

دور خوارزمية الانحدار اللوجستي في التنبؤ بوضع الصادرات الجزائرية في الأسواق الدولية باستخدام لغة البرمجة Python

أحمد لمين بوغنامة^{1*}

¹ مخبر المقاولاتية وإدارة المنظمات، جامعة الشهيد الشيخ العربي التبسي تبسة (الجزائر)

The role of the logistic regression algorithm in predicting the position of Algerian exports in international markets using Python programming language

Ahmed Lamine BOUGHENAMA^{1,*}

¹ Echahid Cheikh Larbi Tebessi University (Algeria)

تاريخ الاستلام: 2024/12/10؛ تاريخ القبول: 2025/06/25؛ تاريخ النشر: 2025/06/30

ملخص: هدفت هذه الدراسة إلى التنبؤ بقابلية استيراد الصادرات الجزائرية باستخدام خوارزمية الانحدار اللوجستي، وذلك بالاعتماد على بيانات تشمل 20 دولة خلال الفترة الممتدة من 2004 إلى 2023 وبالمساعدة بلغة البرمجة Python تم توظيف مجموعة من المتغيرات الاقتصادية الأساسية لتحليل العوامل المؤثرة على تدفقات التجارة الثنائية. أظهرت نتائج الدراسة أن النموذج حقق دقة بلغت 62.75% و 64.75% لكل من المصنف الأول والثاني على التوالي، مع تسجيل قيم منحني ROC بلغت 0.66 و 0.72، مما يدل على كفاءة جيدة في تصنيف البيانات استنادا إلى السمات المميزة مما يعكس فعالية خوارزمية الانحدار اللوجستي في تقديم دعم تحليلي دقيق للقرارات الاستراتيجية الرامية إلى تنويع التجارة الدولية وتعزيز القدرة التنافسية للصادرات الجزائرية. **الكلمات المفتاح:** الصادرات، التنبؤ، تعلم الآلة، خوارزمية الانحدار اللوجستي.

Abstract: This study aimed to predict the importability of Algerian exports using the logistic regression algorithm, based on data covering 20 countries during the period from 2004 to 2023, utilizing the Python programming language. A set of key economic variables was employed to analyze the factors influencing bilateral trade flows.

The study results demonstrated that the model achieved an accuracy of 62.75% for the first classifier and 64.75% for the second classifier, with ROC curve values of 0.66 and 0.72. These findings indicate a good performance in data classification based on distinctive features, reflecting the effectiveness of the logistic regression algorithm in providing precise analytical support for strategic decisions aimed at diversifying international trade and enhancing the competitiveness of Algerian exports.

Keywords: Exports, Prediction, Machine learning, Logistic regression algorithm.

I- تمهيد:

تمثل التجارة الدولية أحد المحركات الرئيسية للنمو الاقتصادي والتنمية المستدامة، حيث تعتمد الدول بشكل كبير على تعزيز صادراتها وتنويعها لدعم ميزانها التجاري وتقليل الاعتماد على مصادر دخل المحدودة. في هذا السياق، تلعب دراسة تدفقات التجارة الثنائية دورا محوريا في فهم ديناميكيات العلاقات التجارية بين الدول، مما يتيح تقديم رؤى استراتيجية تساهم في تعزيز التبادل التجاري وزيادة القدرة التنافسية، ومن هذا المنطلق تبرز أهمية استراتيجيات تنويع الصادرات الجزائرية، بحيث تسعى هذه الأخيرة جاهدة لتوسيع قاعدة شركائها التجاريين وتقليل الاعتماد على المحروقات بهدف تعزيز مرونة اقتصادها في مواجهة التقلبات العالمية.

مع التغيرات الاقتصادية المتسارعة وزيادة المنافسة في الأسواق الدولية، أصبح من الضروري الاستفادة من أدوات تحليلية متقدمة مثل خوارزميات تعلم الآلة، لتوقع الاتجاهات المستقبلية وتحليل العوامل المؤثرة على تدفقات التجارة الخارجية. تساهم هذه الأدوات في تقديم تحليلات دقيقة وتوقعات مبنية على البيانات، مما يساعد صناع القرار والشركات على اتخاذ قرارات استراتيجية مستنيرة تدعم النمو الاقتصادي طويل الأمد، وفي ظل هذه التحديات والفرص يصبح استخدام هذه التقنيات أداة لا غنى عنها لتطوير سياسات تجارية فعالة وتعزيز حضور الجزائر في الأسواق العالمية.

إشكالية الدراسة: انطلاقا مما سبق ارتأينا طرح الإشكالية التالية:

ما مدى فعالية استخدام خوارزمية الانحدار اللوجستي في التصنيف والتنبؤ بالقابلية المحتملة لاستيراد السلع والمنتجات الجزائرية؟

وللإجابة على هذه الإشكالية تم طرح جملة من الأسئلة الفرعية كما يلي:

- هل يمكن أن تقدم تقنية الانحدار اللوجستي تصنيف ناجح للدول من الناحية التجارية بدقة وكفاءة عالية؟

- هل يمكن الوصول الى دقة عالية في التنبؤ بالقابلية لاستيراد السلع الجزائرية؟

الفرضيات: من خلال ما تقدم وبغرض تفسير الإشكالية، تم صياغة الفرضيات الفرعية كما يلي:

- الفرضية الفرعية الأولى: التنبؤ باستخدام خوارزمية الانحدار اللوجستي تقدم نتائج دقيقة؛

- الفرضية الفرعية الثانية: تستطيع خوارزمية الانحدار اللوجستي من التعلم والتمييز بين السمات المختلفة مما يجعلها تتمتع بكفاءة عالية من ناحية التصنيف.

أهداف الدراسة:

تهدف هذه الدراسة إلى تطبيق خوارزمية الانحدار اللوجستي كإحدى تقنيات تعلم الآلة في التنبؤ بالقابلية المحتملة لاستيراد السلع والمنتجات الجزائرية، وذلك من خلال استعمال عينة من البيانات التجارية والاقتصادية لـ 20 دولة أجنبية ذات تعامل تجاري مع الجزائر وباستخدام لغة البرمجة Python.

منهج الدراسة:

تم الاعتماد في هذه الدراسة على المنهج الوصفي باستعراض مختلف المفاهيم المتعلقة بتعلم الآلة في الجانب النظري، بالإضافة إلى المنهج التحليلي والذي تم اعتماده عند القيام بتطبيق خوارزمية الانحدار اللوجستي لتصنيف القابلية الإيجابية لسلع المصدرة من طرف الدولة الجزائرية.

دراسات سابقة:

دراسة (Hrvoje & Berislav, 2022) بعنوان " نهج التعلم الآلي للتنبؤ بالتجارة الدولية: حالة كرواتيا"

ركزت الدراسة على استخدام خوارزميات التعلم الآلي للتنبؤ بتدفقات التجارة الثنائية الدولية، خاصة فيما يتعلق بالواردات والصادرات في حالة كرواتيا. تم جمع بيانات التجارة الثنائية لكرواتيا مع أكثر من 180 دولة حول العالم للفترة الممتدة من عام 2001 إلى 2019، وقد استندت الدراسة إلى المتغيرات الرئيسية لنماذج التجارة القائمة على الجاذبية، والتي تشمل على الصادرات والواردات بدولار الأمريكي بالإضافة إلى العديد من المتغيرات الأخرى مثل اللغة، المسافة والاتفاقيات التجارية، وخلصت الدراسة إلى مجموعة من النتائج وهي:

- ظهرت خوارزميات التعلم الآلي كفاءة عالية في التنبؤ بتدفقات التجارة الثنائية الكرواتية، حيث حققت الشبكة العصبية متعددة الطبقات (MLP) أفضل أداء مقارنة ببقية الخوارزميات المستخدمة بالإضافة إلى أن دقة التنبؤ بالنسبة للدول ذات الحصة الأكبر في التجارة الثنائية الإجمالية لكرواتيا؛

- كانت قيمة RMSE خارج العينة منخفضة عند 0.6 مليون دولار، وهو ما يفسر 79% من تقلبات الصادرات، كما تم تسجيل قيم MAPE للشبكات العصبية أقل من 10% باستمرار في معظم الحالات، مما يشير إلى دقة عالية للخوارزميات في التنبؤ بالتجارة الثنائية الكرواتية.

دراسة (Razia & Pranav, 2022) بعنوان " التنبؤ باستيراد وتصدير السلع باستخدام دعم آلات المتجهات (SVMs) وشبكة العصبية ذات الذاكرة الطويلة قصيرة المدى "

قامت الدراسة بتسليط الضوء على استخدام خوارزمية الانحدار باستخدام آلات المتجهات الداعمة (SVR) للتنبؤ بأسعار السلع المستوردة والمصدرة بين الدول، وذلك باستخدام مجموعة بيانات اقتصادية، وذلك من خلال اقتراح نسخة محسنة من خوارزمية SVR بمساعدة نواة RBF المعدلة لتحسين كفاءة النموذج. بالإضافة إلى ذلك، تم استخدام الشبكات العصبية طويلة الأجل (LSTM) للتنبؤ بأوزان السلع الواردة إلى الدول. وقد خلصت الدراسة إلى النتائج المئوية:

- أظهرت النتائج دقة عالية للتنبؤ باستخدام SVR، مما يؤكد كفاءة الخوارزمية في التنبؤ بالبيانات الاقتصادية.

دراسة (Yonis, et al., 2024) بعنوان " التنبؤ بصادرات التكنولوجيا العالية للدول لتحقيق النمو الاقتصادي المستدام باستخدام تقنيات التعلم الآلي: حالة تركيا "

تهدف هذه الدراسة إلى التنبؤ بصادرات التكنولوجيا العالية لتركيا في إطار أهداف التنمية المستدامة باستخدام تقنيات تعلم الآلة. اقترحت الورقة استخدام ثلاث خوارزميات وهي الشبكات العصبية الاصطناعية، خوارزمية الانحدار اللوجستي، والانحدار باستخدام آلات المتجهات الداعمة (SVR)، للتنبؤ بدقة بقيم صادرات التكنولوجيا العالية بناء على بيانات مثل الناتج القومي

الإجمالي، عدد براءات الاختراع، ونفقات البحث والتطوير للفترة 2007-2023. تم قياس أداء النماذج باستخدام معايير مختلفة مثل معامل التحديد (R^2) وكانت النتائج كالتالي:

— حققت الشبكات العصبية الاصطناعية أعلى دقة بنسبة 94.2% وقيم أخطاء منخفضة ($MSE=0.011$, $MAE=0.073$)، تلاها نموذج SVR بنسبة دقة 90.8%، بينما سجل الانحدار اللوجستي نسبة دقة بلغت 89.7%.

1. الخلفية النظرية للدراسة:

1.1 مفهوم تعلم الآلة:

التعلم الآلي (ML) وهي مجموعة فرعية من الذكاء الاصطناعي، تستفيد من التقنيات الإحصائية لتمكين الآلات من التحسن من خلال التجربة. بدلا من الاعتماد على البرمجة الصريحة تحدد خوارزميات تعلم الآلة الأنماط واكتساب القدرة على تقديم تنبؤات وتوصيات من خلال اكتشاف الأنماط المختلفة في البيانات ومعالجتها، وتكيف هذه الخوارزميات أيضًا بشكل ديناميكي مما يؤدي إلى تحسين كفاءتها ودقتها في حالة مواجهة بيانات جديدة (Chandrasekar, 2021, p. 07).

2.1 مهام تعلم الآلة:

يشمل مجال التعلم الآلي مجموعة من المهام القياسية التي تم تطبيقها على نطاق واسع في العديد من المجالات، ومن أبرزها (بوغنامة و يوسف، 2024):

— التصنيف: تستخدم هذه المهمة لتحديد الفئة أو المجموعة التي ينتمي إليها عنصر معين، ومن أمثلتها تصنيف البريد الإلكتروني إلى رسائل عادية أو رسائل غير مرغوب فيها؛

— الانحدار: تهدف هذه المهمة إلى التنبؤ بقيم عددية مستمرة. على سبيل المثال، يمكن استخدامها لتوقع أسعار الأسهم أو تقدير المؤشرات الاقتصادية بناء على بيانات سابقة؛

— الترتيب: تركز هذه المهمة على ترتيب العناصر وفقا لمعايير محددة، ويعد هذا شائعا في مجالات مثل البحث على الإنترنت، حيث ترتب نتائج البحث حسب مدى صلتها بالكلمات المفتاحية؛

— التجميع: تهدف هذه المهمة إلى تجميع العناصر المتشابهة في مجموعات فرعية بحيث تكون العناصر داخل كل مجموعة متجانسة قدر الإمكان. يستخدم هذا في تطبيقات مثل تحليل سلوك المستخدم أو تقسيم الأسواق؛

— تخفيض الأبعاد: تتعلق هذه المهمة بتقليل عدد الأبعاد التي تمثل البيانات مع الحفاظ على الخصائص الرئيسية لها، ويستخدم هذا الأسلوب بشكل شائع لتقليل حجم البيانات في الصور الرقمية أو لتبسيط النماذج دون فقدان معلومات مهمة؛

3.1 تطبيقات التعلم الآلي:

يمكن تلخيص مختلف مجالات التطبيقات فيما يلي (Pramila & Seema, 2018, pp. 2-3):

— رؤية الكمبيوتر: يشتمل هذا المجال على مجالات فرعية مثل التعرف على الكائنات، اكتشافها ومعالجتها؛

— التنبؤ: التنبؤ هو أحد تطبيقات التعلم الآلي التي تهدف إلى تقديم رؤى مستقبلية استنادا إلى البيانات التاريخية والتحليل الإحصائي، ويشمل التصنيف، التحليل، التشخيص الطبي والتنبؤ بالتغيرات التجارية. على سبيل المثال، يمكن للتعلم الآلي التنبؤ

بحجم الصادرات والواردات بناء على بيانات اقتصادية وتغيرات الطلب العالمي، كما قد تستخدم شركة زراعية هذه التنبؤات لتوسيع إنتاجها وتلبية الطلب المتوقع في الأسواق الأوروبية، بالإضافة إلى ذلك يمكن تطبيق خوارزميات تعلم الآلة في مجال التسويق، يمكن للنماذج التنبؤية تحديد الأسواق الواعدة لمنتج جديد بالاعتماد على بيانات المستهلكين والمنافسة؛

— التحليل الدلالي ومعالجة اللغة الطبيعية: يتضمن التحليل الدلالي ربط الهياكل النحوية من الكلمات والجمل والفقرات بالمعنى العام للنص؛

— استرجاع المعلومات هو علم البحث عن المعلومات داخل المستندات واسترداد المستندات والبيانات الوصفية وقواعد البيانات التي تحتوي على أصوات أو صور.

4.1 أنواع تعلم الآلة:

تصنف خوارزميات التعلم الآلي على نطاق واسع إلى أربعة أنواع: التعلم الخاضع للإشراف، التعلم غير الخاضع للإشراف، التعلم شبه الخاضع للإشراف والتعلم المعزز، بحيث تقدم كل فئة أغراضا مميزة ويمكن تطبيقها على العديد من المشكلات في العالم الحقيقي

التعلم الخاضع للإشراف (Supervised Learning):

يقوم التعلم الآلي الخاضع للإشراف بتدريب نموذج باستخدام بيانات مُسمّاة، حيث تتضمن كل نقطة بيانات سمات الإدخال (Xs) والمخرجات المتوقعة المقابلة (Ys). على سبيل المثال، في مجموعة بيانات مستمدة من التجارة الخارجية لدولة ما، يمكن أن تمثل سمات الإدخال (Xs) مقاييس مثل قيمة الصادرات والواردات، بينما قد تشير المخرجات (Ys) إلى حالة معينة مثل احتمال تحقيق فائض أو عجز تجاري. الهدف الأساسي هو تحديد البنية الداخلية للنموذج من خلال الملاحظات المعروفة باسم الأوزان، والتي تحدد العلاقة بين المدخلات والمخرجات.

— الانحدار: يهدف الانحدار إلى التنبؤ بالقيم المستمرة، بحيث يستخدم النموذج المتغيرات الأولية المعروفة بسمات الإدخال (Xs) للتوصل إلى تنبؤات دقيقة حول القيم الفعلية للمتغيرات المستهدفة (Ys) وذلك من خلال اعتماد النموذج على العلاقة بين المدخلات والمخرجات لتحديد القيم المستقبلية بأكبر قدر من الدقة، مثل التنبؤ بأسعار الأسهم بناءً على العوامل الاقتصادية أو التنبؤ بالقيمة المستقبلية للمتغيرات المالية (Dattaraj, 2019, pp. 27-31).

— التصنيف: يعتبر الانحدار اللوجستي (التصنيف الخطي) إحدى خوارزميات التعلم الآلي الخاضعة للإشراف، تُستخدم للتصنيف والتنبؤ باحتمالية انتماء مدخلات معينة إلى فئة محددة. تعتمد هذه الخوارزمية على دالة لوجستية (تعرف أيضا بالدالة السينية) لتحويل القيم المدخلة إلى احتمالات تتراوح بين 0 و 1، مما يتيح تصنيف البيانات إلى الفئات الإيجابية أو السلبية (بن الضب، 2023، صفحة 25).

التعلم غير الخاضع للإشراف (Unsupervised Learning):

يتميز هذا النهج بقدرته على التعامل مع مجموعات البيانات غير المصنفة، حيث يهدف إلى الكشف عن الأنماط أو الاتجاهات أو الهياكل ذات المغزى دون تدخل بشري، ويستخدم التعلم غير الخاضع للإشراف في مهام متعددة مثل التجميع

وتقدير الكثافة وتعلم الميزات وتقليل الأبعاد واكتشاف الشذوذ واستخراج قواعد الارتباط، حيث يهدف أساسا إلى التحليل الاستكشافي واستخراج الخصائص المفيدة من البيانات (Iqbal , 2021, p. 04).

التعلم شبه المشرف (Semi-Supervised Learning):

يجمع هذا النوع بين خصائص التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف، حيث يعتمد على بيانات مصنفة وغير مصنفة في الوقت نفسه، ونتيجة لذلك يعد هذا النهج مفيدا بشكل خاص في الحالات التي تكون فيها البيانات المصنفة قليلة ولكن البيانات غير المصنفة وفيرة مما يسمح بتحسين دقة التنبؤ مقارنة باستخدام البيانات المصنفة فقط.

أبرز تطبيقات هذا النوع من التعلم هي الترجمة الآلية التي تعتمد على مزج البيانات المصنفة لتوفير نتائج دقيقة مع البيانات غير المصنفة لتعزيز الأداء، بالإضافة إلى اكتشاف الاحتيال من خلال تحليل الأنماط غير المصنفة وربطها بالبيانات المصنفة، وأيضا وضع العلامات على البيانات وتصنيف النصوص لتوفير حلول فعالة ومتكاملة (Iqbal , 2021, p. 04).

التعلم المعزز (Reinforcement Learning):

في هذا النظام، بدلا من تقديم أزواج من مدخلات ومخرجات محددة مسبقا، يتم تحديد الحالة الحالية للنظام ووضع هدف واضح، إلى جانب تحديد الإجراءات المسموح بها مع توضيح القيود البيئية والنتائج المحتملة لهذه الإجراءات بحيث يتعلم نموذج التعلم الآلي تحقيق الهدف بشكل مستقل من خلال تطبيق مبدأ التجربة والخطأ مما يؤدي إلى تعظيم المكافأة.

لقد أثبت التعلم المعزز نجاحا كبيرا في بيئات العالم المغلق مثل الألعاب، حيث تكون الظروف تحت السيطرة ومحددة بشكل جيد، كما يتمتع هذا النظام بأهمية كبيرة في الأنظمة متعددة الوكلاء مثل الأسواق الإلكترونية بحيث يمكن تحسين التفاعلات بين الوكلاء لتحقيق النتائج المرجوة بفعالية أكبر (Christian , Patrick , & Kai , 2021, p. 687).

II – الطريقة والأدوات:

1. مجتمع وعينة الدراسة:

يعد تنوع البيانات حجر الزاوية في خوارزميات تعلم الآلة، حيث يساهم بشكل فعال في اكتشاف الأنماط الخفية والحد من احتمالات الانحياز في النماذج وبالتالي السماح بتعزيز قدرات هذه الخوارزميات على التعامل مع الاختلافات الدقيقة والمتنوعة في البيانات. استنادا إلى هذا المبدأ، تم تحليل البيانات المتاحة المتعلقة بالصادرات والواردات الجزائرية للتأكد من كفايتها من حيث التنوع وحجم العينة لتحقيق أهداف الدراسة.

تهدف الدراسة إلى إبراز دور خوارزميات تعلم الآلة في تحسين استراتيجيات المتابعة لتوجيه الصادرات الجزائرية باستخدام لغة البرمجة Python، وقد شملت البيانات عينة مكونة من 20 دولة أجنبية ومن بين هذه الدول: الصين، فرنسا، إيطاليا، تركيا، بلجيكا وألمانيا، تم اختيارها بعناية لتغطي فترة زمنية تمتد من عام 2004 إلى 2023.

تمثل هذه الفترة إطارا زمنيا كافيا لاستخلاص أنماط واستنتاجات دقيقة حول القابلية الممكنة لهذه الدول لاستيراد المنتجات الجزائرية، وذلك استنادا إلى مجموعة من المؤشرات الاقتصادية مثل الناتج المحلي الإجمالي، وحجم التبادل التجاري

بين الجزائر وهذه الدول، الأمر الذي يقدم رؤية أكثر وضوحا حول العوامل المؤثرة في تحسين التنافسية التجارية للجزائر على المستوى الدولي.

2. متغيرات الدراسة:

■ المتغير التابع:

في هذه الدراسة، تمثل المتغيرات التابعة نسبيتي الصادرات والواردات إلى الناتج المحلي الإجمالي، وهما مؤشران رئيسيان لتقييم القابلية المحتملة لتصدير السلع والمنتجات الجزائرية. يتمثل المتغير التابع الأول (Y1) في نسبة الصادرات إلى الناتج المحلي الإجمالي (Alfredo & Zhenhui, 2000) بحيث تعكس القيمة 0 قابلية منخفضة لاستيراد الصادرات الجزائرية (منتجات و سلع)، بينما تشير القيمة 1 إلى قابلية عالية لاستيراد السلع الجزائرية، أما المتغير التابع الثاني (Y2) فيمثل نسبة الواردات إلى الناتج المحلي الإجمالي، وبنفس التصنيف؛ إذ تعني القيمة 0 قابلية منخفضة، والقيمة 1 تشير إلى قابلية عالية لاستيراد الصادرات الجزائرية.

يعكس هذان المؤشران مدى قبول الأسواق الأجنبية للمنتجات الجزائرية، ما يوفر رؤية دقيقة لدراسة العوامل المؤثرة على التبادل التجاري وتعزيز استراتيجيات تنويع الصادرات.

الجدول رقم 01: المتغيرات التابعة

المتغيرات	رمز المتغير	طرق القياس	المصدر
نسبة الصادرات إلى الناتج المحلي الإجمالي	Y1	$100 \times \frac{\text{قيمة الصادرات}}{\text{الناتج المحلي الإجمالي}}$	(International Trade Centre, 2024)
نسبة الواردات إلى الناتج المحلي الإجمالي	Y2	$100 \times \frac{\text{قيمة الواردات}}{\text{الناتج المحلي الإجمالي}}$	(World Bank, 2024)

المصدر: من اعداد الباحث

تم تصنيف البيانات الخاصة بدول بناء على أساس سنوي ووفق ما تعكسه النسب وفق ما يلي:

المصنف الأول (Y1): يعكس هذا التصنيف نسبة الصادرات إلى الناتج المحلي الإجمالي، حيث تشير النسبة المرتفعة إلى احتمال اعتماد الدولة على الصادرات، مما قد يعكس ضعفا في القابلية لاستيراد السلع الأجنبية. وبالتالي، كلما انخفضت هذه النسبة زادت القابلية لاستيراد السلع الجزائرية، ويصنف هذا الوضع بـ (1).

المصنف الثاني (Y2): يركز هذا التصنيف على نسبة الواردات إلى الناتج المحلي الإجمالي، حيث تشير النسبة المرتفعة إلى احتمال اعتماد الدولة الكبير على الواردات لتلبية احتياجاتها. كلما ارتفعت هذه النسبة، دل ذلك على وجود فرصة أكبر لتصدير السلع الجزائرية إلى تلك الدولة، ويصنف هذا الوضع بـ (1).

■ المتغيرات المستقلة:

لتوضيح فعالية خوارزميات تعلم الآلة في تصنيف القابلية السوقية للصادرات الجزائرية، تم الاعتماد على خمس متغيرات مستقلة موضحة في الجدول أدناه، وقد تم اختيار هذه المتغيرات بناء على الدراسات السابقة والتي أثبتت هذه المتغيرات جدواها في تقييم القابلية العالية أو المنخفضة للأسواق الأجنبية لاستيراد المنتجات الجزائرية، مما يجعلها أدوات أساسية لدعم استراتيجيات تنويع الصادرات وتعزيز القدرة التنافسية للجزائر على الصعيد الدولي.

الجدول رقم 02: طرق قياس متغيرات الدراسة

المتغيرات	رمز	طرق القياس	المصدر
صادرات الجزائر	R1	القيمة المصدرة من المنتجات بواسطة الجزائر الى دول محل الدراسة (بدولار الأمريكي)	(International Trade Centre, 2024)
واردات الجزائر	R2	القيمة المستوردة من المنتجات بواسطة الجزائر الى دول محل الدراسة (بدولار الأمريكي)	(World Bank, 2024)
صادرات الدول	R3	القيمة المصدرة من المنتجات للدول محل الدراسة (بدولار أمريكي)	
واردات الدول	R4	القيمة المستوردة من المنتجات للدول محل الدراسة (بدولار أمريكي)	
الناتج المحلي الاجمالي	R5	قيمة الناتج المحلي الاجمالي للدول محل الدراسة (بدولار الأمريكي)	

المصدر: من اعداد الباحث بالاعتماد على الدراسات السابقة

III- النتائج ومناقشتها:

1. عرض طبيعة المتغيرات

عند وصف طبيعة كل متغير في البيانات، من الضروري تحديد نوعه بدقة سواء كان المتغير ذا طبيعة رقمية أو نصية، ويتم تصنيف المتغيرات الرقمية إلى نوعين رئيسيين: الأعداد الصحيحة التي ترمز بـ (int64) والأعداد العشرية التي ترمز بـ (float64)، أما المتغيرات النصية فتندرج تحت النوع (object) (بن الضب، 2023، صفحة 29).
يسمح هذا التصنيف في فهم طبيعة البيانات بشكل أفضل، كما يعد خطوة أساسية لضمان جودة البيانات وتحسين أداء النماذج التنبؤية المستخدمة، خاصة في الدراسات التي تعتمد على تعلم الآلة لتحليل الأنماط واستخلاص الاستنتاجات الدقيقة.
نعرض الجدول الموالي الذي يبرز طبيعة المتغيرات:

الجدول رقم 03: طبيعة متغيرات الدراسة

```
Country    object
YR          int64
Y1          int64
Y2          int64
R1          int64
R2          int64
R3          float64
R4          float64
R5          float64
dtype: object
```

المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

يُظهر الجدول في الصورة قائمة المتغيرات مع أنواع البيانات الخاصة بكل منها حيث تُصنّف المتغيرات النصية مثل Country ضمن الفئة النصية (object)، بينما يمثل المتغير YR عدد السنوات وهو من النوع العددي الصحيح (int64) كما أن المتغيرات التابعة Y1 و Y2 والمتغيرات المستقلة R1 و R2 تأخذ أيضا طبيعة البيانات العددية الصحيحة (int64) أما المتغيرات المستقلة الأخرى R3، R4 و R5 فهي ذات طبيعة عشرية (float64)، يساعد هذا التنوع في أنواع البيانات على تحقيق فهم شامل وأكثر دقة للنموذج المستخدم وذلك من خلال يشير استخدام قيم دقيقة لتحليل المؤشرات الاقتصادية، خاصة عند تطبيق خوارزميات تعلم الآلة لتحليل العلاقات بين المتغيرات التابعة والمستقلة.

2. الإحصائيات الوصفية:

تعد معالجة المشكلات المتعلقة بالمتغيرات من الخطوات الأساسية في تطبيق خوارزميات تعلم الآلة، حيث تواجه هذه الخوارزميات صعوبة في التعامل مع القيم المفقودة أو غير الصحيحة والتي قد تؤثر سلبا على دقة الخوارزمية وأدائها، وللتأكد من عدم وجود بيانات مفقودة قبل الانتقال إلى المراحل اللاحقة يمكن استخدام الأمر sum().isnull() الذي توفره لغة البرمجة Python لفحص البيانات بشكل تلقائي وعرض عدد القيم المفقودة في كل متغير، مما يسهل اكتشاف هذه المشاكل ومعالجتها بشكل فعال قبل بدء في تطبيق الخوارزميات.

الجدول 04: عرض مختصر لبيانات الدراسة

	Country	YR	Y1	Y2	R1	R2	R3	R4	R5
0	CHN	2004	0	1	259078000	980519000	6.047750e+11	5.561830e+11	1.949450e+12
1	CHN	2005	1	1	363733000	1404420000	7.733390e+11	6.487120e+11	2.290020e+12
2	CHN	2006	1	1	143122000	1947514000	9.917310e+11	7.828120e+11	2.754150e+12
3	CHN	2007	1	1	1160932000	2741975000	1.258060e+12	9.500210e+11	3.555660e+12
4	CHN	2008	0	1	849219000	3751910000	1.497870e+12	1.149040e+12	4.577280e+12

المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

الجدول 05: الكشف عن البيانات المفقودة

```
Missing values per time series:
Country      0
YR           0
Y1           0
Y2           0
R1           0
R2           0
R3           0
R4           0
R5           0
dtype: int64
```

المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

يُظهر الجدول وجود خمس متغيرات مميزة ذات طبيعة رقمية تستخدمها الخوارزمية لتحديد العلاقة بين المتغيرات المستقلة والمخرجات المتوقعة (y) بشكل دقيق. بالإضافة إلى ذلك، يسلط الجدول رقم 05 الضوء على أن بيانات الدراسة خالية تماما من القيم المفقودة، مما يضمن عدم وجود أي تأثير سلبي على دقة الخوارزمية

يلخص الجدول التالي الإحصائيات الوصفية لمجموعة البيانات والتي قدرت 400 (4.000000e+02) مشاهدة لكل متغير من متغيرات الدراسة.

الجدول 06: الإحصائيات الوصفية

	R1	R2	R3	R4	R5
count	4.000000e+02	4.000000e+02	4.000000e+02	4.000000e+02	4.000000e+02
mean	2.314847e+09	1.513677e+09	6.746958e+11	6.793655e+11	2.847141e+12
std	3.134812e+09	1.847292e+09	6.494757e+11	6.901222e+11	4.371071e+12
min	2.840000e+06	4.689000e+07	4.884249e+10	6.322075e+10	1.883290e+11
25%	3.837718e+08	3.126492e+08	2.376892e+11	2.423070e+11	6.856575e+11
50%	1.110428e+09	8.036715e+08	4.913800e+11	4.929235e+11	1.472495e+12
75%	2.955734e+09	1.786158e+09	7.969515e+11	7.969192e+11	2.730855e+12
max	2.003229e+10	9.498749e+09	3.719320e+12	3.966170e+12	2.772070e+13

المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

الجدول 07: عدد التصنيفات

المصنف الأول (Y01)	المصنف الثاني (Y02)
Y1 0 236 1 164 Name: count, dtype: int64	Y2 1 232 0 168 Name: count, dtype: int64


المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

في الجدول السابق تم استعراض عدد المميزات الموجودة في كل تصنيف وذلك على نطاق سنوي، بحيث قد تم تسجيل 164 حالة لدى المصنف الأول والتي تعبر عن قابلية عالية للاستيراد الصادرات الجزائرية من قبل الدول الأجنبية محل الدراسة، في حين تم تسجيل 232 حالة لدى المصنف الثاني والتي تعبر عن قابلية عالية للاستيراد الصادرات الجزائرية من قبل الدول الأجنبية محل الدراسة

3. تصور البيانات:

يستخدم التصور (Visualization) لفهم كيفية توزيع البيانات، وذلك باستخدام مكتبة (Matplotlib) والرسم البياني للتشتت (Scatter plot). يوضح الشكل الموالي تصور التوزيعات لبعض المتغير

الجدول 08: تصور التوزيعات للمتغير R1 والمتغير R2



المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

4. تصميم خوارزمية الانحدار اللوجستي:

تم انشاء خوارزمية الانحدار اللوجستي باستخدام مجموعة من الوظائف الأساسية التي تم توضيحها في النقاط التالية (بوغنامة و يوسف، 2024):

الجدول رقم 09: خوارزمية الانحدار اللوجستي

الهدف	الدالة
تستخدم الدالة <code>__init__</code> لتهيئة المعاملات الأساسية للنموذج مثل معدل التعلم (<code>l_rate</code>) وعدد التكرارات (<code>iterations</code>) التي يحتاجها النموذج أثناء التدريب.	"__init__"

"fit"	تركز الدالة على تدريب النموذج من خلال البيانات المدخلة (R) والتصنيفات المرتبطة بها (Y)، مما يسمح للنموذج بتعلم الأنماط وتحسين دقته.
"predict"	تقوم دالة بتقديم التوقعات المتعلقة بالبيانات الجديدة عبر حساب الاحتمالات المحسوبة وتحديد التصنيف النهائي استنادًا إلى قيمة عتبة 0.5 لتحديد التصنيفات.
"Z-score"	يستخدم مقياس Z-score كأداة لتحويل البيانات وتوحيدها، حيث يساعد في تقليل تأثير القيم الشاذة أو المتطرفة على النموذج وبالتالي تحسين أداء الخوارزمية في التصنيف التنبؤي بالنتائج.


المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python


5. نتائج خوارزمية الانحدار اللوجستي:

■ منحنى ROC:

أداة تحليلية شائعة تستخدم لتقييم كفاءة نماذج التصنيف في مجالي علم البيانات وتعلم الآلة، بحيث يوضح هذا المنحنى مدى قدرة النموذج على التفريق بين الفئات المختلفة بناءً على السمة المستهدفة، حيث تتراوح القيم بين 0 و 1. كلما اقترب المنحنى من الزاوية العلوية اليسرى وابتعد عن القطر، زادت قدرة النموذج التمييزية ودقته في التصنيف (عبد الرزاق ، 2020، صفحة 123).

الشكل 07: منحنى ROC





المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

كما يلاحظ في الجدول 07، فإن منحنى المصنف الأول يتجه الى القسم الأعلى من الجهة اليسرى مما يدل على قدرة الخوارزمية في التصنيف بين الدول ذات قابلية المرتفعة لاستيراد الصادرات من السلع الجزائرية وذات القابلية المنخفضة، بالإضافة الى الملاحظة نستعمل الحزمة (sklearn.metrics) على لغة البرمجة لتحديد مساحة المنطقة تحت منحنى ROC، والذي سجل قيمة رقمية تقترب من الواحد. ROC curve (area=0.66).

أما بالنسبة للمصنف الثاني (Y2) فإن المنحنى يتجه كذلك الى القسم الأعلى من الجهة اليسرى مما يدل على قوة الخوارزمية في التصنيف بين ذات قابلية المرتفعة لاستيراد الصادرات من السلع الجزائرية وذات القابلية المنخفضة، بالإضافة الى تسجيل سجل قيمة رقمية تقترب من الواحد. ROC curve (area=0.72).

■ دقة التنبؤ لخوارزمية الانحدار اللوجستي

الجدول 08: نتائج التنبؤ وفق خوارزمية الانحدار اللوجستي

المصنف الأول (Y01)		المصنف الثاني (Y02)	
المقياس	درجة التنبؤ	المقياس	درجة التنبؤ
Accuracy	0.6275	Accuracy	0.6475

المصدر: من إعداد الباحث بالاعتماد على لغة البرمجة Python

يشير الجدول رقم 08 إلى قدرة خوارزمية الانحدار اللوجستي على التنبؤ بالقابلية المحتملة لاستيراد الصادرات الجزائرية لدى الدول محل الدراسة، بحيث تم التوصل الى دقة 62.75% في المصنف الأول مما يفسر قدرة الخوارزمية على التعلم وقياس

الارتباطات الموجودة بين السمات المختلفة لكل حالة واستعماله للتنبؤ بتصنيف الحالة الاقتصادية للدول محل الدراسة، بالإضافة الى تسجيل نسبة 64.75% في المصنف الثاني، وهذا يدل على أن الخوارزمية تمكنت من التنبؤ الى حد مقبول.

IV- الخلاصة:

يعد استخدام خوارزميات الانحدار اللوجستي في التنبؤ خطوة مهمة نحو تحسين فهمنا وتنبؤنا بمستقبل القطاع التجاري، ففي ظل تطور أنظمة التعلم الآلي والقدرات التقنية الحديثة، نجحت الخوارزمية في تحقيق تنبؤات دقيقة وهذا ما حاولنا القيام به في هذه الدراسة وذلك بغرض التنبؤ بقبالية استيراد الصادرات الجزائرية من السلع والمنتجات ومن أهم النتائج التي توصلنا لها:

- تم التوصل إلى أعلى قيمة لمقياس الدقة (Accuracy) والذي يساوي: 62.75% و 64.75% لكل من المصنف الأول والثاني على التوالي، وهذا ما يثبت قدرة تقنيات تعلم الآلة بشكل عام وخوارزمية الانحدار اللوجستي على التنبؤ بتعثر بقبالية استيراد وهو ما يثبت صحة الفرضية الأولى؛
- تقدم خوارزمية الانحدار اللوجستي كفاءة جيدة في التصنيف، حيث سجلت على منحنى ROC قيمة 0.66 و 0.72 وهي ما تمثل إمكانية جيدة للتصنيف البيانات انطلاقاً من السمات المميزة وهو ما يثبت صحة الفرضية الثانية.

الإحالات والمراجع:

باللغة العربية:

¹. مقالات:

1. علي بن الضب. (أغسطس، 2023). دور الذكاء الاصطناعي وتعلم الآلة في تعزيز كشف الاحتيال على بطاقات الائتمانية. دراسات تطوير القطاع المالي - صندوق النقد العربي، الصفحات 1-41.

². الرسائل الجامعية:

1. مريخي عبد الرزاق. (2020). الانذار بالفضل المالي للمؤسسات الاقتصادية بتطبيق مقارنة الشبكات العصبية الاصطناعية - حالة عينة من مؤسسات الجزائرية-. أطروحة دكتوراه في المحاسبة والتدقيق. الجزائر: جامعة الجزائر 03.

³. ملتقيات علمية:

1. أحمد لمين بوغنامة، ورفيق يوسف. (2024). استخدام خوارزمية الانحدار اللوجستي في التنبؤ بالتعثر المالي للبنوك الإسلامية. ملتقى دولي تطور التمويل الاسلامي على ضوء التغيرات المعاصرة، (الصفحات 01-17). جامعة تلمسان.

● باللغة الأجنبية:

1. Alfredo, m., & Zhenhui, x. (2000). Export growth and domestic performance. Review of international economics, pp. 60-73.
2. Chandrasekar, V. (2021). Machine Learning and Artificial Intelligence for Agricultural Economics. Switzerland: Springer Nature.
3. Christian, J., Patrick, Z., & Kai, H. (2021, April 8). Machine learning and deep learning. Electronic Markets, pp. 685-695.
4. Dattaraj, J. R. (2019). Keras to Kubernetes: The Journey of a Machine Learning Model to Production. Indianapolis: John Wiley & Sons, Inc.
5. Hrvoje, J., & Berislav, Ž. (2022, 11 06). A Machine Learning Approach to Forecast International Trade: The Case of Croatia. Business Systems Research, pp. 144-160.
6. International Trade Centre. (2024, 11 20). TRADE MAP. Retrieved from TRADE MAP: <https://www.trademap.org/>
7. Iqbal, H. (2021, 03 2021). Machine Learning: Algorithms, Real World Applications and Research Directions. SN Computer Science, pp. 1-21.

8. Pramila , P., & Seema , S. (2018). A Review of Machine Learning and Deep Learning Applications. 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA) (pp. 1-6). Pune, India: IEEE.
9. Razia, S., & Pranav, R. (2022, 01 20). Predicting the import and export of commodities using support vector regression and long short-term prediction models. International Journal of Computing and Digital Systems, pp. 635-647.
10. World Bank. (2024, 11 20). Data Bank. Retrieved from Data Bank: <https://databank.worldbank.org/source/jobs/Series/>
11. Yonis, G., Ceren , O., Mehmet , K., Dilsad, E., Zeynep , U., Nisa , E., & Pınar , C. (2024, 06 29). Predicting High Technology Exports of Countries for Sustainable Economic Growth by Using Machine Learning Techniques: The Case of Turkey. sustainability, pp. 1-20.