



## مجلة التجارة والتمويل

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

كلية التجارة – جامعة طنطا

العدد : الثالث

سبتمبر 2023

الجزء الثاني





كلية التجارة – فرع البنات



جامعة الأزهر

قسم الإحصاء

**التنبؤ بالسلاسل الزمنية باستخدام النموذج العجين ARIMA-SVR بالإتماد على التحويل الموجى المنفصل**

إعداد الباحثة

هناء محمد محمود نصار

مدرس مساعد بقسم الإحصاء

كلية التجارة بنات - فرع تفهنا الأشراف

[hanaanassar419@gmail.com](mailto:hanaanassar419@gmail.com)

الإشراف

أ.د/ نصر إبراهيم رشوان أبو زيد

أستاذ ورئيس قسم الإحصاء

كلية التجارة – طنطا

[nasrrashwan@yahoo.com](mailto:nasrrashwan@yahoo.com)

أ.م.د/ ماجدة محمد إسماعيل

أستاذ الإحصاء المساعد – كلية التجارة بنات

جامعة الأزهر – فرع تفهنا الأشراف

[magdaismaileg@gmail.com](mailto:magdaismaileg@gmail.com)

أ.م.د/ أمل أحمد طلعت

أستاذ الإحصاء المساعد ورئيس قسم الإحصاء

كلية التجارة بنات – جامعة الأزهر

[D.amel@hotmail.com](mailto:D.amel@hotmail.com)

## المستخلص

يهدف هذا البحث إلى إستخدام ثلاث نماذج للتنبؤ بالسلاسل الزمنية وهى نموذج الإنحدار الذاتى والمتوسطات المتحركة التكاملية بالإعتماد على التحويل الموجى المنفصل -DWT ARIMA ونموذج إنحدار متجة الدعم بالإعتماد على التحويل الموجى المنفصل DWT-SVR والنموذج الهجين الذى يجمع بين نموذج ARIMA ونموذج SVR بالإعتماد على التحويل الموجى المنفصل DWT-ARIMA-SVR وتم إستخدام هذه النماذج للتنبؤ بأسعار الذهب العالمية الشهرية وذلك بالإعتماد على سلسلة زمنية لأسعار الذهب العالمية الشهرية فى الفترة الزمنية من يناير 1991 إلى ديسمبر 2021 كما تم المفاضلة والمقارنة بين الثلاث نماذج وذلك بالإعتماد على مقاييس دقة التنبؤ وهى متوسط مربعات الخطأ MSE ومتوسط الخطأ المطلق MAE بالإضافة إلى متوسط الخطأ المطلق النسبى MAPE ومعامل عدم التساوى لثايل T وقد توصل البحث إلى تفوق النموذج الهجين بالإعتماد على التحويل الموجى المنفصل على النماذج المفردة لإملاكه أقل القيم لمقاييس دقة التنبؤ.

**الكلمات المفتاحية :** التحويل الموجى المنفصل، نموذج DWT-ARIMA ،نموذج -DWT SVR، النموذج الهجين DWT-ARIMA-SVR، مقاييس دقة التنبؤ.

**Abstract:**

This paper using three models for predicting time series, Auto Regressive Integrated Moving Average based on Discrete Wavelet Transform DWT-ARIMA model and the Support Vector Regression based on Discrete Wavelet Transform DWT-SVR and Hybrid model by combining the ARIMA model with the SVR model based on Discrete Wavelet Transform DWT-ARIMA-SVR, 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 DWT-ARIMA-SVR with individual models DWT-ARIMA and DWT-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 DWT-ARIMA-SVR on other individual models by having the lowest values of the prediction measures.

**Keywords:** Discrete Wavelet Transform; DWT-ARIMA; DWT-SVR; Hybrid model DWT-ARIMA-SVR; prediction measures.

تعد نماذج ARIMA الكلاسيكية غير كافية للتنبؤ في حالة البيانات غير الخطية حيث تفترض خطية البيانات 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 Zhang [25] وسار على نهجه الكثير من الباحثين حيث تجمع النماذج الهجينة بين قوة نماذج ARIMA ومرونة نموذج إحدار 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 كما أن السلاسل المالية تكون غير ثابتة لذا فإن النماذج الهجينة بطريقة Zhang لاتعطي تنبؤات دقيقة بالشكل الكافي وعليه تم استخدام التحويل الموجي المنفصل لبيانات السلسلة الزمنية محل الدراسة للحصول على تنبؤات أكثر دقة وواقعية ويستخدم التحويل الموجي في كثير من المجالات والعلوم المتنوعة مثل التشفير، الهندسة الوراثية، الفلك، التعرف على الأصوات، الرادار والكشف عن الزلازل وغيرها ويتم فيه التعامل مع بيانات السلسلة الزمنية كإشارات ويتم تقسيمها إلى ترددات عالية وترددات منخفضة للحصول على معلومات تقريبية وتفصيلية على طول الموجة ويوجد العديد من الدراسات التي تناولت التنبؤ بالسلاسل الزمنية باستخدام النماذج الهجينة ARIMA-SVR بالإعتماد على التحويل الموجي المنفصل في مجالات متنوعة من الإقتصاد والإحصاء والهندسة والعلوم. [1] يستخدم نموذج ARIMA القائم على التحويل الموجي المنفصل DWT للتنبؤ الشهري بجسيمات PM10 إحدى ملوثات الغلاف الجوي وخلصت نتائج البحث تفوق نموذج DWT-ARIMA على نموذج ARIMA المفرد. [15] تناول نموذج DWT-SVR للتنبؤ بمعدل التدفق اليومي للمياه في ثلاث محطات بولاية كارناتاكا بالهند وخلصت النتائج إلى أن النموذج DWT-SVR أفضل من نموذج SVR المفرد. [13] سعى للتنبؤ الشهري بعدد المتعسرين عن سداد القروض بأحد البنوك بالأردن

باستخدام نموذج DWT-ARIMA وخلصت النتائج إلى أن النموذج DWT-ARIMA أفضل من النموذج المفرد. [12] إتمد نموذج DWT-ARIMA للتنبؤ بإستهلاك الطاقة اليومي لمبنى كامل بإحدى المقاطعات بالصين لمدة عام واحد وخلصت النتائج إلى أن النموذج DWT-ARIMA أفضل من النموذج المفرد. [14] إستخدم نموذج DWT-SVR للتنبؤ اليومي بمعدل فشل المكالمات فى شبكات النظام اللاسلكى لمدة أسبوع واحد فى مدينة هاركورت بنجيريا وخلصت النتائج إلى أن النموذج DWT-SVR أفضل من نموذج SVR المفرد. [2] تناول نموذج DWT-SVR للتنبؤ الشهري بتدفق المياه فى نهر كيزيلرماك بتركيا وخلصت النتائج إلى أن النموذج DWT-SVR أفضل من نموذج SVR المفرد. [16] هدفت الدراسة إلى إستخدم نموذج DWT-SVR للتنبؤ بوقت السفر بالحافلة رقم 550 فى نانجينغ بالصين بين ثلاث محطات مختلفة وخلصت النتائج إلى أن النموذج DWT-SVR أفضل من نموذج SVR المفرد. [21] تناول نموذج DWT-ARIMA للتنبؤ بإنبعاثات ثانى أكسيد الكربون للفرد فى الجزائر وخلصت النتائج إلى أن النموذج DWT-ARIMA أفضل من نموذج ARIMA المفرد. [23] إتمد نموذج DWT-ARIMA للتنبؤ اليومي بحالات الوفيات COVID-19 فى خمس دول فى العالم هى إيطاليا - أسبانيا - فرنسا- المملكة المتحدة - الولايات المتحدة الأمريكية وخلصت النتائج إلى إرتفاع حاد فى حالات الوفيات اليومية على الرغم من الإجراءات الإحترازية المختلفة التى تتخذها حكومات هذه الدول وأن النموذج DWT-ARIMA أفضل من نموذج ARIMA المفرد. [22] تناول نموذج DWT-ARIMA للتنبؤ بملوثات طبقة الأوزون وخلصت النتائج إلى أن النموذج DWT-ARIMA أفضل من نموذج ARIMA المفرد. [19] إستخدم نموذج DWT-SVR للتنبؤ اليومي بالأحمال القصوى لنظام الطاقة باليونان وخلصت النتائج إلى أن النموذج DWT-SVR أفضل من نموذج SVR المفرد.

## ٢- مشكلة البحث

تتمثل مشكلة البحث في أن النماذج الأحادية سواء نماذج بوكس وجينكيز التقليدية ARIMA أو النماذج الحديثة كنموذج إندارد متجة الدعم SVR كلاهما لا يعطى تنبؤات دقيقة للسلسلة الزمنية نظرا لإحتوائها على جزء خطى وآخر غير خطى لذا تناول البحث إستخدام النموذج الهجين بالإعتماد على التحويل الموجى المنفصل من خلال الدمج بين نموذج ARIMA ونموذج إندارد متجة الدعم SVR لكى يتم تعويض القصور الموجود فى كل نموذج على حده والحصول على تنبؤات أكثر دقة

## ٣- أهداف البحث.

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

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

## ٤- أهمية البحث

تكمن 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 وخاصة النماذج



الهجينة بالإعتماد على التحويل الموجى المنفصل حيث يتم تقسيم إشارة الإدخال لبيانات السلسلة الزمنية إلى ترددات منخفضة وعالية للحصول على معاملات تقريبية وتفصيلية مما يساعد في تقليل الأخطاء الناتجة وبالتالي الحصول على تنبؤات أكثر دقة .

#### ٥- حدود البحث

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

#### ٦- التحويل الموجى Wavelet Transform

عبارة عن طريقة تحليلية رياضية تستخدم من أجل معالجة الإشارات بتحويل الإشارة من حيز الزمن إلى حيز التردد والعكس من خلال استخدام نافذة متغيرة العرض بدلا من نافذة ثابتة العرض للحصول على معلومات مختلفة التردد على طول الموجة بهذه الطريقة يتم الحصول موجات يختلف ترددها باختلاف عرض النافذة المستخدم [8] وتقوم النافذة الكبيرة بإنتاج موجة ذات تردد منخفض والتي تعرف بالعوامل التقريبية (Approximation) بينما تقوم النافذة الصغيرة بإنتاج موجة ذات تردد مرتفع والتي تعرف بالعوامل التفصيلية (Details) بعبارة أخرى تكون النافذة قصيرة عند الترددات المرتفعة وطويلة عند الترددات المنخفضة. أي للحصول على المعلومات يتم تحليل الإشارة أي تقسيمها إلى العوامل التقريبية والتفصيلية وتستمر هذه العملية لحين الحصول على مجموعات متتابعة من هذه العوامل [10] وبالتالي فإن التحويل الموجى أداة لدراسة الإشارات في المجالين الزمني والترددى وينقسم التحويل الموجى الى قسمين رئيسيين هما : التحويل الموجى المنفصل - التحويل الموجى المستمر وفى هذا البحث تم إستخدام التحويل الموجى المنفصل .

## (٦-١) التحويل الموجى المنفصل

يقوم التحويل الموجى المنفصل بتحليل الإشارة إلى حزم تردد مختلفة [20] وتكون صيغته على الشكل التالي :

$$W_x(j, k) = \sum_t x(t) 2^{-j/2} \cdot \psi(2^{-j}t - k) \quad (1)$$

حيث أن :

$k$  : تمثل الإزاحة على محور الزمن  $j$  : تمثل الإنتقال وكلا  $(j, k)$  من أعداد صحيحة

ويعبر عن معكوس التحويل الموجى المنفصل بالصيغة التالية :

$$x(t) = \sum_k \sum_j W_x(j, k) 2^{j/2} \cdot \psi(2^j t - k) \quad (2)$$

وتم استخدام التحويل الموجى المنفصل لأنه ينتج كمية قليلة وكافية من المعلومات والموجات كما أن عملية المعالجة لا تتطلب زمنا كبيرا كما يستخدم لكل أنواع الإشارات على العكس من التحويل الموجى المستمر الذي يواجه مشكلة العدد الكبير من الموجات الناتجة بسبب حساب المعاملات الموجية عند مختلف الإزاحات الممكنة وبالتالي ينتج كمية كبيرة من المعلومات وهذا ما يجعل عملية المعالجة تتطلب زمنا كبيرا جدا .

## ٧- المنهجيات المستخدمة Methodology

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

## (٧-١) نماذج الإنحدار الذاتي والمتوسطات المتحركة التكاملية

**Integrated Autoregressive Moving Average Models ARIMA**

تعتبر نماذج ARIMA أكثر نماذج السلاسل الزمنية إستخداما , وتعرف بمنهجية بوكس وجينكيز 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 [4]. فهي مزيج من نماذج الإنحدار الذاتي ونماذج المتوسطات المتحركة بعد أخذ الفروق المناسبة لإستقرار السلسلة ويرمز لها بالرمز  $ARIMA(p, d, q)$  ومنها يمكن إشتقاق جميع النماذج سواء كانت إنحدار ذاتي أو متوسطات متحركة أو مختلطة والصيغة العامة لها تكون على الشكل التالي :

$$y_t = \phi_0 + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon y_{t-p-d} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (3)$$

حيث أن :

$p$  : رتبة نموذج الإنحدار الذاتي .

$q$  : رتبة نموذج المتوسطات المتحركة .

$d$  : عدد الفروق اللازمة لإستقرار السلسلة .

**(٧-٢) نموذج DWT-ARIMA**

تعد السلاسل المالية من السلاسل الديناميكية وغير الثابتة لذا إستخدام نموذج ARIMA بشكل فردي للتنبؤ بأسعار الذهب العالمية الشهرية يعطى نتائج غير مرضية وللحصول نتائج مرضية و تنبؤات أكثر دقة تم إستخدام التحويل الموجى المنفصل لتجزئة إشارة الإدخال لبيانات السلسلة الزمنية لأسعار الذهب العالمية الشهرية إلى  $m$  من السلاسل الفرعية أو المستويات على طول

السلسلة الأصلية إلى مرشح تمرير منخفض للحصول على معاملات تقريبية Approximation Coefficients (A) ومرشح تمرير عالي للحصول على معاملات تفصيلية Detail Coefficients (D) وتسمى هذه العملية decomposition ومن خلال معكوس التحويل الموجى يتم تجميع هذه المعاملات (التقريبية والتفصيلية) مرة أخرى فى الإشارة الأصلية دون فقدان المعلومات بدءاً من آخر عملية تحليل لتشمل عدد مراحل التحليل [5] وتسمى هذه العملية بإعادة البناء Reconstruction وتتكون السلاسل الفرعية من مجموع المعاملات التقريبية للمستوى الأخير والمعاملات التفصيلية لجميع المستويات وتكون على الشكل التالى :

$$S_m = A_m + D_{m-1} + D_{m-2} + \dots + D_1 \quad (4)$$

حيث أن :

$m$  : تمثل عدد مستويات تحليل السلسلة الأصلية  $A$  : المعاملات التقريبية  $D$  : المعاملات التفصيلية  $S_m$  : تمثل السلاسل الفرعية للسلسلة الأصلية .

كما تم استخدام مرشح الموجة دوبشيز db من بين دوال المويجات لأنها أكثر ملائمة للسلسلة الزمنية محل الدراسة حيث تستخدم للإشارات غير المنتظمة [7] والمرشح عبارة عن فاصل خطى يفصل الإشارات بتردداتها المختلفة عن بعضها البعض وتعمل على تنقية الإشارة من التشوش أو الضوضاء ومن خلال برنامج R تم إختيار الموجة db4 من الرتبة الرابعة والمستوى الثالث وبعد تجزئة السلسلة الزمنية وإعادة بناءها حصلنا على ست سلاسل فرعية تحتوى على معامل تقريبي واحد وخمس معاملات تفصيلية  $A_5, D_1, D_2, D_3, D_4, D_5$  وبإفترض أن  $Y$  تمثل بيانات أسعار الذهب العالمية الشهرية للسلسلة الأصلية تكون لدينا المعادلة التالية :

$$Y = A_5 + D_1 + D_2 + D_3 + D_4 + D_5 \quad (5)$$

حيث أن :

$Y$  : تمثل سلسلة أسعار الذهب العالمية الشهرية الأصلية  $A$  : المعاملات التقريبية  $D$  : المعاملات التفصيلية

ووفقا للمعادلة رقم (3) يتم بناء نموذج ARIMA المقابل لكل سلسلة فرعية ومن ثم التنبؤ لكل سلسلة في نموذج ARIMA ثم جمع هذه التنبؤات للحصول على القيم المتنبأ بها لنموذج DWT-ARIMA ويتم تقدير النموذج من خلال العلاقة التالية :

$$Y^* = A_5^* + D_1^* + D_2^* + D_3^* + D_4^* + D_5^* \quad (6)$$

### Support Vector Regression SVR نموذج (٣-٧)

تم استخدام SVR على نطاق واسع للتنبؤ بالسلاسل الزمنية التي تحتوى بيانات غير خطية مثل البيانات الإقتصادية والمالية وتتمثل فكرة SVR في 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 [11] وتستخدم دالة kernel في حالة تعذر فصل البيانات خطيا وتعمل على تحويل فضاء البيانات الأصلية إلى فضاء أعلى الأبعاد حتى تتمكن من فصل البيانات ويتم في إنحدار متجهات الدعم تنظيم المدخلات  $x$  إلى فضاء ذو البعد  $n$  باستخدام مجموعة من التحويلات غير الخطية المحددة  $\varphi(x_i)$  (أى الانتقال ببيانات التدريب من فضاء المدخلات إلى فضاء أعلى الأبعاد) والصيغة العامة SVR تكون على الشكل التالى :

$$f(x, w) = w^T \varphi(x_i) + b \quad (7)$$

حيث أن :

$w^T$ : يمثل متجه الأوزان  $w = w_1, w_2, \dots, w_d$   $b$ : تمثل مقدار التحيز

$\varphi(x_i)$ : تمثل مساحة ميزة عالية الأبعاد يتم تعيينها بشكل غير خطى من مساحة المدخلات

$x_i$  أو دالة kernel

### DWT-SVR نموذج (٤-٧)

يتم تجزئة بيانات السلسلة الأصلية إلى مجموعة من الترددات المنخفضة والعالية باستخدام التحويل الموجى المنفصل DWT للحصول على معاملات تقريبية وتفصيلية على التوالى

[9] ومن ثم إعادة بناءها مرة أخرى من خلال معكوس التحويل المويجي IDWT وبعد تجزئة السلسلة الأصلية لعدد من السلاسل الفرعية يتم تعلم وتدريب كل سلسلة فرعية بشكل منفصل باستخدام نموذج SVR من خلال تحويل فضاء بيانات الإدخال إلى فضاء أعلى بحيث يمكن فصل البيانات وتمييزها وذلك من خلال دالة kernel حيث تعتبر الأداة التي يتم استخدامها في حالة تعذر فصل البيانات خطيا وتعمل على تحويل فضاء البيانات الأصلية إلى فضاء أعلى الأبعاد حتى تتمكن من فصل البيانات كما يعتمد كفاءة نموذج SVR على دالة kernel [24] وتوجد أنواع كثيرة لدوال kernel نذكر منها الأكثر شيوعا وإستخداما كما في جدول (١) التالي :

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)	$k(x_i, x_j) = \exp(-\gamma x_i - x_j ^2)$

جدول (١) يوضح دوال kernel المختلفة

المصدر : (Thanh and Kappas,2018)

ومن ثم تقدير معاملات نموذج SVR ويتم الحصول على نتائج التنبؤ النهائية بجمع مخرجات النموذج لكل مكون أى عن طريق جمع نتائج التنبؤ لجميع نماذج SVR ويعبر عنها كالتالى:

$$y_{predict} = \sum_{j=1}^J D_j^* + A_n^* \quad j = 1,2,3, \dots, J \quad (8)$$

حيث أن :

$y_{predict}$  : تمثل السلسلة الزمنية المقدرة  $D^*$  : المعاملات التفصيلية المقدرة  $A^*$  :  
المعاملات التقريبية المقدرة.

### (٥-٧) النموذج الهجين ARIMA-SVR

النموذج الهجين هو الناتج من دمج نموذج خطى مع نموذج آخر غير خطى أو العكس لعلاج النقص الموجود فيما لو إستخدم كل نموذج على حده بغرض تحسين التنبؤات المستقبلية وتقليل الأخطاء الناتجة من إستخدام نموذج غير مناسب [6] وتتم عملية التهجين والتي تتمثل فى دمج نموذج خطى مع آخر غير خطى للحصول على تنبؤات أكثر دقة وتقليل الأخطاء الناتجة من إستخدام 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 إستخدام كل نموذج بشكل فردى وأول من قدم هذه الفكرة Zhang [25] وسار على نهجه الكثير من الباحثين حيث تجمع النماذج الهجينة بين قوة نماذج ARIMA ومرونة نموذج إنحدار متجة الدعم SVR لقدرته على التعامل مع الأنماط المختلفة من البيانات وتكون صيغته على الشكل التالى :

$$y_t = L_t + N_t \quad (9)$$

حيث أن :

$y_t$  : تمثل السلسلة الزمنية الأصلية  $L_t$  : تمثل الجزء الخطى فى السلسلة الزمنية (الإنحدار الذاتى).

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

### (٦-٧) النموذج الهجين ARIMA-SVR بالإعتماد على DWT

يستخدم التحويل الموجى المنفصل للحصول على تحليل مسبق لبيانات السلسلة الزمنية إلى ترددات عالية وترددات منخفضة ولتهجين النموذج ARIMA-SVR بالإعتماد على التحويل الموجى المنفصل يتم على مرحلتين :

**Decomposition Algorithm** المرحلة الأولى : طريقة تجزئة البيانات

في هذه المرحلة يتم تجزئة بيانات السلسلة الزمنية إلى مرشحات تمريرعالية (معاملات تفصيلية) ومرشحات تمرير منخفضة (معاملات تقريبية) والتي بدورها تلتقط الترددات العالية والمنخفضة . بفرض أن  $C_j$  الإشارة المنفصلة المراد تحليلها وفقا لطريقة التحليل التالية [17] :

$$C_j = LA_{j+1} = HD_{j+1} \quad j = 1,2,3, \dots, J \quad (10)$$

حيث أن :

L : تمثل مرشح التمرير المنخفض Low-pass filter

H : تمثل مرشح التمرير العالى High-pass filter

$A_{j+1}, D_{j+1}$  : تمثل الترددات المنخفضة والترددات العالية للإشارة الأصلية على التوالي .

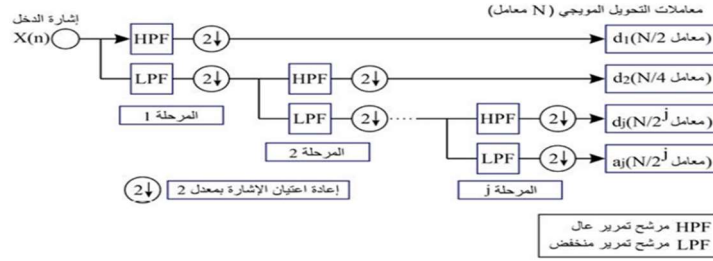
J : تمثل الحد الأقصى للتحليل. أى أن الإشارة المراد تحليلها تتحلل إلى  $d_1, d_2, d_3, \dots, d_j$  and  $a_j$  وتعمل طريقة التحليل هذه على خفض طول بيانات الإشارة إلى النصف بعد التحليل بينما يظل الطول الإجمالى لبيانات المخرجات وبيانات المدخلات للإشارة  $C_j$  ثابت .

**Reconstruction Algorithm** المرحلة الثانية : طريقة إعادة البناء

يمكن إعادة بناء الإشارات المتحللة الناتجة من المرحلة الأولى من خلال طريقة Mallat التي تقوم على تقسيم الإشارة إلى مرشح تمرير منخفض للحصول على معاملات تقريبية والتي تعرف بالمعاملات التدريجية Scaling Coefficient وإلى مرشح تمريرعالى للحصول على معاملات تفصيلية كما فى المعادلة التالية [18]:

$$C_j = L^*A_{j+1} + H^*D_{j+1} \quad j = J - 1, J - 2, \dots, 0 \quad (11)$$





شكل (١) يوضح طريقة مالات

المصدر: (Mallat,1989)

بمعنى آخر يتم تحليل بيانات السلسلة الزمنية لأسعار الذهب العالمية الشهرية من خلال التحويل الموجي المنفصل وإعادة بناءها من خلال طريقة معكوس التحويل الموجي للحصول على البيانات  $Y$  وتشمل تحليل الجزء الخطي  $A_j$  وتحليل الجزء غير الخطي  $D_j$  وتكون على الشكل التالي :

$$Y = A_j + D_j$$

يستخدم نموذج ARIMA للتنبؤ  $A_j$  وتمثل نتيجة التنبؤ  $A_j^*$  ويستخدم نموذج SVR للتنبؤ  $D_j$  وتمثل نتيجة التنبؤ  $D_j^*$ . وجمع تنبؤات نموذج ARIMA ونموذج SVR نحصل على النموذج الهجين SVR-ARIMA بالإعتماد على التحويل الموجي المنفصل  $Y^* = A_j^* + D_j^*$

#### ٨- 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](http://www.indexmundi.com) في الفترة الزمنية من شهر يناير 1991 إلى شهر ديسمبر 2021. ولتقييم أداء النموذج المقترح DWT-ARIMA-SVR تم استخدام مقاييس الخطأ التالية والتي تعتمد على الخطأ بين القيم المقدرة والقيم الفعلية بالإضافة إلى معامل عدم التساوي لثايل [3].

Theil's Inequality Coefficient - معامل عدم التساوى لثايل

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

Mean Square Error (MSE) - متوسط مربعات الخطأ

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

Mean Absolute Error (MAE) - متوسط الخطأ المطلق

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

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

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

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 التساوى 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 الذى يعطى اقل قيمة لمقاييس الخطأ السابقة.

## ٩- الجانب التطبيقي

تم التطبيق على بيانات فعلية خاصة بأسعار الذهب العالمية الشهرية تم الحصول عليها من خلال الموقع الإلكتروني [www.indexmundi.com](http://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 (2020)R(4.0.3) لتحليل بيانات السلسلة الزمنية كما في جدول (٢) التالي :

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

- قبل عملية التقدير لنماذج البحث لابد من إستقرار السلسلة الزمنية في الوسط الحسابي والتباين ومن خلال رسم السلسلة الزمنية لأسعار الذهب العالمية الشهرية إتضح أنها غير مستقرة في الوسط والتباين عبر الزمن كما في شكل (٢) التالي :




شكل (٢) يوضح السلسلة الزمنية لأسعارالذهب العالمية الشهرية

يتضح من الشكل (٢) أن السلسلة الزمنية لأسعار الذهب غير مستقرة لوجود اتجاه عام بالسلسلة أي أنها غير مستقرة في الوسط عبر الزمن كما نلاحظ من الشكل البياني تغير التشتت حول مستوى السلسلة مما يعنى عدم إستقرارها في التباين عبر الزمن . وللتأكد من عدم إستقرار السلسلة تم رسم دالة الارتباط الذاتي ACF ودالة الارتباط الذاتي الجزئي PACF.




شكل (٣) يوضح دالة الارتباط الذاتي للسلسلة الأصلية



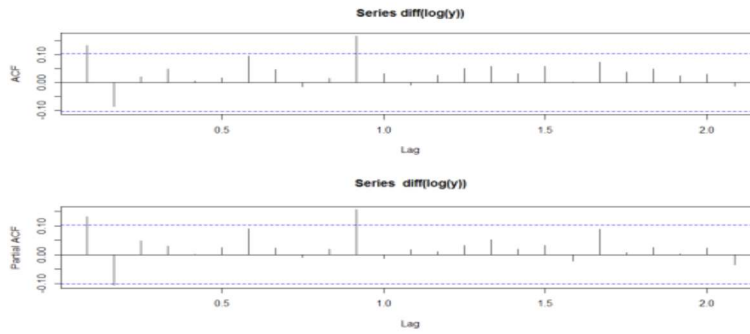
شكل (٤) يوضح دالة الارتباط الذاتي الجزئي للسلسلة الأصلية

نلاحظ من شكل (٣) على وجود تناقص ببطء للدالة مما يدل على عدم إستقرار السلسلة وبالنظر في شكل (٤) نلاحظ عدم إستقرار السلسلة وإستقرار السلسلة الزمنية في الوسط والتباين تم أخذ الفروق الأولى للوغاريتم السلسلة الأصلية ثم رسم السلسلة الزمنية مرة أخرى للتأكد من أن هذه التحويلة مناسبة لإستقرار السلسلة كما في شكل (٥) التالي :



شكل (٥) 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 الذاتي في الشكل (٦) حيث أن أغلب القيم تقع في حدود الثقة .



شكل (٦) يوضح دالتي الارتباط الذاتي والذاتي الجزئي بعد إستقرار السلسلة

بعد إستقرار السلسلة الزمنية تأتي مرحلة التعرف على النموذج من خلال رسم دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) ومن الشكل (٣) والشكل (٤) نلاحظ أن دالة الارتباط الذاتي تتقطع عند الفجوة الزمنية الأولى مما يدل على أن  $q=1$  بينما تتلاشى دالة الارتباط الذاتي الجزئي تدريجياً 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 باستخدام معيار أكايكي المعلوماتي ومعيار بايز المعلوماتي والنموذج الأفضل هو الذي يعطى أقل قيم لمعايير التقييم المذكورة

معايير إختيار النموذج الأفضل هي :

## مقيار أكايكي المعلوماتي (AIC) Akaike Information Criterion

قدم هذا المقيار Hirotugu Akaike عام 1973 والصيغة العامة له على الشكل التالي :

$$AIC(k) = 2l - 2 \ln(\delta_e^2)$$

حيث أن :

$l$ : تمثل عدد معالم النموذج  $\delta_e^2$  : يمثل مقدار تباين الخطأ , والنموذج الذي يعطى أقل قيمة للمقيار يكون هو الأفضل .

## مقيار بايز المعلوماتي (BIC) Bayesian information criterion

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

$$BIC(k) = \ln(n) l - 2 \ln(\delta_e^2)$$

$l$ : تمثل عدد معالم النموذج  $\delta_e^2$  : يمثل مقدار تباين الخطأ  $n$  : تمثل حجم السلسلة الزمنية , والنموذج الذي يعطى أقل قيمة للمقيار يكون هو الأفضل .


## جدول (٣) 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) .


## ١- تقدير نموذج DWT-ARIMA

تم تجزئة السلسلة الزمنية لأسعار الذهب العالمية الشهرية إلى ترددات منخفضة وعالية للحصول على المعاملات التقريبية والتفصيلية باستخدام التحويل الموجي المنفصل وباستخدام الموجة دوبشيز db4 من الرتبة الرابعة ومن خلال برنامج R ووفقا للمعادلة رقم (4) تم الحصول على السلاسل الفرعية كما في شكل (٧) التالي :



شكل (٧) يوضح تجزئة السلسلة الأصلية باستخدام التحويل الموجي المنفصل


شكل (٨) التالي يوضح منحني القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلاسل الفرعية لنموذج DWT-ARIMA من خلال برنامج R ووفقا للمعادلة (6) كالتالي:



شكل (٨) مقارنة القيم المقدرة بالقيم الفعلية  $A_5, D_1, D_2, D_3, D_4, D_5$  لمجموعة الإختبار لنموذج WT-ARIMA



شكل (٩) التالي يوضح منحنى القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلسلة الزمنية الأصلية لنموذج DWT-ARIMA من خلال برنامج R ووفقا للمعادلة (6) كالتالى:



شكل (٩) يوضح منحنى القيم المقدرة والفعلية لنموذج DWT-ARIMA

جدول (٣) التالي يوضح القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلسلة الزمنية لنموذج DWT-ARIMA من خلال برنامج R ووفقا للمعادلة رقم (6) كالتالي :

جدول (٣) يوضح القيم المقدرة والفعلية لنموذج DWT-ARIMA

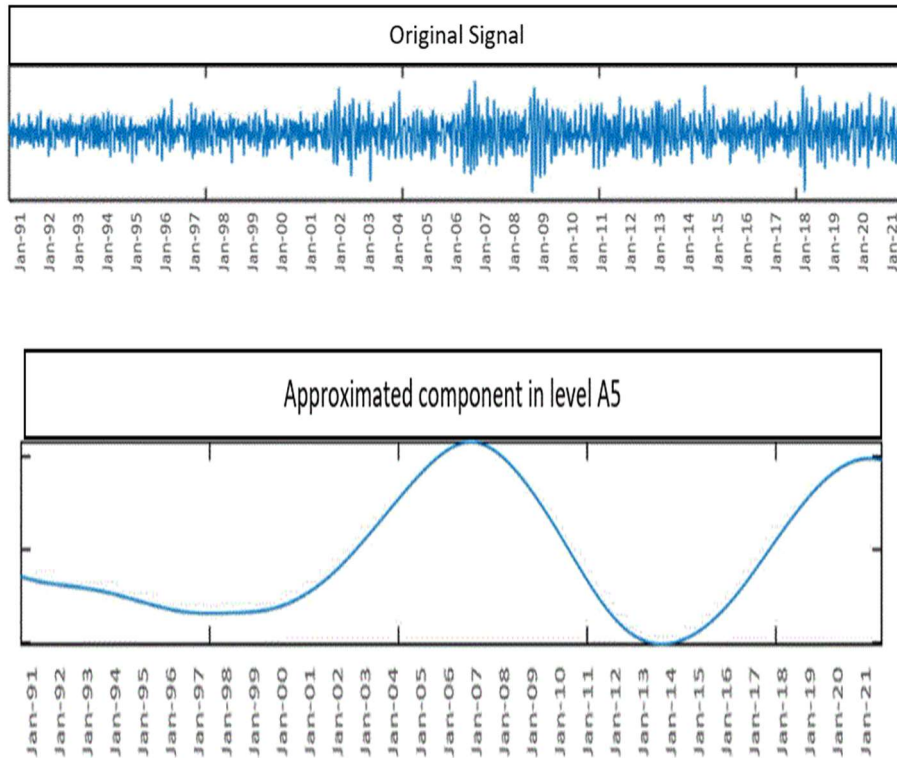
الشهر	السنة	القيم الفعلية	القيم المقدرة
ديسمبر	2018	1250.40	1134.95
يناير	2019	1291.75	1176.30
فبراير	2019	1320.07	1204.62
مارس	2019	1300.90	1185.45
إبريل	2019	1285.91	1170.47
مايو	2019	1283.70	1168.45
يونيو	2019	1359.04	1243.59
يوليو	2019	1412.89	1297.44
أغسطس	2019	1500.41	1394.96
سبتمبر	2019	1510.58	1396.13
أكتوبر	2019	1494.81	1379.36
نوفمبر	2019	1470.79	1366.92
ديسمبر	2019	1479.13	1368.68
يناير	2020	1560.67	1447.52
فبراير	2020	1597.10	1492.85
مارس	2020	1591.93	1479.48

إبريل	2020	1683.17	1568.47
مايو	2020	1715.91	1600.53
يونيو	2020	1732.22	1780.64
يوليو	2020	1846.51	1899.79
أغسطس	2020	1968.63	2016.86
سبتمبر	2020	1921.92	2012.14
أكتوبر	2020	1900.27	1930.41
نوفمبر	2020	1866.30	1912.93
ديسمبر	2020	1858.42	1926.32
يناير	2021	1866.98	1912.55
فبراير	2021	1808.17	1858.62
مارس	2021	1718.23	1914.61
إبريل	2021	1760.04	1923.49
مايو	2021	1850.26	1929.67
يونيو	2021	1834.57	1933.78
يوليو	2021	1807.84	1918.68
أغسطس	2021	1785.28	1882.67
سبتمبر	2021	1775.14	1865.28
أكتوبر	2021	1776.85	1868.07
نوفمبر	2021	1821.76	1918.88
ديسمبر	2021	1819.37	1927.15

بناءً على النتائج المذكورة في الشكل (٩) وجدول (٣) فإن أداء نموذج DWT-ARIMA غير مرضى في التنبؤ بالبيانات الفعلية ولم يكن جيدا في التنبؤ ببيانات أسعار الذهب العالمية الشهرية حيث أن اتجاهات منحنى القيم المقدرة بعيدة بشكل عام من القيم الفعلية كما أن القيم المقدرة لا تتناسب مع القيم الفعلية بشكل جيد .

## ٢- تقدير نموذج DWT-SVR

تم تجزئة سلسلة أسعار الذهب العالمية الشهرية إلى ترددات منخفضة وعالية للحصول على المعاملات التقريبية والتفصيلية باستخدام التحويل الموجي المنفصل وباستخدام الموجة دوبشيز db4 من الرتبة الرابعة ومن خلال برنامج R تم الحصول على السلاسل الفرعية كما في شكل (١٠) التالي :





شكل (١٠) يوضح تجزئة السلسلة الأصلية باستخدام التحويل المويجي المنفصل

شكل (١١) التالي يوضح منحني القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلاسل الفرعية لنموذج DWT-SVR من خلال برنامج R ووفقا للمعادلة (8) كالتالي:




شكل (١١) مقارنة القيم المقدرة بالقيم الفعلية  $A_5, D_1, D_2, D_3, D_4, D_5$  لمجموعة الإختبار لنموذج DWT-SVR

ولتقدير نموذج SVR لابد من إختيار دالة kernel المناسبة أولاً ومن ثم إيجاد المعلمات الخاصة بالدالة المختارة. جدول (٤) التالي يوضح أنواع دوال kernel المختلفة بالإعتماد على متوسط مربعات الخطأ كما يلي:

المقياس	Liner	polynomial	RBF	Sigmoid
MSE	77.56	218.78	180.45	230.55

جدول (٤) يوضح أنواع دوال kernel بالإعتماد على MSE

من الجدول السابق نختار دالة kernel الخطية للتنبؤ بأسعار الذهب العالمية الشهرية لأنها تعطي أقل قيمة لمتوسط مربعات الخطأ ثم نقوم بتقدير المعلمات  $C$ ,  $\epsilon$  ولإيجاد القيم المثلى للمعلمات  $C$ ,  $\epsilon$  لأسعار الذهب العالمية الشهرية تم استخدام منهجية الشبكة والتي تفترض ثبات إحدى المعلمات وتغيير المعلمة الأخرى للحصول على الحد الأدنى MSE من أجل تحديد دالة kernel المناسبة حيث يتم وضع قيمة إفتراضية  $\epsilon$  والتي تمثل دالة الخسارة لإيجاد قيمة  $C$  والتي تمثل معلمة التنظيم وتكون هذه المنهجية على الشكل (١٢) التالي :



المصدر : (Baydaroglu, et al, 2018)

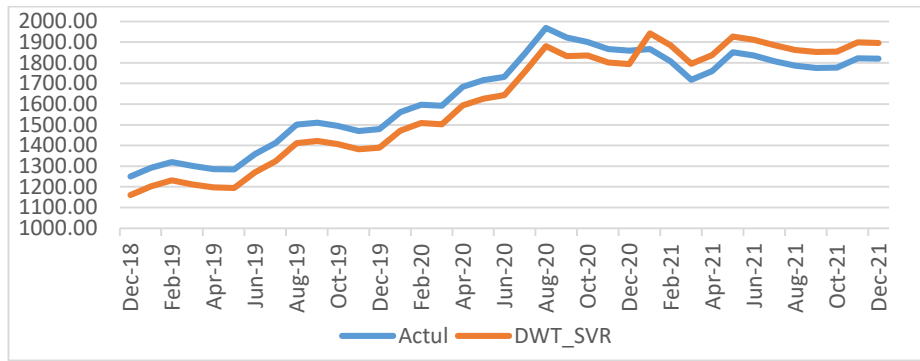
شكل (١٢) يوضح الخطوات التجريبية لنموذج SVR

حيث يتم تخفيض تعقيد النموذج باستخدام دالة الخسارة غير الحساسة ل  $\varepsilon$  عبر تصغير  $\|w\|^2$  لذا يتم إدخال متغيرات راكدة Slack Variables تكون غير سالبة  $\zeta_i, \zeta_i^* \geq 0, i = 1, 2, 3, \dots, n$  لقياس إنحراف مجموعة التدريب خارج المنطقة المحددة ب  $\varepsilon$  وتكون على الصيغة التالية (Sedighi, et al.2019):

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

حيث أن  $C$ : تمثل معلمة التنظيم  $C > 0$  ولها مسميات أخرى حيث تعرف بمعلمة الجزاء التي تحدد الموازنة بين المخاطر التجريبية وتعقيد النموذج. وتمريبات التدريب بعدد من الإختبارات التجريبية بغرض الحصول على قيم المعلمات حيث تم وضع قيم إفتراضية  $\varepsilon$  وحساب قيمة  $C$  المقابلة بالإعتماد على متوسط مربعات الخطأ وبعد عدد من الجولات التجريبية تم الحصول على  $C = 100$  عند وضع قيمة إفتراضية  $\varepsilon = 0.1$  كأفضل الإختيارات للبيانات التجريبية لأنها تعطي أقل قيمة لمتوسط مربعات الخطأ وتم إستخدام المعلمات لتدريب النموذج مرة أخرى ثم التنبؤ بمجموعة الإختبار.

شكل (١٣) التالي يوضح منحنى القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلسلة الزمنية الأصلية لنموذج DWT-SVR من خلال برنامج R ووفقا للمعادلة (8) كالتالى:



شكل (١٣) يوضح منحنى القيم المقدرة والفعلية لنموذج DWT-SVR



جدول (٥) التالي يوضح القيم الفعلية والقيم المقدرة لأسعار الذهب العالمية الشهرية حتى نهاية عام 2021 بواقع 37 مشاهدة والتي تمثل مجموعة إختبار السلسلة الزمنية لنموذج DWT-SVR من خلال برنامج R ووفقا للمعادلة رقم (8) كالتالي :

جدول (٥) يوضح القيم المقدرة والفعلية لنموذج DWT-SVR

الشهر	السنة	القيم الفعلية	القيم المقدرة
ديسمبر	2018	1250.40	1161.40
يناير	2019	1291.75	1202.75
فبراير	2019	1320.07	1231.07
مارس	2019	1300.90	1211.90
إبريل	2019	1285.91	1196.91
مايو	2019	1283.70	1194.70
يونيو	2019	1359.04	1270.04
يوليو	2019	1412.89	1323.89
أغسطس	2019	1500.41	1411.41
سبتمبر	2019	1510.58	1421.58
أكتوبر	2019	1494.81	1405.81
نوفمبر	2019	1470.79	1381.92
ديسمبر	2019	1479.13	1390.13
يناير	2020	1560.67	1471.67
فبراير	2020	1597.10	1508.10
مارس	2020	1591.93	1502.93

إبريل	2020	1683.17	1594.17
مايو	2020	1715.91	1626.91
يونيو	2020	1732.22	1643.22
يوليو	2020	1846.51	1757.51
أغسطس	2020	1968.63	1879.63
سبتمبر	2020	1921.92	1832.92
أكتوبر	2020	1900.27	1835.27
نوفمبر	2020	1866.30	1801.30
ديسمبر	2020	1858.42	1793.42
يناير	2021	1866.98	1943.52
فبراير	2021	1808.17	1884.71
مارس	2021	1718.23	1794.77
إبريل	2021	1760.04	1836.58
مايو	2021	1850.26	1926.40
يونيو	2021	1834.57	1911.11
يوليو	2021	1807.84	1884.38
أغسطس	2021	1785.28	1861.87
سبتمبر	2021	1775.14	1851.68
أكتوبر	2021	1776.85	1853.39
نوفمبر	2021	1821.76	1898.30
ديسمبر	2021	1819.37	1895.88

بناءً على النتائج المذكورة في الشكل (١٣) وجدول (٥) تكون اتجاهات منحنى القيم المقدره قريبة إلى حد ما من القيم الفعلية كما أن القيم المقدره تتناسب مع القيم الفعلية بشكل مناسب وبالتالي فإن نموذج DWT-SVR أفضل من نموذج DWT-ARIMA من حيث النتائج .

### ٣- تقدير النموذج الهجين DWT-ARIMA-SVR

بعد التحليل المسبق لبيانات السلسلة الزمنية باستخدام التحويل الموجي المنفصل يتم تقدير الجزء الخطي للبيانات من خلال نموذج ARIMA وتقدير الجزء غير الخطي من بيانات السلسلة الزمنية من خلال نموذج SVR . يوضح شكل (١٤) التالي منحنى القيم المقدره والفعلية للنموذج الهجين بالإعتماد على DWT وفقاً للمعادلة (11) كما يلي :



شكل (١٤) يوضح منحنى القيم المقدره والفعلية لنموذج ARIMA-SVR بالإعتماد على DWT

كما يوضح جدول (٦) القيم الفعلية والقيم المقدره لأسعار الذهب العالمية الشهرية للنموذج الهجين بالإعتماد على التحويل الموجي المنفصل حتى نهاية عام 2021 بواقع 37 والتي تمثل مجموعة إختبار السلسلة الزمنية من خلال برنامج R ووفقاً للمعادلة رقم (11) كالتالي :

الشهر	السنة	القيم الفعلية	القيم المقدرة
ديسمبر	2018	1250.40	1180.40
يناير	2019	1291.75	1241.75
فبراير	2019	1320.07	1270.07
مارس	2019	1300.90	1250.90
إبريل	2019	1285.91	1265.91
مايو	2019	1283.70	1233.70
يونيو	2019	1359.04	1309.04
يوليو	2019	1412.89	1362.89
أغسطس	2019	1500.41	1450.41
سبتمبر	2019	1510.58	1460.58
أكتوبر	2019	1494.81	1444.81
نوفمبر	2019	1470.79	1420.79
ديسمبر	2019	1479.13	1429.13
يناير	2020	1560.67	1510.67
فبراير	2020	1597.10	1547.10
مارس	2020	1591.93	1541.93
إبريل	2020	1683.17	1633.17
مايو	2020	1715.91	1665.91
يونيو	2020	1732.22	1697.22

يوليو	2020	1846.51	1811.51
أغسطس	2020	1968.63	1933.63
سبتمبر	2020	1921.92	1886.92
أكتوبر	2020	1900.27	1865.27
نوفمبر	2020	1866.30	1831.30
ديسمبر	2020	1858.42	1823.42
يناير	2021	1866.98	1831.98
فبراير	2021	1808.17	1773.17
مارس	2021	1718.23	1689.23
إبريل	2021	1760.04	1725.05
مايو	2021	1850.26	1815.40
يونيو	2021	1834.57	1799.57
يوليو	2021	1807.84	1772.84
أغسطس	2021	1785.28	1750.28
سبتمبر	2021	1775.14	1740.14
أكتوبر	2021	1776.85	1741.85
نوفمبر	2021	1821.76	1786.76
ديسمبر	2021	1819.37	1784.34

جدول (٦) يوضح القيم المقدرة والفعلية لنموذج ARIMA-SVR بالإعتماد على DWT

بناءً على النتائج المذكورة في الشكل (١٤) وجدول (٦) تكون اتجاهات منحنى القيم المقدره قريبة بشكل عام من القيم الفعلية كما أن القيم المقدره تتناسب مع القيم الفعلية بشكل جيد حيث يظهر النموذج الهجين ARIMA-SVR بالإعتماد على التحويل الموجى المنفصل DWT أداءاً أفضل من النموذج DWT-SVR فى التنبؤ بأسعارالذهب العالمية الشهرية

#### ٤- المقارنة بين نماذج البحث

يوضح جدول (٧) التالى مقاييس دقة التنبؤ الخاصة بنماذج البحث

Model	MSE	MAE	MAPE	Theil's Inequality Coefficient
DWT-ARIMA	2967.90	43.71	2.64	0.43
DWT-SVR	2864.86	40.36	2.36	0.25
DWT-ARIMA-SVR	2365.56	26.64	1.43	0.03

جدول (٧) يوضح مقاييس دقة التنبؤ لنماذج البحث

من الجدول السابق نستنتج ما يلى :

- ١- التنبؤ بأسعار الذهب العالمية الشهرية باستخدام نموذج DWT-SVR أكثر كفاءة من نموذج DWT-ARIMA حيث يعطى أداء أفضل فى التنبؤ بأخطاء قليلة .
- ٢- أظهر نموذج DWT-ARIMA أداءا ضعيفا فى التنبؤ مع وجود أخطاء كبيرة مقارنة بنموذج DWT-SVR .
- ٣- التنبؤ بأسعار الذهب العالمية الشهرية باستخدام النموذج الهجين ARIMA-SVR بالإعتماد على DWT أكثر كفاءة من نموذجي DWT-ARIMA, DWT-SVR حيث يعطى أداء أفضل فى التنبؤ بأخطاء قليلة .

### الإستنتاجات

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

- ١- أن سلسلة أسعار الذهب العالمية الشهرية سلسلة غير مستقرة فى التباين ويوجد بها إتجاه عام وذلك من خلال الرسم البيانى 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- من خلال المقارنة بين نماذج التنبؤ الثلاث الذي 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  $ARIMA-SVR$  بالإعتماد على  $DWT$  لإمتلاكه أقل القيم لمقاييس دقة التنبؤ.
- يلى النموذج الهجين فى الكفاءة فى التنبؤ نموذج  $DWT-SVR$  وكان أقل النماذج والذي أظهر أداءا ضعيفا فى التنبؤ هو نموذج  $DWT-ARIMA$ .



## المراجع

1. Aladağ, E. (2021). “Forecasting of particulate matter with a hybrid ARIMA model based on wavelet transformation and seasonal adjustment”. *Urban Climate*, 39, 100930.
2. Baydaroğlu, Ö., Koçak, K., and Duran, K. (2018). “River flow prediction using hybrid models of support vector regression with the wavelet transform, singular spectrum analysis and chaotic approach”. *Meteorology and Atmospheric Physics*, 130, 349-359.
3. Bleikh, H. Y., and Young, W. L. (2014). “*Time Series Analysis and Adjustment: Measuring, Modelling and Forecasting for Business and Economics*”. Gower.
4. Box, G. E., Jenkins, G. M. (1976). “*Time series analysis: forecasting and control*”. Holden day, London.
5. Chun-Lin, L. (2010). “A tutorial of the wavelet transform”. *NTUEE, Taiwan*, 21, 22.

6. Co, J., Tan, J. A., Estuar, R. J., and Espina, K. (2017).“ Dengue Spread Modeling in the Absence of Sufficient Epidemiological Parameters: Comparison of SARIMA and SVM Time Series Models”. *Proceedings of the RAIS Conference: The Future of Ethics, Education and Research*.
7. Daubechies, I. (1992).“ *Ten lectures on wavelets*”. Society for industrial and applied mathematics.
8. Debdas, S., Jagrit, V., Chandrakar, C., and Quereshi, M. F. (2011).“ Application of wavelet transform for speech processing”. *International Journal of Engineering Science and Technology (IJEST)*, 3(8), 6666-6670.
9. Deka, P. C., Haque, L., and Banhatti, A. G. (2012). “Discrete wavelet-Ann approach in time series flow forecasting-a case study of Brahmaputra river”. *International Journal of Earth Sciences and Engineering* 5 (4), 673-685.

10. Gao, R. X., and Yan, R. (2010). “*Wavelets: Theory and applications for manufacturing*”. Springer Science and Business Media.
11. Ghorbani, M., Zargar, G., and Jazayeri-Rad, H. (2016). “Prediction of asphaltene precipitation using support vector regression tuned with genetic algorithms”. *Petroleum*, 2(3), 301-306.
12. Fang, C., Gao, Y., and Ruan, Y. (2019). “Improving forecasting accuracy of daily energy consumption of office building using time series analysis based on wavelet transform decomposition”. In *IOP Conference Series: Earth and Environmental Science* (Vol. 294, No. 1, p. 012031). IOP Publishing.
13. Jaber, J. J., Ismail, N. O., Ramli, S. I., Al Wadi, S., and Boughaci, D. A. (2020). “Assessment of credit losses based on ARIMA-wavelet method”. *Journal of Theoretical and Applied Information Technology*, 98(09), 1379-392.

14. Joseph, I., Imoize, A. L., Ojo, S., and Risi, I. (2022). “Optimal Call Failure Rates Modelling with Joint Support Vector Machine and Discrete Wavelet Transform”.
15. Kambalimath S, S., and Deka, P. C. (2021). “Performance enhancement of SVM model using discrete wavelet transform for daily streamflow forecasting”. *Environmental Earth Sciences*, 80(3), 1-16.
16. Liu, Y., Ji, Y., Chen, K., and Qi, X. (2019). “Support Vector Regression for Bus Travel Time Prediction Using Wavelet Transform”. *J. Harbin Inst. Technol. (New Ser.)*, 26(03), 26-34.
17. Mallat, S. G. (1989). “A theory for multiresolution signal decomposition: the wavelet representation ”. *IEEE transactions on pattern analysis and machine intelligence*, 11(7), 674-693.
18. Niu, C., and Ji, L. (2012). “ A hybrid method based on wavelet analysis for short term load forecasting”. *Journal of Convergence Information Technology* 7 (17), 540-547.

19. Panapakidis, I. P., Christoforidis, G. C., Asimopoulos, N., and Dagoumas, A. S. (2017). "Combining wavelet transform and support vector regression model for day-ahead peak load forecasting in the Greek power system". In *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)* (pp. 1-6). IEEE.
20. Percival, D. B., and Walden, A. T. (2000). "*Wavelet methods for time series analysis*" Vol. 4. Cambridge university press.
21. SAHED, A., Mekidiche, M., and Kahoui, H. (2023). "Forecasting of CO2 Emissions in Algeria Using Discrete Wavelet Transform–Based Autoregressive Integrated Moving Average Models".
22. Salazar, L., Nicolis, O., Ruggeri, F., Kisel'ák, J., and Stehlík, M. (2019). "Predicting hourly ozone concentrations using wavelets and ARIMA models". *Neural Computing and Applications*, 31(8), 4331-4340.

23. Singh, S., Parmar, K. S., Kumar, J., and Makkhan, S. J. S. (2020). "Development of new hybrid model of discrete wavelet decomposition and autoregressive integrated moving average (ARIMA) models in application to one month forecast the casualties cases of COVID-19". *Chaos, Solitons and Fractals*, 135, 109866.
24. Thanh Noi, 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.
25. Zhang, G. P. (2003). "Time series forecasting using a hybrid ARIMA and neural network model". *Neurocomputing*, 50, 159-175.