

التنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نماذج السلاسل الزمنية ونماذج الشبكات العصبية الاصطناعية

## Forecasting of electricity power consumption in AL - Qadisiya province by using time series models & Artificial neural networks models

أ.د. محمد حبيب الشاروط  
كلية الإدارة والاقتصاد  
جامعة القادسية

دعاء عبد الكريم صاحب  
كلية علوم الحاسوب والرياضيات  
جامعة القادسية

قبول النشر ٢٠١٤/٣/٣١

ارسال التعديلات ٢٠١٤/٣/٢٣

استلام البحث ٢٠١٤/٢/٢٧

### المستخلص :

يعد موضوع تحليل السلاسل الزمنية من المواضيع الإحصائية المهمة التي تهتم بدراسة سلوك الظواهر وتفسيرها عبر فترات زمنية محددة ، من خلال وصف عام للسلسلة الزمنية وبناء نموذج لتفسير سلوكها لغرض التنبؤ. يهدف البحث إلى بناء نموذج تنبؤي باستهلاك الطاقة الكهربائية في محافظة القادسية للفترة (2005- 2012) باستخدام نموذج بوكس - جنكينز في السلاسل الزمنية ونموذج الشبكات العصبية الاصطناعية وقد أظهرت النتائج تفوق نموذج الشبكات العصبية الاصطناعية من خلال تطبيق بعض معايير الخطأ.

### Abstract :

The time series analysis is considered of the important statistics topics which concerned with the study phenomena behavior and interpret them at periods of time. Through a general description of time series and forming a suitable model for time series behavior interpretation for forecasting

The aim of research is to build a forecasting model to the electricity power consumption in AL - Qadisiya province at the period (2005 - 2012) by using Box Jenkins model in time series and Artificial Neural Networks (ANN) model . The results showed superiority of artificial neural networks by using some error criterion.

## 1- المقدمة :

يعد التنبؤ بالسلوك المستقبلي من المواضيع المهمة في علم الإحصاء ، وذلك للحاجة إليه في مختلف مجالات الحياة ، مثل التنبؤ باستهلاك الطاقة الكهربائية ، وحالة السوق ، والأسعار وغيرها [7]. ويعتبر تحليل السلاسل الزمنية من المواضيع المهمة في هذا المجال التي تتناول سلوك الظواهر وتفسرها عبر فترات زمنية محددة ، من خلال بناء نماذج تنبؤية للسلاسل الزمنية بالاعتماد على الأساليب الإحصائية والرياضية مثل نماذج بوكس - جنكينز ونماذج التمهيد الآسي وغيرها . وقد تزايد الاهتمام بموضوع التنبؤ خلال السنوات الأخيرة وظهرت أساليب حديثة خاصة ، ومنها الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN) [13]. تناول البحث عرضاً مبسطاً لمنهجية بوكس جنكينز ، وأساليب الشبكات العصبية الاصطناعية ، بالإضافة إلى تطبيق طريقة بوكس جنكينز وأساليب الشبكات العصبية الاصطناعية على بيانات شهرية تم جمعها من المديرية العامة لتوزيع الكهرباء في محافظة القادسية تمثل استهلاك الطاقة الكهربائية الشهرية للفترة من (2005) إلى (2012) وقد تم الاستعانة بحزمة البرمجيات الجاهزة (MATLAB"r2012a 7.14") لتحليل نموذجي بوكس جنكينز والشبكات العصبية الاصطناعية .

## 2- السلسلة الزمنية (Time series) [11] [6] [3]

تعرف السلسلة الزمنية على إنها مجموعة من المشاهدات لقيم ظاهرة ما خلال مدة زمنية معينة في الغالب تكون متساوية . وتعرف السلسلة الزمنية رياضياً ، بأنها متتابعة من المتغيرات العشوائية معرفة ضمن الفضاء الاحتمالي متعدد المتغيرات ومؤشر بالدليل (t) والذي يعود إلى مجموعة دليبيه (T) ويرمز للسلسلة عادة  $\{x(t): t \in T\}$  . وتقسم السلاسل الزمنية حسب سلوكها إلى : السلاسل الزمنية الموسمية (Seasonal time series) والسلاسل الزمنية غير الموسمية (Non- seasonal time series) كما تصنف السلاسل الزمنية إلى : السلاسل الزمنية المستقرة (Stationary time series) ، والسلاسل الزمنية غير المستقرة (Non-Stationary time series) إذ إن الاستقرار تعني عدم وجود نمو في البيانات ، أي أن تكون البيانات منتشرة حول وسط ثابت لا يعتمد على الزمن  $\mu = E(X_t)$  ولها تباين ثابت أي كمية ثابتة خلال الزمن  $\sigma_x^2 = Var(X_t)$  . إن اغلب السلاسل الزمنية في الواقع العملي والتطبيقي تكون غير مستقرة وقد فشل في إثبات ذلك في الرسم البياني أو الاختبارات الإحصائية، فعلى سبيل المثال نجد أن المتغيرات الاقتصادية غالباً ما تعتبر سلاسل زمنية غير مستقرة كونها تسير بصفة عامة في اتجاه عام . لذلك لا بد من تحويلها إلى سلاسل زمنية مستقرة يسهل نمذجتها ويمكن تحويل السلسلة الزمنية غير المستقرة في المتوسط إلى سلسلة مستقرة وذلك باستعمال أسلوب الفروقات (differencing) وبعد أخذ عدد من الفروق المناسبة من الدرجة (d) للسلسلة الأصلية توصف الفروقات باستعمال عامل الفروق الخلفية (Back shift operator) كالآتي :

$$\nabla^d X_t = (1 - B)^d X_t \quad t=0,1,2,\dots$$

والفروق للسلسلة الزمنية الموسمية تكون من الدرجة (D) وصيغتها كالآتي :  $\nabla_s^D X_t = (1 - B^s)^D X_t$  اما عدم الاستقرار في التباين يعالج باستخدام إحدى التحويلات المناسبة مثل التحويل اللوغارتمي الطبيعي أو تحويل الجذر التربيعي لبيانات السلسلة الزمنية أو باستخدام تحويلات أخرى .

ويمكن استعمال يتم تطبيق اختبار كريسكال واليس (Krudkall-Wallis (KW للكشف عن التأثيرات الموسمية في السلسلة الزمنية بعد إزالة الاتجاه العام وتحسب احصاء الاختبار وفق الصيغة الآتية :

$$KW = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{r_i^2}{n_i} - 3(N+1)$$

اذ ان : N : مشاهدات السلسلة الزمنية بعد ازالة الاتجاه العام و  $n_i$  : مشاهدات السلسلة الزمنية عند k و طول الموسم وتقرن قيمة KW مع قيمة  $(\chi^2)$  الجدولية بدرجة حرية (k-1) وبمستوى معنوية ( $\alpha$ ) معين فإذا كانت قيمة KW اصغر من قيمة  $(\chi^2)$  الجدولية فإن السلسلة الزمنية لا تحتوي على تأثيرات موسمية [9] إما الدالة التي تربط قيم السلسلة الزمنية بالقيم السابقة لها مع إضافة الأخطاء العشوائية ، فتسمى نموذج السلسلة الزمنية (Time Series Model) وإن نماذج السلاسل الزمنية هي في الحقيقة نماذج تصادفية أو احتمالية . وستنظر هنا إلى عدة أنواع من نماذج السلاسل الزمنية وهي كالآتي :

**أ- نموذج الانحدار الذاتي (Autoregressive Model) [10]**

يمكن كتابة الصيغة العامة لأنموذج الانحدار الذاتي كالآتي :

$$\phi(B)X_t = e_t \quad (1)$$

حيث إن  $X_t$  مشاهدات السلسلة الزمنية عند الزمن  $t$  و  $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  و  $\phi_i$  معالم نموذج الانحدار الذاتي  $i=1,2,\dots,p$  و  $e_t$  متغيرات عشوائية غير مرتبطة لها معدل صفر وتباين  $\sigma_e^2$  ويرمز لأنموذج الانحدار الذاتي من الرتبة  $p$  اختصاراً  $AR(p)$

**ب- نموذج الأوساط المتحركة (Moving Average model) [10]**

يمكن كتابة الصيغة العامة لأنموذج الأوساط المتحركة كالآتي :

$$X_t = \theta(B) e_t \quad (2)$$

حيث إن  $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$  و  $\theta_i$  معالم نموذج الأوساط المتحركة  $i=1,2,\dots,q$  ويرمز لأنموذج الأوساط المتحركة من الرتبة  $q$  اختصاراً  $MA(q)$

**ج- نموذج الانحدار الذاتي والأوساط المتحركة (النموذج المختلط)**

**[10] Autoregressive Moving Average Methods (ARMA)**

الصيغة العامة لأنموذج الانحدار الذاتي والأوساط المتحركة  $ARMA(p,q)$  حيث إن  $(p+q)$  هما عدد معالم الأنموذج كالآتي :

$$\phi(B)X_t = \theta(B)e_t \quad (3)$$

ويمكن اعتبار نماذج  $MA(q), AR(p)$  حالات خاصة من الأنموذج  $ARMA$  عندما يكون  $p$  مساوياً للصفر فنحصل على أنموذج  $MA(q)$  وعند التعويض عن  $q$  صفر سنحصل على أنموذج  $AR(p)$ .

**د- النموذج المختلط المتكامل [7] [15]**

**Autoregressive Integrated Moving Average Methods (ARIMA)**

قد تكون بعض السلاسل الزمنية غير مستقرة ، لكنها تصبح مستقرة بعد إجراء عدد من التحويلات أو الفروق لذلك فإن النموذج الذي يعبر عن هذه العملية يختلف عن النموذج الأصلي إذ يجب إن يتضمن هذه الفروق التي أجريت على السلسلة ، إن النماذج التي تمثل السلسلة الزمنية المستقرة تدعى بالنماذج المختلطة المتكاملة (ARIMA) والنموذج من الرتبة  $(p,d,q)$  يكتب بالشكل  $ARIMA(p,d,q)$  ويكون بالصيغة التالية:

$$\phi(B)(1 - B)^d X_t = \theta(B)e_t \quad (4)$$

إما نماذج  $ARIMA$  المضاعفة (Multiplicative ARIMA Model) فتعتبر نماذج معدلة لنموذج (ARIMA) بإضافة التأثير الموسمي ويرمز له  $ARIMA(p,d,q) \times (P,D,Q)_s$  والصيغة العامة للنموذج :

$$\phi_p(B)\phi_p^s(B^s)\nabla^d\nabla_s^D X_t = \theta_q(B)\theta_q^s e_t \quad (5)$$

حيث إن  $P$ : رتبة الانحدار الذاتي للجزء الموسمي و  $p$  رتبة الانحدار الذاتي للجزء غير الموسمي و  $Q$  رتبة الأوساط المتحركة للجزء الموسمي و  $q$  رتبة الأوساط المتحركة للجزء غير الموسمي و  $D$  درجة الفروق الموسمية و  $d$  : درجة الفرق للجزء غير الموسمي و  $s$  : طول الموسم .

طريقة بوكس جنكينز واحدة من الطرق المشهورة في التنبؤ بالسلاسل الزمنية والتي وضعت من قبل Box Jenkins عام 1976 وهذه الطريقة تحلل السلسلة الزمنية المستقرة أو غير المستقرة سواء كانت موسمية Seasonal أم غير موسمية Non-Seasonal وذلك بتطبيق نماذج هذه الطريقة وتستخدم هذه النماذج في التحليل والسيطرة والتنبؤ بالسلاسل الزمنية. تتضمن منهجية بوكس جنكينز عدد من المراحل وهي :

أ- التشخيص (Identification) [11] [1] [6]

وتشمل معرفة نوع النموذج وتحديد رتبة النموذج المحدد ويتم تحديد النموذج ودرجته من خلال سلوك دالتي الارتباط الذاتي (Auto-Correlation Function) والارتباط الذاتي الجزئي (Partial Auto-Correlation Function) والجدول الآتي يوضح سلوك كل من الدالتين :

الأنموذج	دالة الارتباط الذاتي	دالة الارتباط الذاتي الجزئي
AR(p)	تناقص أسّي	يقطع بعد p من الإزاحات
MA(q)	يقطع بعد q من الإزاحات	تناقص أسّي
ARMA(p,q)	تناقص أسّي	تناقص أسّي

جدول (1) : بوضوح سلوك دالتي الارتباط الذاتي والارتباط الذاتي الجزئي

وكذلك يمكن تحديد النموذج والرتبة من خلال مطابقة عدد من النماذج المقترحة واعتماد مبدأ التجربة والخطأ وبالتالي اختيار النموذج الأفضل وهناك عدة معايير للتحقق من دقة النموذج مقارنة بالنماذج المقترحة والنموذج الأفضل الذي يأخذ أقل قيمة لكل من المعايير الإحصائية ومنها :

- معيار معلومة اكيكي (Akaike Information Criterion (AIC) وصيغته :  $AIC = \ln(\hat{\sigma}^2) + 2p$

- معيار شوارز (Schwarz Criterion (SBC) وصيغته :  $SBC = n \ln(\hat{\sigma}^2) + p + p \ln(n)$

- معيار بيز (Bayesian Information Criterion (BIC) وصيغته :

$$BIC(M) = n \ln \hat{\sigma}_e^2 - (n - p) \ln \left( 1 - \frac{p}{n} \right) + p \ln n + M \ln \left[ \frac{\hat{\sigma}_x^2}{\hat{\sigma}_e^2} - 1/p \right]$$

- متوسط مربع الخطأ (Mean Square Error (MSE) وصيغته :  $MSE = \frac{1}{n} \sum_{t=1}^n a_t^2$

- متوسط مطلق الخطأ (Mean Absolute Error (MAE) وصيغته :  $MAE = \frac{1}{n} \sum_{t=1}^n |a_t|$

-متوسط مطلق الخطأ النسبي (Mean Absolute Percentage Error (MAPE) وصيغته :

$$MAEP = \frac{1}{n} \sum_{t=1}^n |pe_t|$$

حيث إن :  $pe_t$  : يمثل نسبة الاخطاء (Percentage Error) ويحسب كالآتي :  $pe_t = \left( \frac{X_t - e_t}{X_t} \right) * 100$

و  $X_t$  مشاهدات السلسلة الزمنية و  $n$  : حجم عينة الاخطاء و  $p$  : رتبة النموذج و  $\hat{\sigma}^2$  : تقدير تباين الخطأ و  $a_t$  : سلسلة الأخطاء

ب-التقدير (Estimation) [4] [10]

بعد تحديد النموذج الملائم يتم تقدير معلماته باستخدام إحدى طرائق التقدير التامة أو التقريبية والتي تختلف بحسب النموذج المستخدم وهي: وطريقة الإمكان الأعظم التقريبية Maximum Likelihood method (EML) Approximate في حالة كون العينة كبيرة فإن لو غارتيم الإمكان الأعظم لنموذج ARMA(p,q) يكون بالصيغة الآتية :

$$LnL = -\frac{n}{2} Ln(2\pi\sigma_e^2) - \left[ \frac{s(\phi, \theta)}{2\sigma_e^2} \right] \quad (6)$$

إذ إن  $s(\phi, \theta) = \sum_{t=1}^n [e_t | X_t, \phi, \theta]^2 + e' \Omega^{-1} e$  هي مصفوفة التباين المشترك ل  $e_t$  وباشتقاق المعادلة (6) الى المعلمات  $\phi, \theta$  ومساوات المشتقات الى الصفر نحصل على مقدرات الامكان الاعظم التقريبية بالصيغة الآتية :

$$\hat{\beta} = (v'v)^{-1}v' \quad (7)$$

إذ إن  $\beta$  هي مصفوفة للمعلمات  $\phi, \theta$  و  $v$  هي مصفوفة تحوي على العناصر  $X_{t-i}$  و  $i = 1, 2, \dots, n$  إما طريقة المربعات الصغرى غير الخطية Non Linear Least Squares method فيتم من خلال وصف نموذج ARMA(p,q) بدلالة الأخطاء العشوائية كالاتي :

$$e_t = \theta^{-1}(B)\phi(B)X_t \quad (8)$$

وتبسيط معادلة (8) باستخدام اول حدين من متسلسلة تايلر لاجل تحويلها الى خطية في المعالم وبتخصيص قيم أولية للمعالم  $\phi, \theta$  فأذا كانت  $\beta = p + q$  عدد المعالم و  $\beta_0$  هي القيم الاولية فإن النموذج في المعادلة (8) يتحول الى نموذج خطي وفق الصيغة الآتية :

$$e_0 = w(\beta - \beta_0) + e_t \quad (9)$$

حيث إن  $w$  مصفوفة عناصرها  $w_{i,t}$  مشتقات الى المعلمات وعند القيم الأولية  $\beta_0$  و  $i = 1, 2, \dots, n$  وبأستعمال طريقة المربعات الصغرى (Ordinary Least Square) نحصل على المقدرات بالصيغة الآتية :

$$\hat{\beta}_i = \beta_0 + (w'w)^{-1}w'e_0 \quad (10)$$

حيث إن  $e_0$  متجه الاخطاء الاولية بأبعاد  $n \times 1$

ج-فحص مدى ملائمة النموذج (Diagnostic Checking) [8]

يعتمد الاختبار على سلسلة البواقي (Residuals) فإذا كانت معاملات دالة الارتباط الذاتي للبواقي واقعة ضمن حدي الثقة بمستوى ثقة معين فهذا يعني بان بواقي النموذج عشوائية وبالتالي فان النموذج المشخص يكون ملائماً وكذلك يمكن استعمال اختبار (Ljung – Box) الذي يعتمد إحصائية (Q) لمعرفة ملائمة النموذج ويكون بالصيغة الآتية :

$$Q = n(n + 2) \sum_{k=1}^m \frac{1}{n-k} r_k^2(\hat{a}) \sim \chi^2 (m - p) \quad (11)$$

وتقارن قيمة (Q) المحسوبة مع قيمة ( $\chi^2$ ) الجدولية بدرجة حرية (m-p) وبمستوى معنوية ( $\alpha$ ) معين فإذا كانت قيمة (Q) المحسوبة اصغر من القيمة الجدولية فإن النموذج يعتبر أنموذجاً ملائماً

د-التنبؤ (Forecasting) [7]

يعد التنبؤ الخطوة المهمة في نمذجة السلاسل الزمنية فهو عبارة عن التكهّن بالقيم المستقبلية للسلسلة الزمنية المدروسة كما يعد العملية الجوهرية في دراسة الخطط المستقبلية والسيطرة عليها وهناك طريقتان أساسيتان للتنبؤ بالسلاسل الزمنية حسب طريقة بوكس وجنكيز (Box&Jenkins) هما الإسقاط الذاتي (self-projecting) وطريقة السبب والتأثير (cause-and-Effect Approach) و الصيغة التالية هي الصيغة العامة للتنبؤ:

$$E(X_{t+h}) = \hat{X}_t = \phi_1 E(X_{t+h-1}) + \phi_2 E(X_{t+h-2}) + \dots + \phi_{p+q} E(X_{t+h-p=d}) - \theta_1 E(e_{t+h-1}) - \theta_2 E(e_{t+h-2}) - \dots - \theta_q E(e_{t+h-q}) + E(e_{t+h}) \quad (12)$$

محمد حبيب/دعاء عبدالكريم

#### 4- الشبكات العصبية (ANN) *Artificial Neural Networks*

تعرف الشبكة العصبية الاصطناعية على أنها نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة إذ يُعد أسلوباً جديداً في تحليل البيانات وحساب التنبؤ لها ويرمز للشبكات العصبية الاصطناعية (Artificial Neural Networks) اختصاراً بالرمز (ANN).<sup>[14]</sup>

وعرف العالم ( Robert Nielsen ) الشبكات العصبية على أنها نظام حسابي متكون من عدد من وحدات المعالجة المترابطة فيما بينها وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليها.<sup>[7]</sup>

وتأتي أهمية الشبكات العصبية الاصطناعية (ANN) من قابليتها على تمثيل العلاقات الخطية وغير الخطية حيث أنها أنظمة قابلة للتعلم من خلال الأمثلة ، وهي عبارة عن معالج ضخم موزع على التوازي ومكون من وحدات معالجة بسيطة بحيث يقوم بتخزين المعلومات العملية ليجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان.<sup>[13]</sup>

تتكون الشبكة العصبية من ثلاثة مستويات ، وكل مستوى يتضمن عدداً من العقد أو العصبونات، حيث يمثل المستوى الأول المدخلات والمستوى الثاني يمثل الطبقة المخفية والمستوى الثالث يمثل المخرجات ، ويتضمن كل مستوى عدداً من العقد التي ترتبط مع بعضها من خلال الأوزان ، وإن ترتيب العصبونات في الطبقات أو المستويات، وشكل الترابطات ضمن أو بين الطبقات هو ما يدعى (بالبنية الهندسية أو معمارية) هيكلية (الشبكة العصبية).<sup>[2]</sup> وتصنف الشبكات من حيث عدد طبقاتها إلى نوعين :


#### أ- الشبكات وحيدة الطبقة (Single Layer Networks)<sup>[7]</sup> [16]

وهي الشبكات التي لاتمتلك مستوى مخفي وتتكون من طبقة واحدة من الأوزان إما وحدات الإدخال فيمكن تعريفها بأنها الوحدات التي تستلمها من العالم الخارجي وتكون انسياب الإشارات الداخلة من طبقة المدخلات إلى طبقة المخرجات باتجاه إمامي والنموذج العام يكون كالآتي :

$$y_i = f(\sum_{i=1}^n w_{ij}x_i + b) ; j = 0,1,2, \dots, n \quad (13)$$

إذ إن  $y_i$  مخرجات الشبكة ودالة التنشيط المستعملة و  $w_{ij}$  مصفوفة الأوزان و  $x_i$  مدخلات الشبكة و  $b$  الحد الثابت ويمكن تمثيلها كالآتي:

شكل (1) : الشبكة العصبية الاصطناعية ذات الطبقة المفردة



محمد حبيب/دعاء عبدالكريم

ب- الشبكات متعددة الطبقات (Multi Layer Network) [6] [16]

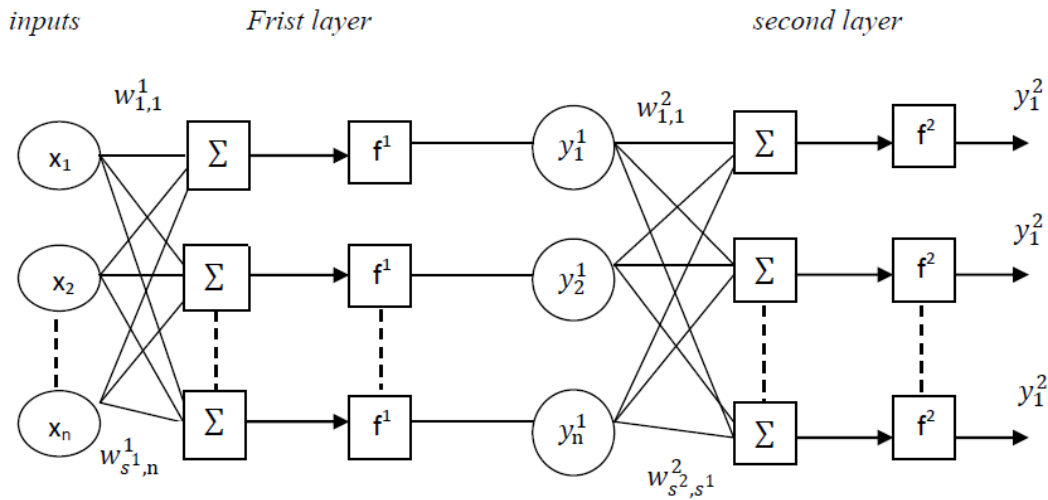
وتتكون هذه الشبكات من طبقة واحد أو أكثر من الطبقات المخفية (Hidden Layer) فضلاً عن طبقة المدخلات وطبقة المخرجات ، وتتميز هذه الشبكات بحل مشاكل أكثر تعقيداً من تلك التي تحلها الشبكات وحيدة الطبقة وذلك بسبب وجود الطبقات المخفية التي تعطي مرونة أكثر في بناء الدوال الناقلية بين المدخلات والمخرجات والنموذج العام يكون كالآتي:

$$y^{m+1} = f^{m+1}(w^{m+1}x^m + b^{m+1}) ; m = 1,2, \dots, M \quad (14)$$

إذ أن :  $M$  : عدد الطبقات في الشبكة و  $f^{m+1}$  : دالة التنشيط المستعملة للطبقة  $m+1$  و  $y^{m+1}$  : متجه المخرجات للطبقة  $m+1$  و  $b^{m+1}$  : متجه الحد المطلق (bias) للطبقة  $m+1$  و  $w^{m+1}$  : مصفوفة أوزان الطبقة  $m+1$  و  $x^m$  : متجه مدخلات الشبكة للطبقة  $m$

ويمكن تمثيلها بالشكل الآتي :

شكل (2) : الشبكة العصبية الاصطناعية متعددة الطبقات



5- تدريب الشبكات العصبية الاصطناعية (Artificial Neural Network Training) [12]

تعد عملية التدريب اساساً لأداء إي عملية من عمليات الشبكات العصبية ، والتدريب هو عملية اكتساب المعرفة من مجموعة من البيانات وخلال عملية التعلم تقوم الشبكة العصبية الاصطناعية بتعديل وضبط الأوزان وان عملية التدريب تعطي للشبكة العصبية القدرة على التعلم وبالتالي الوصول إلى المخرجات بأقل خطأ ممكن ، حيث إن الشبكة العصبية تتعلم عن طريق وسائل معينة تغير قوة الربط الداخلي وهذا ما يدعى بتعديل الأوزان ، ويحدث خلال مرحلة تسمى عملية التعلم ، ومجموعة الإدخال الخارجي تسمى مجموعة التدريب للشبكة ، أو عينة التدريب ، وهناك طريقتان لتدريب الشبكة العصبية هما :

أ- التعليم غير المراقب (Unsupervised Learning of ANN) [7] [12]

تحدث عملية تعلم الشبكة بلا إشراف لان هذا النوع من التعلم لا يحتاج إلى مخرجات مطلوبة أي لا يحدد مسبقاً مقدار المخرجات وتستعمل في الشبكات الأحادية والمتعددة الطبقات .

وفي هذه الطريقة يتم تعديل أوزان الشبكة بشكل إلي واستخلاص الخصائص الموجودة في الإشارات الداخلة وتجميعها على شكل مجموعات عن طريق تقوية أوزان الخلايا التي تستجيب تجاه خاصية معينة من الخصائص التي تحملها البيانات الداخلة وجعلها تتخصص بتمييز هذه الخاصية أكثر من بقية الخلايا التي سوف تجري تقويتها وصيغة تعديل الأوزان تكون كالآتي :

$$w^{new} = w^{old} + y x^T \quad (15)$$

وان  $y = [y_1 \ y_2 \dots \dots \dots y_n]$  متجه المخرجات

ب- التعليم المراقب (*Supervised Learning of ANN*) [7] [12] [2]

إن عملية تعلم أو تدريب الشبكة العصبية الاصطناعية تبدأ بإدخال البيانات إلى الشبكة على هيئة متجه (Exemplars) يتكون من جزئين ، يمثل الجزء الأول مجموعة المتغيرات التوضيحية ، إما الجزء الثاني فيمثل قيم المتغيرات المعتمدة (Criterion Section) ، ثم تتدرب الشبكة على البيانات ونتيجة التدريب نحصل على الأوزان المثلى التي تعطي أفضل تقدير لقيم المعيار وهي تمثل مخرجات الشبكة العصبية

ثم يتم مقارنة هذه المخرجات المولدة بواسطة الشبكة مع مخرجات الهدف (المتغيرات المعتمدة) لنحصل على الخطأ (خطأ التدريب) (Training Error) الذي يمثل الفرق بين مخرجات الشبكة الحقيقية وقيم مخرجات الشبكة المرغوب فيها ويستخدم كأساس في عملية تعديل أو تحديث أوزان الشبكة . إن هدف تدريب الشبكة العصبية الاصطناعية على البيانات ، هو الحصول على أقل خطأ تدريب وبالنتيجة نحصل على الأوزان المثلى التي يتم اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتعلم وصيغة تعديل الأوزان تكون كالآتي :

$$w^{new} = w^{old} + t x^T \quad (16)$$

إذ أن :  $t = [t_1 \ t_2 \dots \dots \dots t_n]$  متجه مخرجات الهدف  
 $x^T = [x_1 \ x_2 \dots \dots \dots x_n]$  متجه متغيرات الإدخال

5-خوارزمية الانتشار الخلفي *Back Propagation algorithm (BP)* [5]

وهي من الخوارزميات المشهورة في التعليم الموجه وتسمى أيضا بخوارزمية قاعدة دلتا العامة Generalized Delta Rule) التي تمثل الطريقة القياسية في تدريب الشبكة العصبية الاصطناعية وهذه الطريقة الشائعة تعمل على تقليل الخطأ وهي متوسطات المربعات الصغرى القياسية (LMS) وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم وتستخدم هذه الخوارزمية لتعليم الشبكات متعددة الطبقات أن تدريب الشبكة العصبية الاصطناعية باستعمال الانتشار العكسي يتضمن ثلاث مراحل وكالآتي:

- مرحلة الانتشار الأمامي للخطأ.
- مرحلة الانتشار الخلفي للخطأ .
- مرحلة تحديث أوزان الشبكة

يمكن تلخيص عمل الانتشار العكسي للخطأ من خلال الخطوات الآتية [2] [6] [12]

أ- جمع ومعالجة البيانات :

تجمع البيانات بحيث تمثل المشكلة تمثيلاً جيداً وكذلك تتضمن هذه المرحلة معالجة البيانات بصورة أولية وصيغة التعديل تكون بالشكل الآتي :

$$X_{new} = \frac{X - \bar{X}}{S} \quad (17)$$

حيث أن:  $\bar{X}$  : متوسط المتغير و  $S$  : الانحراف المعياري  
وهناك صيغة أخرى للتعديل تكون بالشكل الآتي

$$X_{new} = \frac{2(X - X_{min})}{X_{max} - X_{min}} - 1 \quad (18)$$

ويوجد تعديل على هذه الصيغة يتمثل بإضافة أو طرح قيمة صغيرة ويكون ( $\epsilon > 0$ ) وأفضل قيمة أولية له (0.02) إذ تضمن أن تكون البيانات الناتجة تقع ما بين (-1,1) وكما يلي:

$$X_{new} = \frac{2\{X - (X_{min} - \epsilon)\}}{\{(X_{max} + \epsilon) - (X_{min} - \epsilon)\}} - 1 \quad (19)$$

فضلاً عن تحديد كيفية تجزئة السلسلة إلى مجموعة التعليم (training set) ومجموعة اختبار (test set) ومجموعة تقويم (validation set)



لتحديد معمارية الشبكة يتم اختيار متغيرات الإدخال الذي يساوي عدد المتغيرات المستقلة كما إن عدد المتغيرات في نموذج السلاسل الزمنية يعتمد على الصيغة الموصوفة بدلالة المتغيرات المزاحة وكذلك يتم تحديد عدد العقد في الطبقة المخفية من خلال الاعتماد على معايير الأخطاء (MSE, MAE, MAPE, AIC, BIC, SBE) في تحديد عدد العقد في الطبقة المخفية ويفضل الأنموذج الذي يمتلك أقل قيمة لهذه المعايير والتي تعطى بالصيغ الآتية :

$$AIC = nk \ln(\hat{\sigma}^2) + 2s$$

$$BIC(M) = nk \ln \hat{\sigma}_e^2 - (n - s) \ln \left(1 - \frac{s}{n}\right) + s \ln n + s \ln \left[\frac{\hat{\sigma}_x^2}{\hat{\sigma}_e^2} - 1/s\right]$$

$$SBC = nk \ln(\hat{\sigma}^2) + s \ln(n)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$$

$$MAEP = \frac{1}{n} \sum_{t=1}^n |pe_t|$$

إذ أن:  $n$  : عدد بيانات التقدير و  $k$  : عدد عقد الإخراج و  $s$  : عدد المعالم في الأنموذج

إما بالنسبة إلى عقد الإخراج فعقدة واحدة كافية للتنبؤ بخطوة واحدة ولتحديد دالة التنشيط يمكن استعمال إحدى الصيغ الآتية :

$$a = n$$

**الدالة الخطية Linear function**: صيغة هذه الدالة توصف كالآتي :

**الدالة اللوجستية Log- sigmoid function**: صيغة هذه الدالة توصف كالآتي :

$$f(n) = \left(1 + e^{-\frac{n}{T}}\right)^{-1} \quad (20)$$

**الدالة اللوجستية ثنائية القطب Hyperbolic tangent function** صيغة هذه الدالة توصف كالآتي :

$$f(n) = 1 - 2(1 + e^{2n/T})^{-1} \quad (21)$$

إذ إن  $n$  مدخلات الشبكة و  $T$  معلمة افتراضية

ج- التدريب :

يتم تعليم النموذج من خلال إيجاد مجموعة من الأوزان بين العصبونات التي تحدد أقل قيمة لمربع الخطأ بالاعتماد على خوارزمية الانتشار الخلفي (BP) و يتم إختيار قيم عشوائية صغيرة للأوزان والحد المطلق تقع ما بين (-1, 1) ومن العوامل التي تؤثر على كفاءة التدريب في الشبكات العصبية

- **معامل التعلم ( $\alpha$ )** : يعتبر معامل التعلم من العوامل المؤثرة على عملية تحديث الأوزان في الشبكة العصبية إذ إن معدل التعلم يحدد مقدار تغير الوزن وإن قيمة معدل التعلم  $0 < \alpha < 1$

- **معامل الزخم ( $\gamma$ )** : هو من العوامل المهمة الذي يجعل عملية التعلم متزنة و يجعل مقدار التغير في الوزن متزن و مستقر نسبياً وإن قيمة عامل الزخم تكون  $(0 \leq \gamma < 1)$

- **عامل عدد المتجهات في الشبكة العصبية** : إذا كان عدد المتجهات مناسباً فإن الشبكة العصبية بإمكانها استخلاص أنموذج يمثل البيانات، أما إذا كانت مدخلات الشبكة على درجة من التعقيد فيجب زيادة عدد المتجهات لكي تتعلم الشبكة على سلوك البيانات

- **عامل عدد العقد المخفية**: أفضل طريقة في تحديد عدد العقد المخفية في الشبكة العصبية هو اختيار عدد قليل من العقد المخفية عند البدء بتدريب الشبكة العصبية ثم ملاحظة النتائج و بعدها نبدأ بزيادة العقد المخفية إلى أن نصل إلى أقل خطأ.

- **عامل عدد المستويات المخفية** : هو من العوامل المهمة في كفاءة تدريب الشبكة العصبية، إذ يبدأ تدريب الشبكة العصبية بمستوى مخفي واحد و تستمر عملية التدريب أو التعلم على صفات بيانات الشبكة العصبية، إلى أن نصل إلى أقل خطأ ممكن

د : التنفيذ

وهي من أهم الخطوات التي تختبر فيها الشبكة من حيث قدرة التكيف مع حالة التغير في الدورة وإمكانية إعادة التدريب والوصول إلى أقل خطأ عند تغير البيانات وتعتمد على البرنامج المستعمل لنمذجة الشبكات العصبية.

6- خوارزمية *Levenberg- Marquardt* [6]

هذه الطريقة هي لتعديل الانتشار الأمامي في خوارزمية الانتشار الخلفي (BP) للحصول على الحل بأقل مدة زمنية وبأقل عدد من التكرارات وإن خوارزمية (L- M) تعمل على تصغير دالة مجموع مربعات الأخطاء (SSE) للدوال غير الخطية صيغة خوارزمية (L- M) والتي توصف :

$$x_{k+1} = x_k - [J^T(x_k)J(x_k) + \mu I]^{-1} \cdot J^T(x_k)V(x_k) \quad (22)$$

أو تكتب

$$\nabla x_k = x_{k+1} - x_k$$

حيث أن  $J(x_k)$  : عبارة عن مصفوفة لمشتقات دالة الأخطاء بالنسبة للأوزان والحد المطلق و  $V(x_k)$  : دالة الخطأ

7- الشبكة العصبية والتنبؤ بالسلاسل الزمنية [13] [15]

الشبكات العصبية الذكية يمكن استخدامها لنمذجة أي علاقة ما بين متغيرات المدخلات والمخرجات ومنها النماذج الخاصة بالسلاسل الزمنية . فالسلسلة الزمنية تتكون من عدد من المشاهدات  $(X_1, X_2, X_3, \dots, X_t)$  حيث  $t$  تشير إلى الزمن في تحليل السلاسل الزمنية وهناك معالجة للبيانات المولدة والتي على أساسها يتم التنبؤ بالاعتماد على العمليات السابقة والشبكات العصبية بإمكانها السيطرة على هذه العمليات حتى بالنسبة للبيانات غير المنتظمة ونماذج التغذية الأمامية متعددة المستويات تستخدم بصورة شائعة في مجال التنبؤ وستكون المدخلات إلى الشبكة بيانات متخلفة سابقة وستكون المخرجات هي القيم المستقبلية المتنبأ بها ويمكن تمثيل هذه العلاقة كما يلي :  $X_{t+1} = f(X_t, X_{t-1}, \dots, X_{t-m})$  حيث ان  $X_t$  هي المشاهدة في الزمن  $t$  وان  $m$  عدد المشاهدات السابقة المستخدمة للتنبؤ بالسلسلة الزمنية والتي لها  $k$  من المشاهدات ويمكن استخدام شبكة عصبية لها  $n$  من المدخلات ولها مخرج واحد هو القيمة التنبؤية المستقبلية بعد تدريب الشبكة نموذج التدريب الأولي يكون ل  $(X, X_2, \dots, X_n)$  كمدخلات ويكون  $X_{n+1}$  هو الهدف ونموذج التدريب الثاني يكون  $(X_2, X_3, \dots, X_{n+1})$  كمدخلات ويكون  $X_{n+2}$  هو الهدف اما نموذج التدريب النهائي هو  $(X_{k-n}, X_{k-m+1}, \dots, X_{k-1})$  ويكون  $X_k$  هو الهدف . الهدف لعملية التدريب هو إيجاد الأوزان التي تعمل على تخفيض مجموع مربعات الخطأ ما بين المخرجات المقدره والحقيقية إلى أقل ما يمكن .

8- وصف البيانات

جمعت البيانات والتي تتألف من سلسلة زمنية شهرية مكونة من (96) مشاهدة تمثل مقدار استهلاك الطاقة الكهربائية في محافظة القادسية والمقدرة بالميكواط / ساعة وللفترة من كانون الثاني (2005) إلى كانون الأول (2012) بقيمة عليا مقدارها (1500) وقيمة دنيا مقدارها (497.5) ومتوسط (1029) وبأنحراف معياري (234.9) كما موضحة في الجدول الآتي :

جدول (2) : قيم الاستهلاك الشهري للطاقة الكهربائية في محافظة القادسية للفترة (2005-2012)


2012	2011	2010	2009	2008	2007	2006	2005	
1500	1350	1275	1225	1125	850	1000	725	كانون الثاني
1425	1275	1200	1125	1050	998.75	972.5	650	شباط
1250	1167.5	975	1000	997.5	825	800	525	آذار
1225	967.5	1001	975	800	812.5	740	535	نيسان
1445	1167.5	1035	1050	925	995	900	600	أيار
1475	1301.3	1222.5	1187.5	1025	1035	925	745	حزيران
1500	1337.5	1250.8	1200	1112.5	1057.5	992.5	750	تموز
1500	1197.5	1195	1025	1087.5	1000	997.5	750	أب
1350	945	1075	925	825	850	800	690	أيلول
1245	975	972.5	836.25	900	900	600	514.25	تشرين الأول
1125	1217.5	1350	1050	1012.5	1007.5	900	497.5	تشرين الثاني
1325	1337.5	1242.5	1150	1075	1052.5	972.5	745	كانون الأول

محمد حبيب/دعاء عبدالكريم

### 9-نموذج بوكس- جنكينز لتحليل السلسلة الزمنية


أن أولى الخطوات التي تتبع لتحليل السلسلة الزمنية هي رسمها لمعرفة الاتجاه العام والموسمية والشكل رقم (3) يوضح المخطط البياني للسلسلة الزمنية والتي تمثل استهلاك كمية الطاقة الكهربائية في محافظة القادسية

شكل (3) : الرسم البياني لسلسلة استهلاك الطاقة الكهربائية في محافظة القادسية



وقد تم رسم دالتي الارتباط الذاتي لمشاهدات سلسلة استهلاك الطاقة الكهربائية كما في الشكل رقم (4) حيث تبين وجود اتجاه عام متزايد مع الزمن فضلا عن وجود تذبذبات في السلسلة وهذه التذبذبات تتكرر بانتظام مما يدل على وجود تأثيرات موسمية وبذلك يمكن القول بأن السلسلة غير مستقرة في المتوسط والتباين

شكل رقم (4) : معاملات الارتباط الذاتي لبيانات السلسلة الزمنية




ولغرض الحصول على الاستقرار في التباين تم معالجة البيانات باستخدام التحويل اللوغاريتمي وكذلك تم اخذ الفرق الأول للتحويل اللوغاريتمي لتثبيت متوسط السلسلة ولغرض تحقيق الاستقرار الموسمية يتم بأخذ الفروقات الموسمية ولمعرفة الفرق الموسمي المناسب تم إجراء اختبار كريسكال واليس (KW) تبين إن السلسلة الزمنية غير مستقرة عند الفرق الموسمي الأول من الدرجة (6) إذ إن قيمة اختبار كريسكال واليس  $KW = 12.246$  أكبر من قيمة  $\chi^2_{(0.05,5)} = 11.070$  وكذلك بينت النتائج إن السلسلة الزمنية تصبح مستقرة عند الفرق الموسمي الأول من الدرجة (12) إذ إن قيمة اختبار  $KW = 9.514$  أقل من قيمة


محمد حبيب/دعاء عبدالكريم

ويمكن إن نلاحظ الاستقرارية من خلال الشكل (5) والشكل رقم (6) الذي يبين معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي للسلسلة المستقرة على التوالي وبذلك أصبحت السلسلة الزمنية جاهزة للتعرف على الأنموذج

شكل (5): معاملات الارتباط الذاتي للسلسلة المستقرة



شكل (6): معاملات الارتباط الذاتي الجزئي للسلسلة المستقرة



من خلال دراسة وتحليل دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) للسلسلة الزمنية المستقرة والمبينة في الشكلين رقم (4) ورقم (5) على التوالي ويمكن الاستنتاج بشكل أولي بأن النموذج الملائم لتمثيل سلسلة استهلاك الطاقة الكهربائية هو النموذج الموسمي المضاعف  $SARIMA(2,1,1)X(2,1,1)_{12}$  وكذلك تم استخراج تقديرات معالم النموذج ولزيادة دقة تشخيص النموذج تم ترشيح عدد من النماذج القريبة من النموذج المشخص كما موضحة في الجدول الآتي :

**مجلة القادسية لعلوم الحاسوب والرياضيات المجلد (٦) العدد (١)  
السنة (٢٠١٤)**

محمد حبيب/دعاء عبدالكريم


جدول (3): نماذج بوكس - جنكز المقترحة لسلسلة استهلاك الطاقة الكهربائية

النموذج المقترح	المعلمة	تقدير المعلمة	MSE	MAE	MAPE	AIC	SBE	BIC
1- (2,1,1)x (2,1,1) <sub>12</sub>	AR(1)	0.311413	0.0163	0.0960	25.092	-337.5	-332	-306.8
	AR(2)	-0.16566						
	MA(1)	-0.649199						
	SAR(12)	-0.698791						
	SAR(13)	-0.904833						
	SMA(12)	-0.521104						
2- (2,1,0)x (2,1,1) <sub>12</sub>	AR(1)	-0.544135	0.0173	0.0975	25.581	-332	-319	-311
	AR(2)	-0.37194						
	SAR(12)	-0.690657						
	SAR(13)	-0.154461						
	SMA(12)	-0.415948						
3- (2,1,1)x (2,1,0) <sub>12</sub>	AR(1)	-0.145322	0.0181	0.1023	28.842	-329	-319	-269.8
	AR(2)	-0.165147						
	MA(1)	-0.517896						
	SAR(12)	-0.790897						
	SAR(13)	-0.0107877						
4- (2,1,0)x (1,1,0) <sub>12</sub>	AR(1)	-0.589756	0.0187	0.1035	29.341	-326	-321	-301.7
	AR(2)	-0.357475						
	SAR(12)	-0.813595						
5- (0,1,0)x (2,1,1) <sub>12</sub>	SAR(12)	-0.731271	0.0231	0.1132	28.981	-312.7	-303	-298.4
	SAR(13)	-0.204495						
	SMA(12)	-0.566781						
6- (0,1,1)x (1,1,0) <sub>12</sub>	MA(1)	-0.6931	0.0182	0.1007	29.657	-332.5	-328	-291
	SAR(12)	-0.795065						

ومن ملاحظة الجدول تبين إن النموذج SARIMA(2,1,1)x(2,1,1)<sub>12</sub> هو الأفضل من ناحية التقدير حيث نلاحظ إن المعالم تختلف معنويًا عن الصفر كما إن هناك انخفاض في قيم المعايير الإحصائية ولمعرفة مدى ملائمة النموذج تم رسم معاملات الارتباط الذاتي والارتباط الذاتي للأخطاء كما موضحة في الأشكال رقم (7) ورقم (8) حيث يلاحظ إن جميع معاملات الارتباط الذاتي للبقايا تقع ضمن حدود الثقة [-0.22, 0.22] وبتطبيق إحصائية Ljung & Box لفحص مدى ملائمة النموذج تبين إن


$$LBQ = (6.2714) < \chi^2_{(0.05,3)} = (7.8147)$$

مما يدل إن سلسلة البقاي عشوائية وإن النموذج جيد وملائم  
شكل رقم (7) : معاملات الارتباط الذاتي للبقاي



شكل رقم (8) : معاملات الارتباط الذاتي الجزئي للبقاي

محمد حبيب/دعاء عبدالكريم



إما التنبؤ هو المرحلة الأخيرة من مراحل تحليل السلاسل الزمنية باستخدام أسلوب بوكس جنكينز وهو الهدف النهائي من تحليل السلاسل الزمنية والجدول الآتي يعطي التنبؤات المستقبلية لأشهر سنة (2013) لسلسلة استهلاك الطاقة الكهربائية لمحافظة القادسية وقد تم الحصول على هذه التنبؤات باستخدام النموذج  $ARIMA(2,1,1)X(2,1,1)_{12}$

جدول (4): القيم المتنبأ بها وفق منهجية بوكس – جنكينز لسلسلة استهلاك الطاقة الكهربائية

السنة	قيم التنبؤ
كانون الثاني	1471.208
شباط	1561.819
آذار	1553.354
نيسان	1459.959
أيار	1457.696
حزيران	1542.826
تموز	1661.663
أب	1710.124
أيلول	1680.342
تشرين الأول	1598.474
تشرين الثاني	1574.296
كانون الأول	1773.029

## 10- نماذج الشبكات العصبية لتحليل السلسلة الزمنية

إن أولى الخطوات لتحليل الشبكات العصبية هو تحديد المدخلان إذ تم اختيار متغيرات الإدخال لمشاهدات السلسلة الزمنية لاستهلاك الطاقة الكهربائية من  $(X_{t-1})$  إلى  $(X_{t-13})$  والمتغيرات المتداخلة بينهما فضلا عن وجود وحدة إدخال الثابت (bais) المرتبطة مع عقد الطبقة المخفية ومع عقدة الإخراج ، حيث صممت شبكة ذات انتشار عكسي (Back propagation) متعددة الطبقات تتألف من طبقة إدخال وطبقة مخفية واحدة وطبقة إخراج بعقدة واحدة ، واستعملت المقاييس  $MSE, MAE, MAPE, AIC, BIC, SBE$  لتحديد عدد العقد في الطبقة المخفية حيث تبدأ برقم صغير ثم يزداد بالتدريج لحين الحصول على العدد الملائم وتحديد نتائج التدريب .

وتم تجزئة بيانات السلسلة الزمنية بنسبة (80%) للتدريب و (20%) للاختبار وبالنظر لكون مدخلات الشبكة بيانات صحيحة واكبر من واحد لذلك تم تحويلها إلى بيانات حقيقية وذلك بأستعمال الصيغة المعيارية وبقيم أولية وعشوائية للأوزان إما دوال التنشيط المستعملة فهي الدالة اللوجستية (Logistic function) للطبقة المخفية والدالة الخطية (Linear function) لطبقة الإخراج وان تقدير الأوزان في الشبكة يكون عبر تصغير مجموع الأخطاء للنموذج بتكرار معين خلال مرحلة التدريب فقد تم استعمال خوارزمية الانتشار العكسي للخطأ للتدريب واستعملت طريقة (Levenberg-Marquardt) كطريقة تكرارية للوصول

**مجلة القادسية لعلوم الحاسوب والرياضيات المجلد (٦) العدد (١)  
السنة (٢٠١٤)**

محمد حبيب/دعاء عبدالكريم

إلى النموذج الأمثل وقد أخذت عدة نماذج للشبكات العصبية بمتغيرات إدخال مزاحة مع الزمن والجدول الآتي يوضح هذه النماذج :

جدول (5): نماذج الشبكات العصبية المقترحة لسلسلة استهلاك الطاقة الكهربائية

النموذج المقترح	عدد العقد في الطبقة المخفية	عدد المعالم	MSE	MAE	MAPE	AIC	BIC	SBE
1- NN(1,12)	2	9	0.0148	0.0728	20.839	-319	-309	-310
	4	17	0.0153	0.0905	22.456	-358	-283	-292
	8	33	0.0158	0.0617	22.083	-321	-225	-238
	12	49	0.0145	0.0615	20.113	-291	-270	-288
2- NN(1,2,12)	2	11	0.0150	0.0801	20.558	-310	-299	-307
	4	21	0.0141	0.0833	21.923	-315	-302	-295
	8	41	0.0140	0.0647	20.012	-293	-262	-279
	12	61	0.0137	0.0573	23.105	-368	-201	-207
3- NN(1,2,12,13)	2	13	0.0145	0.0654	20.231	-323	-301	-304
	4	25	0.0155	0.0732	23.245	-318	-268	-283
	8	49	0.0144	0.0601	19.921	-287	-266	-280
	12	73	0.0132	0.0521	22.053	-358	-173	-197
4- NN(1-13)	2	31	0.0158	0.0742	20.728	-263	-234	-241
	4	61	0.0132	0.0631	23.348	-301	-223	-257
	8	121	0.0122	0.0421	20.214	-218	-154	-164
	12	181	0.0103	0.0297	17.934	-104	-98	-105

ومن خلال ملاحظة تحليل نماذج الشبكات العصبية لسلسلة استهلاك الطاقة الكهربائية نجد إن المعايير الإحصائية لم تكشف الفروقات بين النماذج بصورة واضحة مما يثبت إن بعض متغيرات الإدخال ذات أهمية قليلة في التحليل .  
ولتحديد متغيرات الإدخال بصورة دقيقة يتم من خلال بناء أنموذج الشبكات العصبية للمتغيرات المزاحة  $(y_{t-1})$  إلى  $(y_{t-13})$  بثلاث عشر متغيراً وبملاحظة نماذج NN(1-13) نجد إن الأنموذج NN(1-13;12) عدد المعالم فيه (181) وكذلك الأنموذج NN(1-13;4) عدد المعالم فيه (61) وبسبب هذا العدد الكبير من المعالم فإن عملية التدريب تؤدي إلى الحصول على تقدير جيد للمعالم ولكنه ليس الأفضل من ناحية التنبؤ ولذلك سوف يتم الاعتماد على المعايير الإحصائية BIC, SBE وبهذا تم حساب ووصف الأوزان للنموذج NN(1-13;2) وكما مبين في الجدول الآتي :

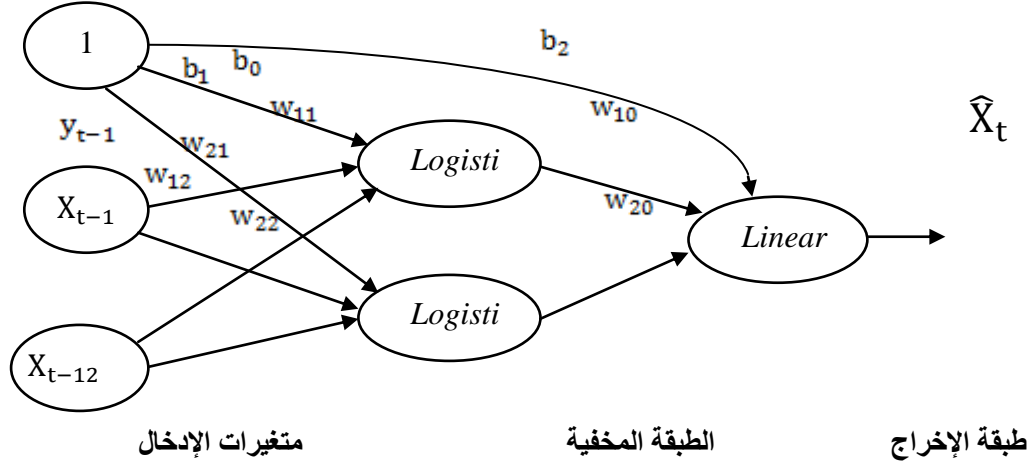
جدول (6) : أوزان الشبكة NN(1-13;2)

العقدة الأولى	الأوزان	العقدة الثانية	الأوزان
1	0.731	1	0.583
2	-0.233	2	0.058
3	-0.324	3	-0.073
4	-0.093	4	0.048
5	-0.423	5	0.042
6	0.324	6	-0.051
7	-0.247	7	0.063
8	-0.342	8	-0.023
9	-0.229	9	-0.019
10	0.528	10	0.108
11	-0.231	11	-0.173
12	0.208	12	0.372
13	0.194	13	-0.271

مجلة القادسية لعلوم الحاسوب والرياضيات المجلد (٦) العدد (١)  
السنة (٢٠١٤)

محمد حبيب/دعاء عبدالكريم

نلاحظ إن الأوزان التي تربط المدخلان بالعقدة المخفية الثانية من الإزاحة (2-11) قيم قريبة من الصفر وهذا يدل على عدم أهميتها وهذا التحليل يوضح إن تحديد عقدتان في الطبقة المخفية كافي للحصول على نموذج جيد وملائم لتمثيل كمية استهلاك الطاقة الكهربائية لذلك يمكن اعتماد النموذج NN(1,12;2) بالمتغيرات ( $X_{t-1}$ ) و ( $X_{t-13}$ ) وبعتدين للطبقة المخفية ويمكن تمثيل هذه الشبكة بالشكل الآتي حيث إن القيمة التنبؤية ( $\hat{X}_t$ ) تمثل مخرجات الشبكة العصبية NN(1,12;2) : يوضح الشبكة العصبية



ويمكن وصف الأنموذج NN(1,12;2) وبدوال التنشيط اللوجستية للطبقة المخفية ودالة إخراج خطية كالآتي :  

$$\hat{X}_t = b^2 + w_1^2 \left\{ (1 + \exp(-b_1^1 - \sum_{j=1}^R w_{1j}^1 \cdot a_j))^{-1} \right\} + w_2^2 \left\{ (1 + \exp(-b_2^1 - \sum_{j=1}^R w_{2j}^1 \cdot a_j))^{-1} \right\}$$
 وإن قيمة المعلمة (T=1) في دالة التنشيط اللوجستية و  $a_j$  مخرجات الحد الثابت (bias) ولأجل الحصول على متكهن الشبكة العصبية (التكهن لخطوة واحدة إلى الإمام) لسلسلة استهلاك الطاقة الكهربائية في محافظة القادسية لأشهر سنة (2013) تم تدريب واختبار الشبكة NN(1,12;2) التي عدت أفضل شبكة من بين الشبكات الأخرى والنتائج موضحة في الجدول الآتي :

جدول (7): القيم المتنبأ بها باستخدام نموذج الشبكة العصبية NN(1,12;2)

السنة	قيم التنبؤ
كانون الثاني	1588.486
شباط	1545.996
أذار	1372.878
نيسان	1353.762
أيار	1508.084
حزيران	1586.939
تموز	1595.189
أب	1589.162
أيلول	1585.085
تشرين الأول	1573.478
تشرين الثاني	1571.177
كانون الأول	1595.741



### 11- مقارنة نموذج بوكس جنكينز مع نموذج الشبكات العصبية

إن منهجية بوكس - جنكينز من المنهجيات الشائعة الاستعمال ذات الكفاءة العالية في صياغة نماذج البيانات التي تنطبق عليها شروط التشخيص مع استقرارية السلسلة الزمنية  
إما منهجية الشبكات العصبية الاصطناعية فهي من الطرق الحديثة ذات الإمكانية العالية في صياغة نماذج للبيانات غير المستقرة ولإغراض المقارنة بين الطريقتين تم اعتماد المعايير الإحصائية (MSE, MAE, MAPE, AIC, BIC, SBE) لتقديم نموذج مناسب لاستهلاك الطاقة الكهربائية في محافظة القادسية وقد تم اعتماد نموذج الشبكات العصبية NN(1,12;2) ونموذج السلاسل الزمنية ARIMA(2,1,1)X(2,1,1)<sub>12</sub> لسلسلة استهلاك الطاقة الكهربائية في محافظة القادسية وكما في الجدول الآتي :

جدول (8): المقارنة بين نموذج بوكس - جنكينز ونموذج الشبكات العصبية

النموذج	MSE	MAE	MAPE	AIC	SBE	BIC
نموذج بوكس - جنكينز لاستهلاك الطاقة الكهربائية	0.0163	0.0960	25.431	-337.5	-332	-302.8
نموذج الشبكات العصبية لاستهلاك الطاقة الكهربائية	0.0148	0.0728	20.839	-319	-309	-310

ومن خلال الجدول يظهر تفوق طريقة الشبكات العصبية الاصطناعية على طريقة بوكس - جنكينز لامتلاك نموذج الشبكة العصبية الاصطناعية اقل معايير إحصائية مقارنة مع طريقة بوكس - جنكينز وبهذا يمكن القول إن طريقة الشبكات العصبية الاصطناعية أكثر ملائمة لتحليل البيانات من طريقة بوكس - جنكينز

### 12- الاستنتاجات:

- 1- يتأثر أداء نماذج بوكس جنكينز ونماذج الشبكات العصبية في التنبؤ بنمط البيانات المدخلة
- 2- تم إن أفضل نموذج للتنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نموذج بوكس جنكينز هو النموذج الموسمي المضاعف SARIMA(2,1,1)X(2,1,1)<sub>12</sub> بناءً على نتائج دالتي الارتباط الذاتي والارتباط الذاتي الجزئي وبالاعتماد على معايير الإحصائية المستعملة (MSE, MAE, MAPE, AIC, BIC, SBE, FBE)
- 3- وجد إن أفضل نماذج الشبكات العصبية لاستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام شبكة الانتشار العكسي متعددة الطبقات بطبقة مخفية واحدة وبعقدتين للطبقة المخفية ومتغيرين إدخال هما  $(x_{t-1})$  و  $(x_{t-12})$  وبأستخدام دالة التنشيط اللوجستية (Logistic function) للطبقة المخفية والدالة الخطية (Linear function) لطبقة الإخراج
- 4- من خلال تحليل معايير الخطأ المطبقة وجد إن النموذج المطبق بطريقة الشبكات العصبية الاصطناعية أكثر ملائمة لتحليل البيانات من النموذج المطبق بطريقة بوكس - جنكينز لتمثيل والتنبؤ لسلسلة استهلاك الطاقة الكهربائية في محافظة القادسية

### 13- التوصيات

- 1- إجراء دراسات باستخدام شبكات عصبية أخرى غير شبكة الانتشار العكسي للخطأ ومقارنة النتائج
- 2- تعميم هذا البحث إلى دراسات مناظرة على مستوى المحافظات الأخرى وإجراء مقارنة بينهما
- 3- نوصي باعتماد النموذج الذي تم التوصل إليه في طريقة الشبكات العصبية بغية الاستفادة منها في التخطيط والتنبؤ للفترات القادمة لأنه يعطي نتائج أفضل

- ١- الجمال، زكريا يحيى؛ العمري، هيلاء انس؛ صالح، فرح عبد الغني، (2011) " استخدام بعض معايير المعلومات في تحديد أفضل نموذج موسمي مضاعف" المجلة العراقية للعلوم الإحصائية (19) ص ص [266-249]
- 2- الخياط ، باسل يونس ؛ زكي، عزة حازم ، (2005) " استخدام الشبكات العصبية في التكهّن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في مدينة الموصل " المجلة العراقية للعلوم الإحصائية (8) ، ص ص [79-63]
- 3- المحمدي ، ناظم عبد الله عبد ؛ طعمة ، سعدية عبد الكريم ، (2011) " استخدام نماذج السلاسل الزمنية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة " مجلة جامعة الانبار للعلوم الاقتصادية والإدارية ، المجلد (4) ، العدد (7) ، ص ص [43-21] .
- 4- حسن، رعد فاضل؛ رشيد، حسام عبد الرزاق؛ عكار، احمد عبد علي ، (2008) " بناء نماذج التنبؤ لاستهلاك المشتقات النفطية في العراق " مجلة القادسية للعلوم الإدارية والاقتصادية ، المجلد (14) ، العدد (3) ، ص ص [214-189]
- 5- حياوي، هيام عبد المجيد؛ طه، قصي أحمد، (2013) "دراسة سلسلة الأوراق المالية باستخدام ARIMA و ANN و PMRS " المجلة العراقية للعلوم الإحصائية (23) ص ص [188-99]
- 6- فائق ، رؤى خلدون ، (2012) " دراسة مقارنة لأسلوب الشبكات العصبية مع طرائق أخرى للتنبؤ بتصريف المياه لبعض السدود في العراق " رسالة ماجستير ، كلية الإدارة والاقتصاد/ الجامعة المستنصرية .
- 7- محمود ، أسيل سمير محمد ، (2005) "مقارنة بين طرائق تحليل وتنبؤ السلاسل الزمنية وتطبيقها على مبيعات الشركة العامة لتوزيع كهرباء بغداد" أطروحة دكتوراه ، كلية الإدارة والاقتصاد/ جامعة بغداد .
- 8-Adhikari, R. & Agrawal , K. , (2012) " **Forecasting strong seasonal time series with artificial neural networks**" Journal of Scientific & Industrial Research ,Vol. (71) , pp[657-666]
- 9- Alhadid, Samah M.,( 2011) " **Modeling Sulphur Dioxide time series Data Using Parametric and Nonparametric Classical Decomposition Methods** " Journal of Environmental Statistics, Volume( 2), Issue( 3).
- 10- Cryer, D. & Chan ,K. (2008)"**Time Series Analysis With Applications in R**" Second Edition, Springer Science+Business Media, LLC,New York,USA .
- 11- Hamilton ,James D.,( 1994) "**Time Series Analysis**" Princeton University Press.
- 12- Kaastra,I.&Boyd,M.,(1996)"**Designing a neural network for forecasting financial and economic time series**", Neurocomputing (10),pp[215-236] .
- 13-Kihoro, J.M.; Otieno, R.O.& Wafula, C., (2004) " **SEASONAL TIME SERIES FORECASTING : A COMPARATIVE STUDY OF ARIMA AND ANN MODELS** " African Journal of Science and Technology, Vol. (5), No. (2), PP [41-49] .
- 14- Panchal, G.; Ganatra, A. & Kosta ,P.,(2010)" **Searching Most Efficient Neural Network Architecture Using Akaike's Information Criterion (AIC)** "International Journal of Computer Applications, Vol( 1) , No. (5) , pp[41-44] .
- 15- Ulama, S. & Endharta ,A.J., (2010) " **Seasonal Time Series Data Forecasting by Using Neural Networks Multiscale Autoregressive Model** "American Journal of Applied Sciences , Vol.(7) , No. (10) , pp[1372-1378] .
- 16- ZURADA ,JACEK M., (1992) " **Introduction to Artificial Neural Systems** " West Publishing Company .