

التنبؤ بالنمو الاقتصادي في سورية: دراسة مقارنة بين نماذج الانحدار الذاتي للمتوسطات المتحركة والمدعومة بالشبكات العصبية

الدكتورة رولى شفيق اسماعيل*

(تاريخ الإيداع ٢٠٢٥ / ١ / ٢٣ - تاريخ النشر ٢٠٢٥ / ٤ / ١٥)

□ ملخص □

هدفت هذه الدراسة إلى تحسين دقة التنبؤ بالنمو الاقتصادي في سورية من خلال تطوير نموذج هجين يجمع بين نماذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) والشبكات العصبية المتكررة (RNN). تم استخدام بيانات النمو الاقتصادي من المكتب المركزي للإحصاء للفترة من ١٩٦١ إلى ٢٠٢٢، حيث تم تطبيق نموذج ARIMA باستخدام دالة "Auto ARIMA" في بيئة R Studio، ونموذج RNN باستخدام مكتبة Keras و TensorFlow. تم دمج نتائج النموذجين في نموذج هجين (NNAR) لتحسين دقة التنبؤ. أظهرت النتائج تفوق النموذج الهجين بشكل واضح، حيث سجل متوسط خطأ (ME) بلغ ٠,٠٠٢٥، وجذر متوسط الخطأ التربيعي (RMSE) عند ٢,٨٨٦، ومتوسط نسبة الخطأ المطلق (MAPE) عند ١,٣٦١٪، مقارنة بنماذج ARIMA و RNN بشكل منفصل. كما توقع النموذج الهجين تقلبات كبيرة في النمو الاقتصادي السوري للفترة من ٢٠٢٣ إلى ٢٠٣٠، مع معدلات نمو تتراوح بين -١,٢٤٧٪ و ٣,٢٤٧٪. توصي الدراسة باعتماد النموذج الهجين كأداة رئيسة لدعم صناع القرار في سورية، وتدريب الكوادر الفنية على تقنيات الذكاء الاصطناعي، ووضع خطط استباقية لمواجهة التحديات الاقتصادية المحتملة. الكلمات المفتاحية: التنبؤ، النمو الاقتصادي، النماذج الهجينة، نماذج ARIMA، الشبكات العصبية المتكررة (RNN).

* أستاذ مساعد، قسم الإحصاء والبرمجة، كلية الاقتصاد، جامعة اللاذقية.

Forecasting Economic Growth in Syria: A Comparative Analysis of Autoregressive Integrated Moving Average (ARIMA) Models and Autoregressive Models Enhanced by Neural Networks

Dr. Rola Shafiq Ismail*

(Received 23/1/2025. Accepted 15/4/2025)

□ ABSTRACT □

This study aims to enhance the accuracy of forecasting economic growth in Syria by developing a hybrid model that combines Autoregressive Integrated Moving Average (ARIMA) models and Recurrent Neural Networks (RNN). The research utilized Syrian economic growth data from the Central Bureau of Statistics for the period 1961–2022. The ARIMA model was applied using the "Auto ARIMA" function in R Studio, while the RNN model was developed using the Keras and TensorFlow libraries. The results of both models were integrated into a hybrid model (NNAR) to improve forecasting accuracy. The findings demonstrated the clear superiority of the hybrid model, achieving a Mean Error (ME) of 0.0025, a Root Mean Square Error (RMSE) of 2.886, and a Mean Absolute Percentage Error (MAPE) of 1.361%, compared to the standalone ARIMA and RNN models. The hybrid model also predicted significant fluctuations in Syria's economic growth from 2023 to 2030, with growth rates ranging between -1.247% and 3.247%. The study recommends adopting the hybrid model as a primary tool for supporting decision-makers in Syria, training technical staff in artificial intelligence techniques, and developing proactive plans to address potential economic challenges.

Keywords: Forecasting, Economic Growth, Hybrid Models, ARIMA, Recurrent Neural Networks (RNN).

* Assistant Professor, Department of Statistics and Programming, Faculty of Economics, Tishreen University

1- المقدمة:

شهدت الشبكات العصبية الاصطناعية تطوراً ملحوظاً في السنوات الأخيرة في مجال تحليل السلاسل الزمنية والتنبؤ بها، حيث أثبتت قدرتها الفائقة على التعامل مع البيانات المعقدة وغير الخطية التي يصعب على النماذج التقليدية معالجتها. تعد الشبكات العصبية المتكررة (RNN) وأنواعها المتقدمة مثل وحدات البوابات المتكررة (GRU) وذاكرة المدى الطويل والقصير (LSTM) من أكثر الأدوات فعالية في هذا المجال، وذلك لقدرتها على التقاط التبعيات الزمنية والأنماط المخفية في البيانات (Yang et al., 2023). بالإضافة إلى ذلك، تم تطوير نماذج للسلاسل الزمنية في إطار تقنيات الشبكات العصبية والنماذج الإحصائية الكلاسيكية، مما يعزز دقة التنبؤات ويوفر رؤى أعمق للعلاقات الخطية وغير الخطية في البيانات (Ahmadi et al., 2019). أما فيما يتعلق بأهمية التنبؤ بالنمو الاقتصادي، فإنه يعد أداة حيوية لصناع القرار في رسم السياسات الاقتصادية وتوجيه الموارد بشكل فعال. يساعد التنبؤ الدقيق بالنمو الاقتصادي في تحديد الاتجاهات المستقبلية للاقتصاد، مما يمكن الحكومات والمنظمات من اتخاذ إجراءات استباقية لتعزيز الاستقرار الاقتصادي وتجنب الأزمات المحتملة (Ma, 2024). في سياق سورية، يكتسب هذا الموضوع أهمية إضافية بسبب التحديات الاقتصادية التي تواجهها البلاد، مما يجعل من الضروري الاعتماد على نماذج تنبؤ متطورة يمكنها تحليل البيانات التاريخية المعقدة وتقديم توقعات دقيقة لدعم عملية صنع القرار.

2- الدراسات السابقة:

• دراسة (Taiba and Ben Saha, 2022) بعنوان: التنبؤ بالنمو الاقتصادي للجزائر باستخدام

منهجية بوكس-جينكينز للفترة الزمنية (١٩٨٠-٢٠٢٠).

Forecasting the economic growth of Algeria using the Box-Jenkins methodology for the time period (1980-2020):

هدفت هذه الدراسة إلى التنبؤ بالنمو الاقتصادي للجزائر خلال الفترة (١٩٨٠-٢٠٢٠) باستخدام منهجية بوكس-جينكينز، حيث تم اختيار معدل نمو نصيب الفرد من الناتج المحلي الإجمالي (GDPH) كمؤشر رئيس لقياس النمو الاقتصادي. اعتمدت الدراسة على منهجية بوكس-جينكينز، التي تعد من أكثر الأساليب فعالية في مجال التنبؤ بالسلاسل الزمنية، وذلك من خلال المرور بجميع مراحل التحليل التي تتضمنها هذه المنهجية، بدءاً من تحديد استقرار السلسلة الزمنية، مروراً باختيار النموذج الأمثل، ووصولاً إلى مرحلة التنبؤ. تم استخدام برنامج EViews 12 لتحليل البيانات وتطبيق النماذج الإحصائية. أظهرت نتائج الدراسة أن النموذج الأمثل لتمثيل البيانات هو ARIMA (١,١,٠)، والذي أثبت فعاليته في التنبؤ على المدى القصير. كما تم التنبؤ بمعدل نمو نصيب الفرد من الناتج المحلي الإجمالي للسنوات الخمس القادمة (٢٠٢١-٢٠٢٥)، حيث أظهرت النتائج تناقصاً تدريجياً في معدل النمو خلال هذه الفترة. وقد تم التحقق من صحة النموذج من خلال اختبارات استقرار السلسلة، واختبارات الارتباط الذاتي، واختبارات التوزيع الطبيعي للبقايا، مما أكد ملاءمة النموذج للتنبؤ. خلصت الدراسة إلى أن منهجية بوكس-جينكينز تعد أداة فعالة للتنبؤ بالتغيرات الاقتصادية على المدى القصير.

• دراسة (MA, 2024) بعنوان: التحليل والتنبؤ بالناتج المحلي الإجمالي باستخدام نموذج ARIMA

Analysis and Forecasting of GDP Using the ARIMA Model:

هدفت هذه الدراسة إلى التحليل والتنبؤ بالناتج المحلي الإجمالي (GDP) للصين باستخدام نموذج (ARIMA (Autoregressive Integrated Moving Average) للفترة من ١٩٧٨ إلى ٢٠٢٢، وذلك بهدف تقديم رؤية علمية لدعم صناع القرار في اتخاذ السياسات الاقتصادية المناسبة. تم اختيار بيانات الناتج المحلي الإجمالي السنوية من المكتب الوطني للإحصاء في الصين، حيث أظهرت البيانات نمواً أسياً واضحاً مع خصائص عدم استقرارية. تم استخدام تحليل السلاسل الزمنية لتحديد النموذج الأمثل، حيث تم تطبيق تحويل لوغاريتمي على البيانات لمعالجة عدم الاستقرارية، ثم تم إجراء اختبارات استقرارية (ADF) لتأكيد استقرار السلسلة بعد التفاضل الثاني. بناءً على تحليل وظائف الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF)، تم تحديد نموذج ARIMA (٠، ٢، ٠) كأفضل نموذج للتنبؤ. أظهرت النتائج أن النموذج المختار يتمتع بدقة تنبؤ عالية، حيث كانت الأخطاء النسبية أقل من ١%، وتم التنبؤ بقيم الناتج المحلي الإجمالي للصين للفترة من ٢٠٢٣ إلى ٢٠٢٧، والتي أظهرت استمرار النمو الاقتصادي بمعدل مرتفع.

• دراسة (Yang et al., 2023) بعنوان: التنبؤ بالإنفاق الحكومي في دولة رائدة باستخدام شبكة

عصبية متكررة ذات وحدة متكررة مُسيرة

The Forecasting of a Leading Country's Government Expenditure Using a Recurrent Neural Network with a Gated Recurrent Unit:

هدفت هذه الدراسة إلى تطوير نموذج للتنبؤ بإنفاق الحكومة باستخدام شبكة عصبية متكررة مع وحدة متكررة ذات بوابات (GRU)، وذلك بهدف تحسين دقة التنبؤات الاقتصادية ودعم صناع القرار في تخصيص الموارد بشكل أكثر فعالية. تم استخدام بيانات من البنك الدولي تغطي الفترة من ١٩٩٠ إلى ٢٠٢٠ لإنفاق حكومات ١٥ دولة من أكبر الاقتصادات العالمية، بما في ذلك الولايات المتحدة والصين واليابان وألمانيا والمملكة المتحدة والهند وفرنسا وإيطاليا وكندا وكوريا الجنوبية وروسيا والبرازيل وأستراليا وإسبانيا والمكسيك. تمت مقارنة أداء نموذج GRU مع نماذج أخرى مثل ARIMA، ودعم الانحدار المتجه (SVR)، والتسوية الأسية (ETS)، وXGBoost، والشبكات العصبية التلافيفية (CNN)، وذاكرة المدى القصير الطويل (LSTM). أظهرت النتائج أن نموذج GRU تفوق على جميع النماذج الأخرى من حيث دقة التنبؤ، حيث حقق متوسط خطأ مطلق (MAE) قدره ٠,٥٢٨٤، وجذر متوسط الخطأ التربيعي (RMSE) قدره ٠,٧٤٦٩، ونسبة الخطأ المطلق المتوسط (MAPE) بنسبة ٢,٧٧٤%. تم التأكد من فعالية النموذج من خلال اختبارات الحساسية وتحليل الأداء باستخدام مقاييس مختلفة، مما أكد قدرته على التقاط العلاقات غير الخطية المعقدة في البيانات الزمنية.

✓ **التعقيب على الدراسات السابقة:**

تناولت الدراسات السابقة موضوع التنبؤ الاقتصادي باستخدام نماذج مختلفة، حيث ركزت دراسة Taiba and Ben Saha (٢٠٢٢) على تطبيق منهجية بوكس-جينكينز للتنبؤ بالنمو الاقتصادي في الجزائر، وأظهرت فعالية نموذج ARIMA في التنبؤ على المدى القصير، إلا أن الدراسة اقتصرت على البيانات الخطية ولم تتناول التعقيدات غير الخطية في السلاسل الزمنية. من جهة أخرى، دراسة Ma (٢٠٢٤) استخدمت نموذج ARIMA للتنبؤ بالناتج المحلي الإجمالي للصين، وأكدت على دقة النموذج في التعامل مع البيانات غير المستقرة، لكنها لم تتعمق في إمكانية تحسين الدقة من خلال دمج تقنيات الذكاء الاصطناعي. في حين أن دراسة Yang et al (٢٠٢٣) قدمت مقارنة أكثر تطوراً باستخدام الشبكات العصبية المتكررة مع

وحدات GRU، حيث أظهرت تفوقاً واضحاً في دقة التنبؤ مقارنة بالنماذج التقليدية، إلا أنها ركزت على إنفاق الحكومة ولم تتناول بشكل مباشر التنبؤ بالنمو الاقتصادي في سياقات اقتصادية معقدة مثل سورية. هذه الفجوات في الأدبيات السابقة تؤكد الحاجة إلى تطوير نموذج هجين يدمج بين نقاط قوة النماذج الإحصائية الكلاسيكية مثل ARIMA وتقنيات الذكاء الاصطناعي الحديثة مثل RNN، لتحسين دقة التنبؤ في البيئات الاقتصادية المعقدة وغير المستقرة، وهو ما يسعى البحث الحالي إلى تحقيقه.

✓ ميزة البحث الحالي عن الأدبيات السابقة:

يتميز البحث الحالي عن الأدبيات السابقة من خلال تقديمه لنموذج هجين مبتكر يجمع بين تقنيات النماذج الإحصائية الكلاسيكية، ممثلة بنموذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA)، وتقنيات الذكاء الاصطناعي الحديثة، ممثلة بالشبكات العصبية المتكررة (RNN). في حين ركزت الدراسات السابقة إما على النماذج الإحصائية التقليدية مثل ARIMA، والتي تعتمد على افتراضات خطية قد لا تكون كافية لالتقاط العلاقات غير الخطية في البيانات، أو على نماذج الشبكات العصبية التي تعالج التعقيدات غير الخطية ولكنها قد تقتصر على القدرة على نمذجة التبعيات الزمنية الخطية بشكل فعال، فإن البحث الحالي يقدم تكاملاً بين النهجين لتعويض نقاط الضعف في كل منهما. بالإضافة إلى ذلك، يتميز البحث بتطبيقه في سياق اقتصادي معقد ومتغير مثل الاقتصاد السوري، والذي يواجه تحديات فريدة بسبب الأزمات السياسية والاقتصادية المتلاحقة، مما يجعله بيئة مثالية لاختبار فعالية النموذج الهجين. هذا التكامل بين النماذج لا يقتصر فقط على تحسين دقة التنبؤات، بل يوفر أيضاً إطاراً نظرياً جديداً لفهم أفضل للعلاقات الخطية وغير الخطية في البيانات الاقتصادية، مما يساهم في إثراء الأدبيات العلمية المتعلقة بتحليل السلاسل الزمنية والتنبؤ الاقتصادي.

3- مشكلة البحث:

على الرغم من التطور الكبير في تقنيات تحليل السلاسل الزمنية والتنبؤ بها، لا تزال هناك تحديات كبيرة في تحقيق تنبؤات دقيقة للنمو الاقتصادي، خاصة في ظل تعقيد البيانات الاقتصادية وعدم استقرارها. تعتمد النماذج التقليدية مثل نماذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) على افتراضات خطية قد لا تكون كافية لالتقاط العلاقات غير الخطية والأنماط المعقدة في البيانات الاقتصادية، مما يحد من فعاليتها في التنبؤ على المدى الطويل. من ناحية أخرى، على الرغم من أن الشبكات العصبية الاصطناعية أثبتت قدرتها على التعامل مع البيانات غير الخطية، إلا أن تطبيقها الفردي قد لا يكون كافياً لتحقيق الدقة المطلوبة في ظل وجود تبعيات زمنية معقدة. هذا يطرح تساؤلاً حول كيفية تحسين دقة التنبؤات الاقتصادية من خلال الجمع بين نقاط قوة النماذج التقليدية والشبكات العصبية في نموذج هجين يمكنه الاستفادة من المزايا المشتركة لكلا النهجين. وبالتالي يمكن صياغة مشكلة البحث وفق التساؤل التالي:

كيف يمكن تحسين دقة التنبؤ بالنمو الاقتصادي في سورية من خلال تطوير نموذج هجين يجمع بين نماذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) والشبكات العصبية المتكررة (RNN)؟

4- أهداف البحث:

١- تطوير نموذج هجين يجمع بين تقنيات النماذج الإحصائية الكلاسيكية (نماذج الانحدار الذاتي للمتوسطات المتحركة ARIMA) وتقنيات الذكاء الاصطناعي الحديثة (الشبكات العصبية المتكررة RNN)، وذلك لتحسين دقة التنبؤات الاقتصادية في ظل تعقيد البيانات وعدم استقرارها.

- ٢- اختبار فعالية النموذج الهجين في سياق اقتصادي متقلب ومعقد مثل الاقتصاد السوري، وذلك من خلال مقارنة أداء النموذج الهجين مع النماذج التقليدية (ARIMA) ونماذج الشبكات العصبية المتكررة (RNN) بشكل منفصل.
- ٣- تقديم أداة تنبؤية دقيقة يمكن أن تساعد صناع القرار في سورية على اتخاذ قرارات اقتصادية مستنيرة، مما يعزز الاستقرار الاقتصادي ويدعم التخطيط الاستراتيجي في ظل الظروف الاقتصادية الصعبة التي تمر بها البلاد.

5- أهمية البحث:

الأهمية النظرية: تكمن أهمية هذا البحث من الناحية النظرية في إثراء الأدبيات العلمية المتعلقة بتحليل السلاسل الزمنية والتنبؤ الاقتصادي، حيث يسعى إلى تطوير نموذج هجين يدمج بين تقنيات النماذج الإحصائية الكلاسيكية متمثلة بالانحدار الذاتي للمتوسطات المتحركة (ARIMA) وتقنيات الذكاء الاصطناعي الحديثة متمثلة بالشبكات العصبية المتكررة (RNN). هذا التكامل يقدم إطاراً نظرياً جديداً لفهم أفضل للعلاقات الخطية وغير الخطية في البيانات الاقتصادية، مما يساهم في توسيع نطاق المعرفة حول كيفية تحسين دقة التنبؤات في ظل تعقيد البيانات وعدم استقرارها. بالإضافة إلى ذلك، يقدم البحث إضافة نوعية من خلال التحقق من فعالية النماذج الهجينة في سياقات اقتصادية متغيرة ومعقدة، مثل الاقتصاد السوري، مما يعزز الفهم النظري لتطبيقات هذه النماذج في البيانات ذات التحديات الفريدة.

الأهمية العملية: من الناحية التطبيقية، فإن هذا البحث يقدم أداة عملية لدعم صناع القرار في سورية من خلال توفير تنبؤات دقيقة للنمو الاقتصادي، مما يمكنهم من اتخاذ قرارات مستنيرة تعزز الاستقرار الاقتصادي وتدعم التخطيط الاستراتيجي. في ظل الظروف الاقتصادية الصعبة التي تمر بها سورية، يعد تطوير نموذج تنبؤ دقيق أمراً بالغ الأهمية لتوجيه السياسات الاقتصادية وتخصيص الموارد بشكل فعال. كما أن النموذج الهجين المقترح يمكن أن يكون قابلاً للتطبيق في سياقات اقتصادية أخرى تعاني من تحديات مماثلة، مما يعزز قيمته التطبيقية على نطاق أوسع.

6- متغيرات البحث:

يتضمن هذا البحث متغيرات رئيسة تتمثل في النمو الاقتصادي كمتغير تابع، حيث يتم قياسه من خلال معدل نمو الناتج المحلي الإجمالي (GDP) كنسبة مئوية سنوية. أما المتغيرات المستقلة فتشمل البيانات التاريخية للنمو الاقتصادي التي تمثل السلاسل الزمنية للفترة المحددة، بالإضافة إلى المعلمات الإحصائية المستخرجة من نماذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) والشبكات العصبية المتكررة (RNN). كما يتم استخدام البواقي (Residuals) الناتجة عن نموذج ARIMA كمدخلات إضافية للنموذج الهجين (ARIMA + RNN) لتحسين دقة التنبؤ. تم اختيار الفترة الزمنية من ١٩٦١ إلى ٢٠٢٢ كفترة زمنية للدراسة، حيث تغطي هذه المدة تحولات اقتصادية وسياسية كبيرة في سورية، بما في ذلك فترات النمو والركود الاقتصادي، مما يوفر مجموعة بيانات غنية ومتنوعة تسمح بتحليل دقيق للأنماط الزمنية. أما المكان فيقتصر على سورية، وذلك بسبب التحديات الاقتصادية الفريدة التي تواجهها البلاد، بما في ذلك الأزمات السياسية والاقتصادية التي أثرت بشكل كبير على النمو الاقتصادي، مما يجعلها حالة دراسة مثالية لتطبيق النماذج الهجينة في ظل ظروف معقدة.

7- فرضيات البحث:

الفرضية الأولى: يوجد فرق ذو دلالة إحصائية بين دقة تنبؤات نموذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) ودقة تنبؤات النموذج الهجين (ARIMA + RNN) في التنبؤ بالنمو الاقتصادي في سورية.

الفرضية الثانية: يتفوق النموذج الهجين (ARIMA + RNN) بشكل ذي دلالة إحصائية على نموذج الشبكات العصبية المتكررة (RNN) من حيث دقة التنبؤ بالنمو الاقتصادي في سورية.

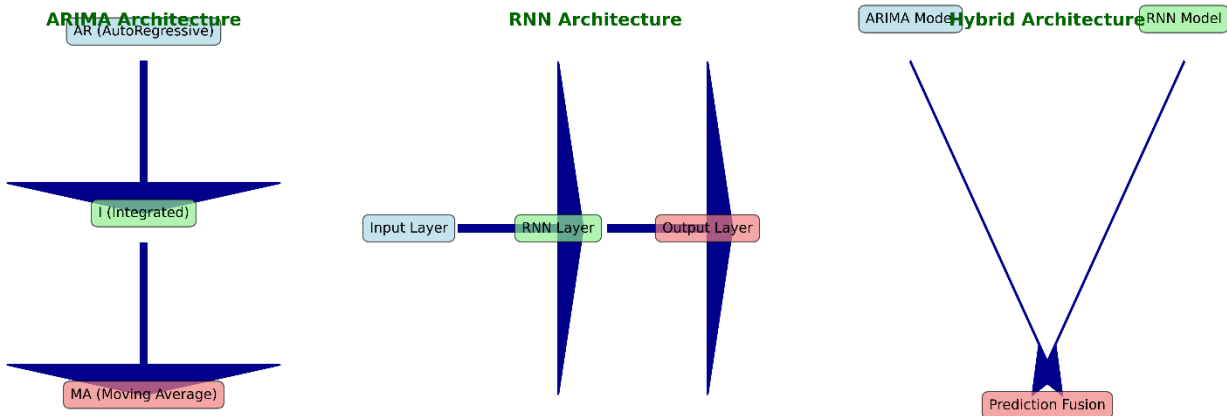
8- طرائق البحث وأدواته:

لتحقيق أهداف البحث، تم اعتماد منهجية علمية متكاملة تعتمد على تحليل السلاسل الزمنية باستخدام نماذج تنبؤية متقدمة، حيث تم تقسيم العمل إلى عدة خطوات منهجية تبدأ بجمع البيانات التاريخية للنمو الاقتصادي في سورية من المكتب المركزي للإحصاء (CBS, 2022)، تليها مرحلة توصيفها لضمان جودتها وملاءمتها للتحليل. بعد ذلك، تم تطبيق نموذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) باستخدام دالة "Auto ARIMA" في بيئة برمجية متخصصة R Studio، والتي تقوم تلقائياً باختيار المعلمات المثلى للنموذج (p, d, q) بناءً على معيار المعلومات أكايكي (AIC). كما تم استخدام مكتبة statsmodels في لغة Python لتقدير معلمات النموذج. في المرحلة التالية، تم تطوير نموذج الشبكات العصبية المتكررة (RNN) باستخدام مكتبة Keras و TensorFlow، حيث تم تصميم هيكل الشبكة ليتكون من طبقة SimpleRNN تليها طبقة Dense، مع استخدام دالة التنشيط DeepRNN لتحسين أداء النموذج. أخيراً، تم دمج النتائج من نموذجي ARIMA و RNN في نموذج هجين (NNAR) لتحسين دقة التنبؤ، حيث تم إدخال بقايا ARIMA كمدخلات إضافية لنموذج RNN.

تم تقييم أداء النماذج باستخدام مقاييس أدائية تتمثل بجذر متوسط الخطأ التربيعي (RMSE) ومتوسط الخطأ المطلق (MAE) ومتوسط نسبة الخطأ المطلق (MAPE)، وذلك باستخدام مكتبات تحليل البيانات pandas و numpy في بيئة Anaconda Python. هذه المنهجية المتكاملة توفر إطاراً قوياً لتحليل البيانات الاقتصادية المعقدة وتحسين دقة التنبؤات في سياقات اقتصادية متغيرة. والشكل التالي يوضح معمارية وخطوات نماذج الدراسة:

شكل (١): معمارية النماذج المستخدمة في البحث

Architectures of ARIMA, RNN, and Hybrid NNAR Models



المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

1-8 نموذج الانحدار الذاتي للمتوسطات المتحركة ARIMA:

نموذج ARIMA، الذي يرمز إلى "المتوسط المتحرك التكاملية الذاتي الانحدار" (AutoRegressive Integrated Moving Average)، هو منهج إحصائي واسع الاستخدام للتنبؤ بالسلاسل الزمنية. في هذه الدراسة، تم تطبيق نموذج ARIMA باستخدام دالة "Auto ARIMA"، التي تقوم تلقائياً باختيار المعلمات المثلى (p, d, q) للنموذج. يتم تعريف نموذج ARIMA بالمعادلة التالية (Ma, 2024) Taiba and Ben (Saha, 2022):

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d y_t = c + (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \epsilon_t \quad (1)$$

حيث y_t تمثل القيمة الحالية للسلسلة في الزمن t . B هو عامل الإزاحة الخلفية (Backshift Operator) المعروف بالعلاقة $B y_t = y_{t-1}$ ، $\phi_1, \phi_2, \dots, \phi_p$ هي معاملات الانحدار الذاتي (AR). $\theta_1, \theta_2, \dots, \theta_q$ هي معاملات المتوسط المتحرك (MA). d هي درجة التفاضل (Differencing). c هو ثابت. ϵ_t هو مصطلح الخطأ في الزمن t . تقوم وظيفة "Auto ARIMA" بتحديد أفضل مجموعة من المعلمات p, q, d عن طريق تقليل معيار المعلومات الأكايكي (AIC - Akaike Information Criterion).

2-8 نموذج الشبكات العصبية المتكررة RNN:

نموذج الشبكة العصبية المتكررة (RNN) هو نوع من الشبكات العصبية الاصطناعية المصممة للتعامل مع البيانات المتسلسلة، مما يجعله مناسباً لمهام التنبؤ بالسلاسل الزمنية. يتكون هيكل RNN المستخدم في هذه الدراسة من طبقة SimpleRNN تليها طبقة Dense. يمكن وصف الصيغة الرياضية لـ RNN بالنسبة لتسلسل الإدخال x_t في الخطوة الزمنية t ، يتم حساب الحالة المخفية h_t كما يلي (Bharadiya, 2023) (Yang et al., 2023):

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b_h) \quad (2)$$

حيث W_h هو مصفوفة الأوزان للحالة المخفية. W_x هو مصفوفة الأوزان للإدخال. b_h هو مصطلح الانحياز (Bias). σ هي دالة التنشيط تكون دالة غير خطية والمستخدم في هذه الدراسة هي DeepRNN. ثم يتم حساب الناتج y_t في الخطوة الزمنية t على النحو التالي:

$$y_t = W_y h_t + b_y \quad (3)$$

حيث W_y هو مصفوفة الأوزان للناتج. b_y هو مصطلح الانحياز للناتج. يتميز هذا النموذج بقدرته على التعلم من الخصائص الزمنية في البيانات، مما يجعله فعالاً في مهام التنبؤ بالسلاسل الزمنية.

3-8 نموذج الانحدار الذاتي المدعوم بالشبكات العصبية الهجين AR + RNN (NNAR):

نموذج الهجين AR-RNN (NNAR) يجمع بين نقاط قوة نموذج ARIMA، الذي يلتقط التبعيات الخطية في البيانات، ونموذج RNN، الذي يتفوق في نمذجة الأنماط غير الخطية، لتحسين دقة التنبؤ. يقوم النموذج الهجين بدمج التنبؤات من كلا النموذجين، مستفيداً من مكون ARIMA لنمذجة الهيكل الخطي

للسلاسل الزمنية ومكون RNN للتعلم من العلاقات المعقدة وغير الخطية. رياضياً، يمكن التعبير عن النموذج الهجين على النحو التالي:

$$y_t^{\text{Hybrid}} = y_t^{\text{ARIMA}} + y_t^{\text{RNN}} \quad (4)$$

حيث y_t^{ARIMA} هو التنبؤ من نموذج ARIMA في الزمن t . y_t^{RNN} هو التنبؤ من نموذج RNN في نفس الخطوة الزمنية. يتم تعريف مكون ARIMA بالمعادلة التالية:

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d y_t^{\text{ARIMA}} = c + (1 + \theta_1 B + \dots + \theta_q B^q) \epsilon_t \quad (5)$$

بينما يتبع مكون RNN الصيغة القياسية للشبكة العصبية المتكررة:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b_h), y_t^{\text{RNN}} = W_y h_t + b_y \quad (6)$$

في هذه الدراسة، تم تطبيق النموذج الهجين ك نموذج الانحدار الذاتي للشبكة العصبية (NNAR)، حيث تم إدخال بواقي ARIMA (الفرق بين القيم الفعلية وتنبؤات ARIMA) في نموذج RNN لتحسين التنبؤات. يعمل هذا النهج على تعزيز دقة النموذج من خلال الاستفادة من قدرة ARIMA على توضيح الأنماط الخطية وقدرة RNN على التعامل مع التعقيدات غير الخطية في البيانات.

4-8 مؤشرات الأداء للنماذج:

في هذه الدراسة، يتم تقييم نماذج التنبؤ باستخدام مجموعة من المقاييس الأدائية، بما في ذلك متوسط الخطأ (ME)، وجذر متوسط الخطأ التربيعي (RMSE)، ومتوسط الخطأ المطلق (MAE)، ومتوسط نسبة الخطأ (MPE)، ومتوسط نسبة الخطأ المطلق (MAPE)، ومتوسط الخطأ المعياري (MASE). توفر هذه المقاييس مجتمعة إطاراً قوياً لتقييم دقة وموثوقية النماذج في التنبؤ بإنتاج القمح. يتم حساب متوسط الخطأ (ME) على أنه متوسط الفرق بين القيم المتوقعة \hat{y}_i والقيم الفعلية y_i ويعبر عنه بالعلاقة التالية (Ahmadi et al., 2019):

$$ME = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (7)$$

حيث n هو العدد الكلي للملاحظات. يشير هذا المقياس إلى ما إذا كان النموذج يميل إلى المبالغة في التقدير أو التقليل من القيم الفعلية. أما جذر متوسط الخطأ التربيعي (RMSE)، فيُعرّف على النحو التالي:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

ويقاس الجذر التربيعي لمتوسط الأخطاء التربيعية، مع التركيز على الانحرافات الكبيرة، مما يوفر مؤشراً قوياً على دقة النموذج بشكل عام. يتم حساب متوسط الخطأ المطلق (MAE) بالعلاقة التالية:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

ويقاس متوسط حجم الأخطاء دون النظر إلى اتجاهها، مما يجعله أقل حساسية للقيم الشاذة مقارنة بـ RMSE. لتقييم الأخطاء النسبية، يتم استخدام متوسط نسبة الخطأ (MPE) ومتوسط نسبة الخطأ المطلق (MAPE). يتم التعبير عن متوسط نسبة الخطأ (MPE) بالعلاقة التالية:

$$MPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) \times 100 \quad (10)$$

ويشير إلى اتجاه الأخطاء (المبالغة في التقدير أو التقليل)، بينما يُعرّف متوسط نسبة الخطأ المطلق (MAPE) على النحو التالي:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (11)$$

ويُقاس متوسط حجم الأخطاء النسبية، مما يسهل المقارنة بين مجموعات البيانات ذات المقاييس المختلفة. أخيراً، يتم حساب متوسط الخطأ المطلق المعياري (MASE) بالعلاقة التالية:

$$MASE = \frac{\sum_{i=2}^{n+1} |y_i - y_{i-1}|}{\sum_{i=2}^{n+1} |e_{naive,i}|} \quad (12)$$

ويوفر تقييماً مستقلاً عن المقياس من خلال مقارنة أخطاء التنبؤ بأخطاء نموذج بسيط مثل Random walk مجتمعة والمشار إليها بـ $\sum_{i=2}^{n+1} |e_{naive,i}|$ ، توفر هذه المقاييس تقييماً شاملاً لأداء النموذج، مما يمكن من الحصول على رؤى دقيقة حول دقة وموثوقية التنبؤات.

9- النتائج والمناقشة:

في هذا القسم، يتم مناقشة هذه النتائج بشكل تفصيلي، مع تحليل أسباب تفوق النموذج الهجين وتفسير الفروقات في أداء النماذج بالإضافة إلى استخلاص الدلالات العملية التي تسهم في دعم صناع القرار في رسم السياسات الاقتصادية.

جدول (1): مؤشرات التحليل الوصفي للنمو الاقتصادي في سورية خلال الفترة (١٩٦١ - ٢٠٢٢)

المؤشر	النمو الاقتصادي
المتوسط	3.589766
أعلى قيمة	25.79577
أدنى قيمة	-26.33902
الانحراف المعياري	9.952641
الالتواء	-0.478861
التقلطح	4.567348
Jarque-Bera	8.715675
الاحتمالية - Probability	0.012806
المشاهدات	62

المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio - Anaconda Python وبيانات المكتب المركزي للإحصاء. يظهر الجدول التحليل الوصفي للنمو الاقتصادي في سورية خلال الفترة من ١٩٦١ إلى ٢٠٢٢، حيث بلغ متوسط معدل النمو الاقتصادي ٣,٥٩%، مما يشير إلى وجود نمو إيجابي بشكل عام على المدى الطويل، رغم التقلبات الكبيرة التي شهدتها الفترة. تم تسجيل أعلى قيمة للنمو الاقتصادي عند ٢٥,٨٠%، مما يعكس فترات من النمو الاقتصادي القوي، مرتبطة بفترات انتعاش واستثمارات كبيرة نتيجة التحسن من صدمة سلبية. من ناحية أخرى، تم تسجيل أدنى قيمة للنمو عند -٢٦,٣٤%، مرتبطة بالأزمات السياسية والاقتصادية التي مرت بها سورية (الحروب والصراعات الداخلية). الانحراف المعياري البالغ ٩,٩٥ يشير إلى درجة عالية من

التقلب في معدلات النمو الاقتصادي، مما يعكس عدم استقرار الاقتصاد السوري واعتماده على عوامل خارجية وداخلية متغيرة. قيمة الالتواء السالبة (-٠,٤٨) تشير إلى أن التوزيع يميل إلى الذيل الأيسر، أي أن الفترات السلبية (الركود) كانت أكثر حدة من الفترات الإيجابية (النمو). أما التقلطح المرتفع (٤,٥٧) فيشير إلى وجود قيم متطرفة (Outliers) في البيانات، مما يؤكد وجود فترات نمو أو ركود غير عادية، وهو ما يتوافق مع طبيعة الاقتصاد السوري الذي شهد صدمات اقتصادية وسياسية كبيرة. اختبار Jarque-Bera الذي بلغت قيمته ٨,٧٢ مع احتمال (p-value) أقل من ٠,٠٥، يؤكد أن توزيع البيانات لا يتبع التوزيع الطبيعي، مما يعزز فرضية وجود تقلبات غير منتظمة في النمو الاقتصادي. هذه النتائج تشير إلى أن الاقتصاد السوري يعاني من عدم استقرار هيكلي، مع وجود فترات نمو قوية تليها فترات ركود حادة، مما يتطلب نماذج تنبؤية قادرة على التعامل مع هذه التقلبات الكبيرة والغير خطية في البيانات والشكل البياني التالي يوضح هذه التقلبات:

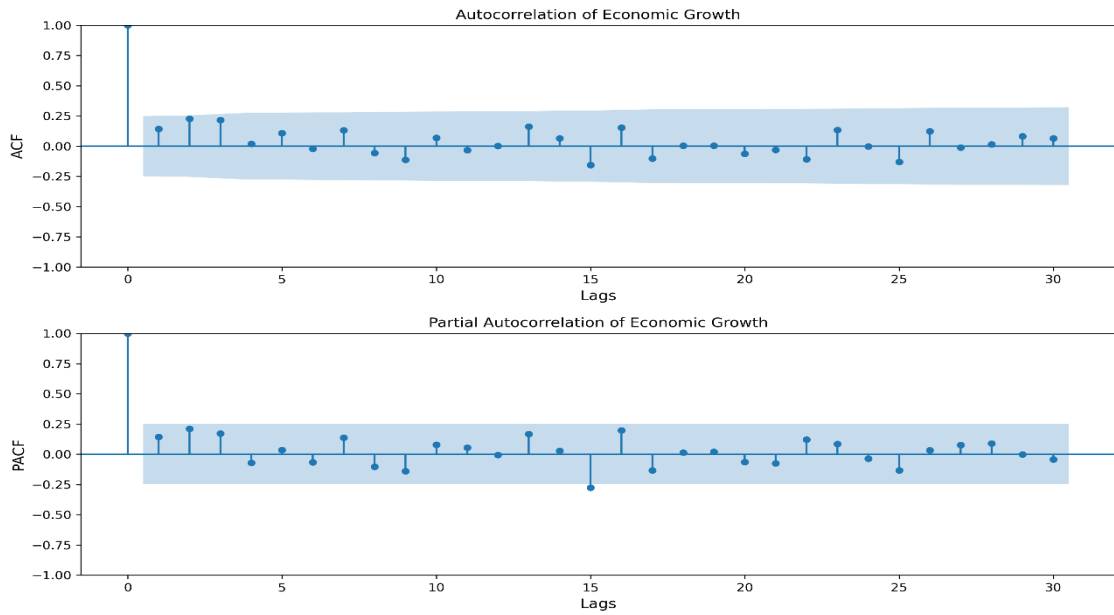
شكل (٢): تطور النمو الاقتصادي في سورية خلال الفترة ١٩٦١-٢٠٢٢



المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python وبيانات المكتب المركزي للإحصاء

ولفهم خصائص السلسلة نقوم بتقدير دالة الارتباط الذاتي الجزئي والكلية وفق الشكل التالي:

شكل (٣): دالة الارتباط الذاتي الكلية والجزئي للنمو الاقتصادي



المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

يوضح الشكل البياني دالة الارتباط الذاتي الكلي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) للنمو الاقتصادي في سورية، والتي تُستخدم لتحديد طبيعة التبعيات الزمنية في السلاسل الزمنية. في دالة الارتباط الذاتي الكلي (ACF)، نلاحظ أن قيم الارتباط تتناقص ببطء مع زيادة الفجوات الزمنية (Lags)، مما يشير إلى وجود ارتباط ذاتي قوي بين القيم المتتالية في السلسلة الزمنية. يعكس هذا النمط من التناقص البطيء وجود تأثيرات طويلة المدى في البيانات، وهو ما يتوافق مع طبيعة الاقتصاد السوري الذي يتأثر بعوامل هيكلية وسياسية تمتد تأثيراتها لفترات زمنية طويلة. من ناحية أخرى، تُظهر دالة الارتباط الذاتي الجزئي (PACF) قيماً مرتفعة في الفجوات الزمنية الأولى (1 و 2 Lags)، ثم تتخفف بشكل حاد بعد ذلك، مما يشير إلى أن الارتباط الذاتي في البيانات يمكن تفسيره بشكل رئيس من خلال الفجوات الزمنية القريبة. هذا النمط يُشير إلى أن النمو الاقتصادي في سورية يتأثر بشكل كبير بالقيم السابقة القريبة، مما يدعم استخدام نماذج الانحدار الذاتي (AR) في التحليل. من الناحية الإحصائية، يشير هذا السلوك إلى أن السلسلة الزمنية للنمو الاقتصادي غير مستقرة (Non-stationary)، وهو ما يتطلب تطبيق تقاضل (Differencing) لتحقيق الاستقرار في السلسلة قبل تطبيق نموذج ARIMA. من الناحية الاقتصادية، يعكس هذا النمط من الارتباط الذاتي الطبيعة المتقلبة للاقتصاد السوري، حيث أن الأحداث السياسية والاقتصادية الكبرى، مثل الحروب والصراعات، لها تأثيرات مستمرة وممتدة على النمو الاقتصادي، مما يجعل من الصعب تحقيق استقرار اقتصادي على المدى القصير. هذه النتائج تؤكد أهمية استخدام نماذج هجينة قادرة على التعامل مع التبعيات الزمنية المعقدة وغير الخطية في البيانات الاقتصادية السورية. وفق الخصائص السابقة نقدر نموذج ARIMA ونحصل على النتائج التالية:

جدول (٢): معالم نموذج Auto ARIMA(0,1,1)

المعلمة	القيمة/الوصف
نوع النموذج	ARIMA
رتب النموذج	(0,1,1)
المعاملات	MA1: -0.8771 (± 0.0794)

96.53	(sigma ²) تباين الخطأ
-226.16	Log Likelihood
456.33	AIC

المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

يوضح الجدول معالم نموذج Auto ARIMA (٠,١,١) الذي تم تطبيقه لتحليل السلاسل الزمنية للنمو الاقتصادي في سورية. وتم تحديد رتبته على أنه (٠,١,١)، حيث يشير الرقم الأول (٠) إلى عدم وجود مكون الانحدار الذاتي (AR)، والرقم الثاني (١) يشير إلى أن السلسلة الزمنية تم تقاضلها مرة واحدة لتحقيق الاستقرار، والرقم الثالث (١) يشير إلى وجود مكون متوسط متحرك (MA) من الرتبة الأولى. بلغت قيمة معامل المتوسط المتحرك (MA1) -٨٧٧١.٠٠ مع انحراف معياري قدره $\pm ٠,٧٩٤$ ، مما يشير إلى أن القيمة الحالية للنمو الاقتصادي تتأثر بشكل سلبي بالأخطاء (البواقى) في الفترة السابقة. تعكس هذه القيمة السالبة وجود تأثير عكسي في البيانات، حيث أن الأخطاء السابقة تؤدي إلى انخفاض في القيمة الحالية، وهو ما قد يكون مرتبطاً بطبيعة التقلبات الكبيرة في الاقتصاد السوري. تباين الخطأ (sigma²) بلغ ٩٦,٥٣، وهو مؤشر على درجة التشتت في الأخطاء التنبؤية للنموذج. تعكس هذه القيمة المرتفعة نسبياً وجود تقلبات كبيرة في البيانات، مما يتوافق مع طبيعة الاقتصاد السوري الذي شهد فترات نمو وركود حادة. يشير تحليل معالم النموذج إلى أن نموذج ARIMA (٠,١,١) قادر على التقاط بعض الأنماط في البيانات، ولكن التقلبات الكبيرة وعدم الاستقرار في السلسلة الزمنية للنمو الاقتصادي السوري تتطلب نماذج أكثر تعقيداً، مثل الشبكات العصبية التي لا تفترض أي افتراضات أولية حول البيانات:

جدول (٣): معالم النموذج التسلسلي (RNN)

المعلمة	القيمة/الوصف
نوع النموذج	Sequential Model (RNN)
هيكل النموذج	SimpleRNN + Dense
عدد الطبقات	2
الطبقة الأولى	SimpleRNN (50 عقدة)
الطبقة الثانية	Dense (عقدة إخراج 1)
عدد المعلمات الكلي	7,955
المعلمات القابلة للتدريب	2,651
المعلمات غير القابلة للتدريب	0
معلمات المحسن	5,304
الشكل الناتج	(None, 1)

المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

يوضح الجدول معالم النموذج التسلسلي للشبكة العصبية المتكررة (RNN) الذي تم تطويره لتحليل السلاسل الزمنية للنمو الاقتصادي في سورية. النموذج من نوع Sequential Model (RNN)، حيث يتميز بقدرته على التقاط التبعيات الزمنية والأنماط غير الخطية في البيانات. يتكون هيكل النموذج من طبقتين رئيسيتين: الأولى هي طبقة SimpleRNN تحتوي على ٥٠ عقدة (خلايا عصبية)، وهي مسؤولة عن معالجة

التبعيات الزمنية في البيانات، بينما الطبقة الثانية هي طبقة Dense تحتوي على عقدة إخراج واحدة، وهي مسؤولة عن إنتاج القيمة التنبؤية النهائية.

يسمح هذا الهيكل للنموذج بالتعلم من الأنماط الزمنية في البيانات دون زيادة التعقيد المفرط. يبلغ إجمالي عدد المعلمات في النموذج ٧,٩٥٥، منها ٢,٦٥١ معلمة قابلة للتدريب، بينما لا توجد معلمات غير قابلة للتدريب. تشمل المعلمات القابلة للتدريب أوزان الروابط بين العقد في الشبكة العصبية، والتي يتم تحسينها خلال عملية التدريب عدد معلمات المحسن (Optimizer) بلغ ٥,٣٠٤، وهي تشمل المتغيرات الإضافية التي يستخدمها المحسن لتحديث المعلمات بشكل فعال. الشكل الناتج للنموذج هو (None, 1)، مما يشير إلى أن النموذج يُنتج قيمة تنبؤية واحدة لكل خطوة زمنية، وهو ما يتوافق مع طبيعة مهمة التنبؤ بالنمو الاقتصادي التي تتطلب إخراج قيمة واحدة (معدل النمو) لكل فترة زمنية. من الناحية الإحصائية، يشير هذا الهيكل إلى أن النموذج قادر على التعامل مع التعقيدات غير الخطية في البيانات، ولتحسين دقة التنبؤات في ظل التحديات الفريدة للبيانات الاقتصادية السورية تم تطوير نموذج هجين يجمع بين قدرات الانحدار الذاتي والشبكات العصبية وفق التالي:

جدول (٤): معالم النموذج الهجين $RNN + AR = NNAR(2,2)$

المعلمة	القيمة/الوصف
نوع النموذج	(هجين - شبكة عصبية + الانحدار الذاتي) NNAR
هيكل النموذج	شبكة مع ٩ أوزان 2-2-1
عدد الشبكات	متوسط ٢٠ شبكة
وحدات الإخراج	غير خطية
عدد الأوزان	أوزان 9
فترات التوقعات	فترات زمنية 8
نوع الشبكة العصبية	(شبكة عصبية تكرارية) RNN
دالة RNN	Deep RNN
عدد العقد المخفية	عقد مخفية 2
عدد عقد الإخراج	عقدة إخراج 1
التعلم	تعلم تسلسلي (يعتمد على البيانات التاريخية)

المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

يوضح الجدول معالم النموذج الهجين NNAR(2,2) الذي يجمع بين تقنيات الشبكات العصبية المتكررة (RNN) ونموذج الانحدار الذاتي (AR) لتحليل السلاسل الزمنية للنمو الاقتصادي في سورية. النموذج من نوع NNAR، وهو نموذج هجين مصمم لدمج نقاط قوة النماذج الإحصائية الكلاسيكية (AR) مع تقنيات الذكاء الاصطناعي الحديثة (RNN)، مما يسمح بتحسين دقة التنبؤات من خلال التقاط كل من الأنماط الخطية وغير الخطية في البيانات. يتكون هيكل النموذج من 2-2-1، حيث يشير الرقم الأول (2) إلى عدد

العقد المخفية في طبقة الشبكة العصبية المتكررة (RNN)، والرقم الثاني (٢) يشير إلى عدد الفجوات الزمنية (Lags) المستخدمة في مكون الانحدار الذاتي (AR)، بينما الرقم الأخير (١) يشير إلى وجود عقدة إخراج واحدة، مما يتوافق مع طبيعة مهمة التنبؤ التي تتطلب إخراج قيمة واحدة (معدل النمو) لكل فترة زمنية. يحتوي النموذج على ٩ أوزان، وهي تمثل الروابط بين العقد في الشبكة العصبية، مما يجعل النموذج مناسباً من حيث التعقيد الحسابي. تم تطوير ٢٠ شبكة في المتوسط، حيث يتم تدريب كل شبكة بشكل مستقل لضمان استقرار النموذج وتقليل تأثير التباين في البيانات. وحدات الإخراج في النموذج هي غير خطية، مما يسمح للنموذج بالنقاط العلاقات المعقدة بين المتغيرات، وهو أمر بالغ الأهمية في تحليل البيانات الاقتصادية التي تتسم بعدم الخطية والتقلبات الكبيرة. تم تحديد ٨ فترات زمنية كفترات تنبؤية، مما يعني أن النموذج يستخدم البيانات التاريخية للتنبؤ بالقيم المستقبلية على مدى ٨ فترات قادمة. يعكس هذا النهج قدرة النموذج على التعامل مع التبعيات الزمنية متوسطة المدى في البيانات. النموذج يستخدم شبكة عصبية متكررة (RNN) من نوع Deep RNN، مع عقدتين مخفيتين وعقدة إخراج واحدة. يسمح هذا الهيكل للنموذج بالتعلم من التبعيات الزمنية في البيانات دون زيادة التعقيد المفرط Overfitting، مما يجعله مناسباً للبيانات حيث تتسم بتقلبات كبيرة، عملية التعلم في النموذج هي تعلم تسلسلي، حيث يعتمد النموذج على البيانات التاريخية للتنبؤ بالقيم المستقبلية، مما يعكس قدرته على التعامل مع السلاسل الزمنية الديناميكية والشكل البياني يبين عملية التدريب التي تمت على النموذج:

شكل (٤): دالة التكلفة لتدريب النموذج الهجين وتحسين الأداء



المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

يوضح الشكل البياني أداء تدريب النموذج الهجين AR-RNN من خلال تتبع فقدان التدريب (Training Loss) وفقدان التحقق (Validation Loss) عبر ٥٠ دورة (Epochs). يُظهر الشكل أن كلاً من فقدان التدريب وفقدان التحقق يتناقصان بشكل ملحوظ مع تقدم الدورات، مما يشير إلى أن النموذج يتعلم بشكل فعال من البيانات التدريبية ويحسن من قدرته التنبؤية. في البداية، نلاحظ أن فقدان التدريب وفقدان التحقق يبدآن بقيم مرتفعة نسبياً، حيث بلغت قيمة الفقدان حوالي ٠,٤ في الدورة الأولى. هذا الارتفاع الأولي يعكس عدم دقة النموذج في البداية بسبب عدم تكيفه الكافي مع البيانات. مع تقدم الدورات، نلاحظ انخفاضاً

سريعاً في كلا المؤشرين، حيث يصل فقدان التدريب إلى ٠,٠٢، وفقدان التحقق إلى ٠,٠٠٩٦، بحلول الدورة ٥٠. هذا الانخفاض يشير إلى أن النموذج تحسن بشكل كبير في التقاط الأنماط في البيانات وفق عملية التدريب، سواء كانت خطية أو غير خطية. يشير تقارب منحنيات فقدان التدريب وفقدان التحقق إلى أن النموذج لا يعاني من الإفراط في التخصيص (Overfitting)، حيث أن الفرق بين طريقتي التحقق يبقى محدوداً طوال عملية التدريب. يعكس هذا التوازن بين فقدان التدريب وفقدان التحقق قدرة النموذج على التعميم بشكل جيد على البيانات الجديدة، مما يجعله مناسباً للتنبؤ بالسلاسل الزمنية في ظل التقلبات الكبيرة التي تميز البيانات الاقتصادية السورية. والجدول التالي يورد مقارنة مؤشرات الأداء للنماذج المقترحة:

جدول (٥): مؤشرات الأداء وموثوقية التنبؤ للنماذج

المؤشر	ARIMA(0,1,1)	RNN	HYBRID AR+RNN NNAR(2,2)
ME	-1.378558	1.8077	0.002482576
RMSE	9.665057	3.1517	2.885797
MAE	6.543502	2.1597	1.506943
MPE	12.16044	23.6093	0.05194
MAPE	155.7801	256.2212	1.3608
MASE	0.7227556	1.1076	0.6082636

المصدر: إعداد الباحثة بالاعتماد على بيئة Anaconda Python – R Studio

يظهر النموذج الهجين من خلال الجدول NNAR(2,2) أداءً متفوقاً من حيث متوسط الخطأ (ME)، حيث بلغ ٠,٠٠٢٥، مما يشير إلى أنه لا يميل إلى المبالغة في التقدير أو التقليل من القيم الفعلية، مقارنة بـ ١,٣٧٨ لنموذج ARIMA و ١,٨٠٧٧ لنموذج RNN. بالإضافة إلى ذلك، سجل النموذج الهجين أقل قيمة لجذر متوسط الخطأ التربيعي (RMSE) عند ٢,٨٨٦، مقارنة بـ ٩,٦٦٥ لنموذج ARIMA و ٣,١٥٢ لنموذج RNN، مما يعكس دقة أعلى في التنبؤ وتقليل الانحرافات الكبيرة بين القيم المتوقعة والفعلية. من ناحية متوسط الخطأ المطلق (MAE)، حقق النموذج الهجين قيمة ١,٥٠٧، وهي أقل بكثير من ٦,٥٤٤ لنموذج ARIMA و ٢,١٦٠ لنموذج RNN، مما يؤكد قدرته على تقليل حجم الأخطاء بشكل عام. كما سجل النموذج الهجين متوسط نسبة الخطأ (MPE) عند ٠,٠٥٢٪، وهي قيمة قريبة جداً من الصفر، مقارنة بـ ١٢,١٦٪ لنموذج ARIMA و ٢٣,٦١٪ لنموذج RNN، مما يعكس توازناً في التقديرات النسبية. أما متوسط نسبة الخطأ المطلق (MAPE)، فقد حقق النموذج الهجين قيمة منخفضة جداً عند ١,٣٦١٪، مقارنة بـ ١٥٥,٧٨٪ لنموذج ARIMA و ٢٥٦,٢٢٪ لنموذج RNN، مما يؤكد دقته العالية في التنبؤات النسبية. أخيراً، سجل النموذج الهجين متوسط الخطأ المطلق المعياري (MASE) عند ٠,٦٠٨، وهي قيمة أقل من ١، مما يشير إلى تفوقه على نموذج بسيط مثل Random Walk، مقارنة بـ ٠,٧٢٣ لنموذج ARIMA و ١,١٠٨ لنموذج RNN. من الناحية الإحصائية، تشير هذه النتائج إلى أن النموذج الهجين NNAR(2,2) نجح في تجنب مشكلتي الإفراط في التخصيص (Overfitting) والتقليل من التخصيص (Underfitting)، حيث أن الفروق بين مقاييس الأداء كانت متوازنة ومنخفضة، مما يعكس قدرته على التعميم بشكل جيد على البيانات الجديدة دون فقدان الدقة أو زيادة التعقيد المفرط. هذا يُظهر أن النموذج الهجين تفوق بشكل واضح في دقة التنبؤات

وقدرته على التعامل مع التقلبات الكبيرة في البيانات مما يجعله أداة فعالة لدعم صناع القرار في رسم السياسات الاقتصادية.

وفق السابق نعلم النموذج الهجين في إخراج التنبؤات بالنمو الاقتصادي في سورية ونحصل على النتائج

التالية:

جدول (٧): نتائج التنبؤ مع فترات عدم اليقين للنمو الاقتصادي في سورية خلال الفترة ٢٠٢٣-٢٠٣٠ باستخدام أفضل نموذج

NNAR(2-2)

السنة	(Point Forecast) التوقع	(80%) فترة الثقة	(95%) فترة الثقة
2023	1.294844	[0.9, 1.7]	[0.7, 1.9]
2024	1.053351	[0.6, 1.5]	[0.4, 1.7]
2025	2.243849	[1.7, 2.8]	[1.5, 3.0]
2026	3.246525	[2.7, 3.8]	[2.5, 4.0]
2027	1.247381	[0.8, 1.7]	[0.6, 1.9]
2028	0.247461	[-0.2, 0.7]	[-0.4, 0.9]
2029	-1.24748	[-1.7, -0.8]	[-1.9, -0.6]
2030	3.247483	[2.7, 3.8]	[2.5, 4.0]

المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python


يوضح الجدول نتائج التنبؤ بالنمو الاقتصادي في سورية للفترة من ٢٠٢٣ إلى ٢٠٣٠ باستخدام النموذج الهجين مع تقدير فترات عدم اليقين عند مستويات الثقة ٨٠% و ٩٥%. تشير النتائج إلى أن النمو الاقتصادي المتوقع يتراوح بين -١,٢٤٧% و ٣,٢٤٧% خلال هذه الفترة، مع وجود تقلبات ملحوظة تعكس التحديات الهيكلية التي يواجهها الاقتصاد السوري. في عام ٢٠٢٣، يتوقع النموذج نمواً اقتصادياً بنسبة ١,٢٩٥%، مع فترات ثقة تتراوح بين [٠,٩%، ١,٧%] عند مستوى ثقة ٨٠%، و [٠,٧%، ١,٩%] عند مستوى ثقة ٩٥%. هذه القيم تشير إلى أن النمو الاقتصادي سيكون إيجابياً ولكن بمعدلات متواضعة، مع وجود هامش خطأ محدود يعكس درجة معقولة من الثقة في التنبؤات. في عام ٢٠٢٤، يتوقع النموذج انخفاضاً طفيفاً في معدل النمو إلى ١,٠٥٣%، مع فترات ثقة تتراوح بين [٠,٦%، ٥,١%] عند مستوى ثقة ٨٠%، و [٠,٤%، ١,٧%] عند مستوى ثقة ٩٥%.

قد يعكس هذا الانخفاض الطفيف استمرار التحديات الاقتصادية والسياسية التي تواجهها سورية. في عام ٢٠٢٥، يتوقع النموذج تحسناً ملحوظاً في النمو الاقتصادي ليصل إلى ٢,٢٤٤%، مع فترات ثقة تتراوح بين [١,٧%، ٢,٨%] عند مستوى ثقة ٨٠%، و [١,٥%، ٣,٠%] عند مستوى ثقة ٩٥%. هذا التحسن قد يكون مرتبطاً بجهود إعادة الإعمار أو تحسن في الظروف السياسية والاقتصادية. في عام ٢٠٢٦، يتوقع النموذج أعلى معدل نمو خلال الفترة المدروسة، حيث يصل إلى ٣,٢٤٧%، مع فترات ثقة تتراوح بين [٢,٧%، ٣,٨%] عند مستوى ثقة ٨٠%، و [٢,٥%، ٤,٠%] عند مستوى ثقة ٩٥%. هذا الارتفاع الكبير قد يعكس تأثير سياسات اقتصادية فعالة أو تحسن في البيئة الاستثمارية. في عام ٢٠٢٧، يتوقع النموذج انخفاضاً في معدل النمو إلى ١,٢٤٧%، مع فترات ثقة تتراوح بين [٠,٨%، ١,٧%] عند مستوى ثقة ٨٠%، و [٠,٦%، ١,٩%] عند مستوى ثقة ٩٥%. هذا الانخفاض قد يعكس عودة التحديات الاقتصادية أو تقلبات في الأسواق العالمية. في عام ٢٠٢٨، يتوقع النموذج نمواً ضعيفاً جداً بنسبة ٠,٢٤٧%، مع فترات ثقة تتراوح بين [-٢,٠%، ٠,٧%] عند مستوى ثقة ٨٠%، و [-٤,٠%، ٠,٩%] عند مستوى ثقة ٩٥%.

تشير هذه القيم إلى احتمالية دخول الاقتصاد في حالة من الركود أو النمو الضعيف. في عام ٢٠٢٩، يتوقع النموذج انكماشاً اقتصادياً بنسبة -١,٢٤٧%، مع فترات ثقة تتراوح بين [-١,٧%، -٠,٨%] عند مستوى ثقة ٨٠%، و [-١,٩%، -٠,٦%] عند مستوى ثقة ٩٥%. هذا الانكماش قد يعكس أزمات اقتصادية أو سياسية جديدة. في عام ٢٠٣٠، يتوقع النموذج انتعاشاً اقتصادياً بنسبة ٣,٢٤٧%، مع فترات عدم يقين تتراوح بين [٢,٧%، ٣,٨%] عند مستوى ثقة ٨٠%، و [٢,٥%، ٤,٠%] عند مستوى ثقة ٩٥%. هذا الانتعاش قد يكون نتيجة لتحسن الظروف الاقتصادية أو تنفيذ سياسات إصلاحية. تشير فترات الثقة الضيقة نسبياً إلى أن النموذج يتمتع بدرجة عالية من الثقة في تنبؤاته، خاصة عند مستوى ثقة ٨٠%. ومع ذلك، فإن التقلبات الكبيرة في معدلات النمو المتوقعة تعكس عدم استقرار الاقتصاد السوري وتأثره بعوامل خارجية وداخلية متغيرة والشكل التالي يوضح اتجاهات نمو التوقعات:

شكل (٥): التنبؤ بالنمو الاقتصادي خلال الفترة ٢٠٢٣ - ٢٠٣٠ مع فترات الثقة عند ٨٠-٩٥%.

Forecast Economic Growth In Syria with Uncertainty Intervals (2023-2030) (HYBRID NNAR (2-2))



المصدر: إعداد الباحثة بالاعتماد على بيئة R Studio – Anaconda Python

أظهرت نتائج اختبار فرضيات البحث تفوق النموذج الهجين (AR + RNN) بشكل واضح في دقة التنبؤ بالنمو الاقتصادي في سورية مقارنة بنموذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) ونموذج الشبكات العصبية المتكررة (RNN) بشكل منفصل. حيث أكدت الفرضية الأولى وجود فرق ذو دلالة إحصائية بين دقة تنبؤات نموذج ARIMA والنموذج الهجين، حيث سجل النموذج الهجين متوسط خطأ (ME) بلغ ٠,٠٠٢٥ مقارنة بـ ١,٣٧٨ لنموذج ARIMA، مما يشير إلى أن النموذج الهجين لا يميل إلى المبالغة في التقدير أو التقليل من القيم الفعلية. كما سجل النموذج الهجين أقل قيمة لجذر متوسط الخطأ التربيعي

(RMSE) عند ٢,٨٨٦ مقارنة بـ ٩,٦٦٥ لنموذج ARIMA، مما يعكس دقة أعلى في التنبؤ وتقليل الانحرافات الكبيرة بين القيم المتوقعة والفعلية. أما الفرضية الثانية، فقد أكدت تفوق النموذج الهجين على نموذج RNN بشكل ذي دلالة إحصائية، حيث حقق النموذج الهجين متوسط خطأ مطلق (MAE) بلغ ١,٥٠٧ مقارنة بـ ٢,١٦٠ لنموذج RNN، مما يؤكد قدرته على تقليل حجم الأخطاء بشكل عام. بالإضافة إلى ذلك، سجل النموذج الهجين متوسط نسبة الخطأ المطلق (MAPE) عند ١,٣٦١% مقارنة بـ ٢٥٦,٢٢% لنموذج RNN، مما يعكس دقته العالية في التنبؤات النسبية.

في ضوء الأدبيات السابقة، تتوافق هذه النتائج مع دراسة Yang et al (2023) التي أظهرت تفوق النماذج الهجينة التي تجمع بين تقنيات الذكاء الاصطناعي والنماذج الإحصائية التقليدية في تحسين دقة التنبؤات الاقتصادية. كما تدعم نتائج البحث دراسة Ahmadi et al (2019) التي أكدت على فعالية النماذج الهجينة في التعامل مع البيانات غير الخطية والمعقدة، خاصة في السياقات الاقتصادية المتقلبة. ومع ذلك، فإن البحث الحالي يقدم إضافة نوعية من خلال تطبيق النموذج الهجين في سياق اقتصادي معقد مثل الاقتصاد السوري، والذي يتميز بدرجة عالية من التقلبات وعدم الاستقرار، مما يعزز من قيمة النتائج وقابليتها للتطبيق في بيئات مماثلة.

من ناحية أخرى، تشير النتائج إلى أن النموذج الهجين نجح في تجنب مشكلتي الإفراط في التخصيص (Overfitting) والتقليل من التخصيص (Underfitting)، حيث أن الفروق بين مقاييس الأداء كانت متوازنة ومنخفضة، مما يعكس قدرته على التعميم بشكل جيد على البيانات الجديدة دون فقدان الدقة أو زيادة التعقيد المفرط. هذا يتوافق مع دراسة Khennour et al (٢٠٢٣) التي أكدت على أهمية التوازن بين تعقيد النموذج وقدرته على التعميم في تحسين دقة التنبؤات. كما تدعم النتائج دراسة Ma (٢٠٢٤) التي أشارت إلى محدودية نماذج ARIMA في التعامل مع البيانات غير المستقرة، مما يؤكد الحاجة إلى دمج تقنيات الذكاء الاصطناعي لتحسين الدقة.

10- الاستنتاجات والتوصيات:

1-10 الاستنتاجات:

١- أظهر النموذج الهجين NNAR تفوقاً واضحاً في دقة التنبؤ بالنمو الاقتصادي في سورية مقارنة بنموذج الانحدار الذاتي للمتوسطات المتحركة (ARIMA) ونموذج الشبكات العصبية المتكررة (RNN) بشكل منفصل. حيث سجل النموذج الهجين متوسط خطأ (ME) بلغ ٠,٠٠٢٥ مقارنة بـ ٣٧٨.١ لنموذج ARIMA و ١,٨٠٧٧ لنموذج RNN، مما يشير إلى أن النموذج الهجين لا يميل إلى المبالغة في التقدير أو التقليل من القيم الفعلية. بالإضافة إلى ذلك، سجل النموذج الهجين أقل قيمة لجذر متوسط الخطأ التربيعي (RMSE) عند ٢,٨٨٦ مقارنة بـ ٩,٦٦٥ لنموذج ARIMA و ٣,١٥٢ لنموذج RNN، مما يعكس دقة أعلى في التنبؤ وتقليل الانحرافات الكبيرة بين القيم المتوقعة والفعلية.

٢- تميز النموذج الهجين بقدرته على التعامل مع التقلبات الكبيرة في البيانات الاقتصادية السورية، حيث سجل متوسط خطأ مطلق (MAE) بلغ ١,٥٠٧ مقارنة بـ ٦,٥٤٤ لنموذج ARIMA و ٢,١٦٠ لنموذج RNN. هذا الانخفاض الكبير في قيمة MAE يعكس قدرة النموذج الهجين على تقليل

حجم الأخطاء بشكل عام، مما يجعله أداة فعالة في التنبؤ بالاقتصاديات المتقلبة والمعقدة مثل الاقتصاد السوري.

٣- أظهر النموذج الهجين تحسناً ملحوظاً في دقة التنبؤات النسبية، حيث سجل متوسط نسبة الخطأ المطلق (MAPE) عند ١,٣٦١% مقارنة بـ ١٥٥,٧٨% لنموذج ARIMA و ٢٥٦,٢٢% لنموذج RNN. هذه القيمة المنخفضة جداً لـ MAPE تعكس دقة عالية في التنبؤات النسبية، مما يؤكد قدرة النموذج الهجين على التعامل مع البيانات غير الخطية والمعقدة بشكل فعال.

٤- وفقاً لنتائج النموذج الهجين، يتوقع أن يشهد الاقتصاد السوري تقلبات كبيرة في معدلات النمو خلال الفترة من ٢٠٢٣ إلى ٢٠٣٠، حيث تتراوح التوقعات بين -١,٢٤٧% و ٣,٢٤٧%. على سبيل المثال، في عام ٢٠٢٣، يتوقع النموذج نمواً اقتصادياً بنسبة ١,٢٩٥% مع فترات ثقة تتراوح بين [٠,٩%، ١,٧%] عند مستوى ثقة ٨٠%. هذه التوقعات تعكس التحديات الهيكلية التي يواجهها الاقتصاد السوري، مع وجود احتمالية لتحسن طفيف في بعض السنوات مثل عام ٢٠٢٦ حيث يتوقع النموذج نمواً بنسبة ٣,٢٤٧%.

10-2 التوصيات:

✓ نظراً لتفوق النموذج الهجين (AR + RNN) في دقة التنبؤ، يُوصى باعتماد هذا النموذج كأداة رئيسة لدعم صناع القرار في سورية. يمكن تطبيق هذا النموذج من خلال إنشاء وحدة تحليل بيانات متخصصة ضمن المؤسسات الحكومية، مثل وزارة الاقتصاد أو المكتب المركزي للإحصاء، تعمل على تحديث البيانات الاقتصادية بشكل دوري وتطبيق النموذج الهجين لتوليد تنبؤات دقيقة. هذه التنبؤات يمكن أن تُستخدم لتوجيه السياسات الاقتصادية، مثل تخصيص الموارد ووضع خطط استثمارية تعزز النمو الاقتصادي.

✓ نظراً لقدرة النموذج الهجين على التعامل مع التقلبات الكبيرة في البيانات الاقتصادية، يُوصى بتدريب الكوادر الفنية في المؤسسات الحكومية والبحثية على استخدام تقنيات الذكاء الاصطناعي، وخاصة الشبكات العصبية المتكررة (RNN)، لتحليل البيانات غير الخطية. يمكن تحقيق ذلك من خلال عقد ورش عمل ودورات تدريبية بالتعاون مع الجامعات ومراكز الأبحاث المتخصصة. بالإضافة إلى ذلك، يمكن تطوير برامج تدريبية عبر الإنترنت لضمان استمرارية التعلم ومواكبة التطورات التكنولوجية في مجال تحليل البيانات.

✓ بناءً على توقعات النمو الاقتصادي المستقبلية التي أظهرت تقلبات كبيرة بين السنوات، يُوصى بوضع خطط استباقية لمواجهة التحديات الاقتصادية المحتملة. على سبيل المثال، في السنوات التي يتوقع فيها نمو ضعيف أو انكماش اقتصادي (مثل عام ٢٠٢٩ الذي يتوقع فيه نمو بنسبة -١,٢٤٧%)، يمكن للحكومة تنفيذ سياسات تحفيزية مثل زيادة الإنفاق العام أو تقديم حوافز ضريبية للقطاع الخاص. وفي السنوات التي يتوقع فيها نمو مرتفع (مثل عام ٢٠٢٦ الذي يتوقع فيه نمو بنسبة ٣,٢٤٧%)، يمكن تعزيز سياسات الادخار والاستثمار في البنية التحتية لضمان استدامة النمو. هذه الخطط يجب أن تكون مرنة وقابلة للتعديل بناءً على التحديثات الدورية للتنبؤات الاقتصادية.

11- قائمة المراجع:

- 1- Ahmadi M, Jafarzadeh-Ghouschi S, Taghizadeh R, Sharifi A. *Presentation of a new hybrid approach for forecasting economic growth using artificial intelligence approaches*. Neural Computing and Applications. 2019 Dec;31(12):8661-80.
- 2- Aseeri AO. *Effective RNN-based forecasting methodology design for improving short-term power load forecasts: Application to large-scale power-grid time series*. Journal of Computational Science. 2023 Apr 1;68:101984.
- 3- Bharadiya JP. *Exploring the use of recurrent neural networks for time series forecasting*. International Journal of Innovative Science and Research Technology. 2023;8(5):2023-7.
- 4- Feng L, Zhang J. *Application of artificial neural networks in tendency forecasting of economic growth*. Economic Modelling. 2014 Jun 1;40:76-80.
- 5- Khachiyan A, Thomas A, Zhou H, Hanson G, Cloninger A, Rosing T, Khandelwal AK. *Using neural networks to predict microspatial economic growth*. American Economic Review: Insights. 2022 Dec 1;4(4):491-506.
- 6- Khan M, Khan AU, Khan J, Khan S, Haleem K, Khan FA. *Streamflow forecasting for the Hunza river basin using ANN, RNN, and ANFIS models*. Water Practice & Technology. 2023 May 1;18(5):981-93.
- 7- Khennour ME, Bouchachia A, Kherfi ML, Bouanane K. *Randomising the Simple Recurrent Network: a lightweight, energy-efficient RNN model with application to forecasting problems*. Neural Computing and Applications. 2023 Sep;35(27):19707-18.
- 8- Ma Y. *Analysis and Forecasting of GDP Using the ARIMA Model*. Information Systems and Economics. 2024 Feb 15;5(1):91-7.
- 9- Milačić L, Jović S, Vujović T, Miljković J. *Application of artificial neural network with extreme learning machine for economic growth estimation*. Physica A: Statistical Mechanics and its Applications. 2017 Jan 1;465:285-8.
- 10- SANUSI, N. A., MOOSIN, A. F., & KUSAIRI, S. (2020). Neural network analysis in forecasting the Malaysian GDP. *The Journal of Asian Finance, Economics and Business*, 7(12), 109-114.
- 11- Taiba, Al-Arabi, Ben Saha, Ali. *Forecasting the economic growth of Algeria using the Box-Jenkins methodology for the time period (1980-2020)*. Journal of Business Administration and Economic Studies. 2022 Nov 16;8(2):151-68. [in Arabic].
- 12- Tuo S, Chen T, He H, Feng Z, Zhu Y, Liu F, Li C. *A regional industrial economic forecasting model based on a deep convolutional neural network and big data*. Sustainability. 2021 Nov 19;13(22):12789.
- 13- Xu R, Yu X, Zhao X. *Regional Economic Development Trend Prediction Method Based on Digital Twins and Time Series Network*. Computers, Materials & Continua. 2023 Sep 1;76(2).
- 14- Yang CH, Molefyane T, Lin YD. *The Forecasting of a Leading Country's Government Expenditure Using a Recurrent Neural Network with a Gated Recurrent Unit*. Mathematics. 2023 Jul 12;11(14):3085.
- 15- Central Bureau of Statistics (CBS). *Economic growth data for Syria (1961-2022)*. 2022. [Dataset]. Available at: <http://cbssyr.sy/>