

مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية
(بوكس - جنكنز) مع التطبيق

د. ظافر رمضان مطر **

Thafer63@yahoo.com

رهاد عماد صليوا *

Rehad_Shamany@yahoo.com

المستخلص

تم في هذا البحث مقارنة دقة التنبؤ بين الطريقة الإحصائية للمتسلسلات الزمنية المتمثلة بمنهجية (بوكس - جنكنز)، وبعض الشبكات العصبية الاصطناعية التي اختلفت فيما بينها من حيث وجود التغذية المتكررة في هيكليتها من عدمه، وهي Feed forward Neural (FFNN) ، Network Nonlinear (NARX) ، Elman Neural Network (ENN) ، Autoregressive With Exogenous Input ، وذلك بالتطبيق على بيانات المعدلات الشهرية لدرجات الحرارة العظمى لمدينة الموصل للأعوام (1983-2009) التي بلغ عددها 324 مشاهدة ، إذ تم الإبقاء على 12 مشاهدة بوصفها عينة مبتورة (Truncated Sample) للمقارنة مع قيم التنبؤ التي يتم الحصول عليها من الطريقتين كليهما ، وقد بينت نتائج التنبؤ أن أداء الشبكات العصبية ذات التغذية المتكررة أفضل من غيرها ومن أداء منهجية (بوكس - جنكنز) .

الكلمات المفتاحية : المتسلسلات الزمنية ، منهجية (بوكس-جنكنز) ، التنبؤ، الشبكات العصبية الاصطناعية ، خوارزمية التعلم ، شبكة التغذية الامامية (FFNN) ، شبكات التغذية العكسية

This is an open access article under the CC BY 4.0 license
<http://creativecommons.org/licenses/by/4.0/>

**Comparison Performance Prediction between some Artificial Neural
Networks (Box Jenkins) methodology with application**

Abstract

This paper compares a prediction accuracy between the statistical time series method that use (Box – Jenkins) methodology, and some artificial neural networks, which differ from them through the feedback in their structure.

* مدرس مساعد / قسم الاحصاء والمعلوماتية / كلية علوم الحاسوب والرياضيات/ جامعة الموصل .
** استاذ / قسم الاحصاء والمعلوماتية / كلية علوم الحاسوب والرياضيات/ جامعة الموصل .

These networks are Feed Forward Neural Network (FFNN), Elman Neural Network (ENN), and Nonlinear Autoregressive with Exogenous Input (NARX). By using a set of data, the average monthly maximum temperatures in Mosul for the years (1983– 2009), which numbered 324 observations, twelve observations were kept as Truncated samples in order to compare with the results of prediction models for the above two methods.

The results of prediction with performance of neural networks with feedback is better than others, and the performance methodology of (Box - Jenkins).

1- المقدمة

Introduction

في مطلع العقد السابع من القرن العشرين ظهر اهتمام متزايد بتحليل المتسلسلات الزمنية وطرائق التنبؤ بقيمها المستقبلية ، فقد كانت تعد من أبرز الأساليب الإحصائية المستخدمة في التنبؤ للكثير من التطبيقات والمجالات العلمية ، ويُعزى الاهتمام الكبير بالمتسلسلات الزمنية إلى الحاجة الماسة لنظام تنبؤ موثوق به لتفسير الكثير من الظواهر في مختلف مجالات الحياة ، وهذا النظام التنبؤي يتطلب بناء نماذج دقيقة تُسمى نماذج المتسلسلات الزمنية؛ إذ كانت بُورة البحث والتطوير في السنوات الأخيرة للعديد من المجالات (محمد ، 2011) ، (Bisgaard &) ، (Kulahci, 2011) ففي عام (1976) قدم الباحثان (Box and Jenkins) المنهجية المشهورة باسميهما لبناء وتحليل بعض نماذج المتسلسلات الزمنية، إذ قدما أمثلة تطبيقية عامة عن هذه النماذج أصبحت فيما بعد أمثلة أنموذجية يعتمد عليها أغلب الباحثين في بحوثهم ومؤلفاتهم (Box and Jenkins, 1976). ونظراً لأهمية التنبؤ فإنّ الأساليب المستخدمة في تحسينه تتطور بين الحين والآخر، فقد حدثت قفزة نوعية في التنبؤ؛ إذ شهد العالم في السنين الأخيرة تطورات كبيرة ومتسارعة في مجال استخدام الحاسوب من خلال استخدام الشبكات العصبية الاصطناعية () Artificial Neural Networks والخوارزميات الجينية (Genetic Algorithms). فقد ظهرت تطبيقات في مجال التنبؤ بالاعتماد على الأساليب الحاسوبية الحديثة فبدأ الإحصائيون وغيرهم بالتوجه إليها وتوظيفها في مجالات عملهم، فأصبحت الشبكات العصبية الاصطناعية تستخدم على نطاق واسع، وفي تطبيقات متنوعة لقدرتها على إنتاج تنبؤات مقبولة ودقيقة في الحالات التي تكون

فيها علاقات معقدة بين المدخلات والمخرجات (Moreno,et al.,2011) , ويمكن عد عقد الاربعينيات (1940-1950) هو البداية لتطور الشبكات العصبية، فقد قدمت أولى الشبكات العصبية الاصطناعية عام (1943) من المتخصص في علم الوظائف العصبية (Warren McCulloch)، والمتخصص في علم المنطق (Watter Pitts) إذ أعطيا المفهوم الأول للشبكات العصبية ووفق تصميمهم فإن الأنظمة العصبية تتكون من مجموعة من العصبونات البسيطة المترابطة بعضها مع البعض ومرفقة بأوزان تدريبية (عيسى ، 2000) . وفي عام (1998) بين الباحثان (Chatfield and Faraway) بأن منهجية بوكس-جنكنز قدمت مطابقة أفضل من نماذج الشبكات العصبية في التنبؤ لبيانات متسلسلة زمنية لمسافري الخطوط الجوية الدولية للأعوام (1949-1960) (Chatfield and Faraway,1998)، كذلك قدم الباحث Yao عام (2002) بحثاً عرض فيه دراسة شبكة عصبية للتنبؤ بحالة السوق، وتوصل إلى أن الشبكة العصبية تتفوق على الطرائق الكلاسيكية على الرغم من أنها تحتاج إلى تدريب طويل (Yao,2002) . وفي عام (2008) قدمت زكي بحثاً للتنبؤ بالمتسلسلات الزمنية ذوات السلوك الأسي باستخدام الشبكات العصبية الاصطناعية؛ إذ استخدمت شبكة ايلمان التي أظهرت تفوقاً على طريقة التمهيد الأسي (زكي ، 2008) . وقدم الباحثان (Shen and Chang) عام 2013 بحثاً لتنبؤات متعددة الخطوات للامام عن عمق الغمر باستخدام شبكة (NARX) التي تستخدم التغذية المتكررة لمعالجة المشكلة، وأعطت نتائج جيدة جداً (Shen and Chang,2013) .

Research Objective

2- هدف البحث

يهدف هذا البحث إلى مقارنة تنبؤ بعض الشبكات العصبية التي تختلف فيما بينها من حيث وجود التغذية المتكررة في هيكليتها من عدمه مع منهجية (بوكس - جنكنز) في تحليل المتسلسلة الزمنية الخاصة بالمعدلات الشهرية لدرجات الحرارة العظمى لمدينة الموصل للمدة من 1983 إلى 2009 ، وقد تم الاعتماد على معيار متوسط مربعات الخطأ (MSE) للمقارنة بين الطريقتين .

Time Series

3- المتسلسلة الزمنية

تعرف المتسلسلة الزمنية بأنها متتابعة من قيم المشاهدة لظاهرة معينة مرتبة مع الزمن، وعادة ما تكون هذه القيم غير مستقلة، أي يعتمد بعضها على البعض، ويستغل عدم الاستقلال في التوصل إلى تنبؤات موثوق بها (فاندل ، 1983) ، (Bisgaard & Kulahci, 2011).

Time Series Analysis

4- تحليل المتسلسلات الزمنية

يعد موضوع تحليل المتسلسلات الزمنية من المواضيع الإحصائية المهمة التي تتناول سلوك الظواهر وتفسرها عبر حقب محددة ، ويمكن إجمال أهداف تحليل المتسلسلات الزمنية بالنقاط الآتية : (فاندل ، 1983)

- 1- الحصول على وصف دقيق لملامح العملية التي تتولد منها المتسلسلة الزمنية.
- 2- بناء أنموذج لتفسير سلوك المتسلسلة الزمنية، واستخدام النتائج للتنبؤ بسلوك المتسلسلة في المستقبل .
- 3- التحكم في العملية التي تتولد منها المتسلسلة الزمنية بفحص ما يمكن حدوثه عند تغيير بعض معلمات الأنموذج .

Stationarity of Time Series

5- المراوحة في المتسلسلات الزمنية

تفترض معظم الدراسات التطبيقية الاقتصادية التي تستخدم بيانات متسلسلة زمنية أن تكون المتسلسلة مراوحة او مستقرة؛ اذ تعد مراوحة البيانات عملية مهمة جداً في تحليل المتسلسلات الزمنية، وكذلك في ايجاد الانموذج الرياضي المناسب لها ، في حين أغلب المتسلسلات الزمنية تتصف بعدم المراوحة نتيجة عدم استقرار الظروف المحيطة، ويمكن من خلال رسم انتشار المتسلسلة الزمنية فحص دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي الحكم على مراوحة المتسلسلة من عدمها اذ لا يمكن الحصول على تنبؤات موثوقة إلا إذا كانت المتسلسلة مراوحة؛ ولهذا يمكن أن تقسم المتسلسلات الزمنية إلى قسمين : (المحمدي و طعمة، 2011)

Stationary Time Series

1-5 المتسلسلات الزمنية المراوحة

يقال للمتسلسلة الزمنية بأنها مراوحة (Stationary) إذا لم يكن هناك نمو أو انحراف في البيانات (عدم ظهور اتجاه عام) أي تبعثر البيانات أفقياً حول متوسط ثابت ، بعبارة أخرى تذبذب البيانات حول وسط حسابي ثابت مستقل عن الزمن، وكذلك يكون التباين ثابتاً عبر الزمن (محمد ، 2011) .

Non-Stationary Time Series

2-5 المتسلسلات الزمنية غير المراوحة

إن معظم الظواهر التطبيقية والعملية في المتسلسلات الزمنية تتصف بخاصية عدم المراوحة، وذلك لأحد الأسباب الآتية :

- 1- وجود اتجاه عام .

2- وجود تقلبات موسمية .

3- عدم ثبات التباين أو الوسط الحسابي عبر الزمن .

لذلك يطلق عليها متسلسلة غير مراوحة ، والمشي العشوائي أحد الأمثلة لهذه المتسلسلات (Tsay , 2010) .

Time Series Models

6- نماذج المتسلسلات الزمنية

فيما يأتي نماذج بوكس-جنكنز للمتسلسلات الزمنية الموسمية وغير الموسمية الشائعة :

6-1 نماذج المتسلسلات الزمنية المراوحة (غير الموسمية) (Box and Jenkins,1976)

(Non - Seasonal) Stationary Time Series Models

Autoregressive Model (AR)

1- أنموذج الانحدار الذاتي

يُقال لمتسلسلة زمنية بأنها عملية انحدار ذاتي من المرتبة الأولى AR(1)، إذا أمكن التعبير عن القيمة الحالية للمتسلسلة الزمنية Z_t على أنها دالة خطية للقيمة السابقة للمتسلسلة Z_{t-1} إضافة للخطأ العشوائي الحالي a_t . وبصورة عامة فإن صيغة أنموذج الانحدار الذاتي من المرتبة (p)، الذي يرمز له بـ AR(p) يكون وفق المعادلة الآتية :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$

إذ إن :

ϕ_1, \dots, ϕ_p : تمثل معاملات أنموذج الانحدار الذاتي .

a_t : هو عبارة عن الخطأ العشوائي .

Moving Average Model (MA)

2- أنموذج المتوسطات المتحركة

يُقال لمتسلسلة زمنية بأنها عملية وسط متحرك من المرتبة الأولى MA(1) إذا أمكن التعبير عن القيمة الحالية على أنها دالة خطية لقيمة الخطأ العشوائي الحالي a_t والخطأ العشوائي السابق a_{t-1} للمتسلسلة ، وبصورة عامة فإن أنموذج الوسط المتحرك من المرتبة (q) يرمز له MA(q) عند وجود (q) من القيم السابقة للخطأ العشوائي a_t وصيغته تكتب وفق المعادلة الآتية:

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2)$$

إذ أن :

$\theta_1, \dots, \theta_q$: تمثل معاملات أنموذج المتوسطات المتحركة .

3- أنموذج الانحدار الذاتي والمتوسطات المتحركة (الأنموذج المختلط)

Autoregressive Moving Average Model ARMA(p,q)

الكثير من المتسلسلات الزمنية لا يمكن تمثيلها بأنموذج انحدار ذاتي (AR) فقط أو أنموذج متوسطات متحركة (MA) فقط؛ لأنَّ هناك ظواهر تفشل في وصفها لوحدها لذلك تمثل بالأنموذج المختلط (الانحدار ذاتي و المتوسطات المتحركة) ، ويكتب اختصاراً $ARMA(p,q)$ ، إذ أن P تمثل مرتبة الانحدار الذاتي و q مرتبة المتوسطات المتحركة وتعرف الصيغة العامة لهذا الأنموذج بالآتي :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad . . . \quad (3)$$

2-6 نماذج المتسلسلات الزمنية الموسمية Seasonal Time Series Models

إن النماذج الموسمية للمتسلسلات الزمنية هي النماذج غير الموسمية نفسها مضافاً إليها S للدلالة على الموسمية (Seasonal) ، ويقال للمتسلسلة الزمنية موسمية إذا كانت تعيد نفسها بعد أوقات زمنية ثابتة (المحمدي وطعمة، 2011) . ونماذجها هي:

1- أنموذج الانحدار الذاتي الموسمي Seasonal Autoregressive Model

يقال للمتسلسلة الزمنية بأنها تتبع عملية انحدار ذاتي موسمي من المرتبة الأولى $AR(1)_S$ ، إذا أمكن التعبير عن المشاهدة الحالية للمتسلسلة (Z_t) كدالة خطية في مشاهدة المتسلسلة التي حصلنا عليها في الموسم نفسه من السنة السابقة (Z_{t-s}) ، فضلاً عن تغير عشوائي (a_t) ، وبصورة عامة فإنَّ أنموذج الانحدار الذاتي الموسمي من المرتبة p فيمكن التعبير عنه بالصيغة الآتية:

$$Z_t = \phi_1 Z_{t-s} + \phi_2 Z_{t-2s} + \dots + \phi_p Z_{t-ps} + a_t \quad (4)$$

إذ إن :

ϕ_1, \dots, ϕ_p : تمثل معاملات أنموذج الانحدار الذاتي الموسمي .

2- أنموذج المتوسطات المتحركة الموسمية Seasonal Moving Average

2- أنموذج المتوسطات المتحركة الموسمية

يمكن التعبير عن أنموذج المتوسطات المتحركة الموسمي من المرتبة q بالصيغة الآتية:

$$Z_t = a_t - \theta_1 a_{t-s} - \theta_2 a_{t-2s} - \dots - \theta_q a_{t-qs} \quad . . . \quad (5)$$

إذ إن :

$\theta_1, \dots, \theta_q$: تمثل معاملات أنموذج المتوسطات المتحركة الموسمية .

3- أنموذج الانحدار الذاتي و المتوسطات المتحركة الموسمية المختلطة

Seasonal Mixed Autoregressive Moving Average Model

يشار لأنموذج عملية موسمية مختلطة من المرتبة (p,q) بالرمز $ARMA(P,Q)_S$ ويأخذ الصيغة الآتية : (فاندل ، 1983) .

$$Z_t = \phi_1 Z_{t-s} + \dots + \phi_p Z_{t-ps} + a_t - \theta_1 a_{t-s} - \dots - \theta_q a_{t-qs} \quad (6)$$

7- منهجية بوكس-جنكنز في تحليل المتسلسلات الزمنية

Box-Jenkins Methodology in Time Series Analysis

إن منهجية بوكس - جنكنز تعتمد على دراسة نظامية للمتسلسلات الزمنية انطلاقاً من مواصفاتها من أجل تحديدها ضمن عائلة نماذج ARIMA، وتحديد الأنموذج الملائم للظاهرة المدروسة ، وتتم هذه المنهجية بأربع مراحل هي : (فاندل ، 1983) ، (Box and Jenkins,1976).

1- التعرف على المواصفات الأولية للأنموذج

Model Identification

أولى خطوات بناء أنموذج Box-Jenkins هي تحديد مراوحة المتسلسلة من عدمه ، وفي حالة المراوحة هل هناك تغيرات موسمية ؟ وبعد التأكد من مراوحة المتسلسلة تبدأ مرحلة التعرف على الأنموذج الملائم للبيانات ويتم ذلك من خلال دراسة دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي عن طريق رسم هاتين الدالتين اللتين تظهران بشكل اضمحلال تدريجي بطيء . وتستخدم معايير المعلومات لتحديد الأنموذج الأكثر ملائمة للبيانات من بين النماذج المرشحة؛ إذ يتم اختيار الأنموذج الذي يعطي أقل قيمة لهذه المعايير ، ومنها معيار اكاكي AIC الذي أقترحه Akaike (1974) وصيغته :

$$AIC = n \ln(\hat{\sigma}_a^2) + 2m$$

ومعيار بيز BIC الذي أقترحه Schwarz (1978) وصيغته :

$$BIC(m) = n \ln(\hat{\sigma}_a^2) + m \ln(n) \quad \dots\dots\dots(8)$$

ولقد اقترح كل من Brockwell and Davis (1993) تصحيح حالة التحيز في معيار AIC بإضافة المقدار $2mn/(n-m-1)$ ، ويستعمل AIC_c حينما تكون m كبيرة نسبة إلى حجم العينة n (Bisgaard and Kulahci, 2011) وصيغته :

$$AIC_c(m) = n \ln(\hat{\sigma}_a^2) + \frac{2mn}{(n-m-1)} \quad (9)$$

إذ إن :

m : عدد المعلمات في النموذج .

n : عدد المشاهدات .

$\hat{\sigma}_a^2$: مقدار تباين البواقي .

Model Estimation

2- تقدير النموذج

بعد أن تم التعرف على النماذج المحتملة التي تمثل بيانات المتسلسلة الزمنية قيد الدراسة، وتحديد المرتبة المناسبة لها نقوم بتقدير معالم النموذج المختار، وغالباً السبب الرئيس لتقدير النموذج هو لاستخدامه لحساب تنبؤات المتسلسلة الزمنية .

Diagnostic Checking

3- فحص مدى ملائمة النموذج

بعد مرحلة التعرف بالنموذج وتقدير المعلمات تأتي مرحلة الفحوص التشخيصية، أي اختبار صحة النموذج واختبار حد الخطأ ، إذ إن البواقي Residuals يجب أن تكون تشويشاً أبيض (مستقلة وتتبع التوزيع الطبيعي بمتوسط صفر وتباين σ_a^2) .

Prediction

4- التنبؤ

إن أحد الأهداف الأساسية لتحليل المتسلسلات الزمنية هو التنبؤ ، فبعد تشخيص النموذج وتقدير معلماته وتخطيه مرحلة الفحوص التشخيصية يصبح جاهزاً لاستخدامه للتنبؤ بمشاهدات مستقبلية، إذ حيث يعد ملائماً ويتطابق مع البيانات الأصلية إذا كان له أقل متوسط مربعات لخطأ التنبؤ (محمد ، 2011) .

Criterion test Prediction Accuracy

8- معيار اختبار الدقة التنبؤية

Mean Square Error (MSE)

1-8 متوسط مربعات الخطأ

يستخدم هذا المعيار لاختيار النموذج الأفضل في تمثيل البيانات وبحسب وفق الصيغة

الآتية: (Tsay , 2010) .

$$MSE = \frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2 \quad . . . (10)$$

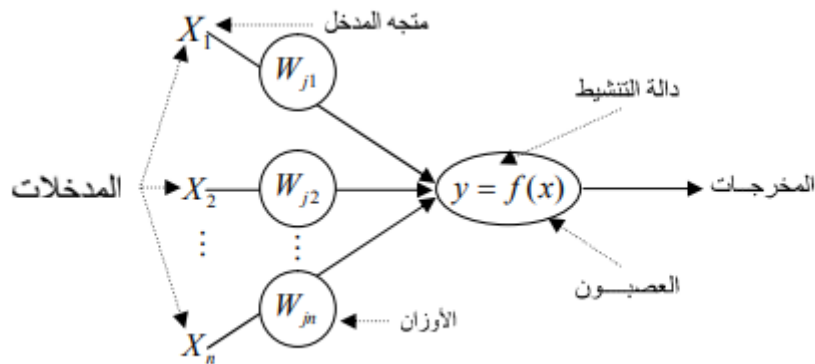
Artificial Neural Networks

9- الشبكات العصبية الاصطناعية

الشبكات العصبية الاصطناعية ANNs عبارة عن نظام معالجة للمعلومات يستند على نماذج رياضية بسيطة لها مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية الحيوية (النظام العصبي) ، وذلك عن طريق معالجة ضخمة موزعة على التوازي ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد أو خلايا Nodes, Neurons, Cells، التي لها خاصية عصبية اذ تقوم بتخزين المعرفة العملية والمعلومات لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان . وتستخدم الشبكات العصبية في الكثير من المجالات و التطبيقات منها معالجة الإشارة Signal Processing ، السيطرة Control ، تمييز الأنماط Pattern Recognition ، تمييز الكلام Speech Recognition (Moreno,et al.,2011).

9-1 مكونات الشبكة العصبية الاصطناعية Artificial Neural Network Components

كما أن للإنسان وحدات ادخال توصله بالعالم الخارجي وهي حواسه الخمس، كذلك فالشبكات العصبية الاصطناعية لها مدخلات تتمثل في وحدات المعالجة التي تتم فيها العمليات الحسابية التي تضبط بها الأوزان ونحصل عن طريقها على ردة فعل لكل مدخل من المدخلات للشبكة ، فوحدات الإدخال تسمى طبقة المدخلات ووحدات المعالجة تكون طبقة المعالجة التي تقوم بإخراج نتائج الشبكة تدعى طبقة المخرجات . وبين كل طبقة من هذه الطبقات هنالك طبقة من الوصلات البينية تربط كل طبقة بالطبقة التي تليها، التي يتم فيها ضبط الأوزان الخاصة بكل وصلة بينية Weights، وهذه الأوزان تمثل المعلومات التي ستبدأ بها الشبكة بحل المشكلة. والشكل الآتي يوضح مكونات الشبكة العصبية الاصطناعية (عيسى ، 2000) .



الشكل (1) : يوضح مكونات الشبكة العصبية الاصطناعية

إذ إن :

- X : يمثل متجه الإدخال الذي يضم مجموعة الإدخال وهي X_1, X_2, \dots, X_n
- W : يمثل متجه الأوزان الذي يضم مجموعة الأوزان W_1, W_2, \dots, W_n

تتميز كل شبكة عصبية من الأخرى بما يأتي: (زكي ، 2008)

- 1- شكل الترابط بين العصبونات التي تقرر هيكل الخلية (بالمعمارية) .
- 2- الطريقة التي تحدد الأوزان لهذه الترابطات (تدريب الخوارزمية) .
- 3- نوع دالة التنشيط المستخدمة أو تابع التنشيط Activation Function .

2-9 هيكلية الشبكة العصبية الاصطناعية ANN Structure

يقصد بهيكلية الشبكة العصبية الاصطناعية ترتيب العقد في مستويات أو طبقات وشكل الترابط ضمن الطبقات أو بينها، فهي تعد من أهم الخصائص التي توصف على أساسها الشبكة العصبية (عيسى ، 2000) .

وتصنف الشبكات بحسب عدد مستوياتها (طبقاتها) إلى صنفين رئيسين :

1- شبكات وحيدة المستوى أو الطبقة Single-Level or Layer Network

وهي الشبكات التي لا تمتلك طبقة مخفية فهي تتكون من طبقتين فقط طبقة إدخال تستقبل الإشارة من الخارج، وطبقة إخراج التي نحصل منها على استجابة الشبكة وتوضع الترابطات بينهما ، ومن أمثلة هذه الشبكات شبكة المدرك وشبكة هوبفيلد Hopfield (Moreno,et al.,2011) .

2- شبكات متعددة المستويات (الطبقات) Multi-level Network

تمتلك هذه الشبكات طبقة مخفية واحدة أو أكثر تعمل على زيادة قدرة الشبكة على معالجة البيانات، ومن عيوبها أنها تبطئ من عملية المعالجة ولكن ميزتها إيجاد الحل الأمثل لاية مشكلة معقدة، ومن الأمثلة عليها شبكة التغذية الأمامية FFNN (Moreno,et al.,2011) .

10- معالجة المعلومات في الشبكة العصبية الاصطناعية (التعلم و التدريب)

Information Processing in ANN (Learning and Training)

يقصد بمعالجة المعلومات في الشبكات العصبية مرور البيانات بمرحلة أساسية هي مرحلة

التعلم أو التدريب Training or Learning Step .

10-1 مرحلة التعلم أو التدريب Training or Learning Step

إن التدريب في الشبكات العصبية الاصطناعية يقصد به عملية تعديل وضبط الأوزان لجعل الخلية تطلق إشارة استجابة للمدخلات، وذلك بهدف تقليل الخطأ في مخرجات الشبكة . والتدريب في الشبكات العصبية يتم وفق طريقتين هما التدريب بإشراف


(Supervised Training)، أي وجود مدرب أو معلم ليعلم الشبكة بالمرجات المرغوب فيها، وتعد خوارزمية انتشار الخطأ الخلفي (Error Back Propagation) مثالاً لهذا النوع. أما التدريب بدون إشراف (Unsupervised Training) فهو تكيف الشبكة للاستجابة للمدخلات واختيارها للهيكلية من المدخلات فقط، لهذا يطلق عليها طريقة التعليم الذاتي (Self-Supervised Learning) لعدم استخدامها لمعلم خارجي (Idowu et al., 2012)، (Shen & Chang, 2013).

11- أنواع الشبكات العصبية الاصطناعية Types of ANN

إن الشبكات العصبية الاصطناعية تكون على نوعين: شبكات ثابتة (Static Network) وشبكات حركية (Dynamic Network) التي تعد امتداداً للشبكات العصبية الثابتة، إذ إن الشبكات الثابتة ليس لها عناصر تغذية عكسية (Feedback) ولا تمتلك تأخيراً زمنياً (Delay time)، أما الشبكات الحركية فهي تحتوي في الأقل على طبقة واحدة ذات تغذية متكررة، وهذا النوع من الشبكات المخرجات لا تعتمد فيه على مدخلات الشبكة فقط، وإنما تعتمد أيضاً على المدخلات والمخرجات السابقة، فالإشارة في هذا النمط من الشبكات العصبية تتجه نحو الإخراج بالاتجاه العكسي لتكون إدخالاً في الوقت نفسه، لذا يطلق عليها بالشبكات الحركية (الديناميكية) (Sahoo et al., 2015). وهنا لا بد من الإشارة إلى وجود نوعين من التغذية في الشبكات العصبية يمكن أن تصنف على أساسها هي:

11-1 الشبكات العصبية ذات التغذية الأمامية Feed Forward Neural Networks

يكون فيها انتشار الإشارات الداخلة إلى الشبكة إلى الأمام دائماً؛ إذ تتجه جميع خطوط الربط باتجاه واحد من طبقة الإدخال حتى طبقة الإخراج، وبذلك فإن الإشارة الخارجة من أية خلية تعتمد على الإشارات الداخلة فقط كما هو موضح في الشكل الآتي: (Gupta, 2006).



الشكل (2) : يوضح تركيب الشبكة العصبية ذات التغذية الامامية FFNN

وهناك عدة خوارزميات لتدريب هذا النوع من الشبكات أهمها :

1-1-11 خوارزمية الانتشار العكسي للخطأ Error Back Propagation Algorithm

تعد من أكثر الخوارزميات استعمالاً، فهي تسعى إلى تقليل مربع الخطأ الكلي عند التدريب، وبالتالي الحصول على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم ، وهذا هو الهدف من تدريب الشبكات العصبية الاصطناعية . فهي تستخدم التدريب بإشراف (Supervised Training) هذا يعني تزويد الشبكة بمثال الإدخال والإخراج . إن تدريب الشبكة العصبية الاصطناعية باستخدام الانتشار العكسي ، تتضمن ثلاث مراحل هي: (Idown et al. , 2012)

- 1- مرحلة الانتشار الأمامي لعينات التدريب .
- 2- مرحلة الانتشار الخلفي للخطأ .
- 3- مرحلة توليف أوزان الشبكة .

وخوارزمية الانتشار العكسي للخطأ يمكن أن نلخصها بالخطوات الآتية: (Gupta , 2006)

- 1- تهيئة قيم أولية للأوزان، واختيار زوج التدريب من مجموعة التدريب .

مرحلة الانتشار الأمامي (التغذية بالاتجاه الأمامي)

- 2- تستقبل كل عقدة في طبقة المدخلات إشارة دخلها، إذ إن $(X_i ; i=1,2,\dots,n)$ ، ثم ترسلها إلى جميع عقد الطبقة المخفية.
- 3- تجمع كل عقدة في الطبقة المخفية $(H_j ; j=1,2,\dots,p)$ قيم وإشارات إدخالها الموزونة وبما يأتي:

$$H_j = V_{oj} + \sum_{i=1}^n X_i V_{ij} \quad \dots \quad (11)$$

بعد ذلك تطبق دالة التنشيط لبحث إشارة إخراجها

$$h_j = f(H_j - \theta_j) \quad \dots \quad (12)$$

وترسل قيم التنشيط إلى عقد طبقة الإخراج جميعها .

- 4- تجمع كل عقدة في طبقة المخرجات $(Y_k ; k=1,2,\dots,m)$ إشارة دخلها الموزونة وبما يأتي :

$$Y_k = W_{ok} + \sum_{j=1}^p h_j W_{jk} \quad \dots \quad (13)$$

وبعد ذلك نطبق تابع التنشيط لحساب إشارة الإخراج لكل عقدة في طبقة المخرجات

$$y_k = f(Y_k - \theta_k) \quad \dots \quad (14)$$

مرحلة الانتشار الخلفي للخطأ

5- يحسب الخطأ (E_k) لعقد الإخراج عن طريق الفرق بين مخرجات العقد (y_k) والقيمة الحقيقية للعقدة (t_k)، أي إنَّ:

$$E_k = t_k - y_k \quad \dots (15)$$

ثم مقارنة مخرجات الشبكة العصبية مع القيم الحقيقية لتقدير الخطأ حسب الصيغة :

$$\delta_k = (t_k - Y_k) \cdot f'(Y_k - \theta_k) \quad \dots (16)$$

ثم نحسب التغير في حجم الخطأ ΔW_{jk} حسب المعادلة :

$$\Delta W_{jk} = \eta \cdot \delta_k \cdot h_j \quad \dots (17)$$

وحساب حد تصحيح انحيازها (المستخدم لتحديث الوزن W_{ok} لاحقاً)

$$\dots (18)$$

$$\Delta W_{ok} = \eta \cdot \delta_k$$

6- تجمع كل عقدة في الطبقة المخفية إشارات المدخلات الموزونة الـ δ كما في المعادلة :

$$\Delta_j = \sum_{k=1}^m \delta_k W_{jk} \quad \dots (19)$$

وتضرب هذه القيمة بمشتقة تابع تنشيطها لحساب δ_j

$$\delta_j = \Delta_j \cdot f'(H_j - \theta_j) \quad \dots (20)$$

ثم نحسب التغير في حجم الخطأ ΔV_{ij}

$$\Delta V_{ij} = \eta \cdot \delta_j \cdot X_i \quad \dots (21)$$

بعدها يحسب حد تصحيح تحيزها (المستخدم لتحديث الوزن V_{oj} لاحقاً)

$$\Delta V_{oj} = \eta \cdot \delta_j \quad \dots (22)$$

مرحلة تحديث الأوزان والتحييزات

7- تحدث الأوزان والتحييزات لكل عقدة في طبقة المخرجات بموجب المعادلة الآتية :

$$W_{jk} (new) = W_{jk} (old) + \Delta W_{jk} \quad ; \quad j=0, \dots, p \quad \dots (23)$$

وكذلك تحدث الأوزان والتحييزات بالنسبة لكل عقدة في الطبقة المخفية بموجب المعادلة الآتية :

$$V_{ij} (new) = V_{ij} (old) + \Delta V_{ij} \quad ; \quad i=0, \dots, n \quad \dots (24)$$

بعدها يطبق تابع تنشيطها لتقدير مخرجات عقد الطبقة المخفية .

8- تستمر الشبكة في تحديث الأوزان لغاية الحصول على الأوزان المثلى ، ثم الحصول على المخرجات المرغوب فيها، أي التوصل إلى أفضل توفيق لأنموذج قيد البحث (بمعنى اختبار شرط التوقف) .

اذ إن :

$$T = (t_1, \dots, t_k, \dots, t_m) \quad \text{(الإخراج المطلوب)}$$

θ : تمثل العتبة Threshold (دالة غير خطية تعرف بدالة التنشيط يتم بواسطتها معالجة مخرجات كل عقدة).

δ_k : عامل تصحيح الخطأ لتوليف الوزن W_{jk}

δ_j : عامل تصحيح الخطأ لتوليف الوزن V_{ij} .

V_{ij} : أوزان مستوى المدخلات إلى المستوى المخفي .

W_{jk} : أوزان المستوى المخفي إلى المستوى المخرجات .

η : تمثل معدل التعلم (Learning Rate)، ويستخدم للتحكم في توليف الوزن خلال كل خطوة في مرحلة التدريب.

H_j : تمثل وحدة الطبقة المخفية ذات الدليل z ، وإخراج وحدات الطبقة المخفية H_j يرمز لها بالرمز h_j .

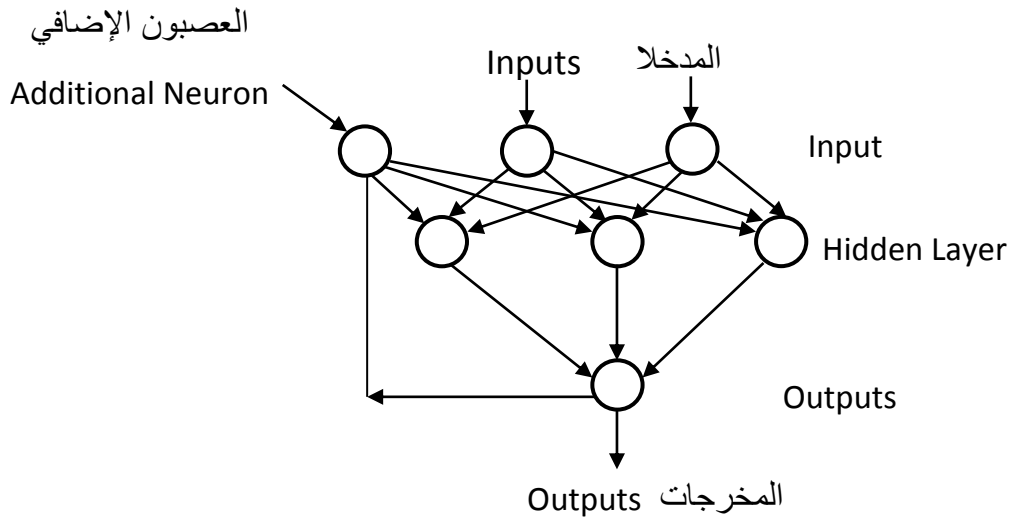
Y_k : تمثل وحدة طبقة الإخراج ذات الدليل k ، وإخراج هذه الوحدة (تنشيطها) يرمز له بالرمز y_k

V_{0j} : تمثل التحيز على وحدة الطبقة المخفية ذات الدليل j .

W_{0k} : تمثل التحيز على وحدة طبقة الإخراج ذات الدليل k .

2-11 الشبكات العصبية ذات التغذية الخلفية (التكرارية) (Feed back (Recurrent) Neural Networks

في هذه الشبكات من الممكن أن تعاد تغذية (كل أو بعض) الإشارات الخارجة من الشبكة، وتحويل اتجاهها لتصبح إشارة داخلة أيضا (إعادة تغذية)، وبذلك فإن الإشارة الخارجة من أية خلية تعتمد على الإشارات الداخلة إليها، فضلاً عن الإشارات الخارجة منها في وقت سابق ، والشكل الآتي يوضح هذا النوع من الشبكات ، كما أنّ خوارزمية التدريب هي خوارزمية الانتشار العكسي نفسها (Sahoo et al. , 2015) . ومن الأمثلة عليها شبكة Elman & NARX (Gupta,2006) .




الشكل (3) : يوضح تركيب الشبكة العصبية التكرارية RNN

Elman Neural Network(ENN)

11-2-1 شبكة أيلمان العصبية

تتكون شبكة إيلمان Elman من عدة طبقات من الخلايا: طبقة الإدخال والطبقة الوسطى، وتسمى الطبقة المخفية، إذ ترتبط كل طبقة في الشبكة بالطبقة التي تليها ارتباطاً إمامياً (feedforward)، بالإضافة إلى هذا الارتباط فإن خلايا الطبقة المخفية ليست مرتبطة فقط مع طبقة المخرجات، ولكن مرتبطة بطبقة أخرى أيضاً تسمى طبقة السياق (Context Layer) لتشكل اتصالات متكررة، ومخرجات طبقة السياق هي مدخلات للطبقة المخفية أيضاً أما الطبقة الأخيرة فهي طبقة الإخراج، وهيكلية هذه الشبكة موضحة بالشكل الآتي .



الشكل (4) : يوضح التركيب العام لشبكة Elman

تستخدم هذه الشبكة خوارزمية الانتشار العكسي للخطأ (BP) مع وجود اتصالات متكررة عكسية في الطبقة المخفية، كما هو موضح في المعادلات الآتية : (Sahoo et al , 2015) .

$$h_t = \sigma_h (W_h x_t + U_h h_{t-1} + b_h) \quad \dots \quad (25)$$

$$y_t = \sigma_y (W_y h_t + b_y) \quad \dots \quad (26)$$

إذ إن :

x_t : متجه الادخال

h_t : متجه الطبقة المخفية .

y_t : متجه الاخراج .

U ، b and W : متجه ومصفوفة المعلمات .

σ_h and σ_y : دوال التنشيط

11-2-2 شبكة الانحدار الذاتي غير الخطي بمدخلات إضافية أو خارجية

Nonlinear Autoregressive with Exogenous Input (NARX)

تعد هذه الشبكة نوعاً من أنواع الشبكات الحركية المتكررة القوية التي تستخدم للتنبؤ بالمتسلسلات الزمنية ، فهي تمتلك تأخيراً زمنياً Delay Time ومعماريتها مبنية على أساس الشبكة العصبية متعددة الطبقات فهي تتكون من ثلاث طبقات من الخلايا: طبقة الإدخال والطبقة المخفية وطبقة الإخراج ، إذ ترتبط كل طبقة في الشبكة بالطبقة التي تليها ارتباطاً إمامياً (feedforward)، بالإضافة إلى هذا الارتباط فإن الإشارة الخارجة من خلايا طبقة الإخراج تعد مدخلات إضافية (External) باتصالات تغذية متكررة (feedback) مرفقة بأوزان لخلايا الطبقة المخفية، وهذا سيؤدي إلى سرعة وصول الشبكة إلى المراوحة ، كما أنها تستخدم خوارزمية الانتشار الخلفي أيضاً (BP) لتصحيح الخطأ (Shen & Chang , 2013)، بالإضافة لاتصالات تغذية عكسية من طبقة الاخراج لطبقة الادخال كما هو موضح في المعادلة والشكل الآتيين :

$$y(t) = f(u(t), u(t-1), u(t-2), \dots, u(t-d), y(t-1), y(t-2), \dots, y(t-d))$$

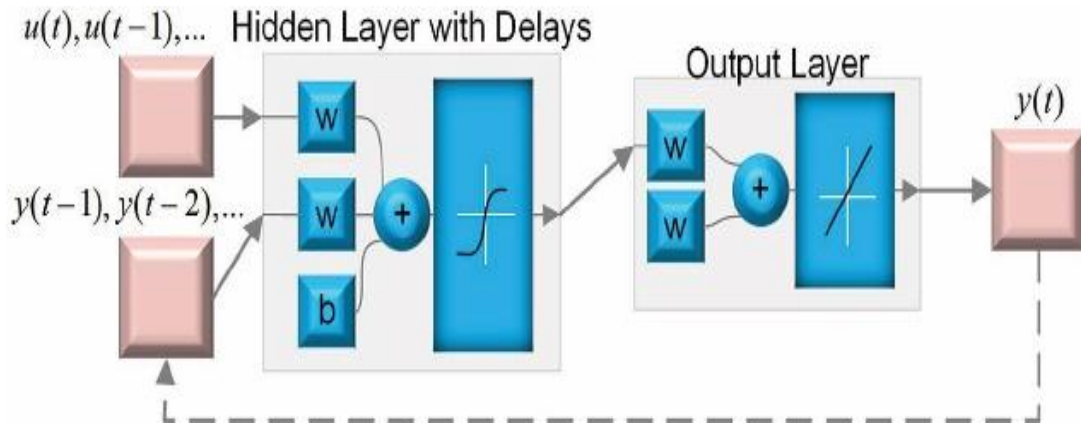
إذ أن :

f : هي دالة غير خطية Nonlinear Function . ، d : زمن التأخير

. Delay Time

u : تمثل إشارة الإدخال Input Signal . ، y : إشارة الإخراج

.Output Signal



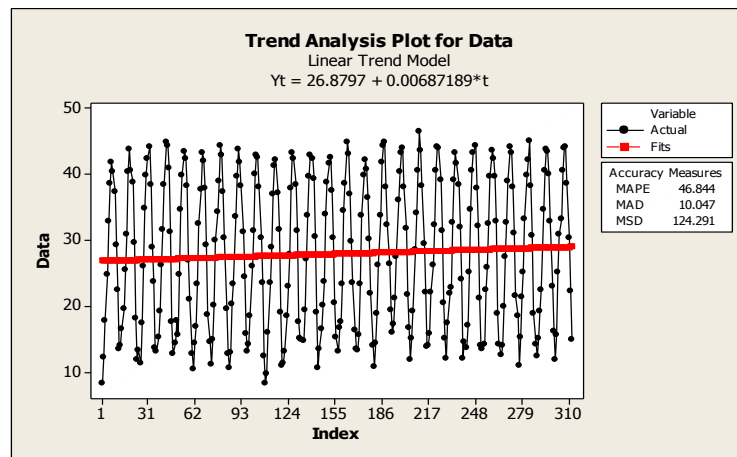
الشكل (5) : يوضح التركيب العام لشبكة NARX

12- الجانب التطبيقي

12-1 التنبؤ باستخدام منهجية بوكس - جنكنز

تم تطبيق منهجية بوكس - جنكنز على بيانات المعدلات الشهرية لدرجات الحرارة لمدينة الموصل المستحصل عليها من مديرية الأنواء الجوية في محافظة نينوى، وتم التحليل باستخدام البرنامج الإحصائي Minitab .


بدايةً قمنا بتحليل البيانات ويبين الشكل (6) رسم الاتجاه العام لهذه المتسلسلة، ويتضح بأنه ليس هناك تشتت واضح، وهذا يدل على أنها مراوحة في التباين .




الشكل (6) : يوضح رسم الاتجاه العام للمتسلسلة

من ملاحظة الشكل (7) نجد أن دالة الارتباط الذاتي (ACF) تظهر سلوكاً موسمياً لا يهبط بسرعة إلى الصفر، وهذا يدل على أن المتسلسلة غير مراوحة موسمياً وبحاجة إلى أخذ الفرق

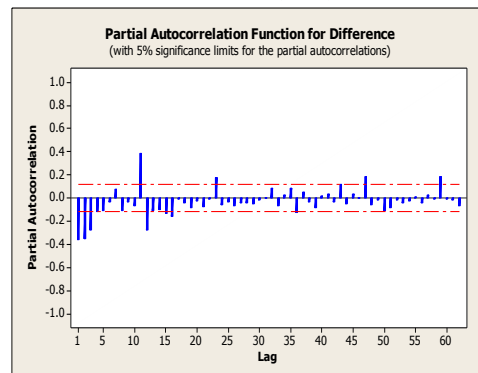

الموسمي عند التخلف 12 مع اخذ الفرق الاعتيادي الأول للبيانات لجعلها مراوحة، إذ إن الهدف ليس إزالة جميع العناصر الموسمية، بل التوصل إلى المراوحة والحصول على متسلسلة جديدة يمكن تحليلها والتنبؤ بها بطريقة أكثر كفاءة .



الشكل (7) : يوضح دالة الارتباط الذاتي للملاحظات الأصلية



الشكل (8) : يوضح سلوك مشاهدات المتسلسلة بعد تحويلها إلى متسلسلة مراوحة



(a) دالة الارتباط الذاتي (ACF) (b) دالة الارتباط الذاتي الجزئي (PACF)

الشكل (9) a ، b : يوضح دالة الارتباط الذاتي والذاتي الجزئي للمتسلسلة المروحة

يظهر الشكل (8) مروحة المتسلسلة بعد أخذ الفرق الموسمي والاعتيادي لها ومن خلال فحص كل من دالة الارتباط الذاتي (ACF)، ودالة الارتباط الذاتي الجزئي (PACF) في الشكل (9) (b,a). وتبين أن الأنموذج الموسمي الملائم للبيانات هو $ARIMA(0,1,2) (0,1,1)_{12}$ ؛ إذ كانت له الأفضلية على النماذج الأخرى المختبرة .

Final Estimates of Parameters

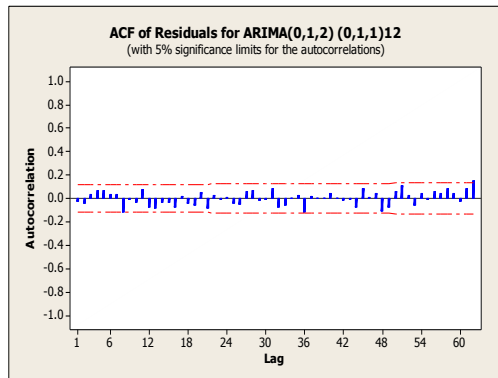
Type	Coefficient	Std.Error Coef	t-Statistic
MA(1) 0.000	0.6696	0.0566	11.84
MA(2) 0.000	0.2132	0.0570	3.74
SMA(12) 0.000	0.9242	0.0372	24.82

Number of observations: 299


MSE = 2.739

AIC = 307.27 AIC_c = 307.35 BIC = 318.37

فمن ملاحظة النتائج نلاحظ بأن القيمة المطلقة لجميع معاملات الأنموذج المختار (معلمتي المتوسطات المتحركة MA(1) & MA(2) ومعلمة المتوسطات المتحركة الموسمية SMA(12)) هي أكبر من ضعف الخطأ المعياري SE لكل منها ، كما يلاحظ بأن القيمة المطلقة لجميع قيم الاحصاء t أكبر من 2، وان قيمة الاحتمالية P لجميع المعلمات المقدره هي أقل من 0.05 ، كما اعطى الانموذج أقل قيمة لـ MSE ولجميع المعايير المطبقة .



(a) دالة الارتباط الذاتي للبقايا




(b) دالة الارتباط الذاتي الجزئي للبقايا

الشكل (10) a , b : يوضح دالة الارتباط الذاتي والذاتي الجزئي لبواقي أنموذج

$ARIMA(0,1,2) (0,1,1)_{12}$

مما تقدم نستنتج بأن الأنموذج $ARIMA(0,1,2) (0,1,1)_{12}$ هو الملائم للتنبؤ بالبيانات المتاحة؛ لأنه نجح في اختبار معنوية المعلمات المقدره، فضلاً عن نجاحه في اختبار تحليل البواقي الموضح في الشكل (10) .



الشكل(11): يوضح مقارنة بين قيم التنبؤ والقيم الحقيقية للمعدلات الشهرية لدرجات الحرارة في

مدينة الموصل لأشهر عام 2009

من خلال الشكل المذكور في أعلاه نلاحظ بأن قيم التنبؤات تسلك سلوك قيم المتسلسلة الأصلية نفسها لعام 2009.

12-2 التنبؤ باستخدام الشبكات العصبية الاصطناعية:

تم تصميم برنامج حاسوبي للحصول على قيم التنبؤ لمتسلسلة المشاهدات دون الحاجة لمعالجة عدم المراوحة باستخدام نظام التحليل والبرمجة الماتلاب (Matlab,R2013a) ، اذ تضمن البرنامج مرحلتين رئيسيتين ، المرحلة الأولى: هي إعداد البيانات Preprocessing Data، اي تحويلها إلى الصيغة القياسية Normalize وتحديد مدخلات الشبكة العصبية ، أما المرحلة الثانية فشملت تقسيم البيانات إلى مجموعة بيانات تدريب Training set ومن ضمنها بيانات التدقيق Validation set ، ومجموعة بيانات الاختبار Testing set . فبعد تهيئة البيانات لإدخالها إلى الشبكة تم تصميم الشبكة إذ تكونت من ثلاثة أطوار رئيسية هي طور التدريب والتحقق والاختبار .

12-2-1 طور التدريب:

تم تكوين وتدريب الشبكة العصبية ذات التغذية الأمامية FFNN باستخدام دالة newff ، إذ دربت شبكة FFNN على إعطاء قيم أقرب ما تكون لبيانات الهدف؛ وذلك بإدخال ومعالجة بيانات التدريب Training set ، فبعد إجراء العديد من التجارب تم اختيار العدد 30000 لدورات التدريب وبنسبة خطأ 0.001، وتبين أن أفضل معمارية للتنبؤ بالملاحظات المستقبلية للبيانات هي باختبار سبع عقد لطبقة الإدخال، واستخدام طبقتين مخفيتين في الأولى سبع والثانية عقدتين وعقدة إخراج واحدة .

وبالنسبة لشبكة ايلمان ENN فتم تكوين وتدريب هذه الشبكة باستخدام دالة newelm، إذ تم اختيار العدد 35000 لدورات التدريب وبنسبة خطأ 0.001 وتبين أن أفضل معمارية للتنبؤ بالملاحظات المستقبلية للبيانات هي باختبار ست عقد لطبقة الإدخال، واستخدام طبقتين مخفيتين لكل منهما أربع عقد وعقدة إخراج واحدة

أما شبكة NARX فتم تكوين وتدريب هذه الشبكة باستخدام دالة newnarx، إذ تم اختيار العدد 20000 لعدد دورات التدريب وبنسبة خطأ 0.001 وتبين أن أفضل معمارية للتنبؤ بالملاحظات المستقبلية للبيانات هي باختبار ثلاث عقد لطبقة الإدخال، واستخدام ثلاث طبقات مخفية احتوت الأولى والثانية على أربع عقد والثالثة على ثلاث عقد، وعقدة إخراج واحدة .

12-2-2 طور التحقق

تم في هذا الطور اختبار الشبكة عن طريق إدخال مجموعة بيانات التدقيق؛ إذ تقارن هذه البيانات مع البيانات المدربة التي حصلنا عليها في طور التدريب للحصول على تطابق مع بيانات الهدف، وبهذا يتم التحقق من أن الشبكة قد دربت بشكل جيد .

12-2-3 طور الاختبار

بعد إتمام عمليتي تدريب الشبكة والتحقق منها تم في هذا الطور إدخال بيانات الاختبار والأوزان المثالية المخزونة للشبكة لمعالجتها، وعمل اختبار لكفاءة الشبكة المدربة وقدرتها على إعطاء تنبؤ مقبول، وبهذا حصلنا على المخرجات المطلوبة من الشبكة .

13- المقارنة بين نتائج الطريقة الإحصائية والشبكات العصبية


الجدول المذكور في أدناه يوضح نتائج مقارنة التنبؤ بين منهجية (بوكس - جنكنز) والشبكات العصبية الاصطناعية باستخدام معيار MSE .

الجدول (1) : يوضح المقارنة بين منهجية (بوكس - جنكنز) وأنواع الشبكات العصبية الاصطناعية

اشهر السنة	القيم الحقيقية لدرجات الحرارة لعام 2009	منهجية بوكس - جنكنز	شبكة FFNN	شبكة ELNN	شبكة NARX
كانون الثاني	14.3	13.4192	13.4939	13.2181	13.4334
شباط	17.5	15.8719	15.5644	16.2762	15.3164
اذار	19.7	20.8782	19.6395	20.0944	19.6323
نيسان	25.8	26.6001	25.9699	25.8027	26.1103
ايار	34.2	34.2428	33.6874	33.9071	33.4038
حزيران	40.3	40.7232	39.8337	40.3407	39.6701
تموز	42.2	44.4695	43.1762	43.2843	42.8241
اب	41.4	44.1281	42.7760	42.8784	42.4148
ايلول	34.4	39.4091	37.9383	37.5515	38.5509
تشرين الاول	32.3	32.0227	29.7828	29.6100	30.9553
تشرين الثاني	20.4	22.3609	20.9135	21.0140	21.5256
كانون الاول	16	15.7129	13.6890	14.3296	15.1511
MSE		3.9475	2.6846	2.2173*	2.4246

*: أقل MSE

يتضح من الجدول (1) والشكل (12) أن أسلوب الشبكات العصبية الاصطناعية قد تفوق على منهجية (بوكس - جنكنز) ، إذ حققت شبكة ENN التي تميزت بالتغذية المتكررة في هيكليتها أفضل النتائج وبأقل خطأ تنبؤ لبيانات المعدلات الشهرية لدرجات الحرارة العظمى لمدينة الموصل .



الشكل (12) : يوضح مقارنة بين قيم تنبؤات أسلوب الشبكات العصبية الاصطناعية باستخدام الشبكات

(FFNN , ENN , NARX) ومنهجية (بوكس - جنكنز) لبيانات المعدلات الشهرية لدرجات الحرارة لمدينة الموصل عام 2009

الاستنتاجات Conclusions

خُصَّ البحث إلى عدد من الاستنتاجات نوجزها بالآتي :

1- تبين أن أسلوب الشبكات العصبية الاصطناعية أكثر دقة للتنبؤ بالقيم المستقبلية لمتسلسلة المعدلات الشهرية لدرجات الحرارة العظمى لمدينة الموصل مقارنة بمنهجية (بوكس-جنكنز)، إذ أعطت الشبكات نتائج تنبؤ ذات مواصفات مثالية من حيث الدقة والسرعة العالية في التنفيذ ، فقد حقق التنبؤ باستخدام شبكة ENN أفضل النتائج تليها شبكة NARX ثم شبكة FFNN ، ومن هذا التسلسل نستنتج بأن الشبكات التي تمتلك في هيكليتها مبدأ التغذية المتكررة مثل أيلمان و NARX أن نتائج التنبؤ لها أدق من تلك التي افتقدت هذا المبدأ في هيكليتها (شبكة التغذية الأمامية) ، في حين نجد بأن منهجية (بوكس-جنكنز) تفترض شروطاً صارمة لا يمكن تجاوزها منها المراوحة والخطية والطبيعية ، والكثير من الظواهر لا تنطبق عليها هذه الشروط على العكس من أسلوب الشبكات العصبية الذي يتحرر من هذه الشروط .

2- نستدل على أن ظاهرة درجات الحرارة لا تقاس فقط بناءً على الحرارة المنبعثة من الشمس، وإنما بناءً على متغيرات أخرى كذلك يسهم بها الإنسان، كالعازات المنبعثة من المعامل والمصانع على سبيل المثال، ولعل هذا يفسر أفضلية أداء الشبكات ذات التغذية العكسية .

التوصيات Recommendations

في ضوء الاستنتاجات التي تم التوصل إليها توصي الدراسة بما يأتي :

- 1- بما أن الكثير من الظواهر لا يتحقق فيها شرط المروحة والخطية والطبيعية فإنّ توظيف أسلوب الشبكات قد يحقق نتائج مشجعة .
- 2- يوصى باستخدام شبكات عصبية أخرى ذات هيكلية مختلفة مثل شبكة Jordan وغيرها للتعامل مع متسلسلة البيانات المستخدمة ومقارنة النتائج .
- 3- إعطاء ثقل أكبر في التعامل مع الشبكات العصبية الاصطناعية ذات التغذية المتكررة؛ وذلك لأنّ النظام الحركي (الديناميكي) لكثير من الظواهر قد يكون معقداً وغير واضح بصورة جلية ، وهذا ما يدفع الباحثين إلى إمكانية توظيف مبدأ التغذية المتكررة، والاستفادة منه عند دراسة مثل هذه الظواهر .
- 4- إجراء دراسات للتنبؤ بالقيم المستقبلية لمتسلسلات زمنية متعددة المتغيرات Multivariate Time Series باستخدام هذه الشبكات .

المصادر :

- 1- المحمدي، ناظم عبدالله و طعمة، سعدية عبدالكريم .(2011). " استخدام نماذج المتسلسلات الزمنية الموسمية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة "، مجلة جامعة الانبار للعلوم الاقتصادية والإدارية، المجلد 4، العدد 7، كلية الإدارة والاقتصاد (الفلوجة) ، ص [21-43] .
- 2- زكي، عزة حازم .(2008). "استخدام الشبكات العصبية في التنبؤ للسلاسل الزمنية ذات السلوك الاسي " ، المجلة العراقية للعلوم الاحصائية (13) ص [163-178] .
- 3- عيسى، علام زكي .(2000). " الشبكات العصبية، البنية الهندسية-الخوارزميات-التطبيقات"، الطبعة الأولى، شعاع للنشر والعلوم، حلب، سوريا.
- 4- فاندل، والتر .(1983). " المتسلسلات الزمنية من الوجهة التطبيقية ونماذج بوكس جنكنز "، تعريب عبد المرضي عزام ، المملكة العربية السعودية .

5-محمد، منعم عزيز .(2011). " التحليل والتنبؤ باستخدام المتسلسلات الزمنية " ، حكومة إقليم كردستان جامعة السليمانية .

- 6- Bisgaard, S. and Kulahci, M. (2011),"Time Series Analysis and Forecasting By Example " , Published by John Wiley & Sons, Inc., Hoboken, New Jersey .
- 7- Box, G. E. P. and Jenkins, G. M. ,(1976), "Time Series Analysis, Forecasting and Control " , Revised ed., Holden-Day, San Francisco, U.S.A.
- 8- Chatfield, Chris and Faraway, Julian,(1998), "Time Series Forecasting with Neural Networks: A Comparative Study using the airline data",Appl.Ststist.Part2,pp231-250
- 9- Gupta,C.(2006). "Implementation of Back Propagation Algorithm (of neural networks) In Vhdl", Department OF Electronics and Communication Engineering, (Deemed University) , Patiala-147004, India .
- 10- Idown, P. A., Osakwe, C., Kayode, A. A., and Adagunodo, E. R.(2012). "Prediction of Stock Market in Nigeria Using Artificial Neural Network", Published Online October 2012 in MECS (<http://www.mecspress.org/>) , PP. 68–74 .
- 11- Moreno, J. J.M., Pol, A. P., Gracia, P. M. (2011). " Artificial Neural Networks Applied to Forecasting time series " , Universidad de las Islas Baleares & Universidad Politecnica de Cataluna, Vol.23-No. 2, PP. 322-329, ISSN 0214 – 9915 .
- 12- Sahoo, P K and Satpathy, P K and Mohanty, M N. (2015), " Elman Neural Network Backpropagation Based Evaluation of Critical Busbars in Power Systems with Renewable Sources " ,International Journal of Renewable Energy Research Satpathy et al.,Vol.5,No.2.

- 13- Shen, H. Y. and Chang, L. C. (2013), " Online multistep-ahead inundation depth forecasts by recurrent NARX networks ", Published: 5 March 2013 , PP. 935–945 .
- 14- Tsay, R. S. (2010), "Analysis of Financial Time Series", 3rd ed., Published by John Wiley & Sons, New Jersey .
- 15- Yao, J. T. (2002). "Towards a Better Forecasting Model for Economic Indices", Department of Computer Science, University of Regina, Saskatchewan, Canada.