

مقارنة بين التقنية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلسلة الزمنية

مثنية عبدالله مصطفى

مساعد باحث

كلية طب الاسنان -جامعة الموصل

الدكتور صفاء يونس الصفاوي

أستاذ مساعد -قسم الإحصاء

كلية علوم الحاسوبات والرياضيات -جامعة الموصل

المستخلص

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

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

Safaa 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 السلسلة الزمنية تطويراً سريعاً في الألفية الثالثة مقترباً بتطور استخدام علوم الحاسوب ومن الطرائق الشائعة في التنبؤ هي طريقة التقنية المكيفة Adaptive Filtering، التي لها القابلية على التكيف مع معادلة التنبؤ للسلسلة لاعشوانية، إذ كانت تلك المعالجات 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 والحسابات 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 والطرق يمكن برمجتها بتوظيف شبكة وبناء خوارزمية لها.

ولمدون بكلمات العصبية بوصفها تقنيات مساعدة للطرق الإحصائية الانتيادية 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 بصددها في هذا البحث.

٢. طريقة التقنية المكيفة

إن أسلوب التقنية المكيفة المقدم من قبل الباحثين Makridakis & Wheelwright في عام (1978) تضمن تقنيات لمراجعة السلسلة الزمنية، لأنها خطية أم لا بإضافة حد التصحيح النسبي إلى حاصل ضرب بوأقي التنبؤات الأكثر حداثة وقيم المشاهدات الأولية.

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

وفي عام (1979) أثبت كل من (Nau & Oliver) أن أسلوب التقنية المكيفة والتنبؤ الذي قدم من قبل Makridakis & Wheelwright يمكن أن ينظر إليه على أن طريقة التقنية المكيفة أكثر دقة وكفاءة من أسلوب التقنية المقدمة من قبل Kalman والمطبق بشكل فعال في نماذج الانحدار الذاتي. ومن الجدير بالذكر أن المعلومات تتغير في هذه الطريقة من فترة إلى أخرى وليس ثابتاً.

(Makridakis, 1978)

١-٢ التقنية 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:

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

اذا إن :

$t = 1, 2, \dots, n$
 a_t : عبارة عن مركبة الخطأ العشوائي بوسط حسابي مساو للصفر وتبين σ_{at}^2 .

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

$\theta_{1t}, \dots, \theta_{pt}$ 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 المتتمثلة بـ a_t^2 وتكون بالصيغة الآتية:

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

وبتربيع طرفي المعادلة نحصل على

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

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

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

$$\frac{\partial a_t^2}{\partial \varphi_{it}} = -2a_t Z_{t-i} \quad i = 1, 2, \dots, p$$

$$\frac{\partial a_t^2}{\partial \theta_{jt}} = 2a_t a_{t-j} \quad j = 1, 2, \dots, q \quad (2-3)$$

وباستخدام الأسلوب التكراري يمكن أن نستنتج أن Revise المعلمات المكيفة هي :

[AL-Nasir,2002]

$$\varphi_{1t}^* = \varphi_{1t} - k \nabla a^2 \quad (2-4)$$

اذا إن :

φ_{1t}^* : تمثل المعلمة المعدلة (المكيفة) الجديدة (Adaptive Parameter).

φ_{1t} : تمثل المعلمة القديمة قبل التعديل.

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

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

$$\varphi_{i,t}^* = \varphi_{i,t} + 2k a_t Z_{t-i} \quad (2-5)$$

والمستخدمة في نماذج الانحدار الذاتي وكذلك فإن:

$$\theta_{j,t}^* = \theta_{j,t} - 2k a_t a_{t-j} \quad (2-6)$$

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

ومن الصيغة (2-2) فإن خطاء الباقي المعدلة الجديدة تكون:

$$a_t^* = Z_{t-1} \varphi_{1,t}^* Z_{t-2} \varphi_{2,t}^* Z_{t-3} \dots \varphi_{p,t}^* Z_{t-p} + \theta_{1,t}^* a_{t-1} + \dots \quad (2-7)$$

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

أو

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

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 يتكون من عدد كبير جداً من عناصر المعالجة (Processing Elements) المتراكبة فيما بينها ذات طبيعة ديناميكية وظيفتها هي التقسيم المتوازي لحساب الشبكة ، وت تكون الشبكة العصبية من عدد من وحدات المعالجة المداخلة والمتلائمة كل وحدة بمفردها أداة حسابية يمكن نمذجتها سلوكها بصيغ رياضية بسيطة.

لقد كانت بداية الشبكات العصبية بسيطة ممثلة بطبقة واحدة (Single Layer) ملخaliya 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 المتصنيف أو التببيب أو التنبؤ ، لهذا قل الاهتمام بدراسة الشبكات العصبية لعدة 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 لنمذج البيانات الخطية واللاخطية ، وتطور بينه هنا المستوي بإضافة أوزان تربط بين مستوى الإدخال والمفهومي من قبل (Paul Werbos)، إذ لم يثير هذا التطور اهتمام الباحثين في الشبكات العصبية الاصطناعية إلا منتصف الثمانينيات 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 ثلاثة 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 عقد طبقة المخرجات ، ثم يتم حساب قيمة التنشيط لكل عقدة من عقد طبقة المخرجات لتتشكل استجابة الشبكة لعينة المدخلات المعطاة وخلال مرحلة التدريب تقوم كل عقدة في طبقة المخرجات بمقارنة تنشيطاتها المحسوبة مع قيمة المخرجات الفعلية، لتحدد قيمة الخطأ الحالى ل تلك العقد ، واعتراضى قيمة الخطأ يتم حساب معاً مل تصحيح الخطأ δ_k فيستخدم معامل تصحيح الخطأ δ_k لتوزيع الخطأ على العقد في طبقة المخرجات، لتنم إعادة إلى كل عقدة في الطبقة السابقة ، وكذلك يستخدم هذا المعامل لتحديث الأوزان في طبقة المخرجات والطبقة المخفية ، بطريقة مشابهة يتم حساب معامل الخطأ δ_k 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.

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

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

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

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

٤. تطبيق التنشيط لقدر مخرجات الطبقة المخفية وترسل قيم التنشيط إلى جميع العقد في طبقة المخرجات.

تحمع كل عقدة في طبقة المخرجات إشارات دخلها الموزونة وبموجب الصيغة الآتية:

$$y_k = f(\sum_i w_{ik} x_i - \theta_k) \quad (3-4)$$

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 الحقيقة لقدر 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.

$$f(v) = f'(\text{NET}_k) \quad \text{ومن ثم حساب التغير في حجم الخطأ } \Delta w_{jk} \text{ وبموجب المعادلة:}$$

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

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 بتتابع التنشيط لحساب δ_j وبعد ذلك يتم حساب التغير في حجم الخطأ Δv_{ij} بالصيغة:

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

تحدد الأوزان لكل عقدة في طبقة المخرجات وبموجب الصيغة:

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

مقارنة بين التقنية المكيفة والشبكات العصبية ذات الانتشار... الصفاوي ومصطفى [١٨٣]

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

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

٨. وتستمر الشبكة في تحديث الأوزان "أي عملية التعلم والتدريب" إلى أن يتم الحصول على الأوزان المثلثي، ومن ثم الحصول على المخرجات المرغوب بها أي التوصل إلى أفضل توفيق للأنموذج 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 :

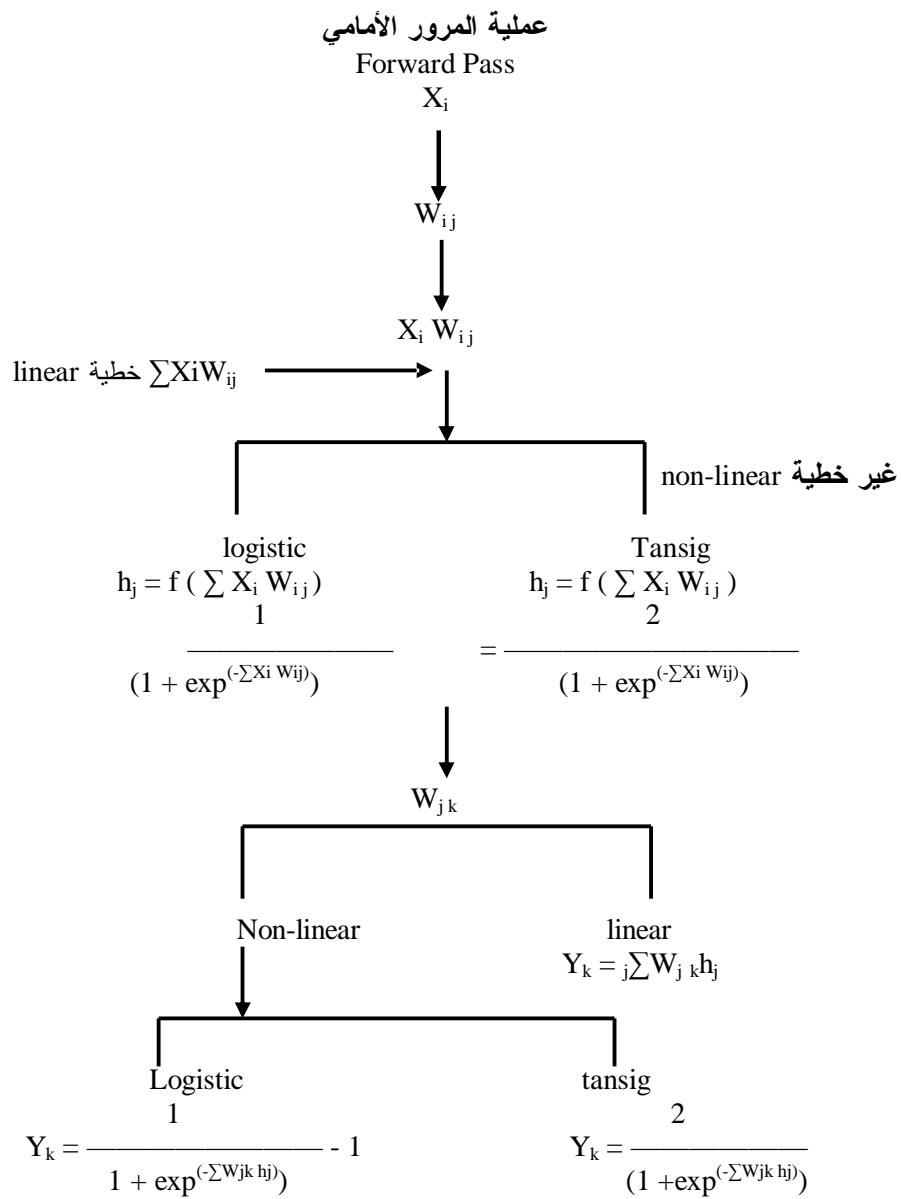
$$f(v) = 1 / \exp^{(-v)} \quad (3-12)$$

تحصر قيمة الدالة $f(v)$ بين (-1,1)

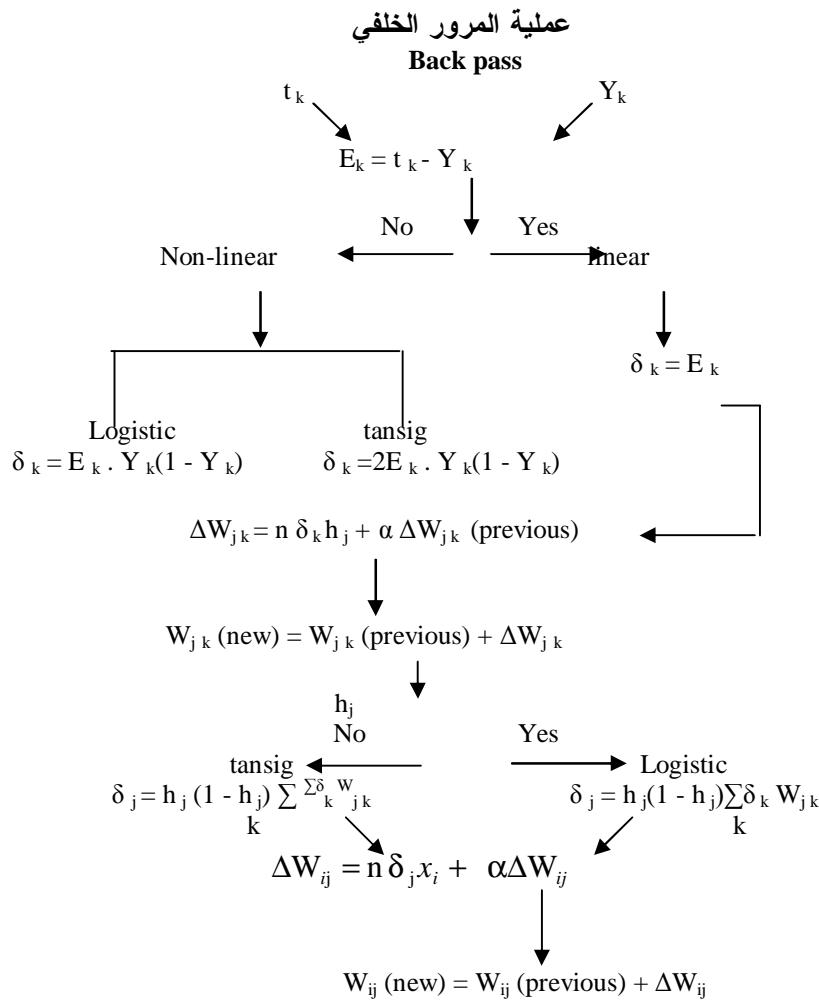
V_k : تمثل المخرجات التوليفية الخطية.

t : المخرجات الفعلية أو المرغوب فيها.

n : معدل التعلم.



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.

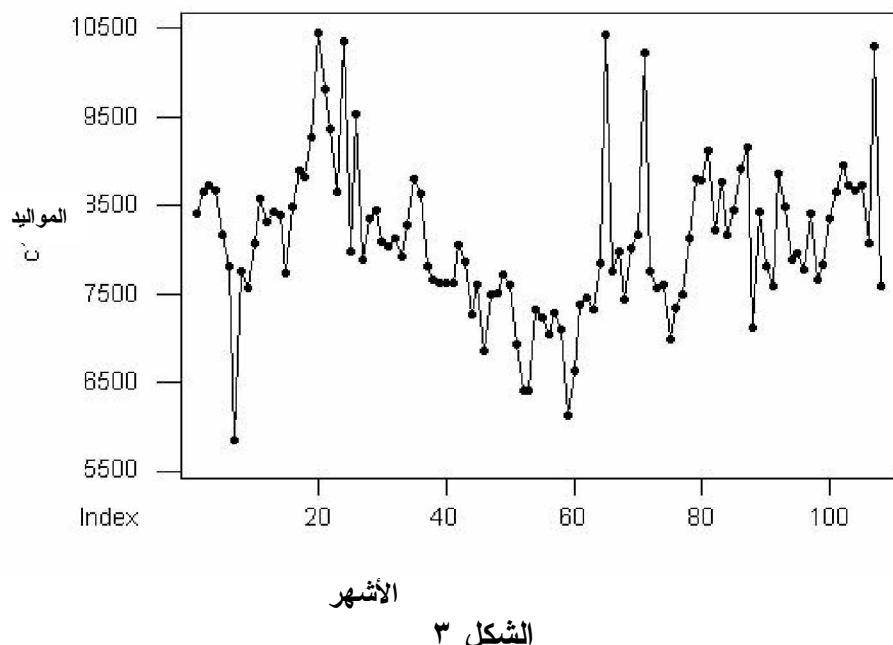
٤. الجانب التطبيقي

يتضمن هذا الجانب عرض الطرائق التي يتم من خلالها التتبؤ بالسلسلة الزمنية وهذه الطرائق هي:

١. التقنية المكيفة.

٢. الشبكات العصبية ذات الانتشار العكسي للخطأ.

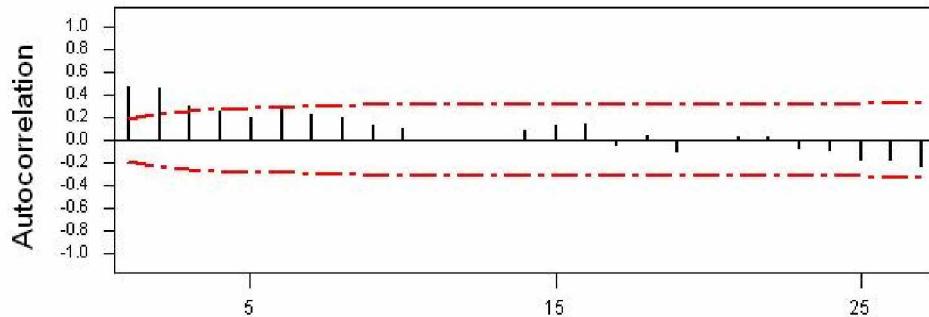
وقد تم استخدام بيانات مثلت عدد المواليد الأحياء من الذكور في مدينة الموصل، الحصول عليها من دائرة صحة نينوى / قسم الإحصاء الصحي والحياتي للفترة من ١٩٩٥/١١ ولغاية ٢٠٠٣/٣١. وتم رسم السلسلة الزمنية، وكان الاتجاه العام لها بالأعتماد على متوسط مربعات الخطأ هو تربيعي.



الشكل ٣

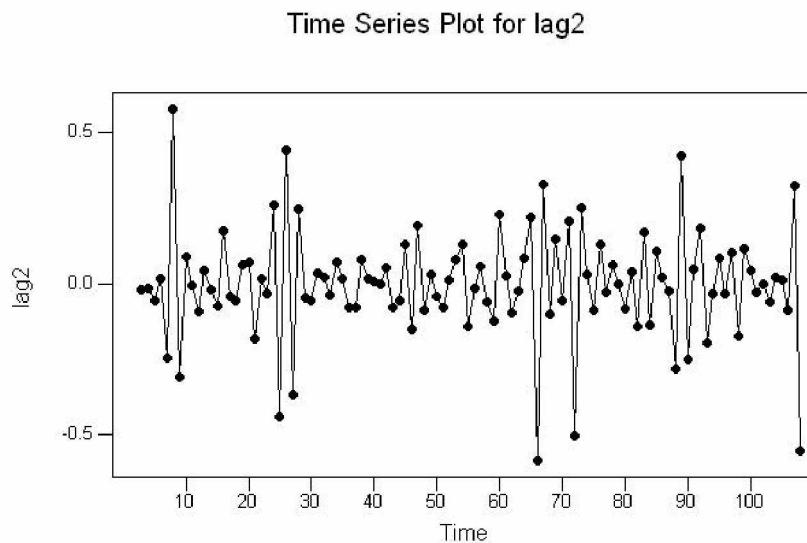
رسم السلسلة الزمنية للمواليد الأحياء من الذكور في مدينة الموصل
للمدة (١٩٩٥-٢٠٠٣)

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

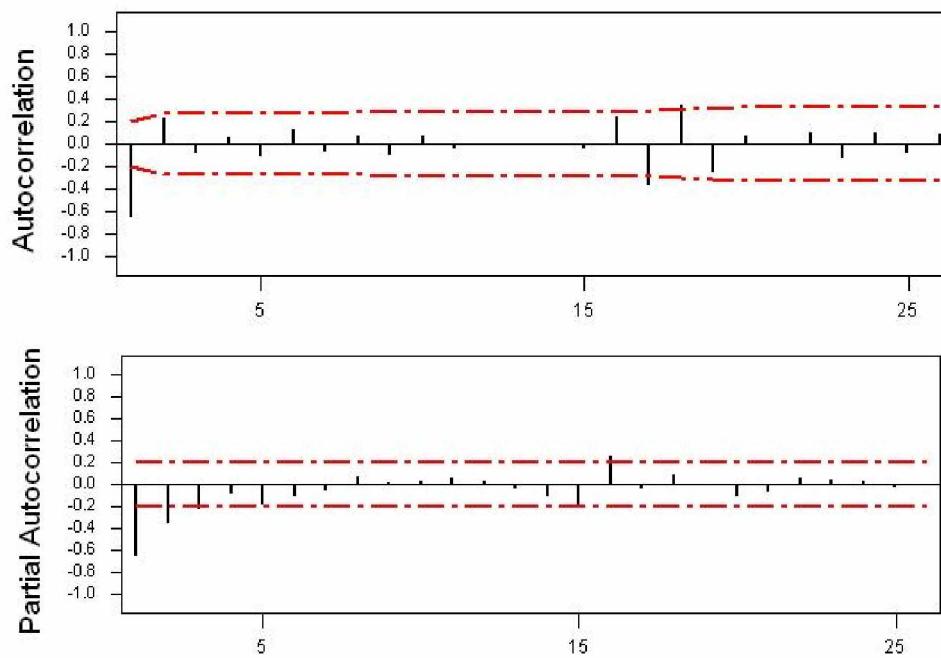


الشكل ٤
دالة الارتباط الذاتي للمشاهدات الخام

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



الشكل ٥
سلوك المشاهدات بعد تحويل السلسلة الزمنية إلى سلسلة مستقرة



الشكل ٦
دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للسلسلة

ومن الشكلين يتبين أن الأنموذج الملائم هو ARMA(1,1) ولدقة وسلامة التشخيص فقد تم استخدام معيار أكاكى (ACI) لتحديد رتبة الأنموذج فكانت قيمة الصغرى عند الأنموذج ARMA(1,1).

بعد أن تحولت السلسلة الزمنية إلى مستقرة تم تحديد رتبة الأنموذج يتم استخدام طريقة التقنية المكيفه والشبكات العصبية ذات الانتشار العكسي للخطأ للتبيؤ المستقبلي عدد المواليد الأحياء من الذكور في مدينة الموصل، وكانت النتائج بالشكل الآتى:

أولاً- باستخدام طريقة التقنية المكيفه

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

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

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

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

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

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 وعند 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 Network) 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 الأحصائية . والشكل ٧ يوضح قيم التنبؤ المحسوبة بهذه الطريقة.

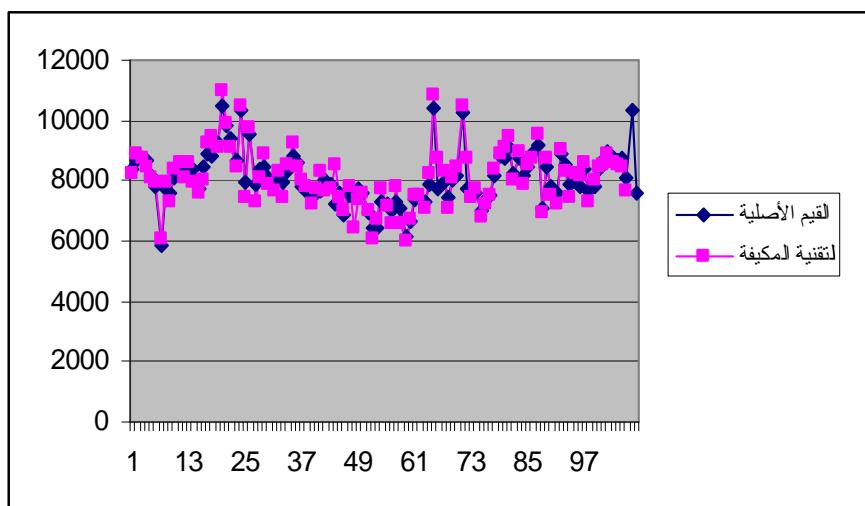
ولغرض المقارنة بين الأسلوبين تم أعتماد المعايير الإحصائية: معدل القيم المطلقة للأخطاء (MAE)، ومعدل مربعات الخطأ (MSE)، ومعدل القيم المطلقة لنسب الأخطاء (MAPE).

الجدول ١
المعايير الإحصائية للاسلوبين

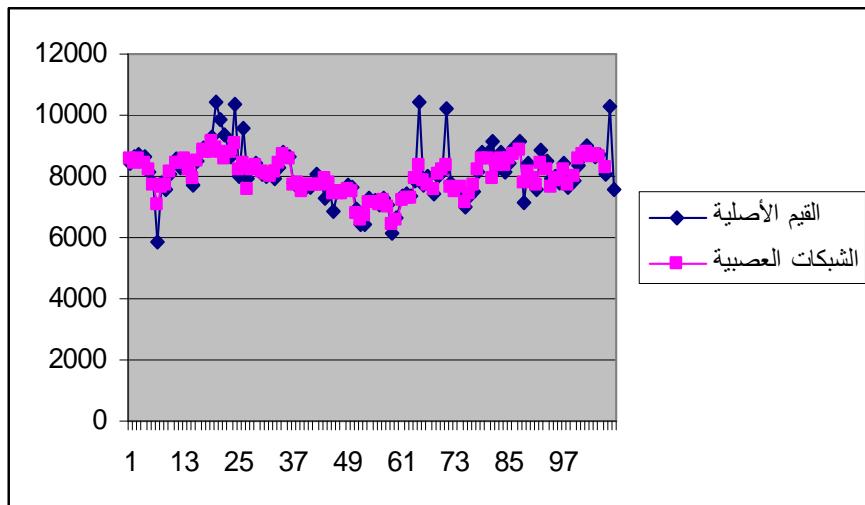
الطريقة المستخدمة	MAE	MSE	MAPE
التقنية المكيفة	٦٩٣,٢٧	٩٧٦٥,٣	٨,٢٣٣
الشبكات العصبية	٢٨٦,٤٣	٨٦٧٢,٨	٣,٥٢٤

وكلما هو واضح فإن أسلوب الشبكات العصبية قد يفوق على طريقة التقنية المكيفة على وفق المعايير الإحصائية الثلاثة . وبذلك تكون الشبكات العصبية هي الطريقة الأفضل والأكثر دقة ومتانة للتنبؤ بقيم السلسل 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- الاستنتاجات

إن أهم الاستنتاجات التي تم التوصل إليها من خلال الدراسة هي:

ان السلسلة الزمنية للمواليد الأحياء من الذكور هي سلسلة غير مستقرة وأن الاتجاه العام للسلسلة تربيعى.

تفوقت الشبكات العصبية على طريقة التقنية المكيفة ، إذ تم الحصول على نتائج ذات قيم أقل للمعايير الإحصائية المستخدمة لحساب أخطاء التنبؤ، من هنا تعد الشبكات العصبية هي الطريقة الأفضل والأكثر دقة في التنبؤ بالقيم المستقبلية للسلسلة الزمنية قيد الدراسة.

٣. تعد الشبكات العصبية طريقة بديلة عن طريقة التقنية المكيفة المستخدمة في التنبؤ التي لها القدرة على معالجة مختلف أنواع البيانات الخطية واللاخطية.

٤- 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 للسلسلة الزمنية متعددة المتغيرات Multivariate Time Series باستخدام الشبكات العصبية.

٣. ملکانية دراسة السلسلة 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 التكهن في السلسلة الزمنية لاستهلاك الطاقة الكهربائية في محافظة نينوى وسالة ماجستير غير منشورة ، كلية علوم الحاسوب والرياضيات، جامعة الموصل ، ٢٠٠٥.

٢. الشيخلي، يبيان علاء ناظم ، تصميم نظام رياضي ديناميكي لا خطمي باستخدام الشبكات العصبية (NARMAX)مراض 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، أسميل سمير مقارنة بين طرائق تحليل وتنبؤ السلسلة 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 csmecchan@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.