https://jsrhs.rcc.edu.ly/
ISSN: 3078-4611
Vol.3 No.2 (2026), 91- 102
Article history:
Received:11/10/2026
Accepted:20/10/2026
Published:25/10/2026

مجلة البحوث المستدامة في العلوم الإنسانية

JSRHS

تحليل السلاسل الزمنية للواردات الليبية وأثر المتغيرات الاقتصادية الكلية عليها: تكامل بين الاقتصاد القياسي والتعلم الآلي (1998–2022)

هشام عبد السلام رجب [1*] ، سالمة محمد ابوقرين [2]

[1]كلية تقنية المعلومات – جامعة مصراتة

https://orcid.org/0009-0009-2818-7448

[2] أستاذ مساعد كلية الاقتصاد – جامعة مصراتة

https://orcid.org/0009-0005-7927-1931

[1] Rajab.a.hesham@it.misuratau.edu.ly [2] Salma.abugrain@eps.misuratau.edu.ly

Time Series Analysis of Libyan Imports and the Impact of Macroeconomic Variables: An Integration of Econometrics and Machine Learning (1998–2022)

Abstract:

This study aims to analyse the temporal behaviour of Libyan imports during (1998–2022) and to estimate the impact of key macroeconomic variables (GDP growth, oil production, and inflation) on them, while comparing econometric models with machine learning techniques. The study adopts an integrative approach that combines OLS, ARDL, ECM, and Granger causality with Random Forest, ANN, and SVR, using annual time series data (25 observations).

The results reveal a long-run equilibrium relationship (F= 6.824), with oil production being the strongest determinant ($\beta = 42.8\, million$; importance = (52.3%) and a high adjustment speed (ECT=0.682-). Machine learning models outperformed econometric models in forecasting, with the ANN achieving the highest accuracy (R^2 =0.914, MAPE =15.2%). This study is among the first to integrate econometrics with machine learning in the analysis of Libyan imports.

Keywords: Libyan Imports, Time Series, Econometrics, Machine Learning, ARDL, Random Forest.

الملخص:

تهدف هذه الدراسة إلى تحليل السلوك الزمني للواردات الليبية خلال الفترة (1998–2022)، وتقدير أثر المتغيرات الاقتصادية الكلية الرئيسية (نمو الناتج المحلي الإجمالي، إنتاج النفط، معدل التضخم) عليها، مع المقارنة بين قدرة النماذج القياسية وتقنيات التعلم الآلي في التفسير والتنبؤ. حيث اعتمدت الدراسة منهجا تكامليا يجمع بين الاقتصاد القياسي (OLS، ARDL، ECM، والسببية (لجرانجر) وتقنيات التعلم الآلي (Random Forest، ANN، SVR)، باستخدام سلسلة زمنية سنوية (25 مشاهدة).

وأظهرت النتائج وجود علاقة توازنيه طويلة الأجل بين الواردات والمتغيرات الكلية (F= 6.824)، وأن إنتاج النفط هو المحدد الأقوى (β = 42.8 Million)، نسبة أهمية (52.3%)، مع سرعة تعديل عالية (ECT=0.682–). كما تفوقت نماذج التعلم الآلي في التنبؤ، حيث حقق نموذج الشبكات العصبية الاصطناعية (ANN) أعلى دقة (R^2–=0.914) (MAPE= 15.2%). وتعد هذه الدراسة من أولى الدراسات التي تدمج الاقتصاد القياسي مع التعلم الآلي في تحليل الواردات الليبية، مما يوفر رؤية منهجية متكاملة.

الكلمات المفتاحية: الواردات الليبية، السلاسل الزمنية، الاقتصاد القياسي، التعلم الآلي، ARDL، Random Forest.

1. المقدمة:

تعد التجارة الخارجية ركيزة أساسية في الاقتصاديات المعاصرة، إذ تشكل الواردات والصادرات حلقة الوصل بين الاقتصاد الوطني والاقتصاد العالمي. وفي الاقتصاديات الريعية التي تعتمد بشكل كبير على مورد واحد، مثل ليبيا، تكتسب دراسة الواردات أهمية مضاعفة، لأنها تعكس – من جهة – القدرة الشرائية للاقتصاد ومدى ارتباطه بالأسواق العالمية، وتعكس – من جهة أخرى – هشاشة البنية الإنتاجية واعتمادها على الاستيراد لتلبية احتياجات الاستهلاك والاستثمار.

وقد شهدت ليبيا خلال الفترة 1998–2022 تحولات اقتصادية وسياسية عميقة أثرت بشكل مباشر على مسار وارداتها، بدءا من رفع العقوبات الدولية جزئيا في أواخر التسعينيات، مرورا برفع الحظر الكامل عام 2003 وتدفق الاستثمارات، وصولا إلى الصدمات السياسية الحادة بعد عام 2011، وما تلاها من انقسام مؤسسي وتوقف جزئي للإنتاج النفطي، ثم جائحة كورونا عام 2020. وقد انعكست هذه التحولات على قيمة الواردات التي تذبذبت بين مستويات متدنية لا تتجاوز 1.9 مليار دينار عام 2000، ومستويات قياسية بلغت 95.4 مليار دينار عام 2022.

2. مشكلة الدراسة:

على الرغم من أن الواردات الليبية تخضع لتفاعل معقد مع مجموعة من المتغيرات الاقتصادية الكلية، إلا أن الادبيات الاقتصادية التي تناولت المحددات الكلية للواردات في ليبيا لا تزال محدودة، كما أن معظم الدراسات السابقة اعتمدت بشكل شبه حصري على الأدوات القياسية التقليدية، دون الاستفادة من التطورات الحديثة في مجال التعلم الآلي التي أثبتت قدرة عالية في التعامل مع العلاقات غير الخطية والبيانات المحدودة الحجم.

وتتمثل مشكلة الدراسة في السؤال الرئيسي التالي:

إلى أي مدى يمكن تفسير تقلبات الواردات الليبية بالمتغيرات الاقتصادية الكلية (نمو الناتج المحلي، إنتاج النفط، معدل التضخم)، وأي المقاربتين – الاقتصاد القياسي أم التعلم الآلي – أكثر قدرة على التفسير والتنبؤ؟

3. أهداف الدراسة:

1. تحليل الاتجاه الزمني للواردات الليبية خلال الفترة 1998–2022.
2. قياس أثر المتغيرات الاقتصادية الكلية على الواردات في الأجلين القصير والطويل.
3. اختبار وجود علاقة توازنيه طويلة الأجل باستخدام نموذج ARDL.
4. بناء نماذج تنبؤية باستخدام تقنيات التعلم الآلي (Random Forest، ANN، SVR).
5. مقارنة أداء النماذج القياسية ونماذج التعلم الآلي في التنبؤ بالواردات.

4. أهمية الدراسة:

تستمد هذه الدراسة أهميتها من كونها:

- أول دراسة – في حدود علم الباحثين – تجمع بين الاقتصاد القياسي والتعلم الآلي في تحليل الواردات الليبية.
- معالجة لفجوة بحثية في الأدبيات الليبية التي ركزت على الصادرات والنمو الاقتصادي أكثر من الواردات.
- ذات بعد تطبيقي يفيد صانعي السياسات في رسم سياسات استيرادية أكثر دقة.

5. حدود الدراسة:

- **الحدود الزمنية:** 1998–2022 (25 مشاهدة سنوية).

- **الحدود المكانية:** الاقتصاد الليبي.
- **الحدود الموضوعية:** الواردات الكلية والمتغيرات الكلية الثلاثة (نمو الناتج المحلي، إنتاج النفط، والتضخم).

6. الأساس النظري لمحددات الواردات(Theoretical Foundations of Import Determinants):

تستند دراسة محددات الواردات والطلب عليها إلى منظومة متكاملة من النظريات والرؤى الاقتصادية الكلية والتجارية التي سعت عبر مراحل تطور الفكر الاقتصادي إلى تفسير السلوك الاستيرادي للدول، وتحديد القوى المحركة له. ويتنوع التفسير النظري وفقا لعدة مناهج ومنظورات تعكس زوايا تحليلية مختلفة؛ بدءا من العلاقات الدخلية الكلاسيكية، مرورا بمتغيرات الأسعار وسعر الصرف، وصولا إلى الطبيعة الهيكلية للإقتصادات الريعية والموردية. وفيما يلي استعراض لأبرز هذه المداخل النظرية:

1.6 المنهج الكينزي(Keynesian Approach):

يرى أن الواردات دالة في الدخل الوطني، وفق العلاقة:

$$M= M_0 +My$$

حيث تعبر M عن الواردات، Y الدخل الوطني، و m الميل الحدي للاستيراد. وقد وجد Elsayir (2018) أن نموذج السلاسل الزمنية للناتج المحلي يعكس علاقات تشابكية بين المتغيرات الكلية.

2.6 منظور التجارة الدولية (International Trade Perspective):

يرى أن الواردات تتحدد بالأسعار النسبية وسعر الصرف والانفتاح التجاري. وقد أكد Odili & Florence (2017) في دراسة على نيجيريا أن تقلبات سعر الصرف تؤثر معنويا على تدفقات التجارة في الأجل الطويل. وفي السياق الليبي، أشار Ben-Naser et al. (2017) إلى أن سعر الصرف الحقيقي يعاني من اختلالات جوهرية ناجمة عن الطبيعة الريعية للاقتصاد.

3.6 المدخل الريعي (Rentier Approach):

يبرز دور النفط كمحدد حاسم للواردات في الاقتصاديات الريعية. وقد أوضح Aimer (2017) أن تقلبات أسعار النفط تؤثر بشكل غير متماثل على القطاعات الاقتصادية في ليبيا، بينما بين Humbatova & Hajiyev (2020) في دراسة على أذربيجان أن العامل النفطي محدد رئيسي لواردات السيارات.

7. الدراسات السابقة ذات الصلة:

1.7 الدراسات الليبية:

تعد الأدبيات الليبية محدودة نسبياً في مجال الواردات، وقد ركزت غالبا على الصادرات والنمو. فقد درس Elbeydi et al. (2010) العلاقة بين الصادرات والنمو الاقتصادي في ليبيا، بينما تناول Nagem Howaidi (2020) العلاقة بين الصادرات والنمو خلال 1970–2010. وفي سياق مشابه، حلّل Abushhewa & Zarook (2016) أثر الاستثمار الأجنبي المباشر على النمو في ليبيا.

وفيما يتعلق بالتقلبات الكلية، أشار Kreiw (2019) إلى أن عدم الاستقرار السياسي كان له أثر عميق على الاقتصاد الليبي، بينما وثق Awidan (2019) تقلبات أسعار النفط باستخدام نماذج السلاسل الزمنية مطبقة على ليبيا ونيجيريا. كما درس Alsanusi et al. (2022) دور سعر الصرف الحقيقي في الميزان التجاري بين تركيا وليبيا.

2.7 الدراسات الدولية في التنبؤ بالواردات:

على الصعيد الدولي، قدم Persio & Segala (2015) مقاربة انحدارية ذاتية لسلاسل الواردات والصادرات. واستخدم Nzayisenga & Zhu (2020) تحليل المكونات الرئيسية (PCA) لبناء نموذج تنبؤي لواردات رواندا، بينما استخدم Allaro (2018) تحليل السلاسل الزمنية لكشف الانكسارات الهيكلية في الواردات الإثيوبية.

وفي دراسة مقارنة، تناول Brabenec & Šuleř (2020) التنبؤ بالميزان التجاري التشيكي والصيني باستخدام التعلم الآلي، بينما قدم Mayorova & Nikita (2021) نموذج Nowcasting لمعدلات نمو الصادرات والواردات الروسية.

3.7 الدراسات التي تجمع بين الاقتصاد القياسي والتعلم الآلي:

يعد التكامل بين الاقتصاد القياسي والتعلم الآلي مجالا بحثيا حديثا نسبيا. وقد أرسوا Zheng et al. (2017) الأساس المنهجي لهذا التكامل، مؤكدين أن الدمج بين المقاربتين يوفر مزايا تفسيرية وتنبؤية متكاملة.

وفي هذا السياق، قدم Malhotra (2018) مقاربة هجينة (Hybrid) بين الاقتصاد القياسي والتعلم الآلي لتحليل الأهمية النسبية لمحددات تضخم الغذاء. وطبق Kaushik & Giri (2020) مقارنة متعددة المتغيرات بين الاقتصاد القياسي التقليدي والتعلم الآلي والتعلم العميق في التنبؤ بأسعار الصرف الأجنبي.

وفي مجال الاقتصاد الكلي، طور Coulombe (2020) مقاربة ((الاقتصاد الكلي كغابة عشوائية))، بينما استخدم Khan et al. (2022) خوارزميات التعلم الآلي الخاضع للإشراف لتحليل البيانات الاقتصادية الكلية. كما قدم Babenko et al. (2021) مراجعة لمنهجيات التعلم الآلي الكلاسيكية في البحوث الاقتصادية، بينما أظهر Buckmann et al. (2021) أدوات تفسيرية للتعلم الآلي في التنبؤ الاقتصادي.

4.7 الدراسات الانحيازية والشبكات العصبية:

مثل التكامل الانحيازي مع التعلم الآلي اتجاها متصاعدا. فقد قدم (Hauzenberger et al. (2022 نماذج الشبكات العصبية الانحيازية للتحليل الاقتصادي الكلي، وطور الفريق نفسه (Hauzenberger et al., 2022) نماذج TVP–VAR باستخدام أشجار الانحدار. وأسس Korobilis & Pettenuzzo (2020) إطاراً شاملاً لاقتصاديات التعلم الآلي الانحيازي.

وفي مجال التعلم العميق، قدم Guimaraes (2022) مقاربة ((التعلم العميق في الاقتصاد الكلي))، بينما استخدم Sermpinis et al. (2014) الانحدار المتجه الداعم الجيني للتنبؤ بالتضخم والبطالة.

8. المنهجية:

تتبنى هذه الدراسة منهجا كميا استنباطيا، يقوم على تصميم تحليلي–مقارن ذي طبيعة زمنية طولية، بهدف اختبار العلاقة الديناميكية بين المتغيرات الاقتصادية الكلية في ليبيا وأثره على الواردات الليبية. وتعتمد الدراسة على بيانات ثانوية مجمعة من مصادر متعددة لضمان موثوقية القياس، حيث تم استقاء بيانات الواردات من مصلحة الإحصاء والتعداد ومصرف ليبيا المركزي، وبيانات نمو الناتج المحلي الإجمالي من قاعدة بيانات آفاق الاقتصاد العالمي (IMF WEO) وقاعدة بيانات مؤشرات التنمية العالمية (World Bank WDI)، وبيانات إنتاج النفط من إدارة معلومات الطاقة الأمريكية (EIA) ونشرة أوبك (OPEC Bulletin)، وبيانات معدل التضخم من مصرف ليبيا المركزي وقاعدة بيانات مؤشرات التنمية العالمية.

1.8 المتغيرات:

- المتغير التابع:IMP = قيمة الواردات (بآلاف الدنانير الليبية).

- المتغيرات المستقلة:GDP (نمو الناتج المحلي)، OIL (إنتاج النفط)، INF (التضخم).
- المتغيرات الضابطة:D_{2011} D_{2020} (متغيرات صورية للصدمات السياسية والجائحة).

1.1.8 المرحلة الأولى: التحليل الوصفي:

$$\bar{x} = \frac{\sum x}{n} \quad ، \quad \sigma = \sqrt{\frac{\sum(\bar{x}-x)^2}{n}}$$

2.1.8 المرحلة الثانية: اختبارات الاستقرارية (ADF Test):

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \sum_{i=1}^{p} \delta_i \Delta Y_{t-i} + \epsilon_t$$

حيث الفرضية الصفرية $H_0: \gamma = 0$ (وجود جذر وحدة).

3.1.8 المرحلة الثالثة: النمذجة القياسية:

- نموذج OLS:

$$\text{IMP}_t = \beta_0 + \beta_1 GDP_t + \beta_2 OIL_t + \beta_3 INF_t + \beta_4 D_{2011} + \beta_5 D_{2020} + \varepsilon_t$$

- نموذج ARDL:

$$\Delta\text{IMP}_t = \alpha_0 + \sum_{i=1}^{p} \alpha_i \Delta\text{IMP}_{t-i} + \sum_{j=0}^{q_1} \beta_j \Delta\text{GDP}_{t-j} + \sum_{k=0}^{q_2} \gamma_k \Delta\text{OIL}_{t-k} + \sum_{l=0}^{q_3} \delta_l \Delta\text{INF}_{t-l} + \lambda_1 \text{IMP}_{t-1} + \lambda_2 \text{GDP}_{t-1} + \lambda_3 \text{OIL}_{t-1} + \lambda_4 \text{INF}_{t-1} + \varepsilon_t$$

- نموذج ECM:

$$\Delta\text{IMP}_t = \alpha_0 + \sum_{i=1}^{p} \alpha_i \Delta\text{IMP}_{t-i} + \sum_{j=0}^{q} \beta_j \Delta X_{t-j} + \varphi \text{ECT}_{t-1} + \varepsilon_t$$

حيث φ تمثل سرعة التعديل (يجب أن تكون سالبة ومعنوية إحصائيا).

4.1.8 المرحلة الرابعة: نمذجة التعلم الآلي:

- الغابة العشوائية (Random Forest):

$$\hat{y} = \frac{1}{B} \sum_{b=1}^{B} T_b(x)$$

- الشبكات العصبية الاصطناعية (ANN):

$$\hat{y} = f\left(\sum w_j \cdot g\left(\sum v_{ij} x_i + b_j\right) + b_0\right)$$

- انحدار متجه الدعم: (SVR):

5.1.8 المرحلة الخامسة: مقارنة الأداء التنبؤي:

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

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|$$

$$\text{MAPE} = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \times 100\%$$

2.8 الأدوات البرمجية:

- Python 3.10+ (pandas, numpy, scikit-learn, statsmodels, tensorflow).
- R 4.2+ (forecast, tseries, lmtest, caret, randomForest).
- EViews 12+ (ARDL, ECM, Granger Causality).
- SPSS 28+ (التحليل الوصفي والاختبارات الأولية).

9. التحليل والمناقشة:

1.9 التحليل الوصفي:

الجدول رقم (1) يوضح قيم الإحصاءات الوصفية لمتغيرات الدراسة.

جدول (1): الإحصاءات الوصفية للمتغيرات

المتغير	المتوسط	الوسيط	الانحراف المعياري	الالتواء	التفرطح
IMP	22,540,000	16,060,567	26,840,000	1.82	2.94
GDP	6.24	2.50	32.40	0.92	4.12
OIL	1.10	1.32	0.45	−0.58	1.82
INF	4.72	2.60	9.84	1.54	2.42

2.9 نتائج اختبارات الاستقرارية:

الجدول رقم (2) يوضح نتائج اختبارات السكون لمتغيرات الدراسة.

جدول (2): نتائج اختبار ADF لجذر الوحدة

المتغير	عند المستوى	عند الفرق الأول	القرار (الحكم)
IMP	−1.854	−4.923***	$I(1)$
GDP	−3.124**	—	$I(0)$

المتغير	عند المستوى	عند الفرق الأول	القرار (الحكم)
OIL	−2.451	−5.183***	$I(1)$
INF	−3.482**	—	$I(0)$

3.9 نتائج النمذجة القياسية:

الجدول رقم (3) يوضح نتائج تقدير نموذج الانحدار الخطي البسيط.

جدول (3): نتائج تقدير نموذج الانحدار الخطي البسيط (OLS):

المتغير	المعامل (β)	الخطأ المعياري	قيمة t	Prob.	المعنوية
C	−8,450,000	5,120,000	−1.650	0.115	غير معنوي
GDP	125,400	98,500	1.273	0.218	غير معنوي
OIL	42,800,000	12,400,000	3.452	0.003	***
INF	−185,000	420,000	−0.440	0.665	غير معنوي
D_{2011}	15,200,000	8,900,000	1.708	0.103	غير معنوي
D_{2020}	8,900,000	9,200,000	0.967	0.345	غير معنوي

$R^2 = 0.784, \quad \text{Adj } R^2 = 0.721, \quad F = 13.452^{***}, \quad \text{DW} = 1.923$

من خلال النتائج بالجداول رقم (3) نجد أن النموذج يتمتع بقدرة تفسيرية عالية حيث 78.4 % من التغيرات الحاصلة في المتغير التابع هي بسبب التغيرات الحاصلة في المتغيرات المستقلة اما ما تبقى 21.6% هي نتيجة متغيرات أخرى لم تدرج في النموذج. ويعزز هذا الاستنتاج قيمة معامل التحديد المعدل Adj R^2=0.721، الذي يأخذ في الاعتبار عدد المتغيرات المستقلة وحجم العينة، إذ بلغ 72.1%، وهو ما يشير إلى أن النموذج يحتفظ بقدرته التفسيرية المرتفعة حتى بعد تصحيحه لدرجات الحرية، مما يدل على خلو النموذج من مشكلة الإفراط في التحديد (Overfitting) وخلو المتغيرات المستقلة من التكرار الخطي المفرط. وبالنظر الى قيمة داربن واتسون نجد ان النموذج خالي من مشكلة الارتباط الذاتي، إضافة إلى أن النموذج معنوي.

الجدول رقم (4) يوضح نتائج اختبار التكامل المشترك.

جدول (4): نتائج اختبار الحدود للتكامل المشترك (ARDL Bounds Test)

الإحصائية	القيمة المحسوبة	I (0) Boundary	I (1) Boundary	القرار
F−Statistic	6.824***	3.23	4.35	وجود علاقة طويلة الأجل
t−Statistic	−4.125***	−2.86	−3.78	وجود علاقة طويلة الأجل

من خلال الجدول رقم (4) نجد ان إحصائية f المحسوبة (6.824) تتجاوز القيمة الحرجة العليا I(1) عند مستوى (4.35)، مما يعني رفض فرضية العدم القائلة بعدم وجود علاقة طويلة الأجل. وهذا يؤكد وجود تكامل مشترك بين المتغيرات.

كذلك نجد إحصائية t المحسوبة (−4.125) تتجاوز القيمة الحرجة العليا I(1) عند (−3.78)، وهو ما يدعم النتيجة نفسها.

هناك أدلة قوية على وجود علاقة توازنيه طويلة الأجل بين المتغيرات المدروسة، وهو ما يبرر الانتقال إلى تقدير نموذج ECM.

جدول (5): نتائج نموذج تصحيح الخطأ (ECM)

المتغير	المعامل	الخطأ المعياري	قيمة t	Prob.
C	2,450,000	1,850,000	1.324	0.198
ΔIMP(−1)	0.421	0.185	2.276	0.034
ΔGDP	85,200	72,400	1.177	0.252
ΔOIL	28,500,000	9,800,000	2.908	0.009
ΔINF	−125,000	310,000	−0.403	0.691
ECT(−1)	−0.682	0.174	−3.920	0.001

تشير النتائج من الجداول رقم (5) أن نموذج تصحيح الخطأ (ECM) إلى وجود علاقة توازنيه طويلة الأجل بين الواردات والمتغيرات الاقتصادية محل الدراسة، وهو ما تؤكده قيمة معامل تصحيح الخطأ ECT (−1) البالغة −0.682 والتابعة إحصائيًا عند مستوى 1%. ويعني ذلك أن نحو 68.2% من الاختلالات قصيرة الأجل تُصحَّح خلال الفترة التالية، بما يدل على سرعة نسبية في عودة النموذج إلى مساره التوازني. وعلى المدى القصير، كان لكل من التغير المتأخر في الواردات ΔIMP (−1) وإنتاج النفط ΔOIL أثر موجب ومعنوي إحصائيا، في حين لم يكن لتغير الناتج المحلي ΔGDP أو معدل التضخم ΔINF أثر معنوي. أما الثابت، فجاء غير معنوي إحصائيا.

جدول (6): نتائج اختبار السببية لجرانجر (Granger Causality):

الفرضية الصفرية	قيمة F	الاحتمالية (Prob.)	القرار
OIL	8.452	0.002	توجد سببية
GDP	2.124	0.145	لا توجد سببية
INF	1.852	0.182	لا توجد سببية
IMP	1.452	0.256	لا توجد سببية
IMP	0.985	0.412	لا توجد سببية

الفرضية الصفرية	قيمة F	الاحتمالية (Prob.)	القرار
IMP	1.124	0.352	لا توجد سببية

تشير النتائج الموضحة بالجداول (6) اختبار سببية جرانجر إلى وجود علاقة سببية ذات دلالة إحصائية بين إنتاج النفط (OIL) والواردات، إذ بلغت قيمة (8.452) = F وقيمة الاحتمالية (0.002)، مما يؤدي إلى رفض الفرضية الصفرية. في المقابل، لم تثبت النتائج وجود سببية معنوية بين الناتج المحلي الإجمالي (GDP) أو معدل التضخم (INF) والواردات، حيث تجاوزت قيم الاحتمالية مستوى 5%. كما لم تظهر الاختبارات الأخرى الخاصة بالواردات (IMP) أي علاقات سببية ذات دلالة إحصائية. وعليه، يتضح أن إنتاج النفط هو المتغير الوحيد الذي يمتلك قدرة تفسيرية سببية تجاه الواردات خلال فترة الدراسة.

4.9 نتائج اختبارات التعلم الالي:

الجدول رقم (7) يوضح الأهمية النسبية في نموذج Random forest.

جدول (7) الأهمية النسبية للمتغيرات في نموذج Random Forest

المتغير	الأهمية (%)	الترتيب
OIL	52.3%	1
GDP	24.8%	2
INF	14.2%	3
D_2011	5.4%	4
D_2020	3.3%	5

جدول (8): مقاييس أداء نماذج التعلم الآلي

النموذج	RMSE	MAE	MAPE	R2
Random Forest	4,250,000	3,120,000	18.5%	0.892
ANN	3,850,000	2,890,000	15.2%	0.914
SVR	4,100,000	3,050,000	16.8%	0.902

5.9 المقارنة بين النماذج القياسية ونماذج التعلم الالي:

الجدول رقم (9) يوضح المقارنة بين النماذج القياسية ونماذج التعلم الالي.

جدول (9) المقارنة الشاملة بين النماذج القياسية ونماذج التعلم الآلي

النموذج	RMSE	MAE	MAPE	R2	الترتيب النهائي
OLS	8,450,000	6,780,000	32.4%	0.784	6
ARDL	7,920,000	6,250,000	29.8%	0.802	5
ECM	7,450,000	5,980,000	28.5%	0.821	4
Random Forest	4,250,000	3,120,000	18.5%	0.892	3
SVR	4,100,000	3,050,000	16.8%	0.902	2
ANN	3,850,000	2,890,000	15.2%	0.914	1

10. الخاتمة والنتائج:

هدفت هذه الدراسة إلى تحليل السلوك الزمني للواردات الليبية خلال الفترة (1998–2022)، وتقدير أثر المتغيرات الاقتصادية الكلية عليها، مع المقارنة بين النماذج القياسية وتقنيات التعلم الآلي.

1. ثبوت وجود علاقة توازن طويلة الأجل بين الواردات والمتغيرات الكلية (F=6.824)
2. يعد إنتاج النفط هو المحدد الأقوى والأهم للواردات $\beta = 42.8$ ونسبة أهمية (52.3%).
3. أظهر نموذج تصحيح الخطأ سرعة تعديل عالية نحو التوازن ECT= −0.682 أي تصحيح 68.2% من الاختلال سنويا.
4. تفوقت نماذج التعلم الآلي بشكل ملحوظ في دقة التنبؤ ANN: (R^2 = 0.914 , MAPE= (15.2%).
5. العلاقات غير الخطية والمركبة بين المتغيرات تم التقاطها بواسطة نماذج التعلم الآلي بفاعلية أكبر.

11. التوصيات:

1. العمل على تنويع مصادر الواردات للحد من المخاطر الاقتصادية.
2. دعم وتعزيز الإنتاج المحلي لتقليل الاعتماد المفرط على الاستيراد.
3. إدارة الطلب على الواردات بحذر خلال فترات انخفاض أو تذبذب إنتاج النفط.
4. بناء نظام إنذار مبكر ومتابعة اقتصادية قائم على تقنيات التعلم الآلي
5. توسيع عينات البحث المستقبلية باستخدام بيانات ربع سنوية أو شهرية.
6. إضافة متغيرات توضيحية أخرى مثل سعر الصرف والدين الخارجي.
7. التكامل بين خوارزميات التعلم الآلي والنماذج الانحيازية (BNN، TVP–VAR).

1.11 افاق البحث المستقبلي:

توصي الدراسة أن يتم التركيز في البحوث المستقبلية على تطوير نماذج متقدمة للتنبؤ والتحليل، باستخدام خوارزميات التعلم العميق، مثل LSTM وGRU وTransformers، إلى جانب نماذج الانحدار والنماذج ذات المعلمات المتغيرة زمنيا، مثل TVP–VAR، بهدف التعامل مع عدم اليقين والتحيز. أيضا توظيف بيانات المدفوعات والمعاملات الآنية، وإجراء مقارنات مع دول نفطية مماثلة، فضلا عن تحليل الواردات حسب القطاعات والسلع، مع إعطاء الأولوية للتعلم العميق، والنماذج المتقدمة، والتحليل القطاعي.

المراجع:

Abushhewa, A. A., & Zarook, T. (2016). The effects of foreign direct investment on economic growth in Libya: A causality analysis.

Aimer, N. M. M. (2017). The effects of oil price volatility on the economic sectors of Libya. International Journal of Business and Social Research, 6, 13–24.

Allaro, H. B. (2018). A time series analysis of structural break time in Ethiopian GDP, export and import. Journal of Global Economics, 6.

Alsanusi, M., Altıntaş, H., & Alnour, M. (2022). The role of real exchange rate in the trade balance between Turkey and Libya. Journal of Ekonomi.

Awidan, R. H. M. (2019). Time series modelling of oil price fluctuations: Applications to Libya and Nigeria.

Babenko, V., et al. (2021). Classical machine learning methods in economics research. WSEAS Transactions on Business and Economics.

Ben-Naser, A. K. M., Bhattarai, K., & Elheddad, M. M. (2017). Estimating equilibrium real exchange rate and misalignment in an oil exporting country: Libya's experience. The Journal of Developing Areas, 52, 249–267.

Brabenec, T., & Šuleř, P. (2020). Machine learning forecasting of CR and PRC balance of trade. SHS Web of Conferences.

Buckmann, M., Joseph, A., & Robertson, H. (2021). Opening the black box: Machine learning interpretability and inference tools. Data Science for Economics and Finance.

Coulombe, P. G. (2020). The macroeconomy as a random forest. SSRN Electronic Journal.

Elbeydi, K. R., Hamuda, A. M., & Gazda, V. (2010). The relationship between export and economic growth in Libya Arab Jamahiriya. Theoretical and Applied Economics, 69–76.

Elsayir, H. (2018). An econometric time series GDP model analysis. Journal of Applied Mathematics and Physics, 6, 2635–2649.

Guimaraes, R. R. S. (2022). Deep learning macroeconomics.

Hauzenberger, N., Huber, F., Klieber, K., & Marcellino, M. (2022a). Bayesian neural networks for macroeconomic analysis. Journal of Econometrics.

Hauzenberger, N., Huber, F., Koop, G., & Mitchell, J. (2022b). Bayesian modeling of TVP-VARs using regression trees [Working paper].

Humbatova, S., & Hajiyev, N. (2020). The impact of oil factor on the car import in Azerbaijan. International Journal of Energy Economics and Policy.

Kaushik, M., & Giri, A. K. (2020). Forecasting foreign exchange rate.

Khan, M. A., et al. (2022). Application of machine learning algorithms for sustainable business management. Sustainability.

Korobilis, D., & Pettenuzzo, D. (2020). Machine learning econometrics. In Oxford research encyclopedia of economics and finance. Oxford University Press.

Kreiw, R. (2019). Impact of the political instability on the Libyan economy. Knowledge International Journal.

Malhotra, A. (2018). A hybrid econometric–machine learning approach for relative importance analysis: Food inflation.

Mayorova, K., & Nikita, N. (2021). Nowcasting growth rates of Russia's export and import by commodity group. Russian Journal of Money and Finance.

Nagem, O., & Howaidi, Z. (2020). Relationship between exports and economic growth in Libya. Studies in Economics and Trade.

Nzayisenga, E., & Zhu, Y. (2020). The import trade forecasting model based on PCA: Evidence from Rwanda. Open Journal of Statistics, 10, 678–693.

Odili, O., & Florence, O. (2017). The effects of exchange rate variability on trade flows in Nigeria.

Persio, L. D., & Segala, C. (2015). Autoregressive approaches to import–export time series II Statistical Finance.

Sermpinis, G., Stasinakis, C., Theofilatos, K. A., & Karathanasopoulos, A. S. (2014). Inflation and unemployment forecasting with genetic support vector regression. Journal of Forecasting, 33, 471–487.

Zheng, E., Tan, Y., Góes, P. B., Chellappa, R., Wu, D.-C., Shaw, M., Sheng, O. R. L., & Gupta, A. (2017). When econometrics meets machine learning. Data and Information Management, 1, 75–83.