



The use of the artificial neural network method and the approximate maximum potential method in diagnosing and estimating the best seasonal model for temperature in Babil

Governorate

إستعمال اسلوب الشبكات العصبية الاصطناعية وطريقة الامكان الاعظم التقريبية في تشخيص وتقدير افضل إنموذج موسمي لدرجات الحرارة في محافظة بابل

* كرار حمزة حسين علي

* ايناس عبد الحافظ محمد

Abstract: In this research, the series of daily temperatures recorded in the Babylon Governorate for the year (2020), which included (334) observations, which were obtained from the Iraqi Meteorological Authority, was analyzed using autoregressive seasonal moving averages SARIMA models and autoregressive seasonal multiple moving averages models depending on programs (Minitab 17, Matlab 2015, E-views 10) with the aim of diagnosing the best seasonal model for the time series from a set of models that have been reconciled, and then choosing the best model from these models using the comparison criteria between models (AIC, BIC, SMAIC) and then estimating The diagnosed model using the approximate maximum potential method, and then comparing this method with the artificial neural networks NARX method. It was concluded that the doubled seasonal model $ARIMA(p,q,d) \times (P,Q,D)_2$ as a representative model for the seasonal time series under study, as well as the multiple seasonal model of the rank $ARIMA(1,1,0) \times (1,2,0)_2$ as the best seasonal model for the temperature series.

It was found that the artificial neural network NARX method is better than the approximate maximum likelihood method based on the MSE standard.

المستخلص: في هذا البحث تم تحليل سلسلة درجات الحرارة اليومية المسجلة في محافظة بابل لسنة (٢٠٢٠) والتي شملت (٣٣٤) مشاهدة والتي تم الحصول عليها من هيئة الانواء الجوية العراقية باستعمل نماذج الانحدار الذاتي المتوسطات المتحركة الموسمية SARIMA ونماذج الانحدار الذاتي المتوسطات المتحركة المضاعفة الموسمية بالاعتماد على البرامج الجاهزة (Minitab 17, Matlab 2015, E-views 10) بهدف تشخيص افضل انموذج موسمي للسلسلة الزمنية من مجموعة نماذج تم توفيقها، ومن ثم اختيار افضل انموذج من هذه النماذج باستعمال معايير المقارنة بين النماذج وهي (AIC , BIC , SMAIC) ومن ثم تقدير الانموذج المشخص باستعمال طريقة الامكان الاعظم التقريبية ومن ثم المقارنة بين هذه الطريقة باسلوب الشبكات العصبية الاصطناعية NARX. وتم التوصل الى ان الانموذج الموسمي المضاعف $ARIMA(p,q,d)x(P,Q,D)_2$ كأتمودج ممثل للسلسلة الزمنية الموسمية محل الدراسة وكذلك تم تشخيص الانموذج الموسمي المضاعف من الرتبة $ARIMA(1,1,0)x(1,2,0)_2$ كأفضل انموذج موسمي لسلسلة درجات الحرارة. وقد تبين بان اسلوب الشبكات العصبية الاصطناعية NARX افضل من طريقة الامكان الاعظم التقريبية اعتماداً على معيار متوسط مربعات الخطأ MSE.

١. المقدمة : لقد شهدت العقود الأخيرة من القرن الماضي إستخداماً واسعاً لنماذج السلاسل الزمنية وبخاصة نماذج الانحدار الذاتي – الأوساط المتحركة الموسمية التي يطلق عليها إختصاراً النماذج المختلطة الموسمية المستقرة $SARMA(p,q)$ والنماذج المختلطة المتكاملة الموسمية غير المستقرة $SARIMA(p,d,q) x(P,Q,D)_S$ والنماذج المضاعفة عند الازاحة الموسمية S . وإن شرط الاستقرارية (Stationary) في المتوسط هو الأداة الرئيسة في بناء هذه النماذج. تتبنى غالبية الإدارات عند صياغة برامجها التخطيطية والتنموية تطبيقات واسعة في مجال السلاسل الزمنية وصولاً الى نتائج أكثر دقة وفاعلية، فالتقدم الذي تشهده الدول تعبير عن قدرتها في وضع الخطط السليمة لتنمية مواردها المادية والبشرية، من هنا يأتي دور السلاسل الزمنية للمساهمة في بناء الخطط والبرامج المستقبلية، ولوجود الكثير من الظواهر تتغير عبر الزمن من خلال تغير خصائصها وسماتها ومنها ما يتضمن التغيرات الموسمية والتي كانت درجات الحرارة واحدة من تلك السلاسل الزمنية التي تطلب بناء انموذج احصائي يفسر سلوك تلك الظاهرة ويعمل على تقديرها. ففي عام (٢٠١١) استخدم الباحثان (المحمدي و طعمة) نماذج السلاسل الزمنية الموسمية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة من خلال دراسة وتحليل البيانات الشهرية عن استهلاك الطاقة

الكهربائية في مدينة الفلوجة للفترة (٢٠٠٥-٢٠١٠) وتوصلا الى ان الانموذج الملائم والكفوء لتمثيل بيانات السلسلة الزمنية هو الانموذج الموسمي المضاعف من الدرجة $SARIMA(1,1,1)$ $x(0,1,1)_{12}$ وتم التنبؤ بكميات الاستهلاك الشهري للفترة من كانون الثاني ٢٠١١ ولغاية كانون الاول ٢٠١٢ ، حيث اظهرت النتائج قيما تنبؤية متناسقة مع بيانات السلسلة الاصلية. (المحمدي و طعمة، ٢٠١١) ، وفي عام (٢٠١٢) استعمل الباحث (Moreno) وآخرون عدة انواع من الشبكات العصبية الاصطناعية وتم تطبيقها على السلاسل الزمنية وهي السلاسل الزمنية متعددة الطبقات والدالة الشعاعية وانحدار الشبكة العصبية المعجم والشبكة العصبية المتكررة . واثبتنا ان اساليب الشبكات العصبية اكثر دقة في الحصول على تنبؤات حول السلاسل الزمنية . (Moreno et al , 2012) ، وفي عام (٢٠١٣) درس الباحثين (Wang et al) السلسلة الزمنية الممثلة لهطول الأمطار والتي تستند إلى مدينة Shouguang في الكتب السنوية الإحصائية لـ Shandong للفترة ١٩٩٦- ٢٠٠٩ والتي لها ارتباط ذاتي قوي بالخصائص الموسمية في السلاسل الزمنية. باستعمال منهجية الانحدار الذاتي والايواسط المتحركة الموسمية (SARIMA) وتوصلا الى ان الانموذج المستعمل هو الافضل والكأ في تقدير ظاهرة هطول الامطار. (Wang & et al, 2013) ، وفي عام (٢٠١٤) قام الباحث (لقوقي فاتح) باستعمل نماذج السلاسل الزمنية الموسمية المختلطة في تقدير سلسلة المبيعات الشهرية لمؤسسة مطاحن جديع من منتج الفرينة و النخالة في الفترة الممتدة من 2008 إلى 2012 ، و من ثم اختبار دقتها في التنبؤ بالمبيعات المستقبلية لتسع أشهر الأولى من سنة 2013 ، ليتم فيما بعد مقارنتها بالقيم الفعلية واستنتاج مدى دقة في مجال المبيعات SARIMA. حيث أظهرت النتائج تقارب بين القيم الفعلية للمبيعات والقيم التنبؤية. وفي نفس العام (٢٠١٤) قارن الباحثان (البدراي و صليو) دقة التنبؤ بين نماذج بوكس جنكز ونموذج الشبكة العصبية الاصطناعية متمثلة بشبكة FFN(feed forward Neural Network) وشبكة ايلمان و الثالثة شبكة (NARX) لبيانات تمثل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة De Belt الهولندية للاعوام من ١٩٨٣ الى ٢٠٠٩ لدقتها ، اذا بلغ عددها (٣٢٤) مشاهدة والابقاء على ١٢ مشاهدة كعينة بعدية للمقارنة بقيم التنبؤ التي يتم الحصول عليها من الانموذج ، وقد توصلا الى الشبكات العصبية الاصطناعية ذوات التغذية العكسية افضل من غيرها ومن اداء بوكس وجنكز . (البدراي و صليو ، ٢٠١٤) وفي عام (٢٠١٦) درست الباحثة (خلود) نماذج السلاسل الزمنية الموسمية SARIMA و Holt Winter و يميز بين الموسمية المضافة والمضاعفة ، وتمت المقارنة بين الطريقتين وفقاً لمعيار RMSE MSE . واطهرت النتائج تقارب الطريقتين ولكن تفوق طريقة التمهيد الاسي الثلاثي Holt winter على نماذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة الموسمية SARIMA وفقاً لمعيار RMSE. (خلود ، ٢٠١٦) ، وفي عام (٢٠١٨) استعملت الباحثة (وفاء) منهجية Box-Jenkins لحساب الدليل الموسمي لأسعار اللحوم الحمراء) الضاني، الجاموسي للتنبؤ بأسعار اللحوم ووضع السياسات الاقتصادية الزراعية وتبين أن النموذج الأمثل هو

ARIMA(0,1,2) (2,0,2) S للحم الجاموس والانموذج ARIMA(1,0,1) (1,1,1) S
 لاسعار اللحوم الكندوز والانموذج ARIMA(0,1,2) (1,0,0) S لاسعار اللحوم الضأن كما تبين
 إقبال المستهلكين على شراء اللحوم خلال شهري أكتوبر ونوفمبر في فترة الأعياد القومية وان هناك
 تقارب إلي حد ما بين القيم التنبؤية والقيم الفعلية، وتوصي الدراسة باستخدام هذه لنماذج في التنبؤ
 بالأسعار الشهرية للحوم الحمراء الضاني، الجاموسي والكندور. (وفاء ، ٢٠١٨)، وفي عام (٢٠١٩) قدم
 الباحث (Mengqing Qin) دراسة حول نماذج السلاسل الزمنية الموسمية مع تطبيقها على بيانات
 الطقس. اذ تضمنت الدراسة مفاهيم السلاسل الزمنية ، ونماذج المتوسط المتحرك الانحدار الذاتي
 المتكاملة (والمختصرة بـ ARIMA) ، وتقدير المعلمات ، وتشخيص النماذج ، والتنبؤ. تم تطبيق نماذج
 السلاسل الزمنية المدروسة على بيانات مستوى البحيرة اليومي في بحيرة بيفر (١٩٨٨-٢٠١٧) وبيانات
 درجة الحرارة القصوى اليومية في نيويورك سنترال بارك (١٨٧٠-٢٠١٧). نظراً لموسمية البيانات ،
 تم اقتراح ثلاث طرق مختلفة للنمذجة: نموذج الانحدار ، نموذج ARIMA الموسمي ونموذج ARIMA
 الموسمي المضاعف. وتمت مقارنة القيم المتوقعة لعام ٢٠١٨ مع البيانات الاصلية للسلسلة ؛ وبينت
 النتائج بأ، انموذج الانحدار هي الأفضل للتنبؤ بالقيم اليومية ، وانموذج ARIMA الموسمي المضاعف
 هوالأفضل بسبب الدقة العالية له. (Mengqing & Qin, 2019)، في عام (٢٠٢٠) استعمل
 الباحثان (Chaurasia & Pal) استخداما انموذج الانحدار وانموذج التمهيد الاسي وانموذج Holt
 winter وانموذج الانحدار الذاتي الاوساط المتحركة لغرض تقدير بيانات السلسلة الزمنية الممثلة
 لمرض COVID-19 المأخوذة من منظمة الصحة العالمية "بيانات منظمة الصحة العالمية حالات
 فيروس كورونا Covid-19 والوفيات WHO-COVID وقرارنا بين النماذج باستعمال معيار متوسط
 مربعات الخطأ وتوصلا الى ان ARIMA هو الافضل في تقدير الظاهرة وان معدل الوفيات سيزداد الى
 ٦٠٠ وفاة في يناير ٢٠٢١. (Chaurasia & Pal, 2020).

2. السلاسل الزمنية الموسمية: (Seasonal time series) : تظهر بعض السلاسل الزمنية
 نمطا للموسمية بجانب الاتجاه العام. في حين هنالك تتضمن معدلا معيناً بالإضافة الى تذبذبات عشوائية
 .وبناءً على هذه الاختلافات في تركيبات السلاسل الزمنية ظهرت عدة طرائق تنبؤية تلائم مختلف
 أنواع التذبذبات في السلاسل. ان الكثير من المتغيرات البيئية والاقتصادية والسياسية... الخ تخضع
 لانماط الموسمية حيث انها تكرر نفسها عند فترات معينة قد تكون (يوم- شهر- سنة) ، ويؤدي تجاهل
 هذا النمط في السلسلة الى زيادة تباين السلسلة عند التنبؤ ويتم اكتشاف النزعة الموسمية من خلال رسم
 البيانات (الشكل البياني) باستخدام دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF)
 تظهر التباطؤات 12,24,36, للبيانات الشهرية والتباطؤات (4,8,12 ...) للبيانات ربع سنوية
 بشكل معنوي بدلا من التباطؤات 1,2 ... اللاموسمية . وفي هذه الحالة يتم إضافة عنصر انحدار

ذاتي موسمي او عنصر متوسط متحرك موسمي او كلاهما عند الفترة الثانية عشر اذا كانت معنوية للبيانات الشهرية $AR(1)_{12}$ $MA(1)_{12}$ في النموذج .

ويتم معالجتها في طريقة (Box- Jenkins) باخذ الفروق الموسمية بالإضافة الى الفروق غير الموسمية. (رزمان ، ٢٠١٥) .

٣. نماذج السلاسل الزمنية الموسمية (Seasonal time series Models): النماذج الموسمية (Seasonal) للسلاسل الزمنية هي النماذج اللاموسمية نفسها مضافاً إليها (S) للدلالة على أن السلسلة موسمية . ويقال للسلسلة الزمنية موسمية إذا كانت تعيد نفسها بفترة زمنية ثابتة ويمكن تمييز السلاسل الموسمية المستقرة من خلال معاملات الارتباط الذاتي التي تكون معنوية لكل فترة زمنية ثابتة كأن تكون (2,4,,6,8,12,....) ولكن في حالة السلاسل غير المستقرة فالتمييز يكون صعباً لأنه يختلط مع الاتجاه العام للبيانات لذلك يجب تحويلها إلى سلاسل مستقرة أولاً ثم البحث عن الشكل الموسمي فيها. اما النماذج الملائمة لتمثيل السلاسل الزمنية الموسمية فهي : (لمحمدي و طعمة، ٢٠١١) (فاندل، والتر، 1992).

٣,١ إنموذج الانحدار الذاتي الموسمي (Seasonal Autoregressive Models)

يعد هذا الإنموذج الأكثر شيوعاً في تحليل السلاسل الزمنية الموسمية ويرمز له بالشكل SAR(P) ويتمثل بالصيغة الآتية:

$$Y_t = \Phi_{1s} Y_{t-s} + \Phi_{2s} Y_{t-2s} + \dots + \Phi_{ps} Y_{t-ps} + a_t \quad \dots (1)$$

إذ أن:

Y_{t-ps} قيم مشاهدات السلسلة الزمنية الموسمية $t=0,1,2,\dots,p$

S طول الفترة الموسمية

Φ_{ps} معاملات الانحدار الذاتي الموسمي

P درجة الأنموذج الموسمي

a_t البواقي (الخطأ العشوائي) ، إذ أن $a_t \sim NID(0, \sigma_a^2)$

ولغرض تحقق الاستقرارية يشترط ان تكون جذور المعادلة :

$$\Phi_s(B^s) = 1 - \Phi_s(B^s) = 0 \quad \dots (2)$$

خارج دائرة الوحدة (Unit Circle) (دائرة نصف قطرها يساوي واحد) ، أي لكي يكون الأنموذج مستقرًا يشترط ان تكون $-1 < \Phi_s < 1$. (Wei, 1990:161). إذ أن B هو عامل الارتداد الخلفي (Back Shift operator) ويعرف بالشكل الآتي:

$$B^s Y_t = Y_{t-s} \quad \forall s = 1, 2, \dots, K \quad \dots (3)$$

وإن الصيغة العامة لدالة الارتباط الذاتي (ACF) لانموذج الانحدار الذاتي الموسمي من الدرجة الأولى SAR(1) تأخذ الشكل الآتي:

$$\rho = \begin{cases} 1 & K = 0 \\ \Phi_s & K = s \\ 0 & k = 1, 2, \dots, K, s - 1 \end{cases} \quad \dots (4)$$

تتناقص أسياً ، في حين ان دالة الارتباط AR(p) اي ان دالة الارتباط الذاتي للانموذج الموسمي (الطائي و Markidaki & McGee, 1983) (P) تنقطع بعد الفاصلة PAR(P) الذاتي الجزئي (الكوراني ، ٢٠٠٨)

3.2 انموذج الأوساط المتحركة الموسمي (Seasonal Moving Average Models) ((SMA)

باستعمال عامل الازاحة (الارتداد) الخلفي (B) في الصيغة الآتية :

$$Y_t = \Theta_s B^s a_t \\ = (1 - \Theta_s B^s - \Theta_{2s} B^{2s} - \Lambda\Lambda - \Theta_{Qs} B^{Qs}) a_t \quad \dots (5)$$

فان الصيغة العامة لانموذج الواسط المتحركة الموسمي من الدرجة (Q) ستأخذ بالشكل الآتي:

$$Y_t = a_t - \Theta_s a_{t-s} - \Theta_{2s} a_{t-2s} - \Lambda\Lambda - \Theta_{Qs} a_{t-Qs} \quad \dots (6)$$

إذ أن:

$$-1 < \Theta < 1, \quad i=1, 2, \dots, \Lambda, Q, \quad \Theta_{Qs}$$

Q درجة انموذج الاوساط المتحركة الموسمي

ان دالة الارتباط الذاتي للانموذج (SMA) تنقطع بعد الفترة Q_s (تؤول الى الصفر بعد الدرجة Q) . في حين دالة الارتباط الذاتي الجزئي (PACF) تتناقص اسياً. (الطائي و الكوراني ، ٢٠٠٨) (WAFAA, 2017)

3.3 الإنموذج المختلط (الإنحدار الذاتي - الأوساط المتحركة) الموسمي

(Seasonal Mixed (Autoregressive-Moving Average) Model (SARMA)

باستعمال عامل الازاحة (الارتداد) الخلفي (B) في الصيغة الآتية :

$$\Phi_s B^s Y_t = \Theta_s B^s a_t$$

$$(1 - \Phi_s B^s - \Phi_{2s} B^{2s} - \Lambda\Lambda - \Phi_{ps} B^{ps}) Y_t = (1 - \Theta_s B^s - \Theta_{2s} B^{2s} - \Lambda\Lambda - \Theta_{qs} B^{qs}) a_t \quad \dots(7)$$

فان الصيغة العامة للنموذج المختلط الموسمي من الدرجة (P,Q) ستأخذ الشكل الآتي (الخصيري، ١٩٩٦و:١٣):

$$Y_t = \Phi_s Y_{t-s} + \Phi_{2s} Y_{t-2s} + \Lambda\Lambda + \Phi_{ps} Y_{t-ps} + a_t - \Theta_s a_{t-s} - \Theta_{2s} a_{t-2s} - \Lambda\Lambda - \Theta_{qs} a_{t-qs} \quad \dots(٨)$$

والذي يرمز له بالرمز $ARMA(P,Q)_s$. (WAFAA ,2017)

3.4 الإنموذج المختلط التكاملي الموسمي (Seasonal Autoregressive Integrated Moving Average Model)

ان النماذج الموسمية اعلاه تنطبق على السلاسل الزمنية المستقرة، اما اذا كانت السلسلة Y_t غير مستقرة فانه يمكن ايجاد الانموذج بعد ايجاد الفروق الموسمية المطلوبة لانتاج سلسلة مستقرة ، حيث ان عامل الفرق الموسمي من الدرجة D هو :

$$\nabla_s^D = (1 - B^s)^D \quad \dots(٩)$$

وهكذا يتكون لدينا انموذج مختلط موسمي غير مستقر (Box&Jenkins, 1976, 154) والذي يمكن ان يكتب بالشكل الآتي:

$$\Phi_s B^s \nabla_s^D Y_t = \Theta_s B^s a_t \quad \dots(10)$$

حيث ان (P,D,Q) تحدد درجة الانموذج والذي يكتب اختصاراً $ARIMA(P,D,Q)_s$

(Box and Jenkins ,1976) (Reisen and Lopes , 2001)

3.5 إنموذج ARIMA المضاعف (Multiplicative ARIMA Model)

يعد الأنموذج المضاعف من النماذج المحورة لانموذج ARIMA وذلك عن طريق اضافة التأثير الموسمي وعدم الاستقرارية (Shumaw & Stoffey, 2006) فالنماذج المضاعفة تتكون من نماذج الانحدار الذاتي ونماذج الاوساط المتحركة عند الازاحة (S) . إن إنموذج ARIMA الموسمي

يستعمل الفرق عندما تكون الإزاحة مساوية الى عدد شهور السنة فمثلاً لازالة التأثير المضاعف يمكن التعبير عن الإنموذج $ARIMA(p,d,q)(P,D,Q)_S$ المضاعف بالشكل الآتي (Comwperwait) : (Mengqing Qin, 2019) & Metcalf, 2009 :

$$\phi_p(B)\Phi_P(B^S)\nabla^d\nabla_S^D Y_t = \theta_q(B)\Theta_Q(B^S)a_t \quad \dots (11)$$

$$\begin{aligned} \phi_p(B) &= 1 - \phi_1(B) - \phi_2(B^2) - \dots - \phi_p(B^p) \\ \Phi_P(B^S) &= 1 - \Phi_y(B^y) - \Phi_{2y}(B^{2y}) - \dots - \Phi_{Py}(B^{Py}) \\ \theta_q(B) &= 1 - \theta_1(B) - \theta_2(B^2) - \dots - \theta_q(B^q) \\ \Theta_Q(B^S) &= 1 - \Theta_y(B^y) - \Theta_{2y}(B^{2y}) - \dots - \Theta_{Qy}(B^{Qy}) \end{aligned} \quad \dots(12)$$

إذ أن:

p درجة انموذج الانحدار الذاتي غير الموسمي، d درجة الفرق غير الموسمي، q درجة انموذج الاوساط المتحركة غير الموسمي، P درجة انموذج الانحدار الذاتي الموسمي، D درجة الفرق الموسمي، Q درجة انموذج الاوساط المتحركة الموسمي، $\phi_p(B)$ و $\Phi_P(B^S)$ معامل الانحدار الذاتي اللاموسمي والموسمي على التوالي، $\theta_q(B)$ و $\Theta_Q(B^S)$ معامل الاوساط المتحركة اللاموسمي والموسمي على التوالي، a_t الاخطاء العشوائية

$\nabla^d\nabla_S^D$ عدد الفروق الموسمية $(1-B^S)$ عند الزمن D واللاموسمية $(1-B)$ عند الزمن d التي تمكنا للتوصل الى استقرار السلسلة، وان رتبة الانموذج هي $ARIMA(p,d,q)(P,D,Q)_S$ ، S الازاحة الموسمية للأنموذج. (ناظم وسعدية، ٢٠١١)، (الجمال وآخرون، ٢٠١١) (الخصيري، ١٩٩٦) (Anderson, 1976)

4. التشخيص (Identification) : بعد ان يتم التحقق من الاستقرار في السلسلة الزمنية الموسمية، تبدأ عملية تحديد الانموذج المناسب الذي يمثل السلسلة ودرجته باستعمال دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF). وتعتمد هذه الطريقة على دقة الرسوم البيانية لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي بمطابقة معاملات الارتباط الذاتي والجزئي للسلسلة الزمنية الموسمية مع السلوك النظري لدالتي (ACF) و (PACF). والجدول (١) يبين طبيعة الانموذج وفقاً لمنحنى الارتباط الذاتي (Box and et al. 2013).

الجدول (١) طبيعة الانموذج وفقاً لمنحنى الارتباط الذاتي

الانموذج	دالة الارتباط الذاتي (ACF)	دالة الارتباط الذاتي الجزئي (PACF)
SAR(PS)	تتناقص تدريجياً سالكة سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	قطع بعد الإزاحة الموسمية PS (Cuts-off)
SMA(QS)	تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	قطع بعد الإزاحة الموسمية QS (Cuts-off)
SARMA(PS,QS)	تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)

ان عملية الانحدار الذاتي المستقرة (SAR) تمتلك ارتباط ذاتي (ACF) تتناقص اسياً وتقترب من الصفر، وان معاملات الارتباط الذاتي قد تتبادل بالإشارة بصورة متعاقبة او تاخذ شكل الموجة بالارتفاع والانخفاض، ولكن في كل الحالات فان المعاملات تقترب من الصفر لذلك فان عملية الانحدار الذاتي الموسمي من الرتبة (P) والتي توصف SAR(P) تمتلك ارتباط ذاتي جزئي (PACF) ينقطع بعد الإزاحة (P) ، وان طول الإزاحة لآخر سنان بارز من (PACF) يساوي رتبة انموذج SAR من الدرجة P. وان معاملات دالة الارتباط الذاتي لعملية تتبع انموذج الاوساط المتحركة الموسمي SMA بالرتبة q تنقطع بعد الإزاحة (q) وان معاملات الارتباط الذاتي تضمحل اسياً باقترابها من الصفر. اما عن العملية المستقرة المختلطة الموسمية التي تجمع بين ميزات الانحدار الذاتي (SAR) والمتوسطات المتحركة (SMA) وهي عملية (SARIMA) فان كلاً من معاملات الارتباط الذاتي والارتباط الذاتي الجزئي تتناقص اسياً وتقترب من الصفر (Chaurasia & Pal, 2020).

5. تحديد رتبة الانموذج (Model Identification): بعد التعرف على أنواع النماذج وخصائص ومميزات كل نوع لابد من معرفة رتبة الأنموذج وهذا يتم من خلال معايير إحصائية عديدة ، إن الاختيار الصحيحة لرتبة الأنموذج تؤدي إلى دقة الأنموذج الذي يتم التوصل إليه. يشير الباحث (Wei, 1989) إلى أن السلسلة الزمنية ومن خلال رسم دالة (A.C.F) إذا كانت تعاني من الاضمحلال وان رسم السلسلة لدالة (P.A.C.F) تعاني من وجود قطوعات فهذا دليل على إن الأنموذج AR وان رتبة الأنموذج تكون في منطقة القطع. لذلك لا يمكن الاعتماد على سلوك معاملات دالتي الارتباط ولكن يمكن الاستعانة في مثل هذه الحالات بمعايير إحصائية عديدة في تشخيص الأنموذج الملائم

وتحديد رتبته وهي معيار معلومة أكاكي (AIC) (Akaike Information Criterion) و معيار معلومة بيز (Bayesian Information Criterion)(BIC) و معيار اكاكي المعدل الموسمي ((The Seasonally modified Akaiki;s information criteria (SMAIC)):

6. فحص النموذج (Model Checking): فحص النموذج أو مدى ملاءمة النموذج وهي المرحلة التالية بعد تحديد رتبة النموذج وتقدير المعلمات للنموذج المشخص ويتم خلال هذه المرحلة إعادة احتساب السلسلة الزمنية باستعمال النموذج الذي تم التوصل إليه سابقاً ومن ثم حساب البواقي وكذلك اختبار البواقي (تساوي الفرق بين القيم الفعلية والقيم التقديرية) وهي مرحلة التأكد من مدى ملاءمة النموذج المحدد أو الذي تم التوصل إليه وتعمل هذه المرحلة تحت الفرضية الآتية.

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \quad \dots(13)$$

$$H_1 : \rho_i \neq \rho_L ; i \neq L$$

هناك العديد من الاختبارات المستعملة للتأكد من مدى ملاءمة النموذج المشخص وهنا سوف نذكر بعض هذه الاختبارات.

6.1 اختبار Box and Pierce :

ظهر هذا الاختبار في العام ١٩٧٠ من قبل الباحثين Pierce and Box ويستعمل لاختبار عشوائية الأخطاء في الأنموذج المشخص وهو اختبار للتحقق من مدى ملائمة الأنموذج المشخص أيضاً ويتم ذلك باختبار الفرضية الإحصائية الآتية.

$$Q_{B\&P} = (n-d) \sum_{k=1}^m r_k^2(a) \sim X^2(m-j), \alpha \quad \dots(14)$$

إذ أن :

d: يمثل عدد الفروقات المأخوذة بعد تحقق شرط الاستقرار حول متوسط البيانات للسلسلة الزمنية.

k: تمثل عدد الإزاحات وتساوي $k=1,2,3,\dots,m$

j: عدد المعلمات المقدر (p,q) للنموذج المشخص وتقارن قيمة الاختبار أعلاه مع قيمة X^2 الجدولية بدرجة حرية (m-p,q) ومستوى دلالة α .

إذا كانت القيمة المستخرجة من الاختبار أصغر من القيمة الجدولية عند مستوى الدلالة المحدد ودرجة الحرية فهذا يدل على ملائمة الأنموذج المشخص لبيانات السلسلة الزمنية ونقبل فرضية العدم. وعلى غرار هذا الاختبار أوجد الباحثان Box و Ljung في عام ١٩٧٨ اختباراً معتمداً على توزيع

الارتباطات الذاتية لبواقي الأنموذج المشخص ويعتمد على قيم X^2 الجدولية في إجراء المقارنة وإعطاء القرار بحق ملائمة الأنموذج من عدمه. (McElroy and Monsell, 2014)

٦,٢ إختبار Ljung-Box Test :

Ljung-Box إختبار إحصائي يستعمل لاختبار أي مجموعة من الارتباطات الذاتية في السلسلة الزمنية كونها تختلف معنوياً عن الصفر أم لا، ويمكن استعمال هذا الإختبار أيضاً للتحقق من عشوائية البيانات (إجمالاً) باستعمال مجموعة من الإزاحات. وفي الحقيقة إن صيغة إختبار (Ljung-Box) هي صيغة معدلة لصيغة (Q_{BP}) إذ إن قام كل من (Ljung, G.M & Box, G.E.P) بتعديل صيغة إختبار (Q_{BP}) الأصلية التي اقترحها كل من (Box & Pierce) بالشكل الآتي:

$$Q = m(m + 2) \sum_{i=1}^k \frac{r_i^2(u)}{(m-i)} \quad \dots(15)$$

إذ إن: $m=(n - d - SD)$ ، n : يمثل عدد مشاهدات السلسلة الزمنية ، d : عدد الفروق غير الموسمية. ، D : عدد الفروق الموسمية ، S : طول الموسم . K : أكبر إزاحة $r_i(u)$: يمثل الارتباط الذاتي للاخطاء عند الإزاحة (i)

وهناك إختبارات عديدة يمكن استعمالها للتأكد من مدى ملاءمة الانموذج منها إختبار بارتلت (Bartlett Test) ، وإختبار مقدم (Mokkadem Test) ، وإختبار مونتي (Monti Test). وغيرها من الإختبارات الأخرى. (Box & et al, 2013) (Reza & Yeganegi, 2019)

7. طريقة الامكان الاعظم التقريبية: Approximate Maximum Likelihood method

إن تقديرات الامكان الاعظم التقريبية المعتمدة على حساب المخطط الدوري تدعى تقريب Whittle الى لوغارتيم دالة الامكان. وللحصول على مقدر Whittle يتم استخدام صيغتين تقريبيتين في صيغة لوغارتيم دالة الامكان كما في المعادلة الآتية:

$$\dots(2-50) L(\theta) = -\frac{1}{2} \text{Log det } \Gamma(\theta) - \frac{1}{2} y' \{ \Gamma(\theta) \}^{-1} y$$

بعد قسمتها على حجم العينة نحصل على

$$\frac{1}{2n} \text{Log det } \Gamma(\theta) \approx \frac{1}{4\pi} \int_{-\pi}^{\pi} \text{Log } [2\pi f_{\theta}(\lambda)] d\lambda \quad \text{as } n \rightarrow \infty$$

$$\frac{1}{2n} y' \{ \Gamma(\theta) \}^{-1} y \approx \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda$$

إذ أن :

$$I(\lambda) = \frac{1}{2n\pi} \left| \sum_{j=1}^n y_j e^{i\lambda_j} \right|$$

تمثل المخطط الدوري للسلسلة $\{y_t\}$.

وبذلك أن لو غاريتم دالة الإمكان التقريبي:

$$L(\theta) = - \frac{1}{4\pi} \left[\int_{-\pi}^{\pi} \text{Log} [f_{\theta}(\lambda)] d\lambda + \int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda \right] \dots(16)$$

ولتبسيط حساب التكامل يمكن الأستعاضة عنها بمجاميع (Riemann) :

$$\int_{-\pi}^{\pi} \text{Log} [f_{\theta}(\lambda)] d\lambda \approx \frac{2\pi}{n} \sum_{j=1}^n \text{Log} [f_{\theta}(\lambda_j)]$$

$$\int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda \approx \frac{2\pi}{n} \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)}$$

وبذلك فإن الصيغة المتقطعة الى لو غاريتم دالة الامكان ستكون :

$$L(\theta) = - \frac{1}{2n} \left[\sum_{j=1}^n \text{Log} [f_{\theta}(\lambda_j)] + \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)} \right] \dots(17)$$

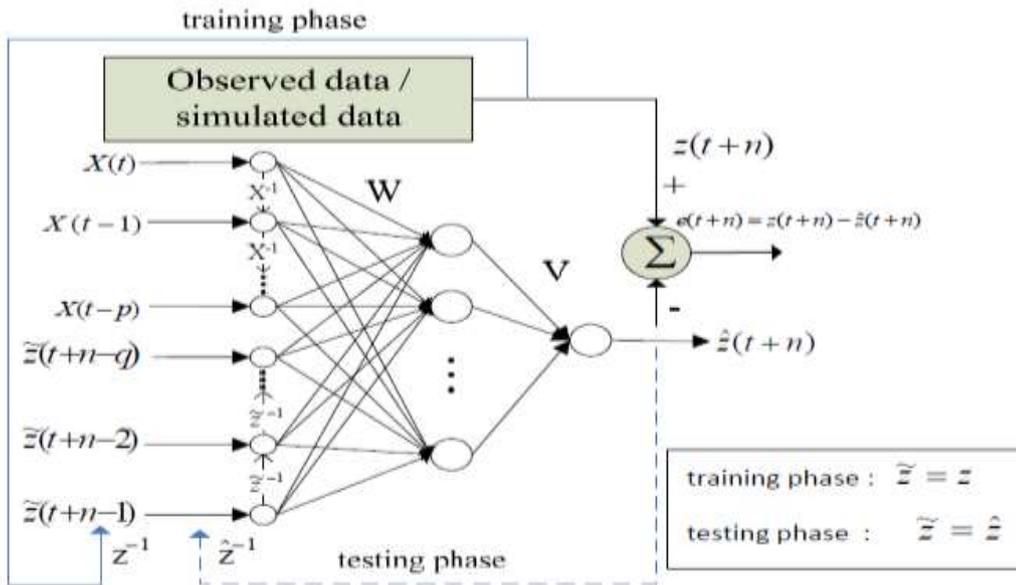
كما أن هناك صيغة أخرى مبسطة الى لو غاريتم دالة الامكان لـ (Whittle) وذلك بإهمال الحد الأول في صيغة (2-53) نحصل على :

$$L(\theta) = - \frac{1}{2\pi} \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)} \dots(18)$$

(Palma ,W. 2007) (Reisen , 2001)

٨. شبكة الانحدار الذاتي اللاخطية بمدخلات خارجية (NARX) : تبني فكرة عمل الشبكات العصبية الاصطناعية على محاكاة وظائف الدماغ البيولوجية لإجراء عمليات حسابية متوازية لمعالجة البيانات واستخراج المعرفة للوصول إلى نموذج لهذه البيانات لغرض التحليل أو التصنيف أو التقدير أو التنبؤ أو أي معالجة أخرى دون الحاجة إلى أنموذج مقترح لهذه البيانات، وبهذه الميزة فقد حازت الشبكات العصبية الاصطناعية اهتمام الكثير من الباحثين والعلماء حيث لها المرونة العالية بالمقارنة مع الأساليب الرياضية المستخدمة (Cheng, 2014, 7). و تعتبر الشبكات العصبية الاصطناعية (ANN) هي حالة ذكية من نظرية الشبكات في عملية التعلم على إنموذج للبيانات وخرن وبث المعلومات في الشبكة العصبية الاصطناعية. وهي احدى النماذج اللاخطية الذي يحاكي الشبكات العصبية الحيوية(النظام العصبي) ، وذلك عن طريق معالجة ضخمة موزعة على التوازي ومكونة من

وحدات معالجة بسيطة تسمى هذه الوحدات بالعصبونات او عقد او خلايا (Nodes, cells , Neurons) والتي لها خاصية عصبية لانها تقوم بتخزين المعرفة العلمية والمعلومات التجريبية لتجعلها متاحة عن طريق ضبط الاوزان (Negenvitsky, 2011, 286). وتستعمل الشبكات العصبية الاصطناعية في الكثير من المجالات والتطبيقات منها معالجة الاشارة (Signal processing) والسيطرة (control) ، تمييز الانماط (Pattern recognizing) ، الطب (Medicine) ، انتاج الكلام وتمميز الكلام (speech production and recognizing) وكذلك في تحليل السلاسل الزمنية (البدراني و صليو ، ٢٠١٤ ، ١) . والشبكة العصبية (NARX) من الشبكات العصبية الحركية المتركرة القوية التي تستعمل للتنبؤ بالسلاسل الزمنية فيكون لها تأخراً زمنياً (Delay Time) ومعماريتها مبنية على أساس الشبكة العصبية متعددة الطبقات فهي تتألف من ثلاث طبقات من الخلايا : طبقة ادخل والطبقة المخفية وطبقة الاخراج ، وترتبط كل طبقة في السبطة بالطبقة التي تليها ارتباطاً امامياً (feed forward) فضلاً عن هذا الترابط فان الشارة الخارجة من خلايا طبقة الاخراج تعتبر كمدخلات اضافية (External) باتصالات تغذية عكسية (Feed Back) لخلايا طبقة الادخال وهذا سيؤدي الى سرعة وصول الشبكة الى الاستقرار ، كما انها تستخدم خوارزمية الانتشار الخلفي (Back Propagation) لتصحيح الخطأ (البدراني و صلية ، ٢٠١٤ ، ١١) والشكل (١٠-٢) يبين معمارية (NARX)



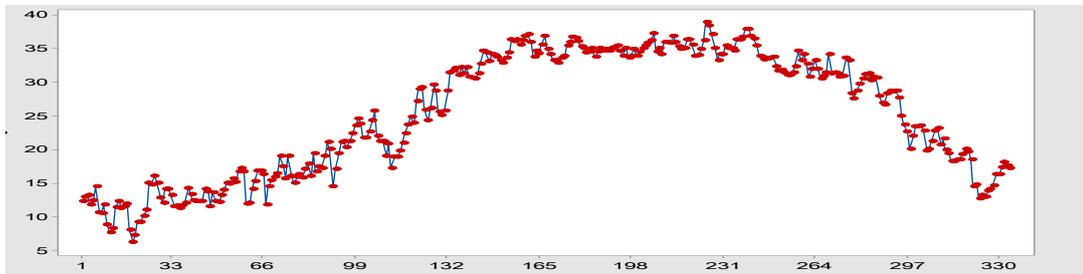
شكل (١) معمارية شبكة (NARX) العصبية الاصطناعية

٩. الجانب التطبيقي : تم بناء نماذج سلسلة زمنية موسمية والمقارنة بين هذه النماذج باستعمال معايير المفاضلة بين النماذج واختيار افضل نموذج تمثل درجات الحرارة في محافظة بابل حيث تم الحصول على البيانات الخاصة بالبحث من هيئة الانواء الجوية العراقية ، التي تمثل درجات الحرارة اليومية

المسجلة في محافظة بابل لسنة (٢٠٢٠) والتي شملت (٣٣٤) مشاهدة . والتي تم الحصول عليها من هيئة الانواء الجوية العراقية والمبينة في ملحق (A). وتم اختبار اعتدالية البيانات وفقاً لاختبار Goodness of fit وتم تحليل البيانات وبالاعتماد على البرامج الجاهزة (Minitab 17, Matlab) (2015, E-views 10

لغرض تحديد الانموذج الافضل في تقدير درجات الحرارة اليومية في محافظة بابل سيتم اتباع خطوات التحليل التالية على السلسلة وكما يأتي:

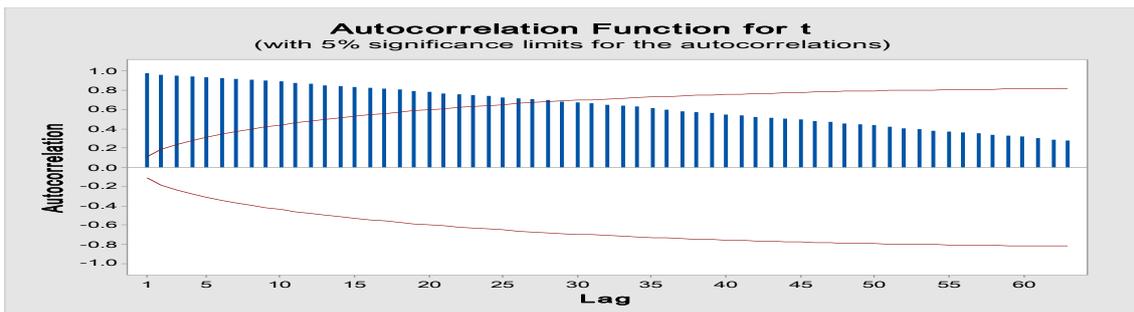
فحص استقرارية السلسلة : بعد جمع البيانات والتي تعتبر المرحلة الاولى من مراحل عملية تحليل البيانات، وقبل عملية التحليل لابد من ان نقوم برسم سلسلة البيانات التي تمثل درجات الحرارة اليومية المسجلة في محافظة بابل للتعرف على سلوك السلسلة وخصائصها الأولية والشكل (٢) يمثل رسم السلسلة :

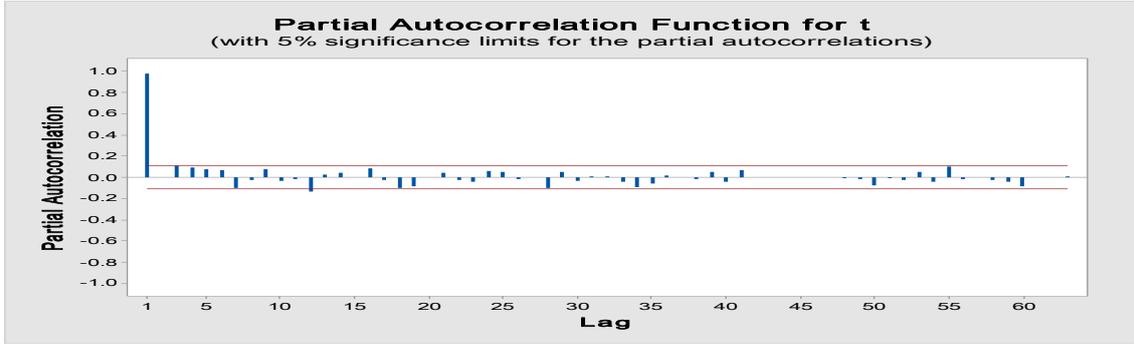


الشكل (٢) يبين سلسلة درجات الحرارة اليومية في محافظة بابل Y_t

من خلال الشكل (٢) نلاحظ ان المحور العمودي يمثل قيم درجات الحرارة اليومية والمحور الافقي يمثل الأيام، ونلاحظ عدم استقرار السلسلة الزمنية حيث تعبر عن الاتجاه العام مع الزمن فضلاً عن وجود تذبذبات متمثلة في تقعات وبتوءات ، وهذه التذبذبات تتكرر بانتظام بوتيرة متشابهة كل يوم مع اختلافها والتي تزداد بها من يوم لآخر الى آخر ، وهذه التغييرات تؤثر لنا على وجود مركبة اتجاه عام ومركبة موسمية وان السلسلة غير مستقرة.

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) وكما في الشكل (2-3) :





الشكل (3) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t

نلاحظ من الشكل رقم (3) بأن الكثير من معاملات دالة الارتباط الذاتي ACF خارج حدود الثقة بمستوى 95% وكذلك بعض معاملات الارتباط الذاتي الجزئي وهذا مؤشر على عدم استقرار السلسلة.

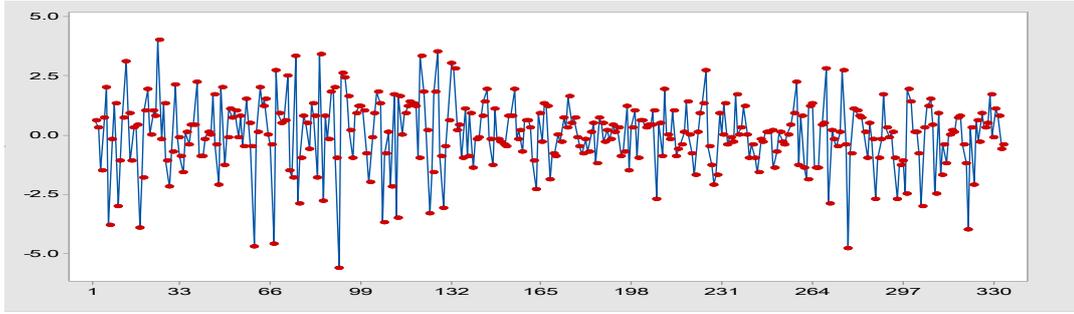
وللتأكد أكثر من عدم استقرار سلسلة درجات الحرارة في محافظة بابل نلجأ إلى اختبار ديكي- فولر الموسع ويبين الجدول (3) نتائج الاختبار.

جدول (3) يبين نتائج اختبار ديكي – فولر الموسع للسلسلة الزمنية

Test	Test Statistic	Table Statistic	P-value
Augmented Dickey Fuller	-1.66945	-3.4498	0.4459

تبين نتائج الاختبار في الجدول (3) إن القيمة المطلقة لاحصاء الاختبار هي اقل من القيمة الجدولية الخاصة باختبار ديكي – فولر الموسع عند مستوى معنوية (0,05). وهذا يدعونا الى عدم رفض فرضية عدم ورفض الفرضية البديلة التي تشير إلى استقرار السلسلة الزمنية اي ان السلسلة غير مستقرة.

ولازالة الاتجاه العام من السلسلة الزمنية تم اخذ الفرق الاول لقيم السلسلة الزمنية Y_t إذ نلاحظ أنه تم تحقيق الاستقرار حول المتوسط في السلسلة وكما مبين في الشكل (4).

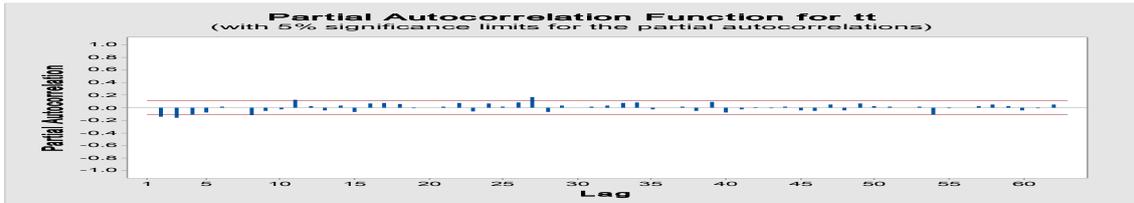
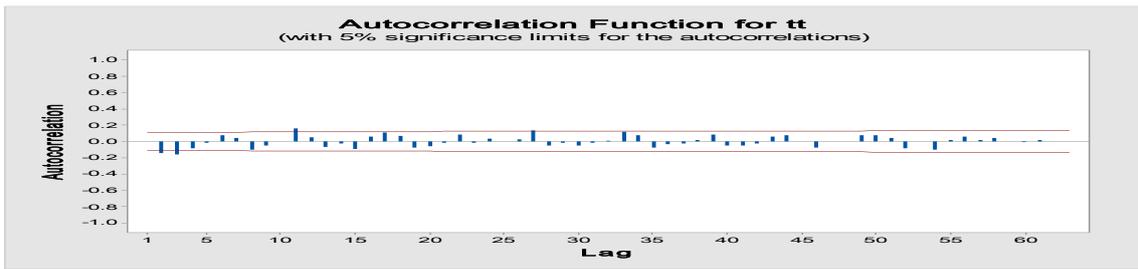


الشكل (4) يوضح رسم سلسلة درجات الحرارة في محافظة بابل Y_t بعد اخذ الفرق الاول لها

من خلال الشكل (4) نلاحظ استقرار السلسلة الزمنية حيث انعدام الاتجاه العام مع الزمن حيث ان المنحنى يوازي محور الفواصل مما يدل على غياب الاتجاه العام في السلسلة مع بقاء المركبة الموسمية اي ان السلسلة غير مستقرة وهذا ماتؤكدده لنا احصاءة Ljung-Box :

$$Q.stat = LBQ = 89.4217 > \chi^2_{(62,0.05)} = 88.38$$

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) بعد اخذ الفرق الأول وكما في الشكل (5) :



الشكل (5) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t بعد اخذ الفرق الأول

نلاحظ من الشكل رقم (5) بأن اغلبية معاملات دالة الارتباط الذاتي ACF داخل حدود الثقة بمستوى 95% وكذلك معاملات الارتباط الذاتي الجزئي وهذا مؤشر على استقرارية السلسلة والسلسلة تخلصت من الاتجاه العام مع بقاء المركبة الموسمية.

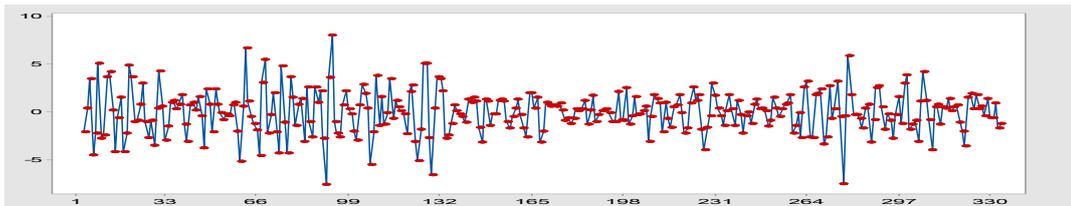
وللتأكد أكثر من استقرارية سلسلة درجات الحرارة في محافظة بابل بعد اخذ الفرق الأول نلجأ إلى اختبار ديكي- فولر وبيين الجدول (٥) نتائج الاختبار.

جدول (٥) يبين نتائج اختبار ديكي – فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الاول

Test	Test Statistic	Table Statistic	P-value
Augmented Dickey Fuller	-12.2505	-3.42384	0.000

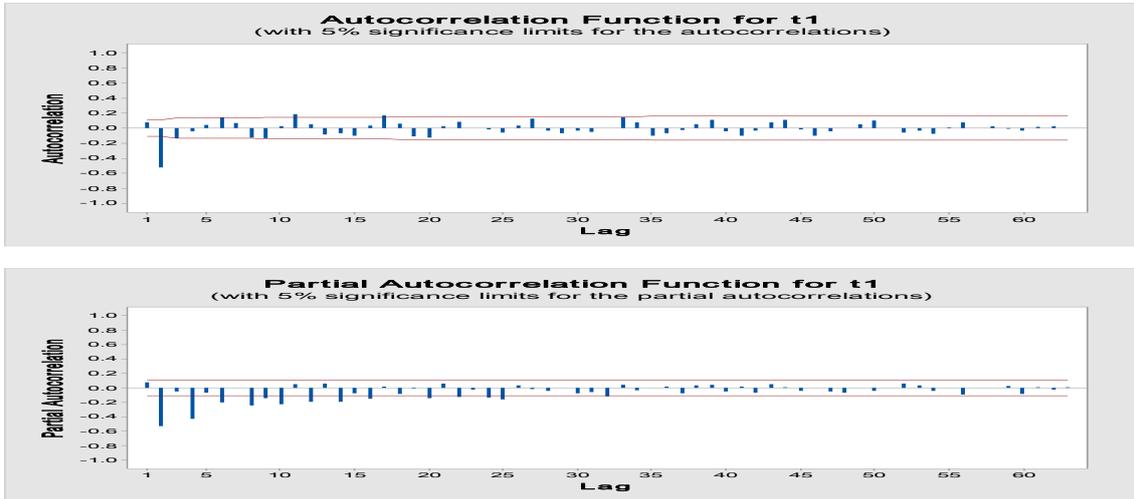
تبين نتائج الاختبار في الجدول (٥) إن القيمة المطلقة لاحصاء الاختبار هي اكبر من القيمة الجدولية الخاصة باختبار ديكي – فولر عند مستوى معنوية (٠,٠٥) . وهذا يدعونا الى رفض فرضية العدم وقبول الفرضية البديلة التي تشير إلى استقرارية السلسلة الزمنية اي ان السلسلة مستقرة بعد الفرق الأول.

ولغرض ازالة المركبة الموسمية ومن ملاحظة قيم الارتباطات الذاتية للسلسلة المعدلة (بعد اخذ الفرق الأول) تبين ان هذه القيم معنوية في فترات معينة وغير معنوية في فترات اخرى فهي تعيد نفسها كل فترتين زمنتين مما يدل على وجود الموسمية فيها ، لذلك لغرض التخلص من الموسمية تم اخذ الفروق الموسمية من الدرجة الثانية لنحصل على السلسلة المعدلة والمخلصة من الاثر الموسمي والشكل (6) يبين السلسلة الزمنية المعدلة بعد اخذ لفروق الموسمية لها وانها معنوية فقط عند الازاحة الثانية مما يدل على استقرارية السلسلة الزمنية.



الشكل (٥) يبين سلسلة درجات الحرارة اليومية في محافظة بابل Y_t بعد ازالة الموسمية

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) وكما في الشكل (6) :



الشكل (6) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t بعد اخذ الفروق الموسمية

نلاحظ من الشكل رقم (٦) بأن معاملات دالة الارتباط الذاتي ACF داخل حدود الثقة بمستوى 95% وكذلك الكثير معاملات الارتباط الذاتي الجزئي وهذا مؤشر على استقرار السلسلة الزمنية بعد الفرق الموسمي الأول.

وللتأكد أكثر من استقرار سلسلة درجات الحرارة في محافظة بابل نلجأ إلى اختبار ديكي- فولر الموسع ويبين الجدول (٦-٣) نتائج الاختبار.

جدول (٦) يبين نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الموسمي

Test	Test Statistic	Table Statistic	P-value
Augmented Dickey Fuller	-9.01859	-2.87044	0.000

تبين نتائج الاختبار في الجدول (٦) إن القيمة المطلقة لاحصاء الاختبار هي اقل من القيمة الجدولية الخاصة باختبار ديكي - فولر الموسع عند مستوى معنوية (٠,٠٥) . وهذا يدعونا الى رفض فرضية عدم وقبول الفرضية البديلة التي تشير إلى استقرار السلسلة الزمنية وتكون خالية من الاتجاه العام والمركبة الموسمية.

تشخيص وتحديد الانموذج الموسمي الملائم: بعد تحقيق الاستقرار في السلسلة الخاصة بدرجات الحرارة في محافظة بابل نقوم بتشخيص الانموذج الملائم لتمثيل السلسلة الزمنية عن طريق دراسة ومقارنة السلوك النظري لدالتي (ACF),(PACF) والجدول رقم (7-٣) يبين سلوك دالتي الارتباط الذاتي والارتباط الذاتي الجزئي في تحديد الأنموذج اذ نلاحظ بان الانموذج الملائم هو الانموذج المضاعف $ARIMA(p,q,d)(P,Q,D)_2$ اذ يتضح ان دالة الارتباط الذاتي ودالة الارتباط الذاتي

الجزئي للعينه تتناقص تدريجياً مع زيادة فترات التخلف الزمني سالكة سلوك دالة الجيب، وبشكل أدق في تحديد رتبة الانموذج تم توفيق عدد من النماذج المعنوية واختيار الإنموذج الأفضل بالاعتماد على احصاءة (Ljung-BoxChi-Square) والمعايير (AIC) و (BIC) و (SMAIC) ، والنماذج المقترحة هي كما موضحة في الجدول رقم (٧)

الجدول (٧) يبين النماذج الموسمية المضاعفة المقترحة ذات التقديرات المعنوية

No.	الانموذج	AIC	BIC	SMAIC	Ljung-Box Chi- Square	P-Value
1	ARIMA(1, 1, 0) (1, 1, 0) ₂	-36.76	-288.91	-130.77	165.7	0.000
2	ARIMA(1, 2, 0) (1, 1, 0) ₂	-33.45	-202.34	-37.77	195.5	0.000
3	ARIMA(2, 1, 0) (1, 1, 0) ₂	-35.81	-233.63	-35.54	184.6	0.000
4	ARIMA(2, 2, 0) (1, 1, 0) ₂	-35.81	-233.63	-35.54	184.6	0.000
5	ARIMA(1, 1, 0) (1, 2, 0) ₂	-146.81	-288.91	-130.77	378.78	0.000
6	ARIMA(1, 1, 0) (2, 1, 0) ₂	-43.41	-222.56	-56.76	212.6	0.000
7	ARIMA(1, 1, 0) (2, 2, 0) ₂	-120.61	-210.53	-45.45	128.9	0.000
8	ARIMA(2, 1, 0) (1, 2, 0) ₂	-47.41	-237.56	-66.76	234.3	0.000
9	ARIMA(1, 1, 0) (0, 1, 0) ₂	-31.48	-199.36	-31.74	192.7	0.000
9	ARIMA(1, 1, 0) (0, 2, 0) ₂	-47.41	-237.56	-66.76	234.0	0.000
9	ARIMA(0, 1, 0) (0, 2, 0) ₂	-137.45	-188.76	-128.39	85.2	0.000
10	ARIMA(1, 0, 0) (0, 2, 0) ₂	-43.77	-246.55	-61.42	239.0	0.000

إذا يتضح من جدول (7) ان افضل انموذج موسمي مضاعف من الدرجة $ARIMA(0,1,0)$ $(0,2,0)_2$ لان امتلك اقل قيم لمعايير المقارنة (AIC, BIX, SMAIC) واعتمادا على ذلك سيتم تقدير معاملات هذا الانموذج واختيار افضل طريقة بالتقدير.

تقدير معاملات الانموذج واختبار معنويتها وملائمة الإنموذج :

بعد تحديد الإنموذج الموسمي ورتبته تأتي الخطوة اللاحقة من مراحل بناء انموذج السلاسل الزمنية وهي تقدير معاملات الانموذج واختبار معنويتها وباستخدام برنامج (Gretl 1.9.11) و برنامج (MiniTab Ver 17) و (E-Views 10) و (NCSS 2007) تم تطبيق ثلاثة طرائق لتقدير معالم الانموذج المقترح وكما يأتي:

التقدير باستعمال طريقة الامكان الاعظم التقريبية EMLE : بتطبيق طريقة الامكان الاعظم التقريبية على بيانات السلسلة الزمنية قيد الدراسة تم الحصول على تقدير الانموذج الموسمي المضاعف $ARIMA(1,1,0)X(1,2,0)_2$ كما يأتي:

جدول (8) نتائج تقدير الانموذج المقترح بموجب طريقة الامكان الاعظم التقريبية AMLE

Type	Coef.	SE Coef.	T	P-Value
AR 1	-0.1507	0.0560	-2.69	0.008
SAR 2	-0.7656	0.0366	-20.92	0.000
Differencing: 1 regular, 2 seasonal of order 2				
MSE = 11.65				

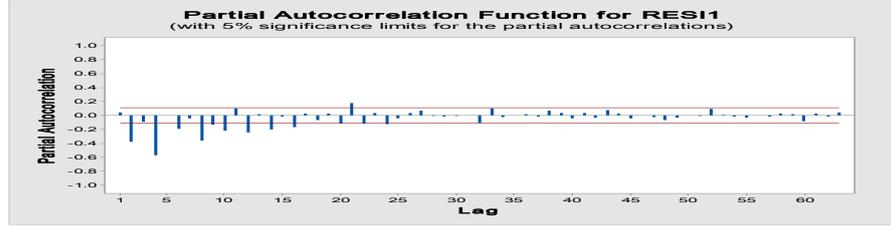
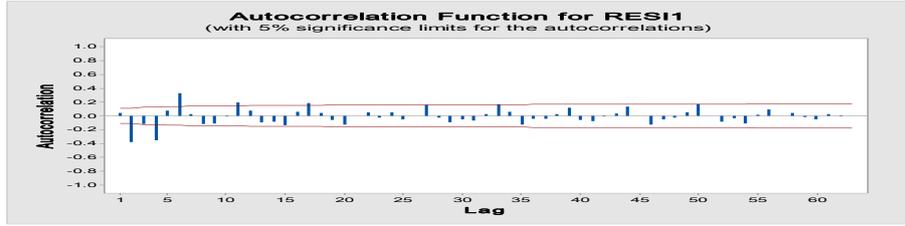
اذ نلاحظ من جدول (8-3) ان الانموذج معنوي من الناحية الاحصائية لان قيمة P-Value اقل من مستوى المعنوية (0,05)

1-1 فحص ملائمة الإنموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE:

بعد تشخيص الإنموذج وتحديد درجته وتقديره لا بد من التأكد من صحة ملائمة الانموذج وكفاءته وتم ذلك من خلال ما يأتي:

أ- إختبار معاملات الارتباط الذاتي المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE:

تم استخراج معاملات الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي (الاحطاء العشوائية) للانموذج المقدر كما في جدول (8) وتم رسمها كما في شكل (7) اذ تبين بان اغلبية قيم معاملات الارتباط الذاتي والارتباط الذاتي الجزئي ضمن ضمن حدود الثقة مما يعني بان سلسلة البواقي عشوائية وان الانموذج المستعمل جيد وملائم.



شكل (٧) دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف

إختبار Portmanteau للاخطاء العشوائية المقدرة بموجب طريقة الامكان الاعظم التقريبية
:AMLE

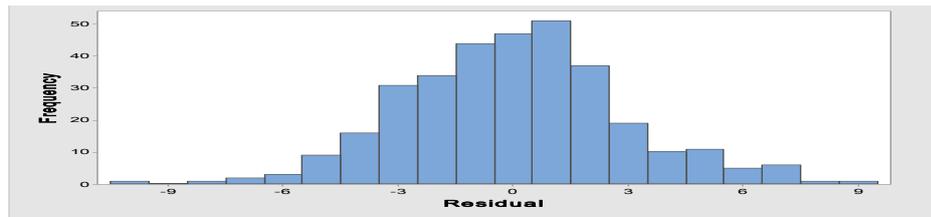
بما ان الاخطاء تعتبر (White Noise) اي ان $a_t \sim NID(0, \sigma_a^2)$ وان معاملات الارتباط للبواقي $r_k(\hat{a})$ تتوزع طبيعياً بوسط حسابي يساوي صفر وتباين مقداره $(1/N)$ فقد تم تطبيق احصاءة (Ljung-Box) لفحص ملائمة الانموذج وظهر بان:

$$Q.stat = LBQ = 428.875 > \chi^2_{(61,0.05)} = 88.38$$

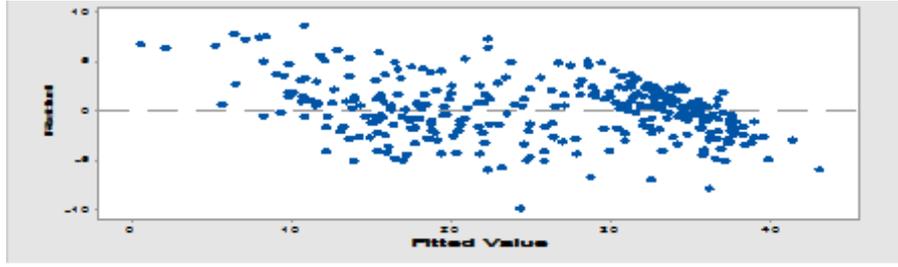
ومن ذلك نستنتج بأن سلسلة البواقي غير معنوية (عشوائية) ومن ثم فان توفيق الانموذج جيد وملائم وكفوء

ب- اختبار التوزيع الطبيعي للبواقي المقدرة بموجب طريقة الامكان الاعظم التقريبية AMLE :

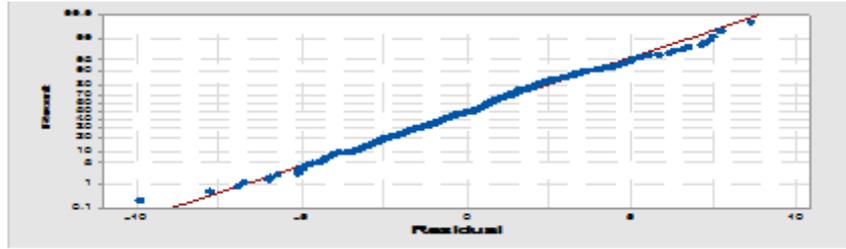
يوضح الشكل رقم (٨) اختبار التناظر والتسطح الطبيعي لسلسلة البواقي للانموذج المقدر وهو يدل على ان سلسلة البواقي تحمل خصائص التوزيع الطبيعي مما يؤكد على دقة وكفاءة وملائمة الانموذج المقدر .



(a)



(b)



(c)

شكل (٨) (a) المدرج التكراري لسلسلة البواقي للانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي للانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي للانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية

AMLE

التقدير باستعمال الشبكة العصبية الاصطناعية NARX : لغرض الحصول على القيم التقدير للسلسلة درجات الحرارة في قضاء الحلة وباستعمال السلسلة الأصلية للبيانات المكونة من (٣٣٤) مشاهدة والتي تعاني من عدم الاستقرار ، تم تصميم برنامج بلغة ماتلاب (MatLab , 2015a) كما في ملحق (A) والذي تضمن مرحلتين رئيسيتين ، المرحلة الأولى هي الاعداد للبيانات (Preparing Data) وهي عملية تحويل البيانات الى الصيغة المعيارية (Normalized) وكذلك تحديد مدخلات الشبكة العصبية، اما المرحلة الثانية فهي عملية تقسيم البيانات اذ تم تقسيم البيانات بنسبة (٨:٢) الى مجموعتين هما مجموعة التدريب (Training set) ومن ضمنها مجموعة بيانات التدقيق (Validation set) والمكونة من (٢٦٠) مشاهدة بنسبة (٧٧,٨%) والمجموعة الثانية هي مجموعة بيانات الاختبار (Testing set) المؤلفة من (٧٤) مشاهدة بنسبة (22.2%) ، فبعد ان تم تهيئة البيانات لادخالها الى الشبكة تم تصميم الشبكة والتي تألفت من ثلاثة اطوار رئيسية هي طور التدريب و طور التحقق و طور الاختبار وحسب الأتي:

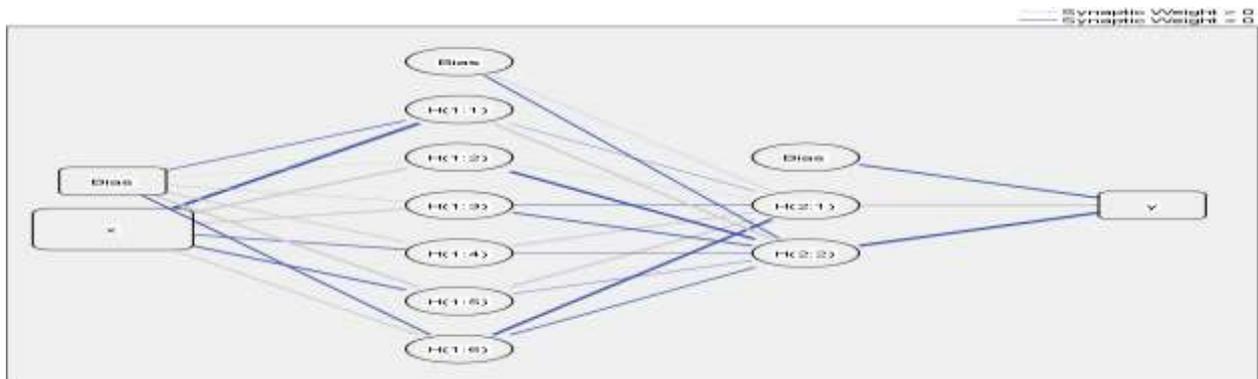
اولاً: طور التدريب: تم تكوين وتدريب الشبكة العصبية (NARX) باستعمال الدالة (newnarx) واعطاء قيم أقرب ماتكون لبيانات درجات الحرارة بادخال ومعالجة بيانات التدريب واختيار العدد (25000) كعدد لدورات التدريب وبنسبة خطأ (٠,٠٠٠١) وتبين بان افضل معمارية لتقدير

المشاهدات هي باختيار خمس عقد لطبقة الادخال واستعمال طبقتين مخفيتين الاولى تضمنت ست عقد والثانية تضمنت عقدتين وعقدة اخراج واحدة .

ثانياً: طور التحقق: تم اختيار الشبكة عن طريق ادخال بيانات التدقيق اذ تقارن هذه البيانات مع البيانات المدربة التي تم الحصول عليها في طور التدريب للحصول على تطابق مع بيانات الهدف وبهذا يتم التحقق من الشبكة قد دربت تدريباً جيداً .

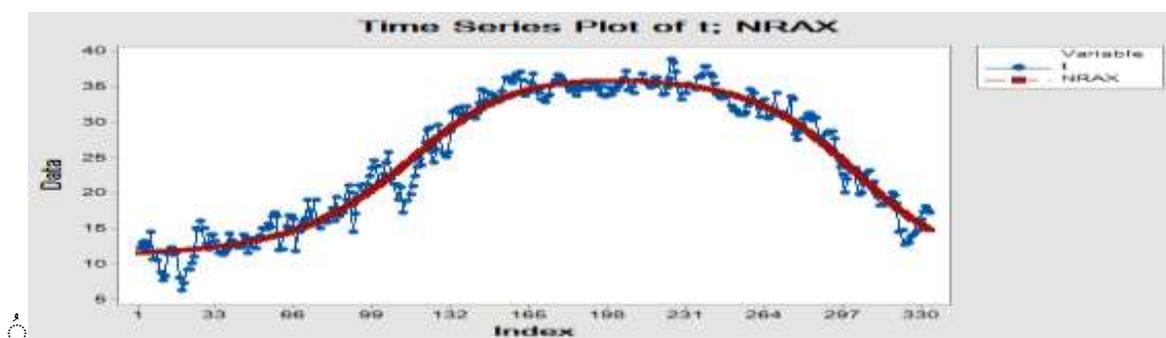
ثالثاً: طور الاختبار: بعد ان تم اكمال عملية التدريب وعمية التحقق يتم الآن ادخال بيانات الاختبار والاوزان المثالية المخزونة للشبكة ومعالجتها وعمل اختبار لكفاءة الشبكة العصبية المدربة وقدرتها على اعطاء قيم تقديرية مقبولة وبهذا تم الحصول على المخرجات المطلوبة من الشبكة العصبية الاصطناعية .

والشكل (١١) يبين معمارية الشبكة العصبية الاصطناعية



شكل(11) معمارية الشبكة العصبية الاصطناعية NARX

والشكل (١٢) يبينان القيم التقديرية لسلسلة درجات الحرارة اليومية في محافظة بابل باستعمال الشبكة العصبية الاصطناعية والتي تكون متناسقة مع القيم الاصلية للسلسلة وهذا يدل على دقة وكفاءة جيدة للانموذج المقدر.



شكل (١٢) القيم التقديرية والحقيقية لسلسلة درجات الحرارة في محافظة بابل المقدر بموجب الشبكة العصبية الاصطناعية NARX.

وجداول (٨) يبين معيار متوسط مربعات الخطأ (MSE) لكل من طريقة الامكان الاعظم التقريبية

وطريقة الشبكات الصنناعية:

EMLE	NARX
11.65	3.55

وكما هو واضح من جدول (٨) بان طريقة الشبكات العصبية الاصناعية قد تفوقت على طريقة الامكان الاعظم التقريبية في تقدير سلسلة درجات الحرارة في محافظة بابل كونها حققت اقل قيمة لمتوسط مربعات الخطأ بلغت (3.55) .

١٠. مناقشة النتائج : ان الانموذج الموسمي المضاعف $ARIMA(p,q,d)(P,Q,D)_2$ حدد كافضل أنموذج ممثل للسلسلة الزمنية الموسمية محل الدراسة. وقد تم تشخيص الانموذج الموسمي المضاعف من الرتبة $ARIMA(1,1,0)(1,2,0)_2$ كأفضل انموذج موسمي لسلسلة درجات الحرارة في قضاء الحلة. ومن خلال نتائج التطبيق تبين تفوق تفوق اسلوب الشبكات العصبية الاصطناعية على طريقة الامان الاعظم التقريبية اذ حقق هذا الاسلوب اقل متوسط مربعات خطأ . وان قيم بيانات السلسلة الزمنية الممثلة لدرجات الحرارة في محافظة بابل المقدرة بطريقة الشبكات العصبية الاصطناعية اكثر تناسق من طريقة الامكان الاعظم التقريبية .

المصادر:

١. البدراني ، ظافر رمضان مطر، صليو ، رهاد عماد صليو، (٢٠١٤) ، " تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستخدام الشبكات العصبية " المجلة العراقية للعلوم الاحصائية، (٢٦) ، (١-١٩)
٢. التميمي ، د. رعد فاضل (٢٠١٣) " الانحدار والسلاسل الزمنية أساليب إحصائية تطبيقية متقدمة باستخدام نظام Minitab " ، كتاب ، بغداد.
٣. الجبوري ، وليد دهان صليبي (٢٠١٠) " التنبؤ بمستوى التضخم في أسعار المستهلك الشهرية في العراق باستخدام السلاسل الزمنية ثنائية المتغيرات" رسالة ماجستير في العلوم الإحصائية، كلية الإدارة والاقتصاد/ الجامعة المستنصرية .
٤. الجمال . زكريا يحيى ، العمري ، هيلاء أنس ، صالح ، فرح عبد الغني ، " استخدام بعض معايير المعلومات في تحديد افضل انموذج موسمي مضاعف" ، ٢٠١١ ، المجلة العراقية للعلوم الاحصائية ص ص ٢٤٩-٢٦٦ .

٥. المحمدي، ناظم عبد الله عبد ، طعمة ، سعدية عبد الكريم ، " استخدام السلاسل الزمنية الموسمية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة" مجلة جامعة الانبار للعلوم الاقتصادية والادارية ، ٢٠١١ المجلد ٤ العدد ٧ .
٦. خلود جمال عوض الله، (٢٠١٦) ، " استخدام نماذج SARIMA و Holt-Winters في التنبؤ بالسلاسل الزمنية الموسمية Using SARIMA and Holt-Winters models to forecast seasonal time series" ،رسالة ماجستير في الاحصاء ، جامعة الأزهر غزة -عمادة الدراسات العليا كلية الاقتصاد والعلوم الإدارية قسم الإحصاء التطبيقي.
٧. خليل، بيداء ابراهيم. (٢٠٠١). "مقارنة التطبيق لبعض الشبكات العصبية الاصطناعية"، بحث ماجستير ، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.
٨. زرمان , كريم(2015) "دراسة تحليلية وتنبؤية لمعدلات الخسارة في شركات التأمينات دراسة حالة الشركة الجزائرية للتأمين الشامل CAAT بقسنطينة منذ 1995" رسالة دكتوراه، جامعة محمد خيضر بسكرة , الجزائر .
٩. شرماط ، طاهر ، بوعيشاوي يوسف، " دراسة تنبؤية لاستهلاك الكهرباء باستعمال نموذج الانحدار الذاتي الاوساط المتحركة الموسمي دراسة حالة مدينة المدية للفترة من ٢٠١٧-٢٠١٩" ،مجلة بحوث الادارة والاقتصاد ، الجزائر.
١٠. صليو ، رهاد عماد ، مطر، ظافر رمضان ، (٢٠١٩) "مقارنة اداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية _ بوكس-جنكنز) مع التطبيق " المجلة العراقية للعلوم الاحصائية (٨٢٨) ، ص ص ٧٦-٥١ .
١١. طعمه ، سعدية عبد الكريم،(٢٠١٢). "استعمال السلاسل الزمنية في التنبؤ باعداد المصابين بالأورام الخبيثة في محافظة الانبار"مجلة جامعة الانبار للعلوم الاقتصادية والإدارية ،مجلد ٤ . العدد ٨ .
١٢. عاشور ، مروان عبد الحميد ، (٢٠٢٠) ، " استخدام الشبكات العصبية الاصطناعية المحسنة ونماذج بوكس-جنكنز في تحليل السلاسل الزمنية " ، اطروحة دكتوراه ، المملكة العربية السعودية
١٣. فاندل، والتر" (1992) السلاسل الزمنية من الوجة التطبيقية ونماذج بوكس-جينكنز"، تعريب عبد المرضي حامد عزام، دار المريخ للنشر، الرياض، المملكة العربية السعودية.

١٤. لقوقي فاتح ، "جودة نماذج السلاسل الزمنية الموسمية المختلطة في التنبؤ بالمبيعات دراسة حالة مؤسسة مطاحن جديع بتقوت" ، رسالة ماجستير ، وزارة التعليم العالي والبحث العلمي الجزائر.

١٥. محمد ، عبد الرحمن جاسم (2014) "مقارنة بعض طرائق تحديد رتبة و تقدير معاملات أنموذج (ARX) مع تطبيق عملي على سعر صرف الدينار العراقي" ، رسالة ماجستير في الاحصاء ، كلية الإدارة والاقتصاد/جامعة بغداد.

16. Box , Georg E.P and Jenkins , Gwilym M. and Reinsel ,Gregory C. (2013) Time Series Analysis for casting and Control.

17. Box ,G.E.P. & Jenkins ,G.M.(2008).Time Series Analysis: Forecasting and Control . Holden – Day . Sanfransco . USA .

18. Cheng, Xiaoyu, (2014), " Applications of Artificial Neural Networks (ANNs) in exploring materials property-property correlations" , a theses of the Degree of Doctor of Philosophy at University of London .

19. Comwpertwait Paul.S.P. & Metcalf Andrew.V., (2009). " Introduction to Ttime Series with Rn " ,Spring, New York. Forecasting and Control " , San Francisco , Holden-Day , U.S.A.

20. Hajdu, Gergo, Minoso, Yaclaudes, Rafael, Lopez, Acosta, Miguel, Elleithy, Abdelrahman, (2019) , "Use of Artificial Neural Networks to Identify Fake

21. Harba , M.I.A. , (1981) , " Signal Processing & Digital Computer Techniques Applied To Surface Electromyography Ph.D. Dissertation University Of Bristol .

22. Hossein Hassani, Mohammad Reza Yeganegi,(2019), "Selecting optimal lag order in Ljung–Box test" , Physica A 541 (2020) 123700

23. Makridakis , S. , Wheel Wright S. , C. , and McGee (1983) , " Forecasting
24. Mengqing Qin, (2019),"Seasonal Time Series Models with Application o Weather and Lake Level Data", Missouri State University, Mengqing1214@live.missouristate.edu , Method and Application " , 2nd ed , John Wily and Sons. Inc. U.S.A. .Methods. Addison-Wesley publishing company. USA.
25. Negnevitsky, M. (2011). "Artificial Intelligence", 3rd ed., University of Tasmania, ISBN 978-1-4082-2574-5 .
26. Palma ,W. (2007).Long – Memory Time Series:Theory & Methods. John – Wiley & Sons , Inc. , Puplication . USA .
27. Principe, Jese C., Euliano, Neil R. and Lefebvre, W. Curt. (2000): “Neural and Adaptive Systems: Fundamentals through Simulation “, John Wiley and Sons INC, New York.
28. Profiles" , Department of Computer Science William Paterson UniversityWayne, NJ, USA.
29. Rajae AZRAK and Guy MÉLARD, 2013, "EXACT MAXIMUM LIKELIHOOD ESTIMATION FOR EXTENDED ARIMA MODELS", Boulevard du Triomphe, B-1050 BELGIUM, DOI: 10.1007/978-1-4899-4515-0_9
30. Reisen , V. , Abraham , B. and Lopes , S.(2001).” Estimation Paramerters in ARFIMA Processes : A Simulation Study “ . Communications in Statistics – Simulation and computation . Vol.30 , Issue 4 .
31. Reisen , V. , Abraham , B. and Lopes , S.(2001).” Estimation Paramerters in ARFIMA Processes : A Simulation Study “ . Communications in Statistics – Simulation and computation . Vol.30 , Issue 4

32. Shen, H. Y. and Chang, L. C. (2013), " Online multistep-ahead inundation depth forecasts by recurrent NARX networks ", Published: 5 March 2013 , PP. 935–945.
33. Shumway Robert H. & Stoffer David .S., Springer ,(2006) . "Time Series Analysis and its Applications with R Examples", 2nd edition , Science & Business Media , LLC,US.
34. Tucker McElroy and Brian Monsell, (2014), " The multiple testing problem for Box-Pierce statistics" , Electronic Journal of Statistics Vol. 8 (2014) 497–522 ISSN: 1935-7524.
35. Vikas Chaurasia & Saurabh Pal, (2020), "Application of machine learning time series analysis for prediction COVID-19 pandemic", Research on Biomedical Engineering <https://doi.org/10.1007/s42600-020-00105-4>