المجلة العراقية للعلوم الاحصائية (18) 2010

ص ص [1-32]

تحليل ونمذجة السلسلة الزمنية لتدفق المياه الداخلة الى مدينة الموصل

دراسة مقارنة

ظافر رمضان مطر* انتصار ابراهيم الياس

الملخص

يقدم هذا البحث مطابقة لنموذج شبكات عصبية ومقارنة التكهنات الناتجة مع تلك المستحصلة من طريقة بوكس- جنكنز , وقد استخدمت بيانات السلسلة الزمنية للتدفق الشهري لمياه نهر دجلة الداخلة الى مدينة الموصل للفترة من 1950-1995 لانجاز عملية المقارنة. إن عمل التكهن من خلال اسلوب بوكس- جنكنز وأسلوب الشبكات العصبية لا يعني العمل ضمن مجالين مختلفين أو متنافسين بل على العكس من ذلك فان اختيار معمارية الشبكات العصبية الملاءمة يتطلب استخدام مهارات النمذجة الإحصائية , وفيما يتعلق بالتطبيق فقد أعطى أسلوب بوكس – جنكنز تكهنات لأشهر عام 1995 أكثر ملاءمة من تلك التي قدمها أسلوب الشبكات العصبية , وقد استخدمت البرامج الجاهزة Minitab و SPSS في الجانب الإحصائي والبرنامج الجاهز Alyuda في جانب الشبكات العصبية .

* أستاذ / قسم الإحصاء والمعلوماتية/ كلية علوم الحاسوب والرياضيات-جامعة الموصل/العراق

تاريخ التسلم :5/ 4/ 2010 ــــــــ تاريخ القبول : 18/7 /2010

Analysis and Modeling Time Series of Water Flow into Mosul City A Comparative Study

Abstract

This paper presents fits for neural network model , and comparative resulting forecasts with those obtained from Box-Jenkins Method. We use time series data of Tigris's monthly flow into Mosul city from 1950-1995. To perform a comparative . forecasting work through the Box-Jenkins and neural network doesn't mean working with two different or competing aspect ; on the contrary choosing a proper architecture of neural net works requires using the skills of statistical modeling . As for application , Box-Jenkins Method has given more appropriate forecasts than those given by feed forward artificial neural network . We used Minitab and SPSS programs in the statistical aspect and Alyuda program in the neural network aspect.

1-مقدمة Introduction

تعد عملية التكهن من المسائل الشائعة في العديد من مجالات العلوم كالكهرباء والهيدرولوجيا والاقتصاد...الخ ، وكانت هذه العملية محط اهتمام الإحصائيين لفترة طويلة من الزمن (Lendasse,et al.,2000) . ولان التكهن له أهمية واضحة ومؤثرة في دقة القرار ، ولوجود ارتباطات ذاتية عالية ضمن مجموعات البيانات ، فان الفشل في اخذ الاعتماد الزمني بنظر الاعتبار ينتج عنه تكهن ضعيف (Karaman , 2004) .

بالنظر لأهمية السلاسل الزمنية فان العديد من الأعمال يمكن ملاحظتها في الأدبيات حول هذه المواضيع وبصورة خاصة تلك التي تعتمد على النماذج الإحصائية Statistical Models ، ويوجد العديد من الأساليب الممكنة لوصف السلوك الزمني ويعد أسلوب بوكس جنكنز أسلوباً جذابا في تحليل السلاسل الزمنية إذ

يزودنا بمنهجية نمذجة إحصائية شاملة ويغطي تنوعاً واسعاً من الأنماط تمتد من الاستقرارية إلى عدم الاستقرارية والموسمية للسلاسل الزمنية . إن احدى المشكلات التي تسبب إزعاجاً لتطوير واستخدام نماذج بوكس – جنكنز هي متطلبات صياغة النموذج من حيث التوزيع الاحتمالي المفترض للبيانات ، إذ تعد منهجية بوكس – جنكنز في بعض الأحيان غير ملاءمة لحالات محددة فهي تفشل في وصف السلوك المتغير ديناميكيا مع الزمن (Behavior Varies Dynamically with Time) (Rojas and Pomares , 2004).

إن الطرائق الأخرى المعتمدة على الأساليب غير الخطية مثل الشبكات العصبية Neural Networks والمنطق المضبب Fuzzy Logic والخوارزمية التطورية Developing Algorithm قدمت حلولا لمثل هذه الحالات . وقد وفرت الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs) بعض الميزات الاحتمالية أكثر من نماذج ARIMA للسلاسل الزمنية بتعاملها مع مشاكل البيانات غير الطبيعية Non Normal وغير الخطية Non Linear ، وان احدى ميزات هذه الشبكات هو تعدد استخدامها وعدم تطلبها نموذجاً قياسياً بمواصفات أو توزيعات احتمالية مفترضة للبيانات هذا من جانب ، ومن جانب أخر قابلية هذه الشبكات على احتمال وجود المكونات الفوضوية Chaotic Components بشكل أكثر من اغلب الطرائق البديلة وبسبب ان العديد من السلاسل الزمنية المهمة تمتلك مكونات فوضوية معنوية فان هذه القابلية تعد مهمة (Rojas and Pomares,2004).

لقد وجد بان نموذج الشبكات العصبية الذي يقدم مطابقة جيدة للبيانات ربما يعطي تكهنات ضعيفة خارج العينة Out-of-Sample ، لذلك فان التحليل الحكيم يتطلب استخدام مهارات النمذجة الإحصائية لاختيار نموذج الشبكات العصبية الجيد(Chatfield and Faraway,1998) . إن ذلك يقدم مؤشراً على إن العلاقة بين نماذج الشبكات العصبية ونماذج بوكس جنكنز يمكن أن تكون علاقة تكامل لا تنافس وصولا إلى نماذج بمطابقة وتكهنات جيدة .

2- هدف البحث

نظرا لأهمية دراسة الأنهار بنواحيها المتعددة ومنها التكهن بتدفق النهر فان الهدف الرئيس للبحث هو تحليل ومناقشة النمذجة التصادفية للسلسلة الزمنية لنهر دجلة عند دخوله مدينة الموصل باستخدام أسلوب النمذجة الاحصائية (نماذج بوكس– جنكنز) واسلوب الشبكة العصبية الاصطناعية (**خوارزمية الانتشار الخلفي**).

3- بعض نماذج السلاسل الزمنية Some Time Series Models

أ- عمليات المتوسطات المتحركة Moving Average Processes

بافتراض إن $\{u_t \mid t \in T\}$ هي عملية تشويش ابيض White Noise Process بمعدل صفر وتباين σ_u^2. عندئذ يقال للعملية $\{x_t \mid t \in T\}$ بأنها عملية متوسطات متحركة من الرتبة q،ويشار إليها بالرمز MA(q) وصيغتها: انظر(فاندل،1992; Anderson,1976 ; Powell ,1997).

$$x_t = u_t + \alpha_1 u_{t-1} + \alpha_2 u_{t-2} + \ldots + \alpha_q u_{t-q} \quad ; \quad t \in T \ldots(1)$$

إذ $\{\alpha_i\}$ تمثل معلمات المتوسطات المتحركة Moving Average Parameters(أي تمثل الثوابت Constants)،بينما التغيرات العشوائية مستقلة عن بعضها البعض.

ب- عمليات الانحدار الذاتي Autoregressive Processes

لتكن $\{u_t \mid t \in T\}$عملية تشويش ابيض بمعدل صفر وتباين σ_u^2 عندئذ يقال للعملية $\{x_t \mid t \in T\}$بأنها عملية انحدار ذاتي من الرتبة p ، ويشار أليها بالرمز AR(p) ، وصيغتها: نظر(فاندل،1992 , Xuan, 2004 ; Powell ; Anderson , 1976 ;1997):-

$$x_t = \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \beta_p x_{t-p} + u_t \qquad \dots(2)$$

حيث$\{\beta_i\}$تمثل معلمات الانحدار الذاتي Autoregressive Parameters(أي تمثل الثوابت) .

ج- نماذج الانحدار الذاتي والمتوسطات المتحركة المندمجة

Mixed Autoregressive Moving Average Models

إن الفئة المفيدة من السلاسل الزمنية هي التي تكون بصيغة دمج عملية الانحدار الذاتي AR وعملية المتوسطات المتحركة MA ، اذ إن نموذج الانحدار الذاتي والمتوسطات المتحركة المندمجة يحتوي على p من حدود عملية الانحدار الذاتي و q من حدود عملية المتوسطات المتحركة ويشار الى هذا النموذج بالرمز ARMA(p,q) وكما ياتي انظر(فاندل،1992 Xuan , 2004 ; Powell , 1997 ; Anderson , 1976 ;):-

$$x_t=\beta_1 x_{t-1}+\beta_2 x_{t-2}+\dots+\beta_p x_{t-p}+u_t-\alpha_1 u_{t-1}-\alpha_2 u_{t-2}-\dots-\alpha_q u_{t-q} \qquad .(3)$$

حيث $\{u_t \mid t \in T\}$ تمثل سلسلة تشويش ابيض ونلاحظ بان عمليات الانحدار الذاتي من الرتبة p والمتوسطات المتحركة من الرتبة q والتي عرضت بصورة واضحة في أ و ب هي حالات خاصة من عملية ARMA(p,q).

ان اغلب السلاسل الزمنية هي سلاسل غير مستقرة فقد يكون الاتجاه العام عنصرا من عناصر هذه السلاسل وفي هذه الحالة يجب اخذ الفرق العادي وقد تستدعي الحالة اخذ الفرق الموسمي او كليهما لتحقيق الاستقرارية والنموذج العام في حالة اخذ الفرق العادي يشار اليه بنموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ويرمز له بـ ARIMA(p,d,q) .

4- **التكهن** Forecasting

إن هدف التكهن Object of Forecasting رياضياً هو الحصول على اقل متوسط مربع لخطأ التكهنات Minimize Mean Square Error of Forecasting (Powell,1997). بافتراض أن t تشير الى الفترة الزمنية الحالية التي يتم عندها حساب التنبؤات والمطلوب التنبؤ بقيمة المشاهدة التي ستحدث بعد h من الفترات الزمنية ، أي التنبؤ بقيمة المشاهدة y_{t+h} التي لم تحدث بعد . تسمى h في هذه الحالة بأفق التنبؤ Prediction-Horizon أو الزمن الدليل Lead Time (فاندل ، 1992 ;Girard ,et al.,2002). أيضا ، تشير$y_t(h)$ الى القيمة التنبؤية التي نحصل عليها في الفترة الزمنية t للمشاهدة y_{t+h} التي ستحدث بعد h من الفترات الزمنية . فمثلاً, أذا كانت h=1 ، فأن $y_t(1)$ تشير إلى القيمة التنبؤية التي نحصل عليها في الفترة t للمشاهدة y_{t+1} التي ستحدث بعد فترة زمنية واحدة ، وهكذا (فاندل ، 1992).

إن قاعدة القرار الشائعة عند مقارنة النماذج في أدبيات السلاسل الزمنية استخدام معيار معلومات اكاكي AIC وقد أشار (Kumar and Mujumdar,1990) إلى عيوب نظرية theoretical واخرى عددية numerical في هذا المعيار بما يأتي :-

أولا:- إن معيار معلومات اكاكي (AIC) لا يمتلك خاصية الامثلية Optimal Property بعبارة أخرى انه لا يخفض قيمة المعدل لأية دالة معيار.

ثانيا: إن قانون معيار معلومات اكاكي (AIC)غير متسق Not Consistent بمعنى إن احتمال ذهاب قاعدة القرار لاختيار نموذج خطأ Wrong Model هذا الاحتمال لا يذهب إلى الصفر حتى أذا اقترب عدد المشاهدات من ما لا نهاية (∞) .

لذلك فقد أوصى(Chatfield and Faraway , 1998) باستخدام تصحيح التحيزBias-Corrected لمعيار معلومات اكاكي AIC (بمعنىAIC_cالذي اقترحه

Brockwell and Davis (1993) ، وذلك بإضافة 2 (p+1) (p+2) /(n-p-2) إلى قيمة (AIC)، وهذا يجعله اقل فرقا للقيم الصغيرة ل(P) بينما للقيم الكبيرة (P) فانه يتعامل بصرامة اكبر مع المعلمات الإضافية أكثر من معيار معلومات اكاكي (AIC). إن معيار (AIC_c) غير مألوف عند العديد من الإحصائيين ويستحق انتباه أكثر من قبلهم لتجاوز سلبيات معيار (AIC) .

$$AIC = n\ ln(^{S}/_{n})\ +2P \qquad (Akaike\ Information\ Criterion)$$

$$AIC_c = AIC + \frac{2(P+1)(P+2)}{n-P-2} \quad (Corrected\ Akaike\ Information\ Criterion)$$

حيث أن :

n: تمثل عدد المشاهدات الفعالة Effective observations المستخدمة في مطابقة النموذج .

P: تمثل عدد المعلمات (الأوزان) الملاءمة في نموذج الشبكات العصبية .

S: تمثل مجموع مربعات البواقي Sum of Squared Residuals ، أذ إن البواقي تمثل خطا تكهن لخطوة واحدة الى الأمام داخل العينة Within Sample.

5- الشبكات العصبية الاصطناعية ومعماريتها:

Artificial Neural Network and its Architecture

5-1 تعريف الشبكة العصبية الاصطناعية ومجالات استخدامها:

Definition of Artificial Neural Network and its Using Areas

تعرف الشبكة العصبية الاصطناعية(ANN) على أنها نظام حسابي مكون من عدد من وحدات(عصبونات) المعالجة(Processing Elements)المترابطة مع بعضها

وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليها(ألعبيدي،2000;Kumar,et al. ,2004).

تعد الشبكات العصبية من أهم الأساليب التي تستخدم في الكثير من التطبيقات التي يصعب إيجاد الحلول لها بالطرائق والخوارزميات التقليدية وذلك لاعتماد معظم الشبكات العصبية على أسلوب المحاكاة للواقع الحقيقي لحل هذه المشاكل (الصقال وطاهر، 2006)، لذا فان الشبكات العصبية الاصطناعية (ANNs) تكون وسيلة فعالة لحل مسائل متنوعة تتضمن تصنيف الأنماط Pattern Classification وتمييز الأنماط(Pattern Recognition) (ألعبيدي،2000;Christopher,2000) ، ويمكن استخدامها أيضا في المسائل المالية والطب والجيولوجيا والهندسة لمسائل مثل التنبؤ والتصنيف والعنقدة(Clutering) أنظر(Andereescu,2004).وتستخدم كذلك في حقول الكيمياء والهندسة الكيميائية .

2-5 مكونات الشبكة العصبية الاصطناعية:

Artificial Neural Network Components

هناك ثلاث ميزات (صفات) للشبكات العصبية الاصطناعية (ANNs) يتم من خلالها وصف الشبكة العصبية وهي (عيسى,2000; Allende,et al.,1999):

1. شكل الترابط بين العصبونات (وهو ما يدعى بالمعمارية).
2. الطريقة التي تحدد الأوزان لهذه الترابطات (والتي تدعى التدريب، التعلم، الخوارزمية).
3. نوع دالة التنشيط المستخدمة.

3-5 معمارية (هيكلية) الشبكة العصبية الاصطناعية:

Artificial Neural Network Architecture (Structure)

إن ترتيب العصبونات في الطبقات أو المستويات ، وشكل الترابطات ضمن أو بين الطبقات يدعى بالبنية الهندسية أو معمارية (هيكلية) الشبكة العصبية. ويتم

حساب عدد الطبقات في الشبكة بدون حساب طبقة الإدخال أو يمكن معرفتها من عدد الترابطات بين العصبونات (عيسى،2000).

وتصنف الشبكات العصبية الاصطناعية من حيث عدد طبقاتها إلى نوعين أنظر(ألعبيدي،2000; عيسى, 2000; الصقال وطاهر، 2006; Moseley,2003; Kumar,et al.,2004; Andreescu, 2004):

أ.الشبكات وحيدة الطبقة Single Layer Networks

تتكون هذه الشبكات من طبقتين فقط،هما طبقة المدخلات (Input Layer) وطبقة المخرجات (Output Layer). وتكون انسيابية الإشارات الداخلة من طبقة المدخلات إلى طبقة المخرجات باتجاه إمامي Forward Direction .

ب.الشبكات متعددة الطبقات Multi Layer Network

تحتوي هذه الشبكات على طبقة واحدة أو أكثر من الطبقات الوسطية (التي تمثل الطبقات المخفية Hidden Layers) فضلا عن طبقة المدخلات وطبقة المخرجات . وتتميز هذه الشبكات بقدرتها على حل مسائل أكثر تعقيداً من المسائل التي يمكن حلها في الشبكات ذات الطبقة المفردة بسبب وجود الطبقات الوسطية التي تعطي مرونة أكثر في بناء الدوال الناقلة بين المدخلات والمخرجات ، وعلى الرغم من ان تدريب هذه الشبكات يستغرق وقتاً أطول لكن التدريب لهذه الشبكات ناجح أكثر من غيره . إذ يمكن أن نتعرض لمشكلة لا يمكن حلها إطلاقا باستخدام شبكة وحيدة الطبقة حتى لو دربت لفترة طويلة.وتتطلب العديد من المشاكل المطلوب حلها شبكات عصبية متعددة الطبقات ، علما أن الخصائص المميزة للمشكلة هي التي تقرر أي نوع من الشبكات يتم استخدامه. وتنقسم هذه الشبكات إلى نوعين هما: الشبكات ذات التغذية الأمامية والشبكات ذات التغذية الخلفية (العكسية) .وفي الشبكة العصبية ثلاث طبقات من الأوزان هي (عيسى 2000) :-

1.طبقة الوزن بين مستوى الإدخال والمستوى المخفي(Input to Hidden Weights).

2.طبقات الأوزان بين المستويات المخفية (Hidden Weights).

3.طبقة الوزن بين المستوى المخفي ومستوى الإخراج (Hidden to Output Weights).

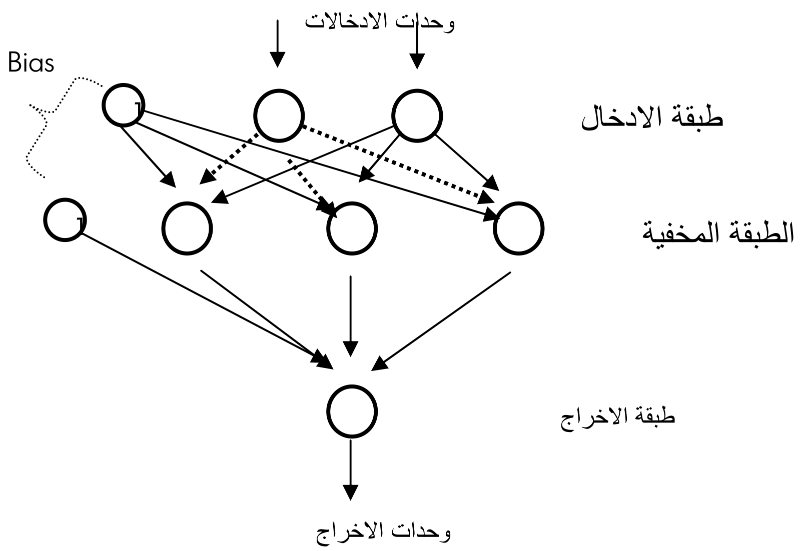

الشكل (1): مخطط يوضح معمارية الشبكة العصبية الاصطناعية النموذجية

6- **الشبكات العصبية الاصطناعية** Artificial Neural Networks

في الشبكة العصبية الاصطناعية ان الإشارة الخارجة من أية خلية تعتمد على الإشارات الداخلة كما موضح بالشكل(1) أنظر (ألعبيدي ،2000; Ghodsian et al.,2003; Andreescu,2004; Kumar et al. ,2004).

وهذه الشبكة تكون عادة غير دورية أو غير تكرارية بمعنى أخر ، الارتباطات بين العقد غير دورية(Christopher,2000) . وتستند الشبكة العصبية الى مفهوم تدريب الشبكة المعتمد على حجم الخطأ (متوسط مربع الخطأ) ، حيث تحدث الأوزان بين الطبقات بقدر مساهمة الوزن في تكوين الخطأ وتستمر الشبكة في تحديث الأوزان حتى الحصول على الأوزان المثلى التي تحقق أفضل توفيق للنموذج (الناصر والعبيدي، 2003) .

ويجري تعليم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلمLearning Algorithms تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل إشارة الخطأ فيها Error Signal استناداً إلى مقياس معلوم للوصول إلى النتيجة المثلى لهذه الأوزان التي تمكن الشبكة من تحقيق أفضل نتيجة مطابقة أو قريبة من النتيجة المطلوبة . ويجري تعديل هذه الأوزان جزئياً في كل دورة وتؤخذ إشارة الخطأ دليلاً ومؤشراً على مدى القرب أو البعد عن القيم الصحيحة. إن الشكل(2) يوضح المخطط العام لتعديل (تكييف) الأوزان (ألعبيدي ، 2000).

ومن الخوارزميات المشهورة في التعليم الموجه ، خوارزمية الانتشار الخلفي (للخطأ) Back- Propagation وتسمى أيضا بخوارزمية قاعدة دلتا العمومية (العامة) Generalized Delta Rule التي تمثل الطريقة القياسية في تدريب الشبكة العصبية الاصطناعية(ANNs).وهذه الطريقة الشائعة تعمل على تقليل الخطأ وهي مربعات المتوسطات الصغرى القياسية (LMS) (لأنها بكل بساطة عبارة عن طريقة الإنحدار التدريجي Gradient Descent وذلك لإيجاد القيمة الصغرى لمربع الخطأ الكلي لقيمة الإخراج المحسوب من قبل الشبكة) وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكات العصبية الاصطناعية. وتستخدم هذه الخوارزمية لتعليم الشبكات متعددة الطبقات انظر (ألعبيدي،2000; عيسى،2000; الكسو،2005 Kisi,2005; Andreesc 2005

;Christopher,2000;2004,)، وتكون الصيغة الرياضية لتعديل الأوزان كالأتي (ألعبيدي ، 2000) :

$$\Delta w_{ji}(k+1) = \eta\, \delta_j\, X_i + \rho \Delta w_{ji}(k)$$

Where

$$\delta_j = f'(net)(d_j - y_j) \quad \textbf{for Output Layer}$$

$$\delta_j = f'(net)\sum \delta_j w_{ij} \quad \textbf{for Hidden Layer}$$

إذ أن:-

ρ: هي معامل الزخم Momentum Term.

Δwji : مقدار التعديل على وزن الخليتين i,j .

η: معامل نسبة التعلم Learning Rate.

δ: معامل تعديل الأوزان (الفرق بين الإشارة الخارجة والقيمة المطلوبة).

d: القيمة المطلوبة Desired Value .

y: قيمة الإشارة الخارجة.

k: مؤشر التكرار Iteration Index .

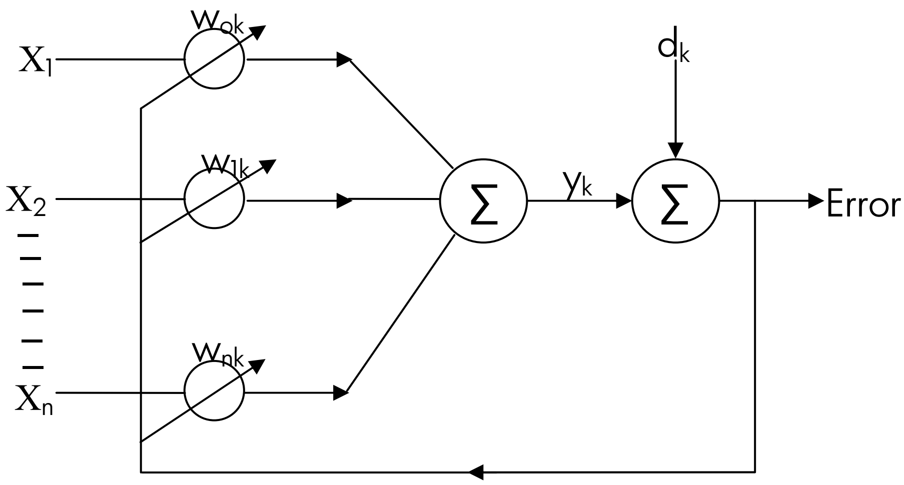

الشكل (2): المخطط العام لخوارزمية تعديل الأوزان

وهنالك خوارزميات مختلفة لتدريب هذه الشبكة منها :

خوارزمية الانتشار الخلفي للخطأ Error Back Propagation Algorithm

تسمى هذه الخوارزمية أيضا بخوارزمية الانتشار الخلفي التزايدي Incremental Back Propagation Algorithm- (Online) ، إذ أن أوزان الشبكة تحدث بعد تقديم كل حالة من مجموعة التدريب بدلا من أن يتم التكرار . وهذا أصلا يجدد التغاير للانتشار الخلفي وفي بعض الأحيان يشار اليه بالانتشار الخلفي القياسي Standard Back Propagation . إن هذه الخوارزمية تكون الأكثر تفضيلا لمجموعة البيانات الكبيرة أنظر (Alyuda , 2003).

إن تدريب الشبكة العصبية الاصطناعية باستخدام الانتشار العكسي تتضمن ثلاث مراحل هي كالآتي (عيسى ، 2000 ; الناصر والعبيدي ، 2003) :

- خطوة الانتشار الأمامي للخطأ Error Forward propagation Step
- خطوة الانتشار الخلفي للخطأ Error Back propagation Step
- خطوة توليف أوزان الشبكة Network Weights Synthetic Step

7-الجانب التطبيقي

7-1- مقدمة

أن المعلومات المتعلقة بتدفق المجرى Stream flow عند أية نقطة تعد مهمة وضرورية في التحليل وتصميم مشاريع مصادر المياه المتعددة مثل أنشاء سد Dam construction وعمل الخزان Reservoir operation والسيطرة على الفيضانات Flood Control وتنظيم تصريف المياه Wastewater disposal)

(Kumar,et al.2004) . من هنا فأن تطور النماذج التصادفية واستخداماتها للظواهر الهيدرولوجية ادت دورا مهما في هندسة مصادر المياه وبضمنها استخدامها في التكهن بتدفقات النهر ، وأن اختيار النموذج الصحيح للسلسلة الهيدرولوجية المعينة يعد مظهرا مهما لعملية النمذجة modeling process (Mujumdar and kumar ,1990).

نظرا لأهمية دراسة الأنهار بنواحيها المتعددة ومنها التكهن بتدفق النهر فأن الهدف الرئيسي للرسالة هو تحليل ومناقشة النمذجة التصادفية للسلسلة الزمنية لنهر دجلة عند دخوله مدينة الموصل باستخدام أساليب النمذجة الاحصائية (نماذج بوكس- جنكنز) ونماذج الشبكات العصبية لذلك تم استخدام بيانات سلسلة زمنية عن كميات المياه الداخلة شهريا الى مدينة الموصل للفترة من 1950-1995 بمجموع مشاهدات يبلغ 552 مشاهدة (انظر الملحق) إذ تم استخدام المشاهدات منذ شهر كانون الثاني 1950 ولغاية كانون الأول 1994 لتقدير النماذج وأبقيت الأشهر ألاثني عشر الأخيرة والتي تمثل عام 1995 لإغراض المقارنة مع التكهنات التي يتم الحصول عليها. إن الافتراض الرئيسي لتحليل السلاسل الزمنية ومطابقة النمذجة modeling fitting هو أن البيانات تكون مستقرة stationary وابسط تعريف للسلسلة المستقرة أنها لاتحتوي على اتجاه عام trend (تغير نظامي في الوسط) وكذلك تغير نظامي في التباين،وقبل تطبيق أي تحليل يجب التحقق من توافر الافتراضات المطلوبة أولا(انظر Nairn-Birch,2008). يوضح الشكل (3-a) الرسم البياني لمشاهدات السلسلة الزمنية المستخدمة حيث يتبين بأن هناك تشتتا واضحا حول التباين بمعنى وجود نمط التباينات الكبيرة والتباينات الصغيرة للسلسلة مما يؤكد وجود تأثيرات عشوائية واضحة ومؤثرة في هذه السلسلة مما يدل على أن التباين ليس ثابتا مع الزمن لذا نستنتج بأن السلسلة لها تباين غير مستقر ووجد أيضا أن معاملات الارتباط الذاتي لاتقترب من الصفر بسرعة كافية وهذا يدل ايضاً على

ان السلسلة غير مستقرة في الوسط ، لذلك تم تحويل السلسلة الى سلـسلة مـستقرة باخذ التحويل اللوغاريتمي للسلسلة لغرض تثبيت التباين وتـم اخـذ الفـرق الاول للتحويل اللوغاريتمي والفرق الموسمي عند(S=12) للفرق الاول لسلـسلة التـدفق الشهري لنهر دجلة لغرض تثبيت متوسط السلسلة خلال الزمن كما في الـشكل (3-b) الاتي:

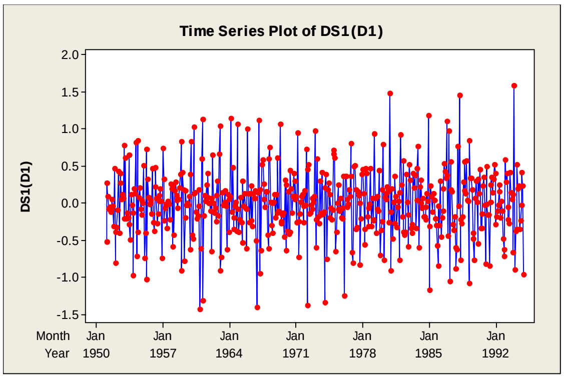

(b)

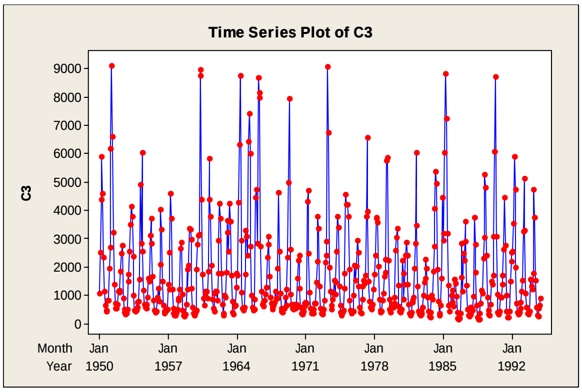

(a)

الشكل (3):(a)الرسم الزمني لبيانات السلسلة الزمنية ، (b) الرسم البياني لسلسلة التدفق الشهري لنهر دجلة بعد إزالة الاتجاه العام والموسم من البيانات المحولة باستخدام التحويلة اللوغاريتمية

نلاحظ من الشكل (3-b) أعلاه أن تباين المشاهدات ثابتٌ نسبياً مع الزمن ، وإن الاتجاه العام واثر الموسم قد تمت إزالتهما لغرض تثبيت متوسط السلسلة خلال

الزمن وبذلك أصبحت السلسلة الزمنية مستقرة، ويمكن أن نلاحظ تحقق الاستقرارية أيضا من خلال الشكل الاتي والذي يقدم معاملات الارتباط الذاتي للسلسلة والتي أصبحت جاهزة للتعرف على النموذج الملائم لها.

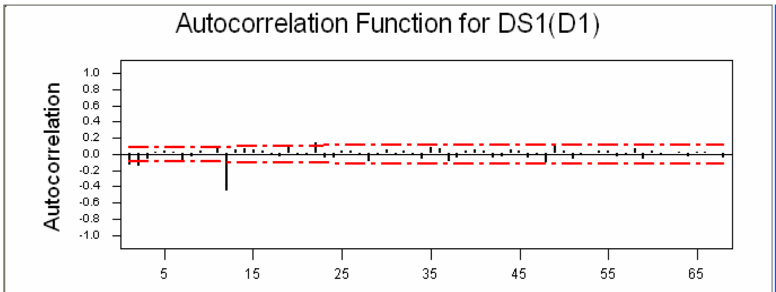

Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	-0.14	-3.22	10.43	16	0.04	0.71	157.13	31	-0.02	-0.29	184.92	46	-0.05	-0.92	209.88	61	-0.03	-0.43	234.25
2	-0.15	-3.41	22.60	17	-0.01	-0.25	157.23	32	0.03	0.61	185.58	47	-0.00	-0.02	209.88	62	0.01	0.18	234.32
3	-0.06	-1.36	24.64	18	-0.04	-0.66	157.96	33	-0.02	-0.37	185.82	48	-0.10	-1.76	215.95	63	0.02	0.35	234.57
4	0.03	0.57	25.01	19	0.08	1.55	161.91	34	-0.06	-1.07	187.89	49	0.11	1.81	222.46	64	-0.04	-0.61	235.36
5	0.03	0.69	25.54	20	-0.01	-0.18	161.97	35	0.08	1.49	191.94	50	0.03	0.51	222.98	65	0.02	0.37	235.65
6	0.02	0.38	25.70	21	-0.02	-0.39	162.22	36	0.07	1.14	194.34	51	-0.07	-1.13	225.55	66	0.02	0.29	235.83
7	-0.08	-1.80	29.30	22	0.14	2.61	173.61	37	-0.09	-1.59	199.02	52	-0.01	-0.17	225.61	67	0.01	0.10	235.85
8	-0.04	-0.86	30.14	23	-0.06	-1.04	175.48	38	-0.05	-0.82	200.29	53	0.00	0.07	225.62	68	-0.05	-0.82	237.28
9	0.03	0.64	30.61	24	-0.05	-0.81	176.62	39	0.04	0.73	201.28	54	0.03	0.54	226.22				
10	0.00	0.09	30.62	25	0.04	0.72	177.52	40	0.05	0.94	202.97	55	0.03	0.53	226.79				
11	0.08	1.68	33.85	26	0.03	0.61	178.17	41	0.03	0.55	203.54	56	-0.04	-0.60	227.52				
12	-0.46	-10.04	150.52	27	-0.02	-0.27	178.30	42	-0.06	-1.00	205.45	57	-0.00	-0.05	227.53				
13	0.05	1.01	152.15	28	-0.09	-1.67	183.20	43	-0.04	-0.61	206.16	58	0.06	1.04	229.75				
14	0.07	1.23	154.57	29	-0.03	-0.50	183.65	44	0.05	0.80	207.40	59	-0.07	-1.21	232.80				
15	0.06	1.04	156.31	30	0.04	0.79	184.77	45	0.04	0.66	208.25	60	0.04	0.71	233.87				

الشكل (4) : دالة الارتباط الذاتي لسلسلة التدفق الشهري لنهر دجلة بعد إجراء التحويل اللوغاريتمي واخذ الفروق

7-2-التعرف على النموذج

للتعرف على النموذج فأنه ومن خلال الشكل (4) والذي يمثل دالة الارتباط الذاتي لعينة المشاهدات وكذلك من خلال الشكل (5) والذي يمثل دالة الارتباط الذاتي الجزئي للسلسلة المستقرة . فأن النموذج الافضل الذي تم اختياره من خلال فحص دالة الارتباط الذاتي والارتباط الذاتي الجزئي هو النموذج المنضرب الموسمي ARMA(1,1)×SARMA(0,1).

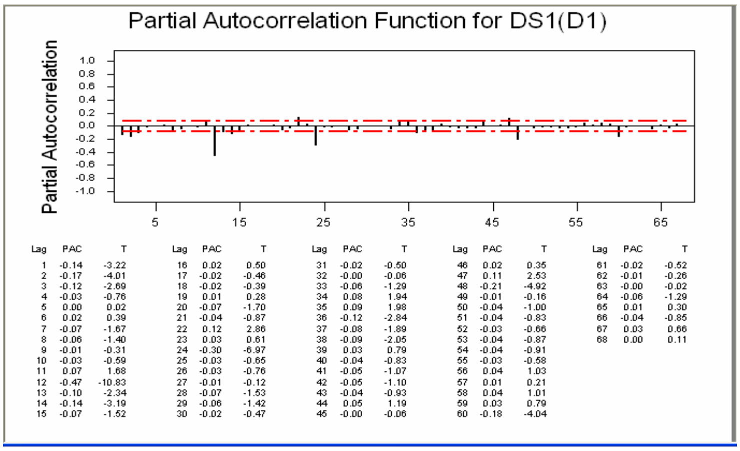

الشكل(5): دالة الارتباط الذاتي الجزئي لسلسلة التدفق الشهري لنهر دجلة بعد إجراء التحويل اللوغاريتمي واخذ الفروق

```
Final Estimates of Parameters

Type        Coef   SE Coef        T       P

AR    1   0.6793    0.0316    21.48   0.000

MA    1   0.9570    0.0012   794.09   0.000

SMA   12  0.9116    0.0234    38.91   0.000

Number of observations:   527

Residuals:     SS =   50.1007 (backforecasts excluded)

               MS =   0.0956   DF = 524
```

$AIC = -18.138$; $AIC_C = -18.063$

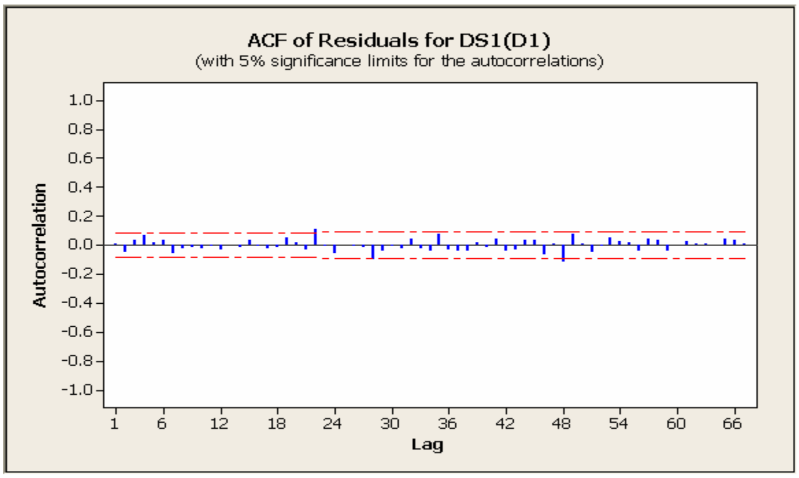

الشكل (6) : دالة الارتباط الذاتي لبواقي نموذج ARMA(1,1)×SARMA(0,1)

مما تقدم نستنتج بأن نموذج ARMA(1.1)×SARMA(0,1) هو النموذج الملائم للبيانات المتاحة لأنه نجح في اختبار معنوية المعلمات المقدرة للنموذج فضلا عن نجاحه في اختبار تحليل البواقي (بمعنى أخر نجح في اختبار الفحوص التشخيصية لهذا النموذج) وأن قيمة متوسط مربع الخطأ لهذا النموذج هي 0.0956 وأن قيمة الجذر ألتربيعي لمتوسط مربع الخطأ Root Mean Square Error تعرف كالأتي (Liu,2006) :

$$\mathbf{RMSE} = \sqrt{\frac{1}{m}\sum_{t=1}^{m}(y_t - \hat{y}_t)^2} = \mathbf{0.309}$$

تم أيجاد التكهن للنموذج الذي ثبتت ملاءمته للبيانات المتاحة بالنسبة لأشهر عام 1995 والشكل الأتي يوضح قيم التكهن مقارنة بالقيم الاصلية:

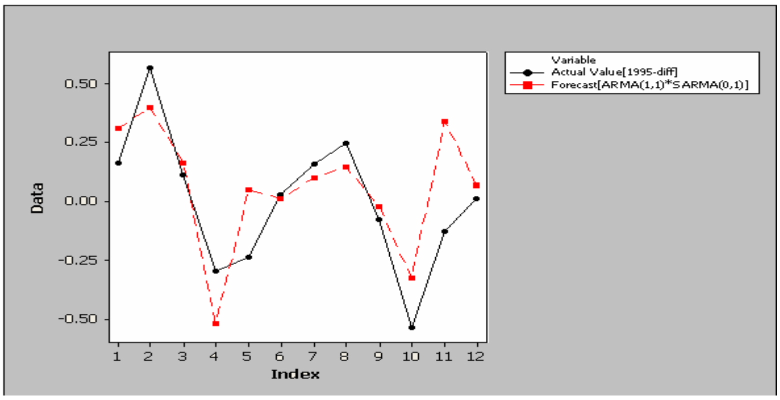

الشكل (7):مقارنة بين قيم التكهن اعتمادا على النموذج المقترح

(نموذج ARMA(1,1)×SARMA(0,1)) مع القيم الحقيقية لاشهر عام 1995

أن الشكل أعلاه يمثل التكهن لخطوة واحدة الى الإمام لـ(12) فترة زمنية مستقبلية. ونلاحظ من خلال الرسم بأن قيم التكهنات تسلك سلوك قيم السلسلة الأصلية نفسه لعام 1995 (بمعنى أخر أن التكهنات تقارب قيم السلسلة الأصلية لاشهر سنة 1995) . لذا يعد النموذج المنضرب الموسمي ARMA(1,1)×SARMA(0,1) نموذج ملائما للبيانات المتاحة على الرغم من أن (Mujumdar and kumar,1990) أوضحا أنه يوجد هدفان في عملية النمذجة الأول هو اختيار نموذج لتمثيل البيانات ، والثاني التكهن لخطوة واحدة الى الامام ، وأن أفضل النماذج لهذين الهدفين غالبا ليست نفسها.

7-3-استخدام الشبكات العصبية الاصطناعية في التكهن بالسلسلة الزمنية لتدفق مياه نهر دجلة

إن خطة التكهن للسلسلة الزمنية لتدفق مياه نهر دجلة الداخلة إلى مدينة الموصل اعتمادا على الشبكات العصبية تتكون من ثلاثة متطلبات هي:

1- تحديد عدد المدخلات الضرورية لمتكهن الشبكة العصبية

يوضح الشكل (8-a) دالة الارتباط الذاتي الجزئي للتحويل ألاوغاريتمي لسلسلة تدفق نهر دجلة (قبل اخذ الفرق) ويتضح من هذا الشكل وجود (13) ارتباطاً

ذاتياً جزئياً معنوياً ، وبعد اخذ الفرق الذي يمثله الشكل (8-b) أصبح عدد معاملات الارتباط الذاتي الجزئي المعنوية (14) ، وبناء على ذلك فان عدد المدخلات الضرورية لمتكهن الشبكة العصبية (13) ادخالا ، انظر (Lin et al. ,1995)

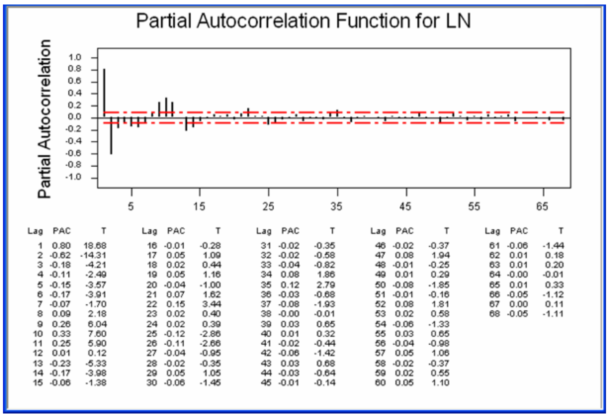

(a)

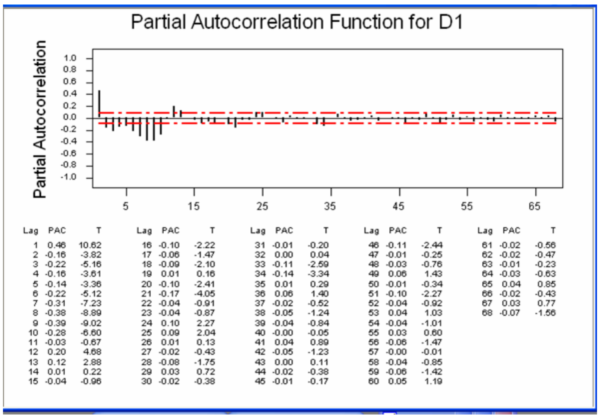

(b)

الشكل(8): (a) دالة الارتباط الذاتي الجزئي للسلسلة الزمنية بعد اجراء التحويل أللوغاريتمي (قبل اخذ الفرق) ، (b) دالة الارتباط الذاتي الجزئي للسلسلة الزمنية بعد اجراء التحويل أللوغاريتمي واخذ الفروقات(بعد اخذ الفرق)

2- تحديد عدد العصبونات في الطبقة المخفية

باستخدام المعادلة الاتية والمعروفة بقاعدة Baum-Haussler في تحديد عدد العصبونات في الطبقة المخفية وعلى وفق القانون الاتي :

$$N_{Hidden} \leq \frac{N_{Train}\, E_{Tolerance}}{N_{Pts} + N_{Output}}$$

لقد تم تثبيت مقدار الخطا المسموح به $E_{Tolerance}$ كي يكون 0.01 وعدد مرات التدريب N_{Train}=10000 وعدد نقاط البيانات لكل مثال تدريب 13

N_{Pts}= وعدد عصبونات الاخراج $N_{\text{Output}}=1$ وبتطبيق المعادلة المذكورة انفا نجد أن:

$$N_{\text{Hidden}} \leq \frac{10000 \times 0.01}{13 + 1}$$

$$N_{\text{Hidden}} \leq 7$$

لذا فان عدد العصبونات في الطبقة المخفية هي اقل او تساوي 7، إذ تمثل 7 الحد الاعلى لعدد العصبونات في الطبقة المخفية وهذا العدد يكافى نصف مجموع عدد وحدات الادخال والاخراج أنظر (Andreescu,2004) . إن البيانات المستخدمة في هذه الدراسة يبلغ عددها (552) مشاهدة وباستخدام النظام الجاهز Alyuda عد (68.3%) من المشاهدات كمجموعة التدريب Training Test و(15.85%) من المشاهدات كمجموعة شرعية Validation Set ، بينما عد (15.85%) من المشاهدات كمجموعة أختبارTest- Set . لقد تم استخدام دالة التنشيط Logistics في الطبقة المخفية وطبقة الاخراج . تم تدريب الشبكات باستخدام خوارزمية الانتشار الخلفي الرزم (الدفع) Batch Back Propagation Algorithm وكان عدد التكرارات (1000) تكرار وعدد مرات اعادة التدريب Number of Retrains=1 وباستخدام عدة عصبونات مخفية لاختيار أفضلها وكان عددها بين 7-2 وذلك من اجل الحصول على افضل معمارية للشبكة العصبية والنتائج موضحة في الجدول (1) ادناه:

الجدول (1) : النتائج الاحصائية لمعمارية عدة شبكات عصبية

معمارية الشبكة Architecture	عدد الاوزان # of Wieghts	المطابقة Fitness	معكوس خطا الاختبار Inverse Test error	خطا التدريب Train error	Akaike's Criterion (AIC)	Corrected Akaike's Criterion (AIC_C)
[13-2-1]	**31**	**0.002195**	**455.516907**	**560.900696**	**0.004425**	**4.253921**
[13-3-1]	46	0.002176	459.574646	567.296997	0.003846	9.364841
[13-4-1]	61	0.002157	463.538086	572.195251	0.003413	16.731464
[13-5-1]	76	0.00214	467.391388	575.733337	0.003075	26.578296
[13-6-1]	91	0.002125	470.547241	578.415344	0.002802	39.160696
[13-7-1]	106	0.001976	506.038605	644.230469	0.002354	54.770126

من الجدول أعلاه نلاحظ بان أفضل معمارية للشبكة العصبية هي [13-2-1] من بين المعماريات الاخرى وذلك حسب المعيار الإحصائي AIC_C ونلاحظ أيضا بان عدد الأوزان للشبكة [13-2-1] يساوي 31 وزنا وذلك يتطابق مع المعادلة الاتية (Chatfield and Faraway,1998):

$$P = (n_i + 2)n_u + 1$$

حيث إن :

n_i: تمثل عدد متغيرات الإدخال (ما عدا الحد الثابت) .

n_u:تمثل عدد العصبونات أو عدد الوحدات في الطبقة المخفية .

P: تمثل عدد المعلمات (الأوزان) وتساوي عدد الترابطات في نموذج الشبكة العصبية .

إن تقديم وحدة إدخال الثابت المرتبطة مع عصبوني الطبقة المخفية ومع عصبون الإخراج يجنبنا ضرورة تقديم منفصل لما يطلق عليه علماء الحاسوب التحيز Bias ولما يسميه الاحصائيون حد المقطع Intercept Term لكل وحدة معالجة (لكل عصبون) . وان التحيزات أساسا تصبح فقط جزءاً من مجموعة الأوزان (معلمات النموذج) كما مبين في أدناه انظر (Chatfield and Faraway,1998) .

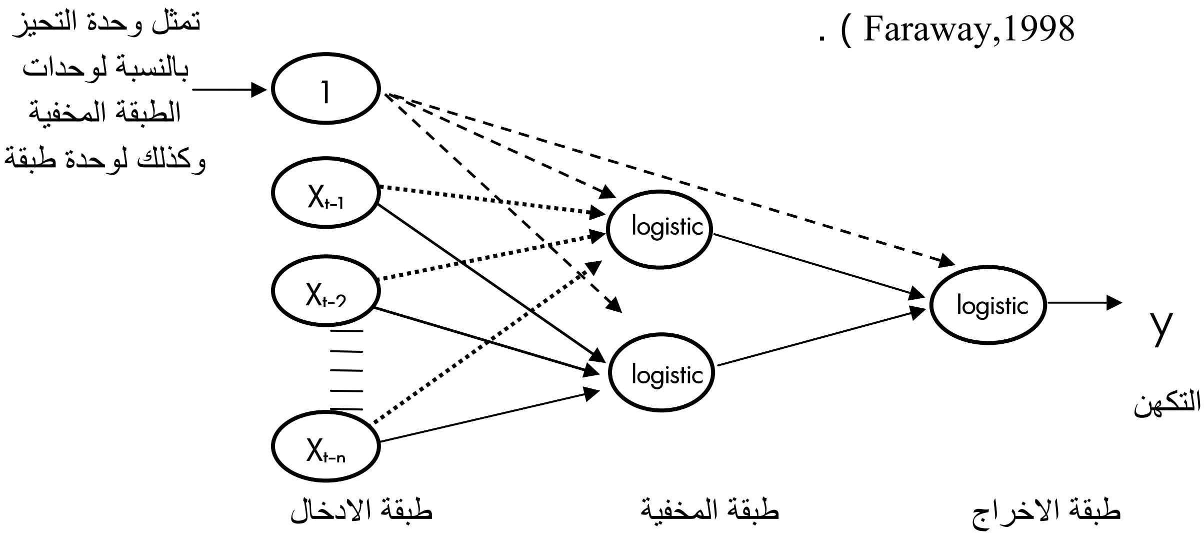

الشكل (9): معمارية الشبكة العصبية النموذجية لتكهن السلسلة الزمنية بطبقة مخفية واحدة

3-بناء متكهن الشبكة العصبية

لأجل الحصول على قيم متكهن الشبكة العصبية (التكهن لخطوة واحدة الى الامام)لاشهر عام 1995 تم تدريب واختبار الشبكة الأفضل وهي [1-2-13] التي عد ت افضل شبكة من بين الشبكات الاخرى باستخدام خوارزمية الانتشار الخلفي التزايدي (Online) Incremental Back Propagation algorithm

حيث تم في هذه الخوارزمية أيضا تثبيت معلمات التدريب التي تمثل نسبة التعلم Learning Rate=0.9 وثابت الزخم Momentum Constant =0.9 وعدد التكرارات Iterations =10000 فضلا عن عدد مرات إعادة التدريب Number of Retrains =2 وبعد تدريب الشبكة بالاعتماد على المعلمات تم الحصول على النتائج الاتية:

Parameters	Training	Validation
Absolute error:	801.427432	904.451365
Network error:	0.01812	0
Error improvement:	3.29E-11	
Iteration:	10001	
Training speed, iter/sec:	268.843584	
Architecture:	[13-2-1]	
Training algorithm:	Online Back Propagation	
Training stop reason:	All iterations done	

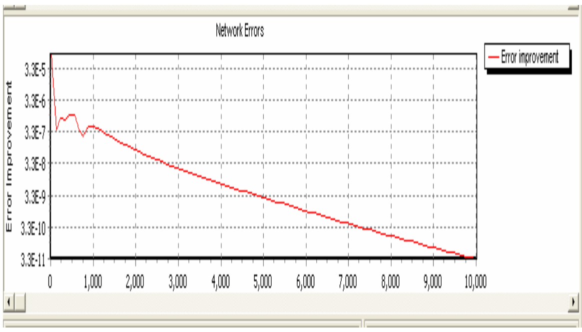

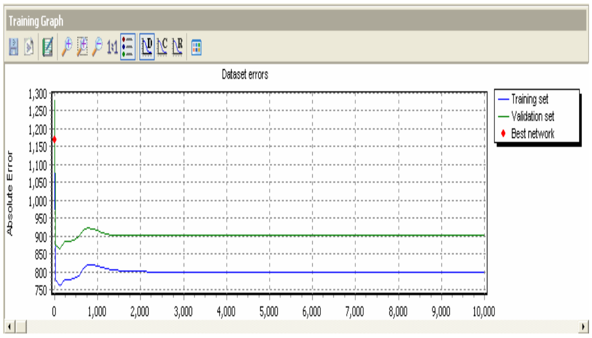

الشكل (10) : رسومات تدريب الشبكة [13,2,1] باستخدام خوارزمية الانتشار الخلفي التزايدي

يتبين من الشكل المذكورة انفا بان مجموعة الشرعية سلكت نفس سلوك مجموعة التدريب وأن الخطأ المطلق لمجموعة التدريب كان الاقل . اما شكل منحني الخطا المطلق للشبكة فانه يأخذ بالتناقص مع زيادة عدد مرات التكرار تحسين الخطأ يسرع ويحسن من قدرة الشبكة العصبية على التكهن وانه مفيد لاكتشاف الحالة عندما تكون الشبكة غير محسنة Not Improved فضلا عن التدريب غير المجدي (Alyuda , 2003) .

ومن خلال تدريب واختبار الشبكة العصبية تم التوصل أيضا إلى قيم التكهن وحساب المعلمات الإحصائية لغرض المقارنة مع الطريقة الاحصائية ، والشكل (11) ادناه يظهر رسم السلسلة الزمنية مع التكهن لاشهر عام 1995المستحصل عليها من خلال خوارزمية الانتشار الخلفي التزايدي:

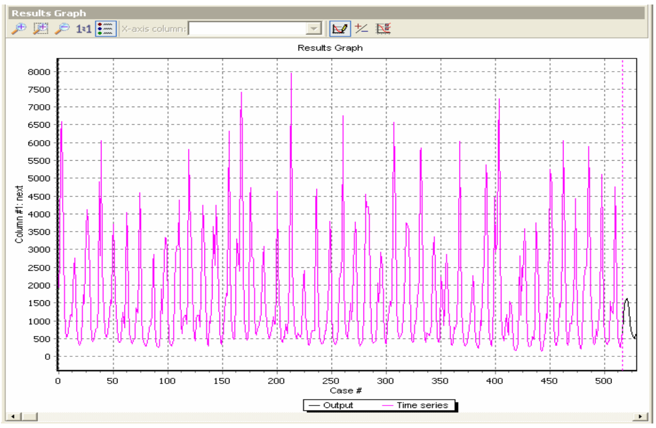

الشكل (11): رسم السلسلة الزمنية بضمنها قيم التكهن للمستقبل لعام 1995 باستخدام الشبكة العصبية [13-2-1]

4- المقارنة بين نتائج الطريقة الإحصائية وطريقة الشبكات العصبية الاصطناعية

لغرض المقارنة بين الاسلوبين المستخدمين ، وهما الأسلوب الكلاسيكي المتمثل بأسلوب بوكس – جنكنز واسلوب الشبكات العصبية الاصطناعية من خلال خوارزمية الانتشار الخلفي التزايدي ، فقد تم الاعتماد على المعايير الإحصائية الاتية في المقارنة وهي RMSE,MSE وكما مبين في الجدول التالي :

الجدول (2) المقارنة إحصائيا بين اسلوب بوكس- جنكنز مع اسلوب الشبكات العصبية الاصطناعية

الشبكة العصبية الاصطناعية [1-2-13]	بوكس – جنكنز	المعايير الإحصائية
Online Back Propagation Alg.	$\mathbf{ARMA(1,1) \times SARMA(0,1)}$	
1.27034	**0.309**	**RMSE**
1.61376	**0.0956**	**MSE**

وكما هو واضح من الجدول اعلاه نجد ان نموذج بوكس- جنكنز متفوق على نموذج الشبكات العصبية الاصطناعية(خوارزمية الانتشار الخلفي التزايدي) ويبين الشكل (12) مقارنة بين قيم تكهنات نموذج الشبكة العصبية الاصطناعية مع تكهنات نموذج بوكس- جنكنز ، ويتضح من الشكل ان منحنى بوكس- جنكنز هو الافضل اداء في قيم التكهن وكالاتي :

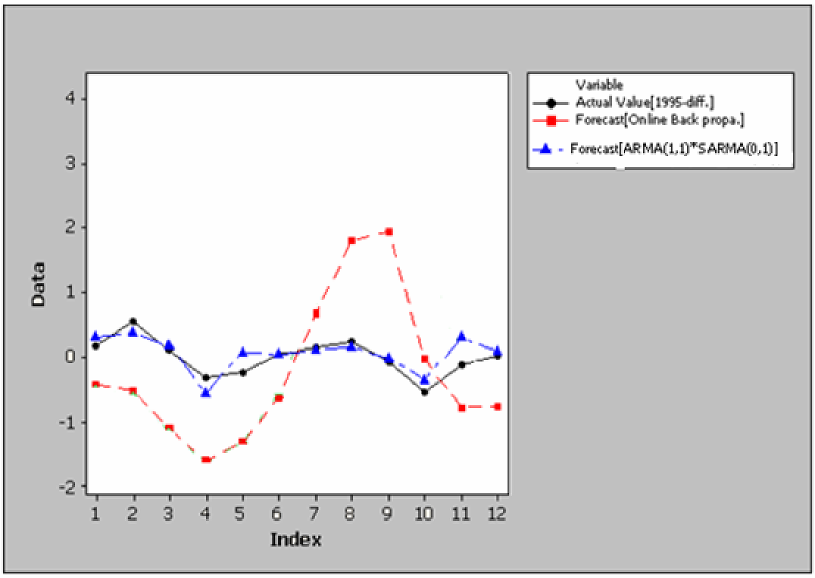

الشكل(12): مقارنة بين قيم تكهنات نموذج الشبكة العصبية الاصطناعية(خوارزمية الانتشار الخلفي التزايدي) مع تكهنات نموذج بوكس- جنكنز

الاستنتاجات:

1- يعد النموذج المنضرب الموسمي ARMA(1,1)×SARMA(0,1) نموذجا جيدا لتمثيل سلسلة بيانات التدفق الشهري لمياه نهر دجلة الداخلة إلى مدينة الموصل لاجتيازه الفحوص التشخيصية ، كذلك قدم هذا النموذج اقل قيم للمعايير الإحصائية المستخدمة لحساب خطا التكهن مقارنة بالشبكة العصبية [13-2-1] إذ كانت :

$$\text{ARMA}(1,1) \times \text{SARMA}(0,1): \quad \text{MSE} = 0.0956, \text{RMSE} = 0.309$$

NN[13-2-1] : MSE=1.61376 , RMSE=1.2703

حيث قدم هذا النموذج تكهنات جيدة ، إذ سلكت التكهنات سلوك قيم السلسلة الأصلية نفسه لأشهر عام 1995 وكذلك فان قيم تكهنات هذا النموذج تقارب قيم السلسلة الأصلية لأشهر عام 1995 وهي بصورة عامة أفضل مما أظهرته تكهنات الشبكة العصبية [13-2-1].

2- تعد الشبكة العصبية الاصطناعية(شبكة الانتشار **الخلفي**) (بالمعمارية [1-2-13] أفضل شبكة عصبية من بين الشبكات العصبية الأخرى لتمثيل السلسلة الزمنية للتدفق الشهري لمياه نهر دجلة الداخلة إلى مدينة الموصل وذلك بالاعتماد على معيار (AIC_c) .

3- إن الوحدات المخفية الإضافية تزيد عدد المعلمات في نموذج الشبكات العصبية وهذا قد يقود الى تحسين في المطابقة لكن ربما يقود الى إفساد التنبؤات خارج العينة.

4- لوحظ إن معيار معلومات اكاكي المصحح (AIC_c) الذي اقترحه Brockwell and Davis (1993) قدم إمكانية أفضل في اختيار النموذج الملائم وكان ذلك واضحا في الاختلاف بين نتائجه للنماذج المختلفة ، في حين لوحظ أن نتائج معيار معلومات اكاكي(AIC) متقاربة من بعضها على الرغم من اختلاف عدد المعلمات مما يجعل عملية اختيار النموذج الملائم تعتمد على خبرة الباحث وقناعاته وهذه المسالة تختلف من باحث إلى آخر .

التوصيات:

1-استخدام نماذج شبكات عصبية أخرى في عملية المقارنة مع نماذج بوكس جنكنز مثل الشبكات العصبية التكرارية التي تتميز باحتفاظها بأحداث الماضي واستخدامها في الحسابات الحالية وهذه الميزة تجعل من هذه الشبكة ملاءمة للظواهر التي تتصف بوجود التغذية العكسية في سلوكها .

2-استخدام معيار معلومات اكاكي المصحح (AIC_c) في عملية المقارنة بين النماذج لاختيار أفضلها بدلا من معيار معلومات اكاكي (AIC)الذي يفتقد خاصية الامثلية.

3-عدم التسرع في أطلاق الأحكام حول أفضلية الأساليب الجديدة للتكهن على أسلوب بوكس جنكنز ما لم تكن هنالك دراسة متأنية .

المصادر

1- الصقال، أديبة إسماعيل وطاهر،غادة محمد .(2006)." استخدام الشبكات العصبية الاصطناعية وشجرة القرار في تشخيص أمراض الفم " ، مجلة الرافدين لعلوم الحاسبات والرياضيات ، المجلد 3 ، العدد2،كلية علوم الحاسبات والرياضيات ، جامعة الموصل.

2- ألعبيدي ، محمود خليل إبراهيم (2000) ."الشبكات العصبية الاصطناعية"، مجلة أبحاث الحاسوب ، المجلد4، العدد1، الجامعة التكنولوجية ، بغداد .

3- الكسو ،ابتهاج عبد الحميد محمد علي .(2005): " استخدام الشبكات العصبية في تقدير رتب سلاسل ماركوف مع التطبيق على سلسلة جبل بطمة في محافظة نينوى "، أطروحة دكتوراه غير منشورة كلية علوم الحاسبات والرياضيات ،جامعة الموصل ،العراق.

4- الناصر،عبد المجيد حمزة والعبيدي ، مروان عبد المجيد . (2003)." استخدام الشبكات العصبية للتنبؤ المستقبلي بقيم السلاسل الزمنية غير المنتظمة في طول الموسمية "، المجلة العراقية للعلوم الإحصائية ،المجلد 3،العدد ،كلية علوم الحاسبات والرياضيات ،جامعة الموصل .

5- عيسى، علام زكي .(2000):" الشبكات العصبية، البنية الهندسية-الخوارزميات – التطبيقات"، الطبعة الأولى، شعاع للنشر والعلوم ، حلب، سوريا.

6- فاندل،والتر.(1992):" السلاسل الزمنية من الوجهة التطبيقية ونماذج بوكس- جنكنز"، تعريب عبد المرضي حامد عزام، دار المريخ للنشر،الرياض،المملكة العربية السعودية.

7-Allende, Hector ; Moraga, Claudio and Salas, Rodrigo (1999), "Artificial Neural Network in time Series Forecasting : A comparative Analysis", German Academic Exchange Service (DAAD) .

8-Anderson, O.D. (1976), "Time Series Analysis and Forecasting the Box-Jenkins approach", F.I.S.,Butter worths (Publishers) Ltd.

9-Andreescu ,Andrea.(2004)," Forecasting Corporate Earnings: A Data Mining Approach" , MSc. Thesis in Accounting The Swedish school of Economics and Business administration.

10-Alyude , NouroIntelligence .(2003) ,"Neural Network Software" .

Web:www.alyuda .com

11-Chatfild, Chris and Faraway, Julian,(1998), "Time Series Forecasting with neural networks : A Comparative Study using the airline data", AppL. Ststist . (1998) 47,Part2, pp.231-250.

12-Christopher, M. Fraser (2000), Neural Networks : Literature Review From a Statiatical Perspective, CSU, Hayward, Statistics Department. http: // WWW.sci. Csuhay ward .edu/ Statistics/ Neural/ cfprojnn.htm

13-Ghodsian, M., Khosronejad, A. and Montazer, G.A.(2003)," Estimation of Scour Hold Properties Around Vertical Pile using ANNs" , International Journal of Sediment Research ,Vol 18, No. 4, PP.290-300.

14-Girard, A. , Rasmussen , C.E. and Murray Smith , R.(2002)," Gaussian Process Priors with Uncertain Inputs: Multiple-Step Ahead Prediction" ,Technical Report ,TR-2002-119, Dept. of Computing Science, University of Glasgow.

15-Kisi, ÖZGÜr (2005) , "Daily River Flow Forecasting using Artificial Neural Networks and Auto-Regressive Models", Turkish J. Eng. Env. Sci ., 9-20, © TÜBİTAK.

16-Kumar, D. Negesh , Raju , K. Srinivasa and Sathish , T. (2004) , "River Flow Forecasting using Recurrent neural Networks", Water Resources Management 18:1431-161.

17-Karaman ,Abdullah S.:(2004).'An Experimental Study On Forecasting Using Tes Processes', Industrial and Systems Engineering Rutgers, University Piscataway, NJ08854, U.S.A.

18-Lendasse ,A.; Bodt, E.DE; Wertz , V. and Vwrleysen, M.(2000), "Non-Linear Financial Time Series Forecasting-Application to The Bel 20 Stock Market Index", European Journal of Ecomoic and Social System 14 N °1(2000) 81-91.

19-Liu , Lon-Mu.(2006)," Time Series Analysis and Forecasting "University of Illionis at Chicago ,Copyright © Scientific Computing Associates ® Corp. ,U.S.A .

20-Lin , Feng , Gregor , Shirley , Irons ,Richard and Yu ,Xing Huo . (1995) , "Time Series Forecasting with Neural Netwark", Complexity International (1995)2.

http: // Journol - Ci. Csse. Monash. Edu./ci/ Vol02/ cmxhk / Cmxhk.html

21-Moseley ,N. (2003) ,"Modeling Economic Time Series Using A focused Time Lagged Feed Forward Neural Network", Proceeding of Student Research Day, CSIS, Pace University.

22-Mujumdar, P. P. and Nagesh Kumar, D.: 1990, 'Stochastic models of streamflow– Some case studies', *Hydrol. Sci. J.* 35, 395–410.

23-Nairn-Birch N.S. (2008),'"A Time Series Analysis of the Pacific Decadal Oscillation ",Msc in statistics, University of California,USA.

24-Powell , James L.(1997) ," Time Series Analysis : Forecasting Product Demand and Rervenue Econometrics Laboratory and Center for Regulatory Policy University of California at Berkeley January 7-9,1998" , Econometrices Laboratory .U.C. Berkeley .

25-Rojas ,I. and Pomares , H. (2004),"Soft-Computing Techniques for Time Series Forecasting ", ESANN 2004 Proceeding European Symposium on Artificial Neural Network-Bruges (Belgium), d-Side Publi., ISBN2-930307-04-8,pp. 93-102 .

26-Xuan , Tang , (2004), "Autoregressive Hidden Markor Model With Application in ELNINO Study ", Department of Mathematics and Statistics, University of Saskatchewan, Saskatoon

الملحق:بيانات السلسلة الزمنية للتدفق الشهري لمياه نهر دجلة الداخلة الى مدينة الموصـل 1950-1995.

DES	NOV	OCT	SEP	AUG	JUL	JUN	MAY	APR	MAR	FEP	JAN	سنة
825	814	474	438	629	1130	2351	4607	5910	4393	2516	1082	1950
1128	695	552	531	720	1369	3214	6589	9098	6187	2685	1945	1951
1736	490	364	311	399	504	899	2759	2483	1853	1108	1187	1952
763	570	479	420	479	994	2356	3777	4121	3509	2564	1484	1953
913	682	549	565	696	1173	2556	6053	2825	4901	1572	798	1954
932	435	402	397	485	825	1664	2839	3707	3107	1483	1588	1955
489	480	434	350	418	643	1490	3321	4044	2095	798	1248	1956
514	415	287	288	346	528	1192	3723	4588	2526	1212	1371	1957
1907	670	313	254	289	471	1016	2866	2644	1219	898	804	1958
1926	459	402	298	348	565	1255	2973	3318	3348	2039	1195	1959
1154	1151	1050	643	884	1754	4380	8973	8761	3134	3097	2786	1960
1154	1151	1050	428	544	846	2053	3777	4380	5812	1841	905	1961
1811	933	1002	303	348	691	1778	3696	4251	2946	1790	820	1962
1288	630	603	342	407	795	1719	3616	4251	2547	3218	3643	1963
3294	1742	568	469	552	1117	2929	8758	6324	4259	1710	1765	1964
4446	858	512	456	568	1007	2722	6000	7413	6428	2390	3080	1965
1026	806	793	596	694	1149	2722	8142	7983	8678	2830	4741	1966
1122	754	637	505	557	707	933	1658	3084	2786	2342	1270	1967
913	541	554	391	426	541	1060	2531	4640	1963	905	905	1968
597	664	498	552	688	1015	2618	7955	4977	2349	1205	651	1969
729	599	423	311	351	589	1239	2413	2219	1591	694	544	1970
503	367	350	351	536	1104	2469	4692	4312	721	734	734	1971
511	367	327	356	554	1304	3375	3784	2204	1468	718	731	1972
1058	870	513	635	1149	1989	6750	9056	2895	2414	2151	820	1973
451	404	298	394	635	1327	3396	3779	2555	1444	1042	1511	1974
443	421	378	466	836	1897	3787	4202	4189	4548	1778	1256	1975
1312	868	345	386	576	1317	2502	2932	2020	1517	2065	1007	1976
689	562	513	573	771	1506	3943	6579	3785	1706	1412	1543	1977
837	426	394	469	865	2035	3557	3722	3750	2393	1738	1205	1978
648	662	391	517	873	2227	5847	5752	2274	1817	1663	1074	1979
2224	512	391	442	600	1348	3367	3056	2590	927	704	579	1980
832	410	306	362	675	1387	2408	2859	2400	1386	860	1765	1981
381	335	293	340	429	1301	3458	6032	2836	1955	940	761	1982
1014	410	223	249	439	910	1963	2271	1604	1466	991	587	1983
1591	627	298	351	771	1903	4944	5378	4055	2714	1832	865	1984
980	686	438	637	1334	3173	7234	8818	6053	3191	2936	4462	1985
1623	375	171	161	196	381	962	1423	1545	602	742	1176	1986
570	319	264	297	520	1350	2917	3590	2231	2487	1154	2831	1987
718	354	166	158	206	638	1812	2786	3747	975	469	533	1988
664	308	311	479	929	2392	4808	5249	3024	2315	1085	1189	1989
933	442	312	380	1037	3087	8732	6060	3069	1689	1374	1487	1990
1498	421	215	225	429	995	2759	4435	2619	1686	1390	916	1991
767	404	332	386	712	1996	4717	5884	3546	2535	2510	2196	1992
435	442	324	356	571	1058	3292	5111	3238	1536	1138	554	1993
661	530	254	287	579	1519	3736	4751	1789	1200	1299	1551	1994
522	381	348	285	348	549	1231	2938	4730	2397	1439	884	1995