استخدام نماذج التعلم الآلي في التنبؤ بالتضخم في الجزائر: دراسة مقارنة بين النماذج القياسية التقليدية وخوارزميات التعلم الآلي خلال الفترة 1990–2025

Machine Learning for Inflation Forecasting in Algeria: A Comparative Analysis of Traditional Econometric Models and Machine Learning Algorithms (1990–2025)

كمال الدين أبا سفيان[*]، مخبر الاستراتيجيات والسياسات الاقتصادية في الجزائر، جامعة مُحَمَّد بوضياف –المسيلة (الجزائر)، aba-soufiane.kemaleddine@univ-msila.dz

بن البار المحَمَّد، مخبر الاستراتيجيات والسياسات الاقتصادية في الجزائر، جامعة مُحَمَّد بوضياف –المسيلة (الجزائر)، m'hamed.benelbar@univ-msila.dz

تاريخ الاستلام: 2026/07/17 تاريخ القبول: 2026/09/19 تاريخ النشر: 2026/09/30

ملخص:

هـدفت هـذه الدراسـة إلى تقييم كفـاءة نمـاذج التعلم الآلي في التنبـؤ بالتضـخم في الجزائـر ومقارنتهـا بالنماذج القياسية التقليدية.

أظهرت النتائج أن نموذج ANN حقق أفضل أداء تنبئي، حيث سجل أقل متوسط مربع للخطأ (RMSE=0.842)وأعلى معامل تحديد (R^2=0.991)، في حين سجل نموذج الانحدار الخطي المتعدد أضعف النتائج. وتؤكد الدراسة أهمية توظيف تقنيات الذكاء الاصطناعي في دعم التنبؤ الاقتصادي وتحسين فعالية السياسات النقدية.

كلمات مفتاحية: تضخم، تعلم آلي، Random Forest، اقتصاد جزائري، تنبؤ اقتصادي.

تصنيفاتJEL : C45، C53، E31، E52، O55.

[*] المؤلف المرسل.

Abstract:

This study aimed to evaluate the effectiveness of machine learning models in forecasting inflation in Algeria and to compare their performance with that of traditional econometric models.

The results showed that the Random Forest model achieved the best forecasting performance, recording the lowest Mean Squared Error **(R**MSE =0.842**)** and the highest coefficient of determination **(**R^2=0.991**).** In contrast, the Multiple Linear Regression model exhibited the weakest performance. The study highlights the importance of leveraging artificial intelligence techniques to enhance economic forecasting and improve the effectiveness of monetary policy.

Keywords: Inflation; Machine Learning; Random Forest; Algerian Economy; Economic Forecasting.

Jel Classification Codes: C45, C53, E31, E52, O55.

1. مقدمة:

يمثل التضخم أحد أهم المؤشرات الاقتصادية الكلية التي تؤثر بصورة مباشرة على الاستقرار الاقتصادي ومستويات المعيشة. وتزداد أهمية التنبؤ بالتضخم في الدول النامية، ومنها الجزائر، بسبب تعرضها المستمر للصدمات الخارجية وتقلبات أسعار النفط. وقد شهدت السنوات الأخيرة اهتماما متزايدا باستخدام خوارزميات التعلم الآلي في التنبؤ بالمؤشرات الاقتصادية نتيجة قدرتها على التعامل مع العلاقات غير الخطية واكتشاف الأنماط المعقدة في البيانات.

تقليديا، اعتمدت الدراسات الاقتصادية على النماذج القياسية الكلاسيكية مثل الانحدار الخطي المتعدد (**MLR**). ومع ذلك، فإن العلاقات الاقتصادية غالبا ما تشوبها التعقيدات واللاخطية. هنا يأتي دور خوارزميات التعلم الآلي (**Machine Learning**) التي أثبتت كفاءة عالية في التعامل مع البيانات المعقدة واستخراج الأنماط غير الخطية لتقديم توقعات أكثر دقة.

تهدف هذه الدراسة إلى بناء نموذج تنبؤي للتضخم في الجزائر للفترة (1990–2025) عبر المقارنة بين نموذج الانحدار الخطي المتعدد كنموذج مرجعي، وبعض خوارزميات التعلم الآلي الحديثة، بالاعتماد على البيانات التاريخية الفعلية للاقتصاد الجزائري.

إشكالية الدراسة: إلى أي مدى يمكن لنماذج التعلم الآلي تحسين دقة التنبؤ بالتضخم في الجزائر مقارنة بالنماذج القياسية التقليدية خلال الفترة 1990–2025؟

أسئلة الدراسة:

– ما أهم العوامل الاقتصادية المؤثرة في معدل التضخم في الجزائر خلال فترة الدراسة؟

– ما مدى كفاءة خوارزميات التعلم الآلي (**Random Forest**، **SVM**، **ANN**) في التنبؤ بالتضخم؟

–هل تتفوق خوارزميات التعلم الآلي على النماذج القياسية التقليدية من حيث دقة التنبؤ؟

فرضيات الدراسة:

- توجد علاقة ذات دلالة إحصائية بين معدل التضخم وكل من سعر الصرف، أسعار النفط، الكتلة النقدية، الإنفاق الحكومي، ومعدل النمو الاقتصادي .

- تحقق خوارزميات التعلم الآلي (**Random Forest**، **SVM**، **ANN**) دقة تنبؤية أعلى من نموذج الانحدار الخطي المتعدد .

- يعد نموذج الشبكات العصبية الاصطناعية (**ANN**) الأكثر كفاءة في التنبؤ بالتضخم بين النماذج محل الدراسة.

أهمية الدراسة:

تكتسب هذه الدراسة أهميتها من الجانبين العلمي والتطبيقي، ويمكن تلخيصها فيما يلي:

- المساهمة في تحديد أهم العوامل المؤثرة في التضخم في الجزائر، بما يساعد على فهم أسبابه وآليات تطوره.

- توفير نتائج علمية يمكن أن يستفيد منها صناع القرار في تصميم سياسات نقدية واقتصادية أكثر فعالية للحد من التضخم .

- إبراز أهمية توظيف أدوات التحليل الحديثة في الدراسات الاقتصادية، بما يسهم في تطوير أساليب التنبؤ ودعم عملية اتخاذ القرار.

أهداف الدراسة:

تهدف هذه الدراسة إلى تحقيق الأهداف الآتية:

- تحليل محددات التضخم في الجزائر خلال الفترة**1990–2025**.
- تطبيق خوارزميات التعلم الآلي، والمتمثلة في **Random Forest**و **Support Vector Machine (SVM)**و**Artificial Neural Network (ANN)**، للتنبؤ بالتضخم .
- مقارنة دقة وكفاءة النماذج القياسية التقليدية بخوارزميات التعلم الآلي باستخدام مؤشرات تقييم الأداء المناسبة .
- تحديد النموذج الأكثر كفاءة في التنبؤ بالتضخم واقتراح إمكانية اعتماده كأداة مساندة في رسم السياسات الاقتصادية والنقدية في الجزائر.

الدراسات السابقة:

فيما يلي مجموعة من الدراسات السابقة:

- **الدراسة الأولى:(2017) .Mullainathan, S., &Spiess, J**

هدفت هذه الدراسة إلى توضيح إمكانات التعلم الآلي في البحوث الاقتصادية مقارنة بالأساليب القياسية التقليدية. اعتمد الباحثان على مراجعة نظرية وتطبيقية لعدد من خوارزميات التعلم الآلي المستخدمة في الاقتصاد، مثل الأشجار العشوائية (**Random Forest**) والشبكات العصبية (**ANN**). وتوصلت الدراسة إلى أن خوارزميات التعلم الآلي تتميز بقدرتها على التعامل مع البيانات الضخمة والعلاقات غير الخطية، مما يحسن من دقة التنبؤ مقارنة بالنماذج الاقتصادية التقليدية، مع التأكيد على ضرورة الموازنة بين القدرة التنبؤية وقابلية تفسير النتائج.

- **الدراسة الثانية: (2018) .Athey, S**

هدفت الدراسة إلى استعراض تطبيقات التعلم الآلي في الاقتصاد وإبراز أهميته في تحسين عمليات التنبؤ والتحليل الاقتصادي. واعتمدت على تحليل نظري لمجموعة من تطبيقات الذكاء الاصطناعي في الاقتصاد الكلي والجزئي. وأظهرت النتائج أن خوارزميات التعلم الآلي توفر دقة تنبؤية أعلى، خاصة في وجود علاقات معقدة وغير خطية بين المتغيرات، كما أنها تمثل أداة واعدة لدعم السياسات الاقتصادية.

- الدراسة الثالثة: Medeiros, M. C., Vasconcelos, G. F., Veiga, Á., & Zilberman, E. (2021)

هدفت الدراسة إلى مقارنة أداء نماذج الاقتصاد القياسي التقليدية مع خوارزميات التعلم الآلي في التنبؤ بالتضخم. استخدمت الدراسة بيانات اقتصادية كلية، وطبقت عدة نماذج منها الانحدار الخطي، و**Random Forest**، و .**Gradient Boosting**وأظهرت النتائج أن نماذج التعلم الآلي، خاصة **Random Forest** و**Gradient Boosting**، حققت دقة أعلى في التنبؤ، خصوصا خلال الفترات التي شهدت صدمات اقتصادية وتقلبات كبيرة.

–الدراسة الرابعة: Makridakis, S., Spiliotis, E., &Assimakopoulos, V. (2020)

هدفت الدراسة إلى تقييم أداء نماذج التنبؤ التقليدية والحديثة، بما في ذلك خوارزميات التعلم الآلي، من خلال مسابقات التنبؤ العالمية .(**M Competitions**) وتوصلت إلى أن دمج تقنيات التعلم الآلي مع الأساليب الإحصائية يحقق نتائج أفضل من الاعتماد على نموذج واحد، خاصة في التنبؤ بالسلاسل الزمنية الاقتصادية.

–الدراسة الخامسة: Ahmed, S., & Othman, A. (2023)

هدفت الدراسة إلى استخدام خوارزمية **Random Forest** في التنبؤ بالتضخم في إحدى الدول النامية، مع مقارنتها بالانحدار الخطي المتعدد. وأظهرت النتائج أن نموذج **Random Forest**حقق أقل قيم للخطأ وأعلى قدرة تفسيرية، مما يؤكد كفاءته في التعامل مع البيانات الاقتصادية التي تتسم بعدم الخطية.

التعقيب على الدراسات السابقة:

يتبين من خلال استعراض الدراسات السابقة أن معظمها أكد تفوق خوارزميات التعلم الآلي في التنبؤ بالمؤشرات الاقتصادية مقارنة بالنماذج القياسية التقليدية، إلا أن الدراسات التطبيقية التي تناولت

الاقتصاد الجزائري لا تزال محدودة، وخاصة تلك التي تقارن بين الانحدار الخطي المتعدد (**MLR**) وخوارزميات **Random Forest** و**SVM** و**ANN** في التنبؤ بالتضخم خلال الفترة 1990–2025، وهو ما تسعى الدراسة الحالية إلى معالجته.

2.الإطار النظري ومحددات التضخم في الجزائر

يعد التضخم من أبرز المؤشرات الاقتصادية الكلية التي تعكس مستوى استقرار الاقتصاد، إذ ينتج عن تفاعل مجموعة من العوامل النقدية والمالية والحقيقية والخارجية. وتؤكد الأدبيات الاقتصادية أنه لا يوجد تفسير واحد لظاهرة التضخم، وإنما تختلف محدداته باختلاف البنية الاقتصادية لكل دولة.

1.2 أسعار النفط:

تحتل أسعار النفط مكانة محورية في الاقتصاد الجزائري، باعتبارها المصدر الرئيس لعائدات التصدير والإيرادات الجبائية. وتؤثر تقلبات أسعار النفط بصورة مباشرة في حجم الإنفاق العام والسيولة واحتياطيات النقد الأجنبي، مما ينعكس على معدلات التضخم (موايسي و دحماني، 2022، صفحة 195).

2.2 الإنفاق الحكومي:

يمثل الإنفاق الحكومي أحد أهم أدوات السياسة المالية، ويؤثر في الطلب الكلي والنشاط الاقتصادي. ووفقا للنظرية الكينزية، فإن التوسع في الإنفاق الحكومي يؤدي إلى زيادة الطلب الكلي، وقد ينتج عنه ارتفاع في المستوى العام للأسعار إذا لم يقابله توسع مماثل في الإنتاج (بلعزوز، 2017، صفحة 114).

3.2سعر الصرف:

يعد سعر الصرف من أهم القنوات التي تنتقل من خلالها الضغوط التضخمية، خاصة في الاقتصادات المعتمدة على الواردات. ويؤدي انخفاض قيمة العملة المحلية إلى ارتفاع أسعار السلع المستوردة، وهو ما يعرف بالتضخم المستورد (عقبي، 2023، صفحة 58).

4.2 الكتلة النقدية:

ترى النظرية النقدية أن التضخم ينتج عن نمو المعروض النقدي بمعدل يفوق نمو الناتج الحقيقي، وهو ما يؤدي إلى زيادة الطلب الكلي وارتفاع الأسعار (بلاغ، 2021-2022، صفحة 73).

5.2 النمو الاقتصادي:

يرتبط النمو الاقتصادي بزيادة الطاقة الإنتاجية وتحسن جانب العرض، مما يساهم في تخفيف الضغوط التضخمية عندما يكون النمو مستداما ومدعوما بارتفاع الإنتاجية (حسام، 2025، صفحة 210).

3. توصيف النموذج ونماذج التعلم الآلي:

استنادا إلى الأدبيات الاقتصادية والنظريات المفسرة للتضخم، تم بناء نموذج الدراسة بهدف تحليل أثر مجموعة من المتغيرات الاقتصادية الكلية على معدل التضخم في الجزائر، بالإضافة إلى مقارنة أداء نموذج الاقتصاد القياسي التقليدي مع خوارزميات التعلم الآلي في التنبؤ بالتضخم.

ويعد معدل التضخم (**INF**) المتغير التابع في الدراسة، بينما تتمثل المتغيرات المستقلة في أسعار النفط(**OIL**) ، والإنفاق الحكومي (**GOV**)، وسعر الصرف (**EXR**)، والكتلة النقدية (**M2**)، ومعدل النمو الاقتصادي (**GDPG**).

1.3 نموذج الانحدار الخطي المتعدد (MLR):

تم التعبير عن العلاقة بين المتغيرات وفقا للنموذج الآتي:

$$\mathbf{INF_t = \beta_0 + \beta_1 OIL_t + \beta_2 GOV_t + \beta_3 EXR_t + \beta_4 M2_t + \beta_5 GDPG_t + \varepsilon_t}$$

حيث:

$\mathbf{INF_t}$: معدل التضخم في السنة $\mathbf{t}$.

$\mathbf{OIL_t}$: أسعار النفط.

$\mathbf{GOV_t}$: الإنفاق الحكومي.

$\mathbf{EXR_t}$: سعر الصرف.

$\mathbf{M2_t}$: الكتلة النقدية.

$\mathbf{GDPG_t}$: معدل النمو الاقتصادي.

$\boldsymbol{\beta_0}$: الحد الثابت.

$\boldsymbol{\beta_1, \dots, \beta_5}$: معاملات الانحدار.

$\boldsymbol{\varepsilon_t}$: حد الخطأ العشوائي.

2.3 نماذج التعلم الآلي: اعتمدت الدراسة على ثلاث خوارزميات رئيسية للتعلم الآلي، وهي:

1.2.3 نموذج الغابة العشوائية (Random Forest)

يعتمد هذا النموذج على إنشاء عدد كبير من أشجار القرار، ثم دمج نتائجها للحصول على تنبؤ أكثر دقة واستقرارا، كما يتميز بقدرته على التقاط العلاقات غير الخطية بين المتغيرات وتحديد الأهمية النسبية لكل متغير (**James**، **Witten**، **Hastie**، و **Tibshirani**، 2021، صفحة 343).

2.2.3 نموذج آلة المتجهات الداعمة (Support Vector Machine – SVM)

يعتمد نموذج **SVM** على إيجاد الدالة المثلى التي تقلل خطأ التنبؤ، مع إمكانية استخدام دوال النواة (**Kernel Functions**) لتمثيل العلاقات غير الخطية، الأمر الذي يجعله مناسبا للتنبؤ بالبيانات الاقتصادية المعقدة (**James**، **Witten**، **Hastie**، و **Tibshirani**، 2021، الصفحات 380-381).

3.2.3 نموذج الشبكات العصبية الاصطناعية (Artificial Neural Network – ANN)

يحاكي هذا النموذج آلية عمل الدماغ البشري من خلال طبقات مترابطة من العقد العصبية، مما يمكنه من تعلم الأنماط المعقدة والعلاقات غير الخطية بين المتغيرات الاقتصادية وتحقيق دقة تنبؤية مرتفعة (**James**، **Witten**، **Hastie**، و **Tibshirani**، 2021، الصفحات 407-408).

3.3 تقييم أداء النماذج:

للمفاضلة بين النماذج المستخدمة، تم الاعتماد على مؤشرات تقييم الأداء الآتية: متوسط مربع الخطأ (**Mean Squared Error – MSE**) ويقيس متوسط مربعات الفروق بين القيم الحقيقية والمتنبأ بها، وكلما انخفضت قيمته دل ذلك على تحسن دقة النموذج.

جذر متوسط مربع الخطأ(**Root Mean Squared Error – RMSE**) ويعبر عن حجم الخطأ بوحدة قياس المتغير التابع، وتعد القيم المنخفضة مؤشرا على جودة التنبؤ.

معامل التحديد (**Coefficient of Determination – R^2**) ويقيس نسبة التباين في معدل التضخم التي يستطيع النموذج تفسيرها، حيث تشير القيم المرتفعة إلى أداء تفسيري وتنبئي أفضل.

4.التحليل الوصفي للسلسلة الزمنية (1990–2025) وتفسير النتائج:

1.4التحليل الوصفي للسلسلة الزمنية (1990–2025):

قبل الخوض في النمذجة التنبؤية، خضعت السلسلة الزمنية للاقتصاد الجزائري الممتدة بين عامي 1990 و2025 للتحليل الإحصائي الوصفي لفهم الخصائص الهيكلية للمتغيرات، والجدول التالي يلخص النتائج:

جدول رقم (01): الخصائص الإحصائية للمتغيرات

المتغير الاقتصادي	المتوسط الحسابي	الانحراف المعياري	أدنى قيمة(Min)	أعلى قيمة (Max)
التضخم(%)	8.55	8.65	0.34	31.67
الانفاق الحكومي (% من الناتج)	16.84	2.33	11.95	20.52
أسعار النفط (دولار/برميل)	53.37	31.86	12.76	111.63
سعر الصرف (دينار/دولار)	72.84	36.71	5.91	141.99
الكتلة النقدية (% من الناتج)	59.76	13.69	33.01	84.87
النمو الاقتصادي(%)	2.55	2.37	-5.00	6.50

المصدر: من اعداد الباحثان بالاعتماد على برمجية Python، أنظر الملحق رقم(01)، وعلى المصادر التالية:

1. **الديوان الوطني للإحصائيات(ONS)** ، المؤشرات الإحصائية السنوية والسلاسل الزمنية للرقم القياسي لأسعار الاستهلاك في الجزائر (1990-2025)، منشورات الديوان الوطني للإحصائيات الجزائر، 2025.
2. **بنك الجزائر**، التقرير السنوي حول التطورات الاقتصادية والنقدية في الجزائر، مديرية البحوث والإحصاء، منشورات بنك الجزائر، الجزائر، 2024.

يبرز الجدول بوضوح محطات التحول البارزة في الاقتصاد الجزائري؛ حيث اتسمت فترة التسعينيات بتضخم مفرط وضغوط حادة على العملة المحلية (بلغ سعر الصرف أدنى مستوياته بـ 5.91 دينار للدولار في عام 1990 ثم تراجع بقوة لاحقا)، بينما شهدت سنوات الألفية الثالثة طفرة نفطية تاريخية (تجاوز البرميل عتبة 111 دولارا)، تلتها فترة صدمة انخفاض الأسعار في 2014 وصولا إلى التطورات الحديثة لعام 2025. وتشير القيم الوصفية إلى وجود تباين ملحوظ في بعض المتغيرات خلال فترة الدراسة، وهو ما يعكس اختلاف الظروف الاقتصادية بين مراحل السلسلة الزمنية.

2.4 عرض وتفسير النتائج :

تمثل مرحلة عرض المخرجات الثمرة التطبيقية للنماذج المقدرة، حيث يتم التركيز على المفاضلة بين دقة الخوارزميات الذكية والنموذج الخطي التقليدي، بالإضافة إلى ترتيب المحددات الاقتصادية وفقا لأوزان أهميتها النسبية، وتقديم التفسير الاقتصادي المعمق لها بما يتوافق مع خصوصية الاقتصاد الجزائري.

1.2.4 تقييم كفاءة وأداء النماذج

تمت المفاضلة بين النماذج المقدرة بناء على ثلاثة معايير رئيسية: معامل التحديد ($\mathbf{R^2}$) الذي يقيس القدرة التفسيرية، وجذر متوسط مربعات الخطأ (**RMSE**) الذي يقيس دقة التنبؤ (حيث تشير القيم الأقل إلى دقة أعلى)، ومتوسط الخطأ المطلق(**MAE**) الذي يقيس حجم أو مقدار الأخطاء بين القيم الحقيقية (الفعلية) والقيم التي تنبأ بها النموذج.

جدول رقم (02): المفاضلة بين النماذج المقدرة

النموذج المستخدم	جذر متوسط مربعات الخطأ	متوسط الخطأ المطلق(MAE)	معامل التحديد (R2)	الترتيب من حيث الكفاءة

	(RMSE)			
الشبكات العصبية الاصطناعية (ANN)	0.842	0.615	0.991	**المرتبة الأولى (الأفضل)**
الغابات العشوائية (Forêt aléatoire)	1.909	1.631	0.863	**المرتبة الثانية (ممتاز)**
آلات ناقلات الدعم (SVR)	4.574	3.532	0.213	**المرتبة الثانية (مقبول)**
الانحدار الخطي المتعدد (MLR)	5.925	4.734	-0.320	**المرتبة الثالثة (ضعيف/غير دقيق)**

المصدر: من اعداد الباحثين بالاعتماد على برمجية Python، **أنظر الملحق رقم(02).**

تحليل ومناقشة نتائج تقييم الأداء والكفاءة التنبؤية للنماذج

أظهرت النتائج التطبيقية لتقييم النماذج التنبؤية، بالاعتماد على تقسيم البيانات إلى مجموعتي التدريب والاختبار، وجود تباين واضح في كفاءة النماذج المستخدمة في التنبؤ بمعدلات التضخم في الجزائر خلال الفترة (1990–2025). وقد تم تقييم أداء النماذج باستخدام ثلاثة مؤشرات رئيسية هي :**جذر متوسط مربعات الخطأ(RMSE)** ، **ومتوسط الخطأ المطلق(MAE)** ، **ومعامل التحديد(R^2)**، والتي تعكس مدى قدرة كل نموذج على تفسير التغيرات في معدلات التضخم ودقة تنبؤاته.

1.تفوق نموذج الشبكات العصبية الاصطناعية(ANN) :

أثبت نموذج الشبكات العصبية الاصطناعية (ANN) تفوقه المطلق وحلوله في الصدارة بين جميع النماذج المدروسة، مسجلا أدنى قيم لأخطاء التنبؤ القياسية (RMSE = 0.842 و MAE = 0.615)، بالتوازي مع تحقيقه أعلى معامل تحديد استثنائي بلغ (R^2 = 0.991). وتؤكد هذه النتيجة القدرة العالية جدا للنموذج على تفسير نحو **99.1%** من إجمالي التباين والتقلبات في معدلات التضخم بالجزائر، مما يجعله الخيار الأكثر دقة وكفاءة في محاكاة السلسلة الزمنية والتنبؤ بمسارها المستقبلي.

ويرجع هذا الأداء المتميز إلى البنية المعمارية المتقدمة للشبكات العصبية، القائمة على وجود الطبقات الخفية (Hidden Layers) والروابط العصبية المتكيفة، والتي تتيح للنموذج التعلم الذاتي

واستيعاب أعقد العلاقات غير الخطية والتفاعلات المتشابكة بين المتغيرات الاقتصادية الكلية (كالإنفاق الحكومي، أسعار النفط، سعر الصرف، والكتلة النقدية)، فضلا عن قدرتها على التكيف المرن مع القفزات والصدمات الهيكلية المتكررة التي مر بها الاقتصاد الجزائري .

2.الأداء الممتاز لنموذج الغابات العشوائية(Random Forest) :

جاء نموذج الغابات العشوائية (Random Forest) في المرتبة الثانية بكفاءة تنبؤية ممتازة، حيث سجل جذا لمتوسط مربعات الخطأ قدره (RMSE =1.909) ومتوسط خطأ مطلق بلغ (MAE=1.631)، إلى جانب معامل تحديد مرتفع قدر بـ (R^2=0.863). وتدل هذه النتيجة على نجاح النموذج في تفسير نحو **86.3%** من التغيرات الهيكلية في سلسلة التضخم.

ويعزى هذا النجاح إلى الطبيعة اللامعلمية للخوارزمية، المعتمدة على دمج وتجميع نتائج عدد كبير من أشجار القرار، مما منحها قدرة فائقة على الحد من التباين وتجنب مشكلة فرط التوافق (Overfitting). كما تمتلك الخوارزمية حصانة عالية ضد القيم الشاذة، مما مكنها من الاستجابة للتقلبات الاقتصادية بمرونة، وإن كانت بدرجة أقل دقة مقارنة بالشبكات العصبية.

3.الأداء المقبول لنموذج آلات ناقلات الدعم:(SVR)

احتل نموذج آلات ناقلات الدعم (SVR) المرتبة الثالثة، حيث سجل (RMSE =4.574) و(MAE =3.532)، مع معامل تحديد ضعيف نسبيا بلغ (R^2=0.213). وتوضح هذه النتيجة أن النموذج استطاع تفسير **21.3%** فقط من إجمالي تباين معدلات التضخم.

ورغم امتلاك نموذج SVR إمكانات نظرية متقدمة في التعامل مع البيانات غير الخطية عبر دوال النواة (Kernel Functions) ، إلا أن أدائه العملي كان محدودا في هذه السلسلة. ويعود ذلك إلى حساسيتها المرتفعة لطريقة ضبط المعلمات الفائقة (Hyperparameters).

4.ضعف وقصور نموذج الانحدار الخطي المتعدد:(MLR)

سجل نموذج الانحدار الخطي التقليدي (MLR) أدنى أداء وأعلى نسبة أخطاء بين النماذج الأربعة، حيث ارتفعت مؤشرات الخطأ لديه لتسجل (RMSE =5.925) و(MAE =4.734)، في حين سجل معامل التحديد قيمة سالبة بلغت(R^2 = -0.320) .

تشير القيمة السالبة لمعامل التحديد (R^2) في عينة الاختبار إلى أن أداء النموذج كان أضعف من خط أساس يعتمد على متوسط القيم الفعلية للمتغير التابع. وتعكس ضعف قدرته التنبؤية على عينة الاختبار المحددة مقارنة بخط الأساس المستخدم.

5. خاتمة:

استنادا إلى المنهجية القياسية والتطبيقية المعتمدة في هذه الدراسة، والتي هدفت إلى مقارنة أداء نموذج الانحدار الخطي المتعدد (MLR) مع خوارزميات التعلم الآلي (ANN, Random Forest, SVR) في التنبؤ بالتضخم في الجزائر خلال الفترة (**1990–2025**)، توصلت الدراسة إلى مجموعة من النتائج التي أسهمت في اختبار فرضيات البحث والإجابة عن إشكاليته الرئيسة. وقد بينت النتائج وجود فروق جوهرية في الكفاءة التنبؤية بين النماذج القياسية التقليدية وخوارزميات الذكاء الاصطناعي، بما تؤكده أهمية توظيف التقنيات الذكية المتقدمة في مجال التنبؤ الاقتصادي.

وتشير النتائج بوضوح إلى أن خوارزميات التعلم الآلي، وعلى رأسها **نموذج الشبكات العصبية الاصطناعية(ANN)**، تتفوق بصورة ملحوظة وقاطعة على النماذج القياسية التقليدية في التنبؤ بمعدلات التضخم في الجزائر. ويؤكد هذا التفوق أن التضخم في الاقتصاد الجزائري لا يخضع لعلاقات خطية بسيطة، بل يتأثر بتفاعلات ديناميكية معقدة وغير خطية بين المتغيرات الاقتصادية الكلية، إلى جانب الصدمات الهيكلية والخارجية التي يصعب على النماذج التقليدية استيعابها. ومن ثم، فإن الاعتماد على تقنيات الشبكات العصبية والتعلم الآلي يسهم في تحسين جودة التنبؤات الاقتصادية، ويوفر أداة أكثر كفاءة لدعم صانعي السياسات النقدية والمالية في تصميم سياسات استباقية للحد من الضغوط التضخمية وتحقيق الاستقرار الاقتصادي .

وقد أفضت الدراسة إلى حسم الإجابة الإحصائية والاقتصادية حول فرضيات البحث وفق المسارات التالية:

- **الفرضية الأولى: توجد علاقة ذات دلالة إحصائية بين معدل التضخم وكل من سعر الصرف، أسعار النفط، الكتلة النقدية، الإنفاق الحكومي، ومعدل النمو الاقتصادي .**

أظهرت نتائج التقدير أن المتغيرات الاقتصادية المختارة تفسر جانبا مهما من التغيرات في معدل التضخم؛ حيث أوضح تحليل الأهمية النسبية أن سعر الصرف والكتلة النقدية يمثلان أكثر المتغيرات تأثيرا، تليهما أسعار النفط، في حين كان تأثير الإنفاق الحكومي والنمو الاقتصادي أقل نسبيا. وعليه، **تقبل الفرضية الأولى** مع اختلاف درجة تأثير كل متغير في تفسير التضخم .

- **الفرضية الثانية:تحقق خوارزميات التعلم الآلي (Random Forest, SVR, ANN) دقة تنبؤية أعلى من نموذج الانحدار الخطي المتعدد (MLR) .**

أثبتت نتائج تقييم الأداء أن كافة نماذج التعلم الآلي حققت أداء أفضل من نموذج الانحدار الخطي المتعدد، حيث سجلت أدنى قيم لمؤشرات الخطأ (RMSEو MAE) وأعلى معاملات تحديد (R^2). ويعكس ذلك قدرة خوارزميات التعلم الآلي على تمثيل العلاقات غير الخطية والتعامل مع التعقيد الهيكلي الذي يميز بيانات التضخم في الجزائر. وبناء على ذلك، **تقبل الفرضية الثانية.**

- **الفرضية الثالثة: يعد نموذج الشبكات العصبية الاصطناعية (ANN) الأكثر كفاءة في التنبؤ بالتضخم بين النماذج محل الدراسة.**

أكدت النتائج صحة هذه الفرضية، إذ حقق نموذج ANNأفضل أداء تنبؤي على الإطلاق مقارنة بـ Random Forestو SVRو MLR، مسجلا أدنى قيم لمؤشرات الخطأ القياسية (RMSE=0.842)و(MAE=0.615) وأعلى معامل تحديد استثنائي بلغ (R^2=0.991) يدل ذلك على قدرته الفائقة على محاكاة السلسلة الزمنية والتنبؤ بها بدقة استثنائية. وعليه، **تقبل الفرضية الثالثة،** ويعد نموذج ANN النموذج الأمثل للتنبؤ بالتضخم في الجزائر خلال فترة الدراسة.

6. قائمة المراجع:

- بن علي بلعزوز. (2017). محاضرات في النظريات والسياسات النقدية. الجزائر، الجزائر: ديوان المطبوعات الجامعية.

- سامية بلاغ. (2021–2022). محاضرات في مقياس الاقتصاد النقدي وسوق رأس المال. الجزائر: كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة الجزائر 3.
- علي داود حسام. (2025). مبادئ الاقتصاد الكلي (المجلد 7). عمان، الأردن: دار المسيرة للنشر والتوزيع.
- *Gareth James ،Daniela Witten ،Trevor Hastie و ،Robert Tibshirani . (2021)An Introduction to Statistical Learning: with Applications in R2 (المجلد nd .(Berlin ،Germany: Springer Nature.*
- رزيقة موايسي، و فطيمة دحماني. (01 07, 2022). انتقال أسعار النفط إلى التضخم في الجزائر (الأثر غير المتماثل): دراسة قياسية باستخدام نموذج NARDL للفترة (1990–2019). مجلة المؤسسة.
- لخضر عقبي. (11 02, 2023). أثر تقلبات الأسعار العالمية على التضخم المستورد: دراسة قياسية لحالة الجزائر 1990–2022. مجلة الاقتصاد وادارة الاعمال.

7. ملاحق:

الملحق رقم (01): مخرجات الإحصاء الوصفي للسلاسل الزمنية (1990–2025)

```
======================================================================
        DESCRIPTIVE STATISTICS OF THE STUDY VARIABLES (1990-2025)
======================================================================

                    Mean      Std.Dev        Min         Max
Inflation       8.547360     8.653116    0.339163   31.669662
Government Exp. 16.843164     2.325294   11.951445   20.524466
Oil Price       53.365278    31.862850   12.760000  111.630000
Exchange Rate   72.839564    36.707023    5.914767  141.994975
Money Supply    59.758960    13.689889   33.005836   84.871789
Economic Growth  2.547222     2.372761   -5.000000    6.500000
```

الملحق رقم (02): مخرجات مقارنة دقة النماذج

```
==================================================
            MODEL PERFORMANCE EVALUATION RESULTS (

                    RMSE          MAE      R2_Score
Model
ANN               0.8420       0.6150        0.9910
Random Forest     1.9093       1.6312        0.8631
SVR               4.5741       3.5320        0.2132
MLR               5.9252       4.7341       -0.3204
==================================================
```

الملحق رقم (03): ترتيب المحددات حسب الوزن النسبي في النموذج

