

استخدام نموذج SVM في التنبؤ بالسلاسل الزمنية

using SVM models to forecast time series



سمير فرج رشيد أبو دحروج *

جامعة الأزهر - فلسطين

Samir.abu.dahrouj@gmail.com

-

تاريخ النشر: 2023/06/30

تاريخ المراجعة: 2023/04/25

تاريخ الاستلام: 2023/03/25

ملخص

تناول هذا البحث بناء عدة نماذج من نماذج (SVM) المختلفة للحصول على أفضل نموذج يساعد على التنبؤ في الأجل القصير بأسعار الذهب العالمية، بالاعتماد على بيانات السلسلة الزمنية الشهرية لأسعار الذهب العالمية للفترة الزمنية الممتدة من شهر يناير 2000 حتى شهر سبتمبر 2022 بواقع 273 مشاهدة، وذلك من خلال المفاضلة بين هذه النماذج حسب أقل قيم للمعايير وهما خطأ التدريب وعدد متجهات الدعم، لإيجاد أنسب نموذج لتحليل البيانات محل الاهتمام، وقد توصلت النتائج إلى أن نموذج (SVM) الذي يحتوي على $\gamma=50$, $\epsilon=0.1$, $\text{Cost}(C)=10000$ ، والحاصل على أقل القيم لمعايير التقييم هو النموذج الأنسب والملائم لتحليل البيانات، وذلك للتنبؤ المستقبلي بأسعار الذهب العالمية، وبالاعتماد على هذا النموذج تم التنبؤ بأسعار الذهب العالمية حتى نهاية شهر إبريل 2023، وقد كانت القيم التنبؤية تتبع نفس السلوك للسلسلة الأصلية مما يدل على كفاءة النموذج.

الكلمات المفتاحية: نموذج SVM، التنبؤ، السلاسل الزمنية.

Abstract:

This research dealt with the construction of several models of different (SVM) models to obtain the best model that helps to predict in the short term global gold prices, based on the monthly time series data of global gold prices for the period from January 2000 to September 2022 by 273 views, by comparing these models according to the lowest values of the criteria, namely training error and the number of support vectors, to find the most appropriate model for analyzing the data of interest, and the results found that The (SVM) model, which contains, $C = 10000$, $\gamma=50.$, and which has the lowest values for the evaluation criteria, is the most appropriate and appropriate model for data analysis, in order to predict the future global gold prices, and based on this model, global gold prices were predicted until the end of April 2023, and the predictive values followed the same behavior for the original series, which indicates the efficiency of the model.

Keywords: SVM model, forecasting, time series.

مقدمة

يعتبر التعلم الآلي أحد فروع الذكاء الاصطناعي، حيث يتداخل التعلم الآلي والمحاكاة مع الإحصاء في نواح كثيرة، وهذا من خلال تطوير العديد من التقنيات والمنهجيات الإحصائية الداعمة لمهام التعلم الآلي وجعلها قادرة على التفاعل بينها وبين المحيط الخارجي وكذا إعطاء نتائج تدعم اتخاذ القرار، وعلى اعتبار أن طريقة متجهات شعاع الدعم الآلي SVM عبارة عن نظم معلومات ديناميكية، حيث تتشكل وتبرمج طيلة فترة التطوير المخصصة للتدريب والتعلم، أي أنها تتعلم من التجربة وتكتسب معارفها من خلال التدريب والممارسة العملية، فهي تستطيع تمييز الأنماط وتحديد الرموز المكتوبة والتعرف على الكلمات والتنبؤ بالمتغيرات وغيرها من التطبيقات المختلفة خاصة في مجالات الأعمال والاقتصاد (بوزيدي و بن عيسى، 2020).

إن السلاسل الاقتصادية لما لها من خصوصيات خطية وغير خطية تجعل الطرق التقليدية المعروفة بمنهجية (Box & Jenkins) في بعض الأحيان غير قادرة على التنبؤ الكفؤ، كون الطرق السابقة للتنبؤ تحمل بين طياتها الكثير من الشكوك والضبابية حول دقة نتائجها، الأمر الذي حدا بالدراسة إلى استخدام طرق إحصائية مناسبة أكثر دقة ومنهجية وموضوعية (درويش، 2018)، حيث تم تقديم العديد من النماذج القائمة على آلات التعلم (Learning Machines) لتحليل السلاسل الزمنية، من بينها، آلة المتجه الداعم (Support Vector Machines) فهي تقنية جديدة مصممة لحل مشاكل التصنيف والانحدار غير الخطية في تحليل السلاسل الزمنية نظراً لقدرتها على تحقيق أداء عال ودقة اختبار، يمكن أن يكون (SVM) مفيداً بشكل خاص في التنبؤ بالسلاسل الزمنية (Okasha, 2014).

ونظراً للظروف السياسية التي يمر بها العالم في الآونة الأخيرة حيث أن معظم الدول غير مستقرة سياسياً واقتصادياً فإن ذلك يؤثر على أسعار الذهب العالمية، لذلك يعد التنبؤ بالسلوك المستقبلي لأسعار الذهب من الموضوعات المهمة في المجال الاقتصادي، حيث يتم من خلاله وضع الخطط اللازمة لتفادي الخسائر الناجمة عن التقلبات التي تحدث في أسعاره، بالإضافة لكونه يمثل القوة الاقتصادية للدولة.

1. مشكلة الدراسة

مع وجود طرق مختلفة للتنبؤ بالسلاسل الزمنية الاقتصادية والتي تحتوي على أنماط خطية وغير خطية تجعل الطرق التقليدية، في بعض الأحيان، غير قادرة على التنبؤ الكفء، مما دفع العديد من الباحثين إلى التفكير في إيجاد طرق بديلة أكثر تقدماً كتقنية آلة المتجه الداعم (SVM) Support Vector Machines ، ولكي نحصل على نماذج تنبؤ لبيانات السلاسل الزمنية يكون لها المقدرة على تصوير الواقع، وبدقة عالية في التنبؤات المستقبلية، يجب أن تأخذ هذه النماذج كل الاعتبارات المتعلقة بالبيانات من خطية وعدم خطية ونوعية البيانات، ومن هنا تكمن مشكلة الدراسة في التساؤل الرئيس التالي :

ما هو النموذج الأمثل من بين نماذج SVM للتنبؤ بأسعار الذهب العالمية شهرياً؟

2. أهداف الدراسة

- تحديد النموذج الأمثل من بين نماذج SVM.
- استخدام النموذج الأمثل في التنبؤ بالأسعار العالمية الشهرية من الذهب مستقبلاً.

3. أهمية الدراسة

3.1 الأهمية التطبيقية:

تنبع الأهمية التطبيقية لهذه الدراسة من الأهمية الكبيرة التي تتمتع بها أساليب التنبؤ في تحليل بيانات السلاسل الزمنية الاقتصادية، بغرض إمداد أصحاب رؤوس الأموال بمعلومات مستقبلية عن أسعار الذهب العالمية، وذلك لأخذ الحيطة والحذر من التقلبات السياسية العالمية والأوضاع الاقتصادية المتذبذبة التي تتعرض لها هذه الأسعار، ووضع الخطط المستقبلية حسب النتائج المتوقعة.

3.2 الأهمية الإحصائية:

تستخدم الدراسة أسلوب شعاع الدعم الآلي (SVM)، حيث تتمثل الأهمية الإحصائية للدراسة في إيجاد نموذج من نماذج (SVM) يستخدم للتنبؤ بأسعار الذهب العالمية في الأشهر القادمة من أجل التخطيط للمستقبل.

4. مصدر البيانات:

تم الحصول على بيانات الدراسة الخاصة بأسعار الذهب العالمية خلال الفترة الزمنية الممتدة من شهر يناير 2000 حتى شهر سبتمبر 2022 من الرابط التالي:

<https://www.indexmundi.com/commodities/?commodity=gold&months=360>

5. حدود الدراسة:

تم تقسيم حدود الدراسة إلى حدود زمنية وموضوعية

الحدود الزمنية: الفترة الزمنية من شهر يناير 2000 حتى شهر سبتمبر 2022.

الحدود الموضوعية: أسعار الذهب العالمية.

6. الدراسات السابقة:

هنالك العديد من الدراسات السابقة التي تناولت الموضوع محل الدراسة، المتمثلة في الدراسات العربية، والأخرى الأجنبية، نذكر منها:

دراسة (لطفی ، كنجو، و تقار ، 2022)

هدف الدراسة إلى تقييم فعالية استخدام نموذج شعاع الدعم الآلي في التنبؤ بأداء الأسهم وذلك بالتطبيق على المصارف التجارية الخاصة المدرجة في سوق دمشق للأوراق المالية والتي يبلغ عددها أحد عشر مصرفاً، خلال الفترة الزمنية الممتدة من عام 2012 وحتى عام 2020، وتمت الدراسة من خلال استخراج البيانات الواردة في التقارير المالية التي تنشرها المصارف عينة الدراسة، وتوصلت الدراسة إلى مجموعة من النتائج من أهمها: صلاحية نموذج شعاع الدعم الآلي للتنبؤ بأداء أسهم المصارف التجارية الخاصة المدرجة في سوق دمشق للأوراق المالية، فقد بلغت دقته في التنبؤ 85.71%.

دراسة (Makala & Li, , 2021)

هدف الدراسة إلى المقارنة بين نموذج ARIMA و نموذج SVM للتنبؤ بأسعار الذهب اليومية من عام 1979 إلى 2019 في التحليل، تم استخدام البيانات حتى عام 2014 لتدريب النماذج وتم استخدام الباقي كمجموعة اختبار للتحقق من الصحة، أظهرت نتائج الدراسة أن نموذج SVM أفضل مقارنة بـ ARIMA باستخدام معايير التقييم حسب أقل قيم للمعايير لـ RMSE و MAPE، وقد توصلت الدراسة إلى أن نموذج SVM الحاصل على أقل القيم لمعايير التقييم هو النموذج الأنسب والملائم لتحليل بيانات الدراسة، وتم استخدامه في التنبؤ بأسعار الذهب اليومية نظراً لدقته العالية.

دراسة (التلواني و عبد الحميد، 2021)

هدفت الدراسة إلى استخدام كلاً من الشبكات العصبية الاصطناعية (ANN) وآلة متجه الدعم (SVM) ونماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية (ARIMA) للتنبؤ بمؤشر أسعار المعادن الشهري، تم استخدام بيانات السلسلة الزمنية لمؤشر أسعار المعادن الشهري وذلك خلال الفترة الزمنية من أكتوبر 1990 أكتوبر 2020 بواقع 361 مشاهدة، توصلت الدراسة في البداية إلى تحديد النموذج الأفضل من بين نماذج كل طريقة وكانت النتائج كالتالي -5-5 MLP, ARIMA(1,1,0), (gamma(y=100, Epsilon(ε)=0.1, Cost(C)=1000 and SVM with MLP 5-100-1, وفي نهاية الدراسة تمت المفاضلة بين النماذج المقترحة باستخدام معايير دقة التنبؤ، MAPE, RMSE, MAE، وأشارت النتائج إلى أن نموذج ELM أفضل من نماذج ARIMA, MLP, SVM، بالإضافة إلى أن نموذج ARIMA أفضل من MLP, SVM.

دراسة (Tripathy, 2019)

هدفت الدراسة إلى التنبؤ باتجاه حركة سعر إغلاق مؤشر بلومبرج S&P BSE TECK في سوق الأسهم الهندية من يناير 2008 إلى يناير 2018 باستخدام نموذج SVM، وتشير نتائج الدراسة إلى أن متوسط دقة التنبؤ بلغ 60.2% بعد فترة الأزمة المالية لعام 2008، كما توصلت الدراسة إلى أن اتجاه حركة السوق يكون إيجابياً عندما يكون سعر الإغلاق أعلى من سعر إغلاق اليوم السابق، وأن نموذج SVM لديه أداء تنبؤ أفضل على المدى القصير والمتوسط مقارنة بالمدى الطويل.

دراسة (Patil, patidar, & jain, 2016)

هدفت الدراسة إلى اختبار صلاحية نموذج شعاع الدعم الآلي للتنبؤ بأداء أسهم الشركات المساهمة، وتمت الدراسة بالتطبيق على ثلاث عشرة شركة مساهمة عالمية، خلال الفترة الزمنية الممتدة ما بين عامي 2004-2015، وتم الاعتماد على التقارير المالية السنوية التي تنشرها المصارف عينة الدراسة، وتم تقسيم البيانات المالية ما بين بيانات عينة تدريب، وبيانات عينة اختبار بنسبة 70% و30% على التوالي، وتوصلت الدراسة إلى مجموعة من النتائج من أهمها صلاحية النموذج للتنبؤ بأداء أسهم الشركات المساهمة، حيث بلغت دقة النموذج في التنبؤ 100% بالنسبة لبيانات عينة التدريب، و91.39% بالنسبة لبيانات عينة الاختبار.

دراسة (Okasha, 2014)

هدفت الدراسة إلى المقارنة بين نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية (ARIMA) وANN وSVM على مؤشر القدس لبيانات السلاسل الزمنية لسوق الأوراق المالية الفلسطينية بواقع 1321 مشاهدة، حيث تم تقسيم السلسلة إلى جزأين: مجموعة التدريب وتتكون من 1255 مشاهدة (90% من السلسلة)، و10% من السلسلة وتشكل 66 مشاهدة كمجموعة اختبار، وتم توقع النقاط المستقبلية لمدة شهرين، تم تقييم نتائج تطبيق طرق SVM ودقة التنبؤ ومقارنتها مع تلك الخاصة بطريقتي ARIMA وANN من خلال الحد الأدنى من خطأ الجذر التربيعي للوغاريتم الطبيعي للبيانات، خلصت النتائج إلى أن SVM توفر نموذجاً أكثر دقة وتقنية تنبؤية وكفاءة لمثل هذه البيانات المالية مقارنة مع نمودجي ANN وARIMA.

7. منهجية الدراسة

تتضمن الأساليب غير الخطية شائعة الاستخدام في التنبؤ بالسلاسل الزمنية أسلوب شعاع الدعم الآلي Support Vector Machines (SVM)، حيث تم استخدامه للتنبؤ بأسعار الذهب العالمية، وذلك من خلال الاطلاع على عدد من المراجع والدراسات التي تناولت هذا الأسلوب في تحليل السلاسل الزمنية، حيث سيتم التعامل مع سلسلة أسعار الذهب العالمية الشهرية، والتوصل إلى النموذج المناسب الذي يمثل هذه السلسلة لتحديد وتوفيق النموذج الأمثل للتنبؤ في المستقبل، وذلك وفق أنظمة تستند إلى نظرية التعلم الإحصائية، وسيتم الاعتماد في تحليل بيانات الدراسة على البرنامج الإحصائي R.

8. الجانب النظري:

يعتمد التعلم الآلي على مبدأ تعلم الأنظمة من البيانات المتاحة وتحديد الأنماط المناسبة واتخاذ القرارات بدون تدخل بشري، وحيث أن المهمة الأساسية للتعلم الآلي هي استخلاص المعلومات من البيانات، فإن التعلم الآلي هو طريقة من طرق تحليل البيانات تعمل على أتمتة بناء نماذج تحليل بيانات تعرف بنماذج التحليل التنبؤية، يُعرف هذا النمط باسم نموذج التحليل التنبؤي أو التصنيفي، تتيح هذه النماذج للباحثين والمحللين اتخاذ قرارات تمكن من الوصول لنتائج موثوقة، ويخضع بناء نموذج تحليل البيانات لعدة آليات أو طرق للوصول لنتائج دقيقة، حيث أن مرحلة بناء النموذج تستلزم تنفيذ عدد من الخطوات الرياضية أو المنطقية المرتبة والمتسلسلة للوصول لنموذج تحليلي مدرب يستطيع التنبؤ بقيم أقرب للحقيقة أو تصنيف البيانات بشكل دقيق، يطلق على هذه المجموعة من الخطوات اسم الخوارزمية، كما يطلق على نموذج تصنيف البيانات اسم المصنف (الثقفي، علي، عبد المعطي، و بشير، 2020).

مفهوم آلة المتجه الداعم (SVM):

تعد تقنية آلة المتجه الداعم (SVM) من أهم التقنيات المستخدمة في تصنيف البيانات، إذ تعتمد على عوامل متعددة ومتغيرات تؤثر على نحو مباشر أو غير مباشر على إيجاد الحل النهائي، فمثلاً نموذج آلة المتجه الداعم (SVM) يعتمد على عدد من المعلومات الأساسية مثل المستوى الفاصل (Hyperplane)، ومضارب لاجرانج (Lagrange Multipliers)، التي تؤثر على نحو كبير على دقة عملية التصنيف، إذ إن البيانات الأساسية في فضاء الإدخال (Input Space)، تصنف على وفق النموذج الرياضي الآتي (Steinwart & Christmann, 2008): (Min, Lee, & Han, 2006).


$$W^T x_i + b \geq +1 \text{ for } d_i = +1, i = 1, 2, \dots, N \quad (1)$$

$$W^T x_i + b \leq -1 \text{ for } d_i = -1, i = 1, 2, \dots, N \quad (2)$$

W: متجه الأوزان، x: تمثل متجه الإدخال Input Vector، b: تمثل قيمة التحيز Bias، d: تمثل قيمة الإخراج.

كما يمكن ملاحظة معادلات الحدود في المستوى من خلال الشكل الآتي:

شكل (1): يوضح متجهات الدعم الواقعة على الحد الفاصل بين البيانات في الفضاء.



(المصدر: (قاسم و الوزان، 2018))

من الشكل (1) أعلاه نلاحظ أن معادلة المستوى الفاصل (Hyper plane) تُكتب بالشكل الآتي:

$$W^T x_i + b = 0 \quad (3)$$

إن البيانات القريبة أو التي تقع على حدود الحد الفاصل تسمى متجهات الدعم أو المساندة Support Vector.

كما يمكن حساب المسافة بين النقاط في المستوى الفاصل من خلال العلاقة الآتية:

$$d(W, b, x_i) = \frac{|W^T x_i + b|}{\|W\|} \quad (4)$$

وبعد عدد من الإجراءات والتحويلات الرياضية، يتم إيجاد قيم كل من متجه الاوزان المثالي (W^*) والتحيز المثالي (b^*)

ومن بعدها تحسب دالة التصنيف الآتية:

$$f(x) = I(W^* \cdot x + b^*) \quad (5)$$


إذ أن (W^*): تمثل الوزن المثالي، و(b^*): تمثل قيمة التحيز المثالية، وSGN تمثل القرار النهائي لانتماء (x) لأحد الأصناف

(Classes) (Chen & Li, 2010)؛ (Zhou, Lai, & Yu, 2009).

إن عملية التصنيف في أغلب التطبيقات تعتمد أسلوب الفصل غير الخطي (Nonlinear) لأن البيانات التي صُنفت تكون عموماً غير خطية، لذلك يعتمد على هذه الآلية في معظم تطبيقات تقنية آلية المتجه الداعم التي تأخذ إجراءات رياضية في تكوين دالة الفصل النهائية، ومن أهم هذه الإجراءات دالة النواة (Kernel trick) التي تقوم بتحويل البيانات من فضاء منخفض البعد (Low dimensional) إلى فضاء عالي البعد (High dimensional) من أجل تصنيفها (Danenas & Garsva, 2015)؛ (Bellotti & Crook, 2009).

في بعض الحالات لا يمكن فصل البيانات بواسطة الحد الفاصل (Hyperplane)، لذلك يفضل استخدام (Kernel trick)، التي تقوم بتحويل بيانات المدخلات من الخطية إلى بيانات ذات مساحة أبعاد عالية (بيانات غير خطية)، ويكون التحويل الجديد قابلاً للفصل الخطي بواسطة الحد الفاصل (Hyperplane)، والشكل (2) الآتي يبين كيفية تحويل البيانات من الخطية إلى غير الخطية باستخدام (Kernel trick)؛ (Bellotti & Crook, 2009).

شكل (2): يوضح عملية تحويل البيانات من الخطية إلى غير خطية باستخدام Kernel Trick



(المصدر: (قاسم و الوزان، 2018))

$$T: X \rightarrow Z = T(x)$$

$$T: X = (x_1, x_2, \dots, x_n) \rightarrow Z = (Z_1 = T(x_1), Z_2 = T(x_2), \dots, Z_n = T(x_n))$$

ومن أهم أنواع دوال النواة (Kernel trick) التي تستخدم في مسائل التصنيف تعرض كما في الجدول التالي (Shin,

Lee, & Kim, 2005) (Huang, Chen, & Wang, 2007):

جدول (1): أهم أنواع دوال النواة (Kernel trick) التي تستخدم في مسائل التصنيف

نوع الدالة	الصيغة الرياضية
Gaussian (RBF) kernel	$k(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$
Polynomial kernel	$k(x_i, x_j) = (1 + x_i^t x_j)^d$
Linear kernel	$k(x_i, x_j) = x_i^t x_j$
Monomial	$k(x_i, x_j) = [x_i^t x_j]^m$


9. الجانب التطبيقي:

وصف البيانات

البيانات المتاحة لدينا هي بيانات شهرية لأسعار الذهب العالمية للفترة الزمنية الممتدة من شهر يناير 2000 حتى شهر

سبتمبر 2022 بواقع 273 مشاهدة، وسيتم تحليل بيانات البحث باستخدام البرنامج الإحصائي R.

شكل (3): السلسلة الزمنية الشهرية لأسعار الذهب العالمية



(المصدر: من إعداد الباحث بالاعتماد على مخرجات برنامج R)

نتائج تحليل نموذج (SVM)

يوجد العديد من الأنواع المختلفة من نماذج (SVM) وتختلف هذه النماذج حسب اختلاف قيم المعلمات (γ , C , ϵ) التي تم اختيارها بشكل تجريبي لعدد محدود من القيم، حيث أن قيمة (ϵ) وتساوي (0.1) وهي قيمة افتراضية ثابتة (Garg, 2012)، وقد أشار كلاً من (Suganyadevi & Babulal, 2014) بأن يكون المدى المناسب لـ (C) يتراوح من $1-1000$ ، ولغرض الحصول على تحليل أكثر شمولية قام الباحث بزيادة الحد الأعلى للمدى ليصبح 10000 ، بينما المدى الملائم لـ (γ) من $0.0001-100$ (Okasha, 2014).

سيتم بناء عدة نماذج من نماذج (SVM) المختلفة باختلاف قيم معلماتها، حيث سيتم المفاضلة بين هذه النماذج حسب أقل قيم للمعايير وهما خطأ التدريب وعدد متجهات الدعم أدناه، كما هو مبين في الجدول (2) أدناه.

جدول (2): نماذج (SVM) لأسعار الذهب العالمية

Model	Cost	Gamma	Error	Numbers of SVM	Model	Cost	Gamma	erred	Nu mb ers of SV M
Model 1	1	0.0001	267191.955	246	Model 8	1	0.5000	20374.329	138
Model 2	1	0.0005	194801.932	242	Model 9	1	1.0000	11589.258	133
Model 3	1	0.0010	134877.227	232	Model 10	1	10.0000	3714.701	92
Model 4	1	0.0050	58830.338	219	Model 11	1	30.0000	2972.196	77
Model 5	1	0.0100	54201.121	214	Model 12	1	50.0000	2407.225	67
Model 6	1	0.0500	50068.012	210	Model 13	1	70.0000	2230.448	66
Model 7	1	0.1000	48409.078	199	Model 14	1	100.0000	2200.944	65
Model 15	10	0.0001	134643.921	232	Model 22	10	0.5000	14184.892	135
Model 16	10	0.0005	58694.515	218	Model 23	10	1.0000	9563.111	139
Model 17	10	0.0010	54495.823	215	Model 24	10	10.0000	3474.837	88
Model 18	10	0.0050	51393.105	211	Model 25	10	30.0000	2303.016	66

Model 19	10	0.0100	50410.576	212	Model 26	10	50.0000	1942.251	64
Model 20	10	0.0500	48763.666	208	Model 27	10	70.0000	1989.096	60
Model 21	10	0.1000	42154.214	196	Model 28	10	100.0000	1988.773	61
Model 29	100	0.0001	54514.436	216	Model 36	100	0.5000	10919.15	143
Model 30	100	0.0005	52192.499	210	Model 37	100	1.0000	8718.942	140
Model 31	100	0.0010	51637.582	213	Model 38	100	10.0000	3219.319	83
Model 32	100	0.0050	49844.346	212	Model 39	100	30.0000	2005.038	62
Model 33	100	0.0100	49781.21	213	Model 40	100	50.0000	1960.42	59
Model 34	100	0.0500	44452.795	199	Model 41	100	70.0000	1979.176	61
Model 35	100	0.1000	28421.385	160	Model 42	100	100.0000	1937.016	61
Model 43	1000	0.0001	52000.211	207	Model 50	1000	0.5000	9905.486	139
Model 44	1000	0.0005	51100.516	211	Model 51	1000	1.0000	7430.004	130
Model 45	1000	0.0010	50310.817	210	Model 52	1000	10.0000	3031.779	82
Model 46	1000	0.0050	49686.806	212	Model 53	1000	30.0000	1859.093	61
Model 47	1000	0.0100	49539.442	213	Model 54	1000	50.0000	1902.728	56
Model 48	1000	0.0500	30980.696	164	Model 55	1000	70.0000	1915.316	58
Model 49	1000	0.1000	24580.808	163	Model 56	1000	100.0000	2058.16	62
Model 57	1000	0.0001	51574.446	208	Model 64	1000	0.5000	9418.367	143
Model 58	1000	0.0005	49900.453	212	Model 65	1000	1.0000	6380.051	117

Model 59	1000 0	0.0010	49803.965	212	Model 66	1000 0	10.0000	2741.879	76
Model 60	1000 0	0.0050	49619.419	212	Model 67	1000 0	30.0000	1880.887	61
Model 61	1000 0	0.0100	48923.874	211	Model 68	1000 0	50.0000	1857.969	57
Model 62	1000 0	0.0500	26198.243	169	Model 69	1000 0	70.0000	2013.503	59
Model 63	1000 0	0.1000	22507.451	143	Model 70	1000 0	100.000 0	2111.099	62

(المصدر: من إعداد الباحث بالاعتماد على مخرجات برنامج R)

ولتوفيق أفضل نموذج للسلسلة، سنقوم باختيار خمسة نماذج من نماذج (SVM) المختلفة وذلك حسب قيم $C = (1, 10, 100, 1000, 10000)$ الموضحة في الجدول أعلاه، ثم يتم المفاضلة بين هذه النماذج حسب أقل قيم للمعايير أدناه، كما هو مبين في الجدول (3).

جدول (3): نماذج (SVM) المختارة لأسعار الذهب العالمية

Model	C	Gamma	Training error	Numbers of Support Vectors
Model 14	1	100.0000	2200.944	65
Model 26	10	50.0000	1942.251	64
Model 42	100	100.0000	1937.016	61
Model 53	1000	30.0000	1859.093	61
Model 68	10000	50.0000	1857.969	57

(المصدر: من إعداد الباحث بالاعتماد على مخرجات برنامج R)


نلاحظ من الجدول أعلاه أنَّ النموذج الأفضل هو نموذج (Model 68) الذي يحتوي على $(C = 10000, \gamma = 50)$ ، وذلك لامتلاكه أقل القيم لخطأ التدريب وعدد متجهات الدعم، لذا سيتم استخدامه في التنبؤ بسبعة قيم مستقبلية من أكتوبر 2022 حتى إبريل 2023 ويتضح ذلك من خلال الجدول (4) التالي:

جدول (4): القيم المتنبأ بها لنموذج (SVM) الذي يحتوي على ($C = 10000, \gamma = 50$)

القيم المتنبأ بها	التاريخ
1659.939	Oct/ 2022
1737.796	Nov/ 2022
1913.467	Dec/ 2022
2192.505	Jan/ 2023
2564.678	Feb/ 2023
3004.766	Mar/ 2023
3476.14	Apr/ 2023

(المصدر: من إعداد الباحث بالاعتماد على مخرجات برنامج R)

وشكل (4) التالي يوضح بياناً القيم الفعلية من شهر يناير 2000 حتى شهر سبتمبر 2022 مضافاً إليها القيم المتنبأ بها من شهر أكتوبر 2022 حتى شهر إبريل 2023، حيث تشير التنبؤات المستقبلية أنها تتبع نفس السلوك للسلسلة الأصلية. شكل (4): القيم الفعلية والتنبؤية لأسعار الذهب العالمية من شهر يناير 2000 حتى شهر إبريل 2023



(المصدر: من إعداد الباحث بالاعتماد على مخرجات برنامج R)

الخلاصة:

تم تحليل السلسلة الزمنية وهي بيانات شهرية لأسعار الذهب العالمية للفترة الزمنية الممتدة من شهر يناير 2000 حتى شهر سبتمبر 2022 بواقع 273 مشاهدة، وذلك ببناء عدة نماذج من نماذج (SVM) المختلفة باختلاف قيم معلماتها (γ, C, ϵ) التي تم اختيارها بشكل تجريبي لعدد محدود من القيم، حيث تمت المفاضلة بين هذه النماذج حسب أقل قيم للمعايير وهما خطأ التدريب وعدد متجهات الدعم، وأشارت نتائج الدراسة أن النموذج الأفضل هو نموذج (SVM) الذي يحتوي على $(C = 10000, \gamma = 50)$ ، وذلك لامتلاكه أقل القيم لخطأ التدريب وعدد متجهات الدعم، لذا تم استخدامه في التنبؤ بسبعة قيم مستقبلية من أكتوبر 2022 حتى إبريل 2023، وقد كانت القيم التنبؤية متناسقة مع القيم الأصلية للسلسلة مما يدل على كفاءة النموذج.

وبناء على نتائج الدراسة نوصي باستخدام أساليب تقنية مثل الخوارزمية الجينية (Genetic Algorithm) والمنطق المصطبب (Fuzzy logic) وأسلوب (Valind – Cross) ومقارنة نتائج هذه الأساليب مع نتائج نموذج (SVM) المقترح، وكذلك استخدام الأسلوب الهجين الذي يجمع بين الخوارزمية الجينية (Genetic Algorithm) وآلة المتجه الداعم (SVM) مثل (SVM_ GA).

المراجع:

أولاً: المراجع العربية

- شادي التلباني، و مظهر عبد الحميد. (2021). استخدام الطرق اللاخطية "MLP, ELM, SVM" في التنبؤ بالسلاسل الزمنية: دراسة حالة. مجلة جامعة الأنبار للعلوم الاقتصادية والإدارية، 13(1)، الصفحات 274-291.
- طلال النعفي، ياسر علي، محمد عبد المعطي، و طارق بشير. (2020). استخدام خوارزميات تعلم الآلة لتصنيف همزتي الوصل والقطع. مجلة كلية الآداب والعلوم الإنسانية جامعة قناة السويس، 3(35)، الصفحات 11-47.
- عمر قاسم، و محمد الوزان. (2018). تحسين أداء تصنيف تقانة آلة المتجه الداعم باستخدام الخوارزمية الجينية. مجلة الرافدين لعلوم الحاسوب والرياضيات، 12(2)، الصفحات 49-60.
- لمجد بوزيدي، و عبد الرحمن بن عيسى. (2020). دور طريقة متجهات شعاع الدعم الآلي SVM في تحليل وإدارة المخاطر في المؤسسة الاقتصادية. المجلة العربية للأبحاث والدراسات في العلوم الإنسانية والاجتماعية، 12(4)، الصفحات 168-178.
- مروان درويش. (2018). فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي. مجلة جامعة القدس المفتوحة، 3(10)، الصفحات 75-95.
- ولاء لطفي، كنجو كنجو، و عثمان نقار . (2022). إمكانية التنبؤ بأداء أسهم المصارف التجارية الخاصة المدرجة في سوق دمشق للأوراق المالية باستخدام نموذج شعاع الدعم الآلي. مجلة جامعة حماة، 5(22)، الصفحات 50-63.

ثانياً: المراجع الأجنبية

- Bellotti, T., & Crook, J. (2009). Support vector machines for credit scoring and discovery of significant features. *Expert systems with applications*, 36(2), pp. 3302-3308.
- Chen, F., & Li, F. (2010). Combination of feature selection approaches with SVM in credit scoring. *Expert systems with applications*, 37(7), pp. 4902-4909.
- Danenas, P., & Garsva, G. (2015). Selection of support vector machines-based classifiers for credit risk domain. *Expert systems with applications*, 42(6), pp. 3194-3204.
- Garg, A. (2012). Forecasting exchange rates using machine learning models with time varying volatility(Master Thesis). Linköping University.
- Huang, C., Chen, M., & Wang, C. (2007). Credit scoring with a data mining approach based on support vector machines. *Expert systems with applications*, 33(4), pp. 847-856.
- Makala, D., & Li, Z. (2021). Prediction of gold price with ARIMA and SVM. In *Journal of Physics: Conference Series*, 1767(1), pp. 1-8.
- Min, S., Lee, J., & Han, I. (2006). Hybrid genetic algorithms and support vector machines for bankruptcy prediction. *Expert Systems with Applications*, 31(3), pp. 652-660.
- Okasha, M. K. (2014). Using support vector machines in financial time series forecasting. *International Journal of Statistics and Applications*, 4(1).
- Patil, S., patidar, K., & jain, M. (2016). Stock market prediction using support vector machine. *International journal of current trends in engineering and technology*, 2(1), pp. 18-25.
- Shin, K., Lee, T., & Kim, H. (2005). An application of support vector machines in bankruptcy prediction mode. *Expert systems with applications*, 28(1), pp. 127-135.
- Steinwart, I., & Christmann, A. (2008). *Support vector machines*. Springer Science & Business Media.
- Suganyadevi, M., & Babulal, C. (2014). Support Vector Regression Model for the prediction of Loadability Margin of a Power System. *Applied Soft Computing*, 24, pp. 304-315.
- Tripathy, N. (2019). Stock price prediction using support vector machine approach. In *International Academic Conference on Management & Economics*, pp. 44-59.
- Zhou, L., Lai, K., & Yu, L. (2009). Credit scoring using support vector machines with direct search for parameters selection. *Soft Computing*, 13(2), pp. 149-155.