مجلة تنمية الرافدين

**اسم المقال:** مقارنة بين التقنية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلاسل الزمنية
**اسم الكاتب:** أ.م.د. صفاء يونس الصفاوي، م. مثينة عبدالله مصطفى
**رابط ثابت:** https://political-encyclopedia.org/index.php/library/3149
**تاريخ الاسترداد:** 2026/11/02 17:22 +03

الموسوعة السياسيّة 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 السياسيّة - Encyclopedia Political، يرجى التواصل على info@political-encyclopedia.org

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

تم الحصول على هذا المقال من موقع مجلة تنمية الرافدين كلية الإدارة والاقتصاد / جامعة الموصل ورفده في مكتبة الموسوعة السياسيّة مستوفياً شروط حقوق الملكية الفكريّة ومتطلبات رخصة المشاع الإبداعي التي ينضوي المقال تحتها.

تنمية الرافدين ٨٨ (٢٩) ٢٠٠٧
ص ص [١٧٧-١٩٢]

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

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

**مثينة عبدالله مصطفى**
مساعد باحث
كلية طب الاسنان -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 MAEومعدل القيم المطلقة لـ نسب الأخطاء MAPE معايير إحصائية للمفاضلة 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.

تاريخ التسلم ٢٠٠٦/١٢/٧_____ تاريخ قبول النشر ٢٠٠٧/٣/١٢

## ١. المقدمة

شهدت تقنية التحليل والتنبؤ فيالسلاسل الزمنية تطوراً سريعاً في الألفية الثالثة مقترنبتطور استخدام علوم الحاسبات ومن الطر ائق الشائعة في التنبؤ هي طريقة التنقية المكيفة Adaptive Filtering التي لها القابلية على التكيف مع معادلة التنبؤ للسلسلة ال عشوائية 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، ومازالت 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 الشبكات العصبية بوصفها تقنيات مساعدة للطرائق الإحصائية الاعتيادية 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 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 بواقي 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 فعّال في نماذج الانحدار الذاتي. ومن الجدير بالذكر أن المعلمات تتغير في هذه الطريقة من فترة إلى أخرى وليست ثابتة.
(Makridakis,1978)

### ٢-١ 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 :

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

اذ إن :

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

$a_t$: عبارة عن مركبة الخطأ العشوائي بوسط حسابي مساوٍ للصفر وتباين $\sigma^2_{at}$.

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

$\theta_{1t}, \ldots, \theta_{pt}$ 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 المتمثلة بـ $a^2_t$ وتكون بالصيغة الآتية:

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

وبتربيع طرفي المعادلة نحصل على

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

وبالاشتقاق الجزئي بالنسبة إلى كل من $\varphi_{1t}, \ldots, \varphi_{pt}$ وكذلك بالنسبة إلى كل من $\theta_{1t}, \ldots, \theta_{qt}$ نحصل على :

$$\frac{\partial a^2_t}{\partial \varphi_{it}} = -2a_t Z_{t-i}$$

$$i = 1,2,\ldots\ldots,p$$
$$j = 1,2,\ldots\ldots,q \qquad (2\text{-}3)$$

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

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

[AL-Nasir,2002]

$$\varphi^*_{1t} = \varphi_{1t} - k\nabla a^2 \qquad (2\text{-}4)$$

اذ إن :

$\varphi^*_{1t}$ : تمثل المعلمة المعدلة (المكيفة) الجديدة (Adaptive Parameter).

$\varphi_{1t}$ : تمثل المعلمة القديمة قبل التعديل.

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

$\nabla a^2$: تمثل متجه التدرج (Gradient Vector) لـ $a^2$ ومنها نجد:

$$\varphi^*_{it} = \varphi_{it} + 2ka_t Z_{t-i} \qquad (2\text{-}5)$$

والمستخدمة في نماذج الانحدار الذاتي وكذلك فإن:

$$\theta^*_{jt} = \theta_{jt} - 2ka_t a_{t-j} \qquad (2\text{-}6)$$

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

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

$$a^*_t = Z_t - \varphi^*_{1t} Z_{t-1} \varphi^*_{2t} Z_{t-2} - \ldots - \varphi^*_{pt} Z_{t-p} + \theta^*_{1t} a_{t-1} + \ldots \qquad (2\text{-}7)$$

$$a_t = a^*_t - a_t$$
$$= -(\varphi^*_{1t} - \varphi_{1t}) Z_{t-1} - \ldots - (\varphi^*_{pt} - \varphi_{pt}) Z_{t-p} + (\theta^*_{1t} - \theta_{1t}) a_{t-1} + \ldots$$
$$+ (\theta^*_{qt} - \theta_{qt}) a_{t-q}$$

أو

$$a_t = -2ka_t \{Z^2_{t-1} + \ldots + Z^2_{t-p} + a^2_{t-1} + \ldots + a^2_{t-q}\} \qquad (2\text{-}8)$$

وبقسمة المعادلة (8 -2) على $a_t$ ينتج :

$$\frac{|\nabla a_t|}{a_t} = 2k\,\{Z^2_{t-1} + \ldots + Z^2_{t-p} + a^2_{t-1} + \ldots + a^2_{t-q}\} \qquad (2\text{-}9)$$

ومن العلاقة الأخيرة يمكن استنتاج :

$$0 < k < \frac{1}{\{Z^2_{t-1} + \ldots + Z^2_{t-p} + a^2_{t-1} + \ldots + a^2_{t-q}\}} \qquad (2\text{-}10)$$

## ٣. الشبكات العصبية الاصطناعية

**Artificial Neural Networks(ANNs)**

الشبكة العصبية الاصطناعية هي عبارة عن نظام حاسوبي لمعالجة المعلومات يتكون من عدد كبير جدا 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 & Rosemblatt,1958)، وكانت عملية التعلم فيها مقتصرة على النماذج الخطية (Linear Models) لأغراض

التقدير أو التصنيف أو التبويب أو التنبؤ ،لهذا قلّ الاهتمام بدراسة الشبكات العصبية لعدة سنوات إلى أن تم التوصل إلى شكل جديد للإدراك الحسي بإضافة مستوى جديد اطلق عليه المستوى المخفي (المخبأ) (Hidden Level)، أكسب الإدراك الحسي القدرة على حساب الدوال والعلاقات لنماذج البيانات الخطية واللاخطية ، وتطور بينهما هذا المستوى بإضافة أوزان تربط بين مستوى 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 $\delta_k$ فيستخدم معامل تصحيح الخطأ $\delta_k$ 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 $\delta_j$ 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.

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

$$y = f(u - \theta) \qquad (3\text{-}2)$$

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

$$h_j = f\left(\sum_j w_{ij} \, x_i - \theta_j\right) \qquad (3\text{-}3)$$

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:

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

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

$$E_k = t_k - y_k \qquad (3\text{-}5)$$

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

$$\delta_k = (t_k - y_k). \, f_{(v)} \qquad (3\text{-}6)$$

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 التغير في حجم الخطأ $\Delta w_{jk}$ وبموجب المعادلة :

$$\Delta w_{jk} = n. \, \delta_k. \, h_j \qquad (3\text{-}7)$$

٧. تجمع كل عقدة في الطبقة المخفية إشارات المدخلات الموزونة إلى $\delta$ وكما في الصيغة :

$$\Delta_j = \sum_j \delta_k \, w_{jk} \qquad (3\text{-}8)$$

ومن ثم تضرب هذه القيمة بتابع التنشيط لحساب $\delta_j$ وبعد ذلك يتم حساب التغيير في حجم الخطأ $\Delta v_{ij}$ بالصيغة:

$$\Delta v_{ij} = n. \, \delta_j. \, x_i \qquad (3\text{-}9)$$

تحدث الأوزان لكل عقدة في طبقة المخرجات وبموجب الصيغة:

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

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

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

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 للأنموذج قيد البحث.

إذ إن :

$x_1, x_2, \ldots, x_n$ تمثل المدخلات

$w_1, w_2, \ldots, w_n$ تمثل الأوزان مابين المستويات

u : حساسية العصبون

$\theta$ : تمثل العتبة

y : تمثل مخرجات الشبكة

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

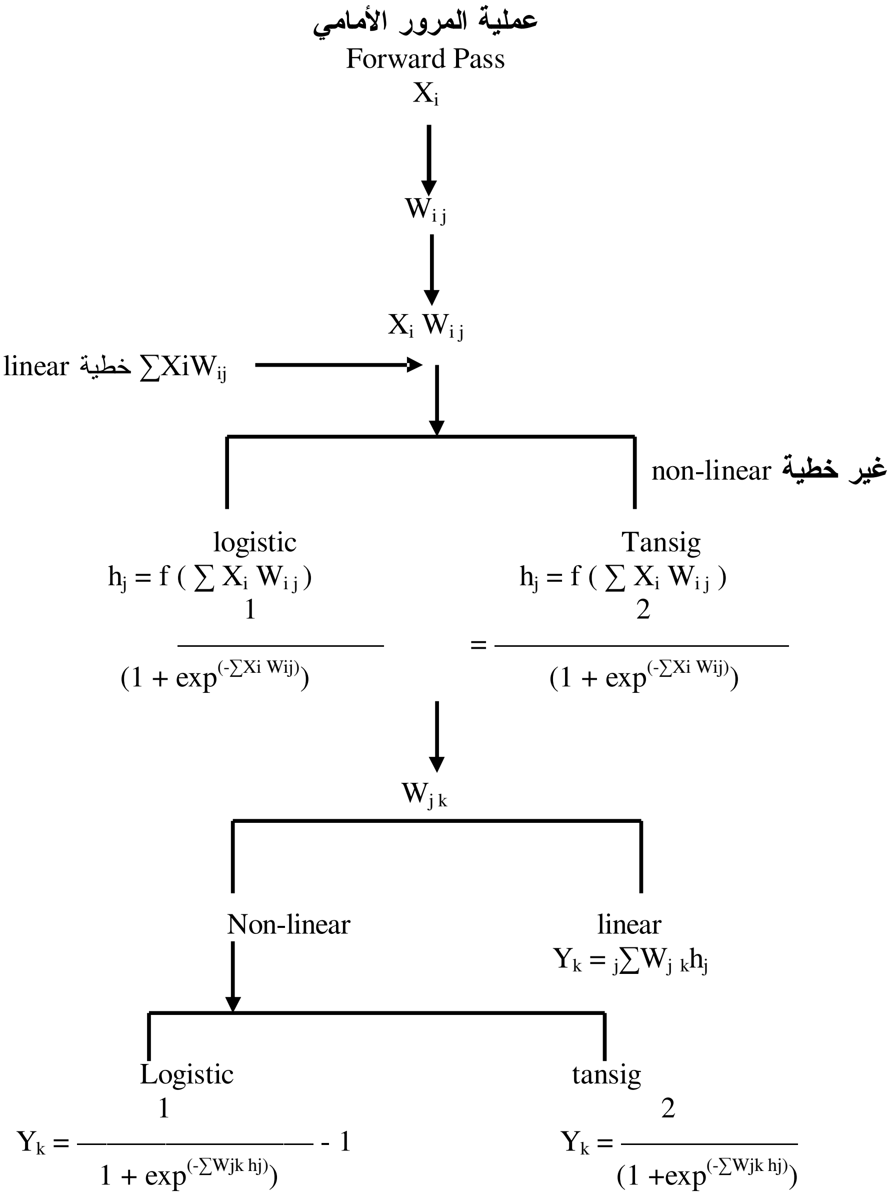
$$f(v) = 1 / \exp^{(-v)} \qquad (3\text{-}12)$$

تنحصر قيمة الدالة f (v) بين (-1,1)

$V_k$ : تمثل المخرجات التوليفية الخطية.

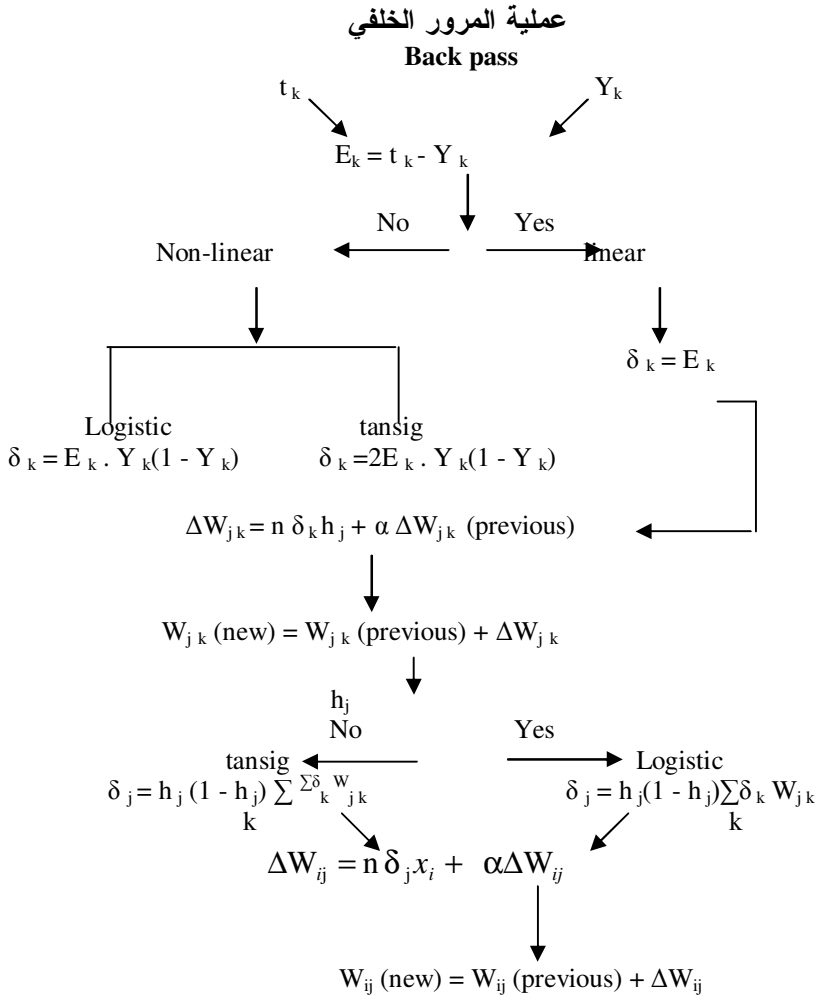
t : المخرجات الفعلية أو المرغوب فيها.

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.
$\Delta W_{ij}$ : التغير في وزن مستوى المدخلات إلى المستوى المخفي.

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

$t_k$ : قيمة المخرجات للوزن السابق.

n : معدل التعلم.

$\delta$ : مشتقة الخطأ.

$\alpha$ : الزخم.

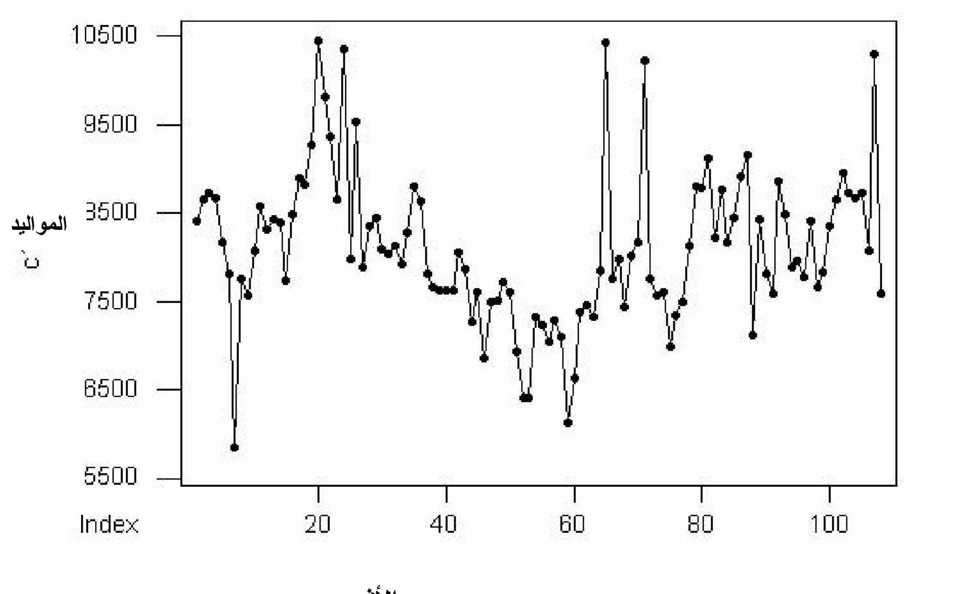
**٤. الجانب التطبيقي**

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

١. التنقية المكيفة.

٢. الشبكات العصبية ذات الأنتشار العكسي للخطأ.

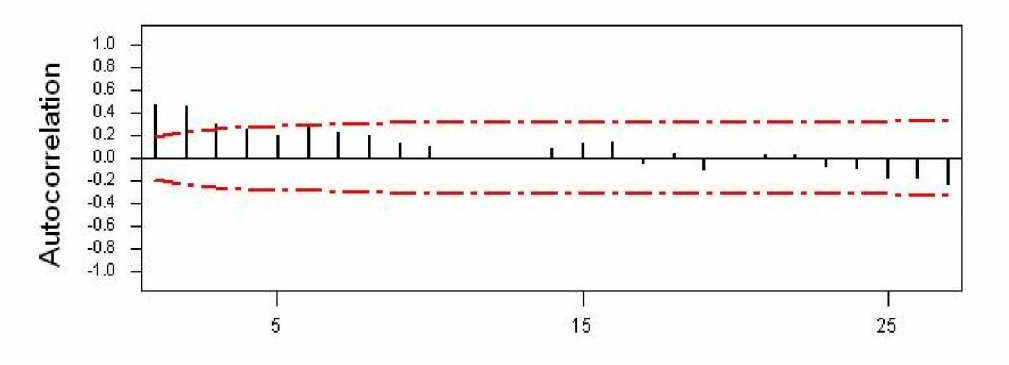
وقد تم استخدام بيانات مثلت عدد المواليد الأحياء من الذكور في مدينة الموصل، الحصول عليها من دائرة صحة نينوى / قسم الإحصاء الصحي والحياتي للفترة من ١٩٩٥/١/١ ولغاية ٢٠٠٣/١/٣١. وتم رسم السلسلة الزمنية، وكان الأتجاه العام لها بالأعتماد على متوسط مربعات الخطأهو تربيعي.




**الشكل ٣**

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

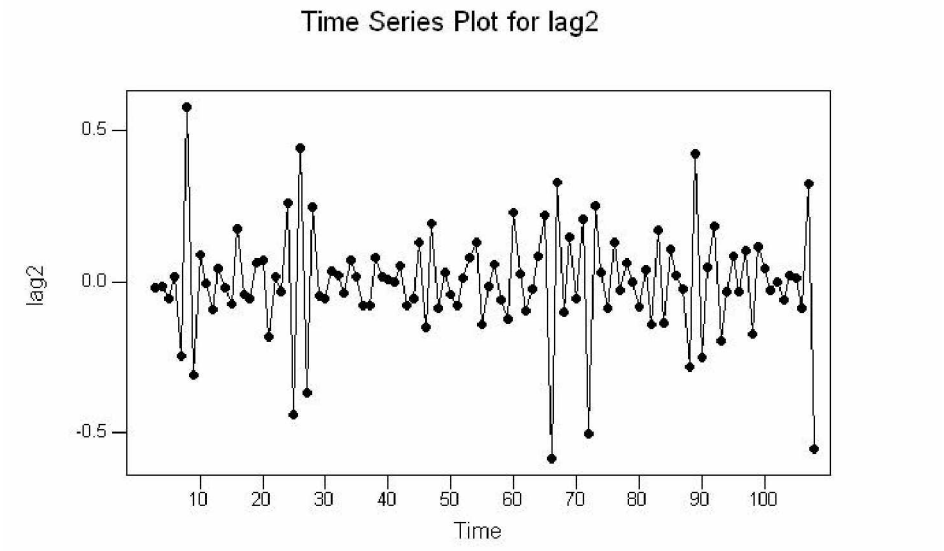
أما الشكل ٤ فيوضح مقدار دالة الارتباط الذاتي ACF للمشاهدات الخام.



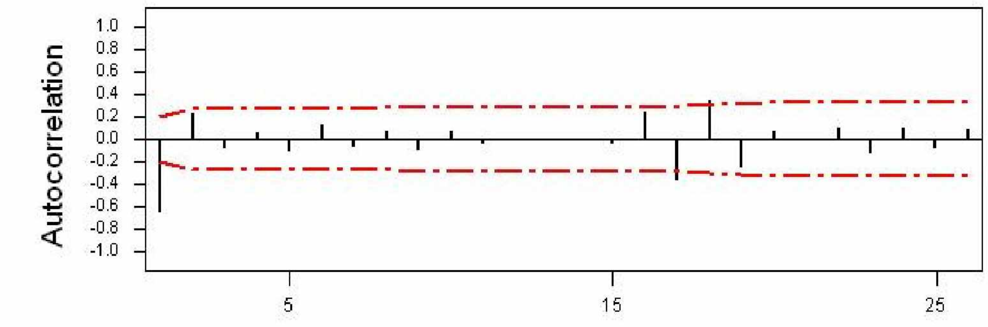

**الشكل ٤**
**دالة الارتباط الذاتي للمشاهدات الخام**

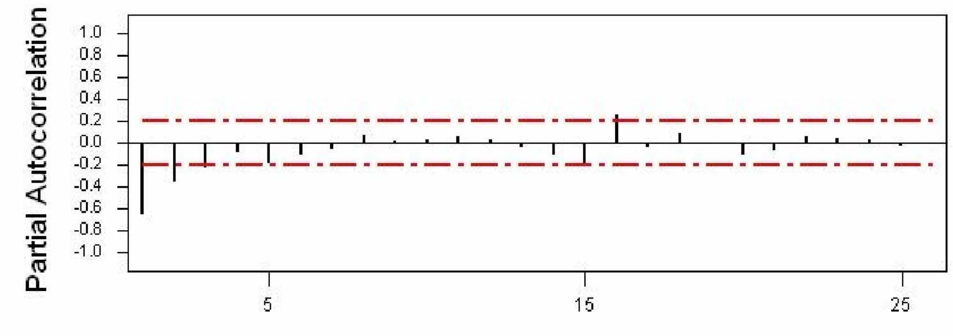
ويتضح من الشكل ٣ السلسلة الزمنية و الشكل ٤ سلوك دالة الا رتباط الـــذاتي أن السلسلة غير مستقرة.

ولغرض جعل السلسلة مستقرة تم أخـــذ التحويـــل أللوغـــاريتمي للتوصـــل للاستقرارية في التباين ، ولجعل السلسلة الزمنية مستقرة في الوسط الحسابي أخـــذت الفروقات (Differences) وبدء بالفرق الأول($\nabla x_t$) ثم الفرق الثـــاني ($\nabla^2 x_t$) الـــذي 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 الأ نموذج الملائم هـو ARMA(1,1) وللدقـة وسـلامة التشخيص فقد تم استخدام معيار أكاكي (ACI) لتحديد رتبة الأنموذج فكانت قيمتـه الصغرى عند الأنموذج ARMA(1,1) .

بعد أن تحولت السلسلة الزمنية إلى مستقروتم تحديد رتبـة الأ نمـوذج يـتم استخدام طريقة التنقية المكيفة والشبكات العصبية ذات الأنتشار العكسي للخطأ للتنبؤ المستقبليلعدد المواليد الأحياء من الذكور في مدينة الموصـل، وكانـت النتـائج بالشكل الآتي:

**أولاً - باستخدام طريقة التنقية المكيفة**

لقد تم استخدام البرنامج الحاسوبي المعد من خـلال (Macros) ومـن خـلال شاشة التشغيل MS-Dosوتشغيله وعرض نتائجه من خلال شاشات نظام Minitab، وإن البيانات كانت وفقاً للأنموذج ARMA(1,1)وتم تحديد معالم الأ نموذج الابتدائية $(\varphi_{=0.497490})$ و $(\theta_{=0.977024})$ وقيمـة (MSE=0.001)وكـذلك الأخطـاء العـشوائية (Residuals)، تبدأ عملية احتساب المعلمات بشكل مستمر بحلقات تكرارية مناسـبة إلى أن يتم التوصل إلىأفضل قيم للمعلمات وبأقل متوسـط مربعـات خطـأ تـم الحصول عليه، أي أن الفرق بين كل قيمتين متنبأ بهما لا يزيد عـن (0.001) عنـد

ذلك يتوقف التنبؤ وتنتهي عملية تعديل المعلمات بهذه الطريقة. أما معـــايير جـــودة التنبؤ فكانت كما يأتي:

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

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

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

**ثانياً - باستخدام الشبكات العصبية ذات الأنتشار العكسي للخطأ**

لقد تم استخدام برنامج بلغة $C^{++}$ لغرض الوصول إلى قـــيم التنبـــؤ وحـــسابها بشكل دقيق فقد تم تحديد عدد العقد المخفية بـ- ٤ عقد وطبقتين مخفيتـــين وحـــسب عدد مرات التدريب ، وبما أن بيانات المستخدمة في هذا البحث بلغ عـــددها ١٠٨ مشاهدة فقد عد ١٥% منها على أنها مشاهدات اختبار Testلغرض الا ختبار وعدت ١٦% من المشاهدات مجموعة الشرعية Validation، أما بـــاقي المـــشاهدات فقـــد استخدمت للتدريب وتقدير قيمة متوسط مربعات الخطأ (MSE) لغرض الحـــصول على أفضل النتائج، وإن أفضل شـــبكة (Best Networ) عنـــد ٥٠٠٠ تكـــرار، وإن الشرعية سلكت سلوك التدريب نفسه ولكن بأقل خطأ مطلق. ومن خـــلال تـــدريب الشبكة العصبية تم التوصل إلى قيم التنبؤ واحتساب المعلمات الأحصائية . والـــشكل ٧ يوضح قيم التنبؤ المحسوبة بهذه الطريقة.

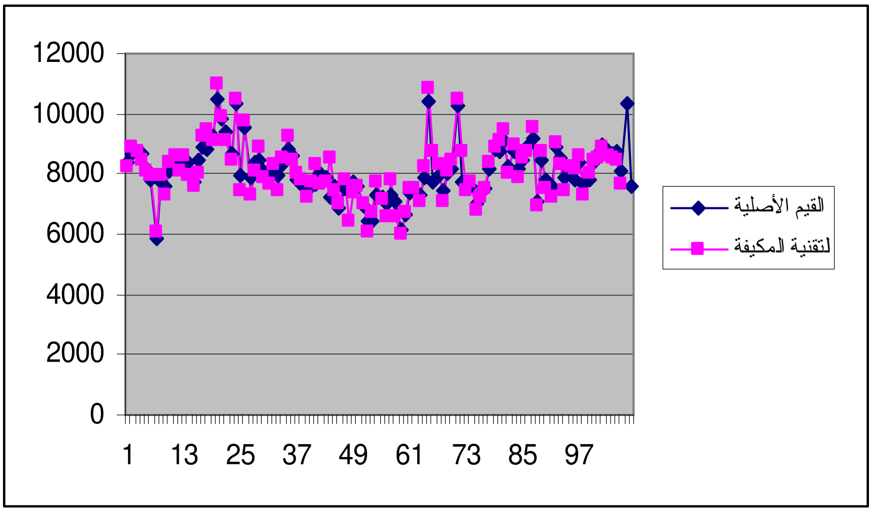
ولغرض المقارنة مبين الأسلوبين تم أعتماد المعايير الإ حصائية: معدل القيم المطلقة للأخطاء (MAE)، ومعدل مربعات الخطأ (MSE)، ومعدل القـــيم المطلقـــة لنسب الأخطاء (MAPE).

**الجدول ١**
**المعايير الإحصائية للاسلوبين**

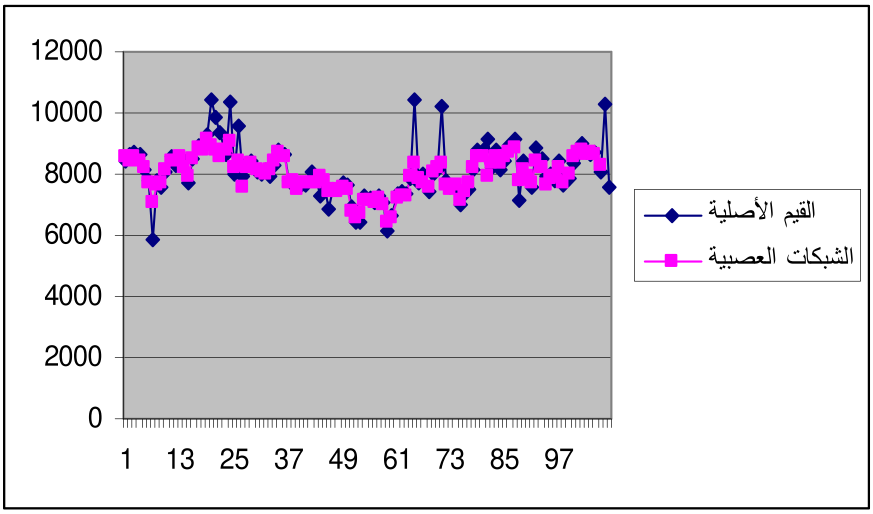
| الطريقة المستخدمة | MAPE | MSE | MAE |
|---|---|---|---|
| التنقية المكيفـــــــــة | ٨,٢٣٣ | ٩٧٦٥,٣ | ٦٩٣,٢٧ |
| الشبكات العصبيـــــة | ٣,٥٢٤ | ٨٦٧٢,٨ | ٢٨٦,٤٣ |

وكما هو واضح فإن أسلوب الشبكات العصبية قد يفوق على طريقـــة التنقيـــة المكيفة على وفق المعايير الإحصائية الثلاثة . وبذلك تكون الشبكات العـــصبية هـــي الطريقة الأفضل والأكثر دقة ومتانة 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 الاستنتاجـــات**

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

١. إن السلسلة الزمنية للمواليد الأحياء من الذكور هي سلسلة غيـــر مـــستقرة وأن الاتجاه العام للسلسة تربيعي.
٢. تفوقت الشبكات العصبية على طريقة التنقية المكيفة ، إذ تم الحصول على نتـــائج ذوات قيم أقل للمعايير الإحصائية المستخدمة لحساب أخطاء التنبؤ، من هنا تعدّ الشبكات العصبية هي الطريقة الأفضل والأكثر دقة في التنبؤ بالقيم المـــستقبلية للسلسلة الزمنية قيد الدراسة.
٣. تعد الشبكات العصبية طريقة بديلة عن طريقة التنقية المكيفة المـــستخدمة فـــي التنبؤ التي لها القدرة على معالجة مختلف أنواع البيانات الخطية واللاخطية.

**٤ -٢ التوصيـــات**

على ضوء الاستنتاجات أعلاه نوصي بما يأتي :

١. إجراء دراسات باستخدام شبكات عصبية أخرى غير شبكة الانتـــشار العكـــسي للخطأ مثل شبكة المدرك وشبكة Hop filed, مقارنة النتائج.
٢. إجراء دراسات للتنبؤ بالقيم المستقبلية للسلاسل الزمنيـــة متعـــددة المتغيـــرات Multivariate Time Series باستخدام الشبكات العصبية.
٣. إمكانية دراسة السلاسل الزمنية متعددة المتغيرات فـــي الدراســـات المـــستقبلية لحالات قد تتطلبها بحوث التنبؤ خاصة في المجالات الطبية والولادات التي قـــد 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 لاســـتهلاك الطاقة الكهربائية في محافظة نينوى وسالة ماجستير غير منشورة ، كلية علـــوم الحاســـبات والرياضيات، جامعة الموصل، ٢٠٠٥.

٢. الشيخلي،ريهان علاء ناظم ، تصميم نظام رياضي ديناميكي لا خطـــي باســـتخدام الـــشبكات العصبية (NARMAX) لأغراض 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، الخوارزميـــات، التطبيقات، ٢٠٠٠.

٤. محمد، أسيل سمير،مقارنة بين ط رائق تحليل وتنبؤ السلاسل الزمنية وتطبيقاتها على مبيعات الشركة العامة لتوزيع كهرباء بغداد ،أطروحة دكتوراه ، كليـــة الإدارة والاقتـــصاد، جامعـــة 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.