

استخدام النموذج الهجين SARIMA – ELMAN (ERNN) للتنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد

علي طارق عبد المجيد**
Ali.tareq87@yagoo.com

أ.م.د. بثينة عبد الجادر عبد العزيز*
Dr.buthainh aljader@gmail.com

المستخلص

ان عملية التخطيط الاستراتيجي لظاهرة معينة وعملية اتخاذ القرارات المناسبة تعتمد بشكل اساس على عملية التنبؤ المستقبلي الدقيق من خلال وضع انموذج رياضي لتمثيل تلك الظاهرة ، لذا تناول هذا البحث دراسة نماذج السلاسل الزمنية الموسمية الهجينة بأفترض ان السلسلة الزمنية تحتوي على المركبة الخطية إذ يمكن وصفها بالانموذج الموسمي المضاعف $SARIMA(p,d,q)(P,D,Q)_s$ والمركبة اللاخطية إذ توصف انموذج الشبكة العصبية الاسترجاعية (شبكة ايلمان) لتمثيل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنوات (1937 – 2013) ومن خلال استخدام مجموعة من المقاييس الاحصائية وجد ان الانموذج الهجين SARIMA(p,d,q)(P,D,Q)s-ELMAN يمتلك قيم صغيرة لمتوسط مطلق الخطأ (MAE) ومتوسط الانحراف المطلق (MAD) ومتوسط مطلق الخطأ النسبي (MAPE) والجذر التربيعي لمتوسط مربعات الخطأ (RMSE) ومتوسط مربعات الخطأ (MSE) والخطأ المعياري للتنبؤ (SEP) وقيمة عالية لـ R^2 ، لذا تم استخدامه للتنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنتين 2017 – 2018 . الكلمات المفتاحية : الانموذج الهجين ، الانموذج الموسمي المضاعف ، التقدير ، التنبؤ ، الشبكات العصبية الاصطناعية ، شبكة ايلمان العصبية التكرارية .

Using The Hybrid Model SARIMA - ELMAN (ERNN) To Predict The Monthly Maximum Temperature Of Baghdad

Ali Tareq Alsalam

Asst . Prof. Dr. Buthaina Abdul Jader

Abstract

The process of strategic planning of a particular phenomenon and the process of making appropriate decisions depend on the process of accurate future prediction through the improvement of a model to represent that phenomenon , This research uses Seasonal Time Series Hybrid Models assuming that the series include components linear , which can be described as the The Multiplicative Sasonal Model SARIMA (p, d, q) (P, D, Q) s and non-linear Component , describing the The Model Elman Recurrent Of The Neural Network Model For the monthly rates of maximum temperatures for the city of Baghdad for the years (1937 - 2013) Using a set of statistical measures, it has been found that the hybrid model SARIMA (P, D, q) (P, D, Q) s-ELMAN has small values for Mean Absolute Error (MAE) and Mean Absolute Deviation (MAD) and Mean Absolute Percentage Error (MAPE) and Root Mean Square Error (RMSE) And Standard Error of Prediction (SEP),and high value for Therefore, it was used to predict the monthly average temperature for Baghdad City for the years 2017-2018.

* الجامعة المستنصرية / كلية الادارة والاقتصاد .
** باحث .

مقبول للنشر بتاريخ 2018/2/21
مستل من رسالة ماجستير

المقدمة Introduction

يعد التنبؤ من المواضيع التي اكتسبت اهمية كبيرة في كثير من الدراسات الديموغرافية والاقتصادية والأنوائية وغيرها . إذ ان من خلال عملية التنبؤ يمكن لصناع القرار من رسم السياسات المستقبلية للظاهرة المدروسة ، وتتم عملية التنبؤ من خلال وضع نماذج توصف السلسلة الزمنية الموسمية المدروسة لذا ظهرت اساليب متعددة للتنبؤ منها معلمي وخطي كنماذج $SARIMA(p,d,q)(P,D,Q)_s$ والتي شاع استخدامها في مجالات عديدة منها الانوائية والاقتصادية والاجتماعية وغيرها. والآخر لامعلمي ولاخطي كنماذج الشبكات العصبية الاصطناعية المتعددة المراحل الامامية والاسترجاعية، ولكن وجد من خلال البحوث والدراسات التي اجريت من ان الأنموذج المفرد **The Single Model** سواء كان يمثل السلسلة الزمنية الموسمية ذات المركبة الخطية أو ذات المركبة اللاخطية لا يمكنه توظيف كافة المعلومات المتوفرة للسلسلة اي انه لا يستطيع ان يعبر بدقة عن خصائص السلسلة الزمنية ويعطي تنبؤات دقيقة . لذا أتجه الكثير من الباحثين الى البحث عن تقنيه جديده لنمذجة السلسلة الزمنية الموسمية من خلال دمج انموذج السلسلة المعلمي الخطي مع الأنموذج اللامعلمي واللاخطي والذي يسمى بالأنموذج الهجين بغية الحصول على تنبؤات دقيقة تقترب من القيم الحقيقية للظاهرة المدروسة . ويضم البحث جانبان الاول نظري والثاني تطبيقي يتناول استخدام بيانات حقيقية تمثل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد .

مشكلة البحث problem of Research

لقد وجد ان التنبؤات المستقبلية المحسوبة من خلال استعمال الأنموذج المفرد سواء كان خطي أو لاخطي لايعطي تنبؤات دقيقة وقريبة من الواقع الفعلي إذ ان التنبؤ المستقبلي الدقيق للسلسلة الزمنية الموسمية لظاهرة معينة يساعد في عملية وضع الخطط المستقبلية واتخاذ القرارات المناسبة ، لذا تم البحث عن تقنيه جديدة الا وهي الدمج بين الأنموذج المفرد الخطي واللاخطي لتوليد الأنموذج الهجين بغية الحصول على تنبؤات دقيقة .

هدف البحث Objective of Research

يهدف البحث الى استخدام الأنموذج الهجين **SARIMA-ELMAN** للسلسلة الزمنية الموسمية للتنبؤات المستقبلية بدرجات الحرارة العظمى لمدينة بغداد للسنتين 2017,2018 .

الجانب النظري

1. الأنموذج الهجين Hybrid Model [9]

يعرف الأنموذج الهجين بالأنموذج الناتج من دمج احد نماذج السلسلة الزمنية الموسمية ذات المركبة الخطية مع انموذج الشبكات العصبية المتعددة الطبقات الامامية أو الاسترجاعية ذات المركبة اللاخطية ، ان اول من بدأ بعملية التهجين هو الباحث (Zhang) [10] عام 2003 إذ استطاع ان يجمع بين نقاط القوة في الأنموذج الخطي مع نقاط القوة في الأنموذج اللاخطي عند تحليل السلسلة الزمنية غير الموسمية ووجد ان التنبؤات المستخرجة تنبؤات دقيقة ، كما جرت دراسة محلية من قبل الجادر والساعدي [2] 2016 باستخدام النماذج الهجينة وغير الهجينة للتنبؤ بأعداد المسافرين لمطار بغداد الدولي . اما عملية التهجين في السلاسل الزمنية الموسمية فقد تمت من قبل الباحث (Chen) [6] عام 2007 إذ استطاع ان يمثل المركبة الخطية للسلسلة الموسمية بأنموذج **SARIMA** والبواقي المستخرجة من هذا الأنموذج تمثل بأنموذج الشبكات العصبية المتعددة المراحل وهناك ايضاً عملية تهجين اخرى إذ يتم اعتبار البواقي المستخرجة من انموذج السلسلة الزمنية الموسمية والتنبؤات المستخرجة مع القيم الحقيقية للسلسلة الزمنية بأزاحات مختلفة كمدخلات للشبكة العصبية العصبية المتعددة المراحل ذات الانتشار الخلفي كما ورد في البحث المقدم من قبل (Tseng) [8] واخرون . في هذه البحث سيتم استخدام الأنموذج الهجين الناتج من دمج احد نماذج السلسلة الزمنية الموسمية مع انموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان) .

1.1. الأنموذج الهجين (SARIMA-ERNN) The Hybrid Model [9]

يستند الأنموذج الهجين على افتراض ان السلسلة الزمنية تتألف من مركبتين الاولى خطية (Linear) والثانية لاخطية (Non Linear) كما في المعادلة الاتية :

$$(1) \dots X_t = L_t + N_t$$

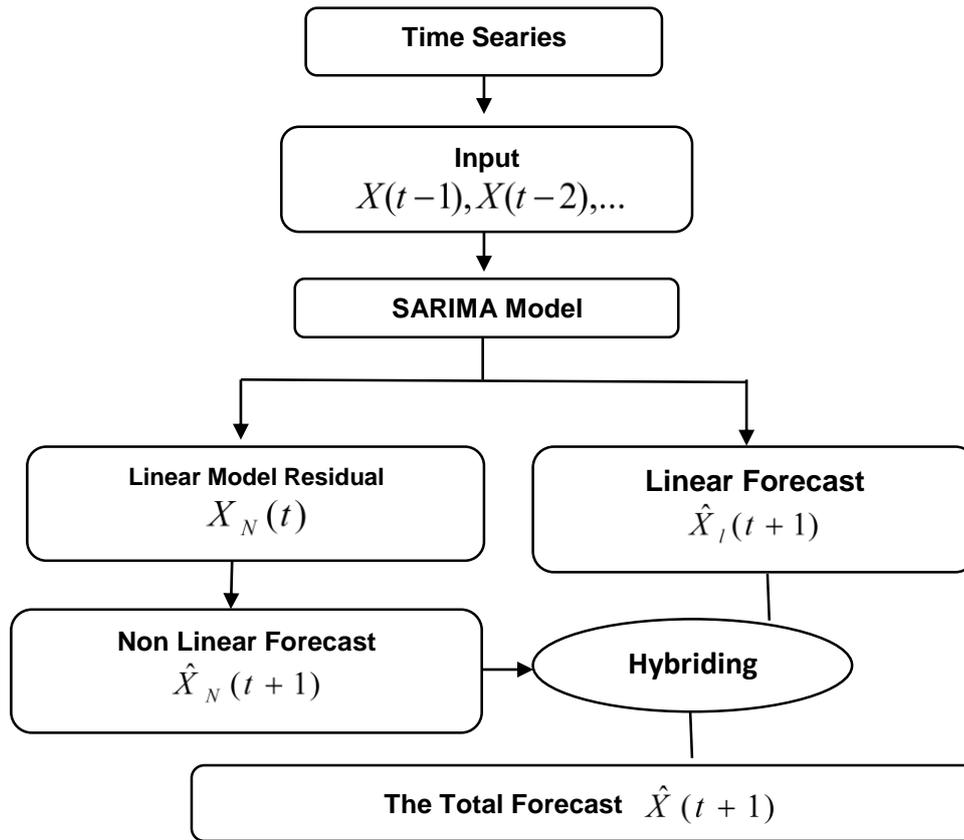
إذ ان : X_t : تمثل السلسلة الزمنية الموسمية

L_t : تمثل المركبة الخطية للسلسلة الزمنية الموسمية (مركبة الانحدار الذاتي)

N_t : تمثل المركبة اللاخطية للسلسلة الزمنية الموسمية (مركبة الخطأ العشوائي) . ويتم تحليل السلسلة الزمنية

بأستخدام الأنموذج الهجين بمركبتين هما :

المرحلة الاولى : ان المركبة الخطيه (L_t) للسلسلة الزمنية الموسمية تمثل بالأنموذج الموسمي المضاعف الذي يرمز له بالرمز SARIMA(p,d,q)(P,D,Q)S .
 إذ ان D, d الفروق الاعتيادية والموسمية على التوالي بأعداد صحيحة ، وتستخرج التنبؤات المستقبلية للأنموذج الخطي ، ان البواقي المستخرجه من هذا الأنموذج وان تعدت مرحلة دقة التشخيص (Diagnostic Checking) فأنها تحمل معلومات عن السلسلة الزمنية يمكن نمذجتها بأحد النماذج كما في المرحلة الثانية .
المرحلة الثانية : ان المركبة اللاخطيه (N_t) والمتمثلة بالبواقي المستخرجه من الأنموذج الخطي توصف بأنموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان Elman). ومن هذا الأنموذج تُستخرج التنبؤات المستقبلية وعلية فأن التنبؤات النهائية للسلسلة الزمنية تكون بجمع التنبؤات المستقبلية المستخرجه بالمرحلتين وفق المعادلة:
 $(2) \dots \hat{X}_t = \hat{L}_t + \hat{N}_t$



المخطط (1)

يُبين عملية بناء الأنموذج الهجين واستخراج التنبؤات المستقبلية للسلسلة الزمنية [9]

لذا سيتم شرح مفصل للأنموذج الموسمي المضاعف Multiplicative Seasonal ARIMA Model عندما تكون الفروق الاعتيادية والموسمية اعداد صحيحة ويأخذ حالة خاصة من هذه النماذج الا وهو الأنموذج الموسمي المضاعف SARIMA(0,1,1)(0,1,1) (باعتباره اكثر النماذج استخداماً في مجال الانواء الجوية إذ ان الجانب التطبيقي يتناول استخدام بيانات حقيقية تمثل المعدلات الشهرية لدرجات الحرارة العظمى في مدينة بغداد) . إذ تم ذكر الخصائص النظرية له ومراحل بناء هذا الأنموذج . ويتضمن الجانب النظري ايضاً شرح لأنموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان Elman) إذ تم التعريف على الشبكات العصبية المتعددة وهيكلية هذه الشبكات وخوارزمية تحديث الاوزان .

2.1. انموذج ARIMA الموسمي المضاعف: Multiplicative Seasonal ARIMA Model [4]
 ان السلسلة الزمنية X_t يمكن تمثيلها بالانموذج الآتي :

$$\omega_p(B)(1-B)^d X_t = \nu_q(B)b_t \dots (3)$$

وان b_t لا تمثل متغيرات عشوائية غير مترابطة (White Noise) بل لها ارتباط عالي في الفترات الموسمية وعالية يمكن تمثيل b_t بنموذج موسمي وبالصيغة الاتية :

$$\omega_p(B^s)(1-B^s)^D b_t = \nu_Q(B^s)a_t \dots \dots \dots (4)$$

وان a_t متغيرات عشوائية غير مترابطة . وبالتعويض عن السلسلة b_t في المعادلة اعلاه ينتج الانموذج الموسمي المضاعف الذي يرمز له بالرمز ARIMA(p,d,q)(P,D,Q)S الذي كتب معادلته بالشكل الاتي:

$$\omega_p(B)\omega_p(B^s)(1-B)^d(1-B^s)^D X_t = \nu_q(B)\nu_Q(B^s)a_t \dots (5)$$

عندما تكون $P=p=0, S=12, D=d=q=Q=1$ ، ينتج الانموذج $ARIMA(0,1,1)(0,1,1)_{12}$ الذي شاع استخدامه في تمثيل السلاسل الزمنية في مجال الانواء الجوية كدرجات الحرارة الشهرية ، كميات الامطار الساقطة شهرياً ، المعدلات الشهرية لسرع الرياح ، المعدلات الشهرية للرطوبة النسبية وكثير من الظواهر الاخرى وتكتب معادلته بالشكل الاتي:

$$(1-B)(1-B^{12})X_t = (1-\nu_1 B)(1-\nu_{1s} B^{12})a_t \dots (6)$$

1.2.1 . خصائص الانموذج الموسمي SARIMA(0,1,1)(0,1,1)^[4]

1.1. 2.1 . دالة التباين المشترك (Auto Covariance Function)^[4]

ان دالة التباين المشترك لهذا الانموذج يمكن ان تستخرج باستخدام الدالة المولدة للتباينات

$$\gamma(B) = \sigma^2 \psi(B)\Psi(B^s)\Psi(B^{-1})\Psi(B^{-s}) \dots (7)$$

اذ يمكن كتابة الانموذج بصيغة الانموذج العام

$$y_t = \psi(B)\psi(B^s)a_t \dots (8)$$

اذ ان :

$$y_t = (1-B)(1-B^s)X_t , \psi(B) = (1-\nu_1 B) , \psi(B^s) = (1-\nu_{1s} B^s)$$

وعليه فان :

$$\gamma(B) = \sigma^2(1-\nu_1 B)(1-\nu_{1s} B^s)(1-\nu_1 B^{-1})(1-\nu_{1s} B^{-s}) \dots (9)$$

وعليه ينتج :

$$\gamma_0 = \sigma^2(1 + \nu_1^2 + \nu_{1s}^2 + \nu_1^2 \nu_{1s}^2)$$

$$\gamma_1 = \sigma^2(-\nu_1 - \nu_1 \nu_{1s}^2) = -\nu_1 \sigma^2(1 + \nu_{1s}^2),$$

$$\gamma_{s-1} = \sigma^2(\nu_1 \nu_{1s}) , \gamma_s = \sigma^2(-\nu_{1s} - \nu_1^2 \nu_{1s}) = -\nu_{1s} \sigma^2(1 + \nu_1^2)$$

$$\gamma_{s+1} = \sigma^2(\nu_1 \nu_{1s})$$

وتساوي صفر عند الحالات الاخرى اي ان دالة التباين المشترك تكون ذات قيم معنوية عند الازاحة (1, S-1, S, S+1) وتكون متساوية عند الازاحة (S-1) و (S+1) وتساوي صفر عند الازاحات الاخرى.

2.1.2.1 . دالة الارتباط الذاتي (Autocorrelation Function)^[4]

يمكن استخراج دالة الارتباط الذاتي لهذا النموذج والتي تكون ذات قيم معنوية فقط عند الازاحات (S+1, S

(S-1, 1) , اي من قسمة دالة التباين المشترك على التباين كالاتي :

$$\rho_r = \frac{\gamma_r}{\gamma_0} , \rho_1 = \frac{-\nu_1}{(1 + \nu_1^2)} , \rho_{s-1} = \rho_{s+1} = \frac{\nu_1 \nu_{1s}}{(1 + \nu_1^2)(1 + \nu_{1s}^2)} , \rho_s = \frac{-\nu_{1s}}{(1 + \nu_{1s}^2)}$$

من خلال ملاحظة صيغ دالة الارتباط الذاتي اعلاه ، نجد ان ρ_1 يساوي ρ_1 لنموذج الاوساط المتحركة غير

الموسمي من الدرجة الاولى MA(1) . و ρ_s يساوي ρ_s لنموذج الاوساط المتحركة الموسمي من الدرجة الاولى

SMA(1) وان ρ_{s+1} , ρ_{s-1} متساويان .

3.1.2.1 . دالة الارتباط الجزئي (Partial Autocorrelation Function)^[4]

ان عملية استخراج دالة الارتباط الذاتي الجزئي لهذا النموذج صعبة جداً ، وقد تم الاعتماد على سلوكية دالة

الارتباط الذاتي الجزئي لنموذج MA(1) ولنموذج SMA(1) من انها تتناقص اسياً في الازاحات غير الموسمية

والموسمية .

4.1.2.1 معكوس دالة الارتباط الذاتي (Inverse Autocorrelation Function) [4]

يمكن استخراج معكوس دالة الارتباط الذاتي للانموذج SARIMA(0,1,1)(0,1,1) الذي يمكن كتابته كما في المعادلة الآتية :

$$y_t = (1 - v_1 B)(1 - v_{1s} B^s) a_t \dots (10)$$

وان الدالة المولدة للتباينات المشتركة كما ذكرت سابقاً في المعادلة (7) فإن معكوس الدالة المولدة للتباينات المشتركة

$$Y^{(I)} = \frac{1}{Y(B)} \quad . \quad Y(B) \neq 0 \dots (11) \quad \text{هي :}$$

$$Y^{(I)}(B) = \frac{1}{\sigma^2(1 - v_1 B)(1 - v_{1s} B^s)(1 - v_1 B^{-1})(1 - v_{1s} B^{-s})} \dots (12)$$

إذ ان $Y^{(I)}(B)$ تمثل معكوس دالة التباين المشترك

$$Y^{(I)}(B) = \frac{1}{\sigma^2} \left[\begin{array}{l} (1 + v_1 B + v_1^2 B^2 + \dots) * (1 + v_1 B^{-1} + v_1^2 B^{-2} + v_1^3 B^{-3} + \dots) * \\ (1 + v_{1s} B^s + v_{1s}^2 B^{2s} + v_{1s}^3 B^{3s} + \dots) * \\ (1 + v_{1s} B^{-s} + v_{1s}^2 B^{-2s} + v_{1s}^3 B^{-3s} + \dots) \end{array} \right]$$

$$Y^{(I)}(0) = \frac{1}{\sigma^2} (1 + v_1^2 + v_1^4 + v_1^6 + \dots) * (1 + v_{1s}^2 + v_{1s}^4 + \dots)$$

$$Y^{(I)}(0) = \frac{1}{\sigma^2} * \frac{1}{(1-v_1^2)} * \frac{1}{(1-v_{1s}^2)}$$

$$Y^{(I)}(1) = \frac{1}{\sigma^2} [v_1(1 + v_1^2 + v_1^4 + v_1^6 + \dots)] = \frac{v_1}{\sigma^2(1 - v_1^2)} \dots (13)$$

$$Y^{(I)}(2) = \frac{1}{\sigma^2} (v_1^2 + v_1^4 + v_1^6 + \dots) = \frac{v_1^2}{\sigma^2(1 - v_1^2)} = v_1 Y_{(1)}^{(I)}$$

$$Y^{(I)}(3) = \frac{1}{\sigma^2} \frac{v_1^3}{(1-v_1^2)} = v_1^2 Y_{(1)}^{(I)}, Y^{(I)}(r) = \frac{1}{\sigma^2} \frac{v_1^r}{(1-v_1^2)} = v_1^{r-1} Y_{(1)}^{(I)}$$

اما معكوس دالة التباين المشترك عند الازاحات الموسمية :

$$Y^{(I)}(s) = \frac{1}{\sigma^2} v_{1s} (1 + v_{1s}^2 + v_{1s}^4 + v_{1s}^6 + \dots) = \frac{v_{1s}}{\sigma^2(1-v_{1s}^2)}$$

$$Y^{(I)}(2s) = \frac{1}{\sigma^2} (v_{1s}^2 + v_{1s}^4 + v_{1s}^6 + \dots) = \frac{v_{1s}^2}{\sigma^2(1-v_{1s}^2)} = v_{1s} Y^{(I)}(s) \dots (14)$$

$$Y^{(I)}(rs) = \frac{1}{\sigma^2} * \frac{v_{1s}^r}{(1 - v_{1s}^2)} = v_{1s}^{r-1} Y_{(s)}^{(I)}$$

نلاحظ من خلال الصيغ المستخرجة اعلاه ان معكوس دالة التباين المشترك تكون معنوية عند الازاحات غير الموسمية (1,2,...,r) وعند الازاحات الموسمية (s,2s,...,rs) . وعليه فإن معكوس دالة الارتباط الذاتي لهذا الانموذج ستكون معنوية في الازاحات غير الموسمية اي ان:

$$\rho_r^{(I)} = \frac{Y^{(I)}(r)}{Y^{(I)}(0)} = \frac{v_1^r}{(1-v_1^2)} \quad r = 1,2 \dots$$

وعند الازاحات الموسمية اي ان:

$$\rho_{rs}^{(I)} = \frac{Y^{(I)}(rs)}{Y^{(I)}(0)} = \frac{v_{1s}^r}{(1-v_{1s}^2)} \quad r = 1,2 \dots$$

إذ انها تتناقص اسياً عند الازاحات الموسمية وغير الموسمية وهي تشبه سلوكية دالة الارتباط الذاتي الجزئي.

2.2.1.2 مراحل بناء الانموذج الموسمي المضاعف SARIMA(0,1,1)(0,1,1) [4]

ان مراحل بناء الانموذج الموسمي المضاعف SARIMA(0,1,1)(0,1,1) هي :

1.2.2.1 تشخيص الانموذج (The Model Identification) [4]

يتم تشخيص الانموذج وتحديد درجته بعد ان يتم تخلص السلسلة الزمنية من اثر الاتجاه العام بأخذ الفرق الاعتيادي الاول (1-B) ، ومن التأثيرات الموسمية يأخذ الفرق الموسمي الاول (1-BS) فتصبح السلسلة الجديدة

$y_t = (1 - B)(1 - B^s) X_t$. عندئذ يتم فحص دالتي الارتباط الذاتي والجزئي للسلسلة y_t إذ تكون معاملات الارتباط

الذاتي معنوية فقط عند الازاحات (S+1,S,S-1,1) ومعاملات الارتباط الذاتي الجزئي تتناقص اسياً في الازاحات غير الموسمية والموسمية .

2.2.2.1. تقدير الانموذج (The Model Estimation) [4]

توجد عدة طرائق لتقدير معالم الانموذج الموسمي المضاعف SARIMA(0,1,1)(0,1,1) وهي طريقة العزوم (Moment Method) وطريقة المربعات الصغرى الاعتيادية (Ordinary Least Squares) وطريقة الامكان الاعظم (Maximum Likelihood Method) ، ان هذه الطرائق تعطي معادلات غير خطية وعند الاعتماد على طريقة الامكان الاعظم المعرفه فان :

$$\ln l(u_1, u_{1s}, \sigma_a^2) = -\frac{n}{2} \ln 2\pi\sigma_a^2 - \frac{s(u_1, u_{1s})}{2\sigma_a^2} \dots\dots(15)$$

$$s(u_1, u_{1s}) = \sum_{t=q+Q-1}^n [E(a_t | u_1, u_{1s}, y_t)]^2 \dots(16)$$

وان المعالم المقدره هي التي تجعل المقدر $s(u_1, u_{1s})$ اقل ما يمكن وذلك بأعطاء قيم للمعلمتين u_1, u_{1s} بحيث ان $-1 < u_1 < 1$. $-1 < u_{1s} < 1$. وحساب المقدر $s(u_1, u_{1s})$ ، ثم نختار قيم المعالم التي تجعل هذا المقدر اقل ما يمكن . أو يمكن استخدام طريقة نيوتن رافسن .

3.2.2.1. تدقيق النموذج (The Model Diagnostic Checking) [4]

في هذه المرحلة يتم تدقيق صحة الانموذج المقترح بالاعتماد على معاملات الارتباط الذاتي للبقايا المستخرجه $\hat{\rho}_a(k)$ واستخراج الصيغتين:

$$Q = n \sum_{k=1}^m \hat{\rho}_a^2(k) \dots\dots\dots(17)$$

$$Q^* = n(n+2) \sum_{k=1}^m (n-k)^{-1} \hat{\rho}_a(k) \dots\dots\dots(18)$$

إذ ان m تمثل الجذر التربيعي لعدد المشاهدات وان كل من الصيغتين تتوزعان مربع كاي بدرجة حرية m ومستوى معنوية α فإذا كانت قيمة χ^2 المستخرجه اكبر من الجدولة بدرجة حرية m ترفض فرضية العدم التي تنص بأنه لا توجد ارتباطات ذاتية بين البواقى اي $H_0 : \rho_k = 0$ اما اذا كانت قيمة مربع كاي اقل من الجدولة نقبل الفرضية اي ان a_t متغيرات عشوائية غير مترابطة وبالتالي فان الانموذج المشخص جيد وملائم لتمثيل بيانات السلسلة الزمنية . كذلك يمكن الاعتماد على دالة الارتباط الذاتي للبقايا عندما تكون محصورة بين حدي الثقة الادنى والاعلى عندئذ يمكن اعتبار البواقى \hat{a}_t متغيرات عشوائية غير مترابطة والانموذج المشخص جيد وملائم لتمثيل بيانات السلسلة .

4.2.2.1. التنبؤ (Forecasting) [4]

بعد ان تم تشخيص الانموذج وتحديد درجته وتقدير معلماته واختباره لمعرفة مدى ملائمته لتمثيل بيانات تلك السلسلة . عندئذ يمكن استخدام حساب التنبؤات المستقبلية للظاهرة المدروسة وعليه فان القيمة المستقبلية عند $t + l$ تمثل التوقع الشرطي اي ان :

$$\hat{y}_t^{(l)} = E(y_{t+l} / y_1, y_2, \dots, y_n) = -\hat{u}_1 a_{t+l-1} - \hat{u}_{12} a_{t+l-s} + \hat{u}_1 \hat{u}_{12} a_{t+l-s-1} \dots(19)$$

وان متوسط مربعات خطأ التنبؤ هو $M.M.S.E.F = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2$ إذ ان ψ_j تمثل الاوزان عندما

يكتب الانموذج بالشكل الاتي : $y_t = \psi(B)\psi(B^S)a_t$ وعند حساب التنبؤات المستقبلية ينبغي مراعاة

- 1 – $E[y_{t-j}] = y_{t-j} \quad j = 0.1.2 \dots$ ما يأتي :
- 2 – $E[y_{t+j}] = \hat{y}_t^{(l)} \quad j = 1.2 \dots$
- 3 – $E[a_{t-j}] = a_{t-j} = y_{t-j} - \hat{y}_{t-j-1}$ ،
- 4 – $E[a_{t+j}] = 0 \quad j = 1.2 \dots$ ،

3.1. الشبكات العصبية الاصطناعية: Artificial Neural Network [2],[5],[7]

تُعد الشبكات العصبية الاصطناعية من اهم مجالات الذكاء الاصطناعي الواسعة التطبيق في مختلف المجالات العلمية وتعكس تطوراً هاماً لطريقة تفكير الانسان وهي محاكاة للشبكة العصبية الحيوية الموجودة في دماغ الانسان البشري من خلال محاكاة البيانات للوصول الى افضل نموذج لغرض التحليل او التنبؤ دون الحاجة الى نموذج مقترح . شهدت السنوات السابقة اهتمام كثير من العلماء والباحثين بنماذج الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN) واستخدامها كبديل مناسب عن النماذج التقليدية لقدرتها على التنبؤ الدقيق بحل المشكلات بسهولة ودقه مقارنة بالاساليب الاحصائية السابقة من خلال تطبيقها دون النظر الى فرضيات معينة بطبيعة المتغيرات وعلاقتها مع بعضها ، ان عملية التدريب للشبكة يتم تدريجياً على بيانات مخزنة داخل الشبكة العصبية ووفقاً لآلية التدريب من خلال خوارزمية التعلم (Learning Algorithms) ومن ثم فإن تطبيق او استخدام اسلوب الشبكات العصبية يعتبر وسيلة مضمونة واداة فعالة للوصول الى افضل تنبؤ بالقيم المستقبلية لظاهرة معينة .

3.2. مفهوم تقنية الشبكات العصبية الاصطناعية [2],[5]

تُعد الشبكات العصبية الاصطناعية (ANN) نظام ترابطي من وحدات المعالجة العصبية ، اي ان عنصر المعالجة (Processing Element) له القدره على العمل كذاكرة محلية واطراف لذلك ان كل عنصر يعمل بشكل غير مترام مع عمليات المعالجة المختلفة التي تتربط مع بعضها لتأخذ شكلاً هيكلياً محدداً. ان عملية المعالجة للبيانات بين الخلايا العصبية تتم بنقل الاشارات بواسطة العصبونات من خلال خطوط الربط وان كل خط ربط له وزن معين ويتم تحديد اشارات الأخراج من خلال تطبيق دالة غير خطية على كل عصبون (مجموع الاشارات الداخلة الموزونه) .

تتكون معمارية الشبكة العصبية الاصطناعية من الاجزاء الاتية : [2],[5]

1. **طبقة المدخلات (Input Layer)** : إذ تعتبر وظيفتها أستلام اشارات الادخال من خارج الشبكة.
2. **الطبقة المخفية (Hidden Layer)** : إذ تعتبر المستوى الثاني لمعمارية الشبكة العصبية الاصطناعية وتحتوي على العقد المخفية (Hidden Nodes) وهذه العقد تحتوي على اوزان (Weights) إذ تمثل الاتصالات بين الطبقات في الشبكات العصبية الاصطناعية (ANN) . ان الاوزان في الشبكات العصبية الاصطناعية تكون بشكل عام من ثلاث طبقات .
- a. **(Input to Hidden Weights)** : طبقة الوزن التي تربط بين طبقة المدخلات والطبقة المخفية (Hidden Weights) .
- b. **(Hidden to Output Weights)** : طبقة الاوزان التي تربط بين الطبقة المخفية وطبقة الاخراج .
3. **طبقة الاخراج (Output Layer)** : إذ تعتبر الطبقة الاخيرة التي تعطي العدد الحقيقي لسلسلة المعالجات التي تتم خلال الطبقات السابقة .
4. **دالة التنشيط (Activation Function)** : إذ تعتبر دالة لمعالجة البيانات الداخلة الى العقد العصبية .

2.3.1. انواع الشبكات العصبية الاصطناعية [2],[5]

توجد عدة انواع من الشبكات والتي تختلف تسميتها وخصائصها اعتماداً على عدد الطبقات (الشبكات العصبية ذات الطبقة الواحدة والشبكات العصبية متعددة الطبقات) وايضاً تعتمد على اسلوب بناء وارتباط الخلايا من طبقة لاخرى (كشبكات ذات التغذية الامامية والشبكات ذات التغذية الخلفية) .

1.2.3.1. الشبكة العصبية ذات التغذية الامامية: Feed Forward Neural Networks(FFNN) [2]

تُعد من اكثر الشبكات استخداماً وتتكون من طبقتين على الاقل وايضاً تحتوي على طبقات مخفية (Hidden Layer) توجد بين طبقة المدخلات وطبقة المخرجات ، وتنتقل العمليات الحسابية من طبقة المدخلات الى طبقة المخرجات عبر الطبقات المخفية اي في اتجاه واحد الى الامام .

2.2.3.1. الشبكات العصبية ذات التغذية الخلفية: Feed Back Neural Networks(FBNN) [2],[5]

تُعد من اكثر الشبكات العصبية الاصطناعية استخداماً لسهولة استخدامها في التعامل مع المسائل غير الخطية ، وهذا النوع من الشبكات يمكن ان يتألف من طبقة واحدة او عدة طبقات وتنتقل العمليات الحسابية عبر الطبقات المخفية باتجاه الامام ويمكن ان تنتقل مرة اخرى باتجاه الخلف لتصبح مدخلات وان هدف الشبكة هو تقليل الخطأ من خلال تعديل الاوزان وتعطي افضل النتائج الممكنة ومنها :

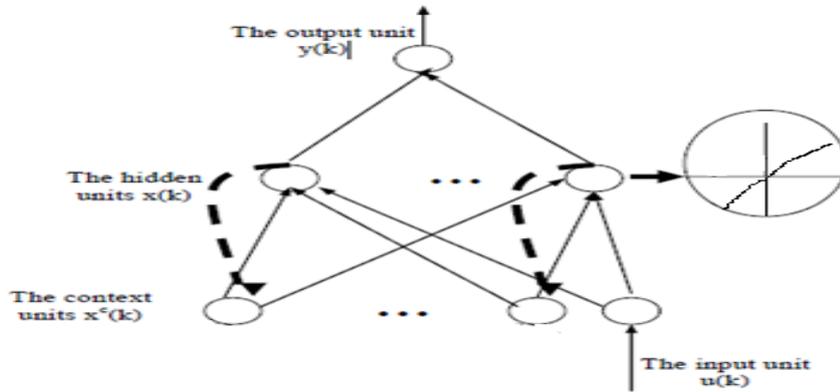
شبكة ايلمان العصبية التكرارية: Elman Recurrent Neural Network (ERNN) [3]

سيتم في هذه الفقرة تفصيل هيكلية وخوارزمية التدريب لشبكة ايلمان العصبية التكرارية التي يرمز لها اختصاراً (ERNN) ، وفضلاً عن وصف الانتشار الخلفي الحركي (Dynamic Back Propagation) الذي يرمز له (DBP) لتدريب الشبكة .

1.2.2.3.1. هيكلية (ERNN) [3] :

ان شبكة (ERNN) مقسمة بشكل عام الى أربعة طبقات : طبقة الادخال (Input Layer) ، الطبقة المخفية (Hidden Layer) ، طبقة السياق (Context Layer) ، طبقة الاخراج (Output Layer) . وان حلقة التغذية الامامية تستعمل للمعالجة من طبقة الادخال عبر الطبقة المخفية الى طبقة الاخراج ، وفي المقابل ان حلقة التغذية الخلفية توظف طبقة السياق التي تكون حساسة لزمن ادخال البيانات . حيث ان روابط الاتصال للتغذية الاسترجاعية الذاتية (Self-Feedback) يتم تقديمها الى طبقة السياق . والجدير بالذكر ان طبقتي الادخال والاخراج تتفاعل مع البيئة الخارجية ، بينما تكون طبقتي السياق والمخفية داخلية . كما ان طبقة الادخال ليست سوى عازله تمر خلالها الاشارات دون تغييرها ، وفي الوقت نفسه ان طبقة الاخراج هي وحده خطية تجمع الاشارات التي تغذيها . اما الطبقة المخفية فأنها تمتلك دوال تنشيط خطية او غير خطية ، ولكن في حالة الشبكة (ERNN) فان دوال التنشيط المستخدمة هي دوال غير خطية . وتستخدم طبقة السياق لحفظ التنشيط السابق للطبقات المخفية ويمكن اعتبارها بمثابة تأخير زمني بخطوة واحدة . ففي وقت محدد وليكن (K) فان التنشيط السابق للطبقات المخفية عند الزمن (K-1) والادخال الحالي عند الزمن (K) تستخدم بمثابة مدخلات للطبقات المخفية ، وفي هذه المرحلة تعمل الشبكة كشبكة تغذية وتنشر هذه المدخلات الى الامام للحصول على الاخراج .

المخطط (2) : رسم الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN



ان المدخلات الخارجية للشبكة تتمثل بـ (u(k)) والمخرجات (y(k)) . وان اجمالي المدخلات الى الاخراج (ith) طبقة مخفية ويرمز له Xi (k) ، كما يشار الى المخرجات (jth) ، طبقة السياق بالرمز $X_j^c(k)$. ان النمذجة الرياضية لشبكة ايلمان يمكن صياغتها على النحو الاتي :

$$v_i(k) = \sum_{j=1}^n w_{i,j}^x(k-1)x_j^c(k) + w_i^u(k-1)u(k), \quad (20a)$$

$$x_i(k) = f(v_i), \quad (20b)$$

$$x_j^c(k) = x_j^c(k-1) + \alpha x_j^c(k-1), \quad (20c)$$

$$y(k) = \sum_{i=1}^n w_i^y(k-1)x_i(k), \quad (20d)$$

إذ ان :

$w_i^u(.)$: وزن الاتصال بين طبقة الادخال والطبقة المخفية

$w_{i,j}^x(.)$: وزن الاتصال بين طبقة الاتساق والطبقة المخفية

$w_i^y(.)$: وزن الاتصال بين الطبقة المخفية وطبقة الاخراج.

n : عدد الطبقات المخفية / الاتساق .

ان الدالة (f) هي دالة تنشيط مستمرة والمعرفة على النحو الاتي :

$$f(v_i) = \left[\frac{e^{(sinh)} - e^{(-sinh)}}{e^{(sinh)} + e^{(-sinh)}} \right] \dots (21)$$

2.2.2.3.1. تدريب الشبكة ERNN [3]:

ان متجه التغذية الاسترجاعية $x^c(k) = \{x_j^c(k)\}$ هو $x(k-1)$ الذي يمثل من $w^x(k-2)x(k-2) + w^u(k-2)u(k-2)$. وبالتالي فإن $x^c(k)$ يعتمد على اوزان أمثال الزمن السابق ، وان الانتشار الخلفي الحركي (DBP) يستخدم لتكيف اوزان الشبكة في ذلك الوقت (Pham and Lin(1996) [6] ، بمعنى ان التأخير في الاتصال بخزن القيم من الخطوه السابقة يمكن ان يستخدم في الخطوه الحالية . وعند عرض زوج المدخلات والمخرجات على الشبكة في الزمن (k) ، تعرف دالة الخطأ عند مخرجات الشبكة كما يأتي:

$$E_k = \frac{1}{2} [y_d(k) - y(k)]^2 \dots (22)$$

إذ ان:

$y(k)$ ، $y_d(k)$: تمثلان المخرجات المطلوبة والحقيقية على التوالي .

واعتماداً على مربعات الخطأ المعروفة بالصيغة (22) فإن اوزان الشبكة (ERNN) يتم تكيفها باستخدام خوارزمية (DBP) في كل خطوه (K) وكما يأتي :

$$\frac{\partial E_k}{\partial w_i^y(k-1)} = -(y_d(k) - y(k)) \frac{\partial y(k)}{\partial w_i^y(k-1)} = -(y_d(k) - y(k)) x_i(k) \dots (23)$$

$$\begin{aligned} \frac{\partial E_k}{\partial w_i^u(k-1)} &= \left(\frac{\partial E_k}{\partial y(k)} \right) \left(\frac{\partial y(k)}{\partial x_i(k)} \right) \left(\frac{\partial x_i(k)}{\partial v_i(k)} \right) \left(\frac{\partial v_i(k)}{\partial w_i^u(k-1)} \right) \\ &= -(y_d(k) - y(k)) w_i^y(k-1) f_{vi} u(k) \dots (24) \end{aligned}$$

$$\begin{aligned} \frac{\partial E_k}{\partial w_{i,j}^x(k-1)} &= \left(\frac{\partial E_k}{\partial y(k)} \right) \left(\frac{\partial y(k)}{\partial x_i(k)} \right) \left(\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} \right) \\ &= (y_d(k) - y(k)) w_i^y(k-1) \left(\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} \right) \dots (25) \end{aligned}$$

$$\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} x_j^c(k) \dots (26)$$

وبتعويض الصيغة (26) في الصيغة (20c) ينتج ان :

$$\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} x_j(k-1) + \alpha \left(\frac{\partial x_i(k-1)}{\partial w_{i,j}^x(k-2)} \right) \dots (27)$$

إذ ان : f_{vi} تمثل مشتقة f بالنسبة الى (vi) . وبالتالي عندما $(\lambda = 1)$ فإن :

$$f_{vi} = f(vi) * (1 - f(vi))^2 \dots (28)$$

ان تعديل الوزن العام باستخدام (gradient descent) يكون : $\Delta w = -\eta \frac{\partial E_k}{\partial w}$..(29)

و ان : $\eta \in [0,1]$ وتمثل معدل التعلم .

3.2.2.3.1. خوارزمية الشبكة ERNN [3] :
 ان خوارزمية الشبكة يمكن توضيحها كالاتي :

$$\Delta w_i^y(k) = \eta(y_d(k) - y(k))X_i(k) \quad (30)$$

$$\Delta w_j^u(k) = \eta(y_d(k) - y(k))w_i(k-1)f_{vi}u(k) \quad (31)$$

$$\Delta w_{i,j}^x(k) = \eta(y_d(k) - y(k))w_i^y(k-1) \frac{\partial X_i(k)}{\partial X_{i,j}^x(k-1)} \quad (32)$$

$$\frac{\partial X_i(k)}{\partial X_{i,j}^x(k-1)} = f_{vi} \{X_j(k-1)\} + \sum_{l=1}^n w_{i,l}^x(k-1) \frac{\partial X_i(k-1)}{\partial X_{i,j}^x(k-2)} \quad (33)$$

إذ ان :

$$\frac{\partial X_i(k-1)}{\partial w_{i,j}^x(k-2)} = f_{vi} \sum_{m=1}^n w_{j,m}^x(k-2) \frac{\partial X_m(k-2)}{\partial w_{i,j}^x(k-3)} \quad , \quad f_{vi} = \frac{\partial f}{\partial v_i} = (1 - f^2(v_i)),$$

$$\frac{\partial X_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} X_j(k-1) \dots (34)$$

$$\Delta w_{i,j}^x(k) = \eta(y_d(k) - y(k))w_i^y(k-1)f_{vi}X_j(k-1) \dots (35)$$

وعند الحصول على اقل خطأ ممكن يتم الانتقال الى مرحلة التنبؤ ، وبعبارة اخرى يتم تعديل الاوزان وذلك بحساب $(w_i^u(k+1), w_{i,j}^x(k+1), w_i^y(k+1))$. وبالتالي تعدل الاوزان من طبقة الى طبقة اخرى سابقة وايجاد

القيمة التنبؤية من طبقة الاخراج وعلى النحو الاتي : $y(K+1) = \sum_{i=1}^n w_i^y x_i(K+1)$ وتجدر الاشارة هنا ،

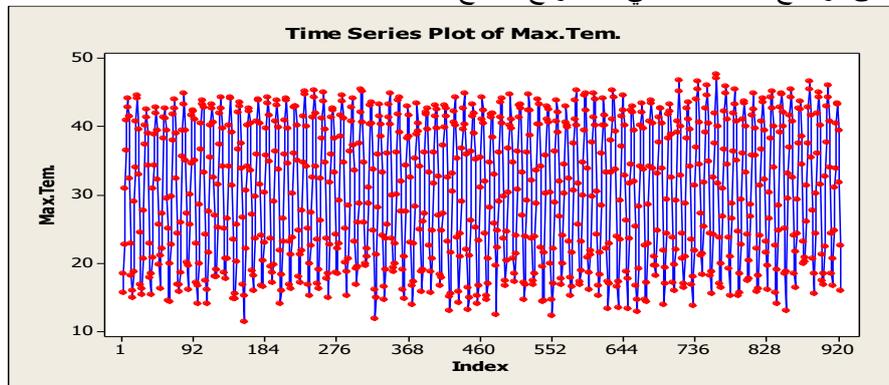
الى ان هذه الشبكة (ERNN) تختلف عن الشبكات التقليدية الاخرى التي تمتلك طبقتان ، وهذا الاختلاف في الطبقة الاولى حيث يكون لديها اتصال متكرر يتم تعليم الشبكة فيها بوجود المعلم .

الجانب التطبيقي

سيتم في هذا الفصل التطبيق الفعلي للبيانات الواقعية التي تمثل سلسلة المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد من الفترة (1937 – 2016) [1] لغرض التنبؤ بالمعدلات الشهرية لدرجات الحرارة بأستعمال الانموذج الهجين: ARIMA(p,d,q)(P,D,Q)S – ERNN .

1.3. الانموذج الموسمي المضاعف ARIMA(p,d,q)(P,D,Q)s :

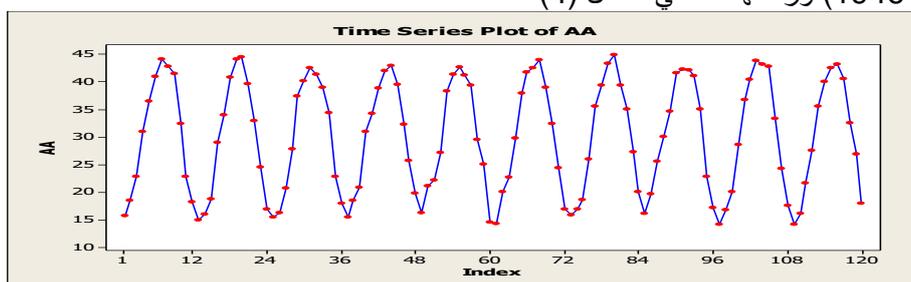
ان الخطوة الاولى في تحليل بيانات السلسلة الزمنية هي رسمها لبيان استقراريتها أو احتواءها على تأثيرات موسمية أو قيم شاذة اي التعرف على سلوكيتها وقد رسمت للفترة من (1937–2013) كما في الشكل (3) ، إذ تم الاعتماد على برنامج Minitab في استخراج النتائج .



الشكل (3)

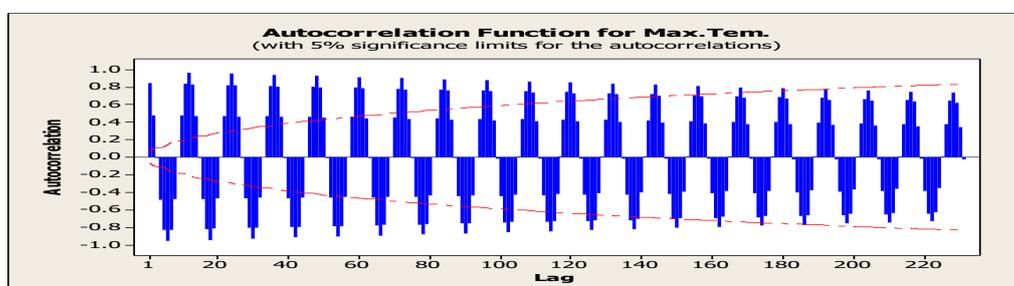
رسم بيانات المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للفترة من (1937-2013)

ونلاحظ ان الشكل (3) لم يكن واضحاً لبيان سلوكية السلسلة الزمنية لذا تم اخذ مجموعة جزئية للفترة من (1937 – 1946) ورسمها كما في الشكل (4)



الشكل (4)

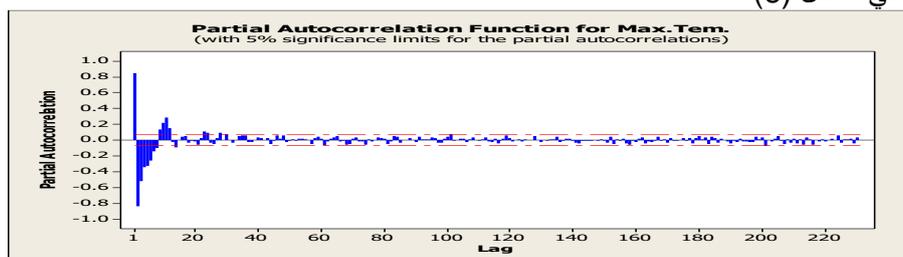
رسم بيانات المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للفترة من (1937–1946) ومن خلال الشكل (4) نجد ان السلسلة مستقرة في التباين ويتضح ان السلسلة تعيد نفسها خلال كل فترة زمنية قدرها (12) شهر وتحتوي ايضاً على اتجاه عام . وقد تم ايجاد قيم معاملات الارتباط الذاتي للسلسلة . ورسمت هذه المعاملات لتوضيح سلوكية دالة الارتباط الذاتي كما في الشكل (5)



الشكل (5)

دالة الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد

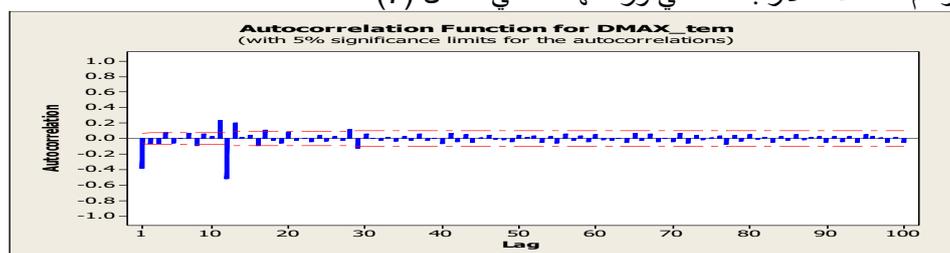
من خلال ملاحظة معاملات الارتباط الذاتي ودالة الارتباط الذاتي نجد ان السلسلة تحتوي على اتجاه عام إذ نجد ان القيم معنوية جداً وتزداد معنويتها في الفترات 12، 24، 36، 48، ... مما يشير الى ان السلسلة تعاني من عدم الاستقرار في المتوسط واحتوائها على تأثيرات موسمية . كما تم حساب ورسم معاملات الارتباط الذاتي الجزئي كما في الشكل (6)



الشكل (6)

دالة الارتباط الذاتي الجزئي للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد

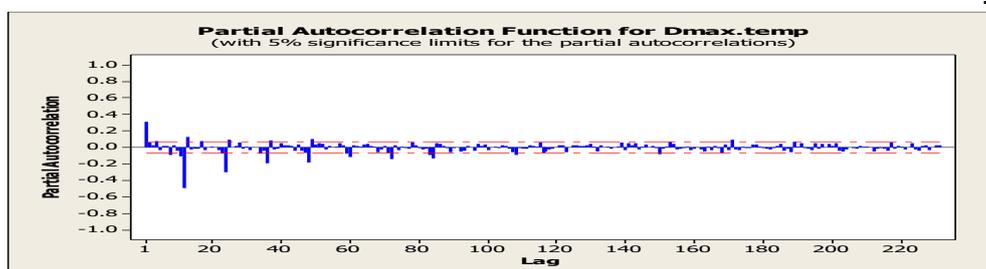
ولقد تم اخذ الفروق الاعتيادية ($d = 1$) والموسمية ($D = 12$) لسلسلة بيانات درجات الحرارة العظمى واعيد حساب ورسم معاملات الارتباط الذاتي ورسمها كما في الشكل (7)



الشكل (7)

دالة الارتباط الذاتي بعد اخذ الفروق الاعتيادية والموسمية للسلسلة الزمنية

من خلال القيم المستخرجة لمعاملات الارتباط الذاتي والرسم نجد ان القيم معنوية فقط في الازاحات الاولى والحادية عشر والثانية عشر والثالثة عشر مما يشير الى ان السلسلة قد استقرت في المتوسط وتخلصت من اثر الموسمية . كما تم حساب ورسم معاملات الارتباط الذاتي الجزئي للسلسلة كما في الشكل (8) وهي تسلك سلوك تنازلي .



الشكل (8)

يبين دالة الارتباط الذاتي الجزئي بعد اخذ الفروق الاعتيادية والموسمية للسلسلة الزمنية

ومن خلال دالتي الارتباط الذاتي والجزئي يمكن ان نشخص انموذج مقترح لتمثيل هذه البيانات الا وهو الانموذج الموسمي المضاعف $SARIMA(0,1,1)_{12}(0,1,1)$ والذي تكتب معادلته كالآتي :

وقد تم تقدير معاملات الانموذج كما في الجدول (1) :

جدول (1)

يمثل تقديرات معاملات الانموذج الموسمي المضاعف واختبارها

Type	Coef	SE Coef	T	P
MA 1 انموذج الاوساط المتحركة	0.8356	0.0183	45.55	0.000
SMA 12 انموذج الاوساط المتحركة الموسمي	0.9639	0.0115	83.9	0.000

$$(1 - B)(1 - B^{12})X_t = (1 - 0.8356)(1 - 0.9639)a_t$$

بمتوسط مربعات الخطأ 2.51 . ومن خلال الجدول نجد ان :

1- ان قيمة معاملات الانموذج المقدره اقل من 1 وبالتالي حققت شرط الانعكاسية

2- ان المعلمات معنوية إذ ان قيمة $\rho = 0.00$ وبالتالي رفضت الفرضيتين :-

$$H_0 : \nu_1 = 0 \quad \text{vs} \quad H_1 : \nu_1 \neq 0$$

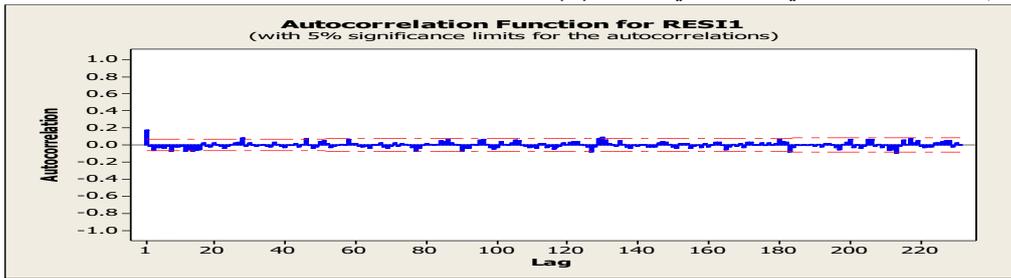
$$H_0 : \nu_{12} = 0 \quad \text{vs} \quad H_1 : \nu_{12} \neq 0$$

وقد تم حساب البواقي كما تم حساب معاملات الارتباط الذاتي وحسبت احصاءة Q (Box-Pierce) والتي

بلغت 15.3 وعند مقارنتها مع قيمة χ^2 الجدولية بدرجة حرية 98 ومستوى معنوية 0.05 وجد انها تساوي

77.93 وبالنتيجة تقبل الفرضية: $H_0 : \rho_{at(k)} = 0 \quad \text{vs} \quad H_1 : \rho_{at(k)} \neq 0$

وتم رسم دالة الارتباط الذاتي لها كما في الشكل (9)



الشكل (9)

دالة الارتباط الذاتي للبقايا

من خلال الشكل نجد ان معاملات الارتباط الذاتي محصورة بين الحدين الاعلى والادنى وبالتالي فإن الاخطاء المستخرجه (البواقى) ماهي الا متغيرات عشوائية غير مترابطة ومنها نستدل ان الانموذج كفوء وجيد وملائم لتمثيل بيانات هذه السلسلة .

2.3. الانموذج الهجين ARIMA(p,d,q)(P,D,Q)_s – ERNN

لايجاد التقديرات للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنوات (2014 ، 2015 ، 2016) باستخدام الانموذج الهجين ARIMA(p,d,q)(P,D,Q)_s – ERNN سيتم جمع التقديرات الناتجة باستخدام الانموذج الموسمي المضاعف $(1 - B)(1 - B^{12})X_t = (1 - 0.8356)(1 - 0.9639)a_t$ مع التقديرات المستخرجة لبواقى هذا الانموذج بعد ان تم نمذجتها باستخدام الشبكات العصبية الاسترجاعية (ELMAN) ووفق ماتم ذكره في الجانب النظري كما في الجدول (2) .

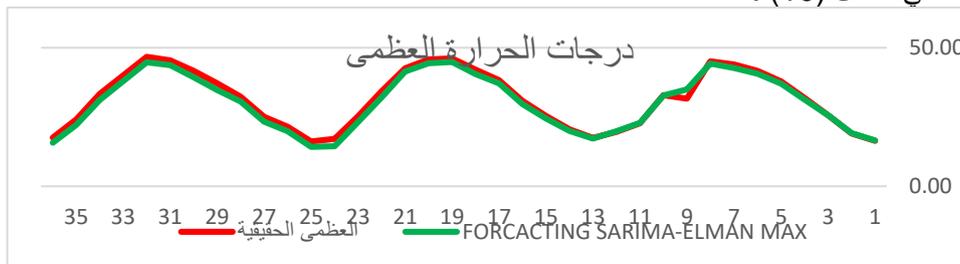
جدول (2)

يمثل التقديرات لدرجات الحرارة العظمى للانموذج الهجين SARIMA - ELMAN للسنوات (2014، 2015، 2016)

الشهر	تقديرات 2014	تقديرات 2015	تقديرات 2016
1	16.5061	17.1938	14.2197
2	19.1259	19.9997	19.8099
3	25.6618	24.4464	23.3342
4	31.3048	29.6665	30.6378
5	37.0286	37.1744	34.6896
6	40.584	40.5582	39.35
7	42.6594	44.9218	43.7082
8	44.3121	44.4633	44.804
9	35.0064	41.4618	37.9575
10	32.8092	32.0772	31.1932
11	22.8245	23.1892	22.1444
12	19.8355	14.5023	15.6627

3.3. مقاييس المفاضلة

لغرض المقارنة بين التقديرات المستخرجة للانموذج الهجين SARIMA-ELMAN مع القيم الحقيقية تم رسمها كما في الشكل (10) .



الشكل (10)

يوضح رسم تقدير الانموذج الهجين SARIMA-ELMAN مع القيم الحقيقية

ومن خلال الرسم نجد ان قيم التقديرات الانموذج الهجين SARFIMA – ELMAN تكون مطابقة ومتفقة من ناحية سلوكيتها مع القيم الحقيقية . كما تم حساب مقاييس المفاضلة والتي هي متوسط مطلق الخطأ (MAE) ومتوسط الانحراف المطلق (MAD) ومتوسط مطلق الخطأ النسبي (MAPE) والجذر التربيعي لمتوسط مربعات الخطأ (RMSE) ومتوسط مربعات الخطأ (MSE) والخطأ المعياري للتنبؤ (SEP) للانموذج والهجين كما في الجدول (3) .

جدول (3)

يبين حساب المقاييس الاحصائية للانموذج الهجين لدرجات الحرارة العظمى

الانموذج	R ²	MSE	RMSE	MAD	MAE	MAPE	SEP
الانموذج الهجين SARIMA-ELMAN	0.92	2.505	1.582	0.037	1.340	4.662	5.20

ومن خلال نتائج الجدول اعلاه تبين ان الانموذج الهجين SARIMA – ELMAN جيد ويمتلك قيم صغيرة للمقاييس الاحصائية (MSE, RMSE, MAD, MAE, MAPE, SEP) وامتلاكه قيمة عالية لـ R² . فقد تم استخدامه لحساب التنبؤات المستقبلية للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنيين 2017 – 2018 وكالاتي : بأعادة بناء الانموذج للبيانات للفترة من (1937 – 2016) إذ تم تقدير معاملات الانموذج الموسمي واختبارها واختبار كفاءة الانموذج باختبار البواقي وتم حساب التنبؤات المستقبلية كما تم استخراج بواقي هذا الانموذج للبيانات من (1937 - 2016) إذ تم نمذجتها بأسلوب الشبكات العصبية الاسترجاعية شبكة ايلمان ELMAN لأستخراج التنبؤات المستقبلية وبعدها تم جمع التنبؤات الناتجة من الانموذج الموسمي (SARIMA) مع تنبؤات البواقي الناتجة من الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN لاجاد التنبؤات النهائية للانموذج الهجين للفترة (2017 – 2018) .

جدول (4)

يبين التنبؤات لدرجات الحرارة العظمى للانموذج الهجين SARIMA – ELMAN للفترة 2017 – 2018

الشهر	تنبؤات 2017	تنبؤات 2018
1	19.7183	14.3645
2	21.8726	18.9342
3	26.5591	26.4007
4	32.3663	31.2945
5	37.8035	38.8240
6	43.7227	41.2929
7	44.7516	43.5938
8	46.2717	45.1094
9	42.1706	42.5621
10	36.3901	32.9368
11	23.9785	23.1455
12	18.4874	17.4938

1.4. الاستنتاجات (Conclusions)

لقد تمخض هذا البحث للموضوع عن جملة من الاستنتاجات تخص التحليل الاحصائي للانموذج الهجين (الانموذج الموسمي المضاعف مع الشبكة العصبية الاسترجاعية شبكة ايلمان والذي يرمز له بالرمز ARIMA(p,d,q)(P,D,Q)S – ERNN وفيما يلي نصها :

1. ان المعدلات الشهرية لدرجات الحرارة العظمى تمثل سلسلة زمنية موسمية إذ تعيد سلوكها كل سنة كما في الشكل (4)
2. عند رسم التقديرات المستخرجة للانموذج الهجين (الانموذج الموسمي المضاعف مع انموذج الشبكة العصبية الاسترجاعية شبكة ايلمان) للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنوات 2014 – 2016 مع القيم الحقيقية لتلك السنوات كما في الشكل (10) وجد ان تقديرات الانموذج الهجين SARFIMA – ELMAN تكاد تكون قريبة من القيم الحقيقية .
3. وجد ان الانموذج الهجين SARIMA – ELMAN الذي وضع لتمثيل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد يمتلك قيم صغيرة لـ (MSE , RMSE , MAD , MAE , SEP) وقيمة عالية لـ R² .
4. نظراً لأمتلاك الانموذج الهجين (SARIMA(p,d,q)(P,D,Q)S – ERNN) قيمة صغيرة للمقاييس الاحصائية المستخدمة (MSE , RMSE , MAD , MAE , SEP) وقيمة عالية لـ R² فقد تم استخدامه لحساب التنبؤات المستقبلية للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للفترة من كانون الثاني / 2017 الى كانون الاول / 2018 من خلال اعادة بناء الانموذج للبيانات للفترة من (1937-2016) كما في الجدول (4) .

2.4 . التوصيات (Recommendation)

- من خلال النتائج والدراسات المستقبلية التي توصل اليها الباحثين نوصي بالأتي :
1. استخدام الانموذج الهجين (الانموذج الموسمي المضاعف مع أنموذج الشبكة العصبية الاصطناعية شبكة ايلمان (ELMAN) من قبل الهيئة العامة للأنواء الجوية والرصد الزلزالي والجهات ذات العلاقة بالموضوع للتنبؤ المستقبلي للمعدلات الشهرية العظمى لمدينة إمتلاكه قيم صغيرة لهذه المقاييس (, MSE , RMSE , MAD , MAE ,) SEP وقيمة عالية لـ R^2 .
 2. اجراء دراسات للتنبؤ بدرجات الحرارة العظمى في مدن عراقية اخرى غير مدينة بغداد.
 3. اجراء دراسات لطواهر مناخية اخرى مثل كمية الامطار الساقطة ، سرعة الرياح ، السطوح الشمسي في مدن العراق باستخدام الانموذج الهجين (الأنموذج الموسمي المضاعف مع انموذج الشبكة العصبية الاسترجاعية شبكة ايلمان (ELMAN) .
 4. نقترح دراسة استخدام الشبكة العصبية متعددة الطبقات ذات التغذية الامامية Multiplicative Feed Forward Neural Networks بدلاً من الشبكة العصبية الاسترجاعية كأنموذج هجين ومقارنة نتائجها مع نتائج البحث .
 5. نقترح دراسة استخدام الشبكة العصبية الاسترجاعية (جوردن) بدلاً من شبكة ايلمان ومقارنة نتائجها مع نتائج البحث.

المصادر العربية ARABIC REFERENCES

1. الهيئة العامة للأنواء الجوية والرصد الزلزالي / قسم المناخ ببيانات غير منشورة .
2. عبد الجادر ، د. بثينة ، الساعدي ، علي احمد (2016) " استخدام نماذج السلاسل الزمنية الهجينة وغير الهجينة للتنبؤ بإعداد المسافرين لمطار بغداد الدولي " قسم الاحصاء – كلية الإدارة والاقتصاد/الجامعة المستنصرية .

المصادر الاجنبية FOREIGN REFERENCES

1. Awad, Hamdi A. "A new version of Elman neural networks for dynamic systems modeling." In The 1 th IEEE International Workshop on Advanced Control Circuits and Systems, ACCS'05, IFAC
2. Box G, E.P & Jenkins, G. M.,(1976), "Time series analysis forecasting and control sanfrancisco Helden-day" .
3. Bukhari.S,Adnan.H.,Hanif,(2008),"Inflation Forecasting Using Artificial Neural Networks", Journal of Neural Networks, IEE .
4. Chen, K.Y., Wang, C.H.,(2007), "A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan", Expert Systems with Applications 32,254–264.
5. Jeong, Chulwoo, and Myung Suk Kim. "Comparison Studies of Hybrid and Non-hybrid Forecasting Models for Seasonal and Trend Time Series Data."Journal of Intelligence and Information Systems 19, no. 1 (2013): 1-17.
6. Tseng, Fang-Mei, Hsiao-Cheng Yu, and Gwo-Hsiung Tzeng. "Combining neural network model with seasonal time series ARIMA model." Technological Forecasting and Social Change 69, no. 1 (2002): 71-87.
7. Wei,Liang-Ying ,(2015)," A Hybrid Model Based on ANFIS and Empirical Mode Decomposition for Stock Forecasting", Journal of Economics, Business and Management, Vol. 3, No. 3.
8. Zhang, G.-P. , (2003),"Time series forecasting using a hybrid ARIMA and neural network model", Neurocomputing, 50,159–175.