

التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى في مدينة بغداد بأستعمال الانموذج الهجين وغير الهجين

Predicting the monthly maximum temperature rates in Baghdad using hybrid and non-hybrid models

أ.م.د. بثينة عبد الجادر عبد العزيز الباحث علي طارق السلام

الجامعة المستنصرية / كلية الإدارة والاقتصاد / قسم الإحصاء

المستخلص

يُعد التنبؤ من المواضيع التي اكتسبت أهمية كبيرة في كثير من الدراسات الديموغرافية والاقتصادية والأنوائية وغيرها، إذ إن من خلال عملية التنبؤ يمكن لصناع القرار من رسم السياسات المستقبلية للظاهرة المدروسة، لذا تناول هذا البحث دراسة نماذج السلاسل الزمنية الموسمية المنفردة والمتمثلة بالانموذج الموسمي الكسري $ARFIMA(p,d,q)(P,D,Q)_s$ عندما تكون السلسلة الزمنية تحتوي على المركبة الخطية وانموذج الشبكات العصبية الاسترجاعية شبكة ايلمان ELMAN عندما تحتوي السلسلة على المركبة اللاخطية، والانموذج الهجين الناتج أو المتولد من دمج الانموذجين المذكورين بأعتبار السلسلة الزمنية تحتوي على المركبتين الخطية واللاخطية لتمثيل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للفترة (1937 – 2013) والتنبؤ بها مستقبلاً، ولغرض المقارنه بين هذه النماذج تم استخراج مجموعة من المقاييس الاحصائية $(R^2, MSE, RMSE, MAPE, MAE, SEP, MAD)$ إذ تفوق انموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان ELMAN) على الانموذجين الاخرين لامتلاكه القيم الدنيا لهذه المقاييس، لذا تم استخدامه في عملية التنبؤ للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنتين 2017 – 2018.

Abstract

Prediction is one of the topics that has gained great importance in many demographics, economic, aerodynamic and other studies, since through the forecasting process decision makers can draw future policies for the phenomenon studied. Therefore, this study examines the study of the models of the single seasonal time series of the $ARFIMA(p, d, q)(P, D, Q)_s$ when the time series contains the linear composition and the model of the ELMAM when the chain contains the vehicle Nonlinearity and The hybrid model resulting from the merging of these two models as the time series contains the linear and nonlinear vehicles to represent the monthly averages of the maximum temperatures for the city of Baghdad for the period (2013 - 1937), And for the purpose of comparing these models, a set of statistical measures

(R^2 , MSE, RMSE, MAPE, MAE, SEP, MAD) were extracted. The ELMAN model exceeded the other two models for having the minimum values of these measures. Therefore, it was used in the forecasting of the monthly average temperatures for the city of Baghdad for the years 2018-2017.

الكلمات المفتاحية: الانموذج الهجين, مفهوم الذاكرة الويلة للسلسلة الزمنية الموسمية, انموذج الانحدار الذاتي والاوساط المتحركة الموسمي الكسري, طريقة الـ CSS, طريقة Two – staged, شبكة Elman العصبية التكرارية.

المقدمة Introduction

ان عملية التخطيط الاستراتيجي لظاهرة معينة وعملية اتخاذ القرارات المناسبة تعتمد بشكل اساس على عملية التنبؤ المستقبلي الدقيق من خلال وضع نماذج لتمثيل السلسلة الزمنية الموسمية المدروسة لذا ظهرت اساليب متعددة للتنبؤ منها معلمي وخطي كالانموذج الموسمي المضاعف $SARIMA(p,d,q)(P,D,Q)s$ عندما تكون الفروق الاعتيادية والموسمية ذات اعداد صحيحة وكسرية. والتي استخدمت في مجالات عديدة منها الانوائية والاقتصادية وغيرها والاخر لامعلمي ولاخطي كنماذج الشبكات العصبية الاصطناعية المتعددة المراحل الامامية والاسترجاعية.

ولقد اجريت دراسات من قبل العديد من الباحثين في ايجاد انموذج اخر الا وهو الانموذج الهجين الذي يدمج بين النماذج المذكورة وذلك لغرض تحسين التنبؤات المستقبلية بغية اقترابها من القيم الحقيقية للظاهرة المدروسة.

وقد ضم البحث جانبان الاول نظري تناول الانموذج الهجين والانموذج الموسمي الكسري وانموذج الشبكات العصبية الاسترجاعية – شبكة ايلمان، والثاني تطبيقي إذ تم التطبيق على بيانات واقعية تمثل المعدلات الشهرية لدرجات الحرارة العظمى في مدينة بغداد للفترة من 1937-2016 كما تم استخدام المقاييس الاحصائية لغرض المقارنة بين هذه النماذج وبالتالي الحصول على الانموذج الجيد لاستخدامه لحساب التنبؤات للسنتين 2017-2018

هدف البحث Objective of Research

يهدف البحث الى استخدام الانموذج الهجين للسلسلة الزمنية الموسمية للتنبؤات المستقبلية ومقارنته مع الانموذجين المنفردين (الانموذج الموسمي الكسري $SARFIMA(p,d,q)(P,D,Q)$ ذات الفروق الكسرية (d,D) و(انموذج الشبكات العصبية الاسترجاعية - شبكة ايلمان) من خلال جملة من المقاييس الاحصائية (R^2 , MAE, MSE, MASE, MAPE, MPE, RMSE) لأختيار الانموذج الافضل واستخدامه للتنبؤ بدرجات الحرارة العظمى لمدينة بغداد.

الجانب النظري

1. الأنموذج الهجين Hybrid Model^[17]

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)^[18] 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 أن التنبؤات المستخرجة تنبؤات دقيقة . اما عملية التهجين في السلاسل الزمنية الموسمية فقد تمت من قبل الباحث (Chen)^[10] عام 2007 إذ استطاع ان يمثل المركبة الخطية للسلسلة الزمنية الموسمية بالأنموذج SARIMA والبواقي المستخرجة من هذا الأنموذج تمثل بالأنموذج الشبكات العصبية المتعددة المراحل وهناك أيضاً عملية تهجين اخرى إذ يتم اعتبار البواقي المستخرجة من انموذج السلسلة الزمنية الموسمية والتنبؤات المستخرجة مع القيم الحقيقية للسلسلة الزمنية بازاحات مختلفة كمدخلات للشبكة العصبية المتعددة المراحل ذات الانتشار الخلفي كما ورد في البحث المقدم من قبل (Fang)^[16] واخرون. في هذه الرسالة سيتم استخدام الأنموذج الهجين الناتج من دمج احد نماذج السلسلة الزمنية الموسمية مع انموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان Elman) .

1.1. الأنموذج الهجين The Hybrid Model (SARIMA-ERNN)^[17]

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

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

أذ 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 باستخدام الأنموذج الهجين بمرحلتين هما:

المرحلة الاولى: ان المركبة الخطية (L_t) للسلسلة الزمنية الموسمية تتمثل بالأنموذج الموسمي المضاعف الكسري الذي يرمز له بالرمز SARFIMA(p,d,q)(P,D,Q)_s . إذ ان d , D الفروق الاعتيادية والموسمية على التوالي بأعداد كسرية، وتستخرج التنبؤات المستقبلية للأنموذج الخطي . ان البواقي المستخرجة من هذا الأنموذج وان تعدت مرحلة دقة التشخيص (Diagnostic Checking) فإنها تحمل معلومات عن السلسلة الزمنية يمكن نمذجتها بأحد نماذج الشبكات العصبية.

المرحلة الثانية: ان المركبة اللاخطية (N_f) والمتمثلة بالبواقي المستخرج من النموذج الخطي توصف بأنموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان Elman). ومن هذا النموذج تُستخرج التنبؤات المستقبلية، وعليه فإن التنبؤات النهائية للسلسلة الزمنية تكون بجمع التنبؤات المستقبلية المستخرجه بالمرحلتين وفق المعادلة:

$$\hat{X}_t = \hat{L}_t + \hat{N}_t \dots (2)$$

الشكل رقم (1) يُبين عملية بناء النموذج الهجين واستخراج التنبؤات المستقبلية للسلسلة الزمنية [17]



لذا سيتم شرح مفصل للنموذج الموسمي المضاعف الكسري (The Fractional Multiplicative Sasonal Model) والذي يرمز له بالرمز SARFIMA على افتراض ان الفروق الاعتيادية والموسمية ذات اعداد كسرية إذ تم ذكر الخصائص النظرية وطرائق تقدير الفروق الاعتيادية والموسمية d, D على التوالي ومعلمات الانموذج. ويتضمن الجانب النظري ايضاً شرح لانموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان Elman) إذ تم التعريف على الشبكات العصبية المتعددة وهيكلية هذه الشبكات وخوارزمية تحديث الاوزان .

2.1. مفهوم الذاكرة الطويلة للسلاسل الزمنية الموسمية [15]

The concept of long memory time series seasonal

اولى الباحثون اهتماماً خاصاً بدراسة السلاسل الزمنية ذات الذاكرة الطويلة ، حيث تم تعريف هذا النوع من السلاسل في حقل الزمن (Time Domain) والتكرار (Frequency Domain) .

وقد قدم الباحث (OPPENHELM, OULD HAYE, 2000)^[15] تعريفاً لدالة التباين والتباين

$$\sum_{h=-\infty}^{\infty} |\sigma(h)| = \infty \quad \dots (3) \quad \text{المشترك وكما يأتي:}$$

$$\sigma(h) = |h|^{-(1+2d)} l_1(h) \quad \dots (4)$$

$$\sigma(h) = E(Z_t, Z_{t+k}) \dots (5) \quad \text{اذ ان } (l_1) \text{ تتغير ببطء في المالا نهائيه. وان:}$$

ان السلسلة الزمنية ذات الذاكرة القصيرة يمكن معرفتها من خلال دالة الارتباط الذاتي اذ ان دالة الارتباط الذاتي تتناقص تدريجياً نحو الصفر، الا ان هذه السلسلة عندما تكون ذات ذاكرة طويلة فأن دالة الارتباط الذاتي تسلك سلوك القطع الزائد ولا تتحول تدريجياً نحو الصفر. وبناءً عليه، فإن التباينات المشتركة سوف تتناقص ببطء متبعة سلوك القطع الزائد (Hyperbolic).

$$\sigma(h) \sim C_1 h^{\alpha-1} \quad \dots (6)$$

$$C_1 = 2C_0 \Gamma(1-\alpha) \sin\left(\frac{\alpha}{2}\pi\right) \quad \dots (7) \quad \text{وعندما } (h \rightarrow \infty):$$

حيث ان (C_0) كمية ثابتة، وان $\Gamma(\cdot)$ تمثل دالة كاما (Gamma Function).

1.2.1. دالة كثافة الطيف : (spectral density)^[15]

لتكن $\{X_t\}$ عملية مستقرة في حقل التكرار بدالة كثافة الطيف $f(w)$ تبدي ذاكرة طويلة (long-memory) او اعتماد المدى الطويل (Long – Range dependence) اذا كان :

$$f(w) \sim C|w|^{-\alpha} \quad 0 < C < \infty, \quad 0 < \alpha < C_1 \quad \dots (8)$$

$$f(0) = \infty$$

$$f(w) = |w|^{2d} l_2(w) \quad \dots (9)$$

اذ ان (l_2) تتناقص ببطء شديد الى الصفر.

2.2.1. النموذج الانحدار الذاتي والاوساط المتحركة الموسمي الكسري التكاملي^[6,13,14]

The Seasonal Fractional Integrated Autoregressive Moving Average Model

درست في الاونة الاخيرة السلاسل الزمنية ذات الذاكرة الطويلة وقد أولت النماذج المختلطة المتكاملة كسرياً SARFIMA(p,d,q)(P,D,Q)_s اهتماماً بالغاً لدى الباحثين والمختصين عندما تكون قيمة معلمة الفروق (d,D) قيماً غير صحيحة كسرية، يظهر السلوك الموسمي لكثير من السلاسل الزمنية في

التطبيقات المختلفة اضافة الى صفة الذاكرة الطويلة عندئذ يستخدم نموذج الانحدار الذاتي والايواسط المتحركة الموسمي الكسري التكاملي لتمثيل هذه السلاسل الذي يرمز له بالرمز $SARFIMA(p,d,q)(P,D,Q)_s$ [13] [14]

بعض التعاريف والخصائص للانموذج :

تعريف (1) [6]: على فرض ان السلسلة الزمنية $\{X_t\}_{t \in \mathbb{Z}}$ عملية عشوائية مستقرة بداله طيفية $f_X(\cdot)$ ، وعلى فرض ان $b \in (0,1)$ وان $C_f > 0$ و $G \in [0, \pi]$ بحيث ان

$$f_X(w) \sim C_f |w - G|^{-b}, \quad W \rightarrow G \quad \dots (10)$$

عندئذ فان $\{X_t\}_{t \in \mathbb{Z}}$ سلسلة زمنية ذات ذاكرة طويلة (Long memory) . وعندما تكون $b \in (-1,0)$ ، فان العملية $\{X_t\}_{t \in \mathbb{Z}}$ انها تمتلك خاصية الاعتماد المتوسط أو الذاكرة المتوسطة (Intermediat Dependence Property) .

تعريف (2) [6]: لتكن $\{X_t\}_{t \in \mathbb{Z}}$ عملية عشوائية تمثل بالانموذج

$$\omega(B)\omega(B^S)(1-B)^d(1-B^S)^D(X_t - \mu) = \nu(B)\nu(B^S)\varepsilon_t \quad \dots (11)$$

اذ ان : μ : متوسط السلسلة الزمنية X_t

ε_t : عملية الخطأ العشوائي (White Noise) بمتوسط (صفر) وتباين ثابت σ_ε^2

S : الفترة الموسمية وتنتمي الى مجموعة الاعداد الصحيحة الموجبة (N)

B : عامل الازاحة الخلفي غير الموسمي بحيث ان $BX_t = X_t - X_{t-1}$

B^{S*} : عامل الازاحة الموسمي بحيث ان $B^{S*}X_t = X_t - X_{t-S}$

$\nabla^d = (1-B)^d$: عامل الفرق الاعتيادي

$\nabla_r^D = (1-B^S)^D$: عامل الفرق الموسمي

وان الـ $\omega(B)$ ، $\nu(B)$ ، $\omega(B^S)$ ، $\nu(B^S)$ متعددات الحدود من الدرجة p ، q ، P ، Q على التوالي اذ تم تعريفها سابقاً . وينبغي ان تكون جذور متعددات الحدود تقع خارج الدائرة التي نصف قطرها يساوي واحد وذلك لتحقيق شرطي الاستقرار (Stationary) والانعكاسية (Invertible) .

1- عندما تكون الـ $Q = P = D = 0$ يتم الحصول على الانموذج الاتي :

$$\omega(B)(1-B)^d(X_t - \mu) = v(B)\varepsilon_t \quad \dots (12)$$

الذي يمثل النموذج الانحدار الذاتي والايواسط المتحركة الكسري التكاملي Autoregressive Fractionally Integrated Moving Average Model الذي يرمز له بالرمز ARFIMA(p,d,q) وان $d < 1$ والذي درس بشكل تفصيلي في عام (2014) من قبل الباحثان (الموسوي وحربي)^[1] بدراسة محلية موسعة للسلاسل الزمنية ذات الذاكرة الطويلة عندما تكون معلمة الفروق الاعتيادية d في المجال (0,0.5) ، ان قيمة هذه المعلمة جعلت ان تكون دالة الارتباط الذاتي للسلسلة لا تسلك السلوك الاسي اي انها لا تتناقص بشكل اسّي (تؤول الى الصفر) بل تسلك سلوك القطع الزائد. وان الدالة الطيفية للسلسلة الزمنية تكون غير محدوده Unboundedness .

2- عندما $d = 0, p = 0 = q$ يتم الحصول على الانموذج الاتي :

$$\omega(B^S)(X_t - \mu) = v(B^S)\varepsilon_t \quad \dots (13)$$

الذي يمثل النموذج الانحدار الذاتي والايواسط المتحركة الموسمي

The Seasonal Autoregressive Moving Average Model يرمز له بالرمز SARMA(P,Q)_S

3- عندما تكون العملية $p = q = P = Q = 0$ فإن الانموذج يكون :

$$(1-B)^d(1-B^S)^D(X_t - \mu_t) = \varepsilon_t \quad \dots (14)$$

والذي يرمز له بالرمز SARFIMA(0,d,0)(0,D,0)_S .

4- عندما تكون العملية $p = q = P = Q = d = 0$

(The Seasonal Fractionally Integrated Process)

$$(1-B^S)^D(X_t - \mu_t) = \varepsilon_t \quad \dots (15) \quad \text{فإن الانموذج يكون :}$$

والذي يرمز له بالرمز SARFIMA(0,D,0)_S .

1.2.2.1. العملية SARFIMA(0,D,0)_S^[3,5]

$$(1-B^S)^D X_t = \varepsilon_t \quad \dots (16) \quad \text{ان العملية SARFIMA(0,D,0) تكتب بالشكل الاتي :}$$

وبمتوسط صفر وان $S \in N$ والتي تمثل طول الفترة الموسمية ويسمى بالعملية الموسمية الكسرية التكاملية (Seasonal Fractionally Integrated Process) ويرمز له اختصاراً بـ (SFI) . والخصائص النظرية عن هذا النموذج تكون على النحو الاتي :

1- عندما $D > -0.5$ فإن العملية $\{X_t\}_{t \in \mathbb{Z}}$ هي عملية انعكاسية يمكن كتابتها بدلالة القيم السابقة $\{X_t\}_{t \in \mathbb{Z}}$ كعملية انحدار ذاتي غير منتهية :

$$\pi(B^S)X_t = \varepsilon_t \quad \dots (17)$$

والجدير بالذكر ان عامل الفروق الموسمية للعملية $\{X_t\}_{t \in \mathbb{Z}}$ تعرف باستخدام متسلسلة ذي الحدين (Binomial Series) [7] :

$$(1 - B^S)^D = \sum_{k=0}^{\infty} \binom{D}{k} (-B^S)^k = 1 - \frac{D}{1} B^S + \frac{D(D-1)}{2} B^{2S}, \dots \dots (18)$$

ويمكن حساب الفروق الموسمية للعملية $\{X_t\}_{t \in \mathbb{Z}}$ بدلالة القيم السابقة من خلال سلسلة مكلورين وكانت :

$$\pi(B^S)X_t = \varepsilon_t \quad \dots (19)$$

إذ ان :

$$\therefore \pi_K = \frac{\Gamma(K-D)}{\Gamma(-D)\Gamma((K+1))} \quad \dots (20) \quad \text{وعندما } (K \rightarrow \infty) :$$

2- عندما $D < 0.5$ فإن العملية $\{X_t\}_{t \in \mathbb{Z}}$ هي عملية مستقرة ويمكن كتابتها بدلالة الاخطاء العشوائية كعملية اوساط متحركة غير منتهية :

$$X_t = \frac{1}{(1-B^S)^D} \varepsilon_t \quad \dots (21)$$

$$X_t = \Psi(B^S) \varepsilon_t = \sum_{K=0}^{\infty} \Psi_K \varepsilon_{t-K} \quad \dots (22)$$

ان عامل الفروق الموسمية للعملية $\{X_t\}_{t \in \mathbb{Z}}$ بدلالة الاخطاء العشوائية تعرف باستخدام متسلسلة ذي الحدين (Binomial Series) [7] :

$$(1 - B^S)^{-D} = \sum_{k=0}^{\infty} \binom{-D}{k} (-B^S)^k = 1 + \frac{DB^S}{1!} + \frac{D(D+1)}{2!} B^{2S} + \dots \dots (23)$$

ويمكن حساب الفروق الموسمية للعملية $\{X_t\}_{t \in \mathbb{Z}}$ بدلالة الاخطاء العشوائية من خلال سلسلة مكلورين وكانت :

$$\Psi(B^S) = \frac{1}{(1-B^S)^D} \quad \dots (24)$$

إذ ان :

$$\Psi_K = K^{D-1} / \Gamma(D) \quad \dots \quad (25) \quad \text{عندما } K \rightarrow \infty :$$

3- عندما $D \in (-0.5, 0.5)$ فإن العملية لها دالة الكثافة الطيفية وتعرف بالشكل الآتي :

$$f_X(w) = \frac{\sigma_\varepsilon^2}{2\pi} \left| 1 - e^{-isw} \right|^{-2D} = \frac{\sigma_\varepsilon^2}{2\pi} \left[(1 - e^{isw})(1 - e^{-isw}) \right]^{-2D}$$

$$f_X(w) = \frac{\sigma_\varepsilon^2}{2\pi} \left[2 \sin\left(\frac{sw}{2}\right) \right]^{-2D}, 0 < w \leq \pi, \quad f_\varepsilon(w) = \frac{\sigma_\varepsilon^2}{2\pi} \quad \dots \quad (26)$$

وبفرض ان التكرار الموسمي $\left[\frac{s}{2} \right]$ ، حيث ان $v = 0, \dots, \left[\frac{s}{2} \right]$ ، $w_v = \frac{2\pi v}{s}$

$$f_X\left(\frac{2\pi v}{s} + w\right) \sim f_\varepsilon\left(\frac{2\pi v}{s}\right) (sw)^{-2D} \quad \dots \quad (27) \quad \text{عندما } w \rightarrow 0 :$$

4 - ان العملية $\{X_t\}_{t \in \mathbb{Z}}$ لها دالة التباين والتباين المشترك التي تم اثباتها من قبل (Brietzke, 2005) [7] واخرون بالاعتماد على الدالة الطيفية

$$Y_x(sk) = \int_{-\pi}^{\pi} e^{iswk} f_x(w) dw = \int_{-\pi}^{\pi} \cos(swk) \frac{\sigma_\varepsilon^2}{2\pi} \left| 2 \sin \frac{sw}{2} \right|^{-2D} dw$$

$$Y_x(sk) = \frac{\sigma_\varepsilon^2}{2\pi} 2^{-2D} \frac{\pi (-1)^k \Gamma(-D+1)}{2^{-2D} \Gamma(k-D+1) \Gamma(1-k-D)} = \sigma_\varepsilon^2 \frac{(-1)^k \Gamma(-2D+1)}{\Gamma(k-D+1) \Gamma(1-k-D)} \dots (28)$$

وان دالة الارتباط الذاتي (AutoCorrelation Function) للعملية X_t [7] هي :

$$p_x(sk) = \frac{Y_x(sk)}{Y_0} \quad , \quad \rho_x(sk + \xi) = \begin{cases} \frac{\Gamma(1-D)(k+D)}{\Gamma(k-D+1)\Gamma(D)}, \xi = 0 \\ 0, \xi \in \{1, 2, \dots, S-1\} \end{cases} \dots (29)$$

5- ان العملية $\{X_t\}_{t \in \mathbb{Z}}$ لها دالة ارتباط ذاتي جزئي (Partial AutoCorrelation Function) يمكن كتابتها كالآتي [7] :

$$\Phi_X(sk + \xi, sl + \eta) = \begin{cases} -\binom{K}{l} \frac{\Gamma(l-D)\Gamma(k-l+1-D)}{\Gamma(K-D+1)\Gamma(-D)} = \Phi_X(K, l), IF \eta = 0 \\ 0, IF \eta \in A, A = \{1, 2, \dots, S-1\} \end{cases} \dots (30)$$

[6] 2.2.2.1. العملية SARFIMA(0,d,0)(0,D,0)_S

على فرض ان $\{X_t\}_{t \in \mathbb{Z}}$ عملية تخضع للانموذج SARFIMA(0,d,0)(0,D,0)_S وان الفترة الموسمية $S \in \mathbb{N}$ فان صيغة الانموذج تكون على النحو الآتي :

$$(1-B)^d(1-B^S)^D X_t = \varepsilon_t \quad \dots (31)$$

وان خصائص هذا الانموذج تكون :

(i) : عندما $|d+D| < 0.5$ وان $|D| < 0.5$ فان العملية $\{X_t\}_{t \in \mathbb{Z}}$ تمتلك دالة كثافة الطيف الاتية :

$$f_X(w) = \frac{\sigma_\varepsilon^2}{2\pi} |1 - e^{-iw}|^{-2d} |1 - e^{-iSw}|^{-2D}, (0 < w \leq \pi) \quad \dots (32)$$

$$f_X(w) = \frac{\sigma_\varepsilon^2}{2\pi} \left[2 \sin\left(\frac{w}{2}\right) \right]^{-2d} \left[2 \sin\left(\frac{Sw}{2}\right) \right]^{-2D}, 0 < w \leq \pi \quad \dots (33)$$

$$\lim_{w \rightarrow 0} \frac{\sin(sw)}{sw} = 1 \quad \text{بما ان :}$$

عندئذ فان الدالة الطيفية ستكون

$$f_X(w) \sim c_1 |w - w_0|^{-2(d+D)}, \quad w \rightarrow 0, \quad c_1 = \frac{\sigma_\varepsilon^2}{2\pi} S^{-2D} \quad \dots (34)$$

وان التكرارات الموسمية $w_j = \frac{2j\pi}{S}$ عندما $\left[\frac{S}{2} \right]$ ، $j = 0, 1, \dots, \lambda \rightarrow 0$ ،

$$\frac{\sigma_\varepsilon^2}{2\pi} \left[2 \sin\left(\frac{w_j}{2}\right) \right]^{-2d} S^{-2D} |\lambda|^{-2D} \quad \dots (35)$$

$$f_X(\lambda + w_j) = \frac{\sigma_\varepsilon^2}{2\pi} \left[2 \sin\left(\frac{\lambda}{2} + \frac{w_j}{2}\right) \right]^{-2d} \left[2 \sin\left(\frac{s\lambda}{2} + \frac{Sw_j}{2}\right) \right]^{-2D} \sim$$

(ii) : ان دالة التباين المشترك الذاتي للعملية $\{X_t\}_{t \in \mathbb{Z}}$ للترتبة h و $h \in \mathbb{Z}$ تكون :

$$\left\{ \sigma_\varepsilon^2 \gamma_0(sv) \gamma_Y(h - sv) \right\}_0 X(h) = \gamma \quad \begin{array}{ll} \text{if } h = sl, & l \in \mathbb{Z}_\infty \\ \text{if } h = sl + \xi, & \xi \in A. \end{array} \quad \dots (36)$$

اذا ان $A = \{1, \dots, s-1\}$ وان $\{Z_t\}_{t \in \mathbb{Z}}$ هي عملية $\text{SARFIMA}(0, D, 0)_s$ بدالة تباين مشترك ذاتي من الرتبة v و $v \in \mathbb{Z}$ والمعطاة على النحو الآتي :

$$\gamma_Z(sv + \xi) = \begin{cases} \frac{(-1)^v \Gamma(1-2D)}{\Gamma(v-D+1) \Gamma(1-v-D)} = \gamma_X(v) & \text{if } \xi=0, \\ 0 & \text{if } \xi \in A. \end{cases} \dots (37)$$

وان $\{Y_t\}_{t \in \mathbb{Z}}$ هي عملية $\text{ARFIMA}(0, d, 0)$ بدالة تباين مشترك من الرتبة h و $h \in \mathbb{Z}$ والمعطاة على النحو الآتي :

$$\gamma_Y(h) = \frac{(-1)^h \Gamma(1-2d)}{\Gamma(h-d+1) \Gamma(1-h-d)} \dots (38)$$

3.2.2.1 العملية $\text{SARFIMA}(p, d, q)(P, D, Q)_s$ [6]

على فرض ان $\{X_t\}_{t \in \mathbb{Z}}$ تمثل عملية $\text{SARFIMA}(p, d, q)(P, D, Q)_s$ والمعطاة في الصيغة (11) بمتوسط صفر وفترة موسمية $s \in \mathbb{N}$. وبفرض ان $\omega(z)\omega(z^s) = 0$ و $v(z)v(z^s) = 0$ فإنه يكون :

(i) : اذا كل $|d+D| < 0.5$ و $|D| < 0.5$ فإن العملية $\{X_t\}_{t \in \mathbb{Z}}$ تمتلك دالة الكثافة الاحتمالية الآتية :

$$f_X(w) = \frac{\sigma_\varepsilon^2}{2\pi} \frac{|v(e^{-i\pi w})|^2 |v(e^{-i\pi s w})|^2}{|\omega(e^{-i\pi w})|^2 |\omega(e^{-i\pi s w})|^2} \left| 2 \sin\left(\frac{w}{2}\right) \right|^{-2d} \left| 2 \sin\left(\frac{sw}{2}\right) \right|^{-2D}, 0 < w \leq \pi \dots (39)$$

(ii) : العملية $\{X_t\}_{t \in \mathbb{Z}}$ تكون مستقرة اذا كل $d+D < 0.5$ و $D < 0.5$ وان $\omega(z)\omega(z^s) \neq 0$ لكل قيم $|z| \leq 1$.

(iii) : العملية المستقرة $\{X_t\}_{t \in \mathbb{Z}}$ تمتلك خاصية الذاكرة الطويلة اذا تحقق ان $0 < d+D < 0.5$ و $0 < D < 0.5$ وان $\phi(z)\Phi(z^s) \neq 0$ لكل قيم $|z| \leq 1$.

(iv) : العملية المستقرة $\{X_t\}_{t \in \mathbb{Z}}$ تمتلك خاصية الذاكرة المتوسطة اذا تحقق ان $-0.5 < d+D < 0$ و $-0.5 < D < 0$ وان $\omega(z)\omega(z^s) \neq 0$ لكل قيم $|z| \leq 1$.

(v) : عندما $|d+D| < 0.5$ و $|D| < 0.5$ فإن دالة التباين المشترك الذاتي للرتبة (h) و $h \in \mathbb{Z}$ ، للعملية $\{X_t\}_{t \in \mathbb{Z}}$ تكون :

$$\gamma_x(h) = \begin{cases} \sigma_\varepsilon^2 \sum \gamma_z(sv) \gamma_y(h - sv), & \text{if } h = sl, \quad l \in \mathbb{Z}_s, \\ 0, & \text{if } h = sl + \xi, \quad \xi \in A, \end{cases} \quad (40)$$

إذاً : $\{Z_t\}_{t \in \mathbb{Z}}$ هي عملية $\text{SARFIMA}(P,D,Q)_s$

$\{Y_t\}_{t \in \mathbb{Z}}$ هي عملية $\text{ARFIMA}(p,d,q)$

$\gamma_z(\cdot)$ دالة التباين المشترك الذاتي للعملية $\{Z_t\}_{t \in \mathbb{Z}}$.

$\gamma_y(\cdot)$ دالة التباين المشترك الذاتي للعملية $\{Y_t\}_{t \in \mathbb{Z}}$ ، وأن $A = \{1, \dots, s-1\}$.

4.2.2.1. طرق التقدير : Estimation Methods [9,11,12]

ان عملية تقدير معاملات الانموذج $\text{SARFIMA}(p,d,q)(P,D,Q)_s$ تتم بأسلوبين :

الاسلوب الأول : يتضمن تقدير معاملات الانموذج $\text{SARFIMA}(p,d,q)(P,D,Q)_s$ باستخدام طريقة مجموع المربعات المشروطة (CSS) كالآتي :

1.4.2.2.1. طريقة مجموع المربعات المشروطة (CSS) : Conditional Sum Of Squares تناول هذه الطريقة الباحثون (Egrioglu , Aladag and Kadilar,2011) [11] و (Chung and Baillie,1993) [9] ، التي تستند على ان يكون مجموع المربعات المشروط اقل ما يمكن ، ويمكن ان تستخدم هذه الطريقة للانموذج الموسمي $\text{SARFIMA}(p,d,q)(P,D,Q)_s$. حيث تلخص خطوات هذه الطريقة كما يأتي :

1- أخذ الفروق الموسمية الكسرية للسلسلة x_t . $y_t = (1-B^s)^D x_t \dots (41)$

2- أخذ الفروق الاعتيادية الكسرية للسلسلة y_t . $z_t = (1-B)^d y_t \dots (42)$

3- ايجاد مجموع المربعات المشروط للانموذج $\text{SARFIMA}(p,d,q)(P,D,Q)_s$ وعلى النحو الآتي :

$$S = \frac{1}{2} \log(\sigma_\varepsilon^2) + \frac{1}{\sigma_\varepsilon^2} \sum [\nu^{-1}(B) \omega^{-1}(B) z_t]^2 \dots (43)$$

ومن ثم ايجاد مقدرات الانموذج من خلال حساب المشتقات لكل معلمة بشكل منفرد ، اضافة الى حساب مصفوفة التباين والتباين المشترك للمعلمات المقدرة .

اما الاسلوب الثاني : يتم تقدير المعلمات بطريقة المرحلتين

2.4.2.2.1. طريقة المرحلتين : TWO – STAGED ^[11]: تستخدم لتقدير معلمات الإنموذج الموسمي SARFIMA(p,d,q)(P,D,Q)_S، وتكون هذه الطريقة بمرحلتين :

1- في المرحلة الاولى، يفرض ان السلسلة الزمنية يمكن ان تمثل العملية SARFIMA(0,d,0)(0,D,0) وان معلمتي الفروق الاعتيادية والموسمية الكسرية (d,D) يتم تقديرها بعدة طرائق وتم استخدام طريقة الشبه المعلمية .

1.4.2.2.1. الطريقة شبه المعلمية لتقدير الإنموذج SARFIMA(0,d,0)(0,D,0)_S ^[12] :

ان دالة الطيف للعملية : $(1-B)^d(1-B^S)^D X_t = \varepsilon_t \quad \dots (44)$

تكون بالشكل الآتي : $f_X(w) = \left[2\sin\left(\frac{ws}{2}\right) \right]^{-2D} \left[2\sin\left(\frac{w}{2}\right) \right]^{-2d} f_\varepsilon(w) \quad \dots (45)$

بأخذ اللوغارتم الطبيعي لطرفي دالة الكثافة الطيفية كالآتي :

$$\text{Log}(f_X(w)) = -D\text{Log}\left| 2\sin\left(\frac{ws}{2}\right) \right|^2 - d\text{Log}\left| 2\sin\left(\frac{w}{2}\right) \right|^2 + \text{Log}(f_\varepsilon(w)) \quad \dots (46)$$

بإضافة وطرح $\text{Log}(f_\varepsilon(0))$ للطرفين نحصل على الآتي :

$$\left[\text{Log}(f_X(w)) = -D\text{Log}\left| 2\sin\left(\frac{ws}{2}\right) \right|^2 - d\text{Log}\left| 2\sin\left(\frac{w}{2}\right) \right|^2 + \frac{\text{Log}(f_\varepsilon(w))}{f_\varepsilon(0)} + \text{Log}(f_\varepsilon(0)) \right] \dots (47)$$

ولغرض تقدير (D,d) نستخدم مخطط الدورية Periodogram بدلاً من دالة الكثافة الطيفية $f_X(w)$ اذا ان :

$$I(w_j) = \frac{1}{n} \left| \sum_{t=1}^n X_t e^{i w_j t} \right|^2 \quad \dots (48)$$

وعندما $w_j \rightarrow 0$ ولكل قيم الـ (j) فإن : $\text{Log}\left(\frac{f_\varepsilon(w)}{f_\varepsilon(0)}\right) \approx 0$

وتم تحويل معادلة لوغارتم المخطط الدوري الى معادلة انحدار خطي متعدد :

$$y_j = B_0 + B_1 x_{j1} + B_2 x_{j2} + V_j \quad \dots (49)$$

$$\left. \begin{aligned} \log(I(w_j)) &= y_j, \quad \log(f_\varepsilon(0)) = B_0, \quad B_1 = -D, \quad B_2 = -d \\ \log\left[2\sin\left(\frac{ws}{2}\right)\right]^2 &= x_{j1}, \quad \log\left[2\sin\left(\frac{w}{2}\right)\right]^2 = x_{j2} \\ V_j &= \log\left[\frac{I(w_j)}{f_X(w_j)}\right] + \log\left[\frac{f_\varepsilon(w_j)}{f_\varepsilon(0)}\right] \end{aligned} \right\} \dots (50)$$

وبذلك فإن مقدر المربعات الصغرى لمعلمتي الذاكرة الطويلة (D) و (d) يكون كما يأتي :

$$\hat{B}_1 = \frac{s_{1y}s_{22} - s_{2y}s_{12}}{s_{11}s_{12} - s_{12}^2}, \quad \hat{B}_2 = \frac{s_{2y}s_{11} - s_{1y}s_{12}}{s_{11}s_{12} - s_{12}^2} \quad \dots (51)$$

$$\left. \begin{aligned} s_{11} &= \sum x_1^2 - n\bar{x}_1^2, \quad s_{22} = \sum x_2^2 - n\bar{x}_2^2 \\ s_{12} &= \sum x_1x_2 - n\bar{x}_1\bar{x}_2, \quad s_{1y} = \sum x_1y - n\bar{x}_1\bar{y}, \quad s_{2y} = \sum x_2y - n\bar{x}_2\bar{y} \end{aligned} \right\} \dots (52)$$

2- في المرحلة الثانية ، يتم تقدير معلمات النموذج الانحدار الذاتي والوساط المتحركة باستخدام أسلوب بوكس - جنكينز .

3.1. الشبكات العصبية الاصطناعية: Artificial Neural Network [8]

تعد الشبكات العصبية الاصطناعية (ANN) نظام ترابطي من وحدات المعالجة العصبية ، اي ان عنصر المعالجة (Processing Element) له قدره على العمل كذاكرة محلية واطافة لذلك ان كل عنصر يعمل بشكل غير متزامن مع عمليات المعالجة المختلفة التي تترايط مع بعضها لتأخذ شكلاً هيكلياً محدداً

1.3.1. انواع الشبكات العصبية الاصطناعية [8]


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 أسلوب بناء وارتباط الخلايا من طبقة لآخرى كشبكات ذات التغذية الامامية Feed Forward Neural Networks (FFNN) والشبكات ذات التغذية العكسية Feed Back Neural Networks (FBNN) ومنها شبكة ايلمان العصبية

1.1.3.1 شبكة ايلمان العصبية التكرارية (ERNN): [4]

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

1.1.1.3.1 (i) هيكلية (ERNN) [4] : 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 تستخدم 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 أن طبقة الاخراج هي وحده خطيه تجمع الاشارات التي تغذيها. اما الطبقة المخفية فأنها تمتلك دوال تنشيط خطية او غير خطية، ولكن في حالة الشبكة (ERNN) فإن 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) فإن 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.

شكل (2) : رسم الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN [4]



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

$$v_i(k) = \sum_{j=1}^n w_{i,j}^x(k-1)x_j^c(k) + w_i^u(k-1)u(k), \dots (53a)$$

$$x_i(k) = f(v_i), \dots (53b)$$

$$x_j^c(k) = x_j(k-1) + \alpha x_j^c(k-1), \dots (53c)$$

$$y(k) = \sum_{i=1}^n w_i^y(k-1)x_i(k), \dots (53d)$$

حيث 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 :

$$f(v_i) = \left[\frac{e^{(sinh)} - e^{(-sinh)}}{e^{(sinh)} + e^{(-sinh)}} \right] \dots (54)$$

2.1.1.3.1 (ii) تدريب الشبكة ERNN^[14] : ان متجه التغذية الاسترجاعية $\{x_j^c(k)\}$ 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)^[11] ، بمعنى ان التأخير في الاتصال بخزن القيم من الخطوه السابقة يمكن ان يستخدم في الخطوه الحالية . وعند عرض زوج المخلات والمخرجات على الشبكة في الزمن (k) ، تعرف دالة الخطأ عند مخرجات الشبكة كما يأتي :

$$E_k = \frac{1}{2} [y_d(k) - y(k)]^2 \dots (55)$$

حيث ان : $y(k), y_d(k)$: تمثلان المخرجات المطلوبة والحقيقية على التوالي . واعتماداً على مربعات الخطأ المعروفة بالصيغة (55) فإن اوزان الشبكة (ERNN) يتم تكيفها باستخدام خوارزمية (DBP) في كل خطوه (K) وكما يأتي :

$$\frac{\partial E_k}{\partial w_i^y(k-1)} = -(y_d(k) - y(k)) \frac{\partial y(k)}{\partial w_i^y(k-1)} = -(y_d(k) - y(k)) x_i(k). \quad (56)$$

$$\frac{\partial E_k}{\partial w_i^y(k-1)} = \left(\frac{\partial E_k}{\partial y(k)} \right) \left(\frac{\partial y(k)}{\partial x_i(k)} \right) \left(\frac{\partial x_i(k)}{\partial v_i(k)} \right) \left(\frac{\partial v_i(k)}{\partial w_i^y(k-1)} \right) = -(y_d(k) - y(k)) w_i^y(k-1) f_{vi} u(k). \quad (57)$$

$$\frac{\partial E_k}{\partial w_{i,j}^x(k-1)} = \left(\frac{\partial E_k}{\partial y(k)} \right) \left(\frac{\partial y(k)}{\partial x_i(k)} \right) \left(\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} \right) = (y_d(k) - y(k)) w_i^y(k-1) \left(\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} \right) \dots (58)$$

$$\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} x_j^o(k) \dots (59)$$

وبتعويض الصيغة (59) في الصيغة (53c) ينتج ان :

$$\frac{\partial x_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} x_j(k-1) + \alpha \left(\frac{\partial x_i(k-1)}{\partial w_{i,j}^x(k-2)} \right) \dots (60)$$

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

$$f_{vi} = f(vi) * (1 - f(vi))^2 \dots (61) \quad \text{فان :}$$

ان تعديل الوزن العام باستخدام (gradient descent) يكون :

$$\Delta w = -\eta \frac{\partial E_k}{\partial w} \dots (62)$$

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

3.1.1.3.1 (iii) خوارزمية الشبكة ERNN^[4] : ان خوارزمية الشبكة يمكن توضيحها كالآتي :

$$\Delta w_i^y(k) = \eta (y_d(k) - y(k)) X_i(k) \dots (63)$$

$$\Delta w_j^u(k) = \eta (y_d(k) - y(k)) w_i(k-1) f_{vi} u(k) \dots (64)$$

$$\Delta w_{i,j}^x(k) = \eta (y_d(k) - y(k)) w_i^y(k-1) \frac{\partial X_i(k)}{\partial X_{i,j}^x(k-1)} \dots (65)$$

$$\frac{\partial X_i(k)}{\partial X_{i,j}^x(k-1)} = f_{vi} \{ X_j(k-1) \} + \sum_{l=1}^n w_{i,l}^x(k-1) \frac{\partial X_l(k-1)}{\partial X_{i,j}^x(k-2)} \dots (66)$$

$$f_{vi} = \frac{\partial f}{\partial v_i} = (1 - f^2(vi)), \quad \text{حيث ان :}$$

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

$$\frac{\partial X_i(k)}{\partial w_{i,j}^x(k-1)} = f_{vi} X_j(k-1) \dots (67)$$

$$\Delta w_{i,j}^x(k) = \eta(y_d(k) - y(k))w_i^y(k-1)f_{vi}X_j(k-1) \dots (68)$$

وعند الحصول على اقل خطأ ممكن يتم الانتقال الى مرحلة التنبؤ ، وبعبارة يتم تعديل الاوزان وذلك بحساب $(w_i^y(k+1), w_{i,j}^x(k+1), w_j^y(k+1))$. 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 العملي للبيانات الواقعية التي تمثل سلسلة المعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد من الفترة (1937 – 2016)^[2] لغرض التنبؤ بالمعدلات الشهرية لدرجات الحرارة باستعمال الانموذجين المنفردين (الانموذج الموسمي المضاعف الكسري وانموذج شبكة ايلمان) والانموذج الهجين (الانموذج الموسمي المضاعف الكسري مع انموذج شبكة ايلمان (ARFIMA(p,d,q)(P,D,Q)S – ERNN) .

1.3. الانموذج الموسمي الكسري SARFIMA

سيتم تمثيل بيانات المعدلات الشهرية لدرجات الحرارة العظمى من الفترة (1937 – 2013) باستخدام الانموذج الموسمي الكسري إذ ان من خلال دالة الارتباط الذاتي كما في الشكل (3)


شكل (3) : دالة الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد



يمكن نستنتج من ان السلسلة ذات ذاكرة طويلة ولغرض انجاز استقراريتها وتخلصها من اثر الموسمية تم اخذ الفرق الاعتيادي (d) الكسري والفرق الموسمي (D) الكسري للسلسلة الزمنية إذ تم تقدير الفرق الاعتيادي (d) والفرق الموسمي (D) بموجب طريقة التقدير شبه المعلمية، إذ بلغت قيمة (d = -0.1359) و (D = -0.2696) باستخدام برنامج كتب لهذا الغرض. وقد تم اخذ هذه الفروق

لبيانات المعدلات الشهرية لدرجات الحرارة العظمى مما أدى الى انجاز الاستقرارية لها وذلك من خلال حساب معاملات الارتباط الذاتي ورسم دالة الارتباط الذاتي كما في الشكل (4) .

شكل (4): دالة الارتباط الذاتي بعد اخذ الفروق الاعتيادية والموسمية الكسرية



من خلال هذه الدالة يمكن اقتراح أنموذج لتمثيل هذه البيانات وهو SARFIMA(0,-0.1359,1)(0,-0.2696,1) وذلك من خلال دالة الارتباط الذاتي إذ تكون معنوية فقط عند الازاحات (13,12,11,1) الذي تكتب معادلته بالشكل الاتي :

$$(1-B)^{-0.1359}(1-B)^{-0.2696}x_t = (1-\nu_1 B)(1-\nu_2 B^{12})a_t \quad \dots (69)$$

وقد تم تقديره كما في الجدول (1)

جدول (1) : يمثل تقديرات معلمات الانموذج الكسري واختبارها

Type	Coef	SE Coef	T	P
MA 1	0.9375	0.0004	2549.93	0.000
SMA 12	0.9722	0.0107	90.99	0.000
Number of observations: 924				
Residuals: SS = 3171.46 (backforecasts excluded)				
MS = 3.44 DF = 922				


ولزيادة التأكد من ان الانموذج المقترح يمثل بيانات السلسلة الزمنية تم اقتراح عدة نماذج وتم حساب متوسط مربعات الاخطاء MSE كما في الجدول ادناه :

جدول (2): يبين توفيق مجموعة من النماذج المقترحة لسلسلة درجات الحرارة العظمى مع قيمة متوسط مربعات الاخطاء

(p,d,q)×(P,D,Q)	MSE
(0,-0.1359,0)×(1,-0.2696,1)	4.94
(0,-0.1359,0)×(1,-0.2696,0)	4.65
(0,-0.1359,0)×(0,-0.2696,1)	3.95
(0,-0.1359,0)×(2,-0.2696,0)	4.14
(1,-0.1359,0)×(2,-0.2696,0)	3.93
(2,-0.1359,0)×(2,-0.2696,0)	3.84
(0,-0.1359,1)×(0,-0.2696,1)	3.44

ولكون الانموذج $SARFIMA(0,-0.1359,1)(0,-0.2696,1)$ يمتلك اقل MSE فقد تم استخراج البواقي له وتم حساب معاملات الارتباط الذاتي لها وتم حساب احصاءة Q (Box-Pierce) والتي بلغت 21.9 وعند مقارنتها مع قيمة χ^2 الجدولية بدرجة حرية 98 ومستوى معنوية 0.05 وجد انها تساوي 77.93 وبالنسبة تقبل فرضية العدم التي تنص على عدم وجود ارتباطات بين البواقي . كما تم رسم دالة الارتباط الذاتي كما الشكل (5)

شكل (5): دالة الارتباط الذاتي لبواقي الانموذج الموسمي الكسري




ومنها نستدل من ان الاخطاء متغيرات عشوائية غير مترابطة وبالتالي فإن الانموذج جيد وملئم لتمثيل البيانات لذا تم استخدامه لحساب التقديرات للسنوات 2014 ، 2015 ، 2016 كما في الجدول (3) جدول (3) : يبين التقديرات لدرجات الحرارة العظمى للانموذج الموسمي الكسري للسنوات (2014 ، 2015 ، 2016)

الشهر	1	2	3	4	5	6	7	8	9	10	11	12
تقديرات 2014	16.8	17.5	23.7	28.5	37.0	41.4	42.3	41.2	40.8	31.4	24.5	17.7
تقديرات 2015	16.8	19.5	21.7	30.5	25.0	40.4	42.3	41.2	40.8	31.4	23.5	15.7
تقديرات 2016	14.8	19.5	21.7	30.5	35.0	40.4	43.3	41.2	40.8	31.4	24.5	17.8

2.3. انموذج شبكة ايلمان ELMAN

سيتم تمثيل المعدلات الشهرية لدرجات الحرارة العظمى بأنموذج الشبكات العصبية الاسترجاعية (شبكة ايلمان ELMAN) المذكورة في المعادلات (53a , ... , 53d) وقد تم تدريب الشبكة وفق الخوارزمية المذكورة في الجانب النظري إذ تم استخراج التقديرات لدرجات الحرارة وقد تم رسمها مع القيم الحقيقية لبيان دقة عمل الشبكة كما في الشكل (6) .

شكل (6) : يمثل حساب التقديرات مع القيم الحقيقية للمعدلات الشهرية لدرجات الحرارة العظمى



وبلاحظ من خلال الشكل مدى توافق القيم التقديرية مع القيم الحقيقية للسلسلة كما يبين الشكل ان السلسلة الزمنية لازالت محتفظة بسلوكيتها إذ تماثل سلوكها مع سلوك السلسلة للقيم الحقيقية .


لذا تم استخدام الانموذج لحساب التقديرات للسنوات 2014 ، 2015 ، 2016 كما في الجدول (4) .

جدول (4) : التقديرات لدرجات الحرارة العظمى لأنموذج الشبكة العصبية الاسترجاعية ELMAN للسنوات (2014 ، 2015 ، 2016)

الشهر	1	2	3	4	5	6	7	8	9	10	11	12
تقديرات 2014	18.4	20.1	26.0	32.8	41.0	42.0	43.2	43.3	34.6	32.6	22.1	19.2
تقديرات 2015	18.1	22.0	26.8	31.7	38.7	43.2	43.8	43.5	41.0	34.1	24.4	17.5
تقديرات 2016	18.1	22.8	26.3	32.9	37.7	43.1	43.6	43.9	38.2	32.6	22.3	17.8

وقد تم رسم هذه التقديرات مع القيم الحقيقية كما في الشكل (7)

شكل (7) : يمثل رسم التقديرات مع القيم الحقيقية للسنوات (2014 ، 2015 ، 2016)



من خلال الشكل اعلاه يبين مدى توافق القيم التقديرية مع القيم الفعلية للسنوات 2014 – 2016 .

3.3. النموذج الهجين : $ARFIMA(p,d,q)(P,D,Q)_s - ERNN$


لايجاد التقديرات للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنوات (2014 ، 2015 ، 2016) باستخدام النموذج الهجين $ARFIMA(p,d,q)(P,D,Q)_s - ERNN$ سيتم جمع التقديرات الناتجة باستخدام النموذج الموسمي الكسري $X_t = (1 - 0.9375)(1 - 0.9722)a_t + (1 - B)^{-0.1359}(1 - B)^{-0.269}$ مع التقديرات المستخرجة لبواقي هذا النموذج بعد ان تم نمذجتها باستخدام الشبكات العصبية الاسترجاعية (ELMAN) كما في الجدول (5).

جدول (5): يمثل التقديرات لدرجات الحرارة العظمى للنموذج الهجين SARFIMA - ELMAN للسنوات (2014 ، 2015 ، 2016)

الشهر	1	2	3	4	5	6	7	8	9	10	11	12
تقديرات 2014	19.1	17.0	25.5	28.2	36.5	40.5	42.4	42.9	36.0	36.2	23.2	21.0
تقديرات 2015	15.7	19.8	21.7	29.7	26.4	39.3	44.3	41.2	41.5	29.8	24.2	13.3
تقديرات 2016	15.8	21.9	20.4	31.7	33.6	40.3	44.4	42.6	37.6	31.6	24.7	17.3

4.3. مقاييس المفاضلة

لغرض المقارنة بين التقديرات المستخرجة للنماذج الثلاثة مع القيم الحقيقية تم رسمها كما في الشكل (8) شكل (8) : يوضح رسم التقديرات للنماذج الثلاثة مع القيم الحقيقية



ومن خلال الرسم نجد ان قيم التقديرات لشبكة ايلمان (ELMAN) تكاد تكون مطابقة ومتفقة من ناحية سلوكيتها مع القيم الحقيقية، وكذلك وجدت ان تقديرات الانموذج الهجين الموسمي الكسري SARFIMA – ELMAN تكون متقاربة 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) للنماذج المنفردة والهجينة كما في الجدول (6)

جدول (6) : يبين قيم مقاييس المفاضلة للنماذج المنفردة والهجينة لدرجات الحرارة العظمى للسنوات (2014 ، 2015 ، 2016)

الانموذج	R^2	MSE	RMSE	MAD	MAE	MAPE	SEP
SARFIMA	0.90	12.334	3.511	0.068	2.450	7.697	12.15
ELMAN	0.98	2.172	1.473	0.034	1.238	4.182	4.66
SARFIMA-ELMAN	0.98	10.047	3.169	0.065	2.339	7.547	10.59

ومن خلال نتائج الجدول اعلاه تبين ان الانموذج المنفرد (انموذج شبكة ايلمان) جيد ويمتلك اقل المقاييس الاحصائية (MSE، RMSE، MAD، MAE، MAPE، SEP) وامتلاكه اعلى قيمة لـ R^2 . ويليه الانموذج الهجين SARFIMA - Elman، فقد تم استخدامهما لحساب التنبؤات المستقبلية للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنتين 2017 – 2018 وكالاتي :

جدول (7) : يبين التنبؤات لدرجات الحرارة العظمى لأنموذج الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN والانموذج الهجين SARFIMA-ELMAN للسنوات 2017 – 2018

الشهر التنبؤات	1	2	3	4	5	6	7	8	9	10	11	12
شبكة ايلمان 2017	15.0	20.4	25.8	31.5	38.0	42.2	44.3	45.4	41.9	33.2	25.2	17.8
SARFIMA-Elman 2017	16.8	18.5	21.7	30.5	35.0	41.4	42.3	41.2	40.8	32.4	24.5	15.8
شبكة ايلمان 2018	18.2	19.7	25.6	32.9	37.3	41.6	44.2	45.8	39.3	32.5	24.3	17.9
SARFIMA-Elman 2018	16.8	18.5	21.7	29.5	37.0	40.4	42.3	41.2	38.8	31.5	22.5	17.8

1.4 .الاستنتاجات (Conclusions)

لقد تمخضت هذه الدراسة التطبيقية للموضوع عن جملة من الاستنتاجات تخص التحليل الاحصائي للانموذج المنفرد (انموذج الشبكة العصبية الاسترجاعية شبكة ايلمان والانموذج الموسمي المضاعف الكسري) والانموذج الهجين (الانموذج الموسمي المضاعف الكسري مع انموذج شبكة ايلمان) والذي يرمز له بالرمز $ERNN - SARFIMA(p,d,q)(P,D,Q)_s$ وفيما يلي نصها :

1 - ان بيانات السلسلة الزمنية بعد استقرارها وتخلصها من اثر الموسمية تم تمثيلها بلانموذج الموسمي المضاعف الكسري $x_t = (1 - \nu_1 B)(1 - \nu_2 B^{12})a_t$ استناداً الى دالة الارتباط الذاتي كما في الشكل (4) ولكونه يمتلك اقل متوسط مربعات خطأ مقارنة مع النماذج الاخرى المقترحة لتمثيل هذه البيانات كما في الجدول (1) .

2 - عند رسم التقديرات المستخرجة للأنموذجين المنفردين (الانموذج الموسمي الكسري وانموذج الشبكة العصبية الاسترجاعية شبكة ايلمان) والانموذج الهجين (الانموذج الموسمي الكسري 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 (8) وجد ان

- ان تقديرات شبكة ايلمان تكاد تكون الاقرب من القيم الحقيقية .
- ان تقديرات الانموذج الهجين $SARFIMA - ELMAN$ تكون قريبة من القيم الحقيقية .
- ابتعاد تقديرات الانموذج المنفرد $SARFIMA$ كثيراً عن القيم الحقيقية .

3 - عند مقارنة تقديرات نماذج السلاسل الزمنية الموسمية المنفردة والهجينة (الأنموذج المنفرد $SARFIMA$ والانموذج المنفرد للشبكة العصبية شبكة ايلمان $ELMAN$ والانموذج الهجين $SARFIMA - ELMAN$) للمعدلات الشهرية لدرجات الحرارة العظمى لمدينة بغداد للسنوات 2014 - 2016 بالاعتماد على جملة من المقاييس الاحصائية المستخدمة كما في الجدول (6) وجد تفوق الانموذج المنفرد (انموذج شبكة ايلمان $ELMAN$) على النماذج الهجينة والمنفردة لإملاكه الحد الأدنى لهذه المقاييس ($MSE, RMSE, MAD, MAE, SEP$) وأعلى قيمة لـ R^2 يليه الانموذج الهجين الكسري $SARFIMA - ELMAN$ لذا فقد تم استخدامهما 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 من الفترة (1937-2016) كما في الجدول (7) .

2.4 . التوصيات (Recommendation)

من خلال النتائج التي توصل اليها الباحث نقترح اجراء الآتي :

- 1 - استخدام انموذج الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN من قبل الهيئة العامة للأنواء الجوية والرصد الزلزالي والجهات ذات العلاقة بالموضوع للتنبؤ المستقبلي للمعدلات الشهرية العظمى لمدينة بغداد لإملاكه قيم صغيرة لهذه المقاييس (MSE , RMSE , MAD , MAE , SEP) وقيمة عالية لـ R^2 .
- 2 - نقترح استخدام الانموذج الهجين الكسري SARFFIMA-ELMAN للتنبؤ بدرجات الحرارة العظمى لمدينة بغداد لإملاكه قيم صغيرة لهذه المقاييس (MSE , RMSE , MAD , MAE , SEP) وقيمة عالية لـ R^2 مقارنة بالانموذج الموسمي المضاعف الكسري SARFIMA .
- 3 - اجراء دراسات للتنبؤ بدرجات الحرارة العظمى في مدن عراقية اخرى غير مدينة بغداد .
- 4 - اجراء دراسات لظواهر مناخية اخرى مثل كمية الامطار الساقطة ، سرعة الرياح ، السطوع الشمسي في مدن العراق باستخدام انموذج الشبكة العصبية الاسترجاعية شبكة ايلمان ELMAN .
- 5 - نقترح دراسة استخدام الشبكة العصبية الاسترجاعية (جوردن) بدلاً من شبكة ايلمان للانموذج الهجين ومقارنة نتائجها مع نتائج البحث .

المصادر

[1] الموسوي ، د. جواد، جربي ، هبه فضل ، (2014) ، " دراسة نظرية وتجريبية لنماذج السلاسل الزمنية المختلطة المتكاملة كسرياً ARFIMA " قسم الاحصاء - كلية الآلة والاقتصاد/الجامعة المستنصرية .

[2] الهيئة العامة للأنواء الجوية والرصد الزلزالي / قسم المناخ بيانات غير منشورة .

[3] Aladag C., Egrioglub E., and Kadilar C.,(2009), "Forecasting Nonlinear Time Series with AHybrid Methodology," Applied Mathematics Letters, Vol. 22, No. 9, pp. 1467-1470.

[4] 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.

[5] Baillie, Richard T. "Long memory processes and fractional integration in econometrics." Journal of econometrics 73, no. 1 (1996): 5-59.

- [6] Bisognin, Cleber, and Sílvia Regina Costa Lopes. "Properties of seasonal long memory processes." *Mathematical and Computer Modelling* 49, no. 9 (2009): 1837-1851.
- [7] Brietzke, Eduardo HM, Sílvia Regina Costa Lopes, and Cleber Bisognin. "A closed formula for the durbin-levinson's algorithm in seasonal fractionally integrated processes." *Mathematical and computer modelling* 42, no. 11-12 (2005): 1191-1206.
- [8] Bukhari.S,Adnan.H.,Hanif,(2008),"Inflation Forecasting Using Artificial Neural Networks", *Journal of Neural Networks, IEE* .
- [9] C.-F. Chung and R. T. Baillie, "Small sample bias in conditional sum-of-squares estimators of fractionally integrated ARMA models," *Empirical Economics*, vol. 18, no. 4, pp. 791–806, 1993.
- [10] 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.
- [11] Egrioglu, Erol, Cagdas Hakan Aladag, and Cem Kadilar. "The CSS and the two-staged methods for parameter estimation in SARFIMA models." *Journal of Probability and Statistics* 2011 (2011).
- [12] Geweke J. and Porter- Hudak S. – "The Estimation and Application of Long Memory Time Series Model" – *J. Time Series Analysis* , V ol.4, No.4, PP.221-238,1983.
- [13] Granger, Clive WJ. "Long memory relationships and the aggregation of dynamic models." *Journal of econometrics* 14, no. 2 (1980): 227-238.
- [14] Hosking, Jonathan RM. "Fractional differencing." *Biometrika* 68, no. 1 (1981): 165-176.
- [15] Oppenheim, G., M. Ould Haye, and M-C. Viano. "Long memory with seasonal effects." *Statistical Inference for Stochastic Processes* 3, no. 1 (2000): 53-68..
- [16] 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.