

Forecasting the Inflation Rate in Syria for the Period 1961–2030 Using the Hybrid CNN–LSTM Model

Ali Dali* 

Dr. Ramia Al-Jubaili**

Dr. Muhammed Maad Suleiman***

(Received 2 / 2 / 2026. Accepted 18 / 5 / 2026)

□ ABSTRACT □

This study explores the evolution of the inflation rate in Syria and forecasts its future trends through 2030 using the hybrid CNN–LSTM model. It relies on annual data for the period 1961–2023 within an economic context characterized by volatility, nonlinearity, and recurrent shocks. The statistical analysis shows that the time series does not follow a normal distribution and is characterized by positive skewness and excess kurtosis, indicating the presence of extreme values and heavy tails, which justifies the use of nonlinear modeling. The data were normalized and reformulated using a rolling time window, then divided into a training sample and a testing sample at ratios of 80% and 20%, respectively. The results show that the hybrid model achieved better forecasting performance than the ARIMA model, with good generalization ability. The future forecasts also indicate that inflation is likely to remain relatively high during the period 2024–2030, within prediction intervals that reflect a degree of uncertainty. The study concludes that the proposed model provides an appropriate framework for forecasting inflation in unstable economic environments and supports the construction of more realistic scenarios for economic decision-making.

Keywords: Inflation rate - Economic forecasting - Deep learning - CNN–LSTM - Forecast uncertainty.



Copyright :Latakia University journal (formerly tishreen) -Syria, The authors retain the copyright under a CC BY-NC-SA 04

* PhD Student – Department of Statistics and Programming – Faculty of Economics – University of Latakia(formerly tishreen) – Latakia, Syria. aliadali@latakia-univ.edu.sy

**Associate Professor – Department of Statistics and Programming – Faculty of Economics – University of Latakia (formerly tishreen) – Latakia, Syria. aljubayli.ramia@latakia-univ.edu.sy

***Associate Professor, Department of Statistics and Information Systems, Faculty of Economics, University of Aleppo, Aleppo, Syria. m.maad.suliman@alepuniv.edu.sy

التنبؤ بمعدل التضخم في سورية للفترة 1961-2030 باستخدام النموذج الهجين CNN-LSTM

علي دالي *

د. راميا الجبيلي **

د. محمد معد سليمان ***

(تاريخ الإيداع 2 / 2 / 2026 قبل للنشر في 18 / 5 / 2026)

□ ملخص □

تستكشف هذه الدراسة تطور معدل التضخم في سورية والتنبؤ باتجاهاته المستقبلية حتى عام 2030 باستخدام النموذج الهجين CNN-LSTM. واعتمدت على بيانات سنوية للفترة 1961-2023، في سياق اقتصادي يتسم بالتقلب وعدم الخطية وتكرار الصدمات. وأظهرت نتائج التحليل الإحصائي أن السلسلة الزمنية لا تتبع التوزيع الطبيعي، وتتسم بالتواء موجب وتقلطح زائد، بما يشير إلى وجود قيم متطرفة وذيل سمكة، وهو ما يبرر استخدام نمذجة غير خطية. وقد جرى توحيد البيانات وإعادة تشكيلها باستخدام نافذة زمنية منزقة، ثم تقسيمها إلى عينة تدريب وعينة اختبار بنسبة 80% و 20% على التوالي. وأظهرت النتائج أن النموذج الهجين حقق أداءً تنبؤياً أفضل من نموذج ARIMA، مع قدرة جيدة على التعميم. كما أشارت التنبؤات المستقبلية إلى استمرار التضخم عند مستويات مرتفعة نسبياً خلال الفترة 2024-2030، ضمن فواصل تنبؤية تعكس درجة من عدم اليقين. وتبين الدراسة أن النموذج المقترح يوفر إطاراً مناسباً للتنبؤ بالتضخم في البيئات الاقتصادية غير المستقرة، ويدعم بناء سيناريوهات أكثر واقعية لصنع القرار الاقتصادي.

الكلمات المفتاحية: معدل التضخم - التنبؤ الاقتصادي - التعلم العميق - CNN-LSTM - عدم اليقين.



حقوق النشر : مجلة جامعة اللاذقية (تشرين سابقاً) - سورية، يحتفظ المؤلفون بحقوق النشر بموجب

الترخيص CC BY-NC-SA 04

* طالب دكتوراه - قسم الإحصاء والبرمجة - كلية الاقتصاد - جامعة اللاذقية (تشرين سابقاً) - اللاذقية، سورية.

aliadali@latakia-univ.edu.sy

** أستاذ مساعد - قسم الإحصاء والبرمجة - كلية الاقتصاد - جامعة اللاذقية (تشرين سابقاً) - اللاذقية، سورية.

aljubayli.ramia@latakia-univ.edu.sy

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

m.maad.suliman@alepuniv.edu.sy

1- مقدمة:

يُعدّ التضخم من أكثر المتغيرات الاقتصادية الكلية حساسية لما يخلّفه من آثار مباشرة في القوة الشرائية، وتخصيص الموارد، وتوزيع الدخل، وفاعلية السياستين النقدية والمالية، ولا سيما في الاقتصادات النامية التي تتسم باختلالات هيكلية وتتعرض لصدمات داخلية وخارجية متكررة. لذلك احتلّ التنبؤ بمعدلات التضخم مكانة محورية في الأدبيات الاقتصادية والتطبيقات القياسية، لأن دقة التنبؤ بهذا المتغير تمثل أداة أساسية لدعم صناع القرار في بناء سياسات استباقية تحد من التقلبات السعريّة وتخفف من آثارها السلبية في الاستقرار الاقتصادي الكلي. وقد اعتمدت الأدبيات التقليدية على نماذج السلاسل الزمنية الخطية، وفي مقدمتها نماذج ARIMA ومنهجية Box-Jenkins، التي أثبتت فاعلية نسبية في البيانات المستقرة ذات الأنماط المنتظمة، إلا أن كفاءتها التنبؤية تتراجع عندما تتسم السلاسل الزمنية بارتفاع اللاخطية، وتغير الأنظمة، ووجود انقطاعات أو تحولات هيكلية حادة [1].

وفي المقابل، شهدت السنوات الأخيرة توسعاً واضحاً في استخدام تقنيات التعلم العميق في التنبؤ الاقتصادي، نظراً لقدرتها على تمثيل العلاقات غير الخطية والنقاط الاعتماد الزمني المعقد من دون الحاجة إلى افتراضات تقييدية صارمة حول شكل السلسلة أو بنيتها الإحصائية. وفي هذا الإطار، برزت الشبكات العصبية التلافيفية CNN بوصفها أداة فعالة في استخراج الأنماط المحلية والسمات القصيرة الأجل من البيانات الزمنية، في حين أثبتت الشبكات العصبية ذات الذاكرة الطويلة قصيرة الأجل LSTM كفاءة عالية في تمثيل الاعتماد طويل الأجل ومعالجة مشكلة تلاشي التدرج، الأمر الذي مهدّ لتطوير نماذج هجينة تجمع بين مزايا الطريقتين [2][3]. وانطلاقاً من ذلك، يهدف هذا البحث إلى التنبؤ بمعدل التضخم في سورية بالاعتماد على بيانات سنوية تغطي المدة 1961-2023، مع استخدام النموذج الهجين CNN-LSTM لتوليد تنبؤات مستقبلية للفترة 2024-2030. ويأتي هذا التوجه في محاولة لتقديم إطار منهجي أكثر كفاءة في توصيف الديناميكية التضخمية في سورية، وتحسين القدرة على استشراف المسار المستقبلي للتضخم ضمن أفق زمني مستقبلي يمتد حتى عام 2030، وبما يسهم في إثراء الأدبيات التطبيقية وتوفير أداة كمية داعمة لصناع القرار في بيئة اقتصادية تتسم بارتفاع عدم اليقين.

1-1 مراجعة الدراسات السابقة:

تركز الدراسات الحديثة في مجال التنبؤ باستخدام نماذج التعلم العميق على عدد من القضايا المنهجية الحاسمة، وفي مقدمتها تنظيم النموذج، وقياس الدقة، وتقدير عدم اليقين، والتعامل مع محدودية حجم العينة. فقد أوضح Srivastava et al. (2014) أن آلية Dropout تؤدي دوراً جوهرياً في الحد من فرط المواءمة عبر إسقاط وحدات عصبية عشوائية أثناء التدريب، بما يحسن قدرة النموذج على التعميم خارج العينة [5]. ثم قدّم Gal and Ghahramani (2016) تطويراً أكثر عمقاً لهذا التصور عندما فسّروا Dropout بوصفه تقريباً بايزياً يتيح تقدير عدم اليقين التنبؤي، وهو جانب بالغ الأهمية في النماذج الاقتصادية التي تعمل في بيئات شديدة التقلب [6]. كما شدد Hyndman and Koehler (2006) على أن تقييم النماذج التنبؤية يجب ألا يعتمد على مؤشر منفرد، بل على حزمة متكاملة من المؤشرات مثل RMSE و MAPE و MSE و R^2 ، لأن كل مؤشر يبين بعداً مختلفاً من جودة الأداء [7]. وإلى جانب ذلك، تبرز أدبيات حديثة أهمية مراعاة تحديات العينات الصغيرة في تطبيقات التعلم العميق الاقتصادية، إذ إن محدودية المشاهدات الزمنية قد تقلل من كفاءة التدريب وتزيد حساسية النماذج لفرط

التخصيص، ما يجعل تنظيم النموذج وتقدير عدم اليقين عنصرين متلازمين مع مسألة الدقة التنبؤية، ولا سيما في السلاسل السنوية طويلة الأجل ذات الحجم المحدود نسبياً.

أما في أدبيات التنبؤ بالتضخم، فقد اتجهت الدراسات الحديثة بوضوح نحو استخدام نماذج التعلم الآلي والتعلم العميق بسبب قدرتها الأعلى على تمثيل اللاخطية والاعتماد الزمني المعقد في البيانات الاقتصادية. فقد بين Medeiros et al. (2021) أن خوارزميات التعلم الآلي تحقق مكاسب تنبؤية ملموسة مقارنة بالنماذج الخطية التقليدية عند التنبؤ بالتضخم في بيانات غنية بالبيانات [10]. كما أظهر Theoharidis et al. (2023) أن نماذج التعلم العميق تتمتع بمرونة عالية في التنبؤ بالتضخم، خاصة عند وجود تحولات هيكلية وأنماط غير خطية [8][15]. وذهب Barkan et al. (2023) إلى تطوير شبكات متكررة هرمية للتنبؤ بمكونات مؤشر أسعار المستهلك، مبينين أن تمثيل البنية متعددة المستويات للمؤشر يساهم في تحسين الدقة التنبؤية [9][17]. كذلك أكدت دراستا Almosova and Andresen (2023) و Paranhos (2025) أن الشبكات المتكررة، ولا سيما LSTM، أكثر قدرة على التقاط الديناميكيات غير الخطية للتضخم مقارنة بالنماذج القياسية [11][16]. وفي السياق نفسه، أوضحت دراسة Seo et al. (2025) أن دمج خصائص تفسيرية إضافية مثل البيانات المساندة يرفع من كفاءة التنبؤ بمؤشر الأسعار [12]، في حين بين Rygh et al. (2025) تفوق شبكات LSTM على بعض النماذج التقليدية في سياقات زمنية محددة [19]. وتدل هذه النتائج مجتمعة على أن تعقّد متغير التضخم من حيث اللاخطية، وعدم الاستقرار، وتعدد مصادر الصدمة، يبرر منهجياً استخدام نموذج هجين مثل CNN-LSTM يجمع بين استخراج السمات المحلية والذاكرة الزمنية طويلة الأجل.

أما في سورية، فقد تناولت الدراسات التضخم من زوايا تحليلية متعددة، غير أن معظمها اعتمد على النماذج القياسية التقليدية وركز على تفسير السلوك التضخمي أو محدّداته أكثر من تركيزه على بناء نماذج تنبؤية هجينة متقدمة. فقد بين Ahmed and Ismail (2024) وجود تباين متغير وخصائص عدم استقرار في معدل التضخم السوري باستخدام نماذج TGARCH [21] كما درس Nasra and Hidar (2024) أثر بعض المتغيرات الاقتصادية الكلية على التضخم في سورية باستخدام نموذج ARDL، مؤكدين وجود علاقات قصيرة وطويلة الأجل بين التضخم وبعض محدّداته الاقتصادية [22]. كذلك ناقش Idlibi and Fadel (2019) الأسباب والآثار الناشئة للتضخم في سورية، بما يوفر أساساً تفسيرياً مهماً لفهم النتائج التنبؤية ضمن سياق الاقتصاد السوري [23]، في حين تناول Othman et al. (2015) محدّدات التضخم خلال مرحلة سابقة، موضحين دور العوامل النقدية والاقتصادية الكلية في تفسير تحركاته [24]. وإلى جانب الأدبيات الأكاديمية، تؤكد تقارير مؤسسات دولية ووطنية مثل البنك الدولي وصندوق النقد الدولي ولجنة الأمم المتحدة الاقتصادية والاجتماعية لغربي آسيا أن الاقتصاد السوري خلال السنوات الأخيرة اتسم بارتفاع عدم اليقين، واختلالات العرض، وضغوط سعر الصرف، وتآكل القدرة الشرائية، وهي عوامل تجعل التضخم أكثر تقلباً وأصعب تنبؤاً بالأساليب الخطية التقليدية. أما على صعيد تطبيقات التعلم العميق في سورية، فقد أظهر Al-Jbeili et al. (2025) كفاءة نماذج LSTM في التنبؤ بسعر الصرف السوري [13]، كما استخدم Al-Jbeili et al. (2025) الشبكات التلافيفية CNN في التنبؤ بالنمو الاقتصادي طويل الأجل [14]. ومع أهمية هذه الجهود، فإنها لم تتجه مباشرة إلى بناء نموذج هجين للتنبؤ بالتضخم السوري نفسه، كما لم تدمج بصورة صريحة بين الدقة التنبؤية وتقدير عدم اليقين ومشكلة محدودية العينة السنوية.

التعليق على الدراسات السابقة ومساهمة البحث

يتضح من العرض السابق أن الأدبيات الدولية قدمت تقدماً مهماً في استخدام التعلم العميق للتنبؤ بالتضخم، كما أبرزت أهمية تنظيم النموذج، وتقييم الدقة بعدة مؤشرات، وتقدير عدم اليقين، في حين ركزت الدراسات السورية في معظمها على تفسير التضخم أو تقديره بنماذج تقليدية، مع ندرة واضحة في الدراسات التي تطبق نموذجاً هجيناً من نوع CNN-LSTM على سلسلة التضخم السورية نفسها. كما يظهر أن الفجوة لا تقتصر على نوع النموذج المستخدم فقط، بل تشمل أيضاً الجمع بين أربعة أبعاد منهجية في إطار واحد، هي تمثيل اللاخطية، والتعامل مع الاعتماد الزمني، وتقدير عدم اليقين التنبؤي، ومراعاة محدودية حجم العينة السنوية. ومن هنا تأتي مساهمة هذا البحث، إذ يسعى إلى سد هذه الفجوة عبر بناء نموذج هجين يركز على التنبؤ بمعدل التضخم في سورية باستخدام إطار CNN-LSTM، مدعوماً بأدوات تنظيم مناسبة، ومؤشرات تقييم متعددة، ومنظور احتمالي لعدم اليقين، بما يمنحه قيمة منهجية وتطبيقية في آن واحد.

2-1 أهداف البحث:

- 1- تحليل الخصائص الإحصائية للتضخم في سورية خلال الفترة 1961-2023، مع التركيز على فهم طبيعة التقلبات، واللاخطية، والاعتماد الزمني في السلسلة الزمنية.
- 2- تصميم وتقدير نموذج هجين يجمع بين الشبكات العصبية التلافيفية (CNN) والشبكات العصبية ذات الذاكرة الطويلة قصيرة الأجل (LSTM) بهدف التنبؤ بمعدل التضخم في سورية.
- 3- تقييم أداء النموذج الهجين في التنبؤ، وذلك من خلال مقارنة نتائج التدريب والاختبار باستخدام مجموعة من مؤشرات الأداء الإحصائية، للتحقق من كفاءته في التنبؤ.
- 4- إعداد توقعات مستقبلية للتضخم في سورية حتى عام 2030، بما يوفر أداة داعمة لصناع القرار عند صياغة السياسات الاقتصادية في البلاد.

3-1 مشكلة البحث:

تتبع مشكلة البحث من صعوبة التنبؤ الدقيق بمعدل التضخم في سورية في ظل بيئة اقتصادية اتسمت خلال العقود الماضية بارتفاع التقلبات، وتكرار الصدمات، وعدم الاستقرار الهيكلي، الأمر الذي جعل السلسلة الزمنية للتضخم أكثر تعقيداً من أن تفسر أو تُتنبأ بدقة كافية بالاعتماد على النماذج القياسية التقليدية وحدها. فقد أظهرت بيانات التضخم في سورية خصائص إحصائية معقدة تمثلت في التذبذب المرتفع، واللاخطية، واحتمال تغير النظام عبر الزمن، إلى جانب تأثير الصدمات الداخلية والخارجية في مساره، وهو ما يضعف من كفاءة النماذج الخطية التي تفترض الاستقرار أو العلاقات المنتظمة عبر الزمن. كما أن الاعتماد على نماذج لا تراعي البنية المركبة للاعتماد الزمني ولا تستطیع النقاط الأنماط غير الخطية قد يؤدي إلى انخفاض الدقة التنبؤية، ومن ثم يحد من فاعلية النتائج التي يمكن الاستناد إليها في دعم السياسة النقدية والتخطيط الاقتصادي. وفي ضوء ذلك، تبرز الحاجة إلى توظيف نماذج أكثر تقدماً قادرة على استيعاب الخصائص الديناميكية المعقدة للتضخم السوري، ولا سيما النماذج الهجينة في التعلم العميق التي تجمع بين استخراج السمات المحلية والذاكرة الزمنية طويلة الأجل. ومن هنا تتحدد مشكلة البحث في اختبار مدى قدرة النموذج الهجين CNN-LSTM على تحسين دقة التنبؤ بمعدل التضخم في سورية، بالاعتماد على البيانات التاريخية للفترة 1961-2023، وتوليد تنبؤات مستقبلية للفترة 2024-

2030. ويتمثل التساؤل الرئيس للبحث في الآتي: هل يسهم استخدام النموذج الهجين CNN-LSTM في تحسين دقة التنبؤ بمعدل التضخم في سورية؟ وينبثق عن هذا التساؤل الرئيس عدد من التساؤلات الفرعية، هي:

- 1- ما أهم الخصائص الإحصائية والزمنية التي تتسم بها سلسلة التضخم في سورية خلال فترة الدراسة؟
- 2- هل يحقق النموذج الهجين CNN-LSTM دقة تنبؤية أعلى من بعض النماذج التقليدية المستخدمة في التنبؤ بالسلاسل الزمنية ARIMA؟
- 3- ما المسار المتوقع لمعدل التضخم في سورية خلال الفترة 2024-2030 في ظل التنبؤات المستخرجة من النموذج، وما حدود عدم اليقين المرتبطة بها؟

4-1 أهمية البحث:

تكمن أهمية البحث في إثراء أدبيات التنبؤ الاقتصادي في البيانات غير المستقرة، وتطوير منهجية لتقدير عدم اليقين التنبؤي، وتقديم إطار منهجي قابل للتكرار والتطوير، إلى جانب تعزيز إدارة المخاطر المرتبطة بالتقلبات السعرية، ودعم تطوير أنظمة الإنذار المبكر للتضخم، وطرح نموذج قابل للتطبيق في ظل محدودية البيانات، فضلاً عن الإسهام في دعم التخطيط الاقتصادي طويل الأجل.

5- منهجية البحث:

اعتمد البحث على المنهج الوصفي التحليلي والمنهج القياسي والاستدلالي، في إطار يجمع بين تحليل السلاسل الزمنية والتعلم العميق، بهدف دراسة سلوك معدل التضخم في سورية والتنبؤ بمساره المستقبلي. واستندت الدراسة إلى بيانات سنوية لمعدل التضخم خلال الفترة 1961-2023، أي ما مجموعه 63 مشاهدة سنوية، وهي عينة صغيرة نسبياً بالنسبة إلى نماذج التعلم العميق، الأمر الذي يستدعي تفسير النتائج بحذر، رغم ملاءمتها لطبيعة البيانات الاقتصادية المتاحة. بدأ التحليل بالإحصاءات الوصفية ودوال الارتباط الذاتي والذاتي الجزئي ACF و PACF للكشف عن خصائص السلسلة الزمنية من حيث التقلب والاعتماد الزمني، ثم أعيدت صياغة السلسلة في إطار تعلم إشرافي باستخدام نافذة زمنية منزقة، مع تقسيم البيانات تاريخياً إلى عينة تدريب بنسبة 80% وعينة اختبار بنسبة 20%.

جرى بناء وتقدير النموذج الهجين CNN-LSTM باستخدام Python ضمن بيئة Jupyter Notebook بالاعتماد على مكتبات NumPy و Pandas و Matplotlib و Statsmodels و TensorFlow/Keras. كما تمت مقارنة أداء النموذج الهجين بنموذج خطي قياسي من نوع ARIMA بهدف التحقق من مدى تحسن الدقة التنبؤية. وللمحد من فرط المواءمة، استُخدمت تقنيات Dropout والإيقاف المبكر Early Stopping، مع توثيق عملية ضبط المعلمات الفائقة من خلال اختبار بدائل متعددة واختيار التركيبة التي حققت أفضل أداء، واستُخدمت مؤشرات RMSE و MSE و MAPE و R^2 لتقييم دقة النموذج في مرحلتي التدريب والاختبار، مع احتساب MAPE بالاعتماد على القيم الأصلية الفعلية بعد إعادة تحويل القيم المتنبأ بها من المقياس المعياري إلى مقياسها الأصلي لضمان قابلية التفسير الاقتصادي. وأخيراً، أنجزت التنبؤات المستقبلية حتى عام 2030 مع تقدير فترات عدم اليقين باستخدام أسلوب Monte Carlo Dropout.

6- متغيرات البحث:

يقتصر البحث على متغير اقتصادي رئيسي يتمثل في معدل التضخم في سورية، بوصفه يعكس مستوى التغير العام في الأسعار ويجسد حالة الاستقرار النقدي والاقتصادي خلال الفترة المدروسة. وقد جرى اختيار هذا المتغير لأهميته البالغة في تقييم الأداء الاقتصادي وصياغة السياسات النقدية والمالية، ولا سيما في الاقتصادات التي تتسم بتقلبات سعرية مرتفعة وعدم استقرار هيكلي.

7- فرضيات البحث:

- 1- يتفوق النموذج الهجين CNN-LSTM على نموذج ARIMA في دقة التنبؤ بمعدل التضخم في سورية، من خلال تحقيق قيم أقل لكل من RMSE و MSE و MAPE، وقيمة أعلى لمعامل التحديد R^2 .
- 2- يسهم النموذج الهجين CNN-LSTM في تقدير المسار المستقبلي لمعدل التضخم في سورية حتى عام 2030 من خلال تقديم تنبؤات نقطية وفترات عدم يقين تدعم التفسير الاقتصادي للنتائج.

8- المناقشة والنتائج:

8-1 الإطار النظري والإحصائي للنموذج:

يمثل متغير الدراسة سلسلة زمنية أحادية سنوية لمعدل التضخم في سورية y_t خلال الأعوام 1961 إلى 2023. الهدف هو بناء نموذج يتعلم ديناميكية الاعتماد الزمني واللاخطية ثم ينتج تنبؤات حتى 2030. تبدأ الخطوات بالتحليل الوصفي ورسم المسار الزمني والتوزيع لفهم السلوك العام ووجود قيم متطرفة وتغير التباين. ثم تستخدم دالتي الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لتشخيص بنية الاعدادات الزمنية ودرجة الذاكرة في السلسلة ولتأكيد أن السلسلة تحتوي اعتماداً زمنياً يمكن تعلمه. هذا منطق Box Jenkins في تشخيص السلاسل عبر ACF و PACF قبل النمذجة التنبؤية [1].

$$y_t = INF_t$$

بعد ذلك يعاد صياغة مشكلة التنبؤ كسؤال تعلم إشرافي من نوع many to one عبر نافذة منزلقة بطول L سنة. كل ملاحظة تدريبية تعتمد على آخر L قيمة من التضخم وتنتج قيمة السنة التالية. هذا يحول السلسلة إلى أزواج مدخلات ومخرجات مع الحفاظ على الترتيب الزمني ثم يقسم تاريخياً بنسبة 80 20% لتجنب تلاشي المعلومات من المستقبل إلى الماضي.

$$x_t = [y_{t-L}, y_{t-L+1}, \dots, y_{t-1}]^T$$

$$\hat{y}_t = f_{\theta}(x_t)$$

تستخدم عملية المعايرة Min Max لتوحيد مدى القيم قبل التدريب لأن الشبكات العصبية حساسة لمقاييس المتغيرات ولأن دوال التنشيط والتدرج تعمل بصورة أكثر استقراراً عندما تكون القيم ضمن مجال محدود. بعد المعايرة ينفذ الجزء الالتقافي CNN 1D لاستخراج سمات محلية من النافذة الزمنية مثل القفزات قصيرة الأجل والانعكاسات والقمم. فكرة الالتفاف تقوم على مرشح متحرك يطبق نفس الأوزان عبر الزمن لاكتشاف أنماط متكررة مع ثبات جزئي للتحويلات. هذا هو جوهر الشبكات الالتقافية كما عرضته الأدبيات التأسيسية للـ CNN [2].

$$h_{t,k} = \sigma(\sum_{i=0}^{K-1} w_{t,i} x_{t,i} + b_{t,k})$$

بعد استخراج السمات، يمر التمثيل إلى طبقة LSTM كي تبين الاعتماد طويل الأجل وتتعامل مع مشكلة تلاشي التدرج التي تعيق الشبكات المتكررة التقليدية. LSTM تبني حالة خلية c_t ومساراً خفياً h_t عبر بوابات نسيان وإدخال وإخراج تتحكم بمقدار حفظ المعلومات أو محوها أو تمريرها. هذا هو التعريف الأصلي لـ LSTM [3]:

$$\begin{aligned}f_t &= \sigma(W_f [h_{t-1}, z_t] + b_f) \\i_t &= \sigma(W_i [h_{t-1}, z_t] + b_i) \\g_t &= \tanh(W_g [h_{t-1}, z_t] + b_g) \\c_t &= f_t \odot c_{t-1} + i_t \odot g_t \\o_t &= \sigma(W_o [h_{t-1}, z_t] + b_o) \\h_t &= o_t \odot \tanh(c_t)\end{aligned}$$

يمثل z_t هنا السمات الخارجة من CNN بعد التجميع والإسقاط Dropout. منطق المزج LSTM CNN أن CNN يوضح البنى قصيرة الأجل ويضغطها في سمات أكثر تمييزاً بينما LSTM يتعامل مع تطور هذه السمات عبر الزمن.

يرمز التعبير $\odot$ إلى الضرب العنصري بين متجهين أو مصفوفتين متماثلتي الأبعاد، بحيث يتم ضرب كل عنصر في المتجه الأول بنظيره المناظر في المتجه الثاني، من دون تنفيذ ضرب مصفوفي اعتيادي. ويستخدم هذا الرمز كثيراً في نماذج التعلم العميق لتمثيل عمليات الانتقاء أو التصفية الجزئية للقيم. هذا النوع من النماذج الهجينة استخدم بنجاح في التنبؤ بسلاسل مالية وزمنية مختلفة لأنه يجمع بين استخراج السمات والذاكرة [4]. يدرّب النموذج عبر تقليل خسارة متوسط مربع الخطأ على بيانات التدريب مع التحقق عبر عينة تحقق داخل التدريب. اختيار MSE يتسق مع كون المسألة انحداراً عديداً ولأنه يقيد الأخطاء الكبيرة بقوة. يستخدم الإيقاف المبكر Early Stopping لتقليل فرط الملاءمة مع بيانات التدريب عبر التوقف عند أفضل أداء تحقق:

$$L(\theta) = (1/N) \sum_{t=1}^N (y_t - \hat{y}_t)^2$$

يستخدم Dropout كتتنظيم Regularization عبر إسقاط عشوائي لوحداث أثناء التدريب مما يقلل الاعتماد المتبادل غير المرغوب بين العصبونات ويحسن قابلية التعميم. هذا هو التعريف القياسي لـ Dropout [5]:

$$\begin{aligned}r_t &\sim \text{Bernoulli}(p) \\ \tilde{h} &= r \odot h\end{aligned}$$

لإضافة عدم اليقين في التنبؤات حتى 2030 يمكن استخدام Monte Carlo Dropout عبر تفعيل Dropout وقت التنبؤ وتنفيذ S تمريرات مستقلة ثم اشتقاق متوسط تنبؤ وفواصل تنبؤية كمجالات كوانتيل. هذا يتوافق مع تفسير Dropout كتقريب بايزي لعدم اليقين في نماذج التعلم العميق [6].

$$\begin{aligned}\hat{y}_t^{\{s\}} &= f_{\theta}(x_t; m^{\{s\}}) \\\hat{\mu}_t &= (1/S) \sum_{s=1}^S \hat{y}_t^{\{s\}} \\PI_t^{\{95\}} &= [Q_{0.025}(\hat{y}_t^{\{s\}}), Q_{0.975}(\hat{y}_t^{\{s\}})]\end{aligned}$$

تقييم النموذج يتم منفصلاً لمرحلة التدريب ومرحلة الاختبار باستخدام مؤشرات خطأ ودقة تفسيرية تشمل MSE و RMSE يقيسان حجم الخطأ بوحدات المتغير بينما MAPE يقيس الخطأ النسبي. R^2 يوضح نسبة التباين المفسر بالتنبؤات. هذه المؤشرات شائعة في أدبيات دقة التنبؤ [7]:

$$\begin{aligned}MSE &= (1/n) \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\RMSE &= \sqrt{MSE} \\MAPE &= (100/n) \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \\R^2 &= 1 - [\sum_{i=1}^n (y_i - \hat{y}_i)^2] / [\sum_{i=1}^n (y_i - \bar{y})^2]\end{aligned}$$

8-2 الإحصاءات الوصفية والرسوم البيانية:


الجدول (1): الإحصاءات الوصفية لمعدل التضخم في سورية خلال الفترة 1961-2023

Statistic	Value
Count	63
Mean	17.75890
Median	10.32637
Minimum	-8.354126
25th Percentile	4.226813
75th Percentile	22.97231
Maximum	120.3234
Standard Deviation (Sample)	25.82674
Skewness	2.835397
Kurtosis (Excess)	8.782637
Jarque-Bera Statistic	248.7177
Jarque-Bera p-value	0.000

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

يبين الجدول (1) أن معدل التضخم في سورية خلال الفترة 1961-2023 اتسم بتباين مرتفع وعدم توزيع طبيعي واضح. وبالنسبة لقيم المؤشرات فهي تتبع وحدة قياس المتغير كنسبة مئوية حيث بلغ المتوسط الحسابي 17.759% والوسيط 10.326%، في حين تراوحت القيم بين -8.354% و 120.323%. كما بلغ الانحراف المعياري 25.827 نقطة مئوية، مما يدل على ارتفاع تشتت السلسلة. وظهر معامل الالتواء بقيمة موجبة مقدارها 2.835، بما يشير إلى التواء التوزيع نحو اليمين، في حين بلغ معامل التفلطح الزائد 8.783، وهو ما يدل على أن التوزيع أكثر حدة وذو ذيول أثخن مقارنة بالتوزيع الطبيعي. كذلك أظهرت نتائج اختبار Jarque-Bera عدم التوزيع الطبيعي للسلسلة إحصائياً عند المستويات المعنوية 5%، وتوضيح شكل التوزيع وتطور المتغير:

Inflation Rate Time Path and Distribution




الشكل (1): المسار الزمني والتوزيع الاحصائي لمعدل التضخم في سورية خلال الفترة 1961-2023

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

يعرض الشكل (1) المسار الزمني لمعدل التضخم في سورية إلى جانب توزيعه الإحصائي. ويظهر المسار الزمني أن السلسلة تتسم بتقلبات متفاوتة عبر الزمن، مع تسجيل سنوات شهدت ارتفاعات كبيرة في معدل التضخم مقارنة

بسنوات أخرى أكثر استقراراً نسبياً. كما يبين الشكل وجود قمة مرتفعة تمثل السنة التي سجلت أعلى قيمة في العينة، والبالغة 120.323%، وهي قيمة تعكس حالة تضخم استثنائية ضمن فترة الدراسة. أما في جزء التوزيع، فيظهر الامتداد الأكبر نحو القيم المرتفعة، وهو ما ينسجم مع الالتواء الموجب المحسوب إحصائياً، كما يبدو أن التوزيع لا يأخذ الشكل الجرسى الطبيعي، وهو ما يتوافق مع نتائج اختبار Jarque-Bera.

تشير النتائج السابقة إلى أن سلوك التضخم في سورية لم يكن منتظماً خلال فترة الدراسة، بل اتسم بدرجات متفاوتة من التقلب مع ظهور سنوات شهدت زيادات سريعة حادة. كما أن وجود قيمة عظمى مرتفعة جداً مقارنة بالمتوسط، إلى جانب الالتواء الموجب والتقلطح الزائد، يعكس أن السلسلة تتضمن مشاهدات متطرفة وخصائص توزيع غير طبيعي. وتعد هذه السمات مهمة من الناحية المنهجية، لأنها تشير إلى أن سلسلة التضخم تتسم بعدم الاستقرار النسبي وبارتفاع الحساسية للصدمات، وهو ما يدعم استخدام أدوات تحليل ونمذجة قادرة على التعامل مع اللاخطية والتقلبات المرتفعة. وتحليل دوال الارتباط نجد:



الشكل (2): دالة الارتباط الذاتي والذاتي الجزئي لمعدل التضخم

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

الشكل (2) يبين دالتي ACF و PACF ويُظهر اعتماد زمني في التضخم عند الإبطاءات الأولى، ما يعني أن تضخم سنة معينة يرتبط بقيم السنوات القريبة السابقة. هذا النمط يدعم فرضية الاستمرارية التضخمية، حيث تؤدي آليات التوقعات والأسعار التعاقدية وتمرير الصدمات إلى بقاء الأثر عبر أكثر من فترة. وجود ارتباطات معنوية عند بدايات الإبطاء ثم تلاشيها تدريجياً يشير إلى ذاكرة قصيرة إلى متوسطة، وهو ما يبرر تحويل السلسلة إلى نافذة زمنية منزقة داخل نموذج CNN-LSTM كي تبين العلاقات القريبة والبعيدة ضمن تمثيل واحد قبل الانتقال إلى تقدير النموذج.

3-8 تقدير النموذج وتقييمه


الجدول (2): نتائج دالة الخسارة للتدريب والتحقق في نموذج CNN-LSTM عبر الجُعب المختارة

Epoch	Training Loss (MSE)	Validation Loss (MSE)	Learning Rate
12	0.004917	0.005075	0.0005
13	0.004518	0.004900	0.0005
14	0.004915	0.004745	0.0005
15	0.004315	0.004715	0.0005
16	0.004525	0.004819	0.0005
17	0.004491	0.004926	0.0005
18	0.004303	0.004972	0.0005
19	0.004614	0.004956	0.0005

20	0.005220	0.004950	0.0005
21	0.004631	0.004830	0.0005
Best Validation Loss (MSE)			0.0045693
Best Epoch			2

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

الجدول (2) يلخص سلوك دالة الخسارة أثناء التدريب والتحقق، إذ تتراوح قيمة خسارة التدريب بين 0.004 و 0.005 تقريباً في الحقب المعروضة، بينما تتراوح خسارة التحقق حول 0.005، ما يشير إلى تقارب المنحنيين واستقرار عملية التعلم دون تقلب واضح. أفضل قيمة تحقق بلغت 0.004569 عند الحقة 2، وهو ما يدل بأن النموذج شرح نمط أولي سريع ثم لم يحقق تحسن كبير لاحق، ما يتسق مع بيانات سنوية محدودة الحجم ومع خصائص السلسلة تحتوي صدمات كبيرة. هذا يمهّد منطقياً لقراءة منحنيات التدريب في الشكل (3) وتفسير سلوك التقارب.



الشكل (3): منحنيات خسارة التدريب والتحقق لنموذج CNN-LSTM عبر الحقب

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

الشكل (3) يوضح منحنيات خسارة التدريب وخسارة التحقق عبر الحقب ويظهر هبوط سريع في البداية ثم استقرار حول مجال ضيق قرب 0.005، ما يعكس تقارب مبكر وتعلم مستقر دون اتساع فجوة كبيرة بين التدريب والتحقق. اقتراب المنحنيين يعني أن فرط المواءمة ليس السمة الغالبة في هذه المرحلة، بينما التسطح المبكر يعكس بأن القيود الأساسية تأتي من طبيعة البيانات نفسها ومن صدماتها البنوية أكثر من كونها من عدد الحقب. هذا يهيئ للانتقال إلى تحليل بنية النموذج في الجدول (3) لفهم أين تتركز القدرة التمثيلية:

الجدول (3): معلمات النموذج الهجين CNN-LSTM وعدد الأوزان القابلة للتقدير

Layer Index	Layer Name	Layer Type	Number of Parameters	Weight Arrays
0	conv1d	Convolutional 1D	256	2
1	max_pooling1d	Max Pooling 1D	0	0
2	dropout	Dropout	0	0
3	lstm	Long Short-Term Memory (LSTM)	33,024	3
4	dropout_1	Dropout	0	0
5	dense	Fully Connected (Dense)	2,080	2

2	33	Output Dense	dense_1	6
---	----	--------------	---------	---

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

الجدول (3) يبين توزيع معلمات النموذج الهجين على طبقاته، حيث تمتلك طبقة LSTM عدد معلمات 33,024 مقارنة بـ 256 في طبقة Conv1D و 2,080 في الطبقة الكثيفة، ما يعني أن الجزء الأكبر من القدرة التمثيلية موجود في آلية الذاكرة الزمنية. اقتصادياً هذا منطقي لأن التضخم سلسلة ذات اعتماد زمني وتراكم صدمات، فحتاج ذاكرة أكبر لتمثيل انتقال الأثر بين السنوات. في المقابل، تقوم طبقة CNN بدور استخراج سمات محلية قصيرة الأجل من النافذة الزمنية قبل أن تتولى LSTM تلخيصها عبر الزمن، وهو ما ينسجم مع تصميم النموذج ويوفر تمهيد لتقييم الأداء الفعلي في الجدول (4).

4-8 النتائج والتنبؤ

الجدول (4): مؤشرات أداء نموذج CNN-LSTM لمرحلتي التدريب والاختبار

النموذج	Dataset	RMSE	MAPE (%)	MSE	R ² معامل التحديد %
CNN-LSTM	Training	9.880968	1.895693	7.633530	85.7103
CNN-LSTM	Testing	9.883186	0.758255	8.332275	87.8289
ARIMA(1,1)	Training	11.246531	2.438917	8.914268	80.1462
ARIMA(1,1)	Testing	12.018744	1.126384	9.785441	76.3915

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

يبين الجدول (4) أن النموذج الهجين CNN-LSTM تفوق على نموذج ARIMA(1,1) في مرحلتي التدريب والاختبار وفق جميع مؤشرات الأداء المعتمدة. فقد سجل قيمة أقل لكل من RMSE و MSE و MAPE، إلى جانب قيم أعلى لمعامل R². ففي عينة الاختبار، بلغت قيمة RMSE للنموذج الهجين 9.883 مقابل 12.019 لنموذج ARIMA(1,1)، وبلغت قيمة MAPE 0.758% مقابل 1.126%، في حين بلغ معامل R² نحو 0.878 مقابل 0.764. وتشير هذه النتائج إلى أن النموذج الهجين يتمتع بدقة تنبؤية أعلى وقدرة أفضل على تمثيل السلوك الديناميكي لمعدل التضخم في سورية. ويُفسر معامل R² هنا بوصفه مؤشراً مكملاً لجودة المطابقة بين القيم الفعلية والمتنبأ بها، ويمكن التعبير عنه كنسبة مئوية تعادل 87.8% في الاختبار، مع الإشارة إلى اختلافه عن التفسير في الانحدار التقليدي، وهو ما ينسجم مع ما توصلت إليه الأدبيات التي أكدت أن نماذج التعلم العميق الهجينة قادرة على تحسين التنبؤ بالتضخم في وجود لاختية واعتماد زمني مقارنة بالنماذج التقليدية [8][10][11]. وفي هذا السياق، تتقاطع هذه النتائج مع توجه Medeiros في إبراز مكاسب التعلم الآلي في بيانات البيانات الغنية [10]، ومع ما قدمه Theoharidis من دليل على فاعلية النماذج العميقة في التنبؤ بالتضخم [8]، أما MAPE فقد سجل 1.896% في التدريب و 0.758% في الاختبار، وهي قيم منخفضة تعكس دقة نسبية عالية، وتتفق مع توصيات Hyndman وآخرون بضرورة الاعتماد على أكثر من مؤشر لقياس الدقة وعدم الاكتفاء بمقياس واحد [7]، إذ يدعم اتساق RMSE و MSE و R² هذه الخلاصة ويعزز الثقة بأن الدقة ليست نتيجة انحياز مؤشر.

الجدول (5): تنبؤات معدل التضخم في سورية مع فترات عدم اليقين 95% للفترة 2030-2024

Year	Forecast Mean	Lower 95% Prediction Interval	Upper 95% Prediction Interval
2024	38.066525%	26.727600%	49.095608%
2025	42.401291%	29.828894%	53.546917%
2026	44.366230%	31.537180%	55.316483%
2027	44.563465%	32.118668%	55.613216%
2028	43.490417%	31.843340%	54.698910%
2029	43.588085%	31.398523%	54.554214%
2030	41.374737%	29.585037%	51.826546%

المصدر: إعداد الباحثين بالاعتماد على بيانات البنك الدولي ونتائج التحليل باستخدام Python

الجدول (5) يعرض المتوسطات التنبؤية لمعدل التضخم في سورية خلال الفترة 2024-2030، إلى جانب حدود فاصل عدم اليقين التنبؤي عند مستوى 95% لكل سنة. وتمثل القيم المدرجة في عمودي 95% Lower و Upper 95% الحدين الأدنى والأعلى للمجال المحتمل الذي قد تقع ضمنه القيمة المستقبلية لمعدل التضخم، ولا تمثل مجالات ثقة للمتوسط بالمعنى التقليدي، كما لا تمثل انحرافات معيارية متوقعة، وإنما تعبر عن فواصل تنبؤية احتمالية ناتجة عن عدم اليقين المرتبط بعملية التنبؤ. وبما أن المتغير المدروس هو معدل التضخم، فإن المتوسطات التنبؤية وحدودها الدنيا والعليا جميعها تُعبر عنها بالنسبة المئوية. ووفقاً لنتائج الجدول، يرتفع المتوسط التنبؤي من 38.067% في عام 2024 إلى 44.563% في عام 2027، ثم يميل إلى الاستقرار النسبي قبل أن ينخفض إلى 41.375% في عام 2030. كما تظهر الفواصل التنبؤية اتساعاً ملحوظاً، إذ تراوح نطاق التنبؤ في عام 2024 بين 26.728% و 49.096%، وفي عام 2027 بين 32.119% و 55.613%، وهو ما يعكس وجود درجة معتبرة من عدم اليقين حول المسار المستقبلي للتضخم. وعليه فإن القيمة التنبؤية تقرأ ضمن المجال الاحتمالي المحيط بها، بما يجعل التفسير الاقتصادي أكثر واقعية عند استخدام النتائج في دعم القرار.

9- الاستنتاجات والتوصيات:

1-6 الاستنتاجات:

- 1- أظهرت نتائج التحليل الوصفي أن سلسلة التضخم في سورية تتسم بعدم الانتظام وارتفاع التقلب وابتعادها عن خصائص التوزيع الطبيعي، وهو ما يدل على أن السلسلة لا تعكس سلوكاً خطياً مستقراً عبر الزمن. وتؤكد هذه النتيجة أن توصيف التضخم السوري يتطلب أدوات قادرة على التعامل مع اللاخطية والتغير في شدة التقلب، الأمر الذي يبرر منهجياً استخدام نموذج هجين من التعلم العميق بدلاً من الاكتفاء بالنماذج الخطية التقليدية.
- 2- بينت نتائج المقارنة أن النموذج الهجين CNN-LSTM قدم أداءً تنبؤياً أفضل من نموذج ARIMA، وهو ما يدل على أن دمج استخراج الأنماط المحلية مع الذاكرة الزمنية طويلة الأجل يوفر تمثيلاً أكثر كفاءة للديناميكية التضخمية في سورية. ويعني ذلك أن النموذج المقترح لا يقتصر على كونه تطبيقاً برمجياً، بل يمثل إطاراً عملياً يمكن الاستفادة منه في تحسين جودة التنبؤ في البيانات الاقتصادية التي تتسم بالتقلب وعدم الاستقرار.
- 3- أظهرت النتائج أن النموذج الهجين يتمتع بدرجة مقبولة من الاستقرار في التعميم، إذ لم تظهر فروق حادة بين أداء التدريب وأداء الاختبار. ويشير ذلك إلى أن النموذج استطاع استيعاب النقاط الإشارات الأساسية في السلسلة الزمنية من دون أن يكون أدائه محصوراً داخل العينة فقط، وهو ما يعزز إمكانية استخدامه بوصفه أداة تنبؤية مساندة في التحليل الاقتصادي التطبيقي.
- 4- أوضحت التنبؤات المستقبلية أن التضخم في سورية مرشح للاستمرار عند مستويات مرتفعة خلال الأفق الزمني المتوقع حتى عام 2030، بما يعكس استمرار الضغوط السعرية في الاقتصاد السوري وعدم عودة المسار التضخمي إلى مستويات منخفضة في الأجل القريب. وتحمل هذه النتيجة دلالة اقتصادية مهمة، مفادها أن الضغوط التضخمية تبدو ذات طابع ممتد لا مؤقت، وهو ما يستلزم معالجة أعمق من التدخلات قصيرة الأجل.

5- بينت فواصل عدم اليقين المصاحبة للتنبؤات أن المسار المستقبلي للتضخم لا ينبغي تفسيره بوصفه قيمة نقطية ثابتة، بل ضمن مجالات احتمالية محتملة. ويعني ذلك أن النموذج المقترح يقدم لصانع القرار أداة أكثر واقعية، لأنها لا تعرض فقط المسار المتوقع، بل تبيّن أيضاً درجة عدم اليقين المحيطة به، وهو ما يزيد من فاعلية استخدامه في بناء سيناريوهات اقتصادية بديلة.

6-2 التوصيات:

- ✓ يوصى باعتماد النموذج الهجين *CNN-LSTM* بوصفه أداة مساندة في التنبؤ الدوري بمعدل التضخم في سورية، مع تحديثه سنوياً كلما توفرت بيانات جديدة، بما يسمح بتحسين دقة التنبؤ ومتابعة تغير المسار التضخمي بصورة مستمرة.
- ✓ يوصى بعدم الاكتفاء بالقيم التنبؤية النقطية عند دعم القرار الاقتصادي، بل اعتماد الفواصل التنبؤية المصاحبة لها عند إعداد السيناريوهات النقدية والمالية، لأن ذلك يوفرّ تقديراً أكثر واقعية لحجم المخاطر المرتبطة بالتضخم المتوقع.
- ✓ يوصى باستخدام النموذج المقترح ضمن نظام إنذار مبكر لرصد الضغوط التضخمية، بحيث تُفسّر الارتفاعات المتوقعة ضمن حدودها التنبؤية على أنها إشارات استباقية تستدعي مراجعة أدوات السياسة النقدية والتجارية والتمويلية قبل تفاقمها.
- ✓ يوصى بإجراء مقارنات دورية بين أداء النموذج الهجين والنماذج القياسية التقليدية مثل *ARIMA*، للتأكد من استمرار كفاءة النموذج المقترح وعدم تراجع قدرته التنبؤية عند تغير خصائص السلسلة الزمنية مستقبلاً.

References:

- [1] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, "Time Series Analysis: Forecasting and Control," Hoboken, NJ: **John Wiley & Sons**, 5th ed, 2015.
- [2] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," **Proceedings of the IEEE**, vol. 86, no. 11, pp. 2278–2324, 1998.
- [3] S. Hochreiter and J. Schmidhuber, "Long short-term memory," **Neural Computation**, vol. 9, no. 8, pp. 1735–1780, 1997.
- [4] I. E. Livieris, E. Pintelas, and P. Pintelas, "A CNN–LSTM model for gold price time-series forecasting," **Neural Computing and Applications**, vol. 32, no. 23, pp. 17351–17360, 2020.
- [5] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," **Journal of Machine Learning Research**, vol. 15, pp. 1929–1958, 2014.
- [6] Y. Gal and Z. Ghahramani, "Dropout as a Bayesian approximation: representing model uncertainty in deep learning," **Proceedings of the 33rd International Conference on Machine Learning (ICML 2016)**, vol. 48, pp. 1050–1059, 2016.
- [7] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," **International Journal of Forecasting**, vol. 22, no. 4, pp. 679–688, 2006.
- [8] A. F. Theoharidis, D. A. Guillén, and H. F. Lopes, "Deep learning models for inflation forecasting," **Applied Stochastic Models in Business and Industry**, vol. 39, no. 3, pp. 447–470, 2023.
- [9] O. Barkan, J. Benchimol, I. Caspi, E. Cohen, A. Hammer, and N. Koenigstein, "Forecasting CPI inflation components with hierarchical recurrent neural networks," **International Journal of Forecasting**, vol. 39, no. 3, pp. 1145–1162, 2023.

- [10] M. C. Medeiros, G. F. R. Vasconcelos, Á. Veiga, and E. Zilberman, "Forecasting inflation in a data-rich environment: the benefits of machine learning methods," **Journal of Business and Economic Statistics**, vol. 39, no. 1, pp. 98–119, 2021.
- [11] A. Almosova and N. Andresen, "Nonlinear inflation forecasting with recurrent neural networks," **Journal of Forecasting**, vol. 42, no. 2, pp. 240–259, 2023.
- [12] I. Seo, M. Kim, J. W. Kim, and B. Jang, "Accurate total consumer price index forecasting with data augmentation, multivariate features, and sentiment analysis: a case study in Korea," **PLOS ONE**, vol. 20, no. 5, e0321530, 2025.
- [13] R. Al-Jbeili, M. M. Suleiman, and A. Dali, "Using deep learning LSTM models optimized with the ADAM algorithm to forecast the exchange rate in Syria," **Tartous University Journal for Research and Scientific Studies (Economic and Legal Sciences Series)**, (in Arabic) vol. 9, no. 6, 2025.
- [14] R. Al-Jbeili, M. M. Suleiman, and A. Dali, "Forecasting economic growth in Syria using convolutional neural networks (CNN) for the period 1961–2023," **Tartous University Journal for Research and Scientific Studies (Economic and Legal Sciences Series)**, (in Arabic) vol. 9, no. 7, 2025.
- [15] A. F. Theoharidis, D. A. Guillén, and H. F. Lopes, "Deep learning models for inflation forecasting," **Applied Stochastic Models in Business and Industry**, vol. 39, no. 3, pp. 447–470, 2023.
- [16] L. Paranhos, "Predicting inflation with recurrent neural networks," **International Journal of Forecasting**, in press, 2025.
- [17] O. Barkan, J. Benchimol, I. Caspi, E. Cohen, A. Hammer, and N. Koenigstein, "Forecasting CPI inflation components with hierarchical recurrent neural networks," **International Journal of Forecasting**, vol. 39, no. 3, pp. 1145–1162, 2023.
- [18] M. C. Medeiros, G. F. R. Vasconcelos, Á. Veiga, and E. Zilberman, "Forecasting inflation in a data-rich environment: the benefits of machine learning methods," **Journal of Business and Economic Statistics**, vol. 39, no. 1, pp. 98–119, 2021.
- [19] T. Rygh, C. Vaage, S. Westgaard, and P. E. d. Lange, "Inflation forecasting: LSTM networks vs. traditional models for accurate predictions," **Journal of Risk and Financial Management**, vol. 18, no. 7, art. no. 365, 2025.
- [20] C. Yang and S. Guo, "Inflation prediction method based on deep learning," **Computational Intelligence and Neuroscience**, vol. 2021, pp. 1–6, 2021.
- [21] A. A. Ahmed and R. S. Ismail, "Modeling the inflation rates in Syria using the TGARCH model for the period 2016–2021," **Tishreen University Journal for Research and Scientific Studies: Economic and Legal Sciences Series**, (in Arabic) vol. 45, no. 6, pp. 137–155, 2024.
- [22] Z. A. Nasra and I. Hidar, "Using the autoregressive distributed lag (ARDL) model to study the impact of some economic variables on the inflation rate in Syria during the period 2000–2022," **Tishreen University Journal for Research and Scientific Studies: Economic and Legal Sciences Series**, (in Arabic) vol. 46, no. 1, pp. 131–150, 2024.
- [23] M. Idlibi and H. M. Fadel, "Emerging causes and effects of inflation in Syria," **Tishreen University Journal for Research and Scientific Studies: Economic and Legal Sciences Series**, (in Arabic) vol. 41, no. 6, pp. 914–949, 2019.
- [24] S. Othman, G. Abbas, and A. Khudour, "Determinants of inflation in Syria during the period 1990–2010," **Tishreen University Journal for Research and Scientific Studies: Economic and Legal Sciences Series**, (in Arabic) vol. 37, no. 2, pp. 281–295, 2015.