



اسم المقال: مقارنة بين التقنية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلاسل الزمنية
اسم الكاتب: أ.م.د. صفاء يونس الصفاوي، م. مثنىة عبدالله مصطفى
رابط ثابت: <https://political-encyclopedia.org/library/3149>
تاريخ الاسترداد: 2026/04/13 07:33 +03

الموسوعة السياسية هي مبادرة أكاديمية غير هادفة للربح، تساعد الباحثين والطلاب على الوصول واستخدام وبناء مجموعات أوسع من المحتوى العلمي العربي في مجال علم السياسة واستخدامها في الأرشيف الرقمي الموثوق به لإغناء المحتوى العربي على الإنترنت. لمزيد من المعلومات حول الموسوعة السياسية - Encyclopedia Political، يرجى التواصل على info@political-encyclopedia.org

استخدامكم لأرشيف مكتبة الموسوعة السياسية - Encyclopedia Political يعني موافقتك على شروط وأحكام الاستخدام المتاحة على الموقع <https://political-encyclopedia.org/terms-of-use>



مقارنة بين التنقية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلاسل الزمنية

مثنىة عبدالله مصطفى
مساعد باحث
كلية طب الاسنان - جامعة الموصل

الدكتور صفاء يونس الصفاوي
أستاذ مساعد قسم الإحصاء
كلية علوم الحاسبات والرياضيات - جامعة الموصل

المستخلص

شهدت الآونة الأخيرة اهتماماً واسعاً بدراسة السلاسل الزمنية، ومن الطرائق الشائعة في تحليل السلسلة الزمنية والتنبؤ بالقيم المستقبلية لها هي طريقة التنقية المكيفة . ومع تطور استخدام علوم الحاسبات في تحليل السلاسل الزمنية فقد ظهرت طرائق حديثة ، ومنها استخدام الشبكات العصبية الاصطناعية في التنبؤ . يهدف هذا البحث إلى مقارنة التنقية المكيفة للنماذج المختلطة $ARMA(p,q)$ والشبكات العصبية ذات الانتشار العكسي للخطأ ، إذ تم اعتماد متوسط مربعات الخطأ MSE ومعدل القيم المطلقة للأخطاء MAE ومعدل القيم المطلقة لنسب الأخطاء MAPE معايير إحصائية للمفاضلة بينهما .

The Comparison of Adaptive Filtering and Back Propagation Neural Networks in Time Series

Saffaa Y. Saffawi (PhD)
Assistant Professor
College of Computers Sciences and
Mathematics
University of Mosul

Muthaina A. Mustafah
Assistant Researcher
Dentistry College
University of Mosul

Abstract

An increasing interest in studying the time series has been recently regarded. One of the potential methods in analyzing the time series and forecasting the future values is the adaptive filtering. A modern method of analyzing time series is the artificial networks in forecasting. The purpose of current paper is to compare the adaptive filtering $ARMA(p,q)$ model with Back propagation neural networks. The mean square error, mean absolute error and mean absolute percentage has been adopted as a statistical criteria mean to find the best one and get a good result. Application was done on alive births of males' data of Mosul city using ANNs, and AF techniques.

١. المقدمة

شهدت تقنية التحليل والتنبؤ في السلاسل الزمنية تطوراً سريعاً في الألفية الثالثة مقترين تطور استخدام علوم الحاسبات ومن الطرائق الشائعة في التنبؤ هي طريقة التنقية المكيفة Adaptive Filtering التي لها القابلية على التكيف مع معادلة التنبؤ للسلسلة العشوائية إذا كانت تلك المعالم تتغير من حين إلى آخر للحصول على التنبؤ الملائم للسلسلة الزمنية.

كما يعد التنبؤ باستخدام الشبكات العصبية من أحدث أساليب التنبؤ، وما زالت الدراسات والبحوث في هذا المجال مستمرة للتعرف على أفضلية هذه الأساليب ، لذلك فقد حظي التداخل بين علوم الإحصاء والحاسبات في السنوات الأخيرة باهتمام متزايد من قبل الباحثين ، فالكثير من الأفكار التي تراود الباحثين في الشبكات العصبية نجدها مبنية على أساسيات علم الإحصاء، وكثير من الوسائل والطرائق يمكن برمجتها بتوظيف شبكة وبناء خوارزمية لها.

ولمرونة بكتلت العصبية بوصفها تقنيات مساعدة للطرائق الإحصائية الإبتدائية التي لا تطلب افتراضات عن طبيعة السلسلة الزمنية ، لأنها خطية أم لا أو مستقرة، لذا يعتقد أن استخدام هذا الأسلوب قد يكون أكثر كفاءة في معالجة مسألة التنبؤ التي نحن بصدها في هذا البحث.

٢. طريقة التنقية المكيفة

Adaptive Filtering Method

إن أسلوب التنقية المكيفة المقدم من قبل الباحثين Makridakis & Wheelwright في عام (1978) تضمن تقنيات لمراجعة Revising تقدير المعلمات بإضافة حد التصحيح النسبي إلى حاصل ضرب بواقى التنبؤات الأكثر حداثة وقيم المشاهدات الأولية.

وقد كانت التنقية المكيفة تستخدم لنماذج الانحدار الذاتي في ذلك الوقت فقط وفي عام (1977) تم توسيع المفردات لتشمل الانحدار الذاتي المتسلسل مع نماذج أخطاء المتوسطات المتحركة والسلاسل الزمنية غير المستقرة.

وفي عام (1979) أثبت كل من (Nau & Oliver) أن أسلوب التنقية المكيفة والتنبؤ الذي قدم من قبل Makridakis & Wheelwright يمكن أن ينظر إليه على أن طريقة التنقية المكيفة أكثر دقة وكفاءة من أسلوب التنقية المقدمة من قبل Kalman والمطبقة بشكل فعال في نماذج الانحدار الذاتي. ومن الجدير بالذكر أن المعلمات تتغير في هذه الطريقة من فترة إلى أخرى وليست ثابتة. (Makridakis, 1978)

١- ٢- التنقية لأنموذج الانحدار الذاتي والمتوسطات المتحركة من الرتبة (p,q):

Adaptive Filtering For ARMA of order (p,q)

إن أنموذج ARMA (p,q) يمكن أن يكتب بالصيغة :

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

اذ إن :

$$t = 1, 2, \dots, n$$

a_t : عبارة عن مركبة الخطأ العشوائي بوسط حسابي مساو للصفر وتباين σ_{at}^2 .

$\phi_{1t}, \dots, \phi_{pt}$ عبارة عن معلمات AR غير المعلومة.

$\theta_{1t}, \dots, \theta_{qt}$ عبارة عن معلمات MA غير المعلومة.

يمكن تقدير المعلمات على وفق طريقة المربعات الصغرى غير الخطية Non-Linear Least Square Method باستخدام طريقة Steepest Descent - الانحدار المتدرج بمعنى استخدام الميول Gradients عند البحث عن الأصغر، إذ إن Gradients عند أي نقطة على سطح الاستجابة يمكن إيجادها عن طريق اشتقاق دالة متوسط مربعات الخطأ Mse المتمثلة بـ a_t^2 وتكون بالصيغة الآتية:

$$a_t = Z_t - \phi_{1t} Z_{t-1} - \dots - \phi_{pt} Z_{t-p} + \theta_{1t} a_{t-1} + \dots + \theta_{qt} a_{t-q} \quad (2-2)$$

وبتربيع طرفي المعادلة نحصل على

$$a_t^2 = (Z_t - \phi_{1t} Z_{t-1} - \dots - \phi_{pt} Z_{t-p} + \theta_{1t} a_{t-1} + \dots + \theta_{qt} a_{t-q})^2$$

وبالاشتقاق الجزئي بالنسبة إلى كل من $\phi_{1t}, \dots, \phi_{pt}$ وكذلك بالنسبة إلى

كل من $\theta_{1t}, \dots, \theta_{qt}$ نحصل على :

$$\frac{\partial a_t^2}{\partial \phi_{it}} = -2a_t Z_{t-i}$$

$$i = 1, 2, \dots, p$$

$$j = 1, 2, \dots, q$$

$$(2-3)$$

$$\frac{\partial a_t^2}{\partial \theta_{jt}} = 2a_t a_{t-j}$$

وباستخدام الأسلوب التكراري يمكن أن نستنتج بـ أن Revise المعلمات

المكيفة هي:

[AL-Nasir, 2002]

$$\phi_{it}^* = \phi_{it} - k \nabla a^2 \quad (2-4)$$

اذ إن :

ϕ_{it}^* : تمثل المعلمة المعدلة (المكيفة) الجديدة (Adaptive Parameter).

ϕ_{it} : تمثل المعلمة القديمة قبل التعديل.

k : تمثل ثابت اختياري يقوم بالسيطرة على سرعة التقارب من خلال عدد مرات التكرار المستخدمة.

∇a^2 : تمثل متجه التدرج (Gradient Vector) لـ a^2 ومنها نجد:

$$\varphi_{it}^* = \varphi_{it} + 2ka_t Z_{t-i} \quad (2-5)$$

والمستخدمة في نماذج الانحدار الذاتي وكذلك فإن:

$$\theta_{jt}^* = \theta_{jt} - 2ka_t a_{t-j} \quad (2-6)$$

إن الصيغ (2-5) و(2-6) تطبق بشكل متكرر إلى الحد أو النقطة التي ينعدم فيها الاختزال أو التخفيض لمتوسط مربعات الخطأ (Mse) عند هذه النقطة، وعليه فإن عملية التعديل (التقنية) تنتهي وإن القيمة النهائية للمعلمة تستخدم للتنبؤ (Prediction).

ومن الصيغة (2-1) فإن أخطاء البواقي المعدلة الجديدة تكون:

$$a_t^* = Z_{t-1} \varphi_{1t}^* Z_{t-2} \varphi_{2t}^* \dots - \varphi_{pt}^* Z_{t-p} + \theta_{1t}^* a_{t-1} + \dots \quad (2-7)$$

$$\begin{aligned} a_t &= a_t^* - a_t \\ &= -(\varphi_{1t}^* - \varphi_{1t}) Z_{t-1} - \dots - (\varphi_{pt}^* - \varphi_{pt}) Z_{t-p} + (\theta_{1t}^* - \theta_{1t}) a_{t-1} + \dots \\ &\quad + (\theta_{qt}^* - \theta_{qt}) a_{t-q} \end{aligned}$$

أو

$$a_t = -2ka_t \{Z_{t-1}^2 + \dots + Z_{t-p}^2 + a_{t-1}^2 + \dots + a_{t-q}^2\} \quad (2-8)$$

وبقسمة المعادلة (2-8) على a_t ينتج:

$$\frac{|\nabla a_t|}{a_t} = 2k \{Z_{t-1}^2 + \dots + Z_{t-p}^2 + a_{t-1}^2 + \dots + a_{t-q}^2\} \quad (2-9)$$

ومن العلاقة الأخيرة يمكن استنتاج:

$$0 < k < \frac{1}{\{Z_{t-1}^2 + \dots + Z_{t-p}^2 + a_{t-1}^2 + \dots + a_{t-q}^2\}} \quad (2-10)$$

٣. الشبكات العصبية الاصطناعية

Artificial Neural Networks(ANNs)

الشبكة العصبية الاصطناعية هي عبارة عن نظام حاسوبي لمعالجة المعلومات يتكوزن عدد كبير جداً من عناصر المعالجة (Processing Elements) المترابطة فيما بينها ذوات طبيعة ديناميكية وظيفتها هي التقسيم المتوازي لحساب الشبكة، وتتكون الشبكة العصبية من عدد من وحدات المعالجة المتداخلة والمتجانسة كل وحدة بمفردها أداة حسابية يمكن نمذجة سلوكها بصيغ رياضية بسيطة.

لقد كانت بداية الشبكات العصبية بسيطة متمثلة بطبقة واحدة (Single Layer) من الخلايا العصبية الاصطناعية التي يتم تعليمها، أطلق عليها الإدراك الحسي (Preceptrons) افترضها الباحثان (Frank & Roseblatt, 1958)، وكانت عملية التعلم فيها مقتصرة على النماذج الخطية (Linear Models) لأغراض

التقدير أو التصنيف أو التوبيب أو التنبؤ ، لهذا قلّ الاهتمام بدراسة الشبكات العصبية عدة سنوات إلى أن تم التوصل إلى شكل جديد للإدراك الحسي بإضافة مستوى جديد أطلق عليه المستوى المخفي (المخبأ) (Hidden Level)، أكسب الإدراك الحسي القدرة على حساب الدوال والعلاقات لنماذج البيانات الخطية واللاخطية ، وتطور بينه لهذا المستوى بإضافة أوزان تربط بين مستوي الإدخال والمخفي من قبل (Paul Werbos)، إذ لم يثر هذا التطور اهتمام الباحثين في الشبكات العصبية الاصطناعية إلا في منتصف الثمانينات بعد استخدام خوارزمية الانتشار العكسي للخطأ (Backpropagation Error)، كي يساعد الشبكات متعددة الطبقات على التعلم (الشيخلي، ٢٠٠٣).

١- ٣ خوارزمية الانتشار العكسي للخطأ

Error Backpropagation Algorithm

إن تدريب الشبكة العصبية الاصطناعية باستخدام الانتشار العكسي يتضمن ثلاث مراحل تتمثل في الآتي: (علام زكي، ٢٠٠٠) (Wasserman,1989)

١. مرحلة الانتشار الأمامي للخطأ.
٢. مرحلة الانتشار الخلفي للخطأ.
٣. مرحلة توليف أوزان الشبكة.

خلال مرحلة الانتشار الأمامي تنتشر إشارة المدخلات إلى كل عقدة من عقد الطبقة المخفية، ثم يتم حساب قيمة التنشيط لكل عقدة من عقد الطبقة المخفية لهذه الإشارة، وبعدئذ ترسل هذه العقد إشاراتها إلى كل عقدة من عقد طبقة المخرجات ، ثم يتم حساب قيمة التنشيط لكل عقدة من عقد طبقة المخرجات لتشكل استجابة الشبكة لعينة المدخلات المعطاة وخلال مرحلة التدريب تقوم كل عقدة في طبقة المخرجات بمقارنة تنشيطاتها المحسوبة مع قيمة المخرجات الفعلية، لتحدد قيمة الخطأ الحاصل لتلك العقد ، واعتماداً على قيمة الخطأ يتم حساب معامل تصحيح الخطأ δ_k فيستخدم معامل تصحيح الخطأ δ_k لتوزيع الخطأ على العقد في طبقة المخرجات، لتتم إعادته إلى كل عقدة في الطبقة السابقة ، وكذلك يستخدم هذا المعامل لتحديث الأوزان في طبقة المخرجات والطبقة المخفية ، بطريقة مشابهة يتم حساب معامل الخطأ δ_j بالنسبة لكل عقدة من عقد الطبقة المخفية ويستخدم هذا المعامل لتحديث الأوزان في الطبقة المخفية وطبقة المدخلات ، وبعد تحديد كل عوامل تصحيح الخطأ يتم توليف الأوزان بالنسبة لجميع الطبقات في اللحظة نفسها.

ويمكن تلخيص خوارزمية أو منهجية عمل هذه الشبكة بالخطوات الآتية:

١. توليد قيم أولية للأوزان "من إحدى التوزيعات الإحصائية".
٢. تستقبل كل عقدة في طبقة المدخلات إشارة إدخالها ثم إرسالها إلى جميع عقد الطبقة المخفية.

$$u = \sum_{i=1}^N w_{ij} x_i \quad (3-1) \quad .٣$$

$$y = f(u - \theta) \quad (3-2)$$

جمع لكل عقدة في الطبقة المخفية قيم إشارات دخلها الموزونة وبموجب الصيغة الآتية:

$$h_j = f\left(\sum w_{ij} x_i - \theta_j\right) \quad (3-3)$$

٤. تطبيق التنشيط لتقدير مخرجات الطبقة المخفية وترسل قيم التنشيط إلى جميع العقد في طبقة المخرجات.
تجمع كل عقدة في طبقة المخرجات إشارات دخلها الموزونة وبموجب الصيغة الآتية:

$$y_k = f\left(\sum w_{ij} x_i - \theta_k\right) \quad (3-4)$$

٦. حساب الخطأ لعقد الإخراج عن طريق حساب الفرق ما بين قيمة التنشيط أي قيمة مخرجات العقد y_k والقيمة الحقيقية للعقدة بمعنى t_k أي:

$$E_k = t_k - y_k \quad (3-5)$$

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

$$\delta_k = (t_k - y_k) \cdot f'(v) \quad (3-6)$$

اذ إن $f(v)$ تمثل دالة اللوجستك أو دالة $tansig$ عندما تكون عقد المخرجات غير خطية وتساوي واحداً في حالة كون الدالة خطية.

$$f'(v) = f'(NET_k)$$

ومن ثم حساب التغيير في حجم الخطأ Δw_{jk} وبموجب المعادلة:

$$\Delta w_{jk} = n \cdot \delta_k \cdot h_j \quad (3-7)$$

٧. تجمع كل عقدة في الطبقة المخفية إشارات المدخلات الموزونة إلى δ وكما في الصيغة:

$$\Delta_j = \sum_j \delta_k w_{jk} \quad (3-8)$$

ومن ثم تضرب هذه القيمة بتابع التنشيط لحساب δ_j وبعد ذلك يتم حساب التغيير في حجم الخطأ Δv_{ij} بالصيغة:

$$\Delta v_{ij} = n \cdot \delta_j \cdot x_i \quad (3-9)$$

تحدث الأوزان لكل عقدة في طبقة المخرجات وبموجب الصيغة:

$$W_{jk}(\text{new}) = W_{jk}(\text{old}) + \Delta W_{jk} \quad (3-10)$$

مقارنة بين التنقية المكيفة والشبكات العصبية ذات الانتشار... ————— الصفراوي ومصطفى [١٨٣]

ومن ثم تحدث الأوزان بالنسبة لكل عقدة في الطبقة المخفية وبموجب الصيغة:

$$V_{ij} (new) = V_{ij} (old) + \Delta V_{ij} \quad (3-11)$$

٨. وتستمر الشبكة في تحديث الأوزان "أي عملية التعلّم والتدريب" إلى أن يتم الحصول على الأوزان المثلى، ومن ثم الحصول على المخرجات المرغوب بها أي التوصل إلى أفضل توفيق للنموذج قيد البحث.

إذ إن :

x_1, x_2, \dots, x_n تمثل المدخلات

w_1, w_2, \dots, w_n تمثل الأوزان ما بين المستويات

u : حساسية العصبون

θ : تمثل العتبة

y : تمثل مخرجات الشبكة

$f(v)$: تمثل دالة الحساسية أو الدالة المنشطة Activation function وتقدر هذه الدالة بموجب المعادلة الآتية :

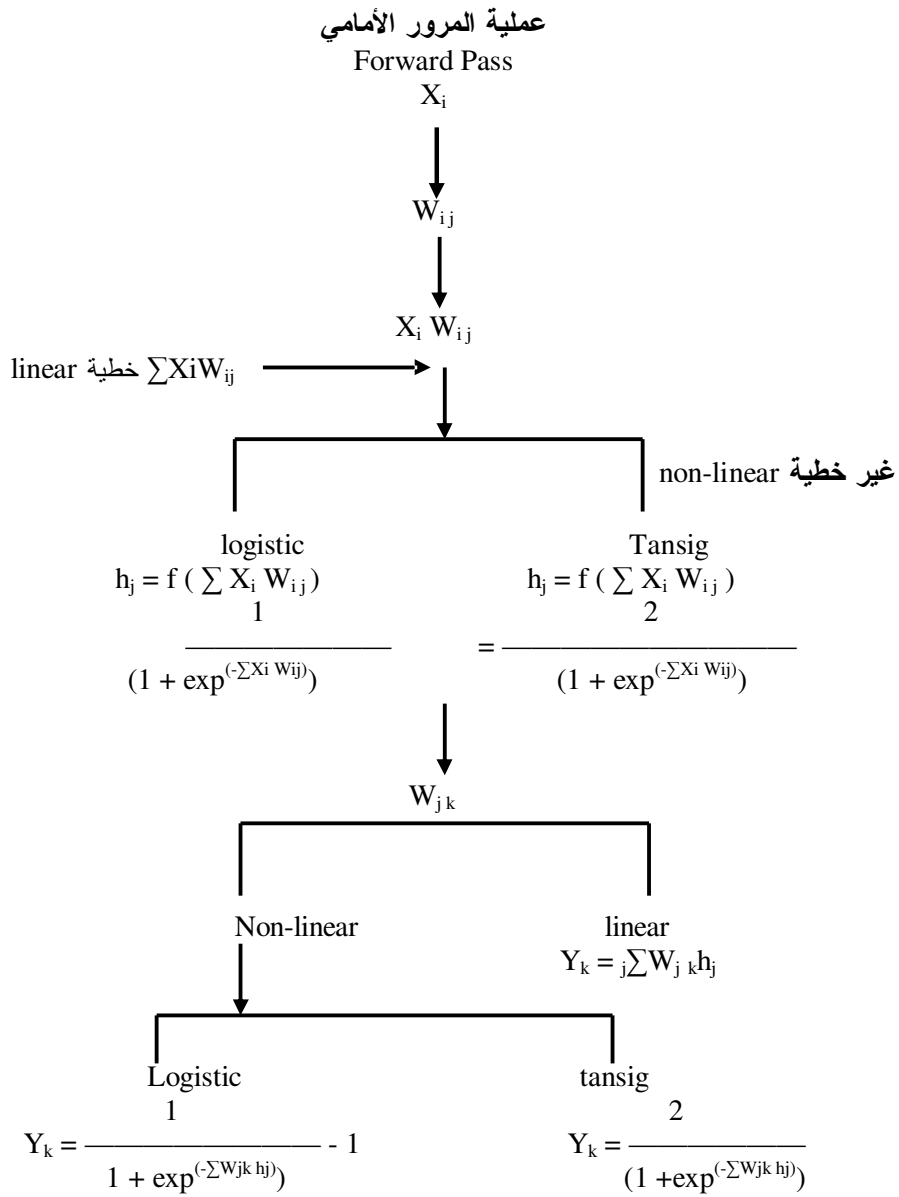
$$f (v) = 1 / \exp (-v) \quad (3-12)$$

تتصرف قيمة الدالة $f(v)$ بين $(-1,1)$

V_k : تمثل المخرجات التوليفية الخطية.

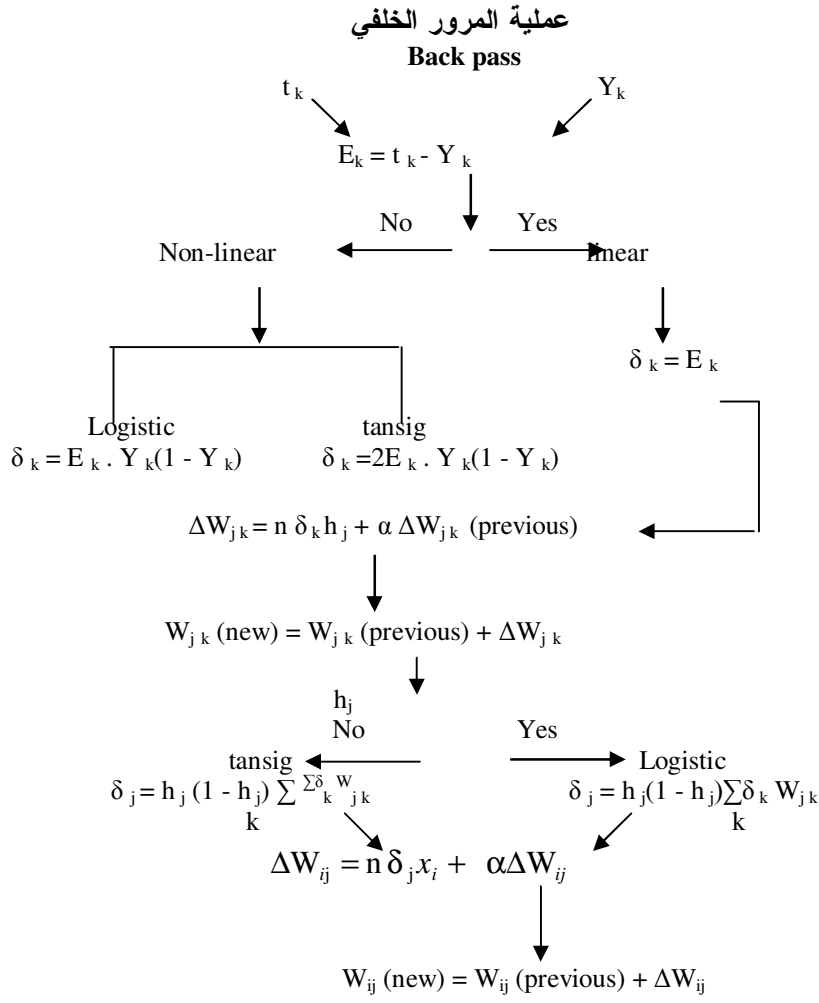
t : المخرجات الفعلية أو المرغوب فيها.

n : معدل التعلّم.



الشكل ١

عملية المرور الأمامي لعقد التنشيط عبر شبكة الانتشار العكسي للخطأ



الشكل ٢
عملية المرور الخلفي لعقد التنشيط عبر شبكة الانتشار العكسي للخطأ

- إذ إن :
- X_i : مدخلات الشبكة.
 - W_{ij} : أوزان مستوى المدخلات إلى المستوى المخفي.
 - h_j : مخرجات المستوى المخفي.
 - Y_k : مخرجات الشبكة العصبية.
 - ΔW_{ij} : التغير في وزن مستوى المدخلات إلى المستوى المخفي.

$\Delta W_{jk}(\text{previous})$: التغير السابق في وزن المستوى المخفي إلى مستوى المخرجات.

t_k : قيمة المخرجات للوزن السابق.

n : معدل التعلم.

δ : مشتقة الخطأ.

α : الزخم.


٤. الجانب التطبيقي

يتضمن هذا الجانب عرض الطرائق التي يتم من خلالها التنبؤ بالسلاسل الزمنية وهذه الطرائق هي:

١. التنقية المكيفة.

٢. الشبكات العصبية ذات الانتشار العكسي للخطأ.

وقد تم استخدام بيانات مثلت عدد المواليد الأحياء من الذكور في مدينة الموصل، الحصول عليها من دائرة صحة نينوى / قسم الإحصاء الصحي والحياتي للفترة من ١٩٩٥/١/١ ولغاية ٢٠٠٣/١/٣١. وتم رسم السلسلة الزمنية، وكان الاتجاه العام لها بالأعتماد على متوسط مربعات الخطأ هو تربيعي.




الأشهر

الشكل ٣

رسم السلسلة الزمنية للمواليد الأحياء من الذكور في مدينة الموصل
للمدة (١٩٩٥-٢٠٠٣)


أما الشكل ٤ فيوضح مقدار دالة الارتباط الذاتي ACF للملاحظات الخام.




الشكل ٤
دالة الارتباط الذاتي للملاحظات الخام

ويتضح من الشكل ٣ السلسلة الزمنية و الشكل ٤ سلوك دالة الارتباط الذاتي أن السلسلة غير مستقرة. ولغرض جعل السلسلة مستقرة تم أخذ التحويل اللوغاريتمي للتوصل للاستقرارية في التباين ، ولجعل السلسلة الزمنية مستقرة في الوسط الحسابي أخذت الفروقات (Differences) وبدء بالفرق الأول (∇x_t) ثم الفرق الثاني ($\nabla^2 x_t$) الذي أعطى استقرارية للسلسلة حول الوسط الحسابي وكما هو واضح في الشكل ٥:

Time Series Plot for lag2



الشكل ٥
سلوك المشاهدات بعد تحويل السلسلة الزمنية إلى سلسلة مستقرة



الشكل ٦
دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للسلسلة

ومن الشكليين يتبين أن الأنموذج الملائم هو $ARMA(1,1)$ وللدقة وسلامة التشخيص فقد تم استخدام معيار أكاي (ACI) لتحديد رتبة الأنموذج فكانت قيمته الصغرى عند الأنموذج $ARMA(1,1)$. بعد أن تحولت السلسلة الزمنية إلى مستقرة وتم تحديد رتبة الأ نمودج يتم استخدام طريقة التنقية المكيفة والشبكات العصبية ذات الانتشار العكسي للخطأ للتنبؤ المستقبلي بجدد المواليد الأحياء من الذكور في مدينة الموصل، وكانت النتائج بالشكل الآتي:

أولاً - باستخدام طريقة التنقية المكيفة

لقد تم استخدام البرنامج الحاسوبي المعد من خلال (Macros) ومن خلال شاشة التشغيل MS-Dos تشغيله وعرض نتائجه من خلال شاشات نظام Minitab، وإن البيانات كانت وفقاً للأنموذج $ARMA(1,1)$ وتم تحديد معالم الأ نمودج الابتدائية $(\phi=0.497490)$ و $(\theta=0.977024)$ وقيمة $(MSE=0.001)$ ، وكذلك الأخطاء العشوائية (Residuals) تبدأ عملية احتساب المعلمات بشكل مستمر بحلقات تكرارية مناسبة إلى أن يتم التوصل إلى أفضل قيم للمعلمات وبأقل متوسط مربعات خطأ تم الحصول عليه، أي أن الفرق بين كل قيمتين متتبعين بهما لا يزيد عن (0.001) عند

ذلك يتوقف التنبؤ وتنتهي عملية تعديل المعلمات بهذه الطريقة. أما معايير جودة التنبؤ فكانت كما يأتي:

$$MSE = (1/M) \sum_{L=1}^M e_t^2(L) \quad (2-3)$$

$$MAE = (1/M) \sum_{L=1}^M |e_t(L)| \quad (3-3)$$

$$MAPE = \left\{ (1/M) \sum_{L=1}^M |e_t(L)/X_{t+L}| \right\} 100\% \quad (4-3)$$

ثانياً - باستخدام الشبكات العصبية ذات الانتشار العكسي للخطأ

لقد تم استخدام برنامج بلغة C++ لغرض الوصول إلى قيم التنبؤ وحسابها بشكل دقيق فقد تم تحديد عدد العقد المخفية بـ ٤ عقد وطبقتين مخفيتين وحسب عدد مرات التدريب ، وبما أن البيانات المستخدمة في هذا البحث بلغ عددها ١٠٨ مشاهدة فقد عد ١٥% منها على أنها مشاهدات اختبار Test لغرض الاختبار وعدت ١٦% من المشاهدات مجموعة الشرعية Validation، أما باقي المشاهدات فقد استخدمت للتدريب وتقدير قيمة متوسط مربعات الخطأ (MSE) لغرض الحصول على أفضل النتائج، وإن أفضل شبكة (Best Networ) عند ٥٠٠٠ تكرار، وإن الشرعية سلكت سلوك التدريب نفسه ولكن بأقل خطأ مطلق. ومن خلال تدريب الشبكة العصبية تم التوصل إلى قيم التنبؤ واحتساب المعلمات الإحصائية . والشكل ٧ يوضح قيم التنبؤ المحسوبة بهذه الطريقة.


ولغرض المقارنة مابين الأسلوبين تم اعتماد المعايير الإحصائية: معدل القيم المطلقة للأخطاء (MAE)، ومعدل مربعات الخطأ (MSE)، ومعدل القيم المطلقة لنسب الأخطاء (MAPE).

الجدول ١
المعايير الإحصائية للأسلوبين


MAE	MSE	MAPE	الطريقة المستخدمة
٦٩٣,٢٧	٩٧٦٥,٣	٨,٢٣٣	التنقية المكيفة
٢٨٦,٤٣	٨٦٧٢,٨	٣,٥٢٤	الشبكات العصبية

وكما هو واضح فإن أسلوب الشبكات العصبية قد يفوق على طريقة التنقية المكيفة على وفق المعايير الإحصائية الثلاثة . وبذلك تكون الشبكات العصبية هي الطريقة الأفضل والأكثر دقة ومثانة للتنبؤ بقيم السلاسل الزمنية.

أ. التنبؤ بطريقة التنقية المكيفة



ب. التنبؤ بطريقة الشبكات العصبية



الشكل ٧

(أ،ب) تبين قيم التنبؤ المحسوبة بالطريقتين التنقية المكيفة والشبكات العصبية على التوالي

٥- ١ الاستنتاجات

- إن أهم الاستنتاجات التي تم التوصل إليها من خلال الدراسة هي:
١. إن السلسلة الزمنية للمواليد الأحياء من الذكور هي سلسلة غير مستقرة وأن الاتجاه العام للسلسلة تربيعة.
٢. تفوقت الشبكات العصبية على طريقة التنقية المكيفة ، إذ تم الحصول على نتائج ذات قيم أقل للمعايير الإحصائية المستخدمة لحساب أخطاء التنبؤ، من هنا تعدّ الشبكات العصبية هي الطريقة الأفضل والأكثر دقة في التنبؤ با لقيم المستقبلية للسلسلة الزمنية قيد الدراسة.
٣. تعد الشبكات العصبية طريقة بديلة عن طريقة التنقية المكيفة المستخدمة في التنبؤ التي لها القدرة على معالجة مختلف أنواع البيانات الخطية واللاخطية.

٤- ٢ التوصيات

- على ضوء الاستنتاجات أعلاه نوصي بما يأتي :
١. إجراء دراسات باستخدام شبكات عصبية أخرى غير شبكة الانتشار العكسي للخطأ مثل شبكة المدرك وشبكة Hop filed مقارنة النتائج.
٢. إجراء دراسات للتنبؤ بالقيم المستقبلية للسلاسل الزمنية متعددة المتغيرات Multivariate Time Series باستخدام الشبكات العصبية.
٣. إمكانية دراسة السلاسل الزمنية متعددة المتغيرات في الدراسات المستقبلية لحالات قد تتطلبها بحوث التنبؤ خاصة في المجالات الطبية والولادات التي قد تتأثر بأكثر من متغير واحد مثل العمر، الحالة الاقتصادية وغيرها.

المراجع

أولاً - المراجع باللغة العربية

١. البك، عزة حازم زكي ، استخدام الشبكات العصبية في التكهّن في السلسلة الزمنية لاستهلاك الطاقة الكهربائية في محافظة نينوى وسالة ماجستير غير منشورة ، كلية علوم الحاسبات والرياضيات، جامعة الموصل، ٢٠٠٥.
٢. الشخطي، يفيان علاء ناظم ، تصميم نظام رياضي ديناميكي لا خطي باستخدام الشبكات العصبية (NARMAX) لدراس تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد ، رسالة ماجستير غير منشورة، كلية الإدارة والاقتصاد، جامعة بغداد، ٢٠٠٣.
٣. عيسى، علام زكي، والمحمد عماد عزو ، الشبكات العصبية ، البنية الهندسية، الخوارزميات، التطبيقات، ٢٠٠٠.
٤. محمد، أسيل سمير مقارنة بين ط رائق تحليل وتنبؤ السلاسل الزمنية وتطبيقاتها على مبيعات الشركة العامة لتوزيع كهرباء بغداد ، أطروحة دكتوراه ، كلية الإدارة والاقتصاد، جامعة بغداد، ٢٠٠٥.

ثانياً - المراجع باللغة الأجنبية

1. Al-Nasir. Abdul Majeed Hamza: "Forecasting Performance of Adaptive Filtering and Box-Jenkins Techniques (An Empirical Investigation)".Baghdad college of Economic Science University, 2002.
2. Chung, C., Cheong W. and Chung, L.: "Financial Time Series Forecasting by Network Using Conjugate Gradient Learning Algorithm Multiple Linear Regression Weight Initialization" Department of Computing The Hong Kong Polytechnic University, Kowloon, Hong Kong, 2001 csmechan@comp.polyu.edu.hk
3. Davalo, E. and Patrick Naim, 1991: " Neural Networks"
4. Jones, D. Appadwedula, S., Berry, M., Haun, M. Moussa, D. and Sachs D.,(2004):"AdaptiveFiltering: LMS Algorithm" <http://www.cnx.vice.edu/content/m10481/latest/>. Macmillan, HongKong.
5. Makridkis, S., Wheel Wright, S. G.: "Forecasting: Methods and Application", John Wiley, New York, 1978.
6. Nau, R. F And R. N. Oliver: "Adaptive Filtering Revisited" S. R. stot. Soc., vol. 35. N4., 1979.
7. Wasserman Philip D.,:"Neural Computing Theory and Practice", Van Nostrand Veinhold-New York, 1989.
8. Zurada, Jacek. M.:"Introduction to Artifical Neural System", Jaico Publishing House, Mumbai, 1994.