



تحليل وتقييم نماذج ARIMA للتنبؤ بالسلاسل الزمنية "دراسة تطبيقية"



This work is licensed under a
Creative Commons Attribution-
NonCommercial 4.0
International License.

أ. هناء سليمان عبدالله أكريم

ماجستير في الإحصاء، محاضر، قسم الإحصاء، كلية العلوم، جامعة بنغازي.

نشر إلكترونياً بتاريخ: ٢٨ فبراير ٢٠٢٥م

الملخص

نموذج SARIMA على التقاط الأنماط الموسمية بشكل أفضل مقارنة بنموذج ARIMA. تم اختبار العشوائية في بواقي النماذج للتحقق من جودة التنبؤ. كما يوصى البحث بإزالة الثابت من النموذج لعدم معنويته، مع ضرورة تضمين التأثيرات الموسمية لتحسين دقة التنبؤ، ومتابعة استقرار النماذج بمرور الوقت. كما يوصى باختبار تأخيرات إضافية باستخدام ACF و PACF لضبط قيم (p, q)، والاعتماد على نموذج SARIMA عند وجود دورات موسمية واضحة، إلى جانب استخدام تقنيات مثل Grid Search و Bayesian Optimization لضبط المعلمات المثلى. مع دراسة نماذج متطورة مثل SARIMA-X والنماذج الهجينة.

الكلمات المفتاحية: نماذج SARIMA، SARIMA، إنتاج النفط، التنبؤ، السلاسل الزمنية.

يهدف البحث إلى دراسة وتقييم أداء نماذج ARIMA و SARIMA في التنبؤ بالسلاسل الزمنية لإنتاج النفط في ليبيا، مع التركيز على مقارنة دقة التنبؤ للنموذجين وتحليل قدرتهما على التقاط الأنماط الزمنية والموسمية. يتضمن البحث تحديد المعلمات المثلى للنماذج (p, d, q)، واختبار جودة بواقي التنبؤ باستخدام اختبارات إحصائية مثل اختبار Ljung-Box. كما تم استخدام المنهج الوصفي التحليلي، حيث جمعت بيانات إنتاج النفط الشهرية من ستة حقول بترول للفترة من سبتمبر ١٩٨٦ إلى أبريل ٢٠١٤ (٣٣٠ مشاهدة)، جرى تحليل خصائص السلاسل الزمنية واختبار استقرارها باستخدام اختبار ديكي فولر الموسع (ADF). تم بناء النماذج باستخدام تقنيات مثل Grid Search و AIC/BIC، وتقييم أدائها باستخدام مقاييس RMSE، MAE، و MAPE. وأظهرت النتائج قدرة

term from the model due to its insignificance, emphasizing the inclusion of seasonal effects to improve prediction accuracy, and monitoring model stability over time. It also recommends testing additional lags using ACF and PACF to optimize (p, q) values and adopting the SARIMA model in the presence of clear seasonal cycles, alongside techniques like Grid Search and Bayesian Optimization for optimal parameter tuning. Advanced models such as SARIMA-X and hybrid models were also suggested.

Keywords: ARIMA models, SARIMA, oil production, forecasting, time series.

* المقدمة

تنبع أهمية أساليب التنبؤ من توفير المعلومات للمستثمرين في قطاع البترول لترشيد القرارات الاستثمارية. إن استخدام وتطبيق البرامج والأساليب الإحصائية المختلفة في شتى المجالات ومنها التنبؤ بالخصائص والمؤثرات للعديد من المتغيرات والظواهر وباستخدام طرق القياس والتحليل الإحصائي يمكن التوصل إلى اتجاه عام لما سيحدث في المستقبل للمتغيرات التي تحكم ظاهرة ما وتوضيح العلاقات بين متغيرات الظواهر لمدة زمنية مقبلة.

Abstract

This research aims to study and evaluate the performance of ARIMA and SARIMA models in forecasting time series for oil production in Libya, focusing on comparing the prediction accuracy of the two models and analyzing their ability to capture temporal and seasonal patterns. The research involves identifying the optimal parameters for the models (p, d, q) and testing the quality of prediction residuals using statistical tests such as the Ljung-Box test. A descriptive-analytical approach was adopted, where monthly oil production data from six oil fields for the period from September 1986 to April 2014 (330 observations) was collected. The characteristics of the time series were analyzed, and their stationarity was tested using the Augmented Dickey-Fuller (ADF) test. Models were built using techniques such as Grid Search and AIC/BIC and evaluated with metrics like RMSE, MAE, and MAPE. The results showed that the SARIMA model was better at capturing seasonal patterns compared to the ARIMA model. The randomness of model residuals was tested to verify prediction quality. The research recommends removing the constant

* مشكلة البحث

تعتبر السلاسل الزمنية أداة أساسية لتحليل البيانات المتغيرة على مدار الزمن، حيث تلعب دوراً جوهرياً في مجالات متعددة مثل الاقتصاد، التمويل، الإنتاج، والطاقة. يتطلب التنبؤ الدقيق بهذه السلاسل الزمنية استخدام نماذج إحصائية فعالة قادرة على التقاط الأنماط الزمنية والتغيرات الموسمية. يُعد التنبؤ بالسلاسل الزمنية من الأدوات الأساسية المستخدمة في مجالات متعددة مثل الاقتصاد، التمويل، وإدارة الموارد. وتُعد نماذج ARIMA و SARIMA من أكثر النماذج شيوعاً للتنبؤ وتحليل البيانات الزمنية. ومع ذلك، تواجه هذه النماذج تحديات تتعلق بدقة التوقعات، وملاءمة البيانات التي قد تحتوي على أنماط موسمية أو اتجاهات معقدة، إلى جانب اختيار الملمات الأمثل للنماذج.

تمثل مشكلة البحث في الإجابة على السؤال التالي: ما مدى كفاءة نماذج ARIMA و SARIMA في التنبؤ بالسلاسل الزمنية؟ وكيف يمكن تحسين أدائها لتقديم توقعات دقيقة تلي احتياجات تطبيقات عملية مختلفة؟

* أهمية البحث

تكمن أهمية هذا البحث في عدة جوانب رئيسية: -
١- تحسين دقة التنبؤ: يساعد هذا البحث في تحسين فهم أداء نماذج ARIMA و SARIMA لتوفير تنبؤات دقيقة تعتمد على البيانات الزمنية، مما يدعم اتخاذ القرارات الاقتصادية والمالية.
٢- تحسين دقة التنبؤ بإنتاج النفط: يساهم البحث في تطوير أساليب دقيقة لتوقع إنتاج النفط باستخدام نماذج

ARIMA و SARIMA، مما يساهم في تحسين إدارة

الموارد النفطية.

* أهداف البحث

١- تحليل وتقييم أداء نماذج ARIMA و SARIMA ودراسة قدرة هذه النماذج على التنبؤ بالسلاسل الزمنية بدقة، مع مقارنة أدائها في سياقات بيانات زمنية مختلفة.
٢- تحديد أفضل معايير ضبط النماذج والتوصل إلى القيم المثلى لمعاملات النماذج (p, d, q) لتحقيق أداء تنبؤي أفضل.
٣- تحليل أثر الموسمية ودراسة تأثير الأنماط الموسمية على أداء نماذج التنبؤ، واختبار كفاءة نموذج SARIMA في التقاط هذه الأنماط مقارنةً بنموذج ARIMA.

* منهجية البحث

تتضمن هذه المنهجية الخطوات التالية: -
١- تحليل البيانات الأولي: استكشاف خصائص السلاسل الزمنية، بما في ذلك الاتجاهات العامة، الأنماط الموسمية. التحقق من استقرارية السلاسل الزمنية باستخدام اختبارات إحصائية مثل اختبار ديكي فولر الموسع (ADF).
٢- تصميم النماذج: بناء نماذج ARIMA و SARIMA مع تحديد الملمات المناسبة (p, d, q) باستخدام تقنيات مثل Grid Search و AIC/BIC، اختبار النماذج من خلال البيانات التاريخية وضبط الملمات لتحسين الأداء.
٣- استخدام برامج متخصصة في السلاسل مثل برنامج (SPSS-VIEWS)

* حدود البحث

احدي شركات البترول الليبية والتي تأسست في عام ١٩٨١ وذلك في المناطق التي تغطيها اتفاقية الالتزام للبحث والتنقيب عن البترول. ممثلة في عدة حقول أهمها (حقول X1 - حقول X2 - حقول X3 - حقول X4 - حقول X5 - حقول X6) ، وسوف يتم الاعتماد في هذه الدراسة علي متوسط الإنتاج الشهري للحقول السابقة وللبينات المتوفرة من شهر سبتمبر ١٩٨٦ وحتى أبريل ٢٠١٤ أي ٣٣٠ مشاهدة.

* فروض البحث

- ١- الفرض الأول: نماذج ARIMA قادرة على تقديم توقعات دقيقة للسلاسل الزمنية ذات الاتجاهات الثابتة.
- ٢- الفرض الثاني: نماذج SARIMA تحقق أداءً أفضل من نماذج ARIMA في السلاسل الزمنية التي تحتوي على أنماط موسمية.
- ٣- الفرض الثالث: تحسين معلمات النماذج (p, d, q) باستخدام معايير مثل AIC و BIC يؤدي إلى تحسين دقة التنبؤ.
- ٤- الفرض الرابع: هناك اختلاف جوهري بين أداء نماذج ARIMA و SARIMA بناءً على طبيعة البيانات المدروسة (اتجاه، تذبذب، موسمية).

* الدراسات السابقة

- 1- Al-Shami, A. H., & Nasser, R. M. (2022): ARIMA Model Application for Forecasting Agricultural Production in Jordan

تناولت الدراسة تحليل بيانات الإنتاج الزراعي في الأردن باستخدام نموذج ARIMA للتنبؤ بالمرجات المستقبلية للمحاصيل الرئيسية، مما ساعد في تحسين التخطيط الزراعي وتوجيه الموارد بكفاءة. أظهرت النتائج تأثير المتغيرات المناخية والاقتصادية على الإنتاجية، وأوصت بتحديث البيانات دورياً وتكامل النماذج مع البيانات المناخية لدعم السياسات الزراعية.

2- Wang, X., & Zhu, Y. (2023): "Comparative Analysis of Time Series Forecasting Models: ARIMA vs. SARIMA on Seasonal Data"

قارنت دراسة Wang و Zhu (2023) بين نماذج ARIMA و SARIMA لتوقع مبيعات شركة تجارية على مدار خمس سنوات. أظهرت النتائج تفوق SARIMA في التقاط الأنماط الموسمية وتحقيق دقة تنبؤ أفضل، حيث سجل انخفاضاً في RMSE و MAE بنسبة ١٨٪ و ٢٢٪ مقارنة بـ ARIMA. أوصى الباحثان باستخدام SARIMA لتحليل البيانات الموسمية وتحسين المعلمات لضمان أداء أمثل.

3- Li & Chen (2023): Optimization of ARIMA Parameters Using Grid Search: Improving Forecast Accuracy for Energy Consumption Data

هدفت الدراسة إلى تحسين أداء نماذج ARIMA لتنبؤ استهلاك الطاقة في المناطق الصناعية باستخدام تقنية البحث الشبكي لضبط المعلمات المثلى. أظهرت النتائج تفوق النموذج المُحسن بنسبة ١٥٪ مقارنة بالنماذج التقليدية، مع

Models: An Application on Tourism Demand in Egypt"

هدفت الدراسة إلى تقييم نماذج السلاسل الزمنية

الموسمية لتنبؤ الطلب السياحي في مصر باستخدام SARIMA. أظهرت النتائج تفوق SARIMA على

ARIMA، حيث قللت الأخطاء التنبؤية بنسبة ٢٠٪. يُوصى باستخدام SARIMA لتحليل البيانات السياحية الموسمية وتضمنين متغيرات اقتصادية وأحداث سياحية لتحسين التنبؤات، مع تشجيع دمجها بتقنيات التعلم الآلي.

* الاختلاف بين الدراسات السابقة والدراسة الحالية

فيما يلي بعض النقاط التي تميز الدراسة الحالية عن

الدراسات السابقة: -

١- ركزت معظم الدراسات السابقة على مجالات مثل التنبؤ بالطلب السياحي، أسعار الأسهم، أو استهلاك الطاقة، تهدف الدراسة الحالية إلى التنبؤ بإنتاج النفط، وهو قطاع حيوي ذو أهمية اقتصادية عالمية.

٢- تقدم الدراسة مقارنة شاملة بين نماذج ARIMA و SARIMA، مع التركيز على تحسين التنبؤ ببيانات إنتاج النفط، وهو تطبيق نادر لهذه النماذج مقارنة بالاستخدامات التقليدية في الدراسات السابقة.

* السلاسل الزمنية

١- نماذج بوكس-جينكينز (Box-Jenkins)

Models) مثل ARIMA

نماذج بوكس-جينكينز (Box-Jenkins)

Models) هي مجموعة من النماذج الإحصائية المستخدمة

لتحليل السلاسل الزمنية والتنبؤ بالقيم المستقبلية. يعتبر نموذج

الانخفاض RMSE بنسبة ١٢٪ و MAE بنسبة ١٠٪.

أوصت الدراسة باعتماد تقنيات تحسين إضافية واختبار فعاليتها في قطاعات أخرى.

4- Park, S., & Kim, D. (2023): "Seasonal Forecasting with SARIMA: Case Study on Climate Data Prediction"

تناولت الدراسة فعالية نموذج SARIMA في

تحليل وتنبؤ بيانات المناخ الموسمية، حيث أظهر تفوقاً في التقاط

التغيرات الموسمية بدقة أعلى مقارنة بنماذج ARIMA

التقليدية. أوصت الدراسة باعتماد SARIMA في التنبؤ

المناخي وتحسين ضبط المعلمات باستخدام Grid Search،

مع تشجيع دمجها بتقنيات تعلم الآلة لتعزيز دقة التنبؤ.

5- Ahmed, M. A., & Khan, R. (2024): "Advanced Time Series Forecasting Models for Financial Markets: A Case Study Using ARIMA and Hybrid Models"

تناولت الدراسة مقارنة بين نموذج ARIMA

والنماذج الهجينة التي تدمج ARIMA مع تقنيات التعلم

العميق مثل RNN و LSTM لتوقع تحركات أسواق المال

الهندية. أظهرت النماذج الهجينة تفوقاً ملحوظاً في التعامل مع

تقلبات السوق، مسجلة انخفاضاً بنسبة ٢٥٪ في RMSE

و ٢٠٪ في MAE. أوصت الدراسة باستخدام النماذج

الهجينة لتحسين التنبؤات وضبط معلمات الشبكات بدقة

لتحقيق الأداء الأمثل.

6- El-Mahdi, N., & Youssef, H. (2024): "Evaluating Seasonal Time Series

ARIMA (Autoregressive Integrated Moving Average) من أهم هذه النماذج، حيث يجمع بين الانحدار الذاتي (AR)، التكاملي (I)، والمتوسطات المتحركة (MA).

٢- مكونات نموذج ARIMA:

١- الانحدار الذاتي (AR - AutoRegressive)

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t \dots \dots \dots (١)$$

١- X_t : القيمة الحالية.

٢- $\phi_1, \phi_2, \dots, \phi_p$: معاملات الانحدار الذاتي.

٣- ϵ_t : الخطأ العشوائي.

٤- التكامل (I - Integration)

$$X_t^{(d)} = X_t - X_{t-1} \text{ الصيغة } *$$

* مكونات الصيغة

١- X_t : القيمة الأصلية للسلسلة الزمنية عند الزمن t .

٢- X_{t-1} : القيمة السابقة للسلسلة الزمنية عند الزمن t .

1.

٣- d : عدد مرات أخذ الفرق (درجة التكامل)

* المتوسط المتحرك (MA - Moving Average)

* المعادلة العامة

$$X_t = \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t \dots \dots \dots (٢)$$

١- $\theta_1, \theta_2, \dots, \theta_q$: معاملات المتوسط المتحرك

٢- $\epsilon_{t-1}, \epsilon_{t-2}, \dots, \epsilon_{t-q}$: الأخطاء السابقة

١- مزايا نموذج ARIMA : مناسب لتحليل السلاسل الزمنية التي لا تحتوي على عناصر موسمية. فعال في التنبؤ بالسلاسل الزمنية الخطية بعد تحويلها إلى سلسلة ثابتة.

٢- قيود نموذج ARIMA : يفترض أن البيانات خطية وقابلة للتحويل إلى سلسلة ثابتة. لا يتعامل بشكل مباشر مع البيانات التي تحتوي على مكونات موسمية (يتم استخدام SARIMA بدلاً منه).

٣- تطبيقات نموذج ARIMA : التنبؤ بإنتاج النفط بناءً على البيانات التاريخية. التنبؤ بأسعار الأسهم. التنبؤ بالمبيعات الموسمية بعد تعديل البيانات.

* النماذج الموسمية SARIMA

١- صيغة نموذج SARIMA: نموذج SARIMA هو امتداد لنموذج ARIMA مع إضافة مكونات موسمية للتحليل حيث تعتبر الصيغة الرياضية

$$\Phi_p(B^s)\phi(B)(1-B)^d(1-B^s)^D Y_t = \Theta_q(B^s)\theta(B)\epsilon_t \dots \dots \dots (٣)$$

٢- مزايا نموذج SARIMA : يتعامل بشكل فعال مع البيانات التي تحتوي على أنماط موسمية. يوفر تنبؤات دقيقة للسلاسل الزمنية الموسمية بعد ضبط العلامات بشكل صحيح. مرن في التعامل مع البيانات الثابتة وغير الثابتة.

٣- قيود نموذج SARIMA: يتطلب خبرة في تحديد العلامات الموسمية بشكل صحيح. قد يكون معقداً عندما تحتوي البيانات على أنماط موسمية متعددة. يفترض خطية البيانات ولا يتعامل بشكل فعال مع الأنماط غير الخطية.

٤- تطبيقات نموذج SARIMA : التنبؤ بمعدلات الإنتاج الموسمية. التنبؤ بالمبيعات خلال الفصول المختلفة. تحليل الطلب الموسمي على الكهرباء أو الغاز.

* المقاييس الشائعة لتقييم دقة التنبؤ

خطأ متوسط القيمة المطلقة (Mean Absolute Error – MAE)

* الصيغة الرياضية

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (٤)$$

١- مزاياه: سهل الفهم ولا يتأثر بالقيم الشاذة .

* خطأ الجذر التربيعي لمتوسط المربعات (Root Mean Squared Error – RMSE)

* الصيغة الرياضية

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (٥)$$

١- مزاياه : حساس للقيم الشاذة

* متوسط نسبة الخطأ المطلقة (Mean Absolute Percentage Error – MAPE)

Percentage Error – MAPE)

* الصيغة الرياضية

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (٦)$$

١- مزاياه : يقدم قياساً نسبياً للأخطاء

* معامل التحديد (R^2)

* المعادلة الرياضية

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (٧)$$

١- مزاياه : يُظهر كفاءة النموذج في تفسير البيانات

٢- استخداماته : مناسب لتقييم الأداء الإجمالي للنموذج

* التطبيق العملي لتحليل البيانات

* إختبارات إستقرار وسكون السلاسل (إختبارات جذر الوحدة)

يتضح أن جميع السلاسل المستخدمة في التقدير تحتوي على جذر الوحدة، أى أنها غير مستقرة في المستوى العام في حالة عدم وجود قاطع وبدون اتجاه عام، ومستقرة في حالة وجود كل من القاطع والاتجاه الزمني العام للفرق الأول، وهذا ما يظهره الجدول التالي.

جدول (٣-٣) نتائج اختبار جذر الوحدة لسلاسل الإنتاج للحقول

الست خلال الفترة المتاحة

ADF	X1		X2		X3		X4		X5		X6	
	Value	Sig.	Value	Sig.	Value	Sig.	Value	Sig.	Value	Sig.	Value	Sig.
Before	0.476	0.817	-0.973	0.295	0.220	0.749	-0.234	0.600	-0.296	0.578	-0.591	0.461
After	-16.392	0.000	-13.28	0.000	-10.37	0.000	-9.312	0.000	-11.49	0.000	-13.25	0.000

يشير اختبار ADF إلى أن جميع السلاسل الزمنية

كانت غير مستقرة قبل الفرق الأول حيث كانت قيم Sig. أكبر من ٠.٠٠٠٥. بعد الفرق الأول، أصبحت السلاسل مستقرة بوضوح مع قيم سالبة كبيرة وقيم Sig. تساوي ٠.٠٠٠٠، مما يؤكد تحقيق الثبات وتحسين ملائمة النماذج.

* معاملات الارتباط الذاتي للسلاسل الزمنية

جدول رقم (٣-٤) معاملات الارتباط الذاتي للسلاسل الزمنية

ACF		Case Processing Summary					
		x1	x2	x3	x4	x5	x6
Series Length		272	272	272	272	272	272
Number of Missing Values	User-Missing	0	0	0	0	0	0
	System-Missing	0	70 ^a	120 ^a	124 ^a	91 ^a	72
Number of Valid Values		272	202	152	148	181	200
Number of Computable First Lags		271	201	151	147	180	199

1- Some of the missing values are imbedded within the series.

تتمتع السلاسل الزمنية بطول موحد (٢٧٢)، مما

يضمن تكامل البيانات، لكن وجود قيم مفقودة في بعض السلاسل (X2) إلى (X6) يشكل تحدياً يؤثر على دقة التوقعات واستقرار النماذج. يُوصى بإزالة القيم المفقودة أو إكمالها بتقنيات مناسبة. كما أن تفاوت التأخيرات بين السلاسل يعكس تأثير القيم المفقودة على تحليل الارتباط الذاتي.

* جودة النماذج

جدول (٣-٧) Model Fit

Fit Statistic	Mean	SE	Minimum	Maximum	Percentile		
					25	50	95
Stationary R-squared	.026	.023	-1.000E-013	.051	-1.000E-013	.029	.051
R-squared	.947	.025	.903	.974	.933	.946	.974
RMSE	521.064	280.646	258.904	1000.643	304.566	461.415	1000.643
MAPE	4.725	1.723	2.644	6.972	2.916	4.801	6.972
MaxAPE	38.017	22.303	20.739	80.436	23.612	28.949	80.436
MAE	325.190	177.908	158.384	623.779	191.274	264.124	623.779
MaxAE	3143.830	2163.511	1155.068	6838.141	1181.331	2838.598	6838.141
Normalized BIC	12.312	1.029	11.165	13.841	11.465	12.205	13.841

يعكس الجدول جودة ملائمة النماذج باستخدام

عدة إحصائيات. سجلت النماذج متوسط R-squared مرتفعاً (٠.٩٤٧) مما يشير إلى قدرة النماذج على تفسير معظم التباين في البيانات. كانت قيمة RMSE مرتفعة بمتوسط ٥٢١.٠٦٤، مما يشير إلى وجود بعض الأخطاء التنبؤية. كذلك، تُظهر قيم MAPE المنخفضة (٤.٧٢٥) دقة نسبية جيدة في التنبؤ، بينما تشير قيم MaxAE المرتفعة إلى وجود بعض الأخطاء الكبيرة في بعض النقاط.

* إحصائيات النماذج

جدول رقم (٣-٨) إحصائيات النماذج

Model Statistics						
Model Number	Number of Predictors	Model Fit statistics	Ljung-Box Q(18) Statistics			Number of Outliers
			Stationary R-squared	Statistics	DF	Sig.
x1-Model_1	0	.025	.025	28.072	17	.044
x2-Model_2	0	-1.000E-013	-1.000E-013	16.299	18	.572
x3-Model_3	0	.032	.032	12.676	17	.758
x4-Model_4	0	.051	.051	30.918	17	.020
x5-Model_5	0	.049	.049	49.735	16	.000
x6-Model_6	0	-1.000E-013	-1.000E-013	20.842	18	.287

تحليل وتفسير نتائج إحصائيات النماذج: يعكس

الجدول إحصائيات تقييم النماذج. يُظهر النموذج X1 قيمة Stationary R-squared منخفضة (٠.٠٢٥) مع اختبار Ljung-Box ذو دلالة إحصائية (٠.٠٤٤)، مما يشير إلى وجود ارتباط زمني متبقي. النموذج X2 لديه قيمة Stationary R-squared صفرية وعدم دلالة إحصائية في اختبار Ljung-Box (0.572)، مما يشير إلى

جودة استقرار ضعيفة ولكن بدون ارتباط زمني. النموذج X5 يظهر ارتباطاً زمنياً ملحوظاً بدلالة إحصائية قوية (0.0000). جميع النماذج لم تسجل وجود نقاط متطرفة.

* نماذج الانحدار الذاتي الموسمية SARIMA

بحساب معاملات الارتباط الذاتي والجزئي للعينة والتي تساعد في التعرف على نموذج SARIMA المناسب وباستخدام التحويلة المناسبة لتحقيق السكون وتثبيت التباين والمتاحة بنظام SPSS حيث تم التوصل إلى أن أفضل النماذج وجودتها ومعالمها المقدرة هي كما يلي:

جدول (٣-٩) نتائج توفيق نماذج السارما لسلاسل الإنتاج للحقول الست خلال الفترة المتاحة

X1	Model_1	ARIMA(0,1,5)(0,0,0)
X2	Model_2	ARIMA(0,1,0)(0,0,0)
X3	Model_3	ARIMA(0,1,1)(0,0,0)
X4	Model_4	ARIMA(0,1,6)(0,0,0)
X5	Model_5	ARIMA(0,1,0)(1,01)
X6	Model_6	ARIMA(0,1,1)(0,0,0)

جدول (٣-١٠) إحصائيات النموذج Model Statistics

Model	Number of Predictors	Model Fit statistics Stationary R-squared	Ljung-Box Q(18)			Number of Outliers
			Statistics	DF	Sig.	
X1-Model_1	0	.065	14.123	16	.590	0
X2-Model_2	0	-6.065e-16	18.090	18	.450	0
X3-Model_3	0	.034	13.529	17	.700	0
X4-Model_4	0	.078	31.406	16	.012	0
X5-Model_5	0	.014	55.914	16	.000	0
X6-Model_6	0	.017	13.942	17	.671	0

يوضح الجدول أداء النماذج المستخدمة لتحليل البيانات الزمنية. يعكس معامل R-Stationary

squared قيمًا منخفضة في معظم النماذج، مما يشير إلى ضعف القدرة التفسيرية لبعض النماذج. اختبار-Ljung-Box يكشف عن ملاءمة النموذج للبيانات؛ حيث تظهر قيم Sig. أكبر من 0.05 لمعظم النماذج، مما يدل على عدم وجود ارتباط ذاتي كبير في البواقي باستثناء النموذجين X4 و X5. لا تحتوي النماذج على أي قيم شاذة، مما يعزز موثوقية التحليل.

جدول (٣-١١) التوقعات المستقبلية لنماذج السارما لسلاسل الإنتاج للحقول

DATE	X1_Model_1	X2_Model_2	X3_Model_3	X4_Model_4	X5_Model_5	X6_Model_6
JAN 2014 P	44262	6100	4473	2823	1867	2489
JAN 2014 A	39665	6015	4421	2796	1877	2468
FEB 2014 P	39489	6020	4411	2787	1877	2465
FEB 2014 A	43765	6152	4337	2797	1871	2460
MAR 2014 P	42073	6157	4323	2796	1877	2489
MAR 2014 A	40347	6210	4327	2703	1791	2496
APR 2014 P	41348	6215	4208	2491	1739	2502
MAR 2014 A	41306	6265	4337	2485	1880	2458
MAY 2014	40823	6270	4243	2464	1885	2451
JUN 2014	39678	6275	4243	2464	1882	2451
JUL 2014	40614	6379	4243	2460	1883	2451
AUG 2014	40236	6284	4243	2461	1882	2451
SEP 2014	40227	6289	4243	2447	1860	2451
OCT 2014	40227	6294	4243	2446	1885	2451
NOV 2014	40227	6298	4243	2446	1885	2451
DEC 2014	40227	6303	4243	2446	1885	2451
JAN 2015	40227	6308	4243	2446	1885	2451
FEB 2015	40227	6313	4243	2446	1885	2451
MAR 2015	40227	6317	4243	2446	1885	2451
APR 2015	40227	6322	4243	2446	1885	2451
MAY 2015	40227	6327	4243	2446	1885	2451
JUN 2015	40227	6332	4243	2446	1885	2451
JUL 2015	40227	6336	4243	2446	1885	2451
AUG 2015	40227	6341	4243	2446	1885	2451
SEP 2015	40227	6346	4243	2446	1885	2451
OCT 2015	40227	6351	4243	2446	1885	2451
NOV 2015	40227	6355	4243	2446	1885	2451
DEC 2015	40227	6360	4243	2446	1885	2451

تُظهر البيانات مقارنة بين القيم الفعلية (Actual) والمتوقعة (Predicted) للنماذج من يناير ٢٠١٤ إلى ديسمبر ٢٠١٥. يشير التحليل إلى أن معظم النماذج قدمت تنبؤات قريبة من القيم الفعلية خلال فترة الاختبار، مع تفاوت طفيف في بعض الأشهر. يلاحظ تفاوت ملحوظ في X1 و X2 خلال الأشهر الأولى من ٢٠١٤، مما يعكس تحديات

في دقة النماذج في بداية الفترة. أما بقية النماذج (X3) إلى (X6) فتُظهر استقراراً ودقة نسبية في التنبؤ على المدى الطويل. يدل الاستقرار الظاهر في التنبؤات على ملاءمة هذه النماذج لتحليل البيانات الزمنية.

* المعايير الإحصائية لقدرة النموذج التنبؤية بالسلسلة الزمنية لكل من السلاسل الزمنية

جدول (٣-١٢) المعايير الإحصائية لتقدير التنبؤ للنموذج

النموذج	الجذر التربيعي للخطأ (RMSE)	المؤشر النسبي للخطأ المطلق (MAPE)	متوسط القيمة المطلقة للأخطاء (MAE)	معامل ثيل (Theil)	معامل التحديد R^2	معامل مؤشر الدلالة TS	معامل الارتباط D_1
X1 للسلاسل	763.9	4.6	507.4	0.03	0.979	5.9	0.53
X2 للسلاسل	162.9	4.1	112.5	0.03	0.910	4.6	0.36
X3 للسلاسل	196.3	3.8	142.3	0.03	0.974	24.5	0.47
X4 للسلاسل	203.5	1.5	137.0	0.01	0.948	10.3	0.46
X5 للسلاسل	461.5	8.19	282.2	0.05	0.942	15.9	0.29
X6 للسلاسل	792.4	1.6	497.9	0.01	0.981	53.5	0.37

النموذج X6 حقق أعلى قيمة لكل من الجذر التربيعي للخطأ (RMSE) ومتوسط القيمة المطلقة للأخطاء (MAE)، مما يعكس أداءً أقل دقة في التنبؤ مقارنة بباقي النماذج، رغم تسجيله لأعلى معامل تحديد ($R^2=0.981$)، ما يشير إلى قدرته على تفسير نسبة كبيرة من التغيرات في البيانات. في المقابل، تميز النموذج X4 بأقل قيمة لمعامل ثيل (Theil) وأعلى استقرار في التنبؤ، مما يجعله من بين أفضل النماذج. أما النموذج X2 فقد حقق قيمة منخفضة لكل من RMSE و MAE، لكنه أظهر ارتباطاً ضعيفاً مع القيم الحقيقية ($p=0.36$) من جهة أخرى، سجل النموذج X5 أعلى قيمة للمتوسط النسبي للخطأ المطلق (MAPE) بنسبة ٨.١٩٪، مما يعكس نسبة خطأ

كبيرة في التنبؤ. جدير بالذكر أن جميع النماذج سجلت معاملات تحديد (R^2) مرتفعة، مما يشير إلى قدرتها على تفسير التغيرات في البيانات بشكل عام.

* تحليل التقديرات والمتغيرات الإحصائية

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	39849.76	133973.0	0.297446	0.7663
AR(1)	0.942125	0.114638	8.218272	0.0000
SAR(1)	0.995791	0.028746	34.64127	0.0000
MA(1)	-0.915495	0.122891	-7.449633	0.0000
R-squared	0.974349	Mean dependent var		19404.66
Adjusted R-squared	0.974112	S.D. dependent var		5913.451
S.E. of regression	951.4600	Akaike info criterion		16.56599
Sum squared resid	2.93E+08	Schwarz criterion		16.61225
Log likelihood	-2712.823	Hannan-Quinn criter.		16.58445
F-statistic	4102.439	Durbin-Watson stat		2.430486
Prob(F-statistic)	0.000000			

توضح النتائج تقدير معاملات نموذج السلاسل الزمنية وتقييم جودته، حيث جاءت المعاملات (AR(1)، SAR(1)، و MA(1) ذات دلالة إحصائية ($Prob=0.000$)، مما يعكس تأثيرها القوي في التنبؤ بالقيم المستقبلية للسلسلة الزمنية. يشير معامل $AR(1)=0.942$ و $SAR(1)=0.995$ إلى وجود ارتباط قوي بين القيم الحالية والماضية للسلسلة الزمنية. كما تؤكد قيم R -squared=0.974 و Adjusted R-squared=0.974 قدرة النموذج على تفسير ٩٧.٤٪ من التغيرات في البيانات. يشير Durbin-Watson stat=2.43 إلى غياب مشكلة الارتباط الذاتي في البواقي، ويدعم F-statistic=4102.439 الدلالة الكلية

للمنموذج. علاوة على ذلك، يشير التقارب بين قيم المعايير الثلاثة $AIC=16.56599$ ، $BIC=16.61225$ ، $HQC=16.58445$ إلى استقرار وتحسن أداء النموذج مع عدم وجود إفراط في عدد المتغيرات، مما يعزز من فعاليته في التنبؤ. هذه القيم المتقاربة تؤكد استقرار الأداء وجودة التقدير، وهو ما يجعل النموذج موثوقاً لتقديم نتائج دقيقة مع الحفاظ على بساطة هيكله، وهو عنصر أساسي في النماذج الإحصائية للسلاسل الزمنية.

* التوصيات

تحليل الأداء يوصي بعدة جوانب لتحسين النموذج ودقة التنبؤ، وأهمها: -

- ١- تضمين التأثيرات الموسمية باستخدام نماذج مثل SARIMA استناداً إلى معنوية معامل $SAR(1)$
- ٢- مراقبة الأداء دورياً واختبار تأخيرات إضافية عبر تحليل ACF و PACF لضبط قيم p و q
- ٣- تحسين ضبط المعلمات: اعتماد تقنيات مثل Grid Search و Bayesian Optimization بجانب إدخال متغيرات إضافية أو خوارزميات تحسين متقدمة.
- ٤- النماذج البديلة: النظر في نماذج موسمية متقدمة مثل SARIMA-X أو النماذج المختلطة مثل VARMA لتحسين الملاءمة.
- ٥- مقارنة النموذج مع نماذج مثل ARIMA و VAR/VECM واختبار معنوية العلاقات باستخدام Granger للسببية.

- ٦- تعزيز جودة التنبؤ: توسيع مقاييس التقييم لتشمل Logarithmic Loss ومؤشرات المعلومات (AIC و BIC)، وتحليل رسومي للأخطاء لفهم الترابط المتبقي.
- ٧- تحليل العلاقات: تحسين فهم العلاقات بين المتغيرات عبر دمج تحليل المكونات الأساسية (PCA).

* المراجع

أولاً- المراجع العربية

- أحمد، محمود علي. (2022). نماذج التنبؤ بالسلاسل الزمنية في الاقتصاد: دراسة تطبيقية. المركز القومي للبحوث الاجتماعية، القاهرة.
- السعيد، عادل عبد الله. (2021). تطبيقات السلاسل الزمنية متعددة المتغيرات في التنبؤ الاقتصادي: دراسة حالة على الاقتصاد المصري. كلية الاقتصاد، جامعة القاهرة.
- العباسي، عبد الحميد محمد. (٢٠٠٩). التحليل المتعدد المتغيرات باستخدام SPSS. معهد الدراسات والبحوث الإحصائية، جامعة القاهرة، مصر.
- العباسي، عبد الحميد محمد. (٢٠١٠). التحليل الإحصائي المتقدم باستخدام SPSS. معهد الدراسات والبحوث الإحصائية، جامعة القاهرة، مصر.
- العباسي، عبد الحميد محمد. (٢٠١٠). التحليل الحديث للسلاسل الزمنية باستخدام EViews. معهد الدراسات والبحوث الإحصائية، القاهرة.

- El-Mahdi, N. & Youssef, H., 2024. Evaluating seasonal time series models: An application on tourism demand in Egypt. *Egyptian Journal of Tourism and Hospitality Studies*, 12(2), pp. 101-119.
- Li, J. & Chen, H., 2023. Optimization of ARIMA parameters using grid search: Improving forecast accuracy for energy consumption data. *Energy Data Science Journal*, 8(4), pp. 77-92.
- Li, J. & Chen, Y., 2023. Optimization of ARIMA parameters using grid search: Improving forecast accuracy for energy consumption data. *Journal of Energy Forecasting and Analytics*, 12(4), pp. 215-229.
- Park, S. & Kim, D., 2023. Seasonal forecasting with SARIMA: Case study on climate data prediction. *Journal of Climate Analytics*, 15(2), pp. 105-120.
- Wang, X. & Zhu, Y., 2023. Comparative analysis of time series forecasting models: ARIMA vs. SARIMA on seasonal data. *International Journal of Data Science and Forecasting*, 18(2), pp. 45-58.
- العباسي، عبد الحميد محمد. (٢٠١٣). التنقيب في البيانات باستخدام SPSS Modeler. معهد الدراسات والبحوث الإحصائية، جامعة القاهرة، مصر.
- العباسي، عبد الحميد محمد. (٢٠١٣). مقدمة في الشبكات العصبية وتطبيقاتها في العلوم الاجتماعية باستخدام SPSS. معهد الدراسات والبحوث الإحصائية، جامعة القاهرة، مصر.
- ثانياً- المراجع الاجنبية
- Ahmed, M.A. & Khan, R., 2024. Advanced time series forecasting models for financial markets: A case study using ARIMA and hybrid models. *Journal of Financial Analytics*, 18(1), pp. 45-67.
- Al-Shami, A.H. & Nasser, R.M., 2022. ARIMA model application for forecasting agricultural production in Jordan. *Journal of Agricultural Forecasting*, 15(3), pp. 123-140.
- Box, G.E., Jenkins, G.M. & Reinsel, G.C., 2015. Time series analysis: Forecasting and control. Hoboken, NJ: John Wiley & Sons.
- Chatfield, C., 2016. The analysis of time series: An introduction, 7th ed. Boca Raton, FL: CRC Press.