https://jsras.rcc.edu.ly/
Vol.3 No.2 (2026), 124-133
Article history:
Received: 20 Aug.2026
Accepted: 10 Sep .2026
Published: 4 Oct.2026

Journal of Sustainable Research in Applied Sciences

JSRAS

Performance Evaluation of ARIMA and SARIMA Models for Modeling and Forecasting Passenger Numbers at Misurata International Airport (2021–2025)

Emhemed Baawa [1,*], emhemmedmilad2017@gmail.com , Mohammed Shafi [2], Shafistat15979@ctsm.edu.ly
[1] Affiliations of Authors: Statistics , Faculty of Science , Misrata University , Misurata, Libya.
[2] Affiliations of Authors: Statistics , Faculty of Technical Sciences ,Ministry Technical Education , Misurata, Libya.
* Corresponding author: Emhemmed Baawa

Keywords

Time Series, ARIMA Models, Seasonal SARIMA Models, Passenger Traffic, Misrata International Airport

Abstract

This study compares the performance of ARIMA and SARIMA models in modeling and forecasting the number of air passengers at Misrata International Airport, using monthly time-series data covering the period from 2021 to 2025. The study adopts the Box–Jenkins methodology to construct and compare several models, including ARIMA(1,1,1), SARIMA(1,1,1)(0,0,1), and SARIMA(1,1,1)(0,1,0). The models were evaluated and compared using several statistical criteria and forecasting accuracy measures, including Mean Absolute Error (MAE), Root Mean Square Error (RMSE), the Coefficient of Determination (R^2), and the Akaike Information Criterion (AIC). The results demonstrate that the seasonal SARIMA models outperform the ARIMA model in capturing the seasonal patterns of the time series and improving forecasting accuracy. The SARIMA(1,1,1)(0,1,0) model achieved the highest coefficient of determination R^2 = (0.9535) and the lowest values of RMSE (511.28) and MAE (415.047). In contrast, the SARIMA(1,1,1)(0,0,1) model achieved the lowest AIC value AIC = (19.2539). Based on the forecasting accuracy measures, the SARIMA(1,1,1)(0,1,0) model was found to be the most suitable model for representing the seasonal behavior of passenger numbers at Misrata International Airport. These findings indicate that incorporating a seasonal component into time-series models can enhance modeling efficiency and improve the accuracy of passenger traffic forecasts.

تقييم أداء نماذج ARIMA و SARIMA في النمذجة والتنبؤ بعدد ركاب مطار مصراته الدولي خلال الفترة (2021-2025)

[1]. أ. امحمد بعوه، [2]. أ. محمد الشعافي
[1]كلية العلوم، الإحصاء، مصراتة، ليبيا، emhemmedmilad2017@gmail.com
[2]كلية العلوم التقنية- مصراتة ، القسم العام، مصراتة، ليبيا، Shafistat15979@ctsm.edu.ly
* المؤلف المراسل: أ. امحمد بعوه

الكلمات المفتاحية

السلاسل الزمنية، نماذج **ARIMA** نماذج **SARIMA** الموسمية، حركة المسافرين، مطار مصراته الدولي.

الملخص

تهدف هذه الدراسة إلى مقارنة أداء نماذج ARIMA و SARIMA في النمذجة والتنبؤ بأعداد المسافرين عبر الرحلات الجوية في مطار مصراته الدولي، باستخدام سلسلة زمنية شهرية للفترة (2021 – 2025). اعتمد هذه الدراسة على منهجية بوكس – جينكنز (Box-Jenkins) لبناء مقارنة بين عدد من النماذج، وشملت:
ARIMA(1 , 1 , 1) ، SARIMA(1 , 1 , 1)(0 , 1 , 0) و SARIMA(1 , 1 , 1)(0 , 0 , 1) وقد تم المفاضلة بين هذه النماذج باستخدام بعض المعايير الإحصائية ومقاييس دقة التنبؤ من بينها: AIC , R^2 , RMSE , MAE . وقد أظهرت النتائج تفوق النماذج الموسمية SARIMA على نموذج ARIMA في تمثيل الأنماط الموسمية للسلسلة وتحسين دقة التنبؤ، كما حقق النموذج SARIMA(1 , 1 , 1)(0 , 1 , 0) أعلى قيمة لمعامل التحديد (R^2 = 0.9535)، وأدنى قيمة لكل من RMASA = (511.28)، MAE = (415.047) في حين حقق النموذج SARIMA(1 , 1 , 1)(0 , 0 , 1) أقل قيمة لمعايير AIC = (19.2539) وبناء على دقة مقاييس التنبؤ أظهر النموذج SARIMA(1 , 1 , 1)(0 , 1 , 0) أنه أكثر ملائمة لتمثيل السلوك الموسمي لأعداد المسافرين في مطار مصراته الدولي، وتشير هذه النتائج إلى أن تضمين المكون الموسمي في نماذج السلاسل الزمنية يمكن أن يحسن من كفاءة النمذجة ودقة التنبؤ بحركة المسافرين.

1.المقدمة

تُعد حركة المسافرين من المؤشرات المهمة في تخطيط وتطوير خدمات النقل الجوي، لما لها من ارتباط مباشر بتحديد احتياجات المطارات من الموارد والتجهيزات والخدمات، ونظراً إلى أن أعداد المسافرين يتغير بمرور الزمن وقد يتأثر بأنماط موسمية متكررة، فإن استخدام نماذج السلاسل الزمنية يوفر وسيلة مناسبة لفهم هذه التغيرات والتنبؤ بالقيم المستقبلية.

تعد نماذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة (ARIMA) من النماذج التقليدية الشائعة في تحليل السلاسل الزمنية والتنبؤ بها، إلا أن قدرتها على تمثيل الأنماط الموسمية تكون محدودة عند وجود موسمية واضحة في البيانات، وفي هذه الحالة، توفر نماذج ARIMA الموسمية SARIMA إطاراً أكثر ملاءمة من خلال تضمين المكونات الموسمية ضمن عملية النمذجة.

لذا جاءت هذه الدراسة للمقارنة بين نماذج ARIMA ، SARIMA في النمذجة والتنبؤ بأعداد المسافرين الشهرية في مطار مصراته الدولي، بالاعتماد على بيانات شهرية للفترة من 2021 إلى 2025 وتحديد النموذج الأكثر ملاءمة للسلسلة الزمنية محل الدراسة من خلال مجموعة من معايير تقييم الأداء ودقة التنبؤ، وذلك للاستفادة منه في التنبؤ بحركة المسافرين، بما يدعم التخطيط واتخاذ القرارات المتعلقة بإدارة وتطوير خدمات المطار.

1.1 أهمية وأهداف الدراسة:

تأتي أهمية هذه الدراسة من أهمية التنبؤ بحركة المسافرين في دعم التخطيط وإدارة الموارد والخدمات بالمطارات، خاصة في ظل وجود أنماط موسمية في أعداد المسافرين، وتهدف إلى مقارنة نماذج ARIMA ، SARIMA في النمذجة والتنبؤ بأعداد المسافرين الشهرية في مطار مصراته الدولي خلال الفترة من2021 إلى 2025، وتحديد النموذج الأكثر ملاءمة من خلال مجموعة من معايير تقييم الأداء ودقة التنبؤ.

2.1 الدراسات السابقة:

نالت نماذج السلاسل الزمنية اهتمام واسع في مجال التنبؤ بحركة المسافرين، وخاصة نماذج ARIMA ، SARIMA لما تتميز به من قدرة على تمثيل الاتجاهات والتغيرات الموسمية في بيانات النقل الجوي.

- أجرى Tsuiet al.(2014) دراسة هدفت إلى التنبؤ بحركة المسافرين في مطار هونغ كونغ الدولي، باستخدام منهجية بوكس – جينكينز ونماذج SARIMA ، ARIMAX وأظهرت النتائج قدرة النماذج المستخدمة على تمثيل حركة المسافرين وتقديم تنبؤات مناسبة، مما أكد أهمية نماذج السلاسل الزمنية في دعم التخطيط وإدارة حركة النقل الجوي.
- أجرى Lopexet al.(2017) دراسة للتنبؤ بحركة المسافرين الجوية في إسبانيا، باستخدام بيانات شهرية، واعتمدت الدراسة على نماذج ARIMAX لتحليل الأنماط الزمنية والموسمية لحركة المسافرين، وأظهرت النتائج أهمية النماذج الموسمية في تحسين التنبؤ كما تناولت الدراسة إمكانية الاستفادة من البيانات المجمعة والمفصلة في بناء التنبؤات.
- أجرى Hopfe et.al(2024) دراسة هدفت إلى مقارنة أداء نماذج السلاسل الزمنية، ومنها SARIMA، ARIMA ، SARIMAY مع نماذج الشبكات العصبية في التنبؤ قصير الأجل بتدفق المسافرين في خمسة مطارات أمريكية، وأظهرت النتائج أن النماذج تختلف باختلاف ظروف حركة المسافرين، مع استخدام نماذج السلاسل الزمنية الموسمية كأدوات مناسبة للتنبؤ بحركة المسافرين.
- في دراسة حديثة أجرى Meliyanaet al(2025) دراسة للتنبؤ بحركة المسافرين المحليين في مطار Sultan Hasanuddin بأندونسيا، باستخدام بيانات شهرية ومنهجية بوكس-جينكيز ونماذج SARIMA وأظهرت النتائج ملائمة النموذج الموسمي المختار للتنبؤ بحركة المسافرين، مع تحقيق مستوى جيد من دقة التنبؤ وتعد هذه الدراسة الأقرب إلى الدراسة الحالية من حيث طبيعة البيانات والمنهج المستخدم لكونها تعتمد على بيانات شهرية لحركة المسافرين في مطار محدد.

2. الجانب النظري:

يتناول هذا البند استعراضاً لبعض المفاهيم العامة، وعرض مراحل بناء نموذج السلاسل الزمنية (ARIMA) وكذلك نماذج السلاسل الزمنية (SARIMA) بالاعتماد على أسلوب (بوكس – جينكنز).

مفاهيم رئيسية (Fundamental Concepts):

1.2 السلسلة الزمنية (Time series):

هي مجموعة من المشاهدات أو القياسات لقيم ظاهرة معينة مأخوذة على فترات زمنية محددة، ويمكن تمثيل السلسلة الإحصائية كما يلي:

$$z_t = f(t) + e_t \quad , \quad t = 0 \, , \pm 1, \pm 2, \ldots$$

F(t) : تمثل الجزء المنتظم الذي يعبر عنهم بدالة رياضية.

e_t : الجزء العشوائي وقد يسمى بالضجيج (التشويش).

2.2 مركبات السلاسل الزمنية (Time series Components):

إن من أهم أهداف السلسلة الزمنية هي وصف الظاهرة موضع الدراسة، والتعرف على التغيرات التي تطرأ على هذه الظاهرة، إن هذه التغيرات تحدث بسبب أربع أنواع من المؤثرات (الاتجاه العام، التغيرات الموسمية، التغيرات الدورية، التغيرات العشوائية).

1.2.2 الاتجاه العام (Secular Trend):

هو الحركة أو المسار طويل الأمد للبيانات بمرور الوقت، ويعكس ما إذا كانت البيانات في تزايد أو تناقص نسبي على فترة زمنية طويلة.

2.2.2 التغيرات الموسمية (Seasonal variable):

هي أنماط متكررة ومنتظمة تحدث في السلاسل الزمنية ضمن فترة زمنية قصيرة لا تتجاوز السنة مثل التغيرات اليومية، الأسبوعية، الشهرية، الفصلية من أمثلة هذا النوع درجات الحرارة.

3.2.2 التغيرات الدورية (Cycled Variation):

هي تغيرات تتكرر بانتظام في فترات زمنية طويلة (سنتين أو أكثر).

4.2.2 التغيرات العشوائية (Irregular Variation):

هي تقلبات مفاجئة وغير متوقعة تحدث في البيانات ولا يمكن تفسيرها بالاتجاه العام أو الموسمية أو الدورية، بل هي عوامل فجائية (كالحروب والفيضانات والزلازل والبراكين ... إلخ).[2]

3.2 الاستقرارية السكون (Stationarity):

يقال أن السلسلة الزمنية ساكنة إذا كانت الخصائص الإحصائية لهذه السلسلة ثابتة عبر الزمن، أي لا تتغير بالإزاحة إلى الأمام أو الخلف بعدد من الوحدات الزمنية، والخصائص الإحصائية يمكن وضعها بشكل كامل أو مؤكد عن طريق دالة الاحتمال التراكمي، ويمكن وضعها بشكل جزئي عن طريق بعض المؤشرات الإحصائية كالتوقع والتبيان والتقدير وعليه يمكن تقسيم السكون إلى:-

1.3.2 السكون التام المؤكد (Strong Stationarity):

يقال أن السلسلة الزمنية مؤكدة السكون إذا كان التوزيع الاحتمالي المشترك لأي مجموعة جزئية من المتغيرات التي تتكون منها السلسلة لا يتأثر بالإزاحة إلى الإمام أو الخلف بعدد من الوحدات الزمنية.

2.3.2 السكون الضعيف (Weak Stationarity):

يقال أن السلسلة ساكنة سكون ضعيف إذا تحقق الشروط الآتية:

أ- التوقع للعملية العشوائية (μ) لا يعتمد على الزمن t أي أن

$$(z_t) = \mu \qquad ; \qquad t = 0 \, , \pm 1, \pm 2, ..$$

ب- التباين لا يعتمد على الزمن

$$V(z_t)=\sigma^2 \quad ; \quad t=0\ ,\pm1,\pm2,..$$

ج- التغاير بين أي متغيرين يعتمد فقط على الفجوة الزمنية بين هذين المتغيرين وليس على القيمة الفعلية الذي حسب عنده التغاير أي أن

$$Cov(z_{t+k}\ ,\ z_t)=\gamma_k \quad ; \quad t=0\ ,\pm1,\pm2,..$$

$$; \quad k=0\ ,\pm1,\pm2,..$$

4.2 دراسة استقرارية السلسلة:

يتم الكشف عن عدم استقرارية السلسلة الزمنية عن طريق الفحص البصري للرسم البياني ودالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي واختبارات جذور الوحدة. [1]

1.4.2 الارتباط الذاتي (Autocorrelation AC):

وهو عبارة عن مؤشر يوضح درجة العلاقة بين قيم المتغير نفسه، عند فترات إزاحة (k) مختلفة ويرمز له بالرمز $(\hat{p}_k)$ وتتراوح قيمته بين [1، -1] ويقدر من العلاقة:

$$\hat{p}_k=\frac{\sum_{t=1}^{n-k}(z_t-\bar{z})(z_{t-k}-\bar{z})}{\sum_{t=1}^{n}(z_t-\bar{z})^2}$$

حيث z_t : مشاهدات السلسلة

$\bar{z}$: الوسط الحسابي للسلسلة

N : عدد المشاهدات

ويطلق على الرسم البياني لمعاملات الارتباط الذاتي $(\hat{p}_k)$ مقابل فترات إزاحة مختلفة بدالة الارتباط الذاتي ويرمز له بالرمز (ACF).

2.4.2 الارتباط الذاتي الجزئي (Partial Auto Correlation PAC):

وهو مؤشر يقيس درجة الارتباط الخطي بين متغيرين يبعدان عن بعضهما البعض وحدتان زمنيتان بعد حذف تأثير المتغير الذي يقع بينهما ويعطى من العلاقة:

$$\hat{\phi}_{k\,k}=\frac{\hat{p}_k-\sum_{j=1}^{k-1}\phi_{k-1\,j}\ \hat{P}_{k-j}}{1-\sum_{j=1}^{k-1}\phi_{k-1\,j}\ \hat{P}_{k-j}}$$

ويطلق على الرسم البياني لمعاملات الارتباط الذاتي الجزئي مقابل فترات إزاحة مختلفة بدالة الارتباط الذاتي الجزئي ويرمز له بالرمز (PACF) وتستخدم دالة الارتباط الذاتي والذاتي الجزئي في تحديد الاستقرارية وكذلك تحديد نوع ورتبة النموذج. [3]

5.2 الاختبارات الإحصائية لاستقرارية السلسلة:

تعد اختبارات الاستقرارية من الخطوات المهمة في تحليل السلاسل الزمنية التي توضح إذا كانت السلسلة مستقرة أو غير مستقرة وهذه الاختبارات هي:

1.5.2 اختبارات معنوية معاملات الارتباط الذاتي:

تتطلب استقرارية السلسلة أن تكون معاملات الارتباط الذاتي $(\hat{p}_k\ ,\ k=0\ ,\pm1,\pm2,..)$ مساوية للصفر، أو أنها لا تختلف جوهرياً عن الصفر بالنسبة لأي فجوة زمنية (k > 0) أي أن معاملات الارتباط الذاتي يجب أن تقع داخل حدود فترة الثقة $\left(\pm\frac{z_{\frac{\alpha}{2}}}{\sqrt{n}}\right)$ باحتمال $(1-\alpha)$. [5]

ولاختبار معنوية معاملات الارتباط الذاتي ككل نستخدم إحصاءة بوكس– بيرس في حالة العينات الكبيرة وتعطى بالصورة:

$$Q=n\sum_{k=1}^{m}\ p_k^2$$

حيث m عدد الفجوات ونقارنها بالقيمة الجدولية $X^2_{m,\alpha}$

أما في العينات الصغيرة نستخدم إحصاءة بوكس لنق والتي تتعطى بالصورة:

$$Q_{lB}=n(n+2)\sum_{k=1}^{m}\frac{p_k^2}{n-k}$$

وتقارن بالقيمة الجدولية $X^2_{m,\alpha}$. [4]

2.5.2 اختبارات جذور الوحدة (Unit Roots tests):

تعد هذه الاختبارات الأكثر دقة وانتشار، حيث تهدف إلى فحص السلسلة الزمنية لكل متغير من متغيرات الدراسة من أشهر اختبارات جذور الوحدة هو اختبار ديكي فولر الموسع.

يعتمد اختبار ديكي فولر على فرضية أن السلسلة الزمنية متولدة بواسطة عملية انحدار ذاتي والذي يقدر بالصورة:

$$\Delta z_t=\phi_0+\phi_{z_t}+e_t$$

حيث أن ϕ : رتبة النموذج، E_t الخطأ العشوائي

Δz_t تشير إلى الفروق الأولى لسلسلة z_t حيث

$$\Delta z_t=z_t-z_{t-1}$$

ويعتمد اختبار ديكي فولر على ثلاث عناصر للتأكد من استقرارية السلسلة من عدمها، وهي صيغ النماذج (a , b , c) وحجم العينة (n) ومستوى المعنوية (α) والصيغ الثلاثة هي:

1- الصيغة الأولى (a):

لا تحتوي هذه الصيغة على الحد الثابت والاتجاه الزمني:

$$\Delta z_t=\phi\ z_{t-1}-e_t$$

2- الصيغة الثانية (b):

تحتوي على الحدث الثابت (c)

$$\Delta z_t=c+\phi\ z_{t-1}-e_t$$

3- الصيغة الثالثة (c):

تحتوي على الحد الثابت والاتجاه الزمني

$$\Delta z_t=c+B_t+\phi\ z_{t-1}-e_t$$

وإذا كان الخطأ (e_t) في الصيغ الثلاثة (a , b , c) يعاني من الارتباط الذاتي فيمكن أن يصحح بأخذ عدد مناسب من الفروق ويسمى عندها اختبار ديكي- فولر الموسع أو المطور. [6]

6.2 طرق معالجة عدم الاستقرارية:

بعد ما تم دراسة والكشف عن عدم استقرارية السلسلة تظهر ملامح عدم الاستقرارية في عدم ثبات المتوسط أو عدم ثبات التباين أو وجود تغيرات موسمية عبر الزمن.

1.6.2 علاج عدم ثبات المتوسط:

يتم ذلك عن طريق أخذ الفروق للسلسلة الزمنية وذلك بطرح قيم المشاهدات من بعضها البعض لفترات زمنية من خلال الفروق المتتالية.

2.6.2 علاج عدم ثبات التباين:

يتم ذلك عن طريق أخذ إحدى التحويلات الرياضية لبيانات السلسلة الزمنية (اللوغارثم الطبيعي للبيانات السلسلة، أخذ المقلوب، أخذ الجذر التربيعي لبيانات السلسلة).

3.6.2 علاج الموسمية:

ويتم ذلك بإزالة الأثر الموسمي جعل السلسلة مستقرة بأخذ الفروق الموسمية كالتالي:

$$\nabla_s Y_t = Y_t = Y_{t-s}$$

حيث: S طول الدورة الموسمية سواء كانت ربع سنوية أو شهرية.

7.2 نماذج بوكس- جينكنز للسلاسل الزمنية:[8]

1.7.2 نماذج الانحدار الذاتي Auto Regressive Model (AR)

يعبر في نماذج الانحدار الذاتي عن قيمة السلسلة الحالية (z_t) بدلالة قيم السلة السابقة $(z_{t-1}, z_{t-2}, \ldots\ldots, z_{t-p})$ وقيمة الخطأ e_t ويمكن التعبير عن هذه النماذج من الرتبة (p) كما يلي:

$$z_t = \phi_0 + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \ldots. + \phi_p z_{t-p} + e_t$$

z_t : مشاهدات السلسلة

ϕ_0 : الحد الثابت

$\phi_1, \phi_2, \ldots., \phi_p$ معالم نموذج الانحدار الذاتي

e_t : الأخطاء العشوائية

ويمكن كتابة هذا النموذج بدلالة الارتداد الخلفي (B) كما يلي:

$$\phi_p(B) z_t = \phi_0 + e_t$$

$\phi_p(B) z_t$ متعددة حدود في (B) لمعالم نموذج الانحدار الذاتي $(\phi_1, \phi_2, \ldots., \phi_p)$

2.7.2 نماذج المتوسطات المتحركة Moving Average Mokles (MA):

يتم التغير في نموذج المتوسطات المتحركة عن قيم السلسلة الحالية z_t بدلالة القيمة الحالية للأخطاء e_t وبدلالة القيم السابقة للأخطاء $(e_{t-1}, e_{t-2}, \ldots. e_{t-p})$ ويمكن التعبير عن هذه النماذج من الرتبة (q) كما يلي:

$$z_t = \theta_0 + e_t - \theta_1 e_{t-1} + \theta_2 e_{t-2} + \ldots. + \theta_q z_{t-q}$$

z_t : مشاهدات السلسلة

θ_0 : الحد الثابت

$\theta_1, \theta_2, \ldots., \theta_q$: معلمات النموذج

$e_{t-1}, e_{t-2}, \ldots., e_{t-q}$ الأخطاء العشوائية

ويمكن كتابة هذا النموذج بدلالة الارتداد الخلفي (B) كما يلي:

$$z_t = \theta_0 + \theta_q(B) e_t$$

حيث $\theta_q(B) e_t$ متعددة حدود في (B) لمعالم نموذج المتوسطات المتحركة $(\theta_1, \theta_2, \ldots., \theta_q)$.

3.7.2 نماذج الانحدار الذاتي والمتوسطات المتحركة :

Auto regressive Moving Average Models (ARMA)

أحياناً لا يمكن التعبير عن السلسلة الزمنية بصيغة الانحدار الذاتي AR(P) فقط أو صيغة المتوسطات المتحركة MA(q) فقط، ولكن هو نموذج مركب يحتوي على خصائص نموذج الانحدار الذاتي والمتوسطات المتحركة، وبذلك يمكن التعبير في هذا النموذج عن القيم الحالية للسلسلة z_t بدلالة القيم السابقة $(z_{t-1}, z_{t-2}, \ldots\ldots, z_{t-p})$ وكذلك اقيم الحالية للأخطاء e_t بدلالة القيم السابقة للأخطاء $(e_{t-1}, e_{t-2}, \ldots\ldots, e_{t-q})$ ويرمز له بالرمز ARMA(p , q) ويمكن التعبير عنه على الصورة:

$$z_t = \phi_0 + \phi_1 z_{t-1} + \ldots\ldots\ldots + \phi_p z_{t-p} + e_t - \theta\ e_{t-1} - \ldots - \theta_q e_{t-q}$$

ويمكن كتابة النموذج بدلالة الارتداد الخلفي (B) كما يلي:

$$\phi_p(B)_{z_t} = \phi_0 + \theta_q(B) e_t$$

حيث $\phi_p(B)_{z_t}$: متعددة حدود في (B) لمعالم نموذج الانحدار الذاتي $\phi_1, \phi_2, \ldots., \phi_p$ و $\theta_q(B) e_t$: متعددة حدود في (B) لمعالم نموذج الانحدار الذاتي $\theta_1, \theta_2, \ldots., \theta_q$

4.7.2 نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية:

Auto regressive Integrated Moving Average Models (ARIMA)

يوجد بعض نماذج السلاسل الزمنية تكون غير مستقرة، ولكي تكون مستقرة يجب إجراء بعض التحويلات أو الفروق عليها، إن مثل هذه النماذج تختلف عن النماذج الأصلية وذلك لاحتوائها على هذه التحويلات أو الفروق، إن هذه النماذج المستقرة تدعي بالنماذج المختلطة التكاملية ويرمز لها بالرمز ARIMA(p , d , q)

p : رتبة نموذج الانحدار الذاتي

q : رتبة نموذج المتوسطات المتحركة

d : عدد الفروق اللازمة لكي تكون السلسلة مستقرة. [6]

8.2 نماذج السلاسل الزمنية الموسمية Seasonal time series Models :

السلاسل الموسمية هي سلاسل تكرر نفسها عند فترات زمنية ثابتة (Fixed inervals) وتدعى هذه الفترة بالفترة الموسمية ونرمز له بالرمز (s) وهي [يوم – شهر – سنة] ويتم الكشف عن الموسمية بواسطة دالتي الارتباط الذاتي والذاتي الجزئي.

1.8.2 نماذج الانحدار الذاتي الموسمية $SAR(P)_s$:

يقال أن النموذج نموذج انحدار ذاتي موسمي من الرتبة (p) والذي يرمز له بالرمز SAR(P) إذا كانت قيم السلسلة الحالية (z_t) عبارة عن دالة في قيم السلسلة في نفس الموسم من السنوات السابقة، (z_{t-p_s}) أي أن القيمة الحالية تعتمد على القيمة من نفس الموسم السابق، ويمكن التعبير عن النموذج كما يلي:

$$z_t = \phi_1 z_{t-s} + \phi_2 z_{t-2s} + \ldots\ldots + \phi_p z_{t-p} + e_t$$

حيث: s طول الفترة الموسمية

z_{t-is} : قيم مشاهدات السلسلة الموسمية $i = 1, 2, \ldots., p$

ϕ_i : معالم نموذج الانحدار الذاتي الموسمي $i = 1, 2, \ldots., p$

p : درج نموذج الانحدار الذاتي الموسمي

e_t : الأخطاء العشوائية

ويمكن كتابة النموذج بدلالة الارتداد الخلفي (B) كما يلي:

$$\phi_p(B^s) z_t = \phi_0 + e_t$$

2.8.2 نماذج المتوسطات المتحركة الموسمية $MA(Q)_s$:

يقال للنموذج أن نموذج متوسطات متحركة موسمي من الرتبة (Q) إذا أمكن التعبير عن قيم السلسلة الحالية كدالة في قيم الخطأ العشوائي (e_t) وبدلالة الأخطاء العشوائية في نفس الموسم من السنوات السابقة من القيمة الحالية تعتمد على أخطاء المواسم السابقة ويمكن التعبير عن النموذج كما يلي:

$$z_t = e_t - \theta_1 e_{t-s} - \theta_2 e_{t-2s} - \ldots - \theta_q e_{t-qs}$$

θ_{is} : تمثل معالم نموذج المتوسطات المتحركة الموسمي $i = 1, 2, \ldots., Q$

Q : تمثل درجة النموذج الموسمي

s : طول الفترة الموسمية

e_{t-is} : الخطأ العشوائي $i = 1, 2, \ldots., Q$

ويمكن كتابة النموذج بدلالة الارتداد الخلفي (B) كما يلي:

$$z_t = \theta_q(B^s) e_t$$ [8]

3.8.2 النماذج المختلطة الموسمية SARMA (p,q)s

نماذج الانحدار الذاتي والمتوسطات المتحركة الموسمية عند دمج الانحدار الذاتي الموسمي مع نموذج المتوسطات المتحركة الموسمي نحصل على نموذج انحدار ذاتي ومتوسطات متحركة موسمية ويرمز له بالرمز SARMA (p,q)s ويمكن التعبير عنه:

$$z_t = e_t + \phi_1 z_{t-1s} + \phi_2 z_{t-2s} + \dots + \phi z_{t-ps} - \theta_1 e_{t-s} - \theta_2 e_{t-2s} - \dots - \theta_q e_{t-qs}$$

ويمكن التعبير عنه بدلالة الارتداد للخلف (B) كما يلي:

$$\phi_p(B^s) z_t = \phi_q + (B^s)\, e_t$$

حيث z_t : السلسلة الزمنية الحالية

$\phi_p(B^s) z_t$ متعددة حدود في (B) لمعالم نموذج الانحدار الذاتي الموسمي

$\phi_q(B^s)\, e_t$ متعدد حدود (B) في معالم نموذج المتوسطات المتحركة الموسمي

4.8.2 نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية SARIMA (p , d , q) (P , D , Q)s

عندما تكون السلسلة الزمنية الموسمية غير مستقرة يتم إيجاد الفروق الموسمية (D) لتحقيق استقرار السلسلة نحصل على نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ويرمز لها بالرمز SARIMA (p , d , q) (P , D , Q)s ويمكن التعبير عن النموذج بواسطة الارتداد الخلفي (B) كما يلي:

$$\phi_p(B)\,\phi_p(\mathbf{B}^s)\, z_t (1-B)^d\; z_t (1-B)^D = \theta_q(B)\,\theta_Q(B^s)\, e_t$$

$\phi_p(B)\phi_p$: معامل الانحدار الذاتي الغير موسمي

$\phi_p(B^s)$: معامل الانحدار الذاتي موسمي

$\theta_q(B)$: معامل المتوسطات المتحركة الغير الموسمي

$\theta_Q(B^s)$: معامل المتوسطات المتحركة الموسمي [7]

9.2 مراحل بناء النماذج باستخدام أسلوب بوكس – جينكيز:

يتم بناء نموذج السلسلة الزمنية وفقاً لمنهجية بوكس- جينكيز عبر أربعة مراحل وهي:

1.9.2 مراحل التعرف (Identification)

يقصد بمرحلة التعرف هي تحديد معالم النموذج (p , d , q) في النماذج الغير الموسمية و (P , D , Q) في النماذج الموسمية ويجب أن يسبق هذه المرحلة مرحلة تهيئة البيانات فإذا كانت البيانات مستقرة تنتقل إلى مرحلة التعرف، وإذا كانت غير مستقرة يتم معالجتها ومن ثم الدخول في مرحلة التعرف.

إن الأداتين المستخدمتين في تحديد نوع ورتبة النموذج هي دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF)، وذلك بالرسم البياني لكل من (ACF) و (PACF)، ومن ثم مطابقة معاملات الارتباط الذاتي والذاتي الجزئي مع السلوك النظري لدالة الارتباط الذاتي (ACF) والذاتي الجزئي (PACF). [2]

10.2 مرحلة التقدير (Estimation)

وهي المرحلة الثانية من مراحل تحليل السلاسل الزمنية، ولكي يحقق النموذج الهدف الأساسي من بنائه وهو التنبؤ فيجب علينا أن نضمن جودة تقدير معالمه، وهناك عدة طرق لتقدير معالم النموذج من أهمها:

1. طريقة المربعات الصغرة الاعتيادية
   Method of ordinary – Least Square
2. طريقة الإمكان الأعظم Maximum likelihood Method

وتنطبق طرق التقدير المذكورة عن كافة نماذج (Box-Jensks) بما في ذلك النماذج الموسمية [1].

11.2 مرحلة التشخيص (Diagnostic):

ويتم في هذه المرحلة فحص النموذج وذلك للتأكد من أن مرحلة التقدير ومخرجاتها تتوافق مع الفروض النظرية الخاصة بالعملية العشوائية التي ولدت البيانات، أو على الأقل لا تظهر خللاً في هذه الفروض وفيما يلي بعض الاختبارات والفحوص التي تجرى على النموذج لاختبار مدى ملاءمته وصلاحيته لتمثيل البيانات وهي:

أ- اختبار معنوية معالم النموذج: وذلك باستخدام اختبار (t-stadent)، فإذا كانت غير معنوية لابد من استبعاد إحدى رتب (MA) أو (AR) أو (SMA) أو (SAR).[5]

ب- تحليل البواقي:

1- رسم البواقي: يجب أن تكون البواقي خالية من كل الأنماط والتحركات المنتظمة، وأن تتأرجح بنشتت ثابت حول الصفر، وأن يبدو شكلها عشوائياً.

2- تحليل الارتباط الذاتي للبواقي (e_t): ويتم ذلك بطريقتين:

الطريقة الأولى: وتعتمد هذه الطريقة على اختبار (Box-Jung) وذلك لاختبار الفرضية الآتية:

$$H_0 : p_1 = p_2 = p_3 = \dots\dots = p_k = 0$$

$$H_1 : p_1 = p_2 = p_3 = \dots\dots = p_k \neq 0$$

معتمدين على الارتباطات الذاتية للبواقي وإحصاءة الاختبار.

$Q = n(n+2)\sum_{k=1}^{m} \frac{\hat{p}_k^2}{n-k}$ وتقارن هذه الإحصاءة بالقيمة الجدولية $X_m^2 - f\ ,\ \alpha$ حيث f عدد المعالم المقدرة، m أكبر إزاحة لـ (k) و n عدد المشاهدات.

الطريقة الثانية: وتعتمد هذه الطريقة على حدود فترة الثقة لمعاملات الارتباطات الذاتية للبواقي المقدرة $(\hat{e}_t)$ والتي يجب أن تقع بين الحدين $\left(\pm \frac{z_{\frac{\alpha}{2}}}{\sqrt{n}}\right)$ فإذا تحقق هذا فهذا يدل على البواقي العشوائية وأن النموذج ملاءم وجيد للبيانات ويمكن استخدامه في التنبؤ.

وهناك عدة معايير أخرى للمفاضلة بين مجموعة من النماذج التي قد تجتاز مرحة التشخيص لأن مرحلة التنبؤ تحتاج إلى النموذج الأنسب من بينها لغرض استعماله في التنبؤ ومن أهم هذه المعايير:

- (AIC) معيار أكيك
- (BIC) معيار ينريان
- RMSE الجذر التربيعي لمتوسط مربعات الخطأ
- MAE متوسط الخطأ المطلق.

حيث يستخدم المعيارين الأولين للموازنة بين جودة ملاءمة النموذج للبيانات وعدد المعالم الموجودة فيه وتستخدم المعيارين الآخرين في قياس دقة التنبؤ.

12.2 مرحلة التنبؤ (Forcasting):

وهي المرحلة الأخيرة من مراحل تحليل السلاسل الزمنية، وهي عادة ما تكون الهدف الأساس من الدراسة ولا يتم الانتقال إليه إلا بعد أن يتجاوز النموذج المبدئي كافة الفحوص والاختبارات وإلا فيجب العودة إلى مرحلة التعرف ونكرر هذه العملية حتى الحصول على نموذج ذو كفاءة عالية. [3]

3. الجانب التطبيقي:

1.3 جمع البيانات:

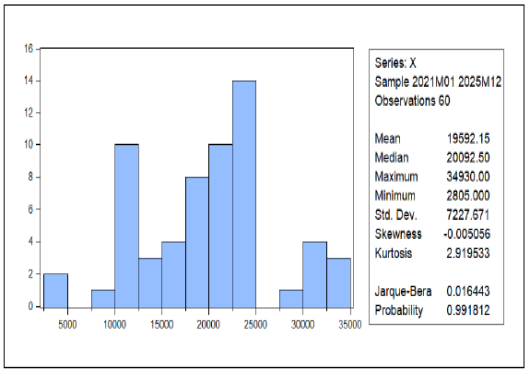
تم جمع البيانات الشهرية والتي تتألف من (60) مشاهدة خلال الفترة الممتدة من (2021/1/1) وحتى (2025/12/31) وتمثل هذه البيانات أعداد الركاب في مطار مصراتة الدولي، ويمكن تخليص بعض المقاييس الوصفية الخاصة بأعداد الركاب في مطار مصراته الدولي كما هو موضح بالجدول (1).

جدول 1. وصف أعداد ركاب مطار مصراته الدولي خلال الفترة (2025-2021)

عدد المشاهدات	أقل قيمة	أكبر قيمة	المتوسط	الوسيط	الانحراف المعياري	الالتواء	التفرطح
60	2805	34930	19592.18	20092.50	7227.71	-0.005	2.91

نلاحظ من الجدول أن قيمة المتوسط والوسيط متقاربتان ويدل هذا على أن توزيع البيانات متوازن نسبياً، أما بالنسبة لمعامل الالتواء قيمته قريبة من الصفر، مما يدل على أن التوزيع متماثل وكذلك قيمة معامل التفرطح قريبة من القيمة النظرية للتوزيع الطبيعي مما يدل على أن توزيع البيانات قريبة من التوزيع الطبيعي ولزيادة التأكيد تم احتساب إحصاءة جوكبير (Javgue-Bara) كما موضح بالشكل(1)

الشكل 1. اختبار التوزيع الطبيعي لبيانات ركاب مطار مصراته الدولي (2021-2025)

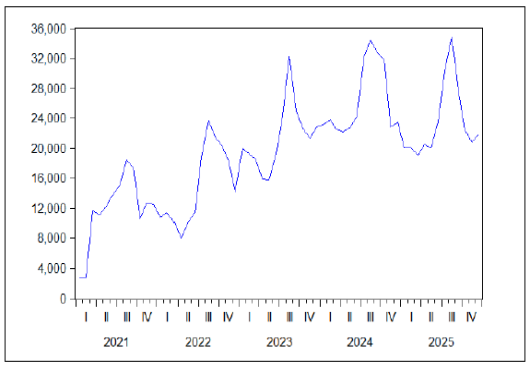


نلاحظ من الشكل أن إحصاءة جوكوبيرا وهي أكبر من (0.05) وعليه فإن بيانات السلسلة الزمنية تتبع تقريباً التوزيع الطبيعي، الأمر الذي يعزز استخدام نماذج (ARIMA) , (SARIMA) .

2.3 التحليل البياني للسلسلة الزمنية:

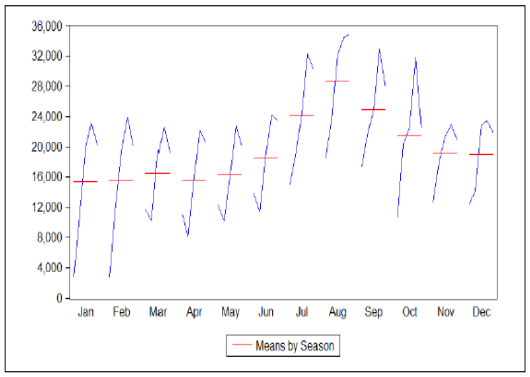
قبل البدء في تطبيق منهجية (بوكس – جينكز) لابد من تهيئة البيانات من خلال تسكينها وتطبيق التحويلات المناسبة لجعلها مستقرة ولمعرفة ذلك تم رسم السلسلة الزمنية كما هو موضح بالشكل (2).

شكل 2. السلسلة الزمنية الأصلية لعدد الركاب بمطار مصراته الدولي (2021-2025)



نلاحظ من الشكل (2) وجود اتجاه تصاعدي واضح مما يدل على أن المتوسط غير ثابت عبر الزمن، كما نلاحظ وجود تذبذبات تتكرر بانتظام وبنفس الوتيرة كل سنة، مما يدل على وجود الموسمية في السلسلة ولزيادة التأكد تم رسم المخطط الموسمي كما هو موضح بالشكل (3).

شكل 3. المخطط الموسمي الذي يوضح النمط الموسمي الشهري لعدد ركاب مطار مصراته الدولي خلال الفترة الزمنية (2021-2025)

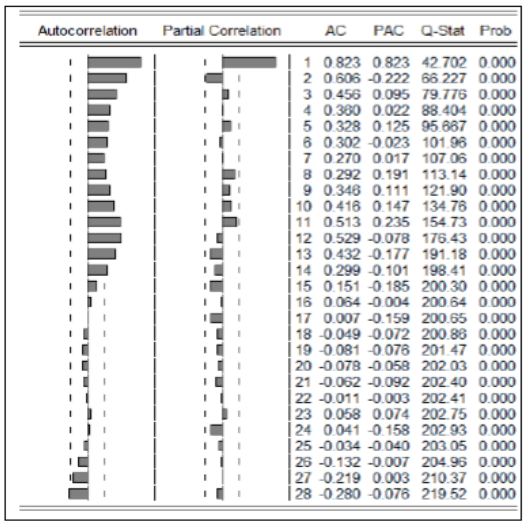


من الشكل (3) نلاحظ وجود نمط موسمي واضح ويتكرر سنوياً، حيث تشهد القيم ارتفاعاً ملحوظ أشهر الصيف مما يدل أن السلسلة تحتوي على مكون موسمي قوي ومنتظم.

3.3 اختبارات الاستقرارية:

لدراسة الاستقرارية لسلسلة الركاب بمطار مصراته الدولي تقوم برسم دالتي الارتباط الذاتي والذاتي الجزئي كما موضح بالشكل (4)

شكل 4. دالتي الارتباط الذاتي والذاتي الجزئي لسلسلة عدد الركاب الأصلية خلال الفترة (2021-2025)



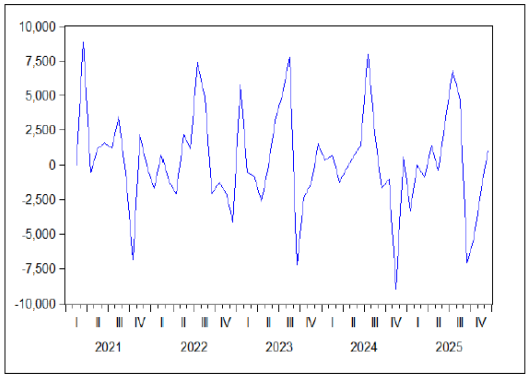
من الشكل (4) نلاحظ أن الإحصاءة (Q = 219.52) أكبر من القيمة الجدولية لـ (X^2 0.05 , 28 = 41.337) وهذا يؤكد عدم استقرارية السلسلة ولزيادة التأكيد قمنا باختبار ديكي فلو الموسع (ADF) كما موضح بالجدول (2)

جدول 2. نتائج اختبار ديكي فلور لسلسلة عدد ركاب مطار خلال (2021-2025)

نوع الاختبار	القيمة المحسوبة	القيمة الجدولية عند مستوى معوية 0.05
اختبار ADF	1.265467	1.946447

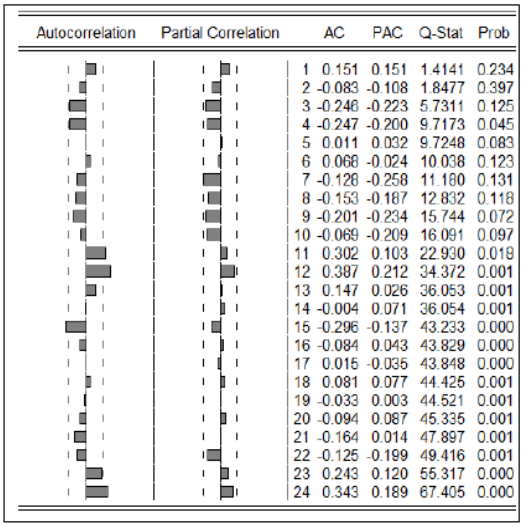
نلاحظ من الجدول (2) أن القيمة المحسوبة المطلقة أصغر من القيمة الجدولية المطلقة عند مستوى 0.05 وبالتالي نقر بوجود جذر الوحدة وبالتالي السلسلة غير مستقرة. ولمعالجة ذلك تم أخذ الفرق الأول للسلة كما موضح بالشكل (5)

شكل 5. المنحنى البياني لسلسلة الفروق من الدرجة الأولى لأعداد الركاب في مطار مصراته الدولي خلال (2021-2025)



من الشكل نلاحظ أن السلة فقدت الاتجاه العام مما يدل على استقرار السلسلة في المتوسط وانها تتأرجح بمقدار ثابت حول الصفر، مما يدل على ثبات السلسلة تقريباً وبالتالي استقرارية السلسلة في التباين ولزيادة التأكيد تم رسم دالتي الارتباط الذاتي والذاتي الجزئي لسلسلة الفروق كما موضح بالشكل (6)

شكل 6. دالتي الارتباط الذاتي والذاتي الجزئي لسلسلة الفروق من الدرجة الأولى لعدد الركاب في مطار مصراته الدولي (2021-2025)

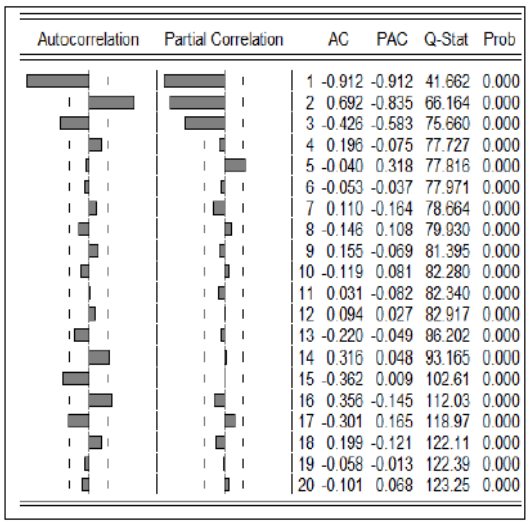


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	0.151	0.151	1.4141	0.234
		2	-0.083	-0.108	1.8477	0.397
		3	-0.246	-0.223	5.7311	0.125
		4	-0.247	-0.200	9.7173	0.045
		5	0.011	0.032	9.7248	0.083
		6	0.068	-0.024	10.038	0.123
		7	-0.128	-0.258	11.180	0.131
		8	-0.153	-0.187	12.832	0.118
		9	-0.201	-0.234	15.744	0.072
		10	-0.069	-0.209	16.091	0.097
		11	0.302	0.103	22.930	0.018
		12	0.387	0.212	34.372	0.001
		13	0.147	0.026	36.053	0.001
		14	-0.004	0.071	36.054	0.001
		15	-0.296	-0.137	43.233	0.000
		16	-0.084	0.043	43.829	0.000
		17	0.015	-0.035	43.848	0.000
		18	0.081	0.077	44.425	0.001
		19	-0.033	0.003	44.521	0.001
		20	-0.094	0.087	45.335	0.001
		21	-0.164	0.014	47.897	0.001
		22	-0.125	-0.199	49.416	0.001
		23	0.243	0.120	55.317	0.000
		24	0.343	0.189	67.405	0.000

(

نلاحظ من الشكل (6) أن الإحصاءة (Q = 67.405) أكبر من القيمة الجدولية (X^2 0.05 , 24 = 36.415) وهذا يؤكد على عدم استقرارية السلسلة حيث أن السلسلة أظهرت وجود مكون موسمي واضح عند التأخير (12، 24) وهو يدعم عدم استقرار السلسلة ولمعالجة عدم الاستقرارية هذا يتطلب أخذ الفرق الموسمي كما هو موضح بالشكل (7)

شكل 7. دالتي الارتباط الذاتي والذاتي الجزئي لسلسلة الفروق من الدرجة الأولى بعد أخذ الفرق الموسمي خلال الفترة (2021-2025)



Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.912	-0.912	41.662	0.000
		2	0.692	-0.835	66.164	0.000
		3	-0.426	-0.583	75.660	0.000
		4	0.196	-0.075	77.727	0.000
		5	-0.040	0.318	77.816	0.000
		6	-0.053	-0.037	77.971	0.000
		7	0.110	-0.164	78.664	0.000
		8	-0.146	0.108	79.930	0.000
		9	0.155	-0.069	81.395	0.000
		10	-0.119	0.081	82.280	0.000
		11	0.031	-0.082	82.340	0.000
		12	0.094	0.027	82.917	0.000
		13	-0.220	-0.049	86.202	0.000
		14	0.316	0.048	93.165	0.000
		15	-0.362	0.009	102.61	0.000
		16	0.356	-0.145	112.03	0.000
		17	-0.301	0.165	118.97	0.000
		18	0.199	-0.121	122.11	0.000
		19	-0.058	-0.013	122.39	0.000
		20	-0.101	0.068	123.25	0.000

من خلال الشكل (7) يبدو أن السلسلة غير مستقرة (أو مستقرة بشكل تقريبي) وهو ما يمكن تفسيره بظاهرة الإفراط في أخذ الفروق حيث أن إدخال فروق إضافية قد يؤدي إلى تضخيم التباين وقد يرجع ذلك بسبب صغر عدد البيانات مقارنة بعدد الفروق، ولكن أخذ الفروق الموسمية جاء بسبب الحاجة إلى إزالة القيمة الموسمية المتبقية والتي أثبتت الأدلة الإحصائية المتمثلة في دالتي الارتباط الذاتي والذاتي الجزئي وجودهما مما يضمن بناء نموذج أكثر تمثيلاً للبيانات ودقة في التنبؤ.

والجدير بالذكر أن تحقيق الاستقرارية النظرية ليس شرط كافياً لاختبار النموذج الأمثل، بل يجب الموازنة بين الخصائص الإحصائية للسلسلة وكفاءة النموذج التنبؤية.

4.3 مرحلة التعرف (Indentification):

تهدف هذه المرحلة إلى تحديد الصيغة المناسبة للنماذج التي يمكن أن تمثل السلسلة الزمنية محل الدراسة، وبعد دراسة الاستقرارية من خلال الفرق العادي والموسمي اعتمدت هذه المرحلة على تحليل كل من دالتي الارتباط الذاتي والذاتي الجزئي بالإضافة إلى الفحص البياني للسلسلة ومن خلال ذلك تم اقتراح ثلاثة نماذج من فئة (ARIMA) وقد تم المفاضلة بينها كما هو موضح بالجدول رقم (3)

جدول 3. تطبيق مجموعة من المعايير على النماذج المقترحة من فئة (ARIMA)

المعيار / النموذج	R-sgurared	AIC	BIC	MAPE	RMSE
ARIMA(1 , 1 , 0)	0.023	19.347	19.445	122.013	3815.403
ARIMA(0 , 1 , 1)	0.031	19.431	19.451	121.422	3711.252
ARIMA(1 , 1 , 1)	0.115	19.330	19.430	120.280	3708.261

من الجدول رقم (3) نلاحظ أن النموذج ARIMA(1 , 1 , 1) هو النموذج الأفضل حيث له أقل قيمة وفق كل معيار وكذلك أكبر قيمة وفق (R-suguored) ونظراً لوجود الموسمية والواضحة في السلسلة وبالاعتماد على دالتي الارتباط الذاتي والذاتي الجزئي وبعد أخذ الفرق العادي وقبل وبعد أخذ الفرق الموسمي فقد تم اقتراح نموذجين من النماذج الموسمية وهي ARIMA(1 , 1 , 1) (0 , 0 , 1) هو ونموذج يحتوي على مركبه موسمية وبدون فرق موسمي وكذلك النموذج

ARIMA(1 , 1 , 1) (0 , 1 , 0) وهو نموذج يحتوي على الفرق الموسمي وبدون مركبات موسمية.

وقد تم تحديد (p , q , P , Q) بناء على أنماط القطع والتناقص في دوال الارتباط الذاتي والذاتي الجزئي مع مراعاة بساطة النموذج.

5.3 مرحلة التقدير (Estimation):

يتم في هذه المرحلة تقدير معالم النماذج المقترحة كما هو موضح بالجدول (4).

جدول رقم 4. تقدير معالم النماذج المقترحة

النماذج	النوع	المعالم	الانحراف المعياري	T-value	p-value
ARIMA(1 , 1 , 1)	AR	0.751352	0.1751	4.407199	0.000
	MA	0.81435	0.19332	4.2122	0.000
	Constant	310.5737	177.8778	1.745995	0.004
ARIMA(1 , 1 , 1) (0 , 0 , 1)	AR	0.597639	0.194452	3.073456	0.0033
	MA	0.71342	0.31443	2.26893	0.018
	ma	0.64321	0.25444	2.52794	0.008
	Constant	307.1234	142.1610	2.160394	0.0352
ARIMA(1 , 1 , 1) (0 , 1 , 0)	AR	-0.8995 0.891475	0.08112	- 10.99073	0.000
	MA	-0.77223	0.0522	-14.7936	0.0081
	Constant	420.144	256-111	1.64046	0.0300

6.3 مرحلة التشخيص (Diagnostic):

لكي تكون النماذج المقترحة جيدة ملائمة للبيانات ويمكن الاعتماد عليها في التنبؤ لابد من إجراء بعض الاختبارات والفحوصات وهي كما يلي:

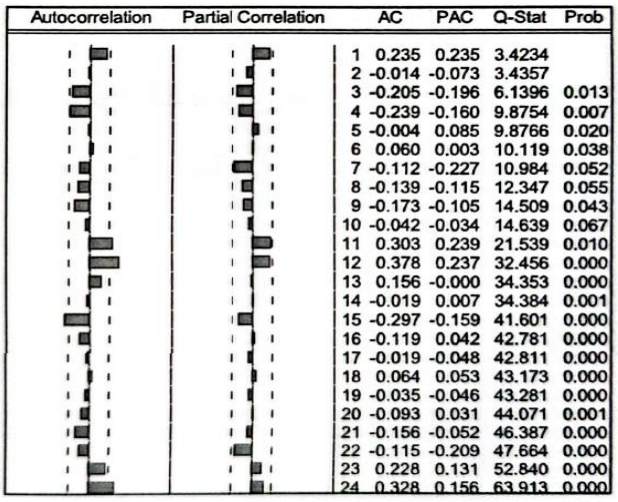
أ- اختبار معنوية المعالم:

من خلال الجدول (4) نلاحظ معنوية معالم النماذج المقترحة أي أنها تختلف جوهرياً عن الصفر بالتالي فهي جيدة ويمكن الاعتماد عليها.

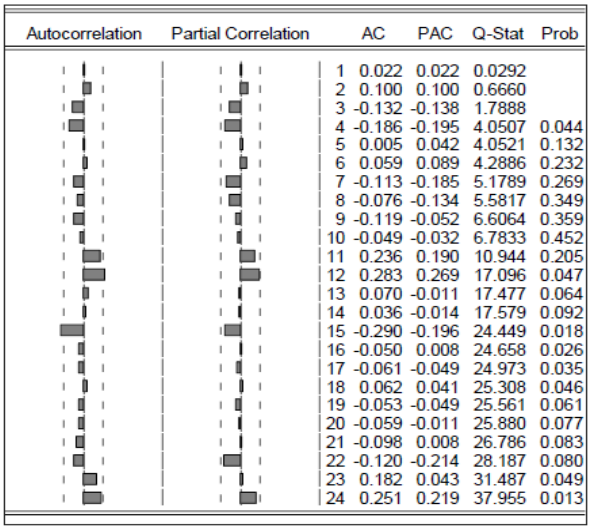
ب-تحليل الارتباط الذاتي للبواقي:

لاختبار عشوائية سلسلة البواقي تم استخراج معاملات الارتباط الذاتي والذاتي الجزئي للبواقي المقدرة ، كما موضح بالأشكال (8، 9، 10).

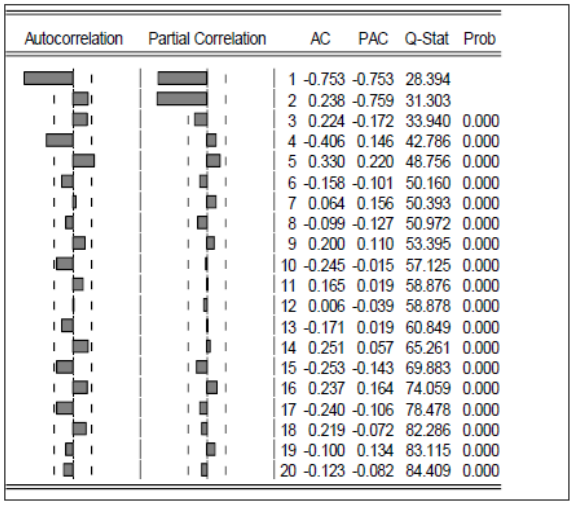
شكل 8. دالة الارتباط الذاتي والذاتي الجزئي لبواقي النموذج ARIMA (1,1,1)



شكل 9. دالة الارتباط الذاتي والذاتي الجزئي لبواقي النموذج SARIMA(1,1,1)(0,0,1)



شكل 10. دالة الارتباط الذاتي والذاتي الجزئي لبواقي النموذج SARIMA(1,1,1)(0,1,0)



نلاحظ من الأشكال (8، 9، 10) أن سلسلة البواقي مستقرة حيث أن معاملات الارتباط الذاتي والذاتي الجزئي للبواقي تقع داخل الفترة $\left(\pm\frac{1.96}{\sqrt{n}}\right)$ ماعدا الإزاحات الأولى والثانية في النموذج الثالث والتي تعتبر مستقلة أيضاً وهي ناتج عن الإفراط في التحويلات وهذا يدل على أن البواقي تمثل تشويش أبيض وأن النماذج جيدة ويمكن الاعتماد عليها. [6]

7-2 المقارنة بين نماذج ARIMA و SARIMA:

بعد الانتهاء من تطبيق منهجية (بوكس- جينكيز) تم الحصول على ثلاثة نماذج مقبولة إحصائياً لكل من نماذج (ARIMA) ونماذج (SARIMA) مع وبدون الفرق الموسمي وبهدف تحديد النموذج الأكثر كفاءة في تمثيل السلسلة تم إجراء مقارنة بين هذه النماذج بالاعتماد على مجموعة من معايير المفاضلة الإحصائية والاختبارات التشخيصية كما موضح بالجدول رقم (5).

جدول رقم 5. نتائج تطبيق مجموعة من المعايير على النماذج الثلاثة لتحديد الأفضل منها

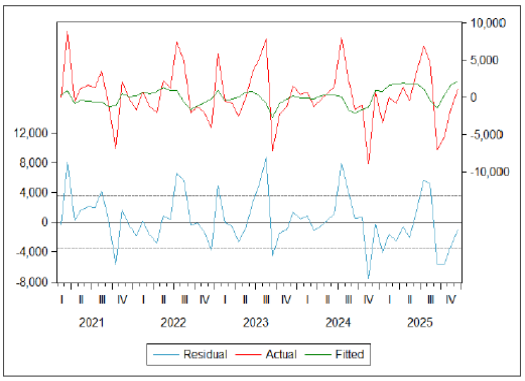
النماذج / المعايير	ARIMA (1 , 1 , 1)	ARIMA (1 , 1 , 1) (0 , 0 , 1)	ARIMA (1 , 1 , 1) (0 , 1 , 0)
معنوية المعالم	معنوية	معنوية	معنوية
معالم التحديد	0.118367	0.195359	0.953498

			R^2
30.96854	19.25589	19.330	AIC
511.2828	3700.668	3708.261	RMSE
415.0434	2763.863	2765.837	MAC

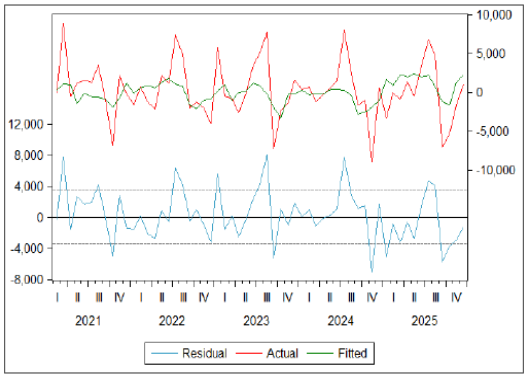
بالنظر إلى الجدول (5) يتضح أن أداء النماذج يختلف باختلاف نوع المعيار المستخدم في التقييم، فقد ظهر نموذج (SARIMA) بدون فرق موسمي تفوقاً نسبياً في بعض المقاييس العددية مثل معايير المعلومات، يليه نموذج (ARIMA) بينما جاء نموذج (SARIMA) مع الفرق الموسمي في مرتبة أقل من حيث هذه المعايير ويعزى ذلك إلى أن المقاييس العددية تميل غالباً إلى تفضيل النماذج الأبسط والأقل في عدد التحويلات مما يجعل النماذج التي تتضمن فرقاً موسمياً أكثر كفاءة من الناحية الاحصائية الشكلية، ومن ناحية أخرى أظهرت نتائج مقاييس التنبؤ والمقارنة بين القيم الحقيقية والقيم المتنبئ بها تفوقاً واضحاً لنموذج (SARIMA) مع الفرق الموسمي حيث حقق أعلى درجة من التقارب بين القيم الحقيقية والمتنبئ بها يليه نموذج (SARIMA) بدون فرق موسمي ثم نموذج (ARIMA) التقليدي ويعزى هذه التفوق إلى قدرة الفرق الموسمي على التقاط النمط الدوري المتكرر في السلسلة وتمثيل التغيرات الموسمية التي لا يمكن للنماذج التقليدية غير الموسمية أو النماذج الموسمية بدون فرق موسمي تفسيرها بشكل كامل.

وبناء على ذلك فإن نموذج SARIMA(1,1,1)(0,1,0) هو النموذج الأكثر كفاءة والأكثر قدرة على تمثيل السلوك الموسمي للسلسلة الزمنية وتحقيق أفضل أداء تنبؤي يليه نموذج SARIMA(1,1,1)(0,0,1) بدون فرق موسمي، ثم نموذج (ARIMA) التقليدي ولزيادة التأكيد عن أن النموذج الفرق الموسمي SARIMA(1,1,1)(0,1,0) هو النموذج الأكفأ والأمثل تم المقارنة من النماذج الثلاثة بالتنبؤ داخل العينة كما هو موضح بالأشكال الآتية (11)، (12)، (13).

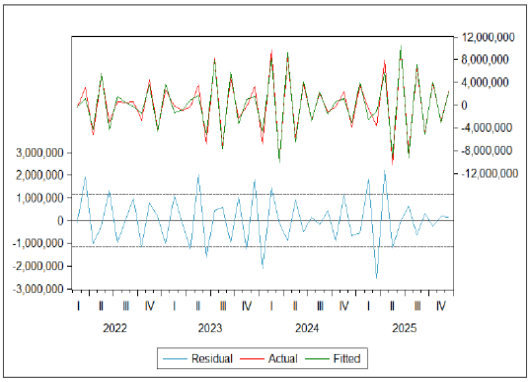
شكل (11) التنبؤ داخل العينة للنموذج ARIMA(1,1,1)



شكل (12) التنبؤ داخل العينة للنموذج SARIMA(1,1,1)(0,0,1)



(شكل (13) التنبؤ داخل العينة للنموذج(SARIMA(1,1,1)(0,1,0



من الأشكال أعلاه نلاحظ أن النموذج SARIMA(1,1,1)(0,1,0) مع الفرق الموسمي أن القيم التقديرية قريبة جداً من البيانات الحقيقة مقارنة بالنماذج الأخرى، وهذا دليل على أن النموذج أخذ في الاعتبار التقلبات الموسمية في السلسلة التي حدثت في الماضي على عكس النماذج الأخرى حيث كانت القيم التقديرية بعيدة على البيانات الحقيقية وبالتالي لم تأخذ في عين الاعتبار التقلبات الموسمية في الماضي.

4. النتائج والتوصيات:

1.4 النتائج:

1. أظهرت الدراسة أن السلسلة الزمنية الأصلية لعدد الركاب لم تكن مستقرة، حيث احتوت على اتجاه عام ومكون موسمي واضح، وتم أخذ الفرق الأول (d=1) لإزالة الاتجاه العام، بالإضافة إلى الفر ق الموسمي (D=1) في نماذج SARTMA لإزالة التأثيرات الموسمية.
2. أظهرت نتائج التقدير أن نماذج SARIMA تفوقت بشكل واضح على نموذج ARIMA التقليدي من حيث جودة الملائمة حيث سجل نموذج SARIM (1,1,1) (0,1,0) أعلى قيمة لمعامل التحديد مما يدل على قدرته العالية في تفسير التباين في البيانات مقارنة ببقية النماذج.
3. أثبت نتائج مقاييس دقة التنبؤ (RMSE,MAE) أن النموذج SARIMA(1,1,1) (0,1,0) هو النموذج الأكثر دقة، حيث سجل أقل قيمة مقارنة ببقية النماذج في المقابل أظهرت نموذج SARIMA(1,1,1) قيم أعلى نسبيا يشير إلى ضعف أدائه في التعامل مع البيانات ذات الطابع الموسمي.
4. بناء على جميع المؤشرات السابقة، يمكن القول إن النماذج الموسمية (SARIMA) هي الأكثر ملائمة لتمثيل بيانات ركاب الطائرات وأن النموذج SARIMA(1,1,1)(0,1,0) هو النموذج الأفضل والأكفأ مقارنة بالنماذج الأخرى.

2.4 التوصيات

-1 ضرورة استخدام نماذج (SARIMA) عند تحليل البليانات التي تحتوي على أنماط موسمية واضحة نظراً لقدرته الفائقة على تمثيل هذه الأنماط مقارنة بالنماذج التقليدية.

-2 نوصي باعتماد نموذج SARIMA(1,1,1)(0,1,0) كنموذج أساسي للتنبؤ بعدد ركاب في مطار مصراتة الدولي لما يتمتع به من دقة عالية وكفاءة احصائية.

-3 تحديث النموذج بشكل دوري عند ادخال بيانات جديدة، خاصة في ظل التغيرات المستمرة في بيانات النقل الجوي.

-4 استخدام نماذج أكثر تقدما في الدراسات المستقبلية مثل النماذج الهجينة، ونماذج التعليم الآلي وذلك لزيادة تحسين دقة التنبؤ.

5. المراجع:

عدنان ماجد عبدالرحمن برى، طرق التنبؤ الإحصائي، مطابع الملك سعود ، المملكة العربية السعودية، الطبعة الأولى، (2002).

سمير مصطفى شعراوي، مقدمة في التحليل الحديث للسلاسل الزمنية، مركز النشر العلمي، المملكة العربية السعودية، الطبعة الأولى، (2005).

علي أحمد حسن الساعدس، استخدام نماذج السلاسل الرتبية الهجينة وغير الهجينة للتنبؤ بأعدد المسافرين لمطار بغداد الدولي، رسالة ماجستير في الاحصاء، كلية الدارة والاقتصاد، جامعة بغداد، العراق (2016).

كرار حمزة حسين علي ، تشخيص وتقدير نماذج السلاسل الزمنية الموسمية مع تطبيق عملي ، رسالة ماجستير في الاحصاء، كلية الإدارة والاقتصاد، جامعة كربلاء، العراق (2021).

سمير فرج رشيد أبوحروج، استخدام نموذج (SARIMA) في التنبؤ بالسلاسل الزمنية الموسمية، مجلة الدراسات الاستراتيجية والبحوث السياسية 2(1)، 105 – 119 . (2023).

Box, G.E.P, &JENKINS,G.M.(1976). Time Serise Analysys- Forecastting and Control (zrced) . san Francisco: Holden – Day.

HOPfc. D.H., lee,k,& yu,c (2024) short – term forecasting airport passenger flow during periods of volatility : compative investigation of time series vs. neural network models Journal of Air transport management 115, 102525.

Meliyana,s .M,Hafid,H.Mar,ah,z, & muthahharah, 1 . (2025) . A ASEASONAL ARI MA (SARIMA) model for forecasting domestic passenger traffic at sultan Hasannddin Airport, Quantitative Economics and Management studies , 6(1), 144-153.

السيرة الذاتية

امحمد بعوه حصل على درجة البكالوريوس في علم الإحصاء من كلية العلوم بجامعة مصراتة، ثم نال درجة الماجستير في علم الإحصاء من الأكاديمية الليبية- مصراتة، وهو حاليا عضو هيئة تدريس بقسم الإحصاء في كلية العلوم بجامعة مصراتة. تشمل اهتماماته البحثية الإحصاء التطبيقي والنمذجة الإحصائية مع تركيز خاص على تحليل السلاسل الزمنية، ونماذج الانحدار الخطي البسيط والمتعدد وأساليب المعاينة وتصميم العينات وتحديد أحجامها. كما أهتم بتطير وتطبيق الأساليب إحصائية لتحليل البيانات الواقعية وبناء نماذج تسهم في فهم الأنماط والعلاقات الإحصائية والتنبؤ بالظواهر محل الدراسة.

محمد الشعافي حصل على درجة البكالوريوس في علم الإحصاء من كلية العلوم بجامعة مصراتة، ثم نال درجة الماجستير في علم الإحصاء من الأكاديمية الليبية- مصراتة، وهو حاليا عضو هيئة تدريس بالقسم العام في كلية العلوم التقنيةز وتشمل اهتماماته البحثية الإحصاء التطبيقي في مجال علوم التعليم والإحصاءات الحيوية.