

استخدام النموذج الموسمي المضاعف للتنبؤ بدرجات الحرارة الشهرية

دراسة حالة: مدينة طرابلس بشمال غرب ليبيا

*محمد امراج محمد¹ و على خير صابر²¹قسم الاحصاء - كلية العلوم - جامعة سبها، ليبيا²قسم علوم الرياضيات - مدرسة العلوم الأساسية - الاكاديمية الليبية. طرابلس، ليبيا*للمراسلة: moh.mohamed@sebhau.edu.ly

الملخص تُعد منهجية بوكس-جينكينز لتحليل السلاسل الزمنية من اهم النماذج التنبؤية. حيث تتميز هذه النماذج بدقة عالية ومرونة في تشخيصها ووصفها لمستقبل الظواهر والمتغيرات المناخية. في هذه الورقة تم تطبيق هذه المنهجية لتحليل البيانات الشهرية لمعدلات درجات الحرارة بمدينة طرابلس بشمال غرب ليبيا. البيانات قيد الدراسة تمثل بيانات شهرية خلال الفترة (1961-2003). أُستخدمت برمجيات مُتخصصة لتحليل البيانات. بعد عمليات المُفاضلة بين عدة نماذج قياسية مُختلفة ضمن مجموعة نماذج ARIMA، تم التوصل الى ان النموذج الموسمي المضاعف من الدرجة $SARIMA(1,0,5)(0,0,2)_{12}$ هو النموذج القياسي الاكثر ملائمة وكفاية في عملية التنبؤ لبيانات درجات الحرارة الشهرية. ووفقا لنتائج تقدير باستخدام هذا النموذج تم التنبؤ بمعدلات درجات الحرارة الشهرية لمدينة طرابلس خلال الفترة من يناير 2004 و إلى ديسمبر 2005. حيث أظهرت القيم المُتنبأ بها تناسقا مع مثيلاتها بالسلسلة الاصلية.

الكلمات المفتاحية: السلاسل الزمنية، منهجية بوكس جينكينز، التنبؤ، معدل، درجات الحرارة، النموذج الموسمي المضاعف.

Using Seasonal Autoregressive Integrated Moving Average Model to Forecasting the Monthly Temperatures

A Case Study: Tripoli Area at the North West of Libya

*Mohamed Amraja Mohamed^a, Ali Khair Saber^b^aStatistical Department, Faculty of Science, Sebha University, Libya^bMathematical Sciences Dept., School of Basic Sciences, The Libyan Academy, Libya*Corresponding Author: Moh.Mohamed@sebhau.edu.ly

Abstract The Box-Jenkins methodology of time series analysis is considered one of the most important predictive models. These models are characterized by high accuracy and flexibility in their diagnosis and description of the future climate phenomena and variables. In this paper the Box-Jenkins methodology has been applied to analyze the average monthly climate data for Tripoli area which are located at Libyan northwestern. The considered data represent monthly data observed the period (1961-2003) inclusive. Specialized software has been used for data analysis. After comparison processes among several different standard models that belong to ARIMA models it has been observed that the $SARIMA(1,0,5)(0,0,2)_{12}$ model is most appropriate and efficient to predict the monthly temperatures. According to the estimation results using this model, the monthly temperature of Tripoli area were predicted for the period from January 2004 to December 2005. The predicted values of the monthly temperature have shown to be consistent with those of the original series.

Keywords: Time series, Box-Jenkins models, forecasting, Average, forecasting, temperature, SARIMA Model.

المقدمة:

المستقبل على ضوء ما حدث لها بالماضي. وإن دراسة السلسلة الزمنية يعني تحليلها إلى عواملها المؤثرة والتي تتمثل بالاتجاه العام، التغيرات الموسمية، التغيرات الدورية، وأخيراً التغيرات العرضية.

تعتبر السلاسل الزمنية من بين أهم الأساليب الاحصائية الحديثة والتي يمكن من خلالها معرفة طبيعة التغيرات التي تطرأ على قيم الظاهرة المدروسة خلال فترة زمنية معينة وتحديد الاسباب والنتائج وتفسير العلاقات المدروسة بينها والتنبؤ بما سيحدث من تغير على قيم الظاهرة في المستقبل على ضوء ما حدث في

نظرا للتغير الكبير في المناخ وتأثيره على البيئة وخصوصا في الارتفاع المستمر في درجات الحرارة فقد أجريت العديد من الدراسات ولا سيما المتعلقة بالظروف المناخية لفهم وتحديد الاتجاه العام للتغير في درجات الحرارة، كميات الامطار وكذلك الرطوبة وغيرها من الدراسات ذات الصلة بدرجات الحرارة وكانت أغلب نتائج هذه الدراسات متشابهة [17]. كما اهتمت هذه الدراسات بدراسة السلسلة الزمنية لأن كثيراً من الظواهر إذا ما درست لعدد من السنوات أو الأشهر أمكن معرفة طبيعة التغيرات التي ستطرأ عليها والتنبؤ بما سيحدث لها من تغير في

تحليل بيانات السلاسل الزمنية نماذج بوكس-جينكينز وذلك لما تتمتع به من دقة عالية في تنبؤاتها.

إن الهدف الرئيسي هو تحديد النموذج الأفضل والأكثر كفاءة لدراسة السلسلة الزمنية من خلال نماذج بوكس-جينكينز الموسمية للتنبؤ بمعدلات درجات الحرارة الشهرية للفترة من (2004 إلى 2005).

منهجية البحث والأدوات المستخدمة: إن المنهجية المتبعة في هذه الورقة هي مزيج بين المنهج الوصفي التحليلي في الجانب النظري، ومنهج دراسة الحالة في الجانب التطبيقي. حيث تم تقسيم الورقة إلى جانبين هما الجانب النظري والذي تم فيه التطرق إلى الأسس النظرية الخاصة بمراحل بناء النموذج وطرق التقدير والتنبؤ وذلك من خلال الاطلاع على عدد من المراجع العربية والأجنبية تناولت منهجية بوكس-جينكينز في تحليل السلاسل الزمنية. أما الجانب التطبيقي فيشمل دراسة تطبيقية على بيانات واقعية عن معدلات درجات الحرارة للوصول إلى نموذج رياضي للتنبؤ بدرجات الحرارة في الفترة من يناير 2004 وحتى ديسمبر 2005، وتضمن الجزء الأخير على أهم الاستنتاجات والتوصيات والملاحق والمراجع. أما الأدوات المستخدمة فهي البرنامج الإحصائي R Core Team (2018).

1. الجانب النظري

نظراً للأهمية البالغة للتنبؤ الدقيق فقد تركز اهتمام الباحثين في دراسة العديد من الطرق والنماذج التنبؤية كان من أبرزها نماذج بوكس-جينكينز والتي أثبتت كفاءتها ودقتها في العديد من المجالات، لذلك سنتناول في هذا الجزء دراسة نماذج السلاسل الزمنية الموسمية ومراحل بنائها وفقاً لأسلوب بوكس-جينكينز. وقبل التطرق إلى النماذج لابد من ذكر بعض التعاريف المتعلقة بأصل البحث.

1-1-1 تعريف ومصطلحات

1-1-1-1 السلسلة الزمنية Time Series

تعرف السلسلة الزمنية بأنها عبارة عن فئة أو سلسلة من المشاهدات أو الأحداث المتتالية لظاهرة معينة مأخوذة على فترات محددة من الزمن تكون على فترات متساوية وفقاً لحدوثها (سنة، فصل، شهر، أسبوع، يوم) أو أية وحدة زمنية. أي أنها عبارة عن بيانات تاريخية يتم اعتمادها لبناء التوقعات المستقبلية [2]، [6].

1-1-1-2 السلاسل الزمنية المستقرة وغير المستقرة Stationary and Non-Stationary Time Series

الماضي، ومن الأساليب الإحصائية المهمة في تحليل السلسلة الزمنية نماذج بوكس-جينكينز حيث تستخدم هذه النماذج لتمثيل سلسلة زمنية تمثل ظاهرة معينة وفي التنبؤ بقيم الظاهرة في المستقبل. ولها تطبيقات كثيرة في المجالات الاقتصادية والأرصاد الجوي.

وقد قام الكثير من الباحثين الإحصائيين بدراسة وتحليل ومعالجة نماذج السلاسل الزمنية منهم الباحثان بوكس وجينكينز حيث قدما دراسة موسعة وتفصيلية لنماذج السلاسل الزمنية الموسمية وغير الموسمية ومراحل بناء هذه النماذج [11]. كما يوجد العديد من الدراسات التي استخدمت نماذج بوكس وجينكينز في التنبؤ في مجالات مختلفة منها التنبؤ بدرجات الحرارة في مدينة بكين بالصين من قبل الباحثين [19] حيث تم تطبيق النموذج الموسمي المختلط من الدرجة $(1,1,1)_{12}(1,0,3)$. وفي العام (2011) قام الباحثان صفاء عبدالله معطي وعبدالرزاق الرازحي بدراسة عن التنبؤ بمعدلات درجات الحرارة الشهرية في مدينة عدن اليمنية باستخدام نماذج بوكس-جينكينز وقد أظهرت النتائج أن السلسلة غير مستقرة لمعدلات درجات الحرارة لمدينة عدن باليمن كما خلصت نتائج الدراسة إلى أن أفضل نموذج ملائم للسلسلة هو نموذج الانحدار الذاتي أو الأوساط المتحركة المختلطة $ARIMA(2,1,1)$ لأنها تحتوي على أقل قيمة لمعيارى AIC و SC وقد أعطى هذا النموذج تنبؤات جيدة وقريبة من القيم الحقيقية. أيضاً قام الباحث بسام يونس إبراهيم بدراسة بعنوان التنبؤ بدرجات الحرارة في ولاية الخرطوم باستخدام أحد نماذج بوكس-جينكينز للسلاسل الزمنية للباحث حيث بينت النتائج أن النموذج الملائم هو النموذج الموسمي المضاعف $ARIMA(0,1,1)(0,1,1)_{12}$. وقد تم التأكد من أن هذا النموذج هو جيد ويعطي تنبؤات دقيقة وقريبة من الواقع من خلال حساب الإحصائية Q التي اتضح عدم معنوياتها.

كما تظهر في العديد من السلاسل الزمنية تأثيرات تتمثل في كونها تأثيرات شهرية أو أسبوعية أو يومية في فترات معينة من السنة، مثل هذه التأثيرات تسمى بالتأثيرات أو التغيرات الموسمية حيث يمكن ملاحظتها في دالتي الارتباط الذاتي والارتباط الذاتي الجزئي والتي تتبع نموذج معين من نماذج ARMA أو ARIMA [11]، [24]. تتبع الأهمية العلمية لهذه الورقة من الأهمية الكبيرة التي تتمتع بها أساليب التنبؤ في تحليل بيانات السلاسل الزمنية الموسمية، وذلك من خلال استخدامها في عمليات اتخاذ القرار ورسم السياسات المستقبلية للقطاعات الحياتية المختلفة، ومن أكثر الأساليب المستخدمة في

وفى حالة السلاسل الزمنية الموسمية يلاحظ ان معاملات الارتباط الذاتي تكون قيمها قريبة أو مساوية للصفر، فى حين تكون قيمها معنوية فقط عند الازاحات $k = 0, s, 2s, \dots$.

1-1-4- Partial (PAC) Autocorrelation

يستخدم الارتباط الذاتي الجزئي كأداة أساسية في تحليل نماذج بوكس - جينكينز الى جانب دالة الارتباط الذاتي حيث تستخدم هاتان الدالتان معاً للتمييز بين نماذج الانحدار الذاتي الجزئية المختلفة بين المشاهدات وفى فترات مختلفة. ويعرف معامل الارتباط الجزئي بأنه مقياس لدرجة العلاقة بين المشاهدين Z_t, Z_{t+s} بثبوت باقي المشاهدات $Z_{t+1}, Z_{t+2}, \dots, Z_{t+s-1}$. ويعتبر الارتباط الجزئي اداة مهمة كونها تستخدم فى تشخيص النموذج وتحديد رتبته ومدى ملائمته من خلال اختبار عشوائية أخطاء التنبؤ (البواقي) [16].

$$\hat{\rho}_s = \frac{Cov \left[(Z_t - Z_t^*) (Z_{t-s} - Z_{t-s}^*) \right]}{Var(Z_t - Z_t^*)} \quad (2)$$

حيث Z_t^*, Z_{t-s}^* يمثلان انحدار كل من Z_t, Z_{t-s} .

1-1-5- Non-Seasonal Time Series Models

تستخدم هذه النماذج لتمثيل كل من السلاسل الزمنية المستقرة والغير مستقرة ومن هذه النماذج [21][22]:

1- نماذج انحدار ذاتي من الرتبة Autoregressive Model AR(P)

بافتراض ان z_{t-p} هي مشاهدات حدثت فى فترات سابقة ولها تأثير على المشاهدة الحالية z_t ، فى هذه الحالة يسمى نموذج الانحدار الذاتي بنموذج انحدار ذاتي من الرتبة (P)، ويكتب بالشكل الآتي

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (3)$$

حيث أن $\mu, \phi_1, \phi_2, \dots, \phi_p$ معالم النموذج و a_t متغيرات عشوائية غير مرتبطة مع بعضها بوسط حسابي صفر وتباين σ_a^2 أي أن:

$$E(a_t) = 0$$

$$E(a_t a_{t+s}) = \begin{cases} 0 & s \neq 0 \\ \sigma_s^2 & s = 0 \end{cases}$$

ويرمز لهذا النموذج بـ $AR(p)$ حيث P تمثل درجة النموذج.

قبل دراسة وتحليل السلوك الدوري لأي ظاهرة يجب اولاً التأكد من وجود اتجاه عام فى السلسلة الزمنية وحسب طبيعة السلسلة يمكن التمييز بين حالتين من الاستقرار وهما الاستقرار فى المتوسط، والاستقرارية فى التباين. فالحالة الاولى هي حالة السلسلة الزمنية عندما لا تظهر اتجاهها عاماً نحو الزيادة أو النقصان ويمكن تحويلها الى مستقرة باستخدام الفروق. أما الحالة الثانية فهي حالة السلسلة عندما لا تظهر تنذبات متباعدة فى شكل السلسلة الزمنية ويمكن تثبيت التباين من خلال احد التحويلات التالية (أخذ اللوغاريتم الطبيعي أو الجذر التربيعي أو المقلوبات) لبيانات السلسلة الزمنية. كما يمكن تمييز السلاسل الزمنية المستقرة عن الغير مستقرة من خلال قيم معاملات الارتباط الذاتي حيث تقترب قيمه من الصفر بعد الفترة الثانية أو الثالثة بالنسبة للسلسلة المستقرة فى حين ان السلاسل الزمنية الغير مستقرة لها فروق معنوية تقترب من الصفر بعد الفترة السابعة أو الثامنة [11].

1-1-3- Auto Correlation Function (ACF)

توضح دالة الارتباط الذاتي لسلسلة زمنية الارتباط الموجود بين المشاهدات لفترات مختلفة وهى ذات أهمية بالغة فى إبراز بعض الخصائص الهامة للسلسلة الزمنية حيث يساعد فى تحديد استقرار السلسلة وكونها موسمية أم لا. كما تستخدم لفحص ملائمة النموذج عن طريق اختبار عشوائية أخطاء التنبؤ، ومن الناحية العملية نقوم بتقدير دالة الارتباط الذاتي من خلال معامل الارتباط الذاتي [8]. يعرف معامل الارتباط الذاتي بأنه مقياس يقيس قوة ودرجة العلاقة بين قيم الظاهرة مع نفسها عند فترات إزاحة موسمية مختلفة، ويقدر معامل الارتباط الذاتي فى حالة السلاسل الزمنية الموسمية وفق الصيغة الرياضية الآتية [26]:

$$\hat{\rho}_s = \frac{Cov(Z_t, Z_{t+s})}{\sqrt{Var(Z_t)Var(Z_{t+s})}} \quad (1)$$

$$= \frac{\sum_{t=1}^{n-s} (Z_t - \bar{Z})(Z_{t+s} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} = \frac{\gamma_s}{\gamma_0}$$

حيث ان Z_t تمثل قيم مشاهدات السلسلة الزمنية وان:

$$\hat{\gamma}_s = \frac{\sum_{t=1}^{n-s} (Z_t - \bar{Z})(Z_{t+s} - \bar{Z})}{T - s}$$

$$\hat{\gamma}_0 = \frac{\sum_{t=1}^{n-s} (Z_t - \bar{Z})^2}{T}$$

أما إذا كانت السلسلة غير مستقرة فيمكن تحويلها إلى مستقرة وذلك بأخذ الفروق المناسبة فمثلاً الفرق الأول يكون وفقاً للمعادلة الآتية:

$$W_t = Z_t - Z_{t-1} \quad (8)$$

ثم تمثل بنفس النماذج السابقة ولكن تضاف فقط كلمة متكاملة Integrated إلى اسم النموذج للدلالة على أن هذا النموذج استخدم لتمثيل سلسلة زمنية غير مستقرة.

4- نماذج الانحدار الذاتي المتكامل والمتوسطات المتحركة Autoregressive-Integrated-Moving Average Model -ARIMA(p,d,q)

من المعلوم أنه لا يمكن تطبيق نماذج ARMA(p,q) إلا في حالة كون السلسلة الزمنية مستقرة، ولتحقيق استقرار السلسلة يجب أخذ الفروق للسلسلة، ويسمى النموذج في هذه الحالة بنموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ARIMA(p,d,q) حيث تشير (p) إلى رتبة الانحدار الذاتي، (d) إلى الفروق، (q) إلى رتبة المتوسطات المتحركة وأن الصورة العامة لهذه النماذج $w_t = \nabla^d z_t$ لتحويلها إلى سلسلة مستقرة [7][16].

ويمكن نمذجة السلسلة المستقرة $w_t = \nabla^d z_t$ على شكل نموذج انحدار ذاتي-متوسط متحرك من الدرجة (p,q)

حيث ∇^d هو عامل الفروق للفروق المتتالية وأن الصورة $W_t = \nabla^d z_t = \nabla z_t$ هو الفرق الأول، ويمكن كتابته على الأزرحة للخلف، حيث $Bz_t = z_{t-1}$ وأن $B^k = z_{t-k}$.

$$\phi_p(B)w_t = \phi_p(B)\nabla^d z_t = \delta + \theta_q(B)a_t, a_t \sim WN(0, \sigma^2) \quad (9)$$

أو

$$\phi_p(B)(1-B)^d z_t = \delta + \theta_q(B)a_t \quad (10)$$

وهذا النموذج يسمى نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية من الدرجة (p,d,q) حيث $\delta \in (-\infty, \infty)$ ثابت النموذج.

6-1-1- نماذج الموسمية Seasonal Time series Models

تتميز السلاسل الزمنية في الواقع بوجود المركبة الفصلية، الشيء الذي يؤدي إلى ارتفاع كل من p,q وبالتالي تصعب عملية تقديرها، وتستخدم لتمثيل السلاسل الزمنية الموسمية [21]. ومن هذه النماذج:

وكحالة خاصة لهذه النماذج هي نماذج الانحدار الذاتي من الرتبة الأولى AR(1).

فإذا كانت بيانات السلسلة الزمنية المستقرة تتولد وفق عملية انحدار ذاتي من الرتبة الأولى فإن المشاهدة الحالية للسلسلة دالة خطية في المشاهدة السابقة لها أي أن (z_t) تعتمد على z_{t-1} مع وجود متغير عشوائي مستقل (a_t) .

$$z_t = \phi z_{t-1} + a_t \quad (4)$$

حيث أن معلمة الانحدار الذاتي والتي تصف أثر المتغير z_{t-1} بوحدة واحدة على z_t وأن a_t متغير عشوائي مستقل يتبع التوزيع الطبيعي بوسط $E(a_t) = 0$ وتباين ثابت $E(a_t, a_s) = \sigma^2, \forall s = t$ و $E(a_t, z_{t-1}) = 0$.

2- نماذج المتوسطات المتحركة Moving Average Model MA(q)

النموذج الذي يعبر عن المشاهدة الحالية z_t بدلالة المتغيرات العشوائية $(a_t, a_{t-1}, \dots, a_{t-q})$ ، بمعنى أن z_t دالة خطية بدلالة المتغيرات العشوائية، ويطلق عليه نموذج متوسط متحرك من الرتبة (q) ويكتب بالصورة:

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (5)$$

وكحالة خاصة لهذه النماذج هي نماذج المتوسطات المتحركة من الرتبة الأولى MA(1)

هو نموذج يمثل العلاقة بين المشاهدة الحالية z_t والخطأ العشوائي السابق a_{t-1} والخطأ العشوائي الحالي a_t بعد حذف المشاهدة السابقة z_{t-1} ويكتب النموذج بالصورة:

$$z_t = a_t - \theta_1 a_{t-1} \quad (6)$$

حيث أن θ_1 هي معلمة المتغيرات المتحركة وهي ثابتة، وأن a_{t-1}, a_t هما متغيرات عشوائية حالية وسابقة وهي مستقلة عن بعضها البعض ولها توزيع طبيعي بمتوسط $E(a_t) = 0$ وتباين ثابت $E(a_t, a_s) = \sigma_a^2, \forall t = s$.

3- نماذج الانحدار الذاتي والمتوسطات المتحركة المختلطة Seasonal Mixed Autoregressive Moving Model- ARMA(p,q)

يعبر عن النموذج المختلط بالصيغة:

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (7)$$

حيث أن (p) تشير إلى عدد معالم الانحدار الذاتي و (q) تشير إلى معالم المتوسطات المتحركة. ومن مميزات النموذج المختلط أنه يؤدي إلى تخفيض عدد معالم النموذج.

وأن: p رتبة الانحدار الذاتي الاعتيادي، P درجة الانحدار الذاتي الموسمي، q رتبة المتوسط المتحرك الاعتيادي، Q رتبة المتوسط المتحرك الموسمي، d رتبة الفروق الاعتيادية، D رتبة الفروق الموسمية S طول فترة الموسم، وان $\phi_p(B)$ معامل الانحدار الذاتي غير الموسمي، $\theta_q(B)$ معامل المتحركة غير الموسمي، $\Phi_P(B^S)$ معامل الانحدار الذاتي الموسمي، $\Theta_Q(B^S)$ معامل الاوساط المتحركة الموسمي وان $\nabla^D = (1-B^S)^D$ يمثل الفروق الموسمية D .

وان $\nabla^d = (1-B)^d$ يمثل الفروق المتتالية من الدرجة d . وان $B^k Z_t = Z_{t-k}$ حيث يرمز للنموذج أعلاه بـ $ARIMA(p,d,q) \times (P,D,Q)_S$.

1-1-7- منهجية بوكس-جينكينز في تحليل السلاسل الزمنية

تحليل السلاسل الزمنية باستخدام نماذج (ARIMA) ذو المتغير الواحد هو أسلوب استخراج التغيرات المتوقعة للبيانات المشاهدة، حيث تتجزأ السلسلة الزمنية الى عدة مكونات خطية وهي الاستقرار المتكامل، والانحدار الذاتي، والمتوسطات المتحركة.

وتتلخص نماذج بوكس-جينكينز في أربع مراحل يتم من خلالها اختيار النموذج الأفضل لغرض التقدير والتنبؤ في نماذج السلاسل الزمنية مع تداخل هذه المراحل فيما بينها أحيانا و هذه المراحل الأربعة الأساسية هي [13].

مرحلة التعرف (التحديد) Identification.

مرحلة التقدير Estimation.

مرحلة التشخيص و الفحص Diagnostic.

مرحلة التنبؤ Prediction.

1- مرحلة تحديد النموذج Identification

تعد هذه المرحلة من أصعب المراحل في بناء نماذج السلاسل الزمنية الخطية، حيث يتم من خلالها تحديد درجة نموذج $ARIMA(p,d,q)$ وذلك كالآتي:

• تحديد درجة التكامل d من خلال تفحص استقرار السلسلة الزمنية الأصلية، فإذا كانت السلسلة غير مستقرة مثل أن يكون لها اتجاه عام فيتم أخذ الفروق من الدرجة الأولى، ثم الفروق من الدرجة الثانية، وهكذا، حتى تصبح مستقرة، وبعد تحقق عامل الاستقرار بعد عدد من الفروق فإن هذا العدد عبارة عن (d) وهناك عدة أساليب للكشف عن استقرار السلسلة مثل

1- نموذج الانحدار الذاتي الموسمي Seasonal Autoregressive Model (SAR)

ويكتب بالشكل الآتي [3]:

$$Z_t = \mu + \phi_S Z_{t-S} + \phi_{2S} Z_{t-2S} + \dots + \phi_{PS} Z_{t-PS} + a_t \quad (11)$$

ويرمز لهذا النموذج بـ $SAR(P)$ حيث P تمثل رتبته.

2- نموذج المتوسطات المتحركة الموسمي Seasonal Moving Average Model (SMA)

وصيغته الرياضية هي:

$$Z_t = \mu + a_t - \theta_S a_{t-S} - \theta_{2S} a_{t-2S} - \dots - \theta_{QS} a_{t-QS} \quad (12)$$

ويرمز لهذا النموذج بـ $SMA(Q)$ حيث Q تمثل رتبته.

3- نموذج الانحدار الذاتي والمتوسطات المتحركة الموسمي

Seasonal Autoregressive Moving Average Model (SARMA)

ويكتب بالشكل الآتي:

$$Z_t = \mu + \phi_S Z_{t-S} + \phi_{2S} Z_{t-2S} + \dots + \phi_{PS} Z_{t-PS} + a_t - \theta_S a_{t-S} - \theta_{2S} a_{t-2S} - \dots - \theta_{QS} a_{t-QS} \quad (13)$$

ويرمز لهذا النموذج بـ $SARMA(P,Q)$ حيث P, Q تمثلان رتبته. أما إذا كانت السلاسل الموسمية غير مستقرة فتحول إلى مستقرة عن طريق أخذ الفرق الموسمي وفق المعادلة الآتية:

$$W_t = Z_t - Z_{t-S} \quad (14)$$

ثم تمثل بنفس النماذج السابقة ولكن تضاف فقط كلمة متكاملة إلى اسم النموذج للدلالة على أن هذا النموذج استخدم لتمثيل سلسلة زمنية غير مستقرة.

4- النموذج الموسمي المضاعف Multiplicative Seasonal Model (SARIMA)

تتميز السلاسل الزمنية بوجود المركبة الفضلية مما يؤدي الى ارتفاع كل من p, q وبالتالي تصعب عملية تقديرهما. ولهذا السبب تم وضع نموذج يسمى بالنموذج المختلط ذو المركبة الموسمية SARIMA، ايضا يعتبر خليط من النماذج اللا موسمية والموسمية [13]، الصيغة العامة للنموذج الموسمي المضاعف من الدرجة $(p,d,q) \times (P,D,Q)_S$ هي:

$$\phi_p(B) \Phi_P(B^S) \nabla^d \nabla_S^D Z_t = \theta_q(B) \Theta_Q(B^S) a_t \quad (15)$$

حيث ان:

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\Phi_P(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$$

$$\theta_q(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$$

$$\Theta_Q(B^S) = 1 + \Theta_1 B^S + \Theta_2 B^{2S} + \dots + \Theta_Q B^{QS}$$

برنامج R. أن طريقة الإمكان الأعظم لتقدير معالم النموذج المختلط ARMA تكتب بالصيغة:

$$L(\theta, \phi, \sigma_a^2 | Z_t) = (2\pi)^{-\frac{N}{2}} (\sigma_a^2)^{-\frac{N}{2}} \text{Exp} \left[-\frac{1}{2\sigma_a^2} S(\theta, \phi) \right] \quad (16)$$

حيث أن $S(\theta, \phi)$ تمثل مجموع مربعات الأخطاء أي:

$$S(\theta, \phi) = \sum_{t=1}^N \hat{a}_t^2(\theta, \phi) \quad (17)$$

$$\text{Ln}L(\theta, \phi, \sigma_a^2) = -\frac{N}{2} \text{Ln}(2\pi\sigma_a^2) - \frac{S(\theta, \phi)}{2\sigma_a^2}$$

وبأخذ التفاضل الجزئي للدالة الأخيرة بالنسبة لكل من σ_a^2, θ, ϕ ومساواة التفاضلات بالصفر نحصل على التقديرات $\hat{\sigma}_a^2, \hat{\theta}, \hat{\phi}$ على التوالي.

3- مرحلة التشخيص Diagnostic

بعد الانتهاء من مرحلتي التحديد وتقدير النموذج وقبل استخدام النموذج لحساب التنبؤات المستقبلية يجب اختبارها للتأكد من صحته وكفائته ويتم ذلك من خلال الطرق التالية:

- اختبار معاملات الارتباط الذاتي للبقايا

نقارن فيها دالة الارتباط الذاتي للسلسلة الأصلية مع تلك المتولدة عن النموذج المقدر، فإذا لوحظ وجود اختلاف جوهري بينهما، فإنه يدل على فشل عملية التحديد، وهذا يستدعي إعادة عملية بناء النموذج وتقديره من جديد. أما إذا تشابهت الداليتان فإننا ننتقل إلى دراسة وتحليل بواقي التقدير مع دالة الارتباط الذاتي للبقايا بحيث أن:

$$\hat{\rho}_k(\hat{a}_t) = \frac{\sum_{t=1}^N \hat{a}_t \hat{a}_{t+k}}{\sum_{t=1}^N \hat{a}_t^2} \quad (18)$$

يجب أن تقع معاملات الارتباط الذاتي للبقايا داخل مجال الثقة المعبر عنه بيانياً بخطين $\left[-\frac{t\alpha/2}{\sqrt{T}}, \frac{t\alpha/2}{\sqrt{T}} \right]$ تحت فرضية التوزيع الطبيعي لدالة الارتباط الذاتي وقد أثبت كل من [14] أن معاملات الارتباط الذاتي للبقايا تتوزع توزيعاً طبيعياً بمتوسط صفر وتباين $\frac{1}{T}$ حيث T تمثل حجم العينة، وعليه فإن: أي

$$\hat{\rho}(k) \sim N\left(0, \frac{1}{T}\right) \text{ وأن:}$$

$$Q = T \sum_{i=1}^k \hat{\rho}_k^2(i) \sim \chi_{\alpha, (k-p-q)}^2 \quad (19)$$

حيث تمثل k أكبر عدد لمعاملات الارتباط الذاتي، فإذا كانت قيمة Q المحسوبة أقل من χ^2 الجدولية فهذا يشير إلى كفاءة وملائمة النموذج للبيانات وبذلك يعني أن السلسلة مستقرة [9].

اختبار جذر الوحدة لديكي-فولار، واختبار ديكي-فولار الموسع، وكذلك اختبار (KPSS) [19].

• تحديد درجة الانحدار الذاتي p ، ودرجة المتوسط المتحرك q ، ويتم باستخدام الدالة الارتباط الذاتي والجزئي، بحيث إذا كان شكل الارتباط يقع داخل حدود فترة الثقة % 95 منذ البداية، فإن معامل الارتباط الذاتي لا يختلف جوهرياً عن الصفر وهذا يعني أن السلسلة مستقرة ومتكاملة من الدرجة صفر وفي هذه الحالة نجري تحليلاً على القيم الأصلية للمتغير Z_t دون إجراء تحويلات عليها، أما إذا اتضح أن شكل الارتباط الذاتي يقع خارج مجال الثقة في فترة طويلة ومعاملات الارتباط الذاتي تختلف معنوياً عن الصفر من أجل S كبيرة نسبياً فإن السلسلة تكون غير مستقرة.

والجدول (1) يحتوي على ملخص للأنماط المختلفة لدالاتي الارتباط الذاتي والارتباط الذاتي الجزئي للنماذج غير الموسمية والموسمية المستقرة المختلفة.

جدول 1: دالاتي الارتباط الذاتي والارتباط الذاتي الجزئي للنماذج غير

الموسمية والموسمية المستقرة المختلفة [24]		
النموذج	دالة الارتباط الذاتي	دالة الارتباط الذاتي الجزئي
	ACF	PACF
AR(p)	تقرب من الصفر تدريجياً	تقرب من الصفر بعد الفترة الزمنية p
MA(q)	تقرب من الصفر بعد الفترة الزمنية q	تقرب من الصفر تدريجياً
ARMA(p,q)	تقرب من الصفر تدريجياً	تقرب من الصفر بعد الفترة الزمنية p+SP
$AR(p) \times SAR(P)$	تقرب من الصفر تدريجياً	تقرب من الصفر بعد الفترة الزمنية p+SP
$MA(q) \times SMA(Q)$	تقرب من الصفر بعد الفترة الزمنية q+SQ	تقرب من الصفر تدريجياً
$ARMA(p,q) \times (P,Q)$	تقرب من الصفر تدريجياً	تقرب من الصفر تدريجياً

2- مرحلة التقدير Estimation

بعد أن يحدد النموذج وتحدد رتبته (p, d, q) ، يتم تقدير معالم النموذج، أي إيجاد قيم كل من $(\theta_1, \dots, \theta_q, \delta)$ ، (ϕ_1, \dots, ϕ_p) وذلك من خلال بيانات السلسلة Z_1, Z_2, \dots, Z_n . وهناك عدة طرق يمكن من خلالها تقدير المعالم منها طريقة العزوم، وطريقة المربعات الصغرى، وطريقة الإمكان الأعظم. وفي هذه الورقة سوف نعتمد طريقة الإمكان الأعظم باستخدام

بعد الانتهاء من الخطوات السابقة، وبعد ان أصبح النموذج مناسباً يمكن استخدامه في التنبؤ بالقيم المستقبلية، والتي تعتبر الهدف النهائي من دراسة السلاسل الزمنية.

للتنبؤ بالقيم المستقبلية للسلسلة الحالية ولنفرض ان Z_n هي المشاهدة الحالية للسلسلة في الزمن الحالي (n) وإذا اردنا أن نتنبأ بقيمة المشاهدة Z_{n+h} والتي ستحدث في الزمن ($n+h$) حيث (h) تمثل أفق التنبؤ ولنفرض ان $Z_{n(h)}$ تمثل القيمة التنبؤية التي نحصل عليها في الفترة الزمنية (n) للمشاهدة Z_{n+h} والتي ستحدث بعد (h) من الفترات الزمنية، لذا يمكن اعتبار ان Z_{n+h} متغير عشوائي علينا معرفة خصائص التوزيع الاحتمالي له والذي يعتمد على المشاهدة الحالية والمشاهدة السابقة [11].

وسوف نعتمد على التنبؤ بفترة لأنه يعطي فرصة أكبر من التنبؤ بنقطة لان النقطة المتنبأ بها تقع ضمن فترة بين حدين الاعلى والادنى وباحتمال كبير. اي ان $P(a \leq Z_{n+h} \leq b) = 1 - \alpha$ وباحتمال $[(1-\alpha)\%]$ [7].

تعتمد أغلب مقاييس دقة التنبؤ على الانحرافات بين القيم الفعلية للسلسلة والقيم المقدرة ومن بين هذه المقاييس:

- متوسط الأخطاء المطلقة **Mean Absolute Errors(MAE)**

بحسب مقياس متوسط الأخطاء المطلقة من خلال الصيغة:

$$MAE = \frac{1}{T} \sum_{t=1}^T |\varepsilon_t|$$

- متوسط مربعات الأخطاء **Mean Square Errors(MSE)**

والصيغة المستخدمة لحساب هذا المقياس هي:

$$MSE = \frac{1}{T} \sum_{t=1}^T \varepsilon_t^2$$

- متوسط الأخطاء النسبي **Mean Percentage Errors (MPE)**

يعطي هذا المقياس بالعلاقة التالية:

$$MPE = \frac{1}{T} \sum_{t=1}^T \frac{\varepsilon_t}{Z_t} * 100$$

- متوسط الأخطاء المطلقة النسبية **Mean Absolute Percentage Errors (MAPE)**

يعطي هذا المقياس بالعلاقة التالية:

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{\varepsilon_t}{Z_t} \right| * 100$$

كما انه توجد إحصائية أخرى بديلة تستخدم في إجراء نفس الاختبار السابق تسمى بإحصائية Ljung-Box وهي إحصائية Box-Pierce المعدلة والتي تعرف بالصيغة:

$$Q^* = T(T+2) \sum_{i=1}^K (T-i) \hat{\rho}^2(i) \sim \chi_{\alpha, (k-p-q)}^2 \quad (20)$$

حيث يمكن استخدامها للعينات الصغيرة والكبيرة على حد سواء حيث تعطي نتائج أفضل من Q.

كذلك يجب ان تقع معاملات الارتباط الذاتي الكلية لمربعات البواقي داخل مجال الثقة $\left[-\frac{t\alpha/2}{\sqrt{T}}, \frac{t\alpha/2}{\sqrt{T}} \right]$ في هذه الحالة تكون سلسلة مربعات البواقي مستقرة. أي ان التباين الشرطي للأخطاء متجانس.

- معايير المفاضلة بين عدة نماذج مختارة

في بعض الاحيان يكون هناك مجموعة من النماذج غير مرفوضة بواسطة الأدوات الإحصائية، وللقيام بالمفاضلة بين هذه النماذج واختيار النموذج الأفضل نستعمل المعايير التالية:

مقياس أكيكي **Akaike Information Criterion (AIC)** [11]

يعد مقياس أكيكي من أكثر معايير المفاضلة استخداماً وبحسب العلاقة:

$$AIC(p, q) = \hat{\sigma}^2 e^{2\left(\frac{p+q}{T}\right)} \quad (21)$$

حيث أن $\hat{\sigma}^2$ تمثل تباين البواقي محسوباً بطريقة الامكان الاعظم، وان $(p+q)$ تشير الى عدد المعالم المقدرة. ويكون الاختبار على أساس أصغر قيمة للمعيار، اي ان النموذج الافضل هو الذي يحظى بأصغر قيمة للمعيار.

مقياس شوارز **Bayesian Information Criterion (BIC)** [23]

ويتم حساب هذا المعيار من خلال الصيغة:

$$BIC = \ln(\hat{\sigma}^2) + \left(\frac{p+q}{T}\right) \ln(T) \quad (22)$$

ويكون اختيار النموذج الافضل على أساس أصغر قيمة للمعيار.

مقياس هاتان كوينن **Hannan-Quinn Criterion (HQc)** [17]

$$HQ(p, q) = \ln(\hat{\sigma}^2) + (p+q) C \frac{\ln(\ln T)}{T}, C > 2 \quad (23)$$

حيث أن $\hat{\sigma}^2$ تمثل تباين البواقي محسوباً بطريقة الامكان الاعظم، وان $(p+q)$ تشير الى عدد المعالم المقدرة. ويكون الاختبار على أساس أصغر قيمة للمعيار، اي ان النموذج الافضل هو الذي يحظى بأقل قيمة للمعيار.

-4 مرحلة التنبؤ **Prediction**

2. الجانب التطبيقي

في الجانب النظري تم التطرق الى الخطوات الرئيسية لمنهجية بوكس جينكينز في كيفية بناء نماذج ARIMA وكذلك اختبار مدى ملائمة النموذج وموافقته للبيانات تحت الدراسة.


في هذا الجزء سنطبق عمليا كل ما ورد سابقا لاختيار النموذج المناسب لسلاسل درجات الحرارة الشهرية المسجلة بمدينة طرابلس، وسوف نتبع الخطوات التالية:

2-1- الدراسة الوصفية لبيانات سلسلة المعدلات الشهرية لدرجة الحرارة:


البيانات المستخدمة في هذه البحث تمثل سلسلة زمنية لمعدلات درجات الحرارة بمدينة طرابلس بواقع (516) مشاهدة حيث تمتد من الفترة (يناير 1961 - ديسمبر 2003)، بمتوسط قدره (20.62)، وقيمة دنيا (9.40)، وقيمة قصوي (31.60). تشتت قيم هذه السلسلة عن متوسطها بانحراف معياري قدره (6.03). البيانات أُخذت من شريط (2010). وهذه البيانات تمثل جزء من البيانات التي قامت الباحثة بتجميعها من مركز الارصاد الجوية طرابلس [10].

2-2- تحليل السلسلة الزمنية:


2-2-1- رسم السلسلة الزمنية: للتعرف على الخصائص الاولى للسلسلة الزمنية بالمالحق (1) تم رسمها بيانيا. ويلاحظ من خلال الشكل أن السلسلة الزمنية مستقرة، ولتأكيد استقرارية السلسلة تم رسم دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF)، ومن خلال الشكل (3) تم استخراج معاملات الارتباط الذاتي والارتباط الذاتي الجزئي والتي يظهر فيها ان معاملات دالة الارتباط الذاتي حتى الفجوة (12) تختلف معنويا عن الصفر، وان معاملات الارتباط الذاتي لا تدخل ضمن حدود الثقة (0.086، -0.086) وباستخدام اختبار Ljung-Box لاختبار المعنوية الكلية لمعاملات دالة الارتباط الذاتي تبين ان (p-value < 0.001) لذلك نرفض فرضية العدم مما يعنى اسقرارية السلسلة الزمنية.



شكل 1: المنحنى الزمني للسلسلة الزمنية الاصلية



شكل 2: مخطط العرض الصندوقي للمعدلات الشهرية لدرجات الحرارة من يناير 1961 وحتى ديسمبر 2003



شكل 3: معاملات الارتباط الذاتي والارتباط الذاتي الجزئي لمعدلات درجات الحرارة الشهرية

2-2-2- اختبار استقرارية السلسلة الزمنية: كما سبق وان ذكرنا في الجانب النظري لهذه الدراسة ان السلسلة الزمنية مستقرة اذا تنبذت حول وسط حسابي ثابت مع تباين ليس له علاقة بالزمن ولاختبار استقرارية السلسلة الزمنية من عدمه يوجد عدة اختبارات وأدوات إحصائية منها اختبار ديكي فولر المعدل (ADF)، حيث يعتمد هذا الاختبار على النماذج الرياضية التالية:

$$\nabla Y_t = \lambda Y_{t-1} + \sum_{i=1}^p \alpha_i \nabla Y_{t-i} + \varepsilon_t$$

$$\nabla Y_t = \mu + \beta T + \lambda Y_{t-1} + \sum_{i=1}^p \alpha_i \nabla Y_{t-i} + \varepsilon_t$$

$$\nabla Y_t = \mu + \beta T + \lambda Y_{t-1} + \sum_{i=1}^p \alpha_i \nabla Y_{t-i} + \varepsilon_t$$

حيث أن μ الحد الثابت، T الاتجاه الزمني بحيث أن

$$T = t - 1 - \frac{n}{2}, t = 2, 3, \dots, n$$

والتي يمكن تحديدها اعتمادا على الصيغة التالية

$$p = \text{int} \left\{ \text{egr} \left\{ 12 \left(\frac{n}{100} \right)^{\frac{1}{4}} \right\} \right\}$$

اتجاه زمني في النموذج الثاني وكذلك إدخال الحد الثابت وحد الاتجاه العام يتمثل في الزمن T في النموذج الثالث. وفي جميع الحالات الثلاثة يكون الفرض المراد اختباره هو:

2-2-4- التقدير: بعد المفاضلة بين عدة نماذج من خلال الدالة (aout.arima) والموجودة بالمكتبة (forecast)، توصلنا الى النموذج الملائم وهو SARIMA(1,0,5)(0,0,2)₁₂ وذلك من خلال معايير المفاضلة AIC-BIC-HQC ومعنوية المعالم واختبار تجانس التباين. وبتطبيق طريقة الامكان الاعظم على بيانات السلسلة الزمنية قيد الدراسة تم الحصول على النتائج التالية:

جدول 3: نتائج النموذج ARIMA (1,0,5) × (0,0,2)₁₂

المقدر	القيمة	الخطأ المعياري	احصاء الاختبار	القيمة الاحتمالية
الحد المطلق	20.61	0.115	179.3951***	0.000
AR(1)	0.66	0.055	12.1915***	0.000
MA(1)	0.08	0.064	1.3685	0.171
MA(2)	0.02	0.046	0.5033	0.614
MA(3)	-0.27	0.037	7.3672***	0.000
MA(4)	-0.31	0.045	6.9285***	0.000
MA(5)	-0.28	0.042	6.7835***	0.000
SMA(1)	0.443	0.047	9.2317***	0.000
SMA(2)	0.40	0.044	9.1041***	0.000

جدول 4: معايير المفاضلة للنموذج

ARIMA (1,0,5) × (0,0,2)₁₂

المعيار	القيمة
AIC	2225.63
SBIC	2268.09
HQC	2226.04

يتبين من الجدول (3) أعلاه معنوية المقدرات وقلة تباين الخطأ، وبهذا يكون النموذج المقدر لتمثيل السلسلة الزمنية لدرجات الحرارة هو:

$$(1 - 0.66B)Z_t = 20.61 + (1 + 0.09B + 0.02B^2 - 0.28B^3 - 0.31B^4 - 0.29B^5)a_t$$

$$Z_t = 20.61 + 0.66Z_{t-1} + (1 + 0.09B + 0.02B^2 - 0.28B^3 - 0.31B^4 - 0.29B^5)$$

$$(1 + 0.44B^{12} + 0.40B^{24})a_t$$

2-2-5- التنبؤ: بعد الانتهاء من مرحلة التشخيص وتقدير معالم النموذج تأتي مرحلة التنبؤ والتي يتم خلالها حساب متوسط البواقي حيث يجب ان تقترب من الصفر لكي يكون النموذج المقدر ملائم لتمثيل السلسلة الزمنية، وكما موضح بالجدول التالي:

فرضية العدم: السلسلة غير مستقرة $H_0: \lambda = 0$
 الفرضية البديلة: السلسلة مستقرة $H_1: \lambda \neq 0$
 كذلك اختبار فيليبس بيرون (PP)، واختبار (KPSS)، وكخلاصة لدراسة استقرارية السلسلة الزمنية قيد الدراسة توصلنا إلى النتائج التالية:

جدول 1: اختبارات استقرارية السلسلة الزمنية

نوع الاختبار	P-value	القرار
ADF	0.01	مستقرة
PP	0.01	مستقرة
KPSS	0.1460	5% T-statistic
	0.0116	


من خلال إجراء الاختبارات الثلاثة يتبين انه بالنسبة لاختبار ديكي فولر المعدل معنوي عند مستوى معنوية 5% وبالتالي فان السلسلة مستقرة، وكذلك بالنسبة لاختبار فيليبس بيرون. اما بالنسبة لاختبار KPSS نلاحظ ان قيمة إحصائية الاختبار للسلسلة هي أصغر من قيمتها الجدولية عند مستوى معنوية 5% أي أن $(0.0116 < 0.1460)$ وبالتالي فان السلسلة مستقرة.

2-2-3- التشخيص: ويقصد التعرف على النموذج واختبار مدى ملائمة النموذج لتمثيل السلسلة الزمنية ويتم ذلك بتحليل البواقي من خلال تحديد رتبة النماذج ARIMA وذلك بالاعتماد على شكل دالة الارتباط الذاتي (Colegram) ومن خلال هذا المؤشر نستنتج ان النموذج الملائم هو النموذج الموسمي المضاعف من الدرجة SARIMA(1,0,5)(0,0,2)₁₂ اي

$$\phi_p(B)\Phi_p(B^{12})\nabla^d\nabla_{12}^D Z_t = \theta_q(B)\Theta_q(B^{12})a_t \quad (24)$$

$$(1 - \phi_1 B)Z_t = \mu + (1 + \theta_1 B + \theta_2 B^2 + \theta_3 B^3 + \theta_4 B^4 + \theta_5 B^5)$$

$$(1 + \Theta_1 B^{12} + \Theta_2 B^{24})a_t \quad (25)$$



شكل 4: دالة الارتباط الذاتي والذاتي الجزئي للبواقي للنموذج

ARIMA (1,0,5) × (0,0,2)₁₂

3. الاستنتاجات والتوصيات

إن هدف الدراسة الأساسي هو تحليل السلاسل الزمنية الموسمية باستخدام نموذج بوكس-جينكنز الموسمي لغرض التنبؤ بمعدلات درجات الحرارة الشهرية في مدينة طرابلس. حيث تم تطبيق ما ورد في الإطار النظري وقد توصل الباحثان إلى جملة من الاستنتاجات والتوصيات.

1-3 الاستنتاجات:

1- أن نماذج **SARIMA** تتطلب إجراء العديد من الخطوات منها اختبار استقرار السلسلة الزمنية للبيانات الأصلية، تقدير معالم النموذج مع التأكد من ملائمة النموذج للبيانات من خلال تحليل البواقي.

2- إن معدلات درجات الحرارة الشهرية لمدينة طرابلس تعتبر سلسلة زمنية مستقرة وموسمية أي أنها تعيد نفسها كل (12) شهراً وذلك من خلال قيم معاملات الارتباط الذاتي، وأن درجات الحرارة تتبع النموذج الموسمي المضاعف $ARIMA(1,0,5) \times (0,0,2)_{12}$ ، وقد تم التنبؤ بالقيم المستقبلية من شهر يناير 2004 وحتى ديسمبر 2005م. كما تم حساب فترات الثقة للقيم المتنبأ بها وقد أعطيت تنبؤات مقاربة من القيم الفعلية.

2-3 التوصيات:

من خلال نتائج هذه الدراسة تم التوصل إلى التوصيات التالية:

1- توسيع الدراسة بحيث تشمل عوامل مناخية أخرى ككميات الأمطار أو الرطوبة وغيرها.

2- يمكن للجهات ذات الاختصاصات المشابهة الاستفادة من هذه الدراسة وذلك بتطبيق النماذج الموسمية المضاعفة لأغراض التنبؤ.

3- من الممكن استخدام نماذج هولت وينترس لتحليل السلاسل الزمنية الموسمية لما تمتاز به من مرونة وسهولة وتعطي نتائج جيدة وملائمة للبيانات.

المراجع

- [1]- أبو صالح محمد صبحي (2000): الطرق الإحصائية. دار اليازوري للنشر، عمان، الأردن.
- [2]- [السعدي سليم ذياب (2004): مبادئ علم الإحصاء. دار الكتاب الجديد المتحدة، بيروت، لبنان.
- [3]- بثينة عبد الجبار عبدالعزيز و رياض مرتضي زين العابدين (1985): تطبيق أحد نماذج بوكس-جينكنز

جدول (5): متوسط البواقي ومعايير دقة التنبؤ الخاصة بنموذج

$$SARIMA(1,0,5) \times (0,0,2)_{12}$$


MASE	MAPE	MPE	MAE	RMSE	متوسط البواقي ME
1.106	8.74	-2.12	1.625	2.038	-0.006

وبناء على هذه النتائج تم تطبيق النموذج أعلاه للتنبؤ بالمعدلات الشهرية لدرجات الحرارة لمدينة طرابلس لفترة 24 شهراً أي من يناير 2004 وحتى ديسمبر 2005 وبناء فترة ثقة، والنتائج موضحة بالجدول التالي:

جدول 6: التنبؤ بمعدلات الشهرية لدرجات الحرارة وفق

$$SARIMA(1,0,5) \times (0,0,2)_{12}$$

السنوات	فترة الثقة للتنبؤ بدرجة ثقة %90		القيمة المتوقعة للمعدل الشهري لدرجة الحرارة
	الحد الأدنى	الحد الأعلى	
1:2004	9.54	17.60	13.57
2:2004	7.97	18.04	13.00
3:2004	9.09	20.00	14.55
4:2004	13.69	24.61	19.15
5:2004	15.81	26.94	21.38
6:2004	17.50	29.25	23.37
7:2004	19.11	31.13	25.12
8:2004	19.17	31.29	25.23
9:2004	17.57	29.74	23.65
10:2004	16.89	29.08	22.99
11:2004	14.57	26.77	20.67
12:2004	12.16	24.37	18.26
1:2005	11.34	23.99	17.66
2:2005	9.97	22.87	16.42
3:2005	10.70	23.71	17.20
4:2005	13.29	26.30	19.79
5:2005	14.28	27.33	20.81
6:2005	15.30	28.46	21.88
7:2005	16.24	29.45	22.84
8:2005	15.85	29.07	22.46
9:2005	15.26	28.49	21.87
10:2005	15.84	29.08	22.46
11:2005	14.41	27.65	21.03
12:2005	12.96	26.20	19.58



شكل 5: المنحنى الزمني لمعدلات درجات حرارة الممتبأ بها مع فترات الثقة

- Methods, 2nd edition, Springer Verlag, New York Inc, New York.
- [16]- Brocklebank , John C. Dickey, David A. (2003): SAS for Forecasting and Time Series, SAS Institute Inc., Cary, NC, USA.
- [17]- Chin, E. H. (1977): Modeling daily precipitation occurrence process with Markov Chain. Water Resour. Res. 13(6).
- [18]- Hannan E.J, Quinn B.G (1979): The determination of the order of an autoregression. Journal of Royal Statistical Society, 41:190 – 195
- [19]- Hung Wenjie and Hongxing (1980): ARIMA Seasonal of Time Series and its Application to long Range Weather Forecasting, WMO Symposium on Probabilistic and Statistical Methods in Weather Forecasting.
- [20]- Kwiatkowski, D.; Phillips, P. C. B.; Schmidt, P.; Shin, Y. (1992): Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of Econometrics*. 54:159–178.
- [21]- Makridakis, S., Wheelwright, S. and McGaee, V. (1983): Forecasting Methods and Applications, 2nd edition, John Wiley & Sons. Inc., U.S.A.
- [22]- Nelson, G. R. (1973): Applied Time Series Analysis For Managerial Forecasting, Holden-Day, Inc.
- [23]- R Development Core Team (2017). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org/>.
- [24]- Sela, Rebecca (2004): Forecasting time series data, stern business school.
- [25]- Schwarz, G. (1978): Estimating the dimension of a model. *Annals of Statistics*, 6:461 –464.
- [26]- Vandaele, W. (1983): Applied Time Series and Box-Jenkins Models, John Wiley & Sons.
- [27]- Wie, W. S. (1990): Time Series Analysis: Univariate and Multivariate Methods, Addison-Wesley Publishing Company Inc., U.S.A.
- للسلاسل الزمنية للتنبؤ بدرجات الحرارة في مدينة الموصل، مجلة تنمية الرافدين، المجلد السابع، العدد الخامس عشر.
- [4]- بسام يونس إبراهيم (2004): التنبؤ بدرجات الحرارة في ولاية الخرطوم باستخدام نماذج بوكس-جينكنز للسلاسل الزمنية، مجلة كلية العلوم، جامعة السودان.
- [5]- صفاء عبدالله معطي وعبدالرزاق الرازحي (2011): التنبؤ بمعدلات درجات الحرارة الشهرية في مدينة عدن باستخدام نماذج بوكس-جينكنز للسلاسل الزمنية، جامعة عدن.
- [6]- طمعة حسن ياسين وحنوش إيمان حسين، (2009): طرق الاحصاء التطبيقي، دار صفاء للنشر والتوزيع، عمان، الأردن.
- [7]- عدنان ماجد عبد الرحمن بري (2002) : طرق التنبؤ الإحصائي، جامعة الملك سعود
- [8]- محمد شبيخي (2012): طرق الاقتصاد القياسي محاضرات وتطبيقات، دار الحامدي للنشر والتوزيع، عمان، الأردن.
- [9]- مولود حشمان (1998): نماذج وتقنيات التنبؤ قصير المدى، ديوان المطبوعات الجامعية، OPU، الجزائر.
- [10]- نهلة محمد شرميط (2010). استخدام التحليل الإحصائي لبيانات المناخ الدالية: دراسة تطبيقية. رسالة ماجستير غير منشورة ، الأكاديمية الليبية، طرابلس، ليبيا.
- [11]- والتر فاندل (1992): السلاسل الزمنية من الوجهة التطبيقية ونماذج بوكس-جينكنز، تعريب عبدالمرضي حامد العزام، دار المريخ للنشر، الرياض، المملكة العربية السعودية.
- [12]- Akaike, H. (1969): Fitting autoregressive models for prediction. *Annals of the Institute of Statistical Mathematics*, 21:243 – 247.
- [13]- Box G. E. P. and Jenkins G. M. T. (1976): Time Series Analysis, Forecasting and Control, Sanfrancisco, Holden-Day, U.S.A.
- [14]- Box, G. M. P. and Pierce, D. A. (1970): Distribution of Residual Autocorrelation in Autoregressive Integrated Moving Average Time Series Models, John Wiley & Sons.
- [15]- Brock Well, P.J. and Davis, R.A. (1991): Time Series Theory and