

التنبؤ بالنمو الاقتصادي في سورية باستخدام الشبكات العصبية الالتفافية (CNN) للتعلم الآلي للفترة ١٩٦١-٢٠٢٣

د. راميا الجبيلي *

د. محمد معد سليمان **

علي دالي ***

(تاريخ الإيداع ٢٠٢٥ /٥/١٣ - تاريخ النشر ٢٠٢٥ /٧/١٤)

□ ملخص □

يهدف هذا البحث إلى التنبؤ بمعدل نمو الناتج المحلي الإجمالي في سورية خلال الفترة ٢٠٢٤-٢٠٢٩ باستخدام نموذج الشبكات العصبية الالتفافية (CNN) وذلك بالاعتماد على بيانات سنوية تمتد من عام ١٩٦١ إلى عام ٢٠٢٣ تم الحصول عليها من المكتب المركزي للإحصاء، تم تحويل السلسلة الزمنية إلى نموذج إشرافي باستخدام نافذة انزلاقية ثم تدريب نموذج CNN على ٩٥% من البيانات واختباره على ٥% منها، أظهرت نتائج النموذج دقة عالية حيث بلغت مؤشرات الخطأ في مجموعة الاختبار $RMSE = 2.64$ و $MAPE = 1.09\%$ مما يعكس قدرة النموذج على التعميم والتنبؤ الدقيق في بيئة اقتصادية غير مستقرة، كما أظهرت التنبؤات المستقبلية للفترة المستهدفة اتجاهاً تنازلياً في النمو مع وجود فترات ثقة عند مستوى ٩٥% تعكس حجم عدم اليقين المحيط بالتوقعات وتبرز أهمية هذا البحث في كونه من أوائل التطبيقات الفعلية لنموذج CNN على بيانات اقتصادية سورية بما يفتح آفاق جديدة أمام استخدام تقنيات التعلم العميق في التنبؤ الاقتصادي ضمن البيئات العربية.

الكلمات المفتاحية: الشبكات العصبية الالتفافية، الناتج المحلي الإجمالي، التعلم العميق، التنبؤ الاقتصادي، السلاسل الزمنية.

*أستاذ مساعد - قسم الإحصاء والبرمجة- كلية الاقتصاد - جامعة اللاذقية - اللاذقية - سورية.

**أستاذ مساعد - قسم الإحصاء ونظم المعلومات - كلية الاقتصاد - جامعة حلب - حلب - سورية.

***طالب دكتوراه - قسم الإحصاء والبرمجة- كلية الاقتصاد - جامعة اللاذقية - اللاذقية - سورية.

Forecasting Economic Growth in Syria Using Convolutional Neural Networks (CNN) for the Period 1961–2023

Dr. Ramia Al-Jubaili*
Dr. Muhammed Maad Suleiman**
Ali Dali***

(Received 13/5/2025.Accepted 14/7/2025)

□ABSTRACT □

This study aims to forecast the growth rate of Syria's Gross Domestic Product (GDP) for the period 2024–2029 using a Convolutional Neural Network (CNN) model. The model is trained on annual GDP data spanning from 1961 to 2023, obtained from the World Bank and the Syrian Central Bureau of Statistics. The time series data were transformed into a supervised learning format using a sliding window approach. The CNN model was trained on 95% of the dataset and tested on the remaining 5%. The results demonstrate high predictive accuracy, with error metrics in the test set reaching $RMSE = 2.64$ and $MAPE = 1.09\%$, indicating the model's ability to generalize and forecast accurately in an unstable economic environment. The forecasted values for the target period showed a downward trend in economic growth, accompanied by 95% confidence intervals that reflect the degree of uncertainty in the predictions. This study represents one of the first practical applications of CNN models to Syrian economic data and highlights the potential of deep learning techniques in economic forecasting within Arab contexts.

Keywords: Convolutional Neural Networks, Gross Domestic Product, Deep Learning, Economic Forecasting, Time Series.

*Assistant Professor – Department of Statistics and Programming – Faculty of Economics – University of Latakia – Latakia, Syria

**Associate Professor, Department of Statistics and Information Systems – Faculty of Economics – University of Aleppo – Aleppo, Syria.

***PhD Student – Department of Statistics and Programming – Faculty of Economics – University of Latakia – Latakia, Syria

١ - المقدمة:

تُعد السلاسل الزمنية الاقتصادية من أهم الأدوات التحليلية التي يعتمد عليها الباحثون وصانعو القرار في رسم السياسات العامة واتخاذ القرارات المستقبلية لا سيما في ظل ما تشهده الاقتصادات من تحولات متسارعة وتقلبات خارجية وداخلية ويعدّ الناتج المحلي الإجمالي (GDP) من أبرز المؤشرات الكلية التي تعكس مستوى النشاط الاقتصادي ويكتسب أهمية مضاعفة في الدول التي تمر بظروف استثنائية كالحروب أو الأزمات الاقتصادية، كما هو الحال في الجمهورية العربية السورية. في هذا السياق ظهرت الحاجة إلى استخدام أساليب تنبؤية حديثة تتجاوز حدود النماذج الكلاسيكية التقليدية خاصة في ظل توفر البيانات الكبيرة وتطور تقنيات الذكاء الاصطناعي. من بين هذه الأساليب برزت الشبكات العصبية الالتفافية (Convolutional Neural Networks - CNN) كأداة فعّالة في تحليل الأنماط المعقدة ضمن السلاسل الزمنية والتنبؤ بالقيم المستقبلية بدقة، حيث استخدم (Durairaj, 2022) و (Mohan & Geng, 2020) نموذج CNN للتنبؤ بالسلاسل المالية وحققوا نتائج عالية الدقة. وطور (Geng, 2020) نموذج CNN محسّن لتوقع استهلاك الطاقة الصناعي بكفاءة عالية. كما أظهر (Tuo et al., 2021) أن استخدام CNN مع البيانات الضخمة يعزز الدقة التنبؤية في النماذج الاقتصادية الإقليمية.

يهدف هذا البحث إلى تقدير نموذج تنبؤي باستخدام CNN لتقدير معدل نمو الناتج المحلي الإجمالي في سورية خلال الفترة (٢٠٢٤-٢٠٢٩) وذلك بالاعتماد على بيانات تاريخية تغطي الفترة (١٩٦١-٢٠٢٣) تم الحصول عليها من المكتب المركزي للإحصاء في سورية، كما يتضمن البحث تقدير فترات عدم اليقين حول التنبؤات لتقييم مدى استقرار النتائج.

١-١ مراجعة الدراسات السابقة

حظي موضوع التنبؤ بالنمو الاقتصادي باهتمام واسع في الأدبيات الاقتصادية خاصة في الدول النامية التي تسعى إلى تعزيز قدرتها على تخطيط السياسات الاقتصادية في ظل عدم اليقين، وقد تطورت منهجيات التنبؤ تدريجياً من النماذج الإحصائية الخطية إلى نماذج الذكاء الاصطناعي المعتمدة على التعلم العميق. في السياق العربي، استخدم عبد الجواد وآخرون (٢٠٢٤) نموذج هجين يجمع بين ARIMA و ANN و SVR للتنبؤ بالسلاسل الزمنية وأثبتت النتائج أن النماذج المركبة تعطي أداءً أدق من النماذج الفردية، بينما استخدم (عبد الرحيم، ٢٠٢٣) منهجية بوكس-جنكينز لتوقع الناتج المحلي الإجمالي في السودان وخلص إلى أهمية توفر الاستقرار البنوي للسلسلة الزمنية لتحقيق دقة تنبؤية مقبولة. من جهة أخرى اعتمد (العربي وطعيبة، ٢٠٢٤) على الخوارزميات الجينية لتنبؤ النمو الاقتصادي في الجزائر، وأثبتت النتائج كفاءة تلك الخوارزميات في التعامل مع العلاقات غير الخطية. كما أوضحت دراسة بلباركي وبلمهدي (٢٠٢٣) أن استخدام نماذج ARDL والشبكات العصبية يساهم في كشف العلاقة المركبة بين التكنولوجيا الحديثة والنمو الاقتصادي. وفي السياق السوري قدمت دراسة (Alakkari, 2023) نموذجاً لتقدير الناتج المحلي الإجمالي باستخدام أسلوب التنبؤ اللحظي (Nowcasting) في بيئة بيانات محدودة بالاعتماد على نموذج VAR الترددي المختلط المعتمد على الأساليب البايزية (Bayesian Mixed-Frequency VAR) وقد أظهرت الدراسة قدرة هذا النموذج على توليد توقعات معقولة رغم محدودية وتشتت البيانات الرسمية إلا أنها اعتمدت على نماذج خطية ولم تتناول إمكانات التعلم الآلي أو الشبكات العصبية في السياق السوري. أظهر (Tuo et al., 2021) أن استخدام CNN مع البيانات الضخمة يعزز الدقة التنبؤية في النماذج الاقتصادية الإقليمية. وبين Wu et al.,

(2023) أن الدمج بين CNN و Bi-LSTM يحسن التوقعات البيئية بينما قدم (Khachiyani et al., 2022) نموذج لتوقع النمو الاقتصادي المحلي باستخدام الشبكات العصبية الدقيقة في السياقات المكانية المصغرة.

من خلال مراجعة هذه الأدبيات يتضح أن معظم الدراسات العربية ركزت على النماذج الكلاسيكية أو الهجينة في حين لا تزال تطبيقات CNN في مجال الاقتصاد الكلي العربي نادرة وخصوصاً في السياق السوري ما يعزز أهمية هذه الدراسة كمحاولة علمية لتطبيق نموذج CNN على بيانات الناتج المحلي الإجمالي في سورية وتقديم بديل غير خطي للتنبؤ في ظل بيئة غير مستقرة.

التعليق على الدراسات السابقة ومساهمة البحث:

يتبين من مراجعة الأدبيات السابقة العربية والأجنبية أن هناك تطور ملموس في الأساليب المستخدمة لتنبؤ الناتج المحلي الإجمالي خاصة من خلال النماذج الهجينة والمبنية على الذكاء الاصطناعي، ومع ذلك لا تزال معظم الدراسات العربية تعتمد على النماذج التقليدية ARIMA و Box-Jenkins أو على نماذج لم تُختبر بشكل كاف على بيانات اقتصادية واقعية شديدة التقلب كما هو الحال في سورية. في المقابل ركزت الأدبيات الأجنبية على استخدام CNN في مجالات مالية وبيئية متنوعة إلا أن استخدامها في النمذجة الاقتصادية الكلية على مستوى الدول النامية، وفي سياقات بيانات غير مستقرة وغير مكتملة لا يزال محدود وهذا ما يجعل من الدراسة الحالية محاولة علمية ومنهجية لسد هذا النقص من خلال تطبيق نموذج CNN على سلسلة الناتج المحلي الإجمالي لخصائصه التي تتيح أخذ خصائص التقلب في المتغيرات نتيجة الأوضاع في سورية للفترة ١٩٦١-٢٠٢٣ وبناء نموذج قادر على التنبؤ للفترة ٢٠٢٤-٢٠٢٩ مع احتساب فترات عدم اليقين. تتمثل مساهمة هذا البحث في تقديم إطار تطبيقي جديد يدمج بين تقنيات الذكاء الاصطناعي والبيانات الاقتصادية وهو ما يعزز من قيمته الأكاديمية والتطبيقية ويفتح المجال أمام استخدام نماذج CNN في دراسات اقتصادية كمية مستقبلية ضمن سياقات عربية مشابهة.

١-٢ أهداف البحث:

يهدف هذا البحث إلى تحقيق الأهداف التالية:

- ١- بناء نموذج تنبؤي باستخدام الشبكات العصبية الالتفافية (CNN) لتقدير معدل نمو الناتج المحلي الإجمالي في الجمهورية العربية السورية استناداً إلى بيانات السلاسل الزمنية للفترة (١٩٦١-٢٠٢٣).
- ٢- توليد تنبؤات مستقبلية للناتج المحلي الإجمالي مع فترات عدم يقين (٩٥%) للسنوات (٢٠٢٤-٢٠٢٩) وتفسير النتائج لدعم صناع القرار في وضع السياسات الاقتصادية.

١-٣ مشكلة البحث:

يشكل التنبؤ بالناتج المحلي الإجمالي أحد المرتكزات الأساسية في تحليل الأداء الاقتصادي وصياغة السياسات العامة إلا أن تحقيق تنبؤات دقيقة في الدول التي تمر بظروف اقتصادية استثنائية مثل سورية يواجه تحديات متعددة منها عدم استقرار البيانات وتعدد مصادرها وتداخل المتغيرات المؤثرة، بالإضافة إلى محدودية كفاءة النماذج الإحصائية الكلاسيكية في تمثيل العلاقات غير الخطية والمعقدة داخل السلسلة الزمنية، وعلى

الرغم من التطور الكبير في تقنيات الذكاء الاصطناعي إلا أن تطبيقاتها في المجال الاقتصادي السوري لا تزال محدودة خاصة فيما يتعلق باستخدام الشبكات العصبية الالتفافية (CNN) كنموذج غير خطي قادر على استخراج الأنماط الداخلية في البيانات وتقديم تنبؤات مدعومة بفترات عدم يقين. انطلاقاً من ذلك تتمحور مشكلة البحث حول الحاجة إلى اختبار مدى قدرة نموذج CNN على التنبؤ بمعدل نمو الناتج المحلي الإجمالي في سورية استناداً إلى بيانات رسمية تمتد لأكثر من ستة عقود وتحديد ما إذا كان هذا النموذج يوفر أداءً تنبؤي يفوق النماذج التقليدية من حيث الدقة والتفسير وبالتالي يمكن صياغة مشكلة البحث من خلال التساؤل: ما مدى كفاءة نموذج الشبكات العصبية الالتفافية (CNN) في التنبؤ بمعدل نمو الناتج المحلي الإجمالي في سورية خلال الفترة (٢٠٢٤-٢٠٢٩) بالاعتماد على بيانات السلسلة الزمنية (١٩٦١-٢٠٢٣)؟

٤-١ أهمية البحث:

تتبع أهمية هذا البحث من نقطتين أساسيتين النظرية والتطبيقي فعلى الصعيد النظري يسهم البحث في إثراء الأدبيات الاقتصادية العربية من خلال تقديم نموذج غير خطي مبني على الشبكات العصبية الالتفافية (CNN) لتنبؤ الناتج المحلي الإجمالي وهو ما يُعد اتجاه حديث في تحليل السلاسل الزمنية الاقتصادية لم يتم توظيفه بشكل كبير في الدراسات الاقتصادية الكلية خاصة في البيئة السورية، كما يضيف البحث قيمة علمية من خلال دمج مفاهيم التعلم العميق مع النمذجة الاقتصادية وتوسيع نطاق استخدام CNN خارج مجالاتها التقليدية كتحليل الصور والبيانات البصرية أما على الصعيد العملي فإن نتائج البحث تتيح لصناع القرار والمؤسسات الاقتصادية في سورية أداة كمية حديثة تساعد على التنبؤ باتجاهات النمو الاقتصادي المستقبلية وتقدير فترات عدم اليقين المحيطة بها وهذا بدوره يسهم في دعم التخطيط الاقتصادي وتوجيه السياسات العامة والتعامل مع حالات عدم الاستقرار التي تعاني منها البيئة الاقتصادية السورية كما يمكن أن تشكل المنهجية المستخدمة نموذجاً أولياً قابلاً للتطبيق في دول أو قطاعات أخرى ذات ظروف مماثلة.

٢-٢ منهجية البحث:

يعتمد هذا البحث على منهج تحليل وصفي يستند إلى تحليل نمو الناتج المحلي الإجمالي الحقيقي في سورية خلال الفترة ١٩٦١-٢٠٢٣ الهدف بناء نموذج تنبؤي دقيق باستخدام تقنيات الذكاء الاصطناعي وبشكل خاص الشبكات العصبية الالتفافية (Convolutional Neural Network - CNN). تم تنفيذ مراحل البحث ضمن بيئة البرمجة Python باستخدام بيئة Jupyter Notebook بالاعتماد على عدد من الحزم المتخصصة، أبرزها Pandas و NumPy لمعالجة البيانات، Matplotlib و Seaborn لإنتاج الرسوم البيانية Statsmodels لتحليل الارتباط الذاتي و Scikit-learn لتقسيم البيانات وتقييم الأداء و TensorFlow و Keras لتصميم وبناء وتدريب نموذج CNN ، وشملت منهجية البحث عدة مراحل بدأت بتنظيف البيانات وتحويلها إلى صيغة إشرافية من خلال تطبيق نافذة انزلاقية ثابتة، حيث يُستخدم عدد من القيم السابقة للتنبؤ بالقيمة التالية، بعد ذلك جرى معايرة البيانات باستخدام خوارزمية Min-Max لتسهيل عملية التدريب، ثم تم تصميم النموذج العصبي باستخدام طبقة Conv1D تليها MaxPooling1D ثم Flatten وطبقتان Dense لإنتاج القيمة المتنبأ بها. تم تدريب النموذج على ٩٥% من البيانات، واختباره على ٥% باستخدام ١٠٠ تكرار مع تتبع دالة الفقد خلال مرحلتي التدريب والتحقق بعد التدريب. تم تقييم النموذج باستخدام مؤشرات الجذر التربيعي للخطأ المتوسط (RMSE) ومربع متوسط الخطأ (MSE) ومتوسط

الخطأ المطلق النسبي (MAPE) لفترتي التدريب والاختبار، كما تم إنتاج تنبؤات مستقبلية للناتج المحلي الإجمالي للفترة ٢٠٢٤-٢٠٢٩ باستخدام القيم الأخيرة من السلسلة، واحتساب فترات الثقة عند مستوى ٩٥% استناد إلى الانحراف المعياري لبواقي النموذج.

٣- فرضيات البحث:

تتمثل من خلال: يُمكن أن يُستخدم نموذج الشبكات العصبية الالتقافية (CNN) بكفاءة عالية في التنبؤ بمعدل نمو الناتج المحلي الإجمالي في سورية وأنه يوفر أداءً تنبؤي جيد في التعامل مع السلاسل الزمنية غير المستقرة والبيانات الاقتصادية المعقدة.

٤- المناقشة والنتائج:

٤-١ الإطار النظري والإحصائي للنموذج:

تعتمد الشبكات العصبية الالتقافية (CNN) على آلية التعلم العميق من خلال تطبيق مرشحات (Filters) لاستخلاص الأنماط الزمنية من البيانات. في حالة السلاسل الزمنية تُستخدم CNN للتعرف على العلاقات الزمنية القصيرة المدى داخل نافذة متحركة من القيم بالتالي يعتمد نموذج CNN على بنية طبقية تشمل طبقات الالتفاف والتجميع والتسطيح، وهي مصممة لاستخلاص السمات الزمنية المركبة من البيانات (Durairaj & Mohan, 2022) يتم تحويل البيانات إلى شكل إشرافي باستخدام نافذة انزلاقية بحجم ثابت (w). حيث يتم استخدام w ملاحظة سابقة للتنبؤ بالقيمة اللاحقة:

$$X_t = [GDP_{t-w}, GDP_{t-w+1}, \dots, GDP_{t-1}]$$

$$y_t = GDP_t$$

تعتمد طبقة الالتفاف على تمرير نافذة ثابتة من القيم خلال تسلسل البيانات لحساب مجموعة من السمات، حسب المعادلة (Geng et al., 2020):

$$z_t = \sum (w_i \times x_{t+i}) + b$$

حيث: z_t هو الناتج عند الزمن t و w_i وزن الفلتر عند الموقع i x_{t+i} هو مدخل السلسلة عند الزمن $t+i$ و b هو معامل التحيز. ثم تمرر البيانات من خلال طبقة التجميع (Pooling Layer) تُستخدم لتقليل حجم البيانات المُخرجة من طبقة الالتفاف، وزيادة كفاءة التعلم. أكثر النماذج استخدام هو MaxPooling (Tuo et al., 2021; Khachiyani et al., 2022):

$$p_t = \max(x_t, x_{t+1}, \dots, x_{t+q-1})$$

بعد تسطیح البيانات (Flatten)، يتم تمريرها إلى طبقة كاملة الاتصال (Dense) لإنتاج القيمة المتوقعة للناتج المحلي:

$$\hat{y}_t = f(\sum (v_j \times h_j) + c)$$

حيث: \hat{y}_t هو التنبؤ بالناتج المحلي في الزمن t و h_j هو ناتج العقدة j في الطبقة السابقة و v_j هو الوزن الرابط بين العقدة j والمخرج c هو الانحياز و f هي دالة التنشيط ReLU. وتم استخدام دالة متوسط مربع الخطأ (MSE) كدالة خسارة لتدريب النموذج (Guo et al. 2024):

$$MSE = (1/n) \times \sum (GDP_t - \hat{y}_t)^2$$

تم استخدام ثلاثة مؤشرات لتقييم أداء النموذج في فترتي التدريب والاختبار وتشمل MSE من خلال المعادلة السابقة وأيضاً:

$$RMSE = \sqrt{MSE}$$

$$MAPE = (100/n) \times \Sigma |(GDP_t - \hat{y}_t) / GDP_t|$$

حيث \hat{y}_t هو المتوسط الحسابي لقيم الناتج المحلي الإجمالي. تم استخدام الانحراف المعياري لبواقي النموذج في بيانات الاختبار لتقدير فترات عدم اليقين للتنبؤات المستقبلية:

$$Lower_t = \hat{y}_t - 1.96 \times \sigma$$

$$Upper_t = \hat{y}_t + 1.96 \times \sigma$$

حيث σ هو الانحراف المعياري لبواقي النموذج و \hat{y}_t هو التنبؤ المركزي لقيمة الناتج المحلي في السنة t

٢-٤ البيانات والأدوات والتطبيق:

تم الاعتماد في هذا البحث على بيانات سنوية تمثل معدل نمو الناتج المحلي الإجمالي الحقيقي في سورية تغطي الفترة من عام ١٩٦١ حتى عام ٢٠٢٣. وقد تم جمع البيانات من المكتب المركزي للإحصاء في سورية (٢٠٢٥) تم تنسيق البيانات وتوحيدها وفق متطلبات النمذجة، ثم تحويلها إلى شكل إشرافي باستخدام أسلوب النافذة المتحركة (Sliding Window) بهدف تدريب نموذج الشبكات العصبية الالتقافية (CNN) وقد أُجري التحليل باستخدام بيئة البرمجة Python مع توظيف عدد من الحزم المتخصصة التي تضم Pandas و NumPy لمعالجة البيانات Matplotlib و Seaborn لإنتاج الرسوم البيانية و TensorFlow و Keras لتصميم وبناء النموذج العصبي وقد أُجريت جميع مراحل التهيئة التدريب التقييم والتنبؤ داخل بيئة Jupyter Notebook.

٢-٤-١ الإحصاءات الوصفية والرسوم البيانية:

الجدول (١): الإحصاءات الوصفية لسلسلة نمو الناتج المحلي الإجمالي خلال الفترة ١٩٦١-٢٠٢٣

Statistic	Value
Count	63
Mean	3.514246
Std. Dev.	9.892104
Min	-26.339017
25th Percentile (Q1)	-0.710218
Median (Q2)	3.954832
75th Percentile (Q3)	8.006513
Max	25.795773

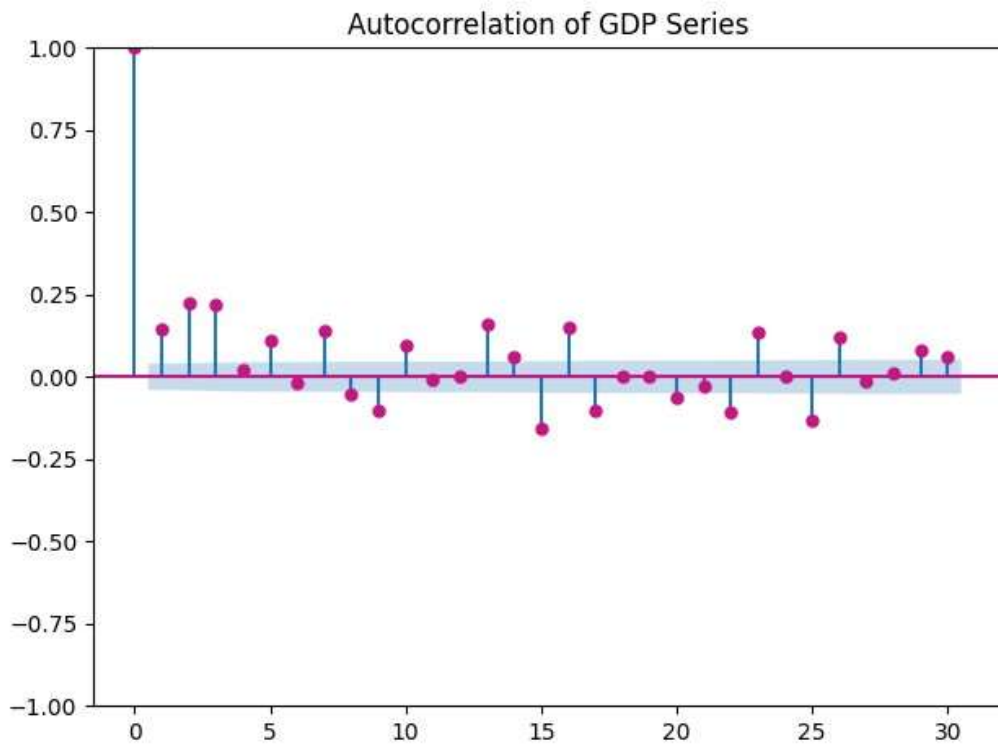
المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يوضح الجدول (١) الإحصاءات الوصفية الأساسية لسلسلة نمو الناتج المحلي الإجمالي في سورية خلال الفترة ١٩٦١-٢٠٢٣ يشير المتوسط الحسابي إلى أن معدل النمو السنوي للناتج المحلي الإجمالي خلال الفترة المدروسة بلغ نحو ٣.٥١% وهو ما يعكس وجود نمو اقتصادي متوسط على المدى الطويل رغم التباينات المسجلة بين السنوات، وبلغ الانحراف المعياري ٩.٨٩% مما يدل على تشتت كبير في قيم النمو وتباينها حول المتوسط. سُجلت القيمة الدنيا للنمو عند -٢٦.٣٤%، ما يشير إلى انكماش اقتصادي حاد بينما بلغت القيمة العظمى ٢٥.٨٠% وهي تدل على فترة نمو استثنائية أما الوسيط (Q2)، فقد بلغ ٣.٩٥%، وهو قريب من المتوسط ما يدل على أن توزيع القيم لا يميل إلى الانحراف وقد بلغ الربع الأدنى -0.71% (Q1) مما يشير إلى أن ٢٥% من القيم كانت في حالة نمو سلبي أو

ضعيف في حين بلغ الربع الأعلى %8.01 (Q3) مما يعني أن ٢٥% من القيم كانت ضمن نطاق نمو مرتفع
 تعكس هذه المؤشرات تذبذب النمو الاقتصادي السوري خلال العقود الستة الماضية وتؤكد أهمية استخدام نماذج
 تنبؤية متقدمة قادرة على التعامل مع هذا التباين المرتفع والشكل ١ يبين تطور وتحركات النمو خلال الفترة
 المدروسة:

الشكل (١): تطور النمو الاقتصادي في سورية خلال الفترة ١٩٦١-٢٠٢٣



المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون
 وحساب دالة الارتباط الذاتي لتوصيف نمط النمو الاقتصادي نجد:



الشكل (٢): الارتباط الذاتي لسلسلة نمو الناتج المحلي الإجمالي

المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يوضح الشكل (٢) نمط الارتباط الذاتي لسلسلة نمو الناتج المحلي حيث يعرض معاملات الارتباط الذاتي (Autocorrelation Coefficients) لمختلف فترات الابطاء (Lags) حتى 30 lag. يُظهر الشكل وجود ارتباطات ذاتية ضعيفة ومتناقصة في الفترات التالية ل 1 إذ تتناقص القيم تدريجي ثم تتذبذب حول الصفر مع بقاء معظمها ضمن حدود فترات الثقة الظاهرة باللون الأزرق كما يشير هذا النمط إلى غياب الارتباط طويل الأجل في السلسلة وهو ما يُفسر طبيعة التقلب العالي والعشوائية النسبية في نمو الناتج المحلي الإجمالي مما يبرر استخدام نموذج الشبكة الالتفافية لتوضيح هذه الأنماط في النموذج.

٢-٤-٢ تقدير النموذج وتدريبه

تم تصميم النموذج بما يتوافق مع طبيعية البيانات الزمنية حيث جرى تحويل السلسلة إلى شكل إشرافي باستخدام نافذة انزلاقية وتطبيع القيم لتناسب بيئة التعلم العميق اعتمد النموذج على طبقة واحدة من نوع Conv1D لتحديد الأنماط الزمنية تليها طبقة MaxPooling1D لتقليل الأبعاد وتقوية السمات ثم طبقة Flatten لتحويل الناتج إلى شكل مناسب للتمرير عبر الشبكات العصبية الكثيفة ثم طبقة Dense مكونة من ٥٠ وحدة مخفية وطبقة إخراج لإنتاج التنبؤ بقيمة واحدة تمثل معدل النمو المتوقع.

الجدول (٢): هيكل نموذج الشبكات العصبية الالتفافية (CNN) ومعلومات التدريب المستخدمة في التنبؤ بالناتج المحلي الإجمالي

Layer (Type)	Output Shape	Parameters
Conv1D	(None, 5, 64)	192
MaxPooling1D	(None, 2, 64)	0
Flatten	(None, 128)	0
Dense	(None, 50)	6,450
Dense (Output Layer)	(None, 1)	51
Total Parameters	—	6,693
Trainable Parameters	—	6,693
Non-trainable	—	0

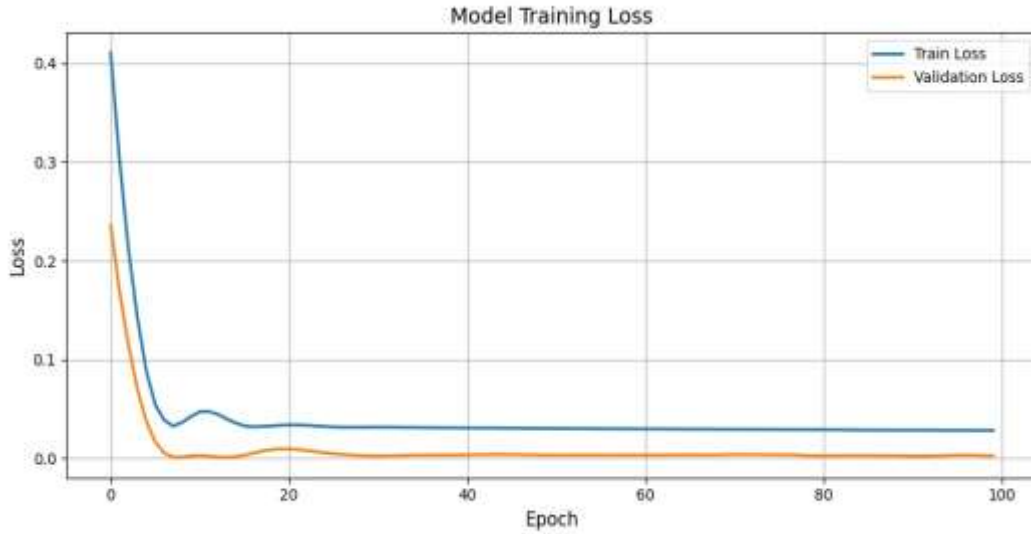
المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يُبين الجدول (٢) تفاصيل بنية النموذج حيث بلغ عدد المعاملات القابلة للتدريب ٦,٦٩٣ موزعة على طبقات النموذج في حين لم يتضمن النموذج أي معاملات غير قابلة للتدريب وتشير هذه البنية إلى تصميم كافٍ لالتقاط العلاقات الأساسية في السلسلة الزمنية دون تعقيد مفرط يؤدي إلى (Overfitting) وجدول ٣ يوضح قيم تدريب وتحقق دالة التدريب:

الجدول (٣): قيم دالة الفقد للتدريب والتحقق عبر التكرارات من ٩١ إلى ١٠٠

Epoch	Training Loss	Validation Loss
91	0.0327	0.0024
92	0.0277	0.0022
93	0.0284	0.0025
94	0.0246	0.0026
95	0.0263	0.0028
96	0.0296	0.0032
97	0.0281	0.0032
98	0.0315	0.0032
99	0.0292	0.0027
100	0.0272	0.0026

المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون الجدول (٣) فيعرض نتائج دالة الفقد (Loss Function) خلال التكرارات من ٩١ إلى ١٠٠ وهي المرحلة الأخيرة من عملية التدريب حيث نلاحظ من القيم أن خسارة التدريب تراوحت بين ٠.٠٢٤٦ و ٠.٠٣٢٧ بينما كانت خسارة التحقق أقل وبلغت في أدها ٠.٠٠٢٢ وفي أقصاها ٠.٠٠٣٢ مما يشير إلى أداء مستقر للنموذج في التحقق من صحة التوقعات دون وجود فجوة كبيرة بين أداء التدريب والاختبار وهذا يدل على أن النموذج لم يتعرض لفرط التعلّم ويحتفظ بقدر جيد من التعميم على البيانات غير المرئية والشكل ٣ يبين دالة الخسارة ل ١٠٠ فترة فقد:

الشكل (٣): منحنى دالة الفقد Loss Function خلال مراحل تدريب نموذج CNN



المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يوضح الشكل (٣) منحنى دالة الفقد (Loss Function) خلال مراحل تدريب نموذج الشبكات العصبية الالتفافية (CNN) وذلك على مدى ١٠٠ تكرار (Epoch) يبين المنحنى الأزرق تطور الخسارة في مجموعة التدريب في حين يمثل المنحنى البرتقالي الخسارة في مجموعة التحقق (Validation) يظهر من الشكل أن الخسارة انخفضت بشكل حاد خلال التكرارات الأولى وهو ما يدل على تعلم سريع للنموذج في المراحل الابتدائية ثم استقرت القيم تدريجي بعد التكرار العشرين مما يشير إلى وصول النموذج إلى حالة من التوازن بين التعلّم والتعميم لاحظنا أن خسارة التحقق بقيت أقل من خسارة التدريب طوال فترة التدريب مع تقارب واضح بين المنحنيين في المراحل الأخيرة ما يدل على أن النموذج لم يتعرض لفرط التكيف (Overfitting) وأن أداءه كان مستقر على كل من البيانات التدريب والاختبار كما يعكس هذا التوازن الجيد في الخسارة فعالية تصميم النموذج وبنيته وقدرته على التنبؤ بالقيم المستقبلية ضمن بيئة اقتصادية معقدة وغير منتظمة كسورية.

٢-٤-٣ تقييم النموذج والتنبؤ

في هذه المرحلة من البحث تم تقييم أداء نموذج الشبكات العصبية الالتفافية (CNN) بناءً على مؤشرات كمية دقيقة ثم توليد تنبؤات مستقبلية لمعدل نمو الناتج مع فترات عدم يقين إحصائية عند مستوى ٩٥%:

الجدول (٤): مؤشرات دقة نموذج CNN في مرحلتي التدريب والاختبار

Metric	Training Set	Test Set
RMSE	8.74	2.64
MSE	76.47	6.96
MAPE (%)	1.1404	1.٠939


المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يُظهر الجدول (٤) مؤشرات دقة النموذج في فترتي التدريب والاختبار فقد بلغ الجذر التربيعي للخطأ المتوسط (RMSE) في مجموعة التدريب ٨.٧٤ بينما انخفض في مجموعة الاختبار إلى ٢.٦٤ ما يشير إلى قدرة النموذج على التعميم عند التعامل مع بيانات جديدة غير مرئية كما بلغ متوسط مربع الخطأ (MSE) في التدريب ٧٦.٤٧ مقابل ٦.٩٦ في الاختبار مما يعزز دلالة الاستقرار وعدم وجود فرط في التكيف أما متوسط الخطأ المطلق النسبي (MAPE) فقد كان متقارب في المجموعتين إذ بلغ ١.١٤% في التدريب و ١.٠٩% في الاختبار ما يعكس دقة تنبؤية عالية عند احتساب الخطأ كنسبة من القيم الفعلية.

الجدول (٥): القيم المتنبأ بها لنمو الناتج المحلي الإجمالي للفترة ٢٠٢٤-٢٠٢٩ مع فترات ثقة عند مستوى ٩٥%

Year	Predicted GDP	Lower 95% CI	Upper 95% CI
2024	-1.6737	-4.5234	1.1760
2025	-2.2926	-5.1422	0.5571
2026	-2.5705	-5.4202	0.2792
2027	-3.2494	-6.0991	-0.3997
2028	-3.5866	-6.4363	-0.7369
2029	-3.9464	-6.7961	-1.0967

المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون يعرض الجدول (٥) القيم المتوقعة لمعدل نمو الناتج المحلي الإجمالي في سورية للسنوات ٢٠٢٤ حتى ٢٠٢٩ وتُظهر النتائج اتجاه تنازلي في النمو مع مرور السنوات حيث تبدأ القيمة المتوقعة عند -١.٦٧% في عام ٢٠٢٤ وتتخفف تدريجياً إلى -٣.٩٥% بحلول عام ٢٠٢٩ كما يتضمن الجدول فترات ثقة عند مستوى ٩٥% لكل سنة مما يوفر تقديرات كمية لعدم اليقين المحيط بالتوقعات ففي عام ٢٠٢٤ يتراوح النمو المتوقع بين -٤.٥٢% و ١.١٨% وهو مجال واسع نسبي يعكس التذبذب المرتفع وعدم الاستقرار في البيئة الاقتصادية السورية.

GDP Forecast with 95% Confidence Intervals (2024-2029)



الشكل (٤): التنبؤ بنمو الناتج المحلي الإجمالي للفترة ٢٠٢٤-٢٠٢٩ مع فترات ثقة عند مستوى ٩٥%

المصدر: اعداد الباحث من خلال البيانات المستمدة من المكتب المركزي للإحصاء في سورية بالاعتماد على لغة بايثون

٥- الاستنتاجات والتوصيات:

٥-١ الاستنتاجات:

١- أظهر نموذج الشبكات العصبية الالتقافية (CNN) قدرة فعالة على التعامل مع سلسلة نمو الناتج المحلي الإجمالي في سورية رغم ما تتسم به من تذبذب حاد وعدم استقرار هيكلي فقد تمكن النموذج من التقاط الأنماط الزمنية المعقدة في البيانات وتقديم تنبؤات دقيقة تعكس الاتجاه العام للنمو، بما يؤكد صلاحية نموذج CNN كأداة غير خطية متقدمة لتحليل الظواهر الاقتصادية في بيانات مضطربة.

٢- أظهرت مؤشرات التقييم أن النموذج يتمتع بدرجة عالية من الدقة حيث كانت الفروق بين أداء النموذج في فترتي التدريب والاختبار محدودة وهو ما يدل على قدرة النموذج على التعميم وعدم وقوعه في مشكلة فرط التكيف. وقد كانت قيم RMSE و MAPE منخفضة، خاصة في الاختبار مما يؤكد فعالية الضبط البنوي للنموذج واختيار بنية مناسبة لخصوصية السلسلة المدروسة.

٣- أظهرت التنبؤات المستقبلية للفترة ٢٠٢٤-٢٠٢٩ اتجاه تنازلي لمعدل النمو الاقتصادي مع وجود فترات ثقة واسعة نسبياً، وهو ما يعكس استمرار حالة عدم اليقين الاقتصادي في سورية خلال السنوات القادمة ويدل هذا الاتساع في مجالات التنبؤ على تأثر الاقتصاد السوري بعوامل خارجية وداخلية متشابهة.

٤- تؤكد نتائج البحث أن استخدام تقنيات الذكاء الاصطناعي وتحديداً نموذج CNN، يُعد خيار عملي ومنهجي في تحليل السلاسل الاقتصادية في الدول النامية وخاصة في ظل غياب الاستقرار البنوي وصعوبة الاعتماد على النماذج التقليدية ويفتح هذا البحث المجال أمام المزيد من الدراسات التي تدرس التعلم العميق لبناء نماذج توقع اقتصادية أكثر دقة ومرونة في البيئات ذات الطابع غير المنتظم.

٥-٢ التوصيات:

✓ توصي الدراسة بضرورة تبني الجهات الحكومية ومراكز القرار في سورية استخدام نماذج الذكاء الاصطناعي مثل الشبكات العصبية الالتقافية (CNN) في تحليل المؤشرات الاقتصادية الكلية نظر لقدرتها على التنبؤ بدقة والتعامل مع البيانات المتقلبة وغير المستقرة وهو ما يعزز فعالية السياسات الاقتصادية المستقبلية.

✓ يُنصح بتوسيع قاعدة البيانات الاقتصادية الوطنية وتحديثها بصورة دورية مع تحسين جودة البيانات الإحصائية بما يضمن دقة أكبر في تدريب النماذج التنبؤية ويعزز موثوقية النتائج الناتجة عنها في دعم خطط التنمية وإدارة الأزمات.

✓ توصي الدراسة بتطبيق النموذج المعتمد على سلاسل زمنية أخرى (التضخم، البطالة، أو الاستهلاك) واختبار أدائه في مجالات اقتصادية مختلفة بما يتيح بناء نظام متكامل للتنبؤ الاقتصادي قائم على تقنيات التعلم العميق في البيئات العربية والنامية.

المراجع:

- ١- بلباركي، مروة، بلمهدي، طارق. (٢٠٢٣). *التنبؤ بعلاقة التكنولوجيا الحديثة بالنمو الاقتصادي: نموذج الانحدار الذاتي ذو الفجوات الموزعة ونموذج الشبكات العصبية*.
- ٢- عبد الجواد، وليد عاطف عبد العزيز، أبوزيد، نصر إبراهيم رشوان، كامل، مي محمد. (٢٠٢٤). *التنبؤ بالسلاسل الزمنية باستخدام النموذج الهجين للانحدار الذاتي المتكامل للمتوسطات المتحركة مع الشبكات العصبية الاصطناعية وآلية المتجه الداعم للانحدار*. مجلة التجارة والتمويل، ٤٤(٤)، ٧٨٤-٨١٣.
- ٣- عبد الرحيم، معتز آدم. (٢٠٢٣). *استخدام منهجية بوكس-جنكينز Box-Jenkins للتنبؤ بالنتائج المحلي الإجمالي في السودان ٢٠١٠-٢٠٣٠م*. مجلة رؤى اقتصادية، ١٣(١).
- ٤- العربي، طعيبة. (٢٠٢٤). *تطبيق الخوارزميات الجينية في التنبؤ بالنمو الاقتصادي للجزائر ٢٠٢٢: دراسة قياسية للفترة ١٩٨٠-٢٠٢٢* (أطروحة دكتوراه، جامعة غرداية).
- ٥- المكتب المركزي للإحصاء. (٢٠٢٥). *البيانات الإحصائية الرسمية للنتائج المحلي الإجمالي في الجمهورية العربية السورية (١٩٦١-٢٠٢٣)*. دمشق: قسم الحسابات القومية.
- 1- Alakkari, K. (2023). *Nowcasting GDP in Parsimony Data Environment Using Bayesian Mixed Frequency VAR (Empirical Evidence from Syria)*. Syrian Journal for Science and Innovation, 1(2-Volume 1).
- 2- Durairaj, D. M., & Mohan, B. K. (2022). *A convolutional neural network based approach to financial time series prediction*. Neural Computing and Applications, 34(16), 13319-13337.
- 3- Geng, Z., Zhang, Y., Li, C., Han, Y., Cui, Y., & Yu, B. (2020). *Energy optimization and prediction modeling of petrochemical industries: An improved convolutional neural network based on cross-feature*. Energy, 194, 116851.
- 4- Guo, Q., He, Z., & Wang, Z. (2024). *Monthly climate prediction using deep convolutional neural network and long short-term memory*. Scientific Reports, 14(1), 17748.
- 5- Hoseinbor, N., Mousavi, S. N., & Aminifard, A. (2022). *DCNN-GCM: A Deep CNN and Granger Causality Models for Forecasting Welfare Level of Energy-Producing Countries and Evaluating the Relationship between Energy Consumption and Sustainable Economic Welfare*. Mathematical Problems in Engineering, 2022(1), 5321485.
- 6- Khachiyan, A., Thomas, A., Zhou, H., Hanson, G., Cloninger, A., Rosing, T., & Khandelwal, A. K. (2022). *Using neural networks to predict microspatial economic growth*. American Economic Review: Insights, 4(4), 491-506.
- 7- Tuo, S., Chen, T., He, H., Feng, Z., Zhu, Y., Liu, F., & Li, C. (2021). *A regional industrial economic forecasting model based on a deep convolutional neural network and big data*. Sustainability, 13(22), 12789.
- 8- Wu, J., Wang, Z., Hu, Y., Tao, S., & Dong, J. (2023). *Runoff forecasting using convolutional neural networks and optimized bi-directional long short-term memory*. Water Resources Management, 37(2), 937-953.

ملحق (١): بيانات الناتج المحلي الإجمالي بالاعتماد على المكتب المركزي للإحصاء .

GDP	DATE	GDP	DATE	GDP	DATE
6.215077835	2005	2.320339937	1983	10.8330639	1961
5.046195556	2006	-7.610630212	1984	24.52129717	1962
5.674591777	2007	9.350807332	1985	-8.652746672	1963
4.476672736	2008	-7.952928955	1986	9.271363802	1964
5.912042793	2009	1.682282346	1987	2.299373875	1965
5.191905841	2010	18.0111401	1988	-7.65906551	1966
2.850002844	2011	-13.64728218	1989	8.257682647	1967
-26.33901708	2012	3.739555902	1990	3.729080221	1968
-26.30008766	2013	7.666468187	1991	18.76791521	1969
-10.31033991	2014	12.97279007	1992	-1.796852875	1970
-4.179791613	2015	6.150895573	1993	8.955814563	1971
-6.405590739	2016	7.213029205	1994	25.6607152	1972
-0.723281777	2017	7.026589543	1995	-10.46985494	1973
1.393176078	2018	9.825569405	1996	25.79577285	1974
1.220705221	2019	5.023804508	1997	16.35157606	1975
-0.697154504	2020	6.785304524	1998	12.2544466	1976
1.854215901	2021	-3.553449871	1999	-1.799517878	1977
0.732781302	2022	0.675642589	2000	9.942590124	1978
-1.207264203	2023	1.047287102	2001	0.887988823	1979
		3.954831927	2002	14.50811695	1980
		7.204435053	2003	7.755343865	1981
		6.902959435	2004	2.789086648	1982