

كفاءة طريقي الشبكات العصبية وطريقة بوكس جنكتز في التنبؤ مع حالات تطبيقية في العراق

* م. نوال علاء الدين الجراح

المستدل:

تم مقارنة كفاءة طريقة بوكس جنكتز مع طريقة الشبكات العصبية للتنبؤ بالسلسل الزمنية. تم بناء اربعة نماذج تنبؤ لسلسل زمنية مختلفة في درجة التعقيد باستخدام خوارزمية التعلم الرجعي back propagation neural network وتم مقارنتها مع نماذج بوكس جنكتز القياسية standard box Jenkins وتم التوصل الى ان نتائج بان طريقة الشبكات العصبية اكثراً كفاءة ومتانة وتعطي نتائج ادق للتنبؤ وبالإمكان الاعتماد عليها كطريقة بدائلة في التنبؤ.

Abstract :

This paper attempts to make a comparison between the most famous classic method of forecasting ; Box-Jenkins method , and the famous expert forecasting method; neural network method . The comparison is based on the forecast error that is evaluated for different types of time series data ; i.e. general and seasonal data . This study showed that the Neural method was very suitable for both data types with better results than box-jenkins method .hence different neural network models were fitted and the resulted forecast were compared with the results obtained from the (box-jenkins) seasonal and non-seasonal ARIMA models.the results showed superior performance of neural network technology; which makes it a valuable tool for decision making .

الهدف من البحث

يهدف هذا البحث الى اجراء مقارنة مابين طريقيتي بوكس جنكتز والشبكات العصبية لمعرفة كفاءة الطريقتين في التنبؤ وايهما افضل من الناحية العملية .

1. المقدمة

تستخدم طرق التنبؤ بالسلسل الزمنية بكثرة في مجال الاقتصاد والإدارة . عدة طرق في التنبؤ تم تطويرها في السنوات الماضية . وكانت طريقة بوكس جنكتز واحدة من أشهر الطرق في التنبؤ ودقيقة بالتطبيق [4]. ان بوكس جنكتز احدى الطرق الكلاسيكية المشهورة في مجال التنبؤ ، وعادة تستخدم في مجال المقارنة مع طريقة الشبكات العصبية . بشكل عام فان خوارزميات الشبكات العصبية الذكية NN شهدت شهرة واسعة في مجال التطبيقات التجارية والاقتصادية وخاصة ان الشبكات العصبية استخدمت بنجاح في عدة مجالات مثل: التنبؤ بالسلسل الزمنية ، التعرف على توافقي الزيان ، التصنيف ، وفي مجالات النماذج الاكثر تعقيدا [1] وبصورة عامة فان استخدامات الشبكات العصبية بدأت بالتزايد بسرعة وفي الوقت الحالي استخدمت في مجال الاقتصاد والاعمال والتكنولوجيا . [2] توصلوا بعد المقارنة مابين الشبكات العصبية وطريقة بوكس جنكتز بان الشبكة البسيطة في طريقة الشبكات العصبية تعطي نتائج دقيقة مشابهة الى طريقة بوكس

* مدرس / الجامعة المستنصرية / كلية الإدارة والاقتصاد / قسم الإحصاء

مقبول للنشر بتاريخ 9 / 3 / 2011

جنكز بينما [3] توصي انه في حالة السلسلة الزمنية الطويلة، فإن الطريقتين تعطيان نتائج متقاربة بينما في حالة السلسلة الزمنية القصيرة فان الشبكات العصبية تعطي نتائج احسن . نتيجة لما سبق ، هذه الدراسة تتضمن مقارنة لنتائج طريقي بوكس جنكز والشبكات العصبية لمعرفة كفاءة الطريقتين و ايهما الأفضل من الناحية العملية.

1- الجانب النظري

1-2 طريقة بوكس جنكز The Box – Jenkins Method

طريقة بوكس جنكز واحدة من الطرق المشهورة في التنبؤ بالسلسلة الزمنية في مجال الاقتصاد والاعمال . الطريقة تستخدم عملية نظامية لاختيار نموذج ملائم من عائلة نماذج تسمى (ARIMA) [7]. النموذج العام لنماذج ARIMA يتميز بالشكل التالي :

$$\Phi_p(B)\Theta_p(B^L)(1-B)^D(1-B)^dZ_t = a + \Theta_q(B)\Theta_q(B^L)\varepsilon_t$$

حيث : $\Phi(B)$, $\Theta(B)$ هما عوامل الانحدار الذاتي والمتوسط المتحرك على التوالي

B هو عامل الازاحة الخلفي

ε هو الخطأ العشوائي والذي يتبع التوزيع الطبيعي $N(0, \sigma^2)$

a ثابت

Z_t هي بيانات السلسلة الزمنية ويجوز تحويلها اذا تطلب الامر.

قبل استعراض الجوانب النظرية لهذا النموذج سنتكلم عن بعض المصطلحات التي يعتمد عليها النموذج وهي:
السلسلة الزمنية المستقرة Stationary Time Series

يمكن تحديد مدى وجود خاصية الاستقرارية لسلسلة من البيانات من خلال اختبار معاملات الارتباط الذاتي (Auto Correlation Coficients) في حالة البيانات المستقرة تهبط الارتباطات الذاتية الى الصفر بعد فترة الازاحة الثانية او الثالثة .

NOn Stationary Time Series

في حالة البيانات غير المستقرة تكون هذه الارتباطات مختلفة معنوية عن الصفر لعدة فترات زمنية . ولتحويل هذه السلسلة الى سلسلة مستقرة تستخدم عملية الفروق ويعرف الفرق من الدرجة (d) بالشكل الآتي:

$$\nabla^d Z_t = (1 - B)^d Z_t$$

(ACF) Auto Correlation Coficients

يمكن ان نعرف بان $\rho(K)$ هي الارتباط الذاتي بين مشاهدات السلسلة (Z_1, Z_2, \dots, Z_n) التي تبعد عن بعضها البعض مسافة مقدارها k وحدات زمنية اي ان :

$$\hat{\rho}(k) = \frac{\sum_{\tau=1}^{n-k} (Z_\tau - \bar{Z})(Z_{\tau+k} - \bar{Z})}{\sum_{\tau=1}^n (Z_\tau - \bar{Z})^2}, \quad k = 0, 1, 2$$

$$\bar{Z} = \sum_{\tau=1}^n Z_\tau / n$$

(PACF) Partial auto correlation function

فستعمل لقياس درجة الاقتران بين Z_t و Z_{t-k} عندما يتم تثبيت فترات الازاحة الاخرى على المتغير Z وتعرف كما يلى:

$$\widehat{\Phi}_{kk} = \begin{cases} \hat{\rho}_1 & \text{if } k = 1 \\ \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \widehat{\Phi}_{k-1,j}}{1 - \sum_{j=1}^{k-1} \widehat{\Phi}_{k-1,j}} & \text{if } k = 2, 3, \dots \end{cases}$$

and

$$\widehat{\Phi}_{Kj} = \widehat{\Phi}_{K-1,j} - \widehat{\Phi}_{KK} \widehat{\Phi}_{K-1,K-j} \quad \text{for } j = 1, 2, \dots, k-1$$

نماذج الانحدار الذاتي auto regressive models
 ان صيغة نموذج الانحدار الذاتي من الدرجة (P) والذي يرمز له AR(P) هو كما يلي :

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

حيث : Z_{t-i} : تمثل المشاهدات $i = 0, 1, 2, p$
 a_t : تمثل مجموعة الاوزان للفيت السابقة الى $i = 1, 2, \dots, p$ Φ_i

نماذج الاوساط المتحركة moving average models
 ان صيغة نموذج الاوساط المتحركة من الدرجة (q) ويرمز له MA(q) هي كالتالي :
 $Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q}$
 حيث : Z_t : قيمة المشاهدة في الفترة (t)
 θ_i : معلم ثابتة للنموذج .
 a_t : يمثل الاخطاء العشوائية

النماذج المختلطة mixed auto regressive moving average models :
 ويرمز لها ARMA(p,q) حيث (p) يمثل درجة الانحدار الذاتي ويمثل (q) درجة الاوساط كما يلي :
 $Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \cdots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q}$

الموسمية (S) seasonality :
 هي نوع من انواع السلسل الزمنية التي تتضمن تغيرات موسمية في تكوينها فإذا كانت فصلية فان (S=4) اما اذا كانت شهرية فان (S=12) ان النموذج الموسمي المضاعف عبارة عن نموذج مخلط يتكون من جزئين هما :
 الجزء الموسمي والجزء غير الموسمي ويرمز للنموذج المخلط المضاعف بالصيغة التالية :
 $ARIMA(p,d,q)(P,D,Q)^S$

يتم التنبؤ بطريقة بوكس جنكنز خلال العمليات التالية :
 1- تعريف النموذج Identification : تعتمد على البيانات التاريخية لذلك ويجب التأكد من كونها مستقرة فإذا لم تكن هكذا فإنه يشترط تحقيق الاستقرارية فيها باخذ الفروق لها و لمعرفة النموذج الملائم لها من بين نماذج بوكس جنكنز. يتم تحديد النموذج عن طريق دراسة خصائص دالة الارتباط الذاتي (k) p و دالة الارتباط الذاتي الجزئي Φ_k والجدول التالي يوضح سلوك كل من الدالتين وعملية تحديد النموذج المناسب .

نماذج MODEL	دالة الارتباط الذاتي ACF	دالة الارتباط الذاتي الجزئي PACF
AR(P)	اسي	يقطع بعد p من الازاحات
MA(q)	يقطع بعد q من الازاحات	اسي
Arma(p,q)	اسي	اسي

جدول (1)

2- التقدير Estimation : يتم تقدير معاملات النموذج الأولى بعدة طرق ومنها طريقة الامكان الاعظم التامة (Exact Maximum Likelihood) وطريقة الامكان الاعظم التقريبية (Approximate Maximum Likelihood) وهناك طرق لا تعتمد على التوزيع الاحتمالي للسلسلة الزمنية وهي طريقة المربعات الصغرى (Least Squares) وتستخدم اعتماداً للبرامجيات الجاهزة الكفوءة .
 3- الاختبار التشخيصي Diagnostic checking : تستخدم اختبارات تشخيصية مختلفة لتتحقق ملائمة النموذج ومعرفة هل هناك حاجة لنماذج بديلة ام لا . وغالباً يتم الاعتماد على سلسلة الباقي (residuals) في هذه المرحلة لمعرفة عشوائية الباقي ويعتمد غالباً على اختبار احصاء Q وهو عبارة عن مجموع مربعات معاملات الارتباط الذاتي للباقي فيما اذا تتواء توزيع χ^2 وبدرجة حرية (N-p-q) فإذا كانت القيمة المحتسبة اقل من القيمة الجدولية فهذا مؤشر يعني ان معاملات الارتباط الذاتي غير معنوية اي ان الاخطاء لها سلوك عشوائي وغير مننظم وعليه يعتبر النموذج المشخص ملائم والصيغة العامة المستخدمة هي كالتالي :

$$Q = (N - d) \sum_{k=1}^k \hat{\rho}_k^2(e)$$

4- التنبؤ Forecasting: يستخدم النموذج الأفضل والذي تم اختباره للتنبؤ.

بعد أن يجتاز النموذج الشخص الاختبار السابق يصبح بالإمكان استخدام النموذج للتنبؤ ويتم تقييم التنبؤ بالاعتماد على أخطاء التنبؤ واهم المؤشرات التي توضح مدى ملائمة النموذج هي متوسط الخطأ (mean square error) والتي اعتمدنا عليه خلال هذا البحث و متوسط الخطأ المطلق (mean absolute error) وتحسب كما يلي :

$$ME = \frac{1}{n} \sum_{i=1}^n e_i$$

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i|$$

2-2 الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)

مبادئ أساسية

الشبكات العصبية تتكون من وحدات المعالجة أي الخلايا العصبية او العصبون والروابط والطبثات مرتبة على شكل طبقة ادخال وطبقات مخفية وطبقة اخراج.

كل عصبون يستلم مجموعة من المدخلات وينتج مجموعة من المخرجات والتي تكون مدخلات الى عصبونا خر للطبقة القادمة، الروابط مابين العصبونات المختلفة مرتبطة باوزان هذه الاوزان تعكس قوة العلاقات مابين العصبونات المتراقبة. العصبون او عنصر المعالجة هو العنصر الاساسي للشبكة العصبية الاصطناعية . الشكل 1 يعرض العصبون الذي j والذى له n من المدخلات $X_1, X_2, X_i, \dots, X_n$ وكل مدخل يكون موزون قبل ان يصل الى العصبون j من خلال اوزان الروابط $w_{1j}, w_{2j}, w_{ij}, \dots, w_{nj}$ بالإضافة الى ذلك فان للعصبون دالة تنشيط او تفعيل والتي تحدد مخرجات العصبون jyj وهنالك انواع مختلفة من دوال التنشيط ولكن الدالة الاسية sigmoid والتي تأخذ القيم مابين 0 الى 1 تستخدم بكثرة والت لها الشكل التالي

$$y_j = \frac{1}{(1+e^{-net_j})}$$

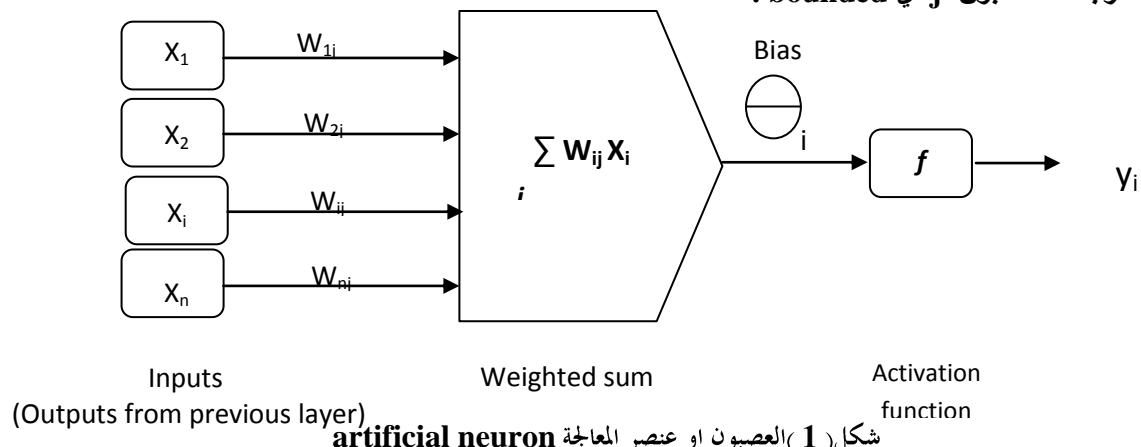
حيث :

y_j : هو مخرجات العصبون j أي (neuron j)

$$net_j = \sum_i w_{ij} X_i$$

:net

والذى يمثل المجموع الموزون للمدخلات الى العصبون j والهدف من دالة التنشيط للتتأكد من محدودية المخرجات للعصبون j أي bounded .

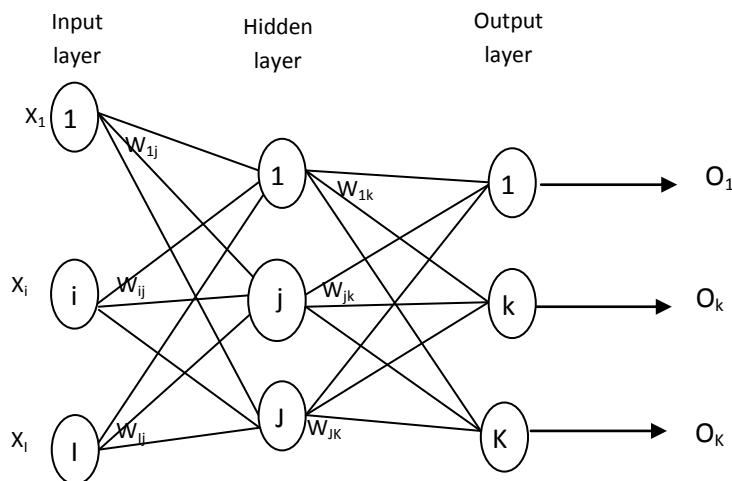


شكل 1 (العصبون او عنصر المعالجة)

كل شبكة عصبية لها معمارية خاصة بها وبعد العصبونات وطريقة ترابطها الخاصة بها وهناك انواع مختلفة من معماريات الشبكات وكل نوع يستخدم لغرض معين ولكن خوارزمية التغذية الامامية للشبكة العصبية مشهورة وتستخدم بصورة واسعة في مجال الادارة.

الشبكات العصبية باللغذية الامامية feed forward neural network

الشبكات العصبية باللغذية الامامية تنقسم مابين طبقة مدخلات، طبقة مخفية، وطبقة مخرجات وكل طبقة تحتوي على عدد مختلف من العصبونات وكل عصبون في طبقة المدخلات يرتبط بكل العصبونات المتواجدة في الطبقة المخفية وكل عصبون في الطبقة المخفية يرتبط بكل العصبونات المتواجدة في طبقة المخرجات كما هو موضح في الشكل 2



شكل (2) : الهيكل النموذجي للشبكة العصبية للتغذية الامامية

هذا النوع من الشبكات العصبية له مسار الى الامام في تغذية المعلومات وليس له مسار تغذية رجعية وعدد العصبونات في طبقة المدخلات وطبقة المخرجات محدد بعدد المدخلات والمخرجات لل المشكلة كل عصبون يستلم المدخلات من باقي العصبونات من خلال الروابط الموزونة وبعد معالجتها تكون مدخلات الى العصبونات التالية ومستوى التنشيط للعصبون في طبقة المدخلات يحدد حسب الاستجابة للمدخلات المستلمة ومستوى التنشيط هو دالة لمستويات التنشيط للعصبونات المرتبطة به وكذلك هي دالة للأوزان المرافقة لهذه الروابط.

التعلم في الشبكة العصبية learning in neural network

التعلم هي عملية اكتساب المعرفة من مجموعة من البيانات وخلال التعلم تقوم الشبكة بتعديل وتصحيح اوزان الروابط المبنية على المدخلات المستلمة وعليه فان المخرجات تبدا بالاقراب من النتائج الحقيقة او مخرجات الهدف. هناك عدة طرق في التعلم ولكن بصورة عامة يمكن تصنيفها الى صفين :

- 1- الصنف الخاضع للإشراف supervised
- 2- الصنف الغير خاضع للإشراف unsupervised

بالنسبة للصنف الاول فهناك مخرجات محددة مسبقا وخلال فترة التدريب تقوم الشبكة بتعديل اوزانها بهدف تخفيض الفروق ما بين البيانات الحقيقة ومخرجات الشبكة الى اقل ما يمكن. اما الصنف الثاني من التعلم فيليس هناك مخرجات محددة مسبقا والشبكة تتعلم من قيم المدخلات فقط وتتعرف على المخرجات لاحقا.

التعلم الرجعي backpropagation learning

خوارزمية التعلم الرجعي هي طريقة التعلم بالاشراف والتي تستخدم لتدريب الشبكات العصبية باللغذية الامامية وفي هذه الطريقة للتعلم تعالج المدخلات خلال الشبكة العصبية وتقارن المخرجات مع المخرجات الحقيقة وتستخدم الاخطاء اي الفوارق لتحديث اوزان الروابط للوصول الى ادنى مجموع مربعات الخطأ.

الشكل (2) استخدم لتوضيح طريقة التعلم الرجعي فإذا كانت قيم $x_p, p = 1, \dots, N$

تتمثل متوجه المدخلات وكانت قيم المخرجات المطلوبة لهذه المدخلات معلومة وكانت N تمثل حجم العينة المدربة فان الهدف لعملية التعلم سيكون حساب مجموعة الاوزان W_i وكذلك W_{ij} لروابط الشبكة العصبية التي تعمل على تدنية مجموع مربعات الاخطاء مابين المخرجات الحقيقة ومخرجات الشبكة O الى اقل ممكناً ويمكن كتابة هدف التعلم كما يلي :

$$\min E = \sum_K (T_K - O_K)^2$$

ان التغيير المستمر للاوزان يساعد على الوصول الى اصغر قيمة لدالة الخطأ وان عملية التعلم الرجعية تشمل عدة خطوات وكما يلي :

1. تغير الاوزان بصورة عشوائية
2. متوجه القيم المخصص للتدريب X_p يكون متوجه ادخال الى طبقة الادخال وباستخدام دالة للتنشيط على سبيل المثال الدالة الاسية (sigmoid function) ستكون مخرجات كل عصبون محسوبة كما يلي :

$$Z_j = f(\text{net}_j)$$

$$\text{net}_j = \sum_i W_{ij} X_i \quad i = 1, 2, \dots, I; \quad j = 1, 2, \dots, J$$

3- ان مخرجات العصبونات في الطبقة المخفية تستخدم لاحتساب المخرجات للعصبونات في طبقة المخرجات والتي تعتبر مخرجات الشبكة العصبية

$$O_k = f(\text{net}_k)$$

$$\text{net}_k = \sum_j W_{jk} Z_j, \quad K = 1, 2, \dots, K$$

4- اوزان الروابط للشبكة العصبية يتم تحديثها من اجل تخفيض قيم الاخطاء المحسوبة لكل عصبون لطبقة المخرجات. الاوزان المرتبطة بالعصبونات في الطبقة المخفية وطبقة المخرجات يتم تحديثها اولاً باستخدام المعادلة التالية :

$$W_{JK}(t+1) = W_{jk}(t) + \Delta W_{jk}(t)$$

حيث:

$$\Delta W_{jk}(t) = \eta \theta_k Z_j + \alpha W_{jk}(t-1)$$

$$\theta_k = (T_K - O_K) \frac{\partial O_K}{\partial \text{net}_k}$$

الحد $W_{jk}(t+1)$ هو مجموع الاوزان في الدورة $(t+1)$

الحد $W_{jk}(t)$ هو مجموع الاوزان في الدورة (t)

$$\frac{\partial O_K}{\partial \text{net}_k}$$

الحد θ_k هو مشتقة دالة التنشيط المستخدمة في طبقة المخرجات فإذا استخدمت الدالة الاسية sigmoid فإن المشتقة ستكون $O_k(1 - k)$

الحدود η ، α هي ثوابت مابين 0،1 وتستخدم للسيطرة وتحسين كفاءة عملية التدريب حيث η هو معدل

التعلم وان α هو لحظة التعلم learning rate ،

5- بعدها يتم تحديث الاوزان التي تربط العصبونات في الطبقة المخفية مع طبقة المخرجات يتم تحديث الاوزان التي تربط المدخلات مع الطبقة المخفية وكما يلي:

$$W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij}(t)$$

Where

$$\Delta W_{ij}(t) = \eta \theta_j X_i + \alpha W_{ij}(t-1)$$

$$\theta_j = \frac{\partial Z_j}{\partial \text{net}_j} \sum_k \theta_k W_{jk}$$

حيث

$$\frac{\partial Z_j}{\partial \text{net}_j}$$

الحد $\frac{\partial Z_j}{\partial \text{net}_j}$ عبارة عن مشتقة دالة التنشيط للعصبونات في الطبقة المخفية وبالنسبة الى الدالة الاسية $Z_j(1 - Z_j)$ ستكون sigmoid.

من خلال مرحلة المرور الى الامام ،المدخلات الى الشبكة تستلم من خلال طبقة المدخلات وبالاعتماد على هذه المدخلات سيتم تحديد المخرجات للطبقة المخفية . والمخرجات في الطبقة المخفية ستستخدم كمدخلات الى العصيوبنات لطبقة المخرجات وباستخدام دالة التشغيل سيتم تحديد المخرجات الى طبقة المخرجات . من خلال المرور العكسي سيتم احتساب الانحرافات مابين قيم المخرجات المفترضة ومخرجات الشبكة والتي تعمل على تحديث الاوزان الرابطة في الطبقة المخفية وطبقة المخرجات او لا ثم تعمل على تحديث الاوزان لطبقة المدخلات والطبقة المخفية ثانيا . عملية المرور الى الامام والمرور العكسي تكرر عدة مرات الى ان نحصل على الاوزان التي تؤدي الى تخفيض الانحرافات مابين مخرجات الشبكة والمخرجات المفترضة الى اقل ما يمكن .

خصائص معاملات التعلم

حجم الشبكة يؤثر على عملية التعلم الشبكة الكبيرة تحتاج الى وقت اكبر للتعلم والوصول الى اقل خطأ ويتأثر بمعدل التعلم α ومعامل الزخم β فكلما كانت عملية التعلم بطيئة نعطي قيمة اكبر الى α ونعطي قيمة اصغر الى β عندما تكون عملية التخفيض في الخطأ سريعة فختار قيمة اصغر الى β لضمان الوصول الى اصغر قيمة للخطأ ولكنها ستحتاج الى وقت طويل لتدريب الشبكة اما بالنسبة الى α فالقيمة الكبيرة لها ستؤدي الى زيادة سرعة التعلم ونوصي بها عندما تكون عملية الوصول الى اقل خطأ بطيئة .

الشبكة العصبية والتنبؤ

الشبكات العصبية الذكية يمكن استخدامها لنمذجة أي علاقة مالية مابين مجتمع متغيرات المدخلات والمخرجات وبضمونها النماذج المالية الخاصة بنماذج السلسل الزمنية . السلسلة الزمنية تتكون من عدد من المشاهدات y_1, y_2, \dots, y_T حيث T تشير الى الزمن .

في تحليل السلسل الزمنية هناك معالجة للبيانات المولدة والتي على اساسها يتم التنبؤ بالاعتماد على العمليات السابقة والشبكات العصبية بامكانها السيطرة على هذه العمليات حتى بالنسبة للبيانات الغير منتظمة ونمذج التغذية الامامية المتعددة المستويات تستخدم بصورة شائعة في مجال التنبؤ وستكون المدخلات الى الشبكة بيانات مختلفة سابقة وستكون المخرجات هي القيم المستقبلية المتباينا بها ويمكن تمثيل هذه العلاقة كما يلي :

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-m})$$

حيث y_t هو المشاهدة في الزمن t وان m هي عدد المشاهدات السابقة والمستخدمة للتتبؤ لقيم المستقبلية للسلسلة الزمنية y_t التي لها T من المشاهدات ويمكن استخدام شبكة عصبية ذكية لها M من المدخلات ولها مخرج واحد هو قيمة التنبؤ المستقبلية بعد تدريب الشبكة $.T_m$.

نموذج التدريب الاول يكون لـ y_m, \dots, y_1 كمدخلات ويكون y_{m+1} هو الغاية او الهدف . ونموذج التدريب الثاني يتالف من y_{m+1}, \dots, y_2 كمدخلات ويكون y_{m+2} هو الغاية ويكون نموذج التدريب النهائي هو $y_{T-1}, \dots, y_{T-m+1}$ هي المدخلات ويكون y_T هو الغاية . الهدف لعملية التدريب هو ايجاد الاوزان التي تعمل على تخفيض مجموع مربعات الخطأ مابين المخرجات المقدرة والحقيقة الى اقل ما يمكن .

2- البيانات Data

تم اختيار اربعة سلسل زمنية وهي بيانات الحمل الكهربائي للشبكة الوطنية العراقية $peak load$ للفترة 2003-2010 شهريا جدول (1) وبيانات كمية الماء المستهلكة $water consumption$ في محافظة بغداد شهريا وللفترة 2005-2009 جدول (2) وبيانات كميات النفط العراقي المستخرج oil جدول (3) وبيانات كميات الغاز المنافق gas للفترة 2006-2008 شهريا جدول (4).

Listing of variable: GAS (load (B2:AK)		Listing of variable: OIL (load (B2:CS)		Listing of variable: WATER (Untitled (B2:B)		Listing of variable: LOAD (iraq load (B2:CS)	
Case	Value	Case	Value	Case	Value	Case	Value
1	13784.0	1	48.3000	1	49735.0	1	2900.00
2	13604.0	2	48.4000	2	51182.0	2	2600.00
3	14676.0	3	60.2000	3	50125.0	3	2100.00
4	15129.0	4	60.9000	4	61706.0	4	2140.00
5	14950.0	5	63.2000	5	62865.0	5	2400.00
6	14513.0	6	67.9000	6	59980.0	6	2980.00
7	15723.0	7	63.9000	7	70408.0	7	3000.00
8	15922.0	8	62.5000	8	71903.0	8	3000.00
9	16303.0	9	63.8000	9	67222.0	9	2760.00
10	16203.0	10	62.6000	10	67935.0	10	2057.00
11	12396.0	11	56.6000	11	64661.0	11	1990.00
12	12306.0	12	56.2000	12	51260.0	12	2980.00
13	10101.0	13	47.7000	13	58158.0	13	4000.00
14	13535.0	14	53.7000	14	53762.0	14	3890.00
15	12944.0	15	60.5000	15	60050.0	15	3200.00
16	14413.0	16	59.1000	16	59214.0	16	2960.00
17	13095.0	17	61.3000	17	60767.0	17	3600.00
18	13684.0	18	59.7000	18	67955.0	18	3700.00
19	14104.0	19	62.8000	19	73028.0	19	3900.00
20	12329.0	20	63.2000	20	62139.0	20	3200.00
21	14144.0	21	67.7000	21	69206.0	21	4200.00
22	16278.0	22	70.9000	22	62551.0	22	4100.00
23	15807.0	23	74.4000	23	54842.0	23	4450.00
24	17101.0	24	68.4000	24	54445.0	24	4350.00
25	13964.0	25	74.4000	25	54199.0	25	3300.00
26	15971.0	26	70.7000	26	51032.0	26	3600.00
27	17451.0	27	73.3000	27	57166.0	27	4210.00
28	14480.0	28	68.8000	28	62252.0	28	3250.00
29	20704.0	29	73.1000	29	67435.0	29	3980.00
30	14249.0	30	71.5000	30	65430.0	30	4140.00
31	16676.0	31	65.4000	31	73457.0	31	4230.00
32	14716.0	32	68.7000	32	73452.0	32	4000.00
33	15985.0	33	72.3000	33	66875.0	33	3400.00
34	15333.0	34	69.2000	34	66479.0	34	4030.00
35	17303.0	35	72.3000	35	64830.0	35	4030.00
36	14863.0	36	69.2000	36	62505.0	36	4050.00

جدول (4) كميات الغاز المتدايق

جدول (3) كميات النفط المستهلك

جدول (2) كميات الماء المستهلك

جدول (1) الحمل الكهربائي

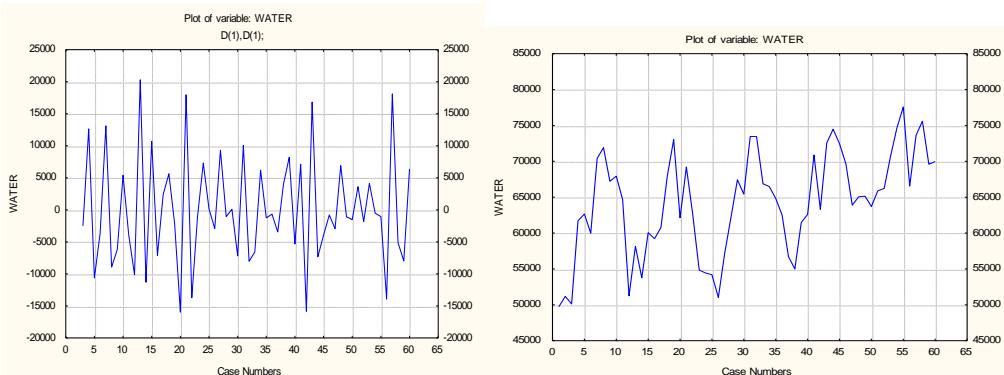
3- التطبيق العملي

بالاعتماد على النظام الجاهز STATISTICA تم التوصل إلى النتائج التالية:

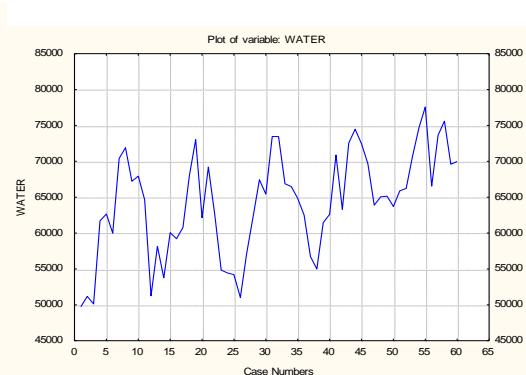
1.3 طريقة بوكس جنكنز :

1-1-3 بيانات الماء: WATER

تم تطبيق نموذج بوكس جنكنز على بيانات الماء الجدول (1) بعد رسم السلسلة الزمنية تبين انها تتصف بالموسمية وبع اخذ الفرق الاول والموسمي لها اصبحت مستقرة كما في الشكل 3 والشكل 4 وتم اختيار النموذج (ARIMA)(2,1,1)(2,1,1) من بين نماذج عديدة بالاعتماد على اصغر متوسط لمربعات الخطأ MSE كما هو موضح في الجدولين 5,6 وتم احتساب معاملات الارتباط الذاتي والجزئي للخطأ كما هو واضح في الاشكال 5,6 والتي تدل على عشوائية الاحطاء. ثم استخدم النموذج للتنبؤ كما هو واضح في الشكل 7 (وكان متوسط مربعات الخطأ يساوي 2742E4).



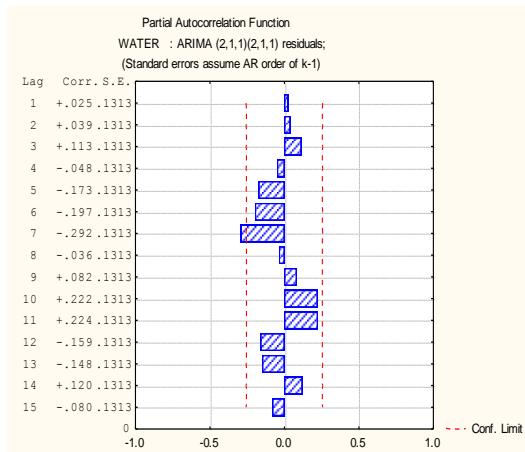
شكل (3) : بيانات الماء المستهلك شهريا



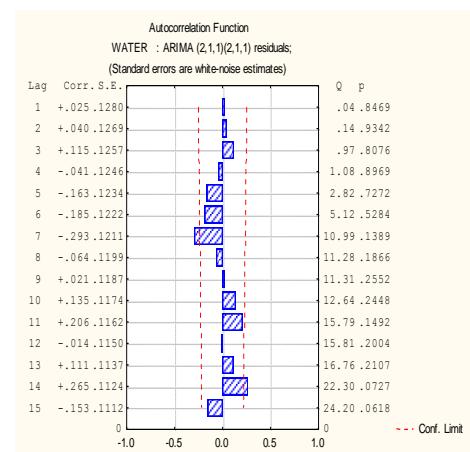
شكل (4) البيانات بعد اخذ الفروق

CaseNo.	Forecasts Model:(2,1,1)(2,1,1) Seasonal lag: 12 (U) Input: WATER Start of origin: 1 End of origin: 36				
	Forecast	Lower 90.0000%	Upper 90.0000%	Std.Err.	Observed
37	63737.6	53444.5	74030.1	6146.3	56733.0
38	61966.6	49794.7	74138.1	7268.1	54998.0
39	65889.1	52665.9	79112.1	7895.9	61465.0
40	68733.4	53830.5	83636.4	8898.9	62606.0
41	71185.1	54834.7	87535.1	9763.2	70871.0
42	72189.1	54620.3	89758.0	10490.7	63305.0
43	77453.4	58646.3	96260.0	11230.2	72555.0
44	75140.7	55136.7	95144.1	11944.9	74473.0
45	74298.7	53162.8	95434.1	12620.8	72455.0
46	72807.4	50567.7	95047.1	13279.9	69645.0
47	70219.9	46902.0	93537.1	13923.7	63890.0
48	68154.6	43786.8	92522.4	14550.6	65056.0
49	69413.6	42788.1	96039.1	15898.7	65139.0
50	67776.4	39510.2	96042.1	16878.4	63703.0
51	71355.5	41659.4	101051.1	17732.3	65881.0
52	74115.5	42852.5	105378.1	18667.9	66225.0
53	76558.1	43795.2	109321.1	19563.5	70698.0
54	77165.4	42976.0	111355.1	20415.4	74663.0
55	82030.7	46423.3	117638.1	21262.0	77570.0
56	80320.5	43319.0	117322.1	22904.5	66550.0
57	79077.9	40711.8	117444.1	22909.3	73635.0
58	77953.1	38241.1	117665.1	23713.0	75600.0
59	75868.6	34827.7	116909.1	24506.5	69590.0
60	74114.9	31762.2	116467.1	25289.8	69975.0
61	75249.6	30544.6	119954.1	26694.5	
62	73877.5	27311.6	120443.1	27805.7	
63	77048.3	28794.2	125302.1	28813.7	
64	79487.6	29413.7	129561.1	29900.4	
65	81645.9	29803.1	133488.1	30956.6	
66	82260.7	28708.6	135812.1	31977.3	
67	86545.6	31286.4	141804.1	32996.6	
68	85064.2	28115.2	142013.1	34005.7	
69	84085.1	25469.7	142700.1	35000.7	
70	83131.6	22863.9	143399.1	35987.4	
71	81337.5	19430.6	143244.1	36966.2	
72	79847.4	16315.0	143379.1	37936.8	

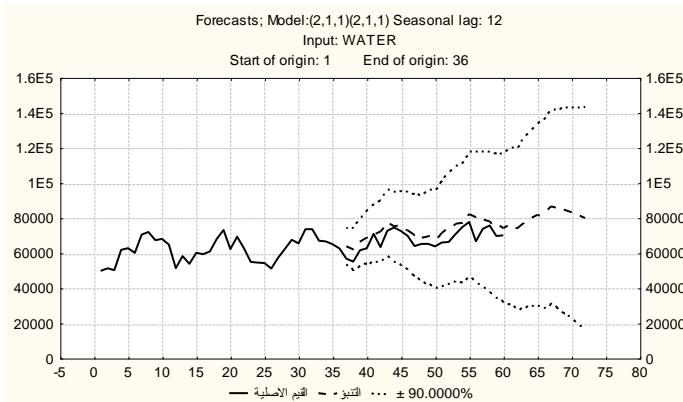
جدول (5) تقييم معلمات النموذج



شكل (5) معامل الارتباط الذاتي لاخطاء النموذج



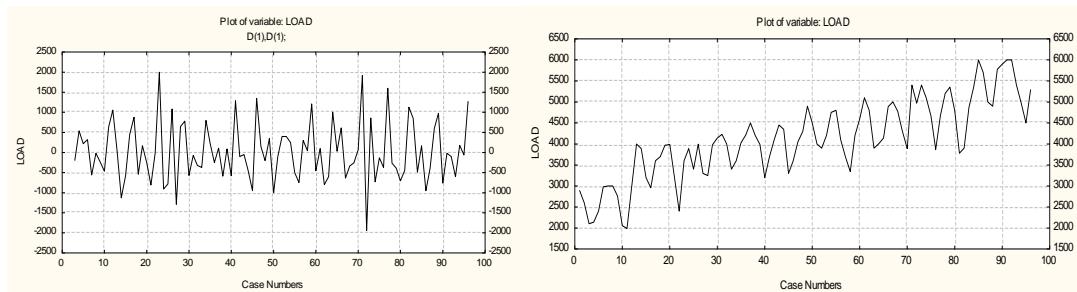
شكل (6) معامل الارتباط الذاتي لاخطاء النموذج



شكل (7) : التنبؤ لكميات الماء المستهلك (WATER) في بغداد حسب نموذج بوكس جنكتر

4-1-2 بيانات الحمل الكهربائي LOAD

بعد رسم السلسلة الزمنية الجدول (2) وبعد اخذ الفرق الاول والموسمي لها اصبحت مستقرة كما في الشكل 8 والشكل 9 وتم اختيار النموذج $(ARIMA(2,1,1)(2,1,1))$ من بين نماذج عديدة بالاعتماد على اصغر متوسط لمربعات الخطأ MSE . كما هو موضح في الجداول 7,8 وتم احتساب معاملات الارتباط الذاتي والجزئي للخطا كما هو واضح في الاشكال 10,11 والتي تدل على عشوائية الاصطاء. ثم استخدم النموذج للتنبؤ كما هو واضح في الشكل 12 وكان متوسط مربعات الخطأ يساوي $2168E2$.



شكل (8):بيانات الحمل الكهربائي للشبكة الوطنية العراقية

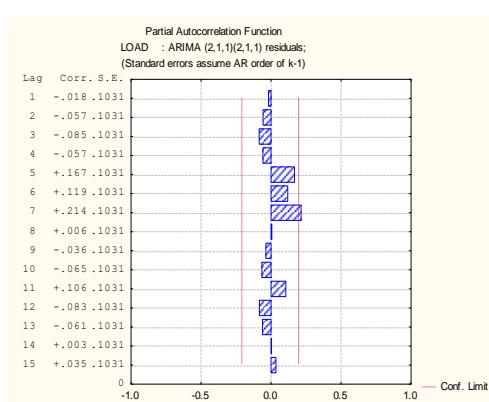
شكل (9) البيانات بعد اخذ الفرق الموسمي والغير موسمي

CaseNo.	Forecasts Model:(2,1,1)(2,1,1) Seasonal lag: 12 (ir)				
	Forecast	Lower	Upper	Std.Err.	Observed
		90.0000%	90.0000%		
73	5351.25	4555.31	6147.1	478.80	5400.00
74	5322.27	4238.33	6406.2	652.04	5100.00
75	4784.39	3509.81	6058.9	766.72	4670.00
76	4711.79	3246.82	6176.7	881.26	3870.00
77	5078.24	3427.63	6728.8	992.93	4670.00
78	5622.38	3794.80	7449.91	1099.39	5205.00
79	5806.74	3806.85	7806.6	1203.04	5350.00
80	5601.41	3431.82	7771.0	1305.13	4790.00
81	5135.85	2798.49	7473.2	1406.05	3780.00
82	4953.76	2449.88	7457.6	1506.22	3900.00
83	5904.56	3234.85	8574.2	1605.98	4870.00
84	6010.84	3175.57	8846.1	1705.57	5350.00
85	6435.29	3331.51	9539.0	1867.09	6000.00
86	6366.23	3012.66	9719.8	2017.36	5700.00
87	5870.64	2282.69	9458.5	2158.35	5000.00
88	5830.94	2007.17	9654.7	2300.21	4900.00
89	6228.26	2168.54	10287.9	2442.15	5780.00
90	6794.33	2499.76	11088.9	2583.42	5900.00
91	7008.33	2479.16	11537.5	2724.55	6000.00
92	6831.14	2067.10	11595.1	2865.84	6000.00
93	6393.51	1394.15	11392.8	3007.39	5400.00
94	6244.23	1008.90	11479.5	3149.35	4980.00
95	7209.95	1737.79	12682.1	3291.81	4500.00
96	7356.04	1646.04	13066.0	3434.88	5300.00
97	7809.09	1779.42	13838.7	3627.18	
98	7766.76	1427.98	14105.5	3813.13	
99	7299.79	661.44	13938.1	3993.34	
100	7288.47	347.41	14229.5	4175.44	
101	7714.13	468.48	14959.7	4358.66	
102	8308.31	757.44	15859.1	4542.27	
103	8550.62	693.34	16407.9	4726.59	
104	8401.71	236.57	16566.8	4911.79	
105	7992.36	-482.13	16466.8	5097.89	
106	7871.48	-913.99	16656.9	5284.96	
107	8865.14	-233.00	17963.2	5473.05	
108	9039.76	-372.82	18452.3	5662.20	

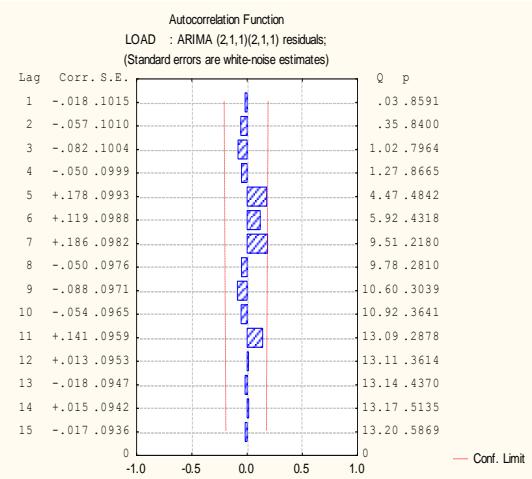
Paramet.	Input: LOAD (iraq load (B2:CS97)) Transformations: D(1),D(1) Model:(2,1,1)(2,1,1) Seasonal lag: 12				
	Param.	Asympt.	Asympt.	p	Low
		Std.Err.	t(88)	95% C	
p(1)	-0.12035				
p(2)	-0.13586				
q(1)	0.95520				
Ps(1)	1.02266				
Ps(2)	-0.02269				
Qs(1)	0.67113				

جدول (8) التسلي الـ 12 شهر القادمة

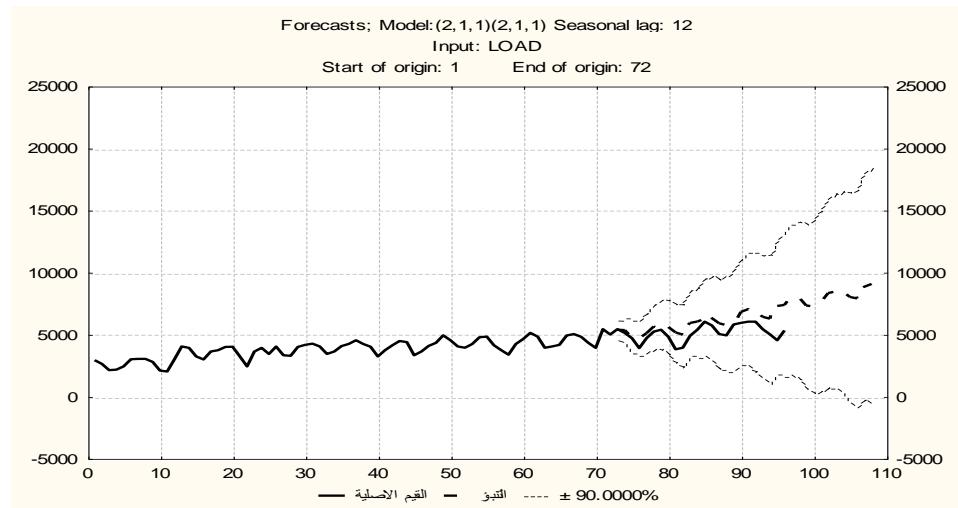
جدول (7) تقدير معلمات النموذج



شكل (10) معامل الارتباط الجزئي لاخطاء النموذج



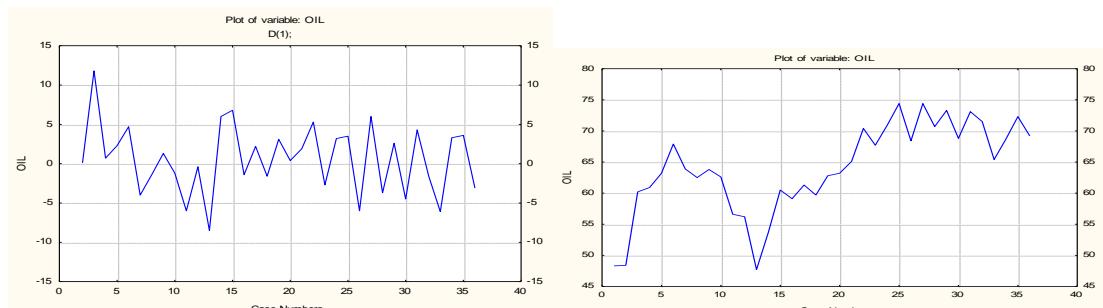
شكل (11) معامل الارتباط الذاتي لاخطاء النموذج



شكل (12) : التبؤ لكميات الحمل الكهربائي LOAD للشبكة الوطنية حسب نموذج بوكس جنكتر

3-1-4 بيانات النفط :OIL

بعد رسم السلسلة الزمنية لبيانات النفط الجدول (3) واخذ الفرق الاول فقط اصبحت مستقرة كما في الشكل 13 والشكل 14 وتم اختيار النموذج (ARIMA)(1,1,1) من بين نماذج عديدة بالاعتماد على اصغر متوسط لمربعات الخطأ MSE . كما هو موضح في الجداول 9,10 وتم احتساب معاملات الارتباط الذاتي والجزئي للخطا كما هو واضح في الاشكال 15,16 والتي تدل على عشوائية الارطاء ثم استخدم النموذج للتنبؤ كما هو واضح في الشكل 17 وكان متوسط مربعات الخطأ يساوي 19.089 .



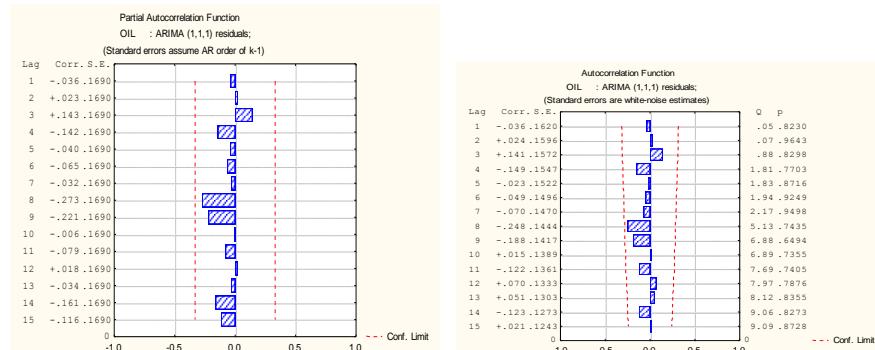
شكل (14) البيانات بعد اخذ الفرق الاول فقط

شكل (13) : بيانات النفط المنتج شهريا

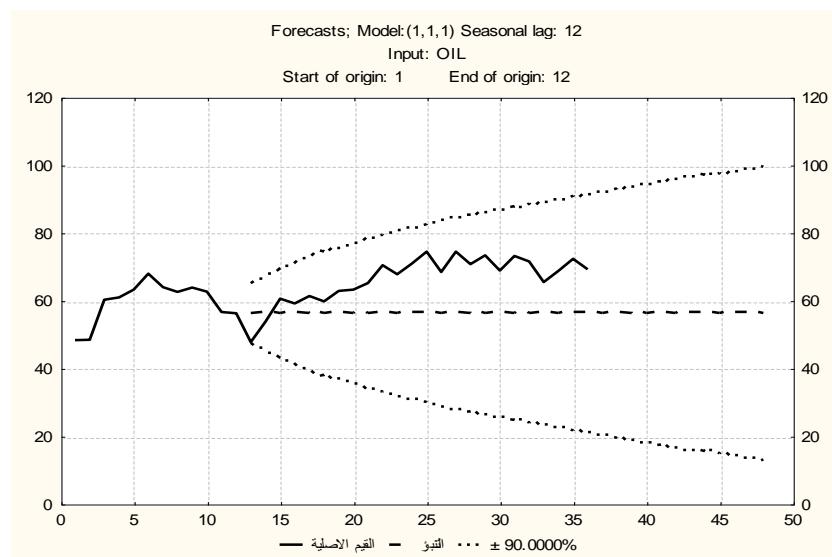
CaseNo.	Forecasts; Model:(1,1,1) Seasonal lag: 12 (load (B2 Input: OIL Start of origin: 1 End of origin: 12				
	Forecast	Lower	Upper	Std.Err.	Observed
	90.0000%	90.0000%			
13	56.2928	47.5026	65.0830	5.1940	47.7000
14	56.2718	45.1664	67.3771	6.5620	53.7000
15	56.2765	43.0191	69.5339	7.8336	60.5000
16	56.2754	41.2185	71.3323	8.8969	59.1000
17	56.2757	39.6025	72.9489	9.8520	61.3000
18	56.2756	38.1317	74.4196	10.7211	59.7000
19	56.2756	36.7710	75.7803	11.5250	62.8000
20	56.2756	35.4994	77.0519	12.2764	63.2000
21	56.2756	34.3012	78.2501	12.9844	65.1000
22	56.2756	33.1651	79.3862	13.6558	70.4000
23	56.2756	32.0823	80.4690	14.2956	67.7000
24	56.2756	31.0458	81.5055	14.9080	70.9000
25	56.2756	30.0504	82.5009	15.4962	74.4000
26	56.2756	29.0913	83.4600	16.0629	68.4000
27	56.2756	28.1649	84.3863	16.6103	74.4000
28	56.2756	27.2682	85.2831	17.1402	70.7000
29	56.2756	26.3983	86.1530	17.6542	73.3000
30	56.2756	25.5530	86.9983	18.1537	68.8000
31	56.2756	24.7304	87.8209	18.6398	73.1000
32	56.2756	23.9287	88.6226	19.1135	71.5000
33	56.2756	23.1464	89.4049	19.5757	65.4000
34	56.2756	22.3821	90.1692	20.0273	68.7000
35	56.2756	21.6347	90.9166	20.4690	72.3000
36	56.2756	20.9031	91.6482	20.9013	69.2000
37	56.2756	20.1863	92.3650	21.3248	
38	56.2756	19.4835	93.0678	21.7401	
39	56.2756	18.7938	93.7574	22.1476	
40	56.2756	18.1167	94.4346	22.5477	
41	56.2756	17.4513	95.1000	22.9409	
42	56.2756	16.7971	95.7542	23.3274	
43	56.2756	16.1536	96.3977	23.7077	
44	56.2756	15.5203	97.0310	24.0819	
45	56.2756	14.8966	97.6547	24.4504	
46	56.2756	14.2822	98.2690	24.8135	
47	56.2756	13.6767	98.8746	25.1713	
48	56.2756	13.0797	99.4716	25.5240	

جدول (10) التنبؤ الى 12 شهر القادمة

جدول (9) تقييم معلمات المودج



شكل (16) معامل الارتباط الذاتي لاخطراء النموذج شكل (15) معامل الارتباط الجزئي لاخطراء النموذج

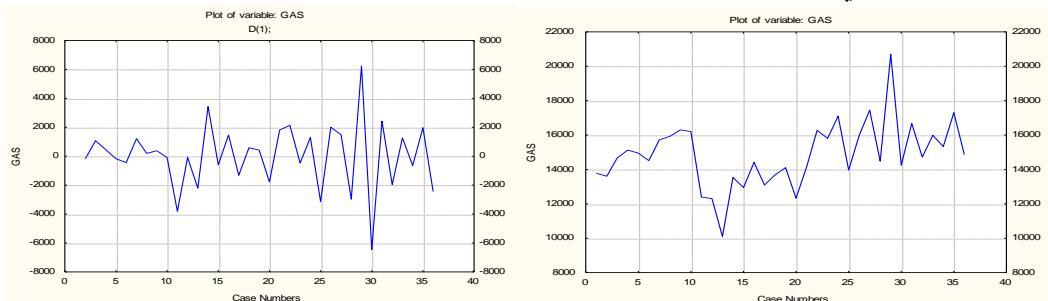


شكل (17) : التنبؤ لكميات النفط (OIL) المنتج شهريا حسب نموذج بوكس جنكر

4-1-4: بيانات الغاز :GAS

بعد رسم السلسلة الزمنية الجدول (4) واخذ الفرق الاول فقط أصبحت مستقرة كما في الشكل 18 والشكل 19 وتم اختيار النموذج $(ARIMA(1,1,0))$ من بين نماذج عديدة بالاعتماد على اصغر متوسط لمربعات الخطأ MSE كما هو موضح في الجدولين 11,12 وتم احتساب معاملات الارتباط الذاتي والجزئي للخطأ كما هو واضح في الاشكال 20,21 .

والتي تدل على عشوائية الخطأ، ثم استخدم النموذج للتنبؤ كما هو واضح في الشكل 22 وكان متوسط مربعات الخطأ يساوي 3057E3



شكل (18) : بيانات الغاز المتغير شهريا

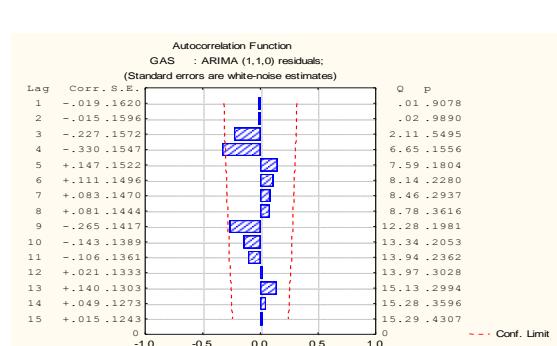
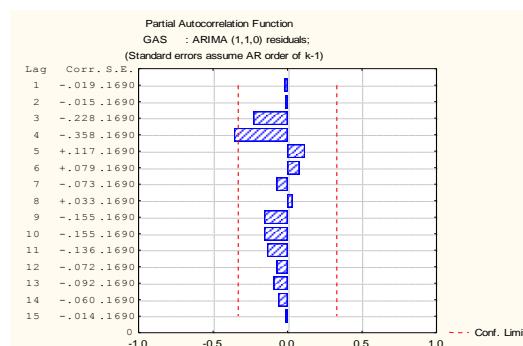
شكل (19) البيانات بعد اخذ الفرق الاول

Forecasts: Model:(1,1,0) Seasonal lag: 12 (load (B2					
Input: GAS					
Start of origin: 1 End of origin: 24					
CaseNo.	Forecast	Lower	Upper	Std.Err.	Observed
25	16248.7	13552.5	18944.9	1594.49	13964.0
26	16810.0	13961.1	19659.0	1684.84	15971.0
27	16440.3	12907.0	19973.6	2089.58	17451.0
28	16683.8	12912.1	20455.5	2230.57	14480.0
29	16523.4	12332.5	20714.4	2478.48	20704.0
30	16629.1	12180.2	21077.9	2631.03	14249.0
31	16559.5	11792.2	21326.7	2819.31	16676.0
32	16605.3	11586.8	21623.8	2967.89	14716.0
33	16575.1	11288.1	21862.1	3126.69	15985.0
34	16595.0	11071.0	22119.0	3266.83	15333.0
35	16581.9	10819.1	22344.8	3408.09	17303.0
36	16590.5	10605.8	22575.3	3539.35	14863.0
37	16584.9	10381.4	22788.3	3668.69	
38	16588.6	10176.9	23000.3	3791.85	
39	16586.1	9970.8	23201.5	3912.26	
40	16587.8	9776.1	23399.4	4028.35	
41	16586.7	9583.5	23589.9	4141.66	
42	16587.4	9398.2	23776.6	4251.65	
43	16586.9	9216.1	23957.8	4359.05	
44	16587.2	9039.4	24135.1	4463.75	
45	16587.0	8866.1	24308.0	4566.12	
46	16587.2	8697.0	24477.4	4666.20	
47	16587.1	8531.1	24643.0	4764.22	
48	16587.1	8368.9	24805.4	4860.23	

Input: GAS (load (B2:AK37))					
Transformations: D(1)					
Model:(1,1,0) MS Residual= 3057E3					
Paramet.	Asympt.	Asympt.	p	Lower	
Param.	Std.Err.	t(34)		95% Conf	
p(1)	-0.65862	0.13490	-4.8820	0.00002	-0.93279

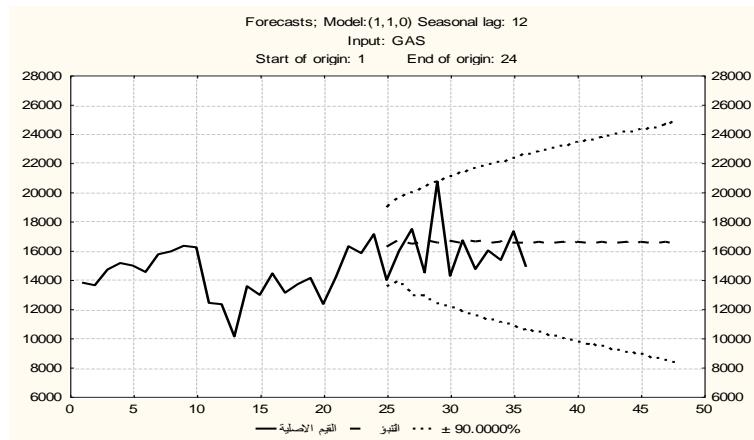
جدول (12) التنبؤ الى ال 12 شهر القادمة

جدول (11) تقييم معلمات النموذج



شكل (20) معامل الارتباط الذاتي لاخطاء النموذج

شكل (21) معامل الارتباط الذاتي لاخطاء النموذج



شكل (22) : التنبؤ لكميات الغاز(GAS) المنتج حسب نموذج بوكس جنكتر

4-2 تحليلات الشبكات العصبية ANN

تم تحويل البيانات الى الصيغة الطبيعية اي مابين [-1,1] قبل استخدامها في الشبكة العصبية الاصطناعية . وتم تحويلها الى الصيغة الطبيعية قبل احتساب مربعات الخطأ. هيكل الشبكات العصبية يكتب كما يلي

$$I \times H \times O$$

حيث ان I, H, O تمثل عدد وحدات الادخال والوحدات المخفية ووحدات الارجاع لكل طبقة.

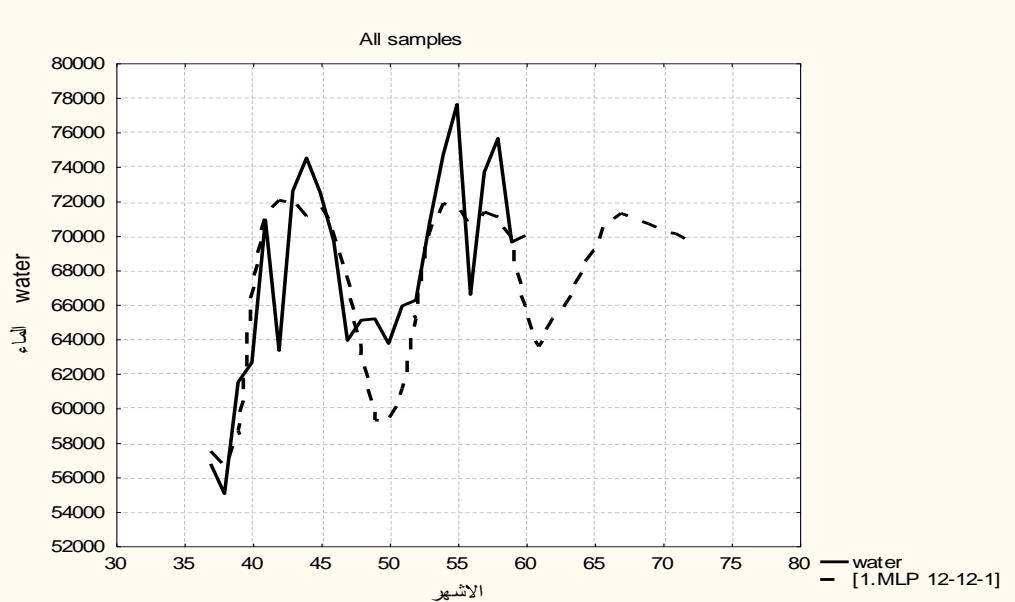
4-2-1 بيانات الماء: WATER

بالنسبة للماء تم التوصل الى النموذج $MLP\ 12-12-1$

كانت عدد وحدات الادخال يساوي 12 والذي يعادل عدد الاشهر لكل سنة وعدد الوحدات المخفية 12. وذلك لأن البيانات فيها صيغة الموسمية وطول الموسمية لها هو 12
بالنسبة الى البيانات الاصطناعية تم حزن نسب 80% من المشاهدات للتدريب والباقي للاختبار ولم يتم استخدامها في بناء النموذج وتم مقارنتها بالنتائج لفترة الاختبار . الجدول (13) يمثل نتائج التنبؤ والشكل (23) يمثل البيانات الاصطناعية مع القيم المتنبأ بها حسب النموذج $MLP\ 12-12-1$ واستخدمت دالة النشيط $tanh$ للطبقة المخفية و دالة النشيط $identity$ لطبقة الارجاع . وكان متوسط مربعات الخطأ هو 1642981

Case name	Time series projection for water (water (B2:B11))	
	water Target	water(Out put) 1. MLP 12-12-1
37	56733.0	57463.9
38	54998.0	56611.4
39	61465.0	58658.9
40	62606.0	66029.4
41	70871.0	71172.4
42	63305.0	72012.3
43	72555.0	72069.7
44	74473.0	71093.3
45	72455.0	71564.9
46	69645.0	70477.9
47	63890.0	67664.5
48	65056.0	63394.1
49	65139.0	59276.7
50	63703.0	59335.7
51	65881.0	61096.7
52	66225.0	65149.3
53	70698.0	70143.4
54	74663.0	71846.8
55	77570.0	71627.7
56	66550.0	70644.7
57	73635.0	71344.6
58	75600.0	71048.2
59	69590.0	69861.3
60	69975.0	65896.8
25		63543.0
26		65152.3
27		66086.2
28		67943.2
29		69117.0
30		70769.1
31		71259.5
32		70984.5
33		70654.5
34		70346.6
35		70088.2
36		69581.2

جدول (13) التنبؤ الى الـ 12 شهر القادمة



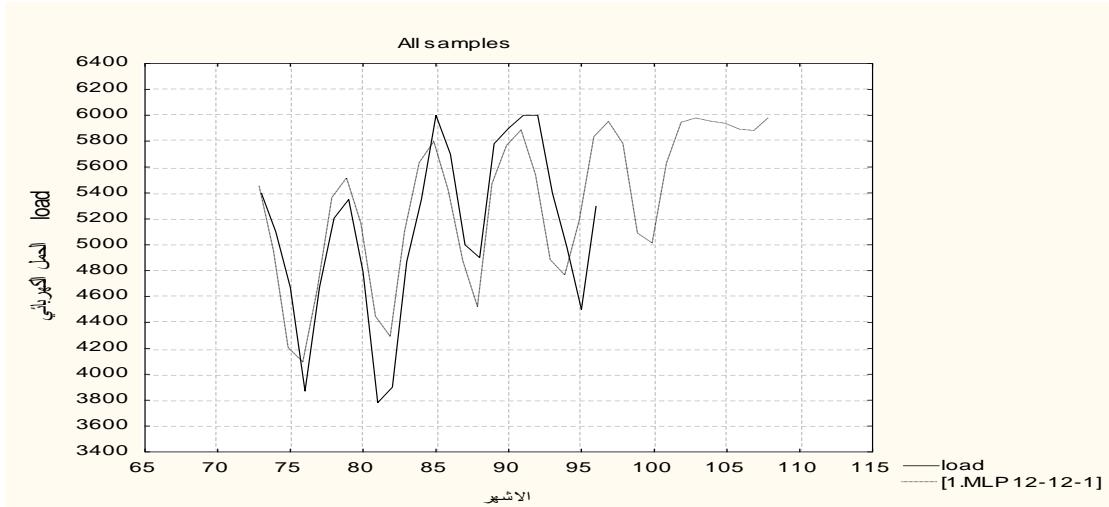
شكل (23) : التنبؤ لكميات الماء المستهلك في بغداد حسب نوذج الشبكات لعصبية

بيانات الحمل الكهربائي LOAD تم التوصل الى النموذج MLP 12-12-1

في هذه الدراسة وبالنسبة الى بيانات الحمل الكهربائي كانت عدد الوحدات المخفية متساوية لعدد وحدات الالدخل حيث كانت 12 والذي يعادل عدد الاشهر لكل سنة . وكان التنبؤ لـ 12 شهر القادمة .
بالنسبة الى البيانات الاصلية تم خزن نسب 80% من المشاهدات للتدريب والباقي للاختبار ولم يتم استخدامها في بناء النموذج وتم مقارنتها بالتنبؤات لفترة الاختبار . الجدول (14) يمثل نتائج التنبؤ والشكل (24) يمثل البيانات الاصلية مع القيم المتباينا بها حسب النموذج MLP 12-12-1 واستخدمت دالة التشبيط exponential لطبقة المخفية ودالة النشيط logistis لطبقة الارجاع . وكان متوسط مربعات الخطأ هو 71508.4

Case name	Time series projection for load (B2:CS97)	
	load Target	load(O output) 1. MLP 12-12-1
73	5400.000	5444.193
74	5100.000	4940.232
75	4670.000	4195.768
76	3870.000	4085.155
77	4670.000	4645.374
78	5205.000	5353.727
79	5350.000	5506.638
80	4790.000	5157.599
81	3780.000	4436.052
82	3900.000	4281.948
83	4870.000	5093.038
84	5350.000	5623.416
85	6000.000	5787.749
86	5700.000	5410.730
87	5000.000	4865.988
88	4900.000	4511.707
89	5780.000	5459.913
90	5900.000	5755.998
91	6000.000	5877.046
92	6000.000	5530.250
93	5400.000	4874.868
94	4980.000	4755.121
95	4500.000	5177.496
96	5300.000	5823.730
25		5941.942
26		5771.985
27		5079.511
28		5003.046
29		5620.334
30		5935.755
31		5968.756
32		5944.647
33		5928.340
34		5881.910
35		5872.706
36		5970.964

جدول (14) التنبؤ الى الـ 12 شهر القادمة



شكل (24) : التنبؤ للحمل الكهربائي للشبكة الوطنية حسب نوذج الشبكات العصبية

بيانات النفط المستخرج OIL

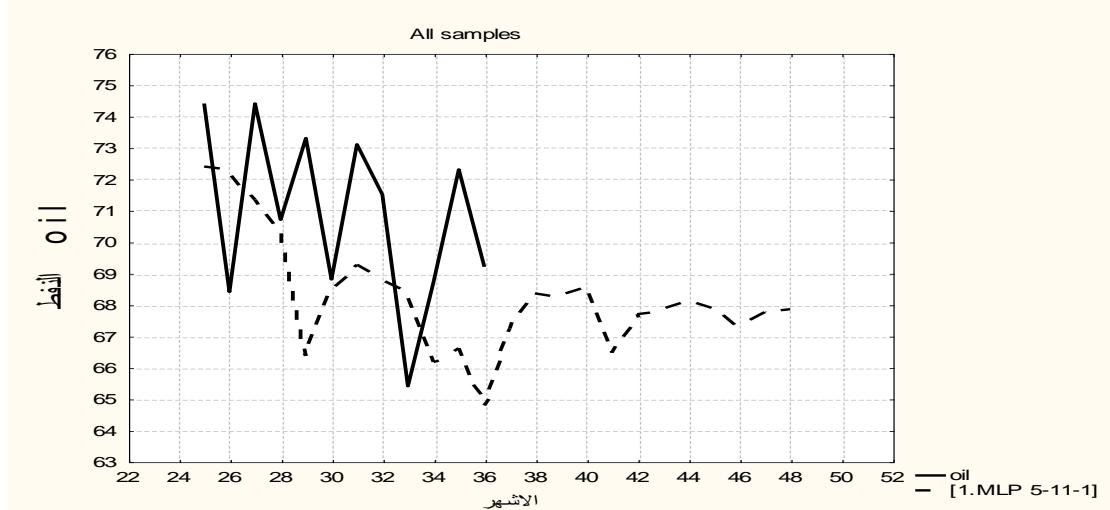
تم التوصل الى النموذج MLP 5-11-1

في هذه الدراسة وبالنسبة الى بيانات النفط كانت عدد الوحدات المخفية تساوي 11 وعدد وحدات الادخال تساوي 5 وعدد المخرجات يساوي 1 .

بالنسبة الى البيانات الاصلية تم حزن نسب 80% من المشاهدات للتدريب والباقي للاختبار ولم يتم استخدامها في بناء النموذج وتم مقارنتها بالنبؤات لفترة الاختبار . الجدول (15) يمثل نتائج التنبؤ والشكل (25) يمثل البيانات الاصلية مع القيم المتباينا بها حسب النموذج MLP 5-11-1 و استخدمت دالة التنشيط identity للطبقة المخفية و دالة النشيط tanh لطبقة الارجاع .. وكان متوسط مربعات الخطأ هو 13.868

Time series projection for oil (load (B2:AK All samples)		
Case name	oil Target	oil(Output) 1. MLP 5-11-1
25	74.4000	72.3909
26	68.4000	72.2471
27	74.4000	71.3370
28	70.7000	70.2524
29	73.3000	66.3647
30	68.8000	68.4380
31	73.1000	69.2695
32	71.5000	68.7940
33	65.4000	68.3295
34	68.7000	66.1706
35	72.3000	66.6116
36	69.2000	64.7919
13		67.2441
14		68.3211
15		68.2927
16		68.5858
17		66.4641
18		67.6920
19		67.9312
20		68.1635
21		67.9311
22		67.2662
23		67.7574
24		67.8484

جدول (15) التنبؤ الى الـ 12 شهر القادمة

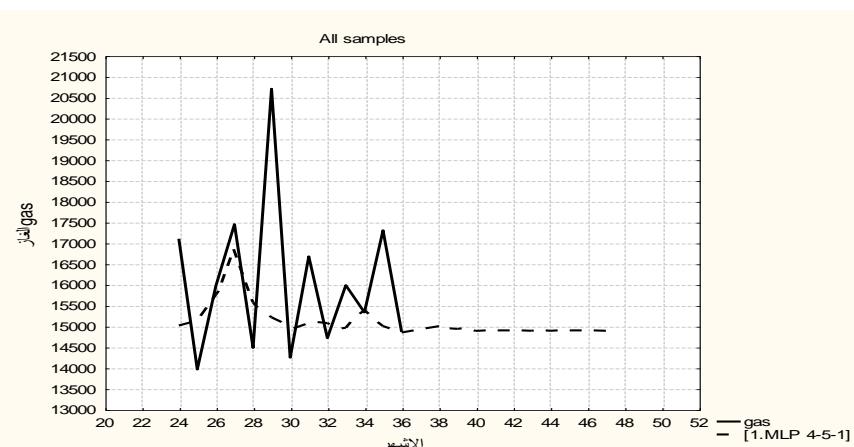


شكل (25) : التنبؤ لكميات النفط المنتج شهرياً حسب نوذج الشبكات العصبية

بيانات الغاز المتدفق GAS تم التوصل الى النموذج MLP 4-5-1 في هذه الدراسة وبالنسبة الى بيانات النفط كانت عدد الوحدات المخفية تساوي 5 وعدد وحدات الادخال تساوي 4 وعدد المخرجات يساوي 1 . بالنسبة الى البيانات الاصلية تم حزن نسب 80% من المشاهدات للتدريب والباقي للاختبار ولم يتم استخدامها في بناء النموذج وتم مقارنتها بالتنبؤات لفترة الاختبار . الجدول (16) يمثل نتائج التنبؤ والشكل (26) يمثل البيانات الاصلية مع القيم المتنبأ بها حسب النموذج MLP 4-5-1 واستخدمت دالة التنشيط $tanh$ للطبقة المخفية ودالة التنشيط logistic لطبقة الارجاع 1757237.

Case name	Time series projection for gas (load (B2:AK))	
	gas Target	gas(Output) 1. MLP 4-5-1
24	17101.0	15018.0
25	13964.0	15136.8
26	15971.0	15760.5
27	17451.0	16860.0
28	14480.0	15573.6
29	20704.0	15212.9
30	14249.0	14958.7
31	16676.0	15089.2
32	14716.0	15077.2
33	15985.0	14962.9
34	15333.0	15383.2
35	17303.0	15004.0
36	14863.0	14843.3
14		14962.9
15		15000.5
16		14935.5
17		14888.4
18		14891.1
19		14891.5
20		14890.7
21		14890.1
22		14890.1
23		14890.1
24		14890.1

جدول (16) التنبؤ الى الـ 12 شهر القادمة



شكل (26) : التنبؤ لكميات الغاز المتدايق شهرياً حسب نموذج الشبكات العصبية

النتائج النهائية:

الجدولين التاليين يمثلان قيم متوسطات مربعات الخطأ للنموذجين بوكس جنكنز ARIMA والشبكات العصبية NUREAL ولجميع السلسل الرزمية للمقارنة ويلاحظ ان متوسط مربعات الخطأ ولجميع السلسل الرزمية اعطى قيم اصغر من متوسطات مربعات الخطأ بطريقة بوكس جنكنز.

MSE	Load	MSE	Water	
216800.0	ARIMA (2,1,1)(2,1,1)	27420000	ARIM(2,1,1)(2,1,1)	ARIMA
71508.4	MLP 12-12-1	16429818	MLP 12-12-1	NUREAL

جدول (17) مقارنة ما بين الطريقيتين للبيانات الموسمية

MSE	Gas	MSE	Oil	
3057000	ARIMA(1,1,0)	19.089	ARIMA (1,1,1)	ARIMA
1757237	MLP 4-5-1	13.868	MLP 5-11-1	NUREAL

جدول (18) : مقارنة ما بين الطريقيتين للبيانات الغير موسمية

٤- الاستنتاجات

الشبكات العصبية هي طريقة بديلة الى طريقة بوكس جنكنز . خاصة في حالة وجود صفة الاتجاه العام والموسمية في البيانات . وتعتبر الطرق التقليدية من الطرق الجيدة في التنبؤ ولكن طريقة الشبكات العصبية هي الأفضل لأنها لا تحتاج خطوات أساسية للتوصل الى نموذج التنبؤ الأفضل كما في حالة بوكس جنكنز لأنها تعتمد على عوامل أخرى وهي طبيعة البيانات وهيكليّة الشبكة وطريقة التدريب ودوال التشغيل وتكرار التجارب بتغيير المعلمات السابقة الذكر وزيادة عدد مرات التدريب CYCLES لحين التوصل الى النموذج الأفضل وذلك عن طريق مقارنة متوسط مربعات الخطأ بين النماذج وكذلك ملاحظة مدى ملائمة النموذج بمساعدة الشكل البياني الخاص بالبيانات الأصلية واقيام التنبؤ لهذه البيانات . يلاحظ من الاشكال البيانية السابقة الخاصة بالقيم الأصلية والتنبؤ بان طريقة الشبكات العصبية اعطت نتائج ادق من طريقة بوكس جنكنز وكذلك الجدولين (17) ، (18) تؤيد جودة الشبكات العصبية في التنبؤ .

٦. المصادر

- [1] Moshir Saeed and Cameron Norman " Neural network Versus Econometric Models in Forecasting Inflation", John Wiley & Sons, Ltd, 2000.
- [2] Wu Shaan-inn and Lu Ruey-Pyng " Combining Articical Neural Networks and Statistics for Stock-Market Forecasting", ACM, 1993.
- [3] Suhartono and Subanar " A comparative Study of Forecasting Models for Trend and Seasonal Time Series : Does Complex Model Always Yield Better Forecast than Simple Models?", Jurnal Teknik Industri, 2005.
- [4] Yan Lai Mei and Choon Ong Hong " Neural Network Forecasting on electricity consumption in Malaysia", USM, Malaysia, 2000.
- [5] Faraway Julian and Chatfield Chris " Time Series Forecasting with Neural Networks: A case study", University of Bath, 1995.
- [6] Suhartono and Subanar " The Effect of Decomposition Method as Data Preprocessing on Neural Network Model For Forecasting trained and Seasonal Time Series", Jurnal Teknik Industri, 2006.
- [7] Momani Nail M. " Time Series Analysis Model for Rainfall Data in Jordan: case study for Using Time series Analysis", American journal of Environment Sciences, 2009.