإنه مكون من 96 عقدة والنااتجة من ضرب عدد المتغيرات والبالغة ثمانية متغيرات في عدد شهور السنة والبالغة 12 شهرا.

6- وضع شروط الشبكة العصبية والمتمثلة ب معدل التعلم *Learing* وهنا اعتمدنا في برنامجنا قيمة (0.01) كافضل معدل للتعلم والشرط الثاني هو *Gool* وهو الحد الاعلى المسموح به لتعليم الشبكة وايضاً كان اختيارنا هو ( $e^{-10}$ ) كنسبة مقبولة للتعلم وكلما قل هذا المقدار زادت كفاءة الشبكة العصبية أي بمعنى اذ ( $e^{-20}$ ) او ( $e^{-30}$ ) تزداد الدقة في الحصول على النتائج أي تقل نسبة الخطأ المسموح به لتدريب البيانات.

كما وضع حد للتكرارات *Epochs* والذي يمثل التكرارات المسموح بها في البرنامج او اكبر عدد من التكرارات . وفي هذا البرنامج وبعد توليف الاوزان كان عدد التكرارات النهائية لحصولنا على النتائج هو ستة تكرارات وهو رقم يعد جيدا بالمقارنة مع الحد الذي وضع في بداية تصميم البرنامج والذي كان بعدد 5000 تكرار .

7. بدء تدريب الشبكة العصبية وعمل العديد من محاولات التنفيذ مع تغيير معدل التعلم في كل مرة او تغيير عدد العقد المخفية في حالتين الاولى عندما تكون الطبقة المخفية منفردة والثانية عندما تكون الطبقة المخفية متعددة الطبقات ويشمل الوقت والتكرار في كل تنفيذ الى ان تم التوصل الى افضل نتيجة يتوقع من خلالها ان تؤدي الشبكة الى افضل تنبؤ .

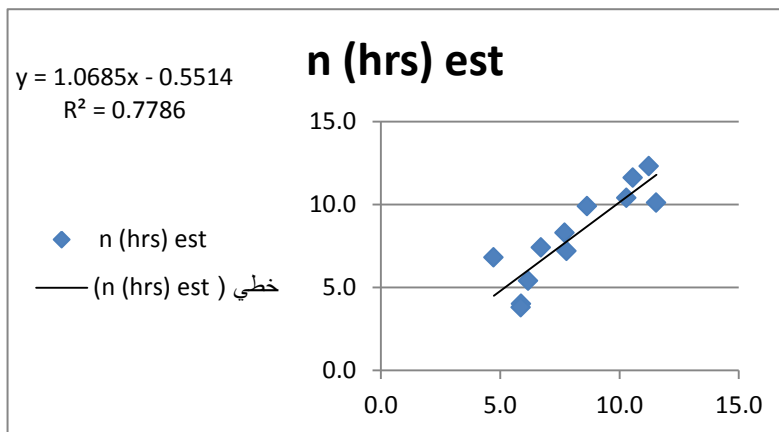
8. الحصول على قيم السنوات المتنبأ بها واعادة صياغة النتائج وارجاعها الى شكلها الاصلي.

9. المقارنة بين السنوات المتنبأ بها والسنوات الاصلية وتحليل تلك المقارنة.

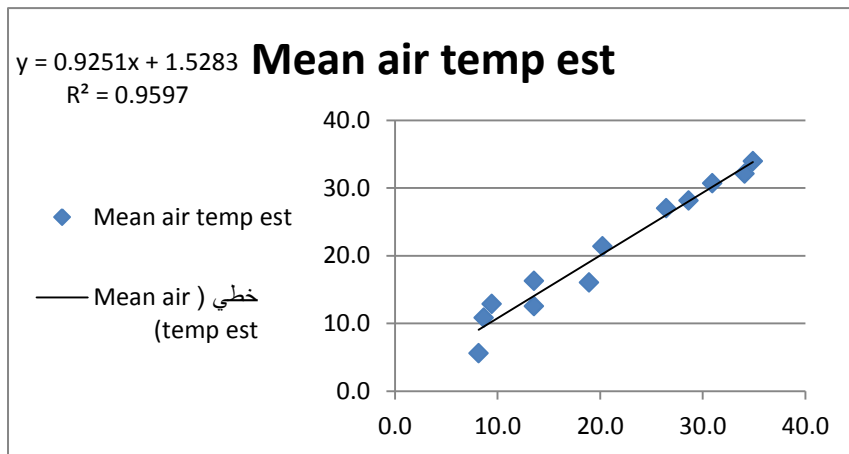
### 3.9 اختبار نتائج الخوارزمية المقترحة للتنبؤ بالحالة الجوية في مدينة الموصل

بعد ان تم التنبؤ بقيم متغيرات الطقس في محافظة نينوى لثلاث سنوات من ضمن البيانات الاصلية وحصلنا على نتائج مرضية الى حد ما تم اختبار تلك النتائج عن طريق رسم نسبة التطابق لكل متغير لسنة ( 2011 ) بين القيم المتنبأ بها والقيم الحقيقية للتأكد من صحة التنبؤ وكانت النتائج على النحو التالي :-

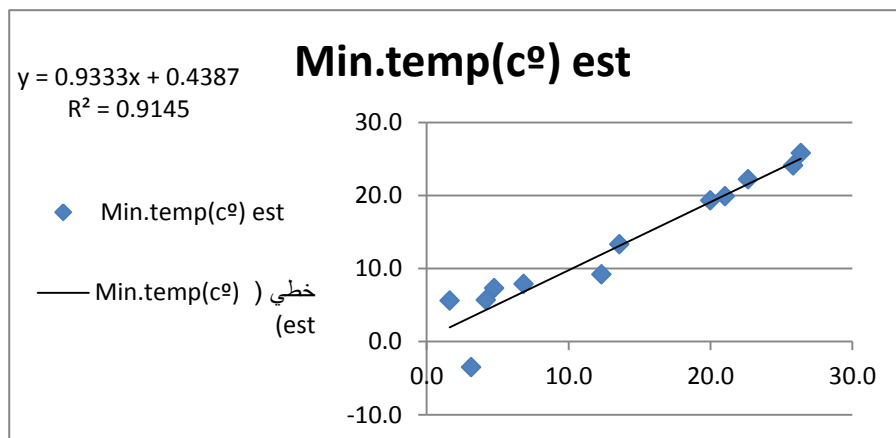
n (hrs)	n (hrs) est
4.7	6.8
5.9	4.0
7.8	7.2
6.7	7.4
8.6	9.9
11.5	10.1
10.6	11.6
11.2	12.3
10.3	10.4
7.7	8.3
6.2	5.4
5.9	3.8



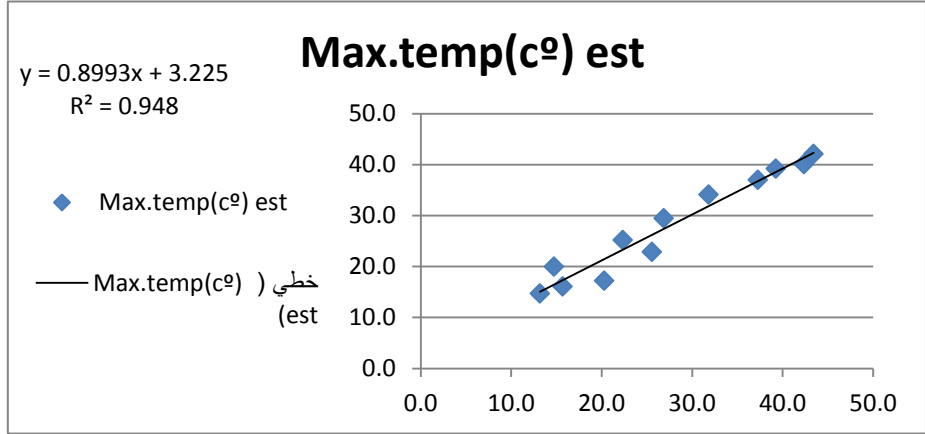
Mean air temp	Mean air temp est
8.2	5.6
9.5	12.9
13.6	12.6
18.9	16.1
26.4	27.0
31.0	30.7
34.9	34.0
34.1	32.1
28.7	28.2
20.2	21.4
13.6	16.3
8.7	10.9



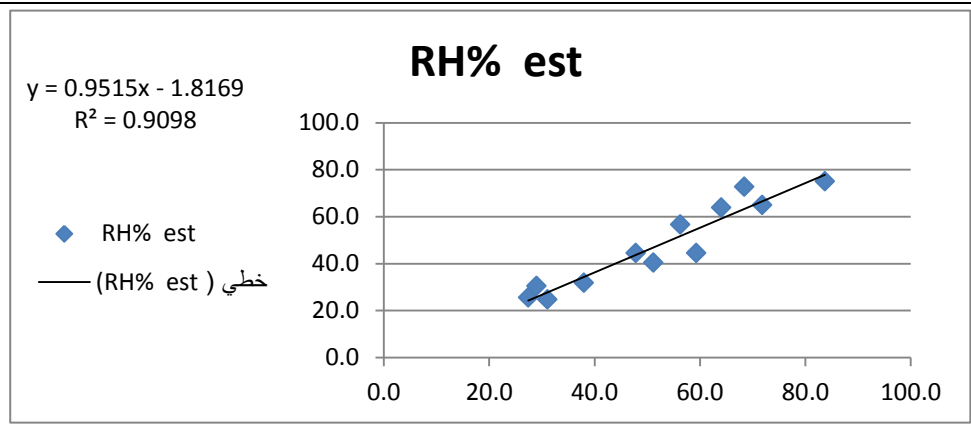
Min.temp(c°)	Min.temp (c°) est
3.1	-3.5
4.2	5.7
6.8	7.9
12.3	9.2
21.0	19.9
22.7	22.2
26.4	25.8
25.8	24.1
20.0	19.3
13.6	13.3
4.8	7.3
1.6	5.6




Max.temp (c°)	Max.temp (c°) est
13.2	14.7
14.7	20.0
20.3	17.2
25.6	22.9
31.8	34.1
39.3	39.2
43.4	42.1
42.4	40.1
37.3	37.0
26.9	29.5
22.3	25.2
15.7	16.1



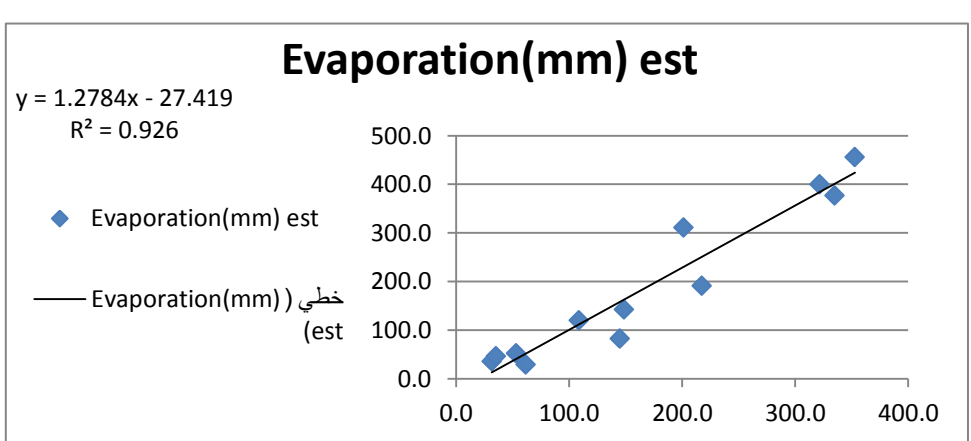
RH%	RH% est
83.7	75.1
71.8	65.0
56.3	56.7
59.3	44.6
51.2	40.4
31.0	24.8
27.4	25.6
29.0	30.5
38.0	31.8
47.8	44.6
64.0	63.9
68.5	72.8



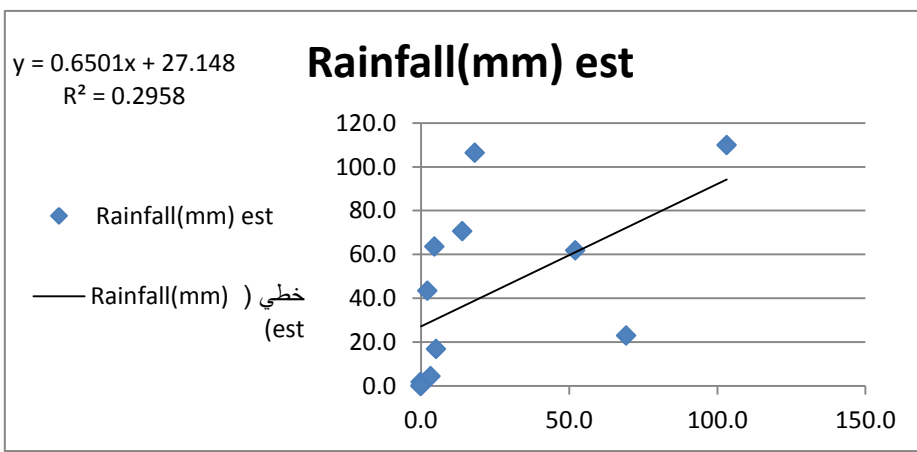
Wind speed (m/s)	Wind speed (m/s) est
0.6	-0.1
0.9	0.8
1.0	1.1
1.5	6.0
1.3	1.2
1.2	1.6
1.2	1.0
1.0	1.8
0.8	1.7
1.2	1.1
0.8	0.9
0.7	0.9



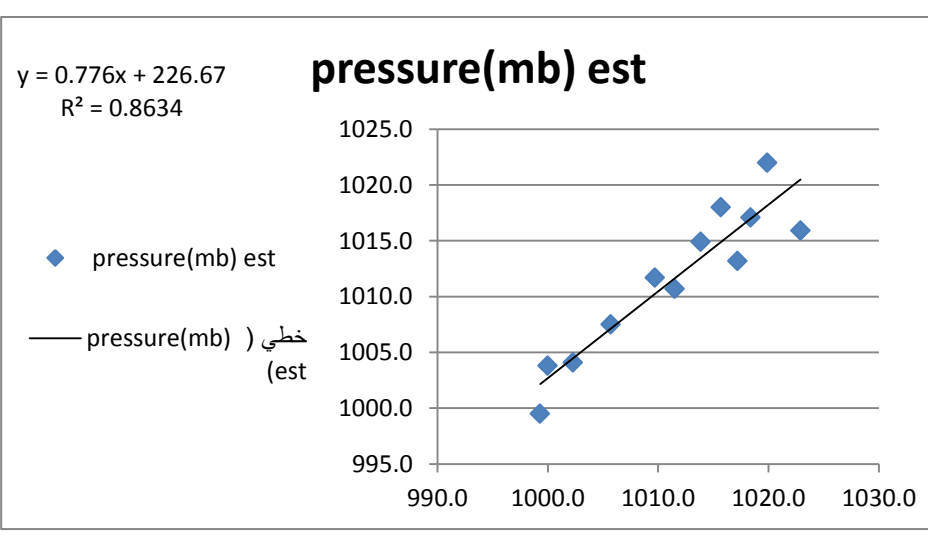
Evaporation (mm)	Evaporation (mm) est
31.5	35.6
53.0	52.3
108.7	120.0
144.9	82.3
201.2	311.0
321.6	400.0
352.9	456.0
335.0	377.0
217.4	191.0
148.6	142.6
61.7	29.0
35.2	46.0



Rainfall (mm)	Rainfall(mm) est
69.3	23.0
52.1	61.9
4.6	63.7
103.2	109.9
5.1	16.9
0.0	1.9
0.0	0.0
0.0	0.2
3.3	4.4
2.2	43.5
14.0	70.7
18.2	106.5



Pressure (mb)	pressure(mb) est
1019.9	1022.0
1015.7	1018.0
1017.2	1013.2
1011.5	1010.7
1009.7	1011.7
1002.3	1004.1
999.3	999.5
1000.0	1003.8
1005.7	1007.5
1013.9	1014.9
1018.4	1017.1
1022.9	1015.9



### الاستنتاجات:-

من خلال ما تم الحصول عليه من الجانب التطبيقي يلاحظ ما يأتي:-

- 1- النتائج التي تم الحصول عليها باستخدام الشبكة العصبية المتتالية جيدة اذا كانت نسبة تطابق البيانات الناتجة من التنبؤ عن البيانات الاصلية للسنوات الثلاثة على التوالي هي (94%، 87%)، و80% وتفي بالغرض في حالة التنبؤ.
- 2- ان الوقت المستغرق في تدريب الشبكة لحين اظهار النتائج كان قصيرا جدا اذ كان الوقت المستغرق في تدريب الشبكة الاصطناعية المتتالية لم يتجاوز العشرة دقائق .
- 3- ان نسبة التطابق ما بين النتائج المتنبأ بها والقيم الاصلية كانت جيدة جدا في جميع المتغيرات ماعدا (الامطار و سرعة الرياح ) كما موضح في الرسومات السابقة لكونهما من اكثر المتغيرات التي لاتخضع لقاعدة معينة ولانستطيع التنبؤ بهما وهذا ما اكدته جميع الدراسات السابقة.

## المصادر

- 1- البدراني ، ظافر رمضان مطر وحسين،الهام عبد الكريم .(2007). "توظيف اسلوب المكونات الرئيسية في التكهّن بنماذج بوكس-جنكنز" ، المجلة العراقية للعلوم الاحصائية ، المجلد 7 ، العدد11، كلية علوم الحاسبات والرياضيات ، جامعة الموصل
- 2- الصقال، أديبة اسماعيل وطاهر،غادة محمد .(2006). " استخدام الشبكات العصبية الاصطناعية وشجرة القرار في تشخيص امراض الفم " ، مجلة الرافدين لعلوم الحاسبات والرياضيات ، المجلد 3 ، العدد2،كلية علوم الحاسبات والرياضيات ، جامعة الموصل.
- 3- أمين بك، عزة حازم زكي. (2004): "استخدام الشبكات العصبية في التكهّن للسلاسل الزمنية"، رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
- 4- عيسى، علام زكي .(2000):" الشبكات العصبية، البنية الهندسية-الخوارزميات – التطبيقات"، الطبقة الاولى، شعاع للنشر والعلوم ، حلب، سوريا.
- 5- قبع، إسرائ زهير . (2012)، "تخمين مشاريع البرمجيات باستخدام الشبكات العصبية"، رسالة ماجستير كلية علوم الحاسبات والرياضيات ، جامعة الموصل.
- 6- Kang Li, Stephen Thompson, 2000, "A Cascaded Neural Network and Its Application to Modelling Power Plant Pollutant Emission", IEEE, Proceedings of the 3d World Congress on Intelligent Control and Automation.
- 7- Atki,K. Shrihari,s. and Manu,B., .(2013)." Water Quality Prediction Distribution System Using Cascade Feed Forward Neural Network", International Journal of Advanced Technology in Civil Engineering, ISSN: 2231 –5721, Vol 2, 84-91.