



مجلة التجارة والتمويل

[/https://caf.journals.ekb.eg](https://caf.journals.ekb.eg)

كلية التجارة – جامعة طنطا

العدد : الثاني

يونيو ٢٠٢٣

**التنبؤ بالسلاسل الزمنية بالاعتماد على النموذج الهجين للإنحدار
الذاتي والمتوسطات المتحركة التكاملية ونموذج إنحدار متجة الدعم**

الباحثة

هناء محمد محمود نصار

مدرس مساعد بكلية التجارة بنات

جامعة الأزهر – فرع تفهنا الأشراف

الإشراف

أ.د / نصر إبراهيم رشوان أبو زيد

أستاذ الإحصاء ورئيس قسم الإحصاء

بكلية التجارة – جامعة طنطا

أ.م.د / ماجدة محمد إسماعيل

أستاذ الإحصاء المساعد بكلية التجارة بنات

جامعة الأزهر- فرع تفهنا الأشراف

أ.م.د / أمل أحمد طلعت

أستاذ الإحصاء المساعد ورئيس قسم الإحصاء

بكلية التجارة بنات – جامعة الأزهر

المستخلص

يهدف هذا البحث إلى استخدام ثلاث نماذج للتنبؤ بالسلاسل الزمنية وهي نموذج الإنحدار الذاتي والمتوسطات المتحركة التكاملية ARIMA ونموذج إنحدار متجة الدعم SVR والنموذج الهجين الذي يجمع بين نموذج ARIMA ونموذج SVR وتم استخدام هذه النماذج للتنبؤ بأسعار الذهب العالمية الشهرية وذلك بالإعتماد على سلسلة زمنية لأسعار الذهب العالمية الشهرية في الفترة الزمنية من يناير 1991 إلى ديسمبر 2021 كما تم المفاضلة والمقارنة بين الثلاث نماذج وذلك بالإعتماد على مقاييس دقة التنبؤ وهي متوسط مربعات الخطأ MSE ومتوسط الخطأ المطلق MAE بالإضافة إلى متوسط الخطأ المطلق النسبي MAPE ومعامل عدم التساوي لتايل T وقد توصل البحث إلى تفوق النموذج الهجين على النماذج المفردة لإملاكه أقل القيم لمقاييس دقة التنبؤ .

الكلمات المفتاحية : نموذج ARIMA ،نموذج SVR، النموذج الهجين، مقاييس دقة التنبؤ.

Abstract:

This paper using three models for predicting time series, Auto Regressive Integrated Moving Average (ARIMA) model and the Support Vector Regression and Hybrid model by combining the ARIMA mode with the SVR model, These models are used to predict monthly global gold prices, based on a time series of monthly global gold prices, the time series data was used during the period from Jan -1991 – Dec-2021, to compare hybrid model of ARIMA-SVR with individual models ARIMA and SVR, These models are compared using the MSE, MAE and MAPE,T prediction accuracy measures to find the most appropriate model for predicting future values. This paper reveals the superiority of ARIMA-SVR on other individual models by having the lowest values of the prediction measures.

Keywords: ARIMA; SVR; Hybrid model; prediction measures.

بالرغم من مرونة النماذج الخطية المتمثلة في نماذج ARIMA إلا إنها لا تستطيع التعامل مع البيانات غير الخطية وخاصة في السلاسل المالية والإقتصادية ومع الحاجة المستمرة لتنبؤات أكثر دقة للظواهر المختلفة لجأ الباحثون إلى استخدام ما يعرف بالنماذج الهجينة وأول من قدم هذه الفكرة هو [21] وسار على نهجه الكثير من الباحثين حيث تجمع النماذج الهجينة بين قوة نماذج ARIMA ومرونة نموذج إندار متجة الدعم SVR لقدرته على التعامل مع الأنماط المختلفة من البيانات والنموذج الهجين هو نموذج ناتج من دمج نموذج خطي مع نموذج آخر غير خطي أو العكس لعلاج النقص الموجود فيما لو استخدم كل نموذج على حده بغرض تحسين التنبؤات المستقبلية [5] وتهدف عملية التهجين إلى الحصول على تنبؤات أكثر دقة ولتقليل الأخطاء الناتجة من استخدام نموذج قد يكون غير مناسب لطبيعة البيانات المستخدمة كما أن نموذج واحد يكون غير كاف لفهم سلوك السلسلة الزمنية لذا فإن النموذج الهجين يعوض النقص الموجود فيما لو تم استخدام كل نموذج بشكل فردي. كثيرا ما يصعب تحديد بيانات السلسلة الزمنية هل هي خطية أم غير خطية ؟ لذا يلجأ الباحثين إلى استخدام النماذج الهجينة لتفادي مشكلة إختيار النموذج المناسب لطبيعة البيانات كما تحتوى العديد من الظواهر وخاصة المالية والإقتصادية على أنماط خطية وأخرى غير خطية واستخدام النماذج التقليدية يكون غير كاف لنمذجة سلسلة البيانات لذا يتم استخدام النماذج الهجينة [13]. يوجد العديد من الدراسات التي تناولت التنبؤ بالسلاسل الزمنية باستخدام النماذج الهجينة -ARIMA SVR في مجالات متنوعة من الإقتصاد والإحصاء والهندسة والعلوم. [9] يستخدم النموذج الهجين للتنبؤ بسعر إغلاق السهم اليومي لمخزون IBM وهي مؤسسة دولية خاصة بإنتاج وبيع أجهزة الكمبيوتر والحوسبة السحابية وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة ARIMA,SVR. [19] سعى للتنبؤ بأسعار الثوم الشهرية لمقاطعة شانغونغ بالصين باستخدام النموذج الهجين وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج

المفردة. [16] هدفت الدراسة إلى التنبؤ بالحركة المستقبلية للأسواق المالية في الدراسة تم سحب مجموعة من موجة إلبوت تمثل 5822 عينة من بيانات الأسعار التاريخية المتداولة في ثلاثة أنواع من الأسواق : مؤشرات الأسهم العالمية وأسواق الصرف الأجنبي والسلع حيث تمثل عينة مؤشرات الأسهم العالمية %26.7 من إجمالي العينة وعينة الصرف الأجنبي تمثل %30.7 بينما عينة السلع تمثل %42.6 وتم تقسيمها إلى ثمانى مجموعات بإستخدام النموذج الهجين والذي أثبت دقته في التنبؤ مقارنة بالنماذج المفردة. [8] إستخدم النموذج الهجين للتنبؤ بمعدل البطالة في ظل إنتشار وباء كورونا في آسيا بالتطبيق على خمس دول نامية وخمس دول أخرى متقدمة وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة ARIMA,SVR. [11] تناول التنبؤ بحجم الكتب المستعارة شهريا من مكتبة جامعة Xiamen بالصين وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة. [18] تناولت النموذج الهجين للتنبؤ بحركة المرور اليومية عبر بوابات الرسوم بإحدى مقاطعات الصين وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة ARIMA,SVR. [22] إستخدم النموذج الهجين ARIMA- SVR للتنبؤ بعدد الحالات المرضية التي تصل لقسم الأشعة يوميا وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة. [14] هدفت الدراسة إلى التنبؤ بعدد الحالات المصابة بفيروس كورونا يوميا بإستخدام النموذج الهجين والذي أثبت دقته في التنبؤ مقارنة بالنماذج المفردة. [20] إستخدمت الدراسة النموذج الهجين للتنبؤ بمعدل الجفاف لمحطات المياه في مقاطعة Henan بالصين وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة [23]. تناولت النموذج الهجين للتنبؤ بسعر الفحم اليومى بميناء تشينهوانغدو بالصين وخلصت النتائج إلى أن النموذج الهجين أفضل من النماذج المفردة ARIMA,SVR. [10] إستخدمت النموذج الهجين للتنبؤ بدرجة حرارة سطح البحر حيث تم إستخدام جنوب بحر الصين بالقرب من شبه جزيرة ماليزيا على خط عرض 1.770833 وخط طول 104.520828 على بعد 40 كيلو متر من أرض

جوهور كمنطقة للدراسة وتم تسجيل درجات الحرارة الشهرية ل H20018 لمجموعتين وقد أوضحت نتائج الدراسة أن النموذج الهجين ARIMA-SVR أفضل من النماذج المفردة.

٢- مشكلة البحث

تتمثل مشكلة البحث في أن النماذج المفردة سواء نماذج بوكس وجينكيز التقليدية أو النماذج الحديثة كنموذج إنحدار متجة الدعم كلاهما لا يعطى تنبؤات دقيقة للسلسلة الزمنية نظرا لإحتوائها على جزء خطى وغير الخطى لذا يتناول البحث استخدام النموذج الهجين من لى يتم تعويض SVR ونموذج إنحدار متجة الدعم ARIMA خلال الدمج بين نموذج القصور الموجود في كل نموذج على حده والحصول على تنبؤات أكثر دقة .

٣- أهداف البحث

ونموذج إنحدار متجة ARIMA يمثل الهدف الأساسى للبحث فى المفاضلة بين نموذج وذلك بالإعتماد على مقاييس دقة التنبؤ ARIMA-SVR والنموذج الهجين SVR الدعم ويتفرع من هذا الهدف أهداف MSE,MAE,MAPE Theil's Inequality Coefficient البحث كالتالى :

- بناء نموذج ARIMA للتنبؤ بأسعار الذهب العالمية الشهرية.
- بناء نموذج SVR للتنبؤ بأسعار الذهب العالمية الشهرية.
- بناء النموذج الهجين ARIMA-SVR للتنبؤ بأسعار الذهب العالمية الشهرية.

٤- أهمية البحث

تكمّن أهمية البحث في تزويد المؤسسات وأصحاب رؤوس الأموال بالمعلومات المستقبلية ، حيث يعتبر التنبؤ من الأدوات المهمة التي يستخدمها متخذو القرار في تخطيط وتطوير السياسات المستقبلية ، لذلك يسعى متخذو القرار على مستوى الدولة والمؤسسات إلى إيجاد الأدوات المناسبة للتنبؤ وتعتبر النماذج الهجينة هي أهم هذه الأدوات لدقتها . كما أن أغلب السلاسل الزمنية تتكون من جزء خطى وآخر غير خطى وإستخدام النماذج الهجينة يعمل على سد الفجوة فى كل نموذج فيما لو تم إستخدام كل نموذج بشكل فردى .

٥- حدود البحث

تنقسم حدود البحث إلى حدود زمنية وحدود موضوعية
 حدود زمنية : حيث تم تناول أسعار الذهب العالمية الشهرية في الفترة الزمنية من
 يناير 1991 إلى ديسمبر 2021.
 حدود موضوعية : حيث تم التركيز على السلسلة الزمنية لأسعار الذهب العالمية الشهرية .

٦- المنهجيات المستخدمة Methodology

في هذا البحث سوف نتناول ثلاث نماذج للتنبؤ بالسلسلة الزمنية لأسعار الذهب العالمية
 الشهرية نموذج ARIMA ونموذج إنحدار متجة الدعم SVR والنموذج الهجين ARIMA-SVR
 وسوف نتناول كل نموذج بشيء من التفصيل كالتالي:

(٦-١) نماذج ARIMA

تعتبر نماذج ARIMA أكثر نماذج السلاسل الزمنية إستخداما , وتعرف بمنهجية بوكس وجينكينز
 اللذان قدماها في مطلع السبعينيات في كتابهما الشهير (Time Series Analysis
 Forecasting And Control) عام 1976 في الولايات المتحدة الأمريكية لتصبح من أهم
 الطرق المستخدمة في تحليل السلسلة الزمنية. فهي مزيج من نماذج الإنحدار الذاتي ونماذج
 المتوسطات المتحركة بعد أخذ الفروق المناسبة لإستقرار السلسلة ويرمز لها بالرمز
 $ARIMA(p, d, q)$ والصيغة العامة لها تكون على الشكل التالي :

$$y_t = \phi_0 + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon y_{t-p-d} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

حيث أن :

p : رتبة نموذج الإنحدار الذاتي .

q : رتبة نموذج المتوسطات المتحركة.

d : عدد الفروق اللازمة لإستقرار السلسلة الزمنية.

- إختبارات جذر الوحدة Unit Root Tests

لمعرفة ما إذا كانت السلسلة الزمنية مستقرة أو غيرمستقرة توجد العديد من الإختبارات فى هذا الصدد نذكر منها ثلاثة إختبارات تم إستخدامها فى التطبيق العملى وقبل أن نذكر الإختبارات التى يتم من خلالها الكشف عن إستقرار السلسلة الزمنية لابد من ذكر الفروض الإحصائية وتكون كالتالى :

الفرض العدمى H_0 : وجود جذر الوحدة أى السلسلة الزمنية غيرمستقرة $H_0: \rho_1 = 1$

الفرض البديل H_1 : عدم وجود جذر الوحدة أى السلسلة الزمنية مستقرة $H_1: \rho_1 < 1$

إختبار ديكى فولر الموسع (ADF) Augmented Dickey Fuller

يسمح هذا الإختبار بمعرفة ما إذا كانت السلسلة الزمنية مستقرة أم لا قدمه [6] ويستخدم هذا الإختبار عندما يعانى حد الخطأ العشوائى الخاص بإختبار ديكى- فولر البسيط من الإرتباط الذاتى حيث يعالج ذلك بإضافة عدد مناسب من الفروق كما يلى :

$$\Delta y_t = \beta T + (\rho - 1)y_{t-1} + \varepsilon_t$$

ويعتمد الإختبار على ثلاثة نماذج :

النموذج الأول : بدون حد ثابت وإتجاه زمنى

$$\Delta y_t = (\rho - 1)y_{t-1} + \sum_{j=1}^k \rho_j \Delta y_{t-j} + \varepsilon_t \quad (2)$$

النموذج الثانى : بدون إتجاه زمنى

$$\Delta y_t = \alpha + (\rho - 1)y_{t-1} + \sum_{j=1}^k \rho_j \Delta y_{t-j} + \varepsilon_t \quad (3)$$

النموذج الثالث: مع حد ثابت وإتجاه زمنى

$$\Delta y_t = \alpha + \beta T + (\rho - 1)y_{t-1} + \sum_{j=1}^k \rho_j \Delta y_{t-j} + \varepsilon_t \quad (4)$$

حيث أن α : الحد الثابت k : فترة الإبطاء أو التأخير T : الإتجاه الزمنى

$$\tau_{\phi_1}^* = \frac{(\hat{\phi}_1 - 1)}{\hat{\delta}_{\phi_1}^2} \quad (5)$$

ويجب إختيار أحد النماذج الثلاثة السابقة المناسب ثم إجراء الإختبار تحت ظل الفروض الإحصائية السابقة .

إذا كانت قيمة الإحصاءة τ المقدره أكبر من القيمة الجدولية فإننا نرفض الفرض العدمى ونقبل الفرض البديل والعكس صحيح .

إختبار فيليب وبيرون PP

إقترح هذا الإختبار [12] لتجاوز مشكلتى الإرتباط الذاتى للبقاى وعدم ثبات التباين للخطأ العشوائى الذى يعانى منها إختبار ديكى فولر العادى ويتم هذا الإختبار على أربع مراحل هى :

- التقدير بإستخدام المربعات الصغرى لنماذج إختبار ديكى فولر وحساب الإحصاءات المرافقة .
- تقدير التباين قصير الأجل $\delta^2 = \frac{1}{n} \sum_{t=1}^n e_t^2$ حيث e_t الباقى المقدر .
- تقدير التباين طويل الأجل

$$S_t^2 = \frac{1}{n} \sum_{t=1}^n e_t^2 + 2 \sum_{i=1}^l \left(1 - \frac{i}{l+1}\right) \frac{1}{n} \sum_{t=i+1}^n e_t e_{t-1} \quad (6)$$

ولتقدير التباين طويل الأجل لابد من معرفة عدد التأخيرات l المقدره بدلالة عدد المشاهدات n

- حساب إحصائية PP

$$t_{\varphi_1}^* = \sqrt{k} \cdot \frac{(\hat{\varphi}_1 - 1)}{\hat{\delta}_{\varphi_1}} + \frac{n(k-1)\hat{\delta}_{\varphi_1}}{\sqrt{k}}, \quad k = \frac{\hat{\delta}^2}{S_t^2} \quad (7)$$

ويتم مقارنة هذه الإحصائية مع القيم الحرجة لجدول Mackinnon وذلك لقبول أو رفض الفرض العدمي.

إختبار KPSS

إقتراح كلا من [7] إستخدام إختبار مضاعف لاجرانج Lagrange Multiplier LM لإختبار الفرض العدمي (عدم وجود جذر الوحدة $H_0: \rho_1 < 1$) مقابل الفرض البديل (وجود جذر الوحدة $H_0: \rho_1 = 1$) على عكس إختبار ديكي - فولر الموسع وتحسب إحصائية مضاعف لاجرانج من العلاقة التالية:

$$LM = \frac{\sum_{i=1}^T s_t^2}{\hat{\delta}_\varepsilon^2} \quad (8)$$

حيث أن s_t^2 : المجموع الجزئي للبواقي e_t

$$e_t: \text{مقدر لتباين الخطأ } \hat{\delta}_\varepsilon^2 \quad s_t = \sum_{i=1}^t e_i \quad i = 1, 2, 3, \dots, T$$

إذا كانت LM المحسوبة أكبر من القيمة الجدولية يتم رفض الفرض العدمي (السلسلة الزمنية مستقرة) وقبول الفرض البديل ويتم قبول الفرض العدمي ورفض الفرض العدمي إذا كانت LM المحسوبة أصغر من القيمة الجدولية

- منهجية بوكس وجينكيز للسلاسل الزمنية

يمر بناء نماذج السلاسل الزمنية طبقاً لمنهجية بوكس وجينكيز بأربع مراحل [3]:

- ١ التعرف على النموذج Identification Model

تعد أهم مرحلة في بناء نموذج السلسلة الزمنية ، ويتم من خلالها تحديد معالم النموذج (p, d, q) حيث يتم تحديد عدد الفروق اللازمة لإستقرار السلسلة d وذلك من خلال فحص إستقرار السلسلة و تحديد رتبتي النموذج (p, q) من خلال دالتي الإرتباط الذاتي (ACF) ، ودالة الإرتباط الذاتي الجزئي (PACF) لمعرفة نوع النموذج المناسب من ضمن نماذج ARIMA(p, d, q) ويتم إستخدام بعض المعايير لإختيار النموذج الأفضل منها :

- معيار أكايكي المعلوماتي Akaike Information Criterion (AIC)

قدم هذا المعيار Hirotsugu Akaike عام 1973 والصيغة العامة له على الشكل التالي :

$$AIC(k) = 2m - 2 \ln(\delta_e^2) \quad (9)$$

حيث أن :

m : تمثل عدد معالم النموذج δ_e^2 : يمثل مقدار تباين الخطأ ، والنموذج الذي يعطى أقل قيمة للمعيار يكون هو الأفضل .

- معيار بايز المعلوماتي Bayesian information criterion (BIC)

قدم هذا المعيار Schwartz بطريقة بايز عام 1978 والصيغة العامة له على الشكل التالي :

$$BIC(k) = \ln(n) m - 2 \ln(\delta_e^2) \quad (10)$$

m : تمثل عدد معالم النموذج δ_e^2 : يمثل مقدار تباين الخطأ n : تمثل حجم السلسلة الزمنية ، والنموذج الذي يعطى أقل قيمة للمعيار يكون هو الأفضل .

٢- تقدير النموذج Estimation Model

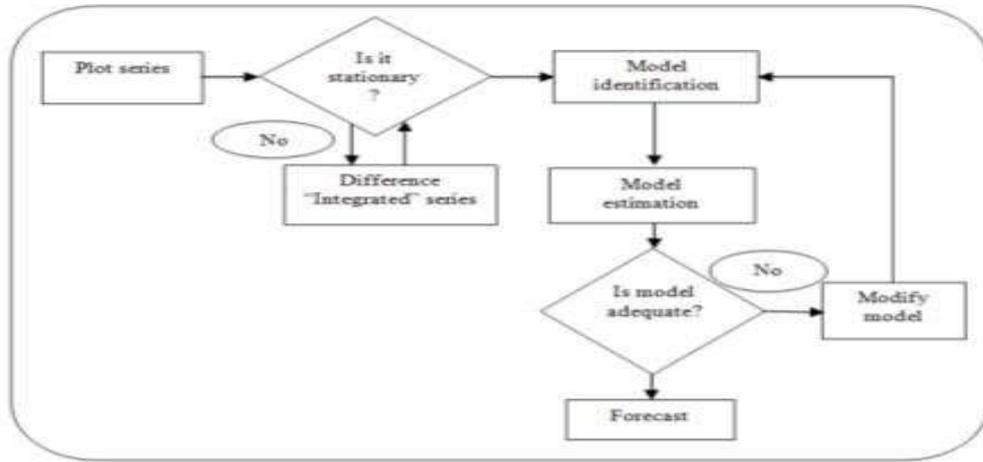
بعد التعرف على نموذج السلسلة الزمنية يتم تقدير معاملات النموذج (θ, ϕ) وذلك من خلال طرق التقدير المعروفة كطريقة المربعات الصغرى الإعتيادية أو طريقة الإمكان الأعظم أو غيرها من طرق التقدير الأخرى.

٣- فحص مدى ملائمة النموذج Diagnostic Checking of the Model

بعد تحديد النموذج وتقدير معالمه لابد من التحقق فيما إذا كان النموذج ملائماً أم لا. ولفحص مدى ملائمة النموذج يمر بمجموعة من الإختبارات والفحوص ولعل من أهمها : تحليل البواقي .

٤- التنبؤ Forecasting

هو آخر مرحلة فى تحليل السلسلة الزمنية ويعد الهدف الأساسى من البحث فبعد تحديد النموذج الملائم للبيانات يتم إستخدامه لمعرفة قيم الظاهرة فى المستقبل لفترات زمنية معينة ويمكن توضيح مراحل بناء نموذج السلاسل الزمنية طبقاً لمنهجية بوكس وجينكيز [1] كما فى شكل (١) التالى :

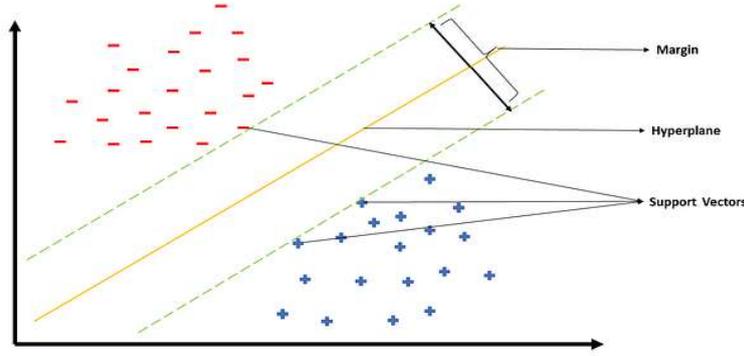


المصدر: (Bleikh,2014)

شكل (١) خطوات تحليل السلسلة الزمنية طبقاً لمنهجية بوكس وجينكيز

(٦-٢) نموذج إنحدار آلة الدعم Support Vector Regression SVR

تم استخدام SVR على نطاق واسع للتنبؤ بالسلاسل الزمنية التي تحتوى بيانات غير خطية مثل البيانات الإقتصادية والمالية. تتمثل فكرة SVR فى فصل البيانات المدخلة عن بعضها البعض من خلال المستوى الفائق hyperplane بينهما بغض النظر عن طبيعة البيانات كانت قابلة للفصل الخطى أم لا بحيث يعظم المستوى الفائق الهامش margin إلى أقصى حد ممكن كما هو موضح بشكل (٢) التالى :



المصدر: (Russell, 2018)

شكل (٢) يوضح المستوى الفائق والمتجهات الداعمة والهامش

يتم فى إنحدار متجه الدعم تنظيم المدخلات x إلى فضاء ذوالبعد n بإستخدام مجموعة من التحويلات غير الخطية المحددة $\varphi(x_i)$ (أى الإنتقال ببيانات التدريب من فضاء المدخلات إلى فضاء الميزات والتي يكون له عدد أكبر من الأبعاد) والصيغة العامة SVR تكون على الشكل التالى [4] :

$$f(x, w) = w^T \varphi(x_i) + b \quad (12)$$

حيث أن :

$$w^T: \text{يمثل متجه الأوزان } w = w_1, w_2, \dots, w_d \quad b: \text{تمثل التحيز}$$

x : تمثل مساحة ميزة عالية الأبعاد يتم تعيينها بشكل غير خطي من مساحة المدخلات x_i

يتم تخفيض تعقيد النموذج باستخدام دالة الخسارة غير الحساسة ل ε عبر تصغير $\|w\|^2$ لذا يتم إدخال متغيرات راكدة تكون غير سالبة $\zeta_i, \zeta_i^* \geq 0 \quad i = 1, 2, 3, \dots, n$ لقياس إنحراف مجموعة التدريب خارج المنطقة المحددة ب ε وتكون على الصيغة التالية [15]:

$$\text{minimize } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) \quad (13)$$

$$\text{s. t. } y_i - f(x, w) - b \leq \varepsilon + \zeta_i$$

$$f(x, w) + b - y_i \leq \varepsilon + \zeta_i^*$$

$$\zeta_i, \zeta_i^* \geq 0 \quad i = 1, 2, 3, \dots, n$$

حيث أن :

C : تمثل معامل التنظيم $C > 0$ أو ما يعرف بمعامل الضبط ولحل معادلة (13) يتم إضافة شروط جديدة باستخدام مضاعف لاجرانج من خلال تقديم مجموعة من المتغيرات الثانوية α_i, α_i^* ويتم تحديد قيم w, b بدلالة المتغيرات الثانوية والتي من خلالها نستطيع تقدير قيم التنبؤ بشكل عددي كما في الصيغة التالية :

$$\text{max. } -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)(\varphi(x_i), \varphi(x_j)) - \varepsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (14)$$

$$\text{s. t. } \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C]$$

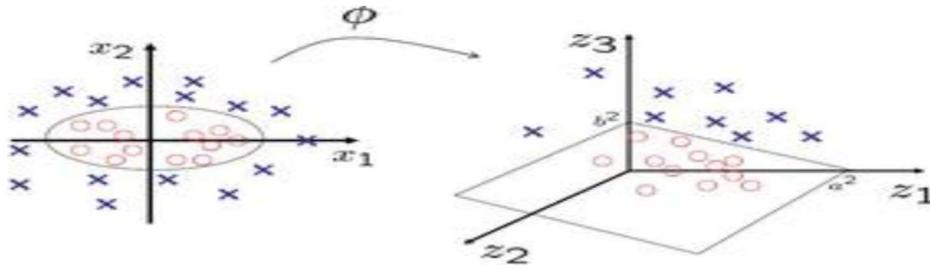
$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i \rightarrow f(x) \quad (15) \quad \text{حيث أن}$$

$$= \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(x, x_i) + b \quad (16)$$

بحيث يتم تقييد المتغيرات الثانوية α_i, α_i^* بالشروط $\alpha_i \leq C, 0 \leq \alpha_i^*$ وتشير $k(x, x_i)$ إلى دالة kernel.

٦-٢-١ عملية الفصل غير الخطي في إنحدار متجة الدعم

في حالة ما إذا كانت البيانات غير قابلة للفصل خطياً تبدأ الخوارزمية بتحويل مجموعة البيانات المدخلة من فضاءها الحالي إلى فضاء أعلى على سبيل المثال لو أن الفضاء الحالي للبيانات ثنائي البعد يمكن تحويلها إلى فضاء ثلاثي الأبعاد حتى يمكننا فصل البيانات وتمييزها لذا تبدأ الخوارزمية بشكل آلي بتدريب إضافة بعد ثالث للبيانات كإحتمال أول وبعدها تختبر البيانات الممثلة في فضاء ثلاثي الأبعاد هل هي قابلة للفصل أم لا؟ إذا تم الفصل للبيانات تبحث الخوارزمية عن المستوى الفائق المناسب وإذا لم يتم الفصل يتم إضافة بعد رابع كإحتمال ثاني ونختبر البيانات [17] وهكذا تستمر الخوارزمية في إضافة أبعاد حتى تصل لمرحلة تصبح بها البيانات قابلة للفصل وتسمى هذه الطريقة kernel Trick كما في شكل (٣) التالي :



المصدر: (Athavale, 2010)

شكل (٣) يوضح الإنتقال من الأبعاد المنخفضة إلى الأبعاد العالية

٦-٢-٢ دالة النواة

أداة يتم إستخدامها فى حالة تعذر فصل البيانات خطيا وتعمل على تحويل فضاء البيانات الأصلية إلى فضاء على الأبعاد حتى تتمكن من فصل البيانات [5]. وتوجد أنواع كثيرة من دوال kernel نذكر منها الأكثر شيوعا وإستخداما كما هو موضح فى جدول (١) التالى :

جدول (١) يوضح دوال kernel المختلفة

دوال kernel	المعادلة
linear	$k(x_i, x_j) = (x_i, x_j)$
polynomial	$k(x_i, x_j) = [\gamma(x_i, x_j) + c]^d$
sigmoid	$k(x_i, x_j) = \tan h(\gamma(x_i, x_j) + c)$
Radial Basis Function (RBF)	$k(x_i, x_j) = \exp(-\gamma x_i - x_j ^2)$

المصدر: [15]

٦-٣ النموذج الهجين Hybrid Model

يتم بناء النموذج الهجين على أساس أن السلسلة الزمنية تتكون من جزئين إحداهما خطى L_t والآخر غير خطى N_t فى الزمن t وتكون على الشكل التالى [24] :

$$y_t = L_t + N_t \quad (17)$$

حيث أن :

y_t : تمثل السلسلة الزمنية الأصلية L_t : تمثل الجزء الخطى فى السلسلة الزمنية

N_t : تمثل الجزء غير الخطى فى السلسلة الزمنية (الخطأ العشوائى).

ARIMA-SVR النموذج الهجين (١-٣-٦)

وفقا لطريقة [21] يتم استخدام البواقي المستخرجة من نموذج ARIMA لبناء نموذج إنحدار متجة الدعم SVR وذلك طبقا لمنهجية [3] بإتباع الخطوات التالية :

١- بناء نموذج ARIMA للسلسلة الزمنية محل الدراسة y_t طبقا لمنهجية بوكس وجنكينز مروراً بمراحله الأربعة ابتداءً من مرحلة التعرف وصولاً لمرحلة التنبؤ .

٢- الحصول على القيم المتنبأ بها \hat{L}_t من نموذج ARIMA الذى تم توفيقه ليمثل الجزء الخطى للسلسلة الزمنية محل الدراسة .

٣- بناء نموذج SVR لنمذجة البواقي بالإعتماد على بواقي ARIMA ثم حساب التنبؤات المستقبلية لها \hat{N}_t

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_n) + \varepsilon_t \quad (18)$$

حيث أن :

$f(\cdot)$: دالة غير خطية تحدد من خلال نموذج SVR ε_t : يمثل الخطأ العشوائى

وبإهمال الأخطاء العشوائية ε_t نحصل على القيم المقدرة \hat{N}_t

$$\hat{N}_t = f(e_{t-1}, e_{t-2}, \dots, e_n) \quad (19)$$

٤- من خلال جمع تنبؤات نموذج ARIMA مع تنبؤات نموذج إنحدارمتجة الدعم SVR يتم الحصول على القيم المتنبأ بها y_t على الشكل التالى :

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (20)$$

٧- البيانات وتقييم النموذج Dataset and Model Evaluation

تم استخدام بيانات خاصة بأسعار الذهب العالمية الشهرية تم الحصول عليها من خلال الموقع الإلكتروني www.indexmundi.com في الفترة الزمنية من شهر يناير 1991 إلى شهر ديسمبر 2021 . ولتقييم أداء النموذج المقترح ARIMA-SVR تم استخدام مقاييس الخطأ التالية والتي تعتمد على الخطأ بين القيم المقدرة والقيم الفعلية بالإضافة إلى معامل متباينة تايل [2] .

- متوسط مربعات الخطأ Mean Square Error (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

- متوسط الخطأ المطلق Mean Absolute Error (MAE)

$$MAE = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{n}$$

- متوسط الخطأ المطلق النسبي Mean Absolute Percent Error (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} * 100$$

- معامل عدم التساوي تايل Theil's Inequality Coefficient

$$T = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2 / n}{\frac{y_t^2}{n}}} \quad 0 \leq T \leq \infty$$

حيث أن :

y_t : تشير إلى قيم السلسلة الزمنية الأصلية في الفترة t \hat{y}_t : تشير إلى قيم السلسلة الزمنية المقدرة في الفترة t n : تمثل عدد مشاهدات السلسلة . ويعد معامل عدم التساوي لثايل من المعايير الشائعة في قياس الكفاءة التنبؤية للنموذج وكلما إقتربت قيمة T من الصفر إرتفعت القدرة التنبؤية للنموذج كما يعتبر النموذج الأفضل أو المتوقع على غيره من النماذج هو الذي يعطى اقل قيمة لمقاييس الخطأ السابقة.

٨- الجانب التطبيقي

تم التطبيق على بيانات فعلية خاصة بأسعار الذهب العالمية الشهرية تم الحصول عليها من خلال الموقع الإلكتروني www.indexmundi.com في الفترة الزمنية من شهر يناير 1991 إلى شهر ديسمبر 2021 بواقع 372 مشاهدة تم استخدام 335 مشاهدة كمجموعة تدريب للسلسلة بنسبة 90% من إجمالي البيانات بينما تم استخدام آخر 37 مشاهدة في البيانات كمجموعة إختبار للسلسلة أي نسبة 10 % من إجمالي البيانات للمقارنة بين القيم الفعلية والمقدرة وتم استخدام برنامج R(4.0.3)(2020) لتحليل بيانات السلسلة الزمنية.

جدول (٢) يوضح تقسيم بيانات سلسلة الذهب العالمية الشهرية

البيانات	إجمالي المشاهدات	الفترة الزمنية
مجموعة التدريب	335 (90%)	يناير 1991 : نوفمبر 2018
مجموعة الإختبار	37 (10%)	ديسمبر 2018 : ديسمبر 2021

١- التحليل الإستكشافي لبيانات الذهب الشهرية

جدول التالي يوضح بعض المقاييس الإحصائية الوصفية لمجموعة تدريب السلسلة والمكونة من 335 مشاهدة .

جدول (٣) المقاييس الإحصائية لمجموعة تدريب السلسلة

Statistics	Value
Observation	355
Mean	727.93
Median	423.35
Min.	256.08
Standard Deviation	464.44
Max.	1772.14
Kurtosis	-1.08
Skewness	0.65

نجد أن متوسط مجموعة التدريب للسلسلة 727.93 بينما الوسيط 423.35 أي أن الوسط الحسابي للبيانات أكبر من الوسيط معنى ذلك أن منحنى توزيع البيانات ملتوى جهة اليمين . كما أن أكبر مشاهدة في البيانات 1772.14 بينما أصغر مشاهدة 256.08 كما نجد أن معامل الإلتواء 0.65 ومعامل التفرطح -1.08 وهو قيمة صغيرة مما يشير إلى أن البيانات تقترب من شكل التوزيع الطبيعي وإن كان فيها إلتواء بسيط ناحية اليمين .

جدول (٤) يوضح بعض المقاييس الإحصائية الوصفية لمجموعة إختبار السلسلة والمكونة من 37 مشاهدة حيث نجد أن متوسط مجموعة الإختبار للسلسلة 1643.99 بينما الوسيط 1718.23 أي أن الوسط الحسابي للبيانات أصغر من الوسيط معنى ذلك أن منحنى توزيع

البيانات ملتوى جهة اليسار. كما أن أكبر مشاهدة فى البيانات 1968.63 بينما أصغر مشاهدة 1250.4 كما نجد أن معامل التفرطح -1.19 معامل الإلتواء -0.46 وهذا يعنى أن البيانات تقترب من شكل التوزيع الطبيعي ولكنها تتضمن إلتواء بسيط ناحية اليسار.

جدول (٤) المقاييس الإحصائية لمجموعة إختبار السلسلة

Statistics	Value
Observation	37
Mean	1643.99.
Median	1718.23
Min.	1250.40
Standard Deviation	219.95
Max.	1968.63
Kurtosis	-1.19
Skewness	-0.46

١- الشكل البياني لبيانات السلسلة الزمنية

شكل (٤) يوضح شكل السلسلة الزمنية لأسعار الذهب العالمية الشهرية حيث يمثل المحور الأفقى x الفترة الزمنية بينما يمثل المحور الرأسى y أسعار الذهب العالمية الشهرية , وذلك لتقييم الأنماط ومعرفة الإتجاه العام وسلوك البيانات بمرور الوقت (عبر الزمن) .

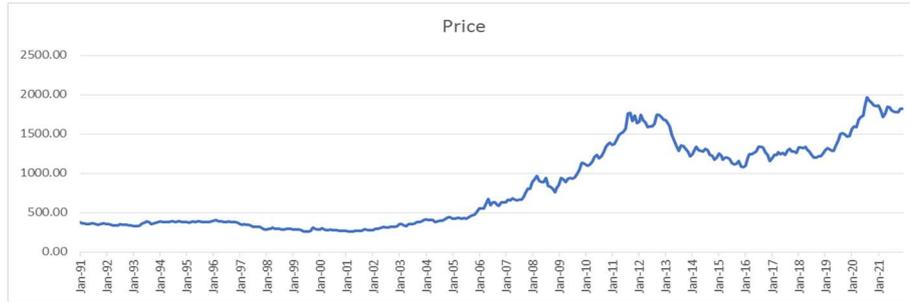


شكل (٤) يوضح السلسلة الزمنية لأسعار الذهب العالمية الشهرية من (1991: 2021)

٢- تقدير نموذج ARIMA

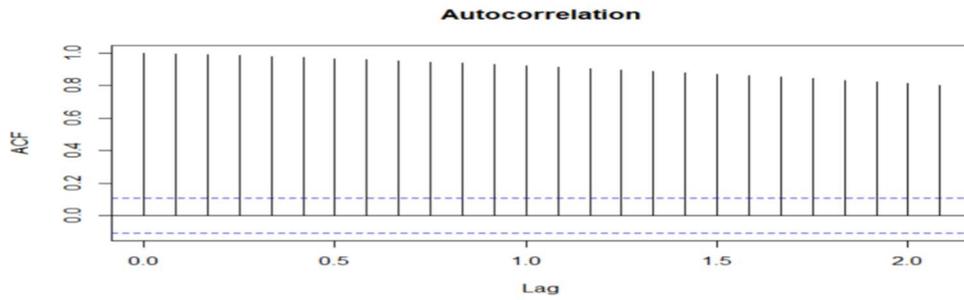
أولاً: تهيئة البيانات

قبل تطبيق منهجية Box and Jenkins لابد من إستقرار السلسلة الزمنية فى الوسط الحسابى والتباين ومن خلال رسم السلسلة الزمنية لأسعار الذهب الشهرية إتضح أنها غير مستقرة فى الوسط والتباين عبر الزمن .

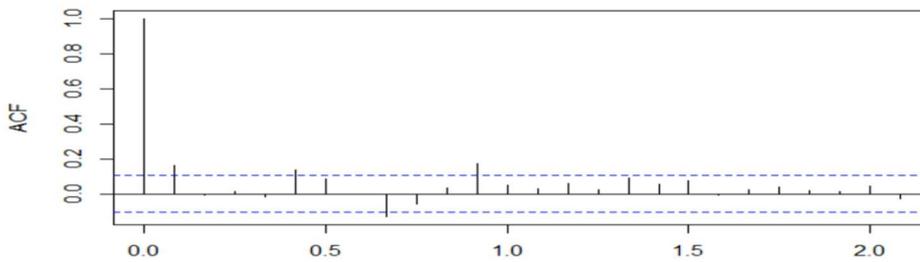


شكل (٥) يوضح السلسلة الزمنية لأسعارالذهب العالمية الشهرية

يتضح من الشكل (٥) أن السلسلة الزمنية لأسعار الذهب غير مستقرة لوجود إتجاه عام بالسلسلة أى أنها غير مستقرة فى الوسط عبر الزمن كما نلاحظ من الشكل البيانى تغير التشتت حول مستوى السلسلة مما يعنى عدم إستقرارها فى التباين عبر الزمن . وللتأكد من عدم إستقرار السلسلة تم رسم دالة الارتباط الذاتى ACF ودالة الارتباط الذاتى الجزئى PACF



شكل (٦) يوضح دالة الارتباط الذاتي للسلسلة الأصلية

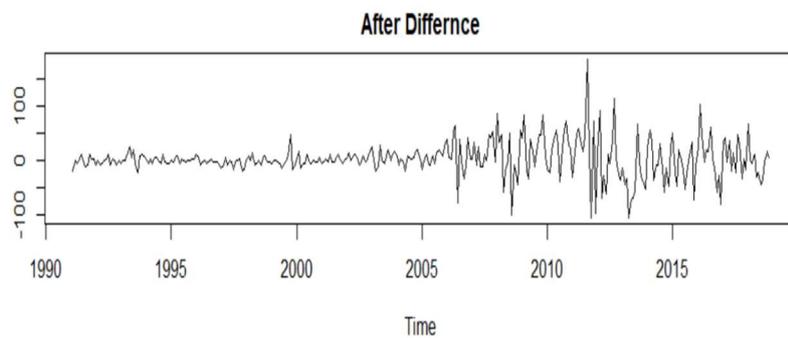


شكل (٧) يوضح دالة الارتباط الذاتي الجزئي للسلسلة الأصلية

نلاحظ من شكل (٦) على وجود تناقص ببطء للدالة مما يدل على عدم إستقرار السلسلة وبالنظر في شكل (٧) نلاحظ عدم إستقرار السلسلة ونفحص سكون السلسلة تم إستخدام إختبار ديكي فولر الموسع Augmented Dickey Fuller ADF وإختبار KPSS وإختبار فيليب وويبيرون PP بإستخدام برنامج R وكانت النتائج كالتالي التالي:

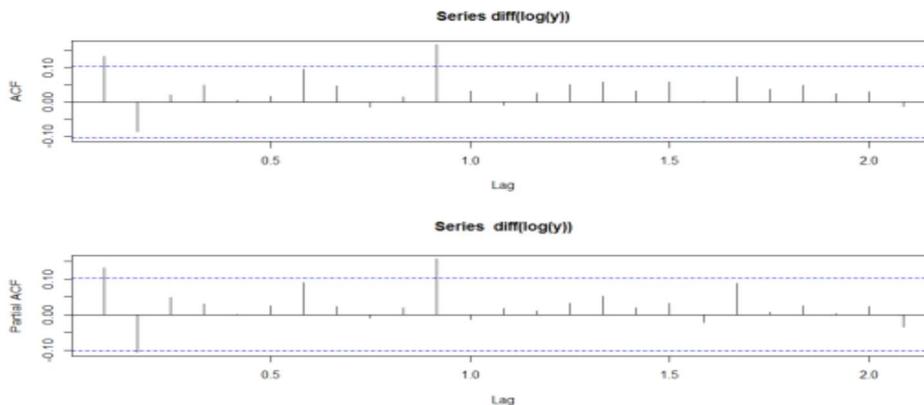
الإختبار	القيمة	P-Value	الحالة
ADF	-1.59	0.750	غير مستقرة
KPSS	4.596	0.01	غير مستقرة
PP	-2.82	0.01	غير مستقرة

من النتائج السابقة لإختبار ADF أن الإختبار غير معنوى حيث أن قيمة P-Value أكبر من 0.05 وبالتالي فإن السلسلة غير مستقرة كما أن نتائج إختبار KPSS تؤكد عدم إستقرار السلسلة وبالتالي نرفض الفرض العدمى الذى يشير إلى عدم وجود جذر الوحدة $H_0: \rho < 1$ ونقبل الفرض البديل $H_1: \rho = 1$ الذى يؤكد عدم إستقرار السلسلة. لإستقرار السلسلة الزمنية فى الوسط والتباين تم أخذ الفروق الأولى للوغاريتم السلسلة الأصلية ثم رسم السلسلة الزمنية مرة أخرى للتأكد من أن هذه التحويلة مناسبة لإستقرار السلسلة .



شكل (٨) السلسلة الزمنية بعد أخذ الفروق الأولى للوغاريتم السلسلة الأصلية

نلاحظ من الشكل السابق أن السلسلة أصبحت مستقرة بعد أخذ الفروق الأولى للوغاريتم السلسلة الأصلية وهذا ما تؤكد دالة الارتباط الذاتى فى الشكل (٩) حيث أن أغلب القيم تقع فى حدود الثقة



شكل (٩) يوضح دالتى الارتباط الذاتى والذاتى الجزئى بعد إستقرار السلسلة

بعد التأكد من خلال الرسم البياني بإستقرار السلسلة تم إستخدام إختبارات ADF, KPSS, PP مرة أخرى للتأكد من إستقرار السلسلة الزمنية وكانت النتائج كالتالى :

الإختبار	القيمة	P-Value	الحالة
ADF	-5.397	0.01	مستقرة
KPSS	0.347	0.0984	مستقرة
PP	-298.28	0.01	مستقرة

النتائج السابقة تدل على معنوية الإختبارات وبالتالي تؤكد إستقرار السلسلة الزمنية .

ثانيا : مرحلة التعرف والتقدير

بعد إستقرار السلسلة الزمنية تأتى مرحلة التعرف على النموذج من خلال رسم دالتى الإرتباط الذاتى (ACF) والارتباط الذاتى الجزئى (PACF) ومن الشكل (٩) نلاحظ أن دالة الإرتباط الذاتى تنقطع عند الفجوة الزمنية الأولى مما يدل على أن $q=1$ بينما تتلاشى دالة الإرتباط الذاتى الجزئى تدريجيا مما يدل على أن $p=0$ وبالتالي يمكن ترشيح نموذج $ARIMA(0,1,1)$. ولتوفيق أفضل نموذج للسلسلة الزمنية نقوم بترشيح نماذج أخرى $ARIMA(p,d,q)$ والمفاضلة فيما بينها بإستخدام معيار أكايكى المعلوماتى ومعيار بايز والنموذج الأفضل هو الذى يعطى أقل قيم لمعايير التقييم المذكورة .

جدول (٥) النماذج المرشحة والمعايير الإحصائية المقابلة لكل نموذج

Model	AIC	BIC
ARIMA(0,1,0)	3714.84	3718.774
ARIMA(1,1,0)	3699.78	3707.64
ARIMA(0,1,1)	3696.688	3705.789
ARIMA(1,1,1)	3699.16	3710.95
ARIMA(0,1,2)	3699.48	3711.272
ARIMA(1,1,2)	3699.15	3714.871

نلاحظ من الجدول السابق أن النموذج $ARIMA(0,1,1)$ يعطى أقل قيم لمعايير التقييم المذكورة وعليه فإن أفضل نموذج يمكن استخدامه في التنبؤ هو $ARIMA(0,1,1)$. تم تقدير معاملات النموذج المرشح باستخدام دالة الإمكان الأعظم من خلال برنامج R كانت النتائج كالتالي :

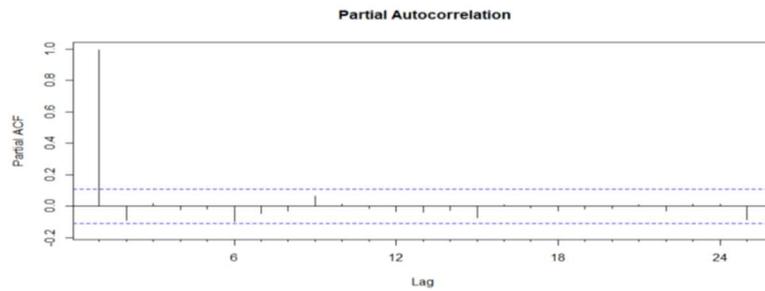
Model	θ_1	AIC	BIC
ARIMA(0,1,1)	0.2276	3696.688	3705.789

وعليه فإن معادلة النموذج المقدر تكون على الشكل التالي :

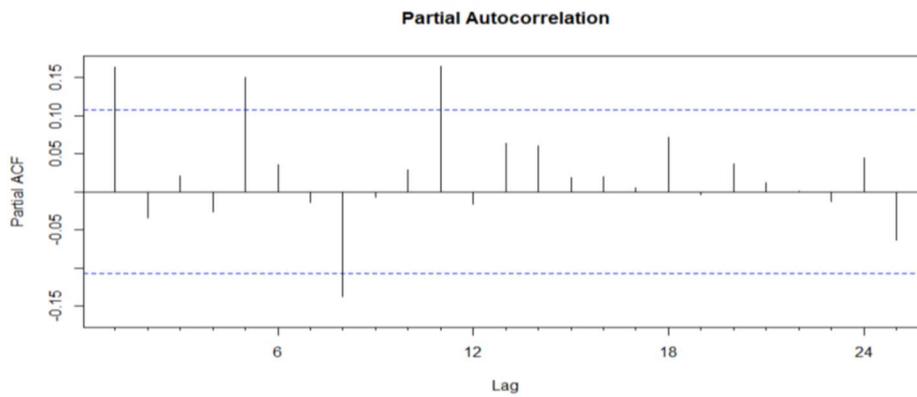
$$\Delta \hat{y}_t = 2.1022 + \varepsilon_t - 0.227\varepsilon_{t-1}$$

ثالثا : مرحلة التشخيص

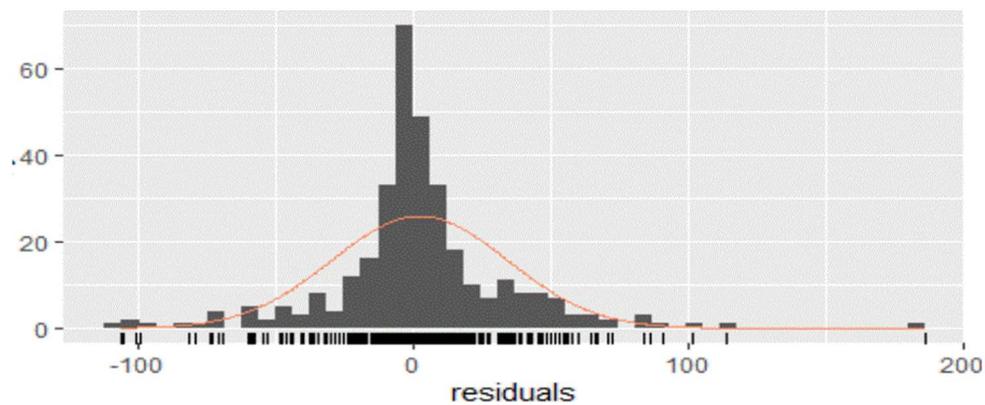
بعد التعرف على النموذج الملائم لبيانات السلسلة وتقدير معالمه نقوم بفحص ملائمة النموذج لبيانات السلسلة الزمنية بغرض تحسينه وتطويره من خلال إختبار عشوائية سلسلة البواقي حيث تم رسم دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي كما في شكل (١٠) وشكل (١١) نجد أن جميع معاملات الارتباط الذاتي تقع ضمن حدود الثقة وبالتالي هي غير معنوية ولغرض التأكد من معنوية معالم النموذج وإحتساب حدى الثقة للتنبؤ تم تمثيل سلسلة بواقي النموذج المقدر للتأكد إن الأخطاء عشوائية كما في شكل (١٢) والذي يظهر فيه خصائص التوزيع الطبيعي مما يؤدي إلى قبول النموذج وإستخدامه في التنبؤ.



شكل (١٠) يوضح دالة الارتباط الذاتي لبواقي النموذج المقدر



شكل (١١) يوضح دالة الارتباط الذاتي الجزئي لبواقي النموذج المقدر



شكل (١٢) يوضح عشوائية البواقي للنموذج المقدر

رابعاً : التنبؤ

بعد الإنتهاء من المراحل الثلاثة السابقة تبقى المرحلة الأخيرة فى عملية تحليل السلسلة الزمنية وهى التنبؤ حيث تم استخدام النموذج $ARIMA(0,1,1)$ بعد تقدير معالمه فى التنبؤ بأسعار الذهب العالمية الشهرية بعدد 37 مشاهدة مستقبلية من ديسمبر 2018 إلى ديسمبر 2021 وهى كالتالى :

الشهر	السنة	القيم الفعلية	القيم المقدرة
ديسمبر	2018	1250.40	1282.84
يناير	2019	1291.75	1316.43
فبراير	2019	1320.07	1340.95
مارس	2019	1300.90	1361.25
إبريل	2019	1285.91	1378.96
مايو	2019	1283.70	1394.87
يونيو	2019	1359.04	1409.44
يوليو	2019	1412.89	1422.97
أغسطس	2019	1500.41	1435.64
سبتمبر	2019	1510.58	1447.61
أكتوبر	2019	1494.81	1458.97
نوفمبر	2019	1470.79	1469.82
			1490.21
			1499.84
			1509.15
			1518.17
			1526.93
			1535.44
			1543.72

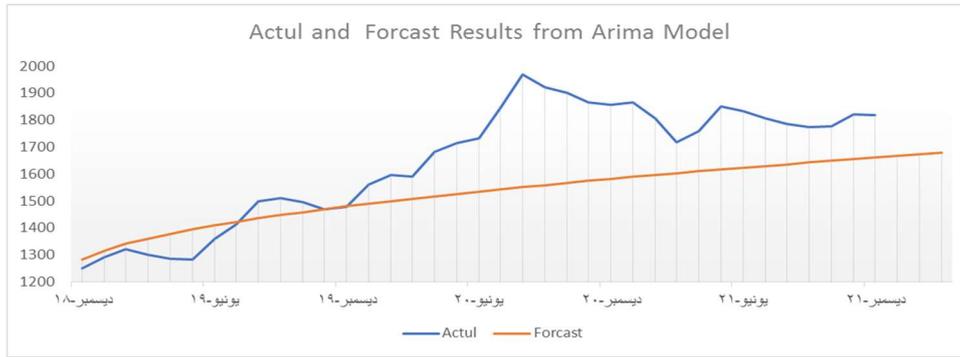
			1559.69
يناير	2020	1560.67	1567.40
			1574.93
فبراير	2020	1597.10	1582.32
			1589.55
مارس	2020	1591.93	1596.64
			1603.61
إبريل	2020	1683.17	1610.44
			1617.17
مايو	2020	1715.91	1623.77
			1630.28
يونيو	2020	1732.22	1636.67
			1642.98
أغسطس	2020	1968.63	1655.87
			1784.53
سبتمبر	2020	1921.92	1767.99

أكتوبر	2020	1900.27	
نوفمبر	2020	1866.30	
ديسمبر	2020	1858.42	
يناير	2021	1866.98	
فبراير	2021	1808.17	
مارس	2021	1718.23	
إبريل	2021	1760.04	
مايو	2021	1850.26	
يونيو	2021	1834.57	
يوليو	2021	1807.84	
أغسطس	2021	1785.28	
سبتمبر	2021	1775.14	
أكتوبر	2021	1776.85	
نوفمبر	2021	1821.76	
ديسمبر	2021	1819.37	

بعد الإنتهاء من المراحل الثلاثة السابقة تبقى المرحلة الأخيرة في عملية تحليل السلسلة الزمنية وهي التنبؤ حيث تم استخدام النموذج $ARIMA(0,1,1)$ بعد تقدير معالمه في التنبؤ بأسعار

الذهب العالمية الشهرية بعدد 37 مشاهدة مستقبلية من ديسمبر 2018 إلى ديسمبر 2021 وهي كالتالي :

جدول (٦) يوضح القيم المقدرة والفعلية لنموذج ARIMA(0,1,1)



شكل (١٣) يوضح منحنى القيم المقدرة والفعلية لنموذج ARIMA(0, 1,1)

بناء على النتائج المذكورة في الشكل (١٣) وجدول (٦) فإن أداء نموذج ARIMA غير مرضى في التنبؤ بالبيانات الفعلية ولم يكن جيدا في التنبؤ ببيانات أسعار الذهب العالمية الشهرية .

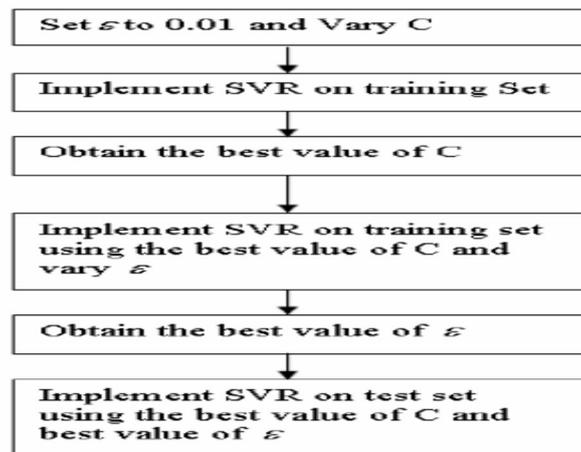
٤- تقدير نموذج Support Vector Regression (SVR)

لتقدير نموذج SVR تم تقسيم بيانات أسعار الذهب العالمية الشهرية إلى قسمين (بيانات التدريب - بيانات الإختبار) التي تمثل نسبة 10% من إجمالي البيانات بواقع 37 مشاهدة) ولتقدير النموذج لابد من إختيار دالة kernel المناسبة أولا ومن ثم إيجاد المعلمات الخاصة بالدالة المختارة. جدول (٧) التالي يوضح أنواع دوال kernel المختلفة بالإعتماد على متوسط مربعات الخطأ :

جدول (٧) يوضح أنواع دوال kernel المختلفة بالإعتماد على متوسط مربعات الخطأ

المقياس	Liner	polynomial	RBF	Sigmoid
MSE	77.56	218.78	180.45	230.55

من الجدول السابق نختار دالة kernel الخطية للتنبؤ بأسعار الذهب العالمية الشهرية لأنها تعطي أقل قيمة لمتوسط مربعات الخطأ. ولإيجاد القيم المثلى للمعلمات ϵ , C لأسعار الذهب الشهرية تم استخدام منهجية الشبكة والتي تفترض ثبات إحدى المعلمات وتغيير المعلمة الأخرى للحصول على الحد الأدنى لمتوسط مربعات الخطأ MSE من أجل تحديد دالة kernel المناسبة وتكون هذه المنهجية على الشكل التالي :



شكل (١٤) يوضح الخطوات التجريبية لنموذج SVR

تمر بيانات التدريب بعدد من الإختبارات التجريبية بغرض الحصول على قيم المعلمات وبعد عدد من الجولات التجريبية تم الحصول على $\epsilon = 0.1$, $C = 100$ كأفضل الإختيارات للبيانات التجريبية لأنها تعطي أقل قيمة لمتوسط مربعات الخطأ وتم استخدام المعلمات لتدريب

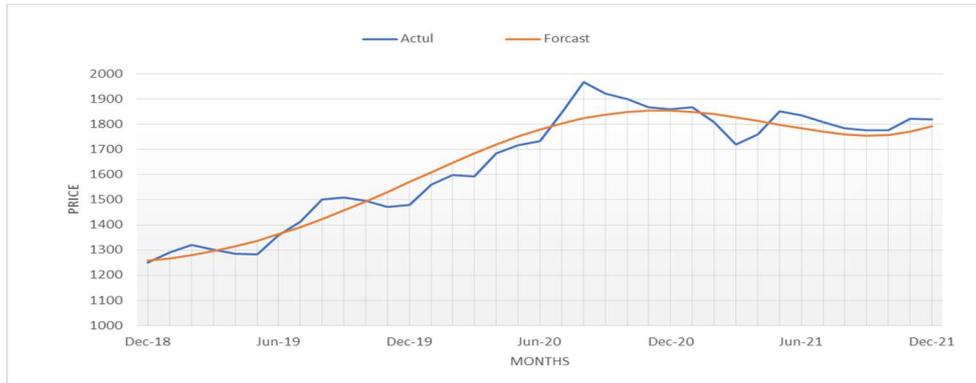
النموذج مرة أخرى ثم التنبؤ بمجموعة الإختبار . تتكون مجموعة الإختبار من 37 مشاهدة فى الفترة الزمنية من ديسمبر 2018 إلى ديسمبر 2021. كما يوضح جدول (٨) التالى القيم الفعلية والقيم المقدره لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 والتى تمثل مجموعة إختبار السلسلة الزمنية من خلال برنامج R ووفقا للمعادلة رقم (13) كالتالى:

الشهر	السنة	القيم الفعلية	القيم المقدره
ديسمبر	2018	1250.40	1259.26
يناير	2019	1291.75	1267.95
فبراير	2019	1320.07	1279.94
مارس	2019	1300.90	1295.36
إبريل	2019	1285.91	1314.30
مايو	2019	1283.70	1336.74
يونيو	2019	1359.04	1362.57
يوليو	2019	1412.89	1391.58
أغسطس	2019	1500.41	1423.47
سبتمبر	2019	1510.58	1457.84
أكتوبر	2019	1494.81	1494.21
نوفمبر	2019	1470.79	1532.02
ديسمبر	2019	1479.13	1570.62
			1609.34
			1647.45
			1684.20
			1718.87
			1750.73
			1779.14
			1803.51
			1823.38
			1838.39

يناير	2020	1560.67	1848.33
			1853.18
فبراير	2020	1597.10	1853.09
			1848.40
مارس	2020	1591.93	1839.67
			1827.67
إبريل	2020	1683.17	1813.37
			1797.96
مايو	2020	1715.91	1782.79
			1769.42
يونيو	2020	1732.22	1759.55
			1755.00
يوليو	2020	1846.51	1838.76
			1851.54
أغسطس	2020	1968.63	1845.23
سبتمبر	2020	1921.92	
أكتوبر	2020	1900.27	
نوفمبر	2020	1866.30	
ديسمبر	2020	1858.42	
يناير	2021	1866.98	
فبراير	2021	1808.17	
مارس	2021	1718.23	
إبريل	2021	1760.04	
مايو	2021	1850.26	

يونيو	2021	1834.57	
يوليو	2021	1807.84	
أغسطس	2021	1785.28	
سبتمبر	2021	1775.14	
أكتوبر	2021	1776.85	
نوفمبر	2021	1821.76	
ديسمبر	2021	1819.37	

جدول (٨) يوضح القيم الفعلية والمقدرة لنموذج SVR



شكل (١٥) يوضح منحنى القيم الفعلية والمقدرة لنموذج SVR

بناءً على النتائج المذكورة في جدول (٨) وشكل (١٥) تكون اتجاهات منحنى القيم المقدرة قريبة بشكل عام من القيم الفعلية كما أن القيم المقدرة تتناسب مع القيم الفعلية بشكل جيد .

٥- المقارنة بين نموذج ARIMA ونموذج SVR

يوضح جدول (٩) التالي مقاييس دقة التنبؤ الخاصة بالنماذج المفردة ARIMA , SVR

Model	MSE	MAE	MAPE	Theil's Inequality Coefficient
ARIMA	6144.69	147.55	8.40	0.63
SVR	5769.18	94.59	5.85	0.35

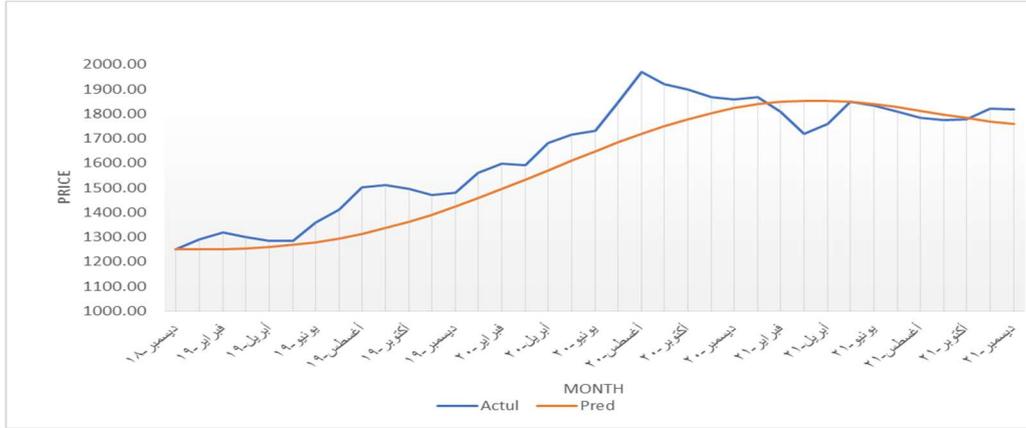
جدول (٩) يوضح مقاييس التنبؤ للنماذج ARIMA , SVR

من الجدول السابق نستنتج ما يلي :

- ١- التنبؤ بأسعار الذهب العالمية الشهرية باستخدام نموذج SVR أكثر كفاءة من نموذج ARIMA حيث يعطى أداء أفضل في التنبؤ بأخطاء قليلة .
- ٢- أظهر نموذج ARIMA أداء ضعيفا في التنبؤ مع وجود أخطاء كبيرة مقارنة بنموذج SVR .

٦- تقديرالنموذج الهجين ARIMA-SVR

لتقدير نموذج ARIMA-SVR يتم تقدير نموذج ARIMA ومن بواقي نموذج أريما الناتجة يتم بناء نموذج SVR ومن ثم جمع تنبؤات النموذجين للحصول على النموذج الهجين ARIMA-SVR .



شكل (١٦) يوضح منحنى القيم المقدرة والقيم الفعلية للنموذج ARIMA-SVR

جدول (١٠) التالي يوضح القيم المقدرة والقيم الفعلية لأسعار الذهب الشهرية للنموذج الهجين ARIMA-SVR لمجموعة الإختبار المكونه من 37 مشاهدة من ديسمبر 2018 إلى ديسمبر 2021 من خلال برنامج R ووفقا للمعادلة رقم (20) كالتالى:

الشهر	السنة	القيم الفعلية	القيم المقدرة
ديسمبر	2018	1250.40	1252.24
يناير	2019	1291.75	1250.90
فبراير	2019	1320.07	1251.64
مارس	2019	1300.90	1254.26
أبريل	2019	1285.91	1259.44
مايو	2019	1283.70	1268.34
يونيو	2019	1359.04	1280.52
			1285.91
			1295.28
			1314.47
			1337.80
			1363.27
			1392.06

يوليو	2019	1412.89	1423.62
			1458.34
أغسطس	2019	1500.41	1494.47
			1532.20
سبتمبر	2019	1510.58	1571.87
			1609.33
أكتوبر	2019	1494.81	1647.74
			1684.56
نوفمبر	2019	1470.79	1719.36
			1751.29
ديسمبر	2019	1479.13	1779.39
			1804.78
يناير	2020	1560.67	1823.09
			1838.40
فبراير	2020	1597.10	1848.27
			1853.65
مارس	2020	1591.93	1854.39
			1848.34
إبريل	2020	1683.17	1840.12
			1828.45
مايو	2020	1715.91	1813.43
			1798.08
يونيو	2020	1732.22	1783.62
			1769.42
أغسطس	2020	1968.63	1786.54
سبتمبر	2020	1921.92	
أكتوبر	2020	1900.27	
نوفمبر	2020	1866.30	

ديسمبر	2020	1858.42	
يناير	2021	1866.98	
فبراير	2021	1808.17	
مارس	2021	1718.23	
إبريل	2021	1760.04	
مايو	2021	1850.26	
يونيو	2021	1834.57	
يوليو	2021	1807.84	
أغسطس	2021	1785.28	
سبتمبر	2021	1775.14	
أكتوبر	2021	1776.85	
نوفمبر	2021	1821.76	
ديسمبر	2021	1819.37	

جدول (١٠) يوضح القيم الفعلية والمقدرة للنموذج الهجين ARIMA-SVR

بناءً على النتائج المذكورة في الشكل (١٦) وجدول (١٠) تكون اتجاهات منحنى القيم المقدرة قريبة بشكل عام من القيم الفعلية كما أن القيم المقدرة تتناسب مع القيم الفعلية بشكل جيد حيث يظهر النموذج الهجين ARIMA-SVR أداءً أفضل من النموذج المفرد SVR في التنبؤ.

٦- المقارنة بين النموذج الهجين والنماذج المفردة

يوضح جدول (١١) التالي مقاييس دقة التنبؤ الخاصة بنماذج البحث

Model	MSE	MAE	MAPE	Theil's Inequality Coefficient
ARIMA	6144.69	147.55	8.40	0.63
SVR	5769.18	94.59	5.85	0.35
ARIMA-SVR	4531.74	78.10	4.75	0.13

جدول (١١) يوضح مقاييس دقة التنبؤ لنماذج البحث

من الجدول السابق نستنتج ما يلي :

١- التنبؤ بأسعار الذهب العالمية الشهرية باستخدام نموذج SVR أكثر كفاءة من

نموذج ARIMA حيث يعطى أداء أفضل في التنبؤ بأخطاء قليلة .

٢- أظهر نموذج ARIMA أداءا ضعيفا في التنبؤ مع وجود أخطاء كبيرة مقارنة

بنموذج SVR .

٣- التنبؤ بأسعار الذهب العالمية الشهرية باستخدام النموذج الهجين ARIMA-SVR

أكثر كفاءة من نموذجي ARIMA,SVR حيث يعطى أداء أفضل في التنبؤ

بأخطاء قليلة .

الإستنتاجات

من خلال الدراسة التطبيقية لموضوع البحث توصلت الباحثة إلى مجموعة من النتائج يمكن إيجازها فيما يلي:

- ١- أن سلسلة أسعار الذهب العالمية الشهرية سلسلة غير مستقرة في التباين ويوجد بها إتجاه عام وذلك من خلال الرسم البياني للسلسلة وكذلك دالتى الارتباط الذاتى والذاتى الجزئى ولإستقرار السلسلة الزمنية تم إستخدام التحويلة اللوغاريتمية لبيانات السلسلة لتثبيت التباين وإستخدام الفروق الأولى للوغاريتم بيانات السلسلة الزمنية لإزالة الإتجاه العام .
- ٢- نموذج $ARIMA(0,1,1)$ هو الأفضل لأسعار الذهب العالمية الشهرية من بين نماذج بوكس وجينكيز الأخرى بالإعتماد على معايير AIC, BIC .
- ٣- من خلال المقارنة بين نماذج التنبؤ الثلاث الذى تم إستخدامهم فى هذا البحث وذلك بالإعتماد على بعض مقاييس دقة التنبؤ $MSE, MAE, MAPE, T$ توصلنا إلى ما يلى :-
 - النموذج الأكثر كفاءة فى التنبؤ بأسعار الذهب العالمية الشهرية هو النموذج الهجين $ARIMA-SVR$ لإمتلاكه أقل القيم لمقاييس دقة التنبؤ.
 - يلى النموذج الهجين فى الكفاءة فى التنبؤ نموذج SVR وكان أقل النماذج والذى أظهر أداءا ضعيفا فى التنبؤ هو نموذج $ARIMA$.

المراجع

أولاً: المراجع العربية

- ١- شعراوى ، سمير مصطفى، (2005). "مقدمة فى التحليل الحديث للسلاسل الزمنية". كلية العلوم، جامعة الملك عبد العزيز، المملكة العربية السعودية.

المراجع الأجنبية

1. Athavale, Y. R. (2010). "Pattern classification of time-series signals using Fisher kernels and support vector machines". Master Thesis of applied Science Electrical and Computer Engineering . Ryerson University.
2. Bleikh, H. Y., and Young, W. L. (2014). "Time Series Analysis and Adjustment: Measuring, Modelling and Forecasting for Business and Economics". Gower.
3. Box, G. E., Jenkins, G. M. (1976). "Time series analysis: forecasting and control". Holden day, London.
4. Cao, L. J., and Tay, F. E. (2003). "Support vector machine with adaptive parameters in financial time series forecasting". *IEEE Transactions on neural networks*, 14(6), 1506-1518.
5. Cosgun, E., Limdi, N. A., and Duarte, C. W. (2011). "High-dimensional pharmacogenetic prediction of a continuous trait using machine learning techniques with application to warfarin dose prediction in African Americans". *Bioinformatics*, 27(10), 1384-1389.
6. Dickey, D. A. and Fuller, W. A., (1981). "Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root", *Journal of the Econometric Society Vol 49, (4), 1057-1072*.
7. Kwiatkowski, D. Phillips, P. Schmidt, P. and Shin, Y. (1992). "Testing the Null Hypothesis of Stationarity against the Alternative of a Unit Root". *Journal of Econometrics*, 54, 159-178, North-Holland.

8. Lai, H., et al. (2021). "COVID-19 pandemic and unemployment rate: A hybrid unemployment rate prediction approach for developed and developing countries of Asia". *Soft Computing* 1-16.
9. Mei, W., Xu, P., Liu, R., and Liu, J. (2018). "Stock price prediction based on ARIMA-SVM model". In *International Conference on Big Data and Artificial Intelligence* (p. 4).
10. Nawi, W. I. A. W. M., Lola, M. S., Zakariya, R., Zainuddin, N. H., Abd Hamid, A. A. K., Aruchunan, E., and Nazzrol, N. S. A. (2021). "Improved of forecasting sea surface temperature based on hybrid ARIMA and support vector machines models". *Malaysian Journal of Fundamental and Applied Sciences*, 17(5), 609-620.
11. Pan, Y., Jin, X., Li, Y., Chen, D., and Zhou, J. (2021). "A Study on the Prediction of Book Borrowing Based on ARIMA-SVR Model". *Procedia Computer Science*, 188, 93-102.
12. Phillips, P.C.B. and Perron, P. (1988). "Testing for Unit Roots in Time Series Regression," *Biometrika*, 75, 335-346.
13. Russell, R. (2018). "*Machine Learning Step-by-Step Guide To Implement Machine Learning Algorithms with Python*". CreateSpace Independent Publishing Platform, USA.
14. Singh, V., Poonia, R. C., Kumar, S., Dass, P., Agarwal, P., Bhatnagar, V., and Raja, L. (2020). "Prediction of COVID-19 corona virus pandemic based on time series data using Support Vector Machine". *Journal of Discrete Mathematical Sciences and Cryptography*, 23(8), 1583- 1597.
15. Smola, A. J., and Schölkopf, B. (2004). "A tutorial on support vector regression". *Statistics and computing*, 14(3), 199-222.
16. Su, S. (2021). "Nonlinear ARIMA Models with Feedback SVR in Financial Market Forecasting". *Journal of Mathematics*, 2021.
17. Thanh N, P., and Kappas, M. (2018). "Comparison of random forest, k-nearest neighbor, and support vector machine classifiers

- for land cover classification using Sentinel-2 imagery”. *Sensors*, 18(1), 18-38.
18. Wang, Y., Li, L., and Xu, X. (2017). “A piecewise hybrid of ARIMA and SVMs for short-term traffic flow prediction”. In *Neural Information Processing: 24th International Conference, ICONIP 2017, Guangzhou, China, November 14–18, Proceedings, Part V 24* (pp. 493-502). Springer International Publishing.
 19. Wang, B., Liu, P., Chao, Z., Junmei, W., Chen, W., Cao, N., and Wen, F. (2018). “Research on hybrid model of garlic short-term price forecasting based on big data”. *CMC: Comput. Mater. Continua*, 57(2), 283-296.
 20. Xu, D., Zhang, Q., Ding, Y., and Huang, H. (2020). “Application of a hybrid ARIMA–SVR model based on the SPI for the forecast of droughta case study in Henan Province, China”. *Journal of Applied Meteorology and Climatology*, 59(7), 1239-1259.
 21. Zhang, G. P. (2003). “Time series forecasting using a hybrid ARIMA and neural network model”. *Neurocomputing*, 50, 159-175.
 22. Zhang, Y., Luo, L., Yang, J., Liu, D., Kong, R., and Feng, Y. (2019). “A hybrid ARIMA-SVR approach for forecasting emergency patient flow”. *Journal of Ambient Intelligence and Humanized Computing*, 10(8), 3315-3323.
 23. Zheng, Y., Yuan, K., and Dai, L. (2021). “Research on Coal Price Forecast based on ARIMA and SVM combination Model”. In *E3S Web of Conferences* (Vol. 257, p. 02008). EDP Sciences.
 24. Zhu, B., and Wei, Y. (2013). “Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology”. *Omega*, 41(3), 517-524.