

التنبؤ بسلسلة اسعار الذهب العالمية باستخدام نوعين من نماذج الشبكة العصبية الاصطناعية LSTM و GRU

Predicting the global gold price series using two types of artificial neural network models LSTM and GRU

حلا كامل جواد²Hala kamel Jawad²

جامعة القادسية، كلية الإدارة والاقتصاد، قسم الإحصاء

 University of Al-Qadisiyah, Faculty of
 Management And Economics,
 Department of Statistics Graduate Studies
statistics.stp.24.6@qu.edu.iq

07819887740

أ.د. محمد حبيب الشاروط¹Prof. Dr. Mohammed Habib Alsharoot¹

جامعة القادسية، كلية الإدارة والاقتصاد، قسم الإحصاء

 University of Al-Qadisiyah, Faculty of
 Management And Economics, Department
 of Statistics Graduate Studies
Mohammed.alsharoot@qu.edu.iq

المستخلص:

يهدف هذا البحث الى مقارنة تنبؤ سلسلة اسعار الذهب العالمية باستخدام نماذج الشبكة العصبية الاصطناعية بانموذج شبكات الذاكرة الطويلة (LSTM) (Long Short Term Memory networks) وانموذج وحدة البوابة المتكررة (GRU) (Gated Recurrent Unit) حيث تم استخدام سلسلة زمنية يومية عن الاسعار العالمية للذهب والممتدة من تاريخ 1968/10/22 ولغاية 2024/3/13 وقد اظهرت نتائج التحليل والمقارنة باستخدام بعض من معايير الدقة ان افضل نموذج للتنبؤ باستخدام نماذج الشبكة العصبية الاصطناعية هو انموذج التنبؤ بشبكات الذاكرة الطويلة (LSTM).

الكلمات المفتاحية: تنبؤ، تجانس التباين، الشبكة العصبية ذات الذاكرة طويلة المدى LSTM، اسعار الذهب، انموذج الشبكة العصبية GRU

Abstract:

This research aims to compare the prediction of the global gold price series using artificial neural network models with the Long Short Term Memory Networks (LSTM) model and the Gate Recurring Unit (GRU) model. (Gated Recurrent Unit) A daily time series of global gold prices was used, extending from 10/22/1968 to 3/13/2024. The results of analysis and comparison using some accuracy standards showed that the best model for prediction using artificial neural network models is the long-term memory network prediction model (LSTM).

Keywords: Prediction , variance Hetrokadastisity, LSTM neural network, gold prices,

1- المقدمة (Introduction)

يُعدُّ تحليل السلاسل الزمنية من المواضيع الإحصائية المهمة حيث تتناول سلوك الظواهر وتفسيرها عبر فترات زمنية محددة ، من خلال وصف عام للسلسلة الزمنية وبناء أنموذج لتفسير سلوكها ؛ لغرض التنبؤ بالأعتماد على الأساليب الإحصائية والرياضية مثل أنموذج بوكس – جنكينز ونماذج التمهيد الآسي وغيرها . [13]
 وقد تزايد الاهتمام بموضوع التنبؤ خلال السنوات الأخيرة وظهرت أساليب حديثة خاصة ، ومنها الشبكات العصبية الاصطناعية (ANNs) . أن الفكرة الأساسية لأسلوب الشبكات العصبية الاصطناعية هو إنشاء أنموذج يحاكي النظام البيولوجي العصبي ، مثل الدماغ لمعالجة المعلومات، إن المفتاح الأساس لهذا الأنموذج هو بناء هيكل جديد لنظام معالجة المعلومات الذي يقوم بربط وتنظيم العديد من عناصر المعالجة المرتبطة مع بعضها والتي تعمل بشكل متناسق لحل المشكلة. والشبكات العصبية الاصطناعية (ANNs) تتدرب بطريقة تشابه تعلم الإنسان من خلال الأمثلة والتدريب ، والتعلم في النظام البيولوجي يستخدم تكييف نقاط الاشتباك العصبي بين العصبونات ، وهذه هي الفكرة الجوهرية في عمل الشبكات العصبية ، لذلك تعد الشبكات العصبية الاصطناعية ذكاءاً من صنع أو ابتكار الإنسان يتم الحصول عليه من خلال إعطاء

الحاسوب القدرة البرمجية على التعلم والتعامل مع أنماط لبيانات خاصة في العديد من المجالات التطبيقية ومعالجة هذه البيانات لإغراض التحليل ، أو التصنيف ، أو التنبؤ ، وأتخاذ قدم نتائج محسنة مقارنة باستعمال انموذج GARCH ونموذج الشبكات العصبية الاصطناعية بمعزل عن بعضها البعض.

2- مشكلة البحث:


يفترض في التحليل القياسي التقليدي ان الحد العشوائي ثابتاً عبر الزمن او ما يعرف بفرضية ثبات التباين (Homoskedasticity assumption)، ولكن في البيانات المالية وبعض البيانات الاقتصادية غالباً لا يتحقق هذا الشرط حيث يظهر تباين وتقلب مختلف في فترات السلسلة الزمنية ، وهذا يعني ان القيم المتوقعة لحد الخطأ العشوائي ستكون اكبر او اقل عبر الفترات المختلفة. ولغرض معالجة ذلك كان لابد من استعمال نماذج احصائية تأخذ بعين الاعتبار هذه التقلبات و تحاول تفسيرها و من هذه النماذج ، نماذج الشبكة العصبية الاصطناعية (Artificial Neural Network) LSTM و GRU

3- هدف البحث:

مقارنة تنبؤ سلسلة اسعار الذهب العالمية باستخدام نماذج الشبكة العصبية الاصطناعية بانموذج شبكات الذاكرة الطويلة (Long Short Term Memory networks) (LSTM) و انموذج وحدة البوابة المتكررة (Gated Recurrent Unit) (GRU) (Unit)

4- الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANNs))

يشير مصطلح الشبكة العصبية الاصطناعية الى مجال فرعي مستوحى بيولوجياً من الذكاء الاصطناعي على غرار الدماغ . وعادةً ما تكون شبكة حسابية تعتمد على الشبكات العصبية البيولوجية التي تبني بنية الدماغ البشري . كما هو الحال في الدماغ البشري الذي يحتوي على خلايا عصبية مترابطة مع بعضها البعض ، تحتوي الشبكات العصبية الاصطناعية ايضاً على خلايا عصبية مترابطة ببعضها البعض في طبقات مختلفة من الشبكات . وتعرف هذه الخلايا العصبية بالعقد [4] والشكل (1) يبين مخطط شبكة الخلية العصبية الاصطناعية



شكل (1) مخطط شبكة الخلية العصبية الاصطناعية [10]

1-4 معمارية الشبكة العصبية (Artificial Neural Network Structure) : يقصد بمعمارية الشبكة العصبية الاصطناعية هيكلها او بنائها و هو ترتيب العقد في المستويات او الطبقات وآلية الترابط ضمن الطبقات او فيما بينها ، وتعد من اهم خصائص الشبكة العصبية والتي تبني على اساسها. وتصنف الشبكات بحسب عدد مستوياتها (طبقاتها) الى صنفين رئيسيين [19] :

- 1- شبكات وحيدة المستوى او الطبقة (Single –level or Layer) : وهي لا تمتلك طبقة (مستوى) مخفية .
- 2- شبكات متعددة المستويات (الطبقات) (Multi – level or Layer) : لها مستوى (طبقة) مخفي واحد او اكثر و هي نوعان ايضاً شبكة امامية التغذية (Feed Forward N) و شبكة عكسية التغذية (Feed Backward N).

وبشكل عام ، فان معمارية الشبكة العصبية الاصطناعية الإنموزجية مكونة من ثلاث مستويات (طبقات) هي:

- 1- مستوى (طبقة) الإدخال (Input level (layer) : هو المستوى الاول في الشبكة العصبية يحتوي على عدد من العقد تمثل عدد المتغيرات المستقلة (الإدخالات).
- 2- المستوى (الطبقة) المخفي (Hidden Level) : وهو المستوى الاوسط الذي يقع بين المستوى الاول (الإدخال) والمستوي الأخير (الإخراج) ، فهو يلي المستوى الاول .
- 3- مستوى (طبقة) الإخراج (Output Level): وهو المستوى الأخير في الشبكة العصبية الاصطناعية الذي يمثل الاخراجات الشبكة العصبية .

ويتكون كل مستوى من المستويات الثلاثة اعلاه من :

- أ- العقد او الخلايا (Nodes) : تشكل نقاط الترابط العصبي بين مستويات (طبقات) الشبكة العصبية .
- ب- المستوى (Level) : يمثل مجموعة العقد او الخلايا التي تستلم الإدخال ولها اخراج .
- ت- الأوزان (Weights) : تشير الأوزان الى مدى قوة الارتباط العصبي بين مستويات (طبقات) الشبكة العصبية فكل عقدة (خلية) وزن يربطها مع المستوى السابق ، و وزن يربطها مع المستوى اللاحق . ان القيم الأولية للأوزان (Initial Weightd) في بداية تدريب الشبكة (Network Training) قيم عديدة عشوائية يتم توليدها من توزيعات احصائية.

وفي الشبكة العصبية ثلاث طبقات من الأوزان هي :

- 1- طبقة اوزان مستوى الإدخال والمستوى المخفي (Input to Hidden Weights)
- 2- طبقة اوزان بين المستويات المخفية (Hidden Weights)
- 3- طبقة اوزان المستوى المخفي ومستوى الإخراج (Hidden to Output Weights)

في كل عصبون، يتم حساب الناتج (output) كحاصل ضرب داخلي لمتجه الأوزان W و متجه الإدخال X متبوعاً بتطبيق دالة التفعيل (activation function) بحيث ان الانموذج الرياضي للشبكة العصبية كالآتي : [2]

$$Net = \underline{W} \underline{X} = \sum_{i=1}^n w_i x_i \quad \dots (5)$$

حيث ان $\underline{W}$: متجه الأوزان الذي يضم مجموعة الأوزان $W = [w_1, w_2, \dots, w_n]$, وهو متجه يحتوي على مجموعة من الأوزان التي يتم تعديلها خلال عملية التدريب لتقليل الخطأ. يمثل كل وزن قوة الربط بين عنصر الإدخال والعصبون. وان w_i هو الوزن المقابل للـ x_i : متجه الإدخال الذي يضم مجموعة الإدخال وهي $x_1, x_2, \dots, x_n$, و متجه يحتوي على مجموعة القيم المدخلة التي تُغذى إلى العصبونات في الشبكة العصبية. بعد حساب الناتج، يتم تمريره عبر دالة تفعيل لتحويله إلى ناتج مناسب. على سبيل المثال، يمكن استخدام دالة التفعيل السينية (sigmoid function) أو دالة التفعيل ReLU (Rectified Linear Unit). بهذا الشكل، يمكن تمثيل الشبكة العصبية الاصطناعية كعملية حسابية يتم فيها تعديل الأوزان لتقليل الخطأ وتحسين دقة التوقعات.

2-4 معالجة المعلومات في الشبكة العصبية (Information Process in Neural Network): ان الشبكات العصبية الاصطناعية نوعان هما الشبكات الثابتة (Fixed) وهي التي لا تتغير اوزانها عند التدريب او التعلم ، والشبكات المكيفة (Adaptive Nets) والتي لها قابلية على تغيير اوزانها . ويقصد بمعالجة المعلومات في الشبكات العصبية مرور البيانات في الشبكات العصبية المكيفة بمرحلتين اساسيتين هما : [1]

اولاً: مرحلة التدريب او التعلم : (Training or Learning)

يعرف التعلم عموماً على انه تغير دائم ومستمر نسبياً في السلوك الذي يحدث بواسطة التجربة والاختبار . والتعلم في الشبكات العصبية هو تطبيق معطى لعمليات (الإدخال – الإخراج) من خلال مجموعة من الأمثلة ، ويكون التعلم ضرورة ملحة عندما يكون هناك نقص في فهم العلاقة بين الإدخال والإخراج بحيث تكون صعبة الوصف . وخلال هذه المرحلة تنتج معلومات (بيانات) جديدة في الشبكة نتيجة لتغير الوزن (Weights) للشبكة .

1- التدريب بإشراف (Supervised Training): وهو تدريب بإرشاد وعادة ما يستخدم في الشبكات التغذية الامامية (Feed Forward Network) ويتطلب وجود زوج من متجه الإدخال (Input) و متجه الإخراج المتوقع (Target Output) والتي تمثل زوج التدريب ، تدرب الشبكة العصبية على عدد من هذه الأزواج ويقارن الإخراج (Output) لمتجه الإدخال المطبق مع متجه الإخراج المتوقع والاختلاف بينهما يمثل خطأ التدريب (Training Error) يرجع خلال الشبكة كي تتغير الأوزان طبقاً للخوارزمية باتجاه تقليل الخطأ . تطبق جميع متجهات مجموعة التدريب وتتغير الأوزان و يحسب الخطأ الى ان يصل لمجموعة التدريب المدخلة الى اقل خطأ تدريب (Minimum Training Error) باستخدام احدى طرائق الشائعة في اقلال الخطأ و هي مربعات المتوسطات الصغرى التقاربية (LMS) وبالنسبة لحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب او التعلم ، و هذا هو الهدف من التدريب الشبكة العصبية الاصطناعية . [18]

2- التدريب بدون اشراف (Unsupervised Training): هذا النوع من التدريب لا يستخدم المعلم الخارجي ويكون الاعتماد فقط على المعلومات الموقعية ، ويشار الى هذا النوع من التدريب بشبكات التنظيم الذاتي (Self Organizing) اي تنظيم البيانات التي تقدم الى الشبكة ذاتياً . في هذا التدريب تمتلك الشبكة العصبية بعض المعلومات خلال التدريب اي لها ادخالات فقط وليس لها معرفة عما سيكون عليه الجواب الصحيح ولا تعرف ما هو الإخراج المطلوب اي عدم وجود (Desired Output) للشبكة يقارن مع النتائج . اكتشف هذا التدريب الباحث كوين واخرون

، تتألف فيه مجموعة التدريب من متجه الإدخال وخوارزمية التدريب لتغيير أوزان الشبكة لإنتاج متجه الإخراج الثابت ، يطبق الإدخال لإنتاج الإخراج المحدد .

ثانياً : **مرحلة العمل (الاسترجاع)** : وهي المرحلة الثانية لمعالجة معلومات (بيانات) الشبكة العصبية الاصطناعية ، وفيها يطبق الإدخال المعطى مع الأوزان الناتجة من المرحلة الأولى (مرحلة التدريب) وبخطوة واحدة نحصل على الإخراج المطلوب (Desired Output) . وهي تغذية أمامية فقط (Feed Forward) ، حيث تكون العصبونات مرتبطة مع الطبقات مما يؤدي إلى انسيابية البيانات باتجاه واحد فقط ، أي أن كل عصبون يستلم المعلومات فقط من العصبونات من الطبقة السابقة ، والإدخال لكل عصبون يمثل الإخراج الموزون للعصبونات في الطبقة السابقة .

4-3 أنواع الشبكات العصبية الاصطناعية (Types of Neural Network) : تقسم الشبكات العصبية إلى نوعين هما: [15]

1. **شبكات عصبية ثابتة (Static Network)** : وهي الشبكات التي ليس لها عنصر تغذية عكسية (Feedback) ولا تمتلك تخلفاً زمنياً (Delay Time) أي أن مخرجاتها تحتسب مباشرة من المدخلات مروراً باتصالات التغذية الأمامية

2. **الشبكات الحركية (Dynamic Network)** : فهي تحتوي على الأقل طبقة واحدة ذات تغذية عكسية ، ففي هذا النوع من الشبكات فإن المخرجات الحالية لا تعتمد فقط على المدخلات الحالية للشبكة وإنما تعتمد أيضاً على المدخلات والمخرجات السابقة ، ومن ثم فإن الإشارة في هذا النمط من الشبكات العصبية تنتج أماماً أي نحو الإخراج وايضاً بالاتجاه العكسي لتكون ادخالاً في الوقت ذاته ويطلق عليها بالشبكات الحركية (الديناميكية) ، إذ أنها تمتلك ذاكرة

5 - شبكات الذاكرة طويلة المدى (Long Short Term Memory Networks LSTM)

تعد شبكات الذاكرة قصيرة المدى (LSTM) نوعاً من بنية الشبكات العصبية المتكررة (RNN) التي قدمت من قبل (Hochreiter & Schmidhuber, 1997) لتكون قادرة على تعلم التبعيات طويلة المدى، مما يجعلها مفيدة بشكل خاص للمهام التي تتضمن بيانات متسلسلة، مثل التنبؤ بالسلاسل الزمنية، ومعالجة اللغة الطبيعية، والتعرف على الكلام. ، وتم تنقيحها ونشرها من قبل العديد من الأشخاص في متابعة العمل. [14] وهي أداة قوية لنمذجة البيانات التسلسلية، وهي قادرة على تعلم التبعيات طويلة المدى والتي تعتبر ضرورية للعديد من تطبيقات العالم الحقيقي. [17]

5-1 مكونات شبكات LSTM: تتكون شبكة الذاكرة طويلة المدى مما يأتي: [3]

- **حالة الخلية (Cell State)** : تمر حالة الخلية عبر سلسلة LSTM بأكملها، مع بعض التفاعلات الخطية البسيطة فقط، مما يسمح بتدفق المعلومات دون تغيير. وتعد المفاتيح لقدرة LSTMs على تذكر المعلومات طويلة المدى.
- **البوابات (Gates)** : وتتألف مما يأتي:

✓ **بوابة النسيان (Forget Gate)**: تقرر المعلومات التي سيتم تجاهلها من حالة الخلية. يأخذ الحالة المخفية السابقة والمدخلات الحالية ويخرج رقمًا بين 0 و 1 لكل رقم في حالة الخلية C_{t-1} إذ يعني الرقم 1 "احتفظ بهذا تمامًا" ويعني الرقم 0 "انس هذا تمامًا"

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad \dots (6)$$

✓ **بوابة الإدخال (Input Gate)**: تقرر المعلومات الجديدة التي سيتم تخزينها في حالة الخلية. وتتكون من جزأين: طبقة بوابة الإدخال، التي تقرر القيم التي سيتم تحديثها، وطبقة تنشئ متجهًا للقيم المرشحة الجديدة

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \dots (7)$$

$$C_t = \tanh(f_o)(W_c \cdot [h_{t-1}, x_t] + b_c) \quad \dots (8)$$

✓ **بوابة الإخراج (Output Gate)** : تقرر ما هي الحالة المخفية التالية. تُستخدم هذه الحالة أيضًا للتنبؤات. يقوم بتصفية حالة الخلية.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \dots (9)$$

✓ **تحديث حالة الخلية (Cell State Update)**: يتم تحديث حالة الخلية بالمعلومات الجديدة التي تحددها بوابة الإدخال وبوابة النسيان.

$$C_t = f_t * C_{t-1} + i_t * C_t \quad \dots (11)$$


✓ تحديث الحالة المخفية (Hidden State Updat) : يتم تحديث الحالة المخفية باستخدام حالة الخلية المحدثة وبوابة الإخراج.

$$h_t = o_t * \tanh(C_t)$$



... (12)

5-1-2 كيفية عمل شبكات LSTM [14]


- 1- التهيئة (Initialization) : ابدأ بحالة الخلية C_0 والحالة الخفية h_0
- 2- التمريرة الأمامية (Forward Pass) : لكل خطوة زمنية t ، وحساب بوابات النسيان والإدخال والإخراج، وتحديث حالة الخلية، وحساب الحالة المخفية باستخدام خطوة الإدخال في ذلك الوقت x_t والحالة الخفية السابقة h_t
- 1- الإخراج (Output) : إخراج شبكة LSTM في خطوة زمنية t يمكن أن تكون الحالة المخفية h_t أو نسخة معدلة منه، حسب المهمة المحددة.



شكل (2) شبكة عصبية ذات ذاكرة طويلة المدى



شكل (3) خلية الذاكرة طويلة المدى (LSTM) خلال معالجة البيانات بشكل تسلسلي والحفاظ على حالتها المخفية عبر الزمن



شكل (4) معمارية شبكة الذاكرة طويلة المدى (LSTM) [16]

6-1 شبكات الوحدات المتكررة المبوبة العصبية (Gate Recurrent Unit networks RGU)

شبكة الوحدة المتكررة المبوبة (GRU) (Gate Recurrent Unit) هي نوع من أنواع الشبكات العصبية المتكررة (Recurrent Neural Networks, RNNs) المستخدمة بشكل شائع في مجال التعلم العميق، وخاصة في معالجة البيانات الزمنية والمتسلسلة مثل النصوص والكلام والفيديو. تم تطوير شبكة GRU للتغلب على مشكلة التلاشي والانفجار التدرجي (Vanishing and Exploding Gradient Problems) التي كانت تواجهها الشبكات العصبية المتكررة التقليدية.

[19] 2-1-6 مكونات شبكة: GRU

يمكن تلخيص مكونات شبكة GRU كالتالي:

▪ بوابة التحديث: (Update Gate)

تتحكم في مقدار المعلومات التي يجب تمريرها إلى الحالة التالية. هذه البوابة تساعد الشبكة على الاحتفاظ بالمعلومات الهامة من التسلسلات السابقة.

▪ بوابة إعادة التعيين: (Reset Gate)

تتحكم في مقدار المعلومات السابقة التي يجب نسيانها أو إعادة تعيينها. تساعد هذه البوابة في التخلص من المعلومات غير الضرورية والتي قد لا تكون مفيدة للحالة الحالية.

3-1-6 آلية عمل شبكة GRU

✓ حساب بوابة التحديث:

يتم حساب بوابة التحديث z_t باستخدام معادلة تعتمد على الحالة السابقة والإدخال الحالي حسب المعادلة الآتية:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad \dots (116)$$

✓ حساب بوابة إعادة التعيين:

يتم حساب بوابة إعادة التعيين r_t باستخدام معادلة تعتمد أيضًا على الحالة السابقة والإدخال الحالي حسب المعادلة الآتية:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad \dots (117)$$

✓ حساب الحالة المؤقتة:


باستخدام بوابة إعادة التعيين، يتم حساب الحالة المؤقتة $\tilde{h}_t$ حسب المعادلة الآتية:


$$\tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t]) \quad \dots (118)$$

✓ تحديث الحالة المخفية:

يتم استخدام بوابة التحديث لتحديد كمية المعلومات التي يجب الاحتفاظ بها من الحالة السابقة والمعلومات الجديدة التي تم الحصول عليها من الحالة المؤقتة، وحسب المعادلة الآتية:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad \dots (119)$$





شكل (5) معمارية الشبكة RGN

7 - الجانب العملي


تم الحصول على بيانات واقعية تمثل اسعار الذهب العالمية اليومية للمدة من (22/3/1968) ولغاية (13/5/2024) بواقع (14138) مشاهدة من موقع شركة أورو نوم (AUROMUN- BARS AND COINS) وهي شركة بريطانية متخصصة في تداول المعادن الثمينة وتوريد العملات الذهبية والفضية والبلاتينية. تم اختبار البيانات من حيث عدم احتواءها على قيم شاذة واختبار خطية البيانات وتوزيع البيانات وكذلك اختبار الاستقرار للبيانات واختبار تجانس التباين وكما يأتي:

7-1 اختبار القيم المفقودة والشاذة (Extreme and Missing data Test): لغرض القيام بعملية تحليل البيانات وتطبيق النماذج الإحصائية يجب التأكد أولاً من أن البيانات لا تعاني من وجود قيم مفقودة ويتضح من البيانات أنها لا تعاني من قيم مفقودة. وللتأكد من أن البيانات لا تحتوي قيم متطرفة تختلف بشكل كبير جداً عن باقي القيم الموجودة. يتضح من البيانات عدم وجود قيم متطرفة في البيانات وكما مبين في الجدول (1) والشكل (6) الآتي:

جدول (1) نتائج اختبار القيم المفقودة والشاذة لبيانات اسعار الذهب

			Case Number	Value
Gold price	Highest	1	14122	2,390.45
		2	14119	2,382.83
		3	14118	2,382.51
		4	14121	2,378.25
		5	14116	2,373.24
	Lowest	1	374	34.95
		2	373	35.00
		3	375	35.05
		4	372	35.10
		5	370	35.10

اذ نلاحظ من الجدول (1) ان مجموعة البيانات مقسمة الى قيم عليا وقيم دنيا متناسقة جداً وعدم وجود قيم متطرفة في البيانات، وكما يتضح ايضاً من الرسم الصندوقي للبيانات في الشكل (5) عدم وجود قيم متطرفة فيها.



شكل (6) الرسم الصندوقي (Boxplot) لفحص القيم المتطرفة او الشاذة

7-2 اختبار توزيع البيانات (Data distribution test): نستخدم تطبيق نماذج (GARCH) ونماذج الشبكات العصبية لا يفترض ان تكون البيانات تتوزع توزيعاً طبيعياً بسبب سلوك وطبيعة البيانات المالية التي غالباً ما تظهر تبايناً متغيراً وتوزيعات

غير طبيعية، مثل التوزيعات متينة الذيل (Heavy tail). وللتحقق من توزيع البيانات اسعار الذهب قيد الدراسة تم اجراء اختبار (Jarque – Bera) لاختبار الفرضية الاحصائية الآتية:


H_0 : The data have Normal distribution

H_1 : The data don't have Normal distribution

جدول (2) اختبار Jarque-Bera للبيانات

Gold price	Jarque-Bera	
	χ^2	Sig.
	2550.880483	.000

يتضح من جدول (2) ان قيمة Sig. للاختبار البالغة (0.000) وهي اقل من مستوى المعنوية (5%) وهذا يعني رفض فرضية العدم التي تنص على ان البيانات تتوزع توزيعاً طبيعياً. ويتضح من الرسم البياني للمدرج التكراري في الشكل (7) ان منحني البيانات ملتوي لجهة اليمين وان البيانات تعاني من ذيل متين وهذا دليل على ان البيانات لا تتوزع توزيعاً طبيعياً.



شكل (7) منحني التوزيع الطبيعي والمدرج التكراري للبيانات الحقيقية

3-7 اختبار BDS لخطية البيانات (BDS test): تم كتابة برنامج احتساب احصاء الاختبار (BDS test) لاختبار الفرضية الآتية:

H_0 : السلسلة الزمنية مستقلة (عشوائية)

H_1 : (السلسلة الزمنية ليست مستقلة) (توجد أنماط لا خطية)

حيث تم افتراض $(\varepsilon=0.5)$ و $(m=2)$ لاختبار لاخطية السلسلة الزمنية باستخدام (BDS test)، وان الأسباب وراء افتراض $\varepsilon=0.5$ و $m=2$ كالآتي:


1. اقتراح $\varepsilon=0.5$ يعتبر قيمة معيارية تستخدم في كثير من التطبيقات. هذه القيمة توفر توازناً جيداً بين تحديد النقاط القريبة بشكل كافٍ ولكن ليست قريبة جداً، مما يسمح للاختبار بأن يكون حساساً للكشف عن الأنماط اللاخطية دون أن يكون حساساً بشكل مفرط للضوضاء العشوائية في البيانات.
2. يوفر مستوى من التوازن بين عدد الأزواج المتقاربة التي يتم تحديدها وعدد الأزواج غير المتقاربة. في بعض الحالات، يمكن تعديل هذه القيمة بناءً على طبيعة السلسلة الزمنية، ولكن $\varepsilon=0.5$ يعد بداية جيدة.
3. في كثير من الحالات، يتم البدء من $m=2$ كقيمة أولية للبعد، ثم يمكن زيادتها بناءً على النتائج الأولية وظروف الدراسة. إذا أظهرت النتائج أن هناك لاخطية يمكن زيادة m لاستكشاف أنماط أكثر تعقيداً.

وبعد تحويل البيانات الى بيانات معيارية باستخدام الدرجة المعيارية حيث بلغت قيمة المتوسط للبيانات (656.45) وقيمة الانحراف المعياري للبيانات ($\sigma=555.0177$) امكن احتساب احصاء الاختبار BDS والحصول على النتائج المبينة في جدول (3)

جدول (3) نتائج اختبار خطية البيانات BDS


Gold price	BDS			
	Statistic	$C(m, \varepsilon)$	$C(1, \varepsilon)^m$	Sig.
	11733.193700	0.420570	0.176896	0.000000

يتضح من الجدول (3) ان قيمة Sig. لاحصاء اختبار BDS والبالغة (0.000000) اقل من مستوى المعنوية (5%) وهذا يدل على رفض فرضية العدم اي ان البيانات لاخطية.



شكل (8) نتائج اختبار BDS

4-7 اختبار استقرارية السلسلة الزمنية (Stationary test): لغرض معرفة السلوك التاريخي الزمني للسلسلة الزمنية بشكل اولي يتم اولا رسم السلسلة الزمنية الممثلة لاسعار الذهب العالمية للمدة قيد الدراسة كما مبين في الشكل (9)



شكل (9) الرسم البياني للسلسلة الزمنية لاسعار الذهب العالمية

من الشكل (9) نلاحظ ان السلسلة الزمنية غير مستقرة في المتوسط و غير مستقرة في التباين , حيث نلاحظ وجود ارتفاع ملحوظ في أسعار الذهب في عام 1980 تليها انخفاض ثم استقرارية في الاسعار لغاية عام 2006 ، ثم تليها ارتفاع تدريجي متصاعد في أسعار الذهب يبدأ من بعد عام 2008 حتى منتصف عام 2014 ثم تنخفض من بعد عام 2014 ولغاية عام 2019 ومن ثم تبدأ بالارتفاع تدريجيا من عام 2020 وصولاً الى عام 2024 . ولغرض تأكيد عدم استقرارية اسعار الذهب تم استخدام بعض اختبارات الكشف عن عدم الاستقرارية وكالاتي:

1-4-7 اختبار جذر الوحدة لديكي فولر الموسع (Augmented Dickey-Fuller (ADF): تم استعمال برنامج (Eviwes12) لغرض اختبار استقرارية سلسلة اسعار الذهب باستخدام اختبار جذر الوحدة لديكي فولر الموسع (Augmented Dickey-Fuller (ADF) وكانت نتائج الاختبار كما مبينة في الجدول (4) وكالاتي :

H_0 : السلسلة الزمنية غير مستقرة

H_1 : السلسلة الزمنية مستقرة

جدول (4) نتائج اختبار ديكي فولر الموسع (ADF) (a) بتضمين الحد الثابت (b) بتضمين الحد الثابت والاتجاه لعام (c) عدم تضمين الحد الثابت والاتجاه العام

(a)			
Prob.	t-Statistic	Augmented Dickey-Fuller test statistic	
0.9972	1.059895		
	-3.430640	1% level	Test critical values
	-2.861552	5% level	
	-2.566818	10% level	

(b)		
Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic

0.9685	-0.74991		
	-3.95868	1% level	Test critical values:
	-3.41012	5% level	
	-3.12679	10% level	

(c)

Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic	
0.9953	2.299995		
	-2.56513	1% level	Test critical values:
	-1.94085	5% level	
	-1.61669	10% level	

يتضح من نتائج الاختبار في الجدول (4) ان قيمة Prob. لاحصاء t الخاصة باختبار (ADF) كانت (0.9972) و (0.9685) و (0.9953) على التوالي للحالات بتضمين الحد الثابت, وبتضمين الحد الثابت والاتجاه, وعدم تضمين الحد الثابت والاتجاه العام وهي عموما اكبر من مستوى المعنوية البالغ (5%) وهذا يعني عدم رفض فرضية العدم اي ان سلسلة اسعار الذهب غير مستقرة.

4-7-2 اختبار فيليبس – بيرون (Phillips – Perron Test (PP)): تم استعمال برنامج Eviwes12 لغرض اختبار استقرارية سلسلة اسعار الذهب باستخدام اختبار فيليبس – بيرون (Phillips – Perron Test (PP)) وكانت نتائج الاختبار كما مبينة في الجدول (5) الاتي :

جدول (5) نتائج اختبار فيليبس – بيرون (Phillips – Perron Test (PP)) بتضمين الحد الثابت (b) بتضمين الحد الثابت والاتجاه لعام (c) عدم تضمين الحد الثابت والاتجاه العام

(a)

Prob.*	Adj. t-Stat	T	
0.9978	1.125353		
	-3.430640	1% level	Test critical values
	-2.861552	5% level	
	-2.566818	10% level	

(b)

Prob.*	Adj. t-Stat	T	
0.9733	-0.68493		
	-3.95868	1% level	Test critical values:
	-3.41012	5% level	
	-3.12679	10% level	

(c)

Prob.*	Adj. t-Stat	T	
0.9962	2.378384		
	-2.56513	1% level	Test critical values:
	-1.94085	5% level	
	-1.61669	10% level	

ويتضح من الجدول (5) ان قيمة Prob. لاحصاء t الخاصة باختبار (PP) البالغة (0.9978) و (0.9733) و (0.9962) بتضمين الحد الثابت, وبتضمين الحد الثابت والاتجاه, و عدم تضمين الحد الثابت والاتجاه العام على التوالي اكبر من مستوى المعنوية (0.05) وهذا يعني عدم رفض فرضية العدم اي ان البيانات غير مستقرة.

4-7-3 اختبار الارتباط الذاتي (Autoregressive Test (AR)): تم استعمال برنامج Eviwes12 لغرض اختبار استقرارية سلسلة اسعار الذهب باستخدام اختبار Ljung-Box لاختبار الفرضية الاحصائية الآتية:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$$

$$H_1: \rho_i \neq \rho_l \quad ; \quad \text{for } i \neq l$$

وتم الحصول على النتائج الآتية:

جدول (6) نتائج اختبار Ljung-Box

Gold price	LB Test Statistics		Sig.
	χ^2	Critical Value	
	280070.589777	31.410433	0.000


نلاحظ من جدول (6) ان قيمة Sig. لاحصاء LB البالغة (0.000) وهي اقل من مستوى المعنوية (5%) وكذلك قيمة احصاء الاختبار البالغة (280070.589777) وهي اكبر من القيمة الحرجة لتوزيع χ^2 عند درجة حرية $m=6$ والبالغة (31.410433) عند مستوى معنوية (5%) وهذا يعني رفض فرضية العدم القائلة بتساوي الارتباطات الذاتية.

والجدول (6-3) يشير الى قيم دالة الارتباط الذاتي الارتباط الذاتي الجزئي واحصاء (LB) والقيمة الاحتمالية عند التخلف الزمني (6)

جدول (7) قيم دالة الارتباط الذاتي الارتباط الذاتي الجزئي واحصاء (LB) والقيمة الاحتمالية عند التخلف الزمني (6)

AC	PAC	Q	P-value	Lag
0.99	0.99	13861	0.000	1
0.985	0.25	27586	0.000	2
0.981	0.085	41186	0.000	3
0.978	0.12	54708	0.000	4
0.974	0.034	68139	0.000	5
0.972	0.052	81498	0.000	6

نلاحظ من جدول (7) ان قيمة P-Value لاحصاء LB عند كل تخلف زمني هي اكبر من القيمة الحرجة والبالغة (31.410433) عند مستوى معنوية (5%) وهذا رفض فرضية العدم اي ان الارتباطات الذاتية غير متساوية.



شكل (10) دالة الارتباط الذاتي (AC) والارتباط الذاتي الجزئي (PAC) للسلسلة اسعار الذهب

5-7 اختبار عدم تجانس التباين (Heterocasticity test): لغرض اختبار عدم تجانس التباين في بيانات السلسلة الزمنية تم استعمال اختبار مضاعف لكرانج (Lagrange Multiplier) لاختبار الفرضية الاحصائية الآتية:

H_0 : التباين متجانس لسلسلة اسعار الذهب العالمية (لايوجد تأثير ARCH)

H_1 : التباين غير متجانس لسلسلة اسعار الذهب العالمية (يوجد تأثير ARCH)

وكانت نتائج الاختبار كما مبينة في الجدول (8) الآتي :

جدول (8) نتائج اختبار (Lagrange Multiplier LM)


Gold price	Lagrange Multiplier LM		Sig.
	χ^2	DF	
	625.883103	1	0.0000

يتضح من نتائج الاختبار في الجدول (8) ان قيمة Sig. لاحصاء اختبار (χ^2) والبالغة (0.0000) اقل من مستوى المعنوية (5%) وهذا يدل على رفض فرضية العدم اي ان البيانات تعاني من وجود عدم تجانس التباين.

6-7 تحليل سلسلة العوائد (الفروق): بعدما أظهرت اختبارات الاستقرارية وجود اتجاه عام في السلسلة وعدم استقرارية في المتوسط كما اوضحت اختبارات التجانس وجود عدم تجانس في التباين في السلسلة المدروسة تم احتساب سلسلة العوائد اليومية y_t باستخدام اللوغاريتم الطبيعي للبيانات وفقاً للمعادلة الآتية:

$$y_t = \ln P_t - \ln P_{t-1} \quad \dots (45)$$


حيث P_t : هي سعر الذهب عند الفترة t . P_{t-1} : هي سعر الذهب عند الفترة $t-1$.
وتم رسم سلسلة العوائد كما مبينة في الشكل (11) الآتي.




شكل (11) سلسلة العوائد لبيانات أسعار الذهب العالمية للمدة من (22/3/1968) ولغاية (13/5/2024)


نلاحظ من الشكل (11) ان السلسلة الزمنية للعوائد تعاني من وجود تقلبات واضحة فيها حيث نجد هناك تفاوت بين فترات من التقلبات تتبعها فترات من الركود النسبي وهكذا كلما تقدمنا بالزمن , ويمكن عرض نتائج الإحصاءات الوصفية ورسم المدرج التكراري لسلسلة العوائد كما مبين في جدول رقم (9) في ادناه

جدول رقم (9) نتائج الإحصاء الوصفي لسلسلة العوائد اليومية لأسعار الذهب العالمية



يتبين من نتائج الجدول (9) ان اصغر قيمة في سلسلة العوائد كانت (-0.128900) واكبر قيمة كانت (0.124953) وأن المتوسط للسلسلة الزمنية مساويه لـ (0.000288) ، وبانحراف معياري يساوي (0.011991) , ويظهر أيضاً أن قيمة معامل الالتواء موجب (Skewness = 0.158374) مما يدل على أن توزيع العوائد له ذيل اطول من جهة اليمين (التواء موجب) , كما نلاحظ ايضا ان معامل التفلطح (Kurtosis) يساوي (13.77950) وهو يختلف عن قيمة " 3 " المميزة للتوزيع الطبيعي , مما يدل على أن سلسلة العوائد لها أطراف متينة الذيل (سميكة) وتنسم بالتفلطح مما يدل على تشبها وبالتالي يختلف عن التوزيع الطبيعي , وهذا ما تؤكد إحصاءه (Jarque-Bera) البالغة (68504.39) التي تشير إلى أن سلسلة العوائد لا تتبع التوزيع الطبيعي عند مستوى معنوية (5%) . والشكل (11) يبين دالتي الارتباط الذاتي والارتباط الذاتي الجزئي لسلسلة عوائد اسعار الذهب:





شكل (12) دالة الارتباط الذاتي (AC) والارتباط الذاتي الجزئي (PAC) لسلسلة عوائد اسعار الذهب

7-7 اختبار استقرارية سلسلة العوائد (Returns Stationary test)

لغرض اختبار استقرارية السلسلة الزمنية لعوائد الذهب تم استخدام اختبارات الكشف عن عدم الاستقرارية وكالاتي :
 1-7-7 اختبار جذر الوحدة لديكي فولر الموسع لسلسلة العوائد: تم استخدام اختبار جذر الوحدة لديكي فولر الموسع (Augmented Dickey-Fuller (ADF)) وكانت نتائج الاختبار كما مبينه في الجدول (10) الآتي :
 جدول (10) نتائج اختبار ديكي فولر الموسع (ADF) لسلسلة العوائد (a) بتضمنين الحد الثابت (b) بتضمنين الحد الثابت والاتجاه لعام (c) عدم تضمين الحد الثابت والاتجاه العام

(a)

Prob.	t-Statistic	Augmented Dickey-Fuller test statistic	
0.0001	-67.85211	Test critical values	
	-3.43064		
	-2.86155		
	-2.56682		

(b)

Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic	
0.0000	-67.8571	Test critical values:	
	-3.95868		
	-3.41012		
	-3.12679		

(c)

Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic	
0.0001	-67.775	Test critical values:	
	-2.56513		
	-1.94085		
	-1.61669		

يتضح من نتائج الاختبار في الجدول (10) ان قيمة Prob. لاحصاء t الخاصة باختبار (ADF) كانت (0.0001) و (0.0000) و (0.0001) على التوالي للحالات بتضمنين الحد الثابت, وبتضمنين الحد الثابت والاتجاه , وعدم تضمين الحد الثابت و الاتجاه العام وهي عموما اقل من مستوى المعنوية البالغ (5%) وهذا يعني رفض فرضية العدم اي ان سلسلة عوائد الذهب مستقرة.

7-7-2 اختبار فيليبس – بيرون لسلسلة العوائد : تم اختبار استقرارية سلسلة عوائد اسعار الذهب باستخدام اختبار فيليبس – بيرون ((Phillips – Perron Test (PP)) وتم الحصول على النتائج الآتية:

جدول (11) نتائج اختبار فيليبس – بيرون لسلسلة العوائد بتضمنين الحد الثابت (b) بتضمنين الحد الثابت والاتجاه لعام (c) عدم تضمين الحد الثابت والاتجاه العام

(a)

Prob.*	Adj. t-Stat	Phillips-Perron test statistic	
0.0001	-119.799	Test critical values	
	-3.43064		
	-2.86155		
	-2.56682		

Prob.*	Adj. t-Stat	Phillips-Perron test statistic	
		1% level	5% level
0.0001	-3.95868	Test critical values:	
	-3.41012		
	-3.12679		
	-3.95868	10% level	

Prob.*	Adj. t-Stat	Phillips-Perron test statistic	
		1% level	5% level
0.0001	-119.755	Test critical values:	
	-2.56513		
	-1.94085		
	-1.61669	10% level	

نلاحظ من جدول (11) ان قيمة Prob. لاحصاء t الخاصة باختبار (PP) لسلسلة العوائد البالغة (0.0001) و (0.0000) و (0.0001) بتضمين الحد الثابت وكذلك بتضمين الحد الثابت والاتجاه و عدم تضمين الحد الثابت والاتجاه العام على التوالي اقل من مستوى المعنوية وهذا يعني رفض فرضية العدم اي ان البيانات مستقرة في المتوسط.

7-7-3 اختبار الارتباط الذاتي لسلسلة العوائد :تم اختبار استقرارية سلسلة العوائد باستخدام اختبار Ljung-Box وتم الحصول على النتائج الآتية:

جدول (12) نتائج اختبار Ljung-Box لسلسلة العوائد


Returns price	LB Test Statistics		Sig.
	χ^2	Critical Value	
	24.23467	31.410433	0.99090

نلاحظ من جدول (12) ان قيمة Sig. لاحصاء LB البالغة (0.99090) اقل من مستوى المعنوية وكذلك القيمة المحسوبة البالغة (24.23467) هي اقل من القيمة الحرجة البالغة (31.410433) عند مستوى معنوية (5%) وهذا يعني عدم رفض فرضية العدم اي ان الارتباطات الذاتية متساوية. وتشير إلى عدم وجود ارتباط ذاتي في سلسلة عوائد اسعار الذهب.


جدول (13) قيم دالة الارتباط الذاتي الارتباط الذاتي الجزئي واحصاء (LB) والقيمة الاحتمالية عند التخلف الزمني (6) لسلسلة العوائد

AC	PAC	LB	P-value	Lag
-0.007	-0.007	12.5563	0.7789	1
-0.025	-0.025	11.5343	0.8966	2
0.031	0.03	12.345	0.8684	3
-0.006	-0.006	12.778	0.4567	4
-0.001	0.0000	17.789	0.7788	5
-0.007	-0.008	22.788	0.2345	6


نلاحظ من جدول (13) ان قيمة P-Value لاحصاء LB لسلسلة العوائد عند كل تخلف زمني هي اقل من القيمة الحرجة البالغة (31.410433) عند مستوى معنوية (5%) وهذا يعني عدم رفض فرضية العدم اي ان الارتباطات الذاتية متساوية. ودلالة على عدم وجود الارتباط الذاتي للبواقي.



a



b



c

شكل (12) انتشار البواقي (Residual Spread) لسلسلة العوائد حسب اختبار الارتباط الذاتي

اذ ان الشكل (12) a بين التوزيع التجريبي لسلسلة البواقي والتوزيع الطبيعي. إذا كانت النقاط تقع على خط مستقيم، فإن الضوضاء البيضاء موزعة بشكل طبيعي، مما يدعم فرضية العشوائية في السلسلة الزمنية b. تعرض الارتباط الذاتي والارتباط الذاتي الجزئي لسلسلة البواقي فاذا كان الرسم البياني لا يظهر نمطاً واضحاً وكانت القيم قريبة من الصفر مع عدم وجود الكثير من القيم خارج حدود الثقة، فإن هذا سوف يتفق مع توقعاتنا بان سلسلة البواقي يفترض أن تكون مستقلة وعشوائية c تقارن بين التوزيع التجريبي للبواقي والتوزيع الطبيعي. حيث نلاحظ ان البواقي لا تتوزع بشكل طبيعي مما يدعم فرضية عدم العشوائية في السلسلة.

8-7 اختبار عدم تجانس التباين لسلسلة العوائد : تم استعمال اختبار مضاعف لكرانج لغرض اختبار عدم تجانس بيانات سلسلة العوائد حسب الفرضية الاحصائية الآتية:

H_0 : التباين متجانس لسلسلة اسعار الذهب العالمية (لايوجد تأثير ARCH)
 H_1 : التباين غير متجانس لسلسلة اسعار الذهب العالمية (يوجد تأثير ARCH)

وكانت النتائج كما في جدول (14)

جدول (14) نتائج اختبار (Lagrange Multiplier LM)

Gold price	Lagrange Multiplier LM		Sig.
	χ^2	DF	
	631.735923	1	0.0000

يتضح من جدول (14) ان قيمة Sig. لاختبار (LM) لسلسلة العوائد والبالغة (0.0000) اقل من مستوى العنوية (5%) وهذا يدل على رفض فرضية عدم اي ان البيانات تعاني من وجود عدم تجانس التباين. مما يعني ان البيانات تحتوي على تأثير ARCH .

8-1 تقدير نموذج LSTM: تم تطبيق انموذج LSTM وباستعمال برنامج ماتلاب، وتم الحصول على متغيرات الادخال للشبكتين باعتبار XTrain هو متغير إدخال الشبكة خلال التدريب، ويمثل القيم السابقة للسلسلة الزمنية. يتم جميع البيانات في هذا المتغير لاستخدامها للشبكة. ويعتمد عدد المدخلات على عدد العينات في مجموعة التدريب - 1 ويتم الحصول عليه كالآتي:

$XTrain = \text{num2cell}(\text{trainDataNorm}(1:\text{end}-1));$

اذ تم أخذ كل قيم البيانات من مجموعة التدريب ما عدا القيمة الأخيرة وتحويلها إلى خلية واحدة (cell) لتناسب مع متطلبات إدخال الشبكة. YTrain هو المتغير الذي يمثل القيم المستهدفة (القيم التي تحاول الشبكة التنبؤ بها) خلال التدريب. يمثل القيم المستقبلية للسلسلة الزمنية. وهو نفسه عدد المدخلات في XTrain ويتم الحصول عليه كالآتي:

$YTrain = \text{num2cell}(\text{trainDataNorm}(2:\text{end}));$

اذ يتم أخذ كل القيم من مجموعة التدريب بدءاً من القيمة الثانية حتى النهاية، ويتم تحويلها إلى خلية واحدة. XTest هو متغير إدخال الشبكة خلال الاختبار، ويمثل القيم السابقة للسلسلة الزمنية من مجموعة الاختبار. ويعتمد على عدد العينات في مجموعة الاختبار - 1. ويتم الحصول عليه كالآتي:

$XTest = \text{num2cell}(\text{testDataNorm}(1:\text{end}-1));$

اذ يتم أخذ القيم من مجموعة الاختبار ما عدا القيمة الأخيرة وتحويلها إلى خلية واحدة لتناسب مع متطلبات إدخال الشبكة. YTest هو متغير يحتوي على القيم الفعلية (الحقيقية) للسلسلة الزمنية من مجموعة الاختبار. يتم استخدام YTest لمقارنة القيم المتنبأ بها بواسطة الشبكة العصبية YPred مع القيم الفعلية لتقييم أداء النموذج. ويتم الحصول على YTest كالآتي:

$YTest = \text{testData}(2:\text{end});$

اذ يتم استخراجها من مجموعة الاختبار (testData) بدءاً من العنصر الثاني إلى النهاية. ومن خلال تحويل البيانات من خلال عمل (Normalization) لجعلها تناسب الشبكة العصبية بشكل أفضل. يتم حساب متوسط القيم (mu) والانحراف المعياري (sigma) ثم يتم استخدامهما لتطبيع البيانات. وكذلك تحويل البيانات إلى خلايا (Cells) يتم تحويل القيم المتسلسلة إلى خلايا باستخدام num2cell حتى يمكن تمريرها بشكل مناسب إلى شبكة LSTM، والمرحلة الأخيرة تم تقسيم البيانات إلى مجموعة تدريب ومجموعة اختبار حسب كل نسبة. في MatLab، تستخدم دالة trainNetwork لبناء وتدريب نموذج LSTM، يتم التعامل مع العمليات الداخلية للبوابات (مثل حساب W , b , o_t , j_t , f_t) بشكل تلقائي داخل النموذج. اذ ان MatLab لا يوفر تفاصيل البوابات كإخراج مباشر، لأن هذه العمليات تتم داخلياً أثناء التدفق الأمامي للشبكة. تم تقدير سلسلة

العوائد بالاعتماد طريقة LSTM بتطبيق نسب بيانات اختبار التدريب (50%, 70%, 80%) , وعدد طبقات مخفية (50, 100, 150) وبعدد مرات Epoch (1000) التي تشير الى مقياس لعدد مرات عرض مجموعة كاملة من بيانات التدريب للنموذج. بمعنى آخر، عند تنفيذ تدريب النموذج، فإن عدد الـ "Epochs" يشير إلى عدد المرات التي يتم فيها تمرير مجموعة البيانات بأكملها عبر خوارزمية التدريب وتمت المقارنة بين النماذج باستعمال معيار (MAPE , MSE) ومعيار الدقة لاقتراح الطريقة الافضل وكما مبين في الجداول الاتية:

أ – في حالة بيانات التدريب 50%

1. بيانات تدريب 50% وعدد طبقات مخفية 50

جدول (15) معايير الدقة لشبكة LSTM عند بيانات تدريب 50% وعدد طبقات مخفية 50

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.007251	0.000111	0.755941

2. بيانات تدريب 50% وعدد طبقات مخفية 100


جدول (16) معايير الدقة لشبكة LSTM عند بيانات تدريب 50% وعدد طبقات مخفية 100

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.007232	0.000101	0.774811

3. بيانات تدريب 50% وعدد طبقات مخفية 150

جدول (17) معايير الدقة لشبكة LSTM عند بيانات تدريب 50% وعدد طبقات مخفية 150

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.007212	0.000103	0.774949



شكل (13) القيم الحقيقية والقيم التقديرية لانموذج LSTM نسبة بيانات اختبار 50% وعدد طبقات مخفية (A=50, B=100, C=150)

ب – في حالة بيانات التدريب 70%

1. بيانات تدريب 70% وعدد طبقات مخفية 50

جدول (18) معايير الدقة لشبكة LSTM عند بيانات تدريب 70% وعدد طبقات مخفية 50

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.007121	0.000091	0.808111

2. بيانات تدريب 70% وعدد طبقات مخفية 100


جدول (19) معايير الدقة لشبكة LSTM عند بيانات تدريب 70% وعدد طبقات مخفية 100

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.006734	0.000074	0.834141

3. بيانات تدريب 70% وعدد طبقات مخفية 150

جدول (20) معايير الدقة لشبكة LSTM عند بيانات تدريب 70% وعدد طبقات مخفية 150

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.006621	0.000021	0.840013



شكل (14) القيم الحقيقية والقيم التقديرية لـ LSTM عند بيانات اختبار 70% وعدد طبقات مخفية (A=50, B=100, C=150)

ج - في حالة بيانات التدريب 80%

1. بيانات تدريب 80% وعدد طبقات مخفية 50

جدول (21) معايير الدقة لشبكة LSTM عند بيانات تدريب 80% وعدد طبقات مخفية 50

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.006464	0.000014	0.858371

2. تدريب 80% وعدد طبقات مخفية 100


جدول (22) معايير الدقة لشبكة LSTM عند بيانات تدريب 80% وعدد طبقات مخفية 100

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.00631	0.000009	0.895901

3. بيانات تدريب 80% وعدد طبقات مخفية 100

جدول (23) معايير الدقة لشبكة LSTM عند بيانات تدريب 80% وعدد طبقات مخفية 100

Criteria Method	MAPE	MSE	Accuracy
LSTM	0.006341	0.0000052	0.897314



شكل (15) القيم الحقيقية والقيم التقديرية لـ LSTM عند بيانات اختبار 80% وعدد طبقات مخفية (A=50, B=100, C=150)

نلاحظ من الجداول (21) الى (23) عند استخدام بيانات تدريب بنسبة 80% وعدد مختلف من الطبقات المخفية، نجد أن نموذج LSTM يستمر في إظهار تفوق واضح مقارنة بنموذج RGU عبر جميع المعايير المستخدمة. مع زيادة حجم بيانات

التدريب إلى 80%، يتحسن أداء LSTM بشكل ملحوظ، حيث يسجل MAPE و MSE أقل، مما يشير إلى دقة أعلى وانخفاض كبير في الأخطاء. فلاحظ، عند استخدام 50 طبقة مخفية، يحقق LSTM MAPE قدره 0.006464 و MSE قدره 0.000014، مع دقة تصل إلى 85.84%، متفوقاً بوضوح على RGU الذي يسجل MAPE أعلى ودقة أقل. ومع زيادة عدد الطبقات المخفية إلى 100 و 150، يواصل LSTM تحسين أدائه، حيث يصل إلى دقة 89.73% و MAPE قدره 0.006341 مع 150 طبقة مخفية، بينما يبقى أداء RGU ثابتاً تقريباً مع دقة تقارب 75.35% وارتفاع نسبي في MSE

الشكل (15) يوضح مقارنة بين القيم الحقيقية والتقديرية لنموذجي LSTM و RGU باستخدام 80% من بيانات التدريب. يظهر شكل (13) توافقاً عالياً بين القيم الحقيقية والتقديرية لنموذج LSTM عبر جميع الطبقات المخفية A=50، B=100، C=150، مما يدل على قدرة النموذج على تقديم تقديرات دقيقة حتى مع زيادة التعقيد. على النقيض، يظهر شكل (12) أن نموذج RGU يعاني من انحرافات أكبر عن القيم الحقيقية، خاصة مع زيادة عدد الطبقات المخفية، مما يشير إلى أن النموذج أقل دقة واستقراراً مقارنة ب LSTM.

بناءً على هذه النتائج، يمكن استنتاج أن نموذج LSTM يتفوق بشكل كبير على RGU عند استخدام 80% من بيانات التدريب، مما يجعله الخيار الأمثل لتحقيق نتائج دقيقة ومستقرة في هذا السيناريو.

من مقارنة جميع النماذج التي تدربها نلاحظ أن نموذج LSTM كان أفضل من نموذج RGU حيث سجل أقل معايير المقارنة وبدقة عالية. وكانت الحالة الأفضل عند نسبة بيانات تدريب (80%) وعدد طبقات مخفية (150) طبقة ونسبة دقة بلغت (90%).

9- الاستنتاجات :

1. أثبتت شبكة LSTM (Long Short-Term Memory) كفاءتها وتفوقها في التنبؤ بأسعار الذهب
2. أن نموذج LSTM هو الأكثر دقة وفعالية في التنبؤ بأسعار الذهب العالمية. يشير ذلك إلى أن الشبكات العصبية العميقة قادرة على استيعاب التعقيدات الموجودة في بيانات أسعار الذهب بشكل أكثر كفاءة من النماذج التقليدية.
3. أكدت اختبارات الاستقرار وعدم تجانس التباين واللاخطية على صحة النماذج قبل التقدير.
4. أظهرت النتائج أن أسعار الذهب العالمية قد تشهد انخفاضاً مستقبلياً بناءً على التنبؤ باستخدام نموذج LSTM.

10- التوصيات:

1. تبني نماذج مثل LSTM في الدراسات المستقبلية لتحليل السلاسل الزمنية المالية، خاصة تلك التي تتميز بالتعقيد والتقلبات العالية، مثل أسعار الذهب والعملات.
2. تدريب الشبكات العصبية على بيانات كبيرة ومتنوعة لتعزيز قدرتها التنبؤية.
3. تطبيق النماذج المستخدمة على بيانات أخرى، مثل أسعار النفط والعملات الرقمية، للتحقق من كفاءتها ومرونتها في سياقات مختلفة.
4. مقارنة الشبكات العصبية العميقة LSTM مع نماذج أخرى مثل Transformer أو Bidirectional LSTM لتحديد أفضل نموذج للسلاسل الزمنية.
5. دراسة تأثير المتغيرات الاقتصادية الأخرى، مثل معدلات الفائدة والتضخم وأسعار العملات، على أسعار الذهب، وإدراجها في النماذج لتحسين دقة التنبؤ.
6. بناء تطبيقات تنبؤية تعتمد على النموذج الأفضل (LSTM) لتقديم تنبؤات مباشرة للمستثمرين والأسواق المالية، مما يساهم في اتخاذ قرارات استثمارية مدروسة.
7. إجراء ورش عمل ودورات تدريبية حول استخدام النماذج الحديثة في تحليل السلاسل الزمنية، لتمكين الباحثين والمستثمرين من استخدامها بفعالية.

References

1. الشخيلي، إيفان علاء ناظم , (2003) , " تصميم نظام رياضي ديناميكي لا خطي باستخدام الشبكات العصبية (NARMAX) لأغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد", رسالة ماجستير في بحوث العمليات , كلية الإدارة والاقتصاد , جامعة بغداد.
2. المرشدي، كزار حمزة حسين علي, (2021) , " تشخيص وتقدير نماذج السلاسل الزمنية الموسمية مع تطبيق عملي " , رسالة ماجستير , كلية الإدارة والاقتصاد , جامعة كربلاء.

3. C. Staudemeyer , Ralf ; Morris, Eric Rothstein, (2019), " Understanding LSTM – a tutorial into Long Short-Term Memory Recurrent Neural Networks " , arXiv:1909.09586v1 [cs.NE] 12 Sep 2019

4. Chen , Danqi ; D. Manning, Christopher , (2014), " A Fast and Accurate Dependency Parser using Neural Networks ", proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), pages 740–750, October 25-29, 2014, Doha, Qatar. c 2014 Association for Computational Linguistics.
5. Caporale , Guglielmo Maria; Pittisy Nikitas ; Spagnolo, Nicola, (2003) , " IGARCH models and structural breaks ", Applied Economics Letters, 10, 765–768.
6. Chen , Danqi ; D. Manning, Christopher , (2014), " A Fast and Accurate Dependency Parser using Neural Networks ", proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), pages 740–750, October 25-29, 2014, Doha, Qatar. c 2014 Association for Computational Linguistics
7. Chen, Hao; Zhang , Jianzhong; Tao, Yubo; Fenglei Tan, (2019), " Asymmetric GARCH type models for asymmetric volatility characteristics analysis and wind power forecasting ", Protection and Control of Modern Power Systems. 4:29.
8. Chen, Yi–Ting, (2002) "On the Robustness of Ljung–Box and McLeod–Li Q Tests: A Simulation Study" Economics Bulletin, Vol. 3, No. 17 pp. 1–10
9. Cheng, Nok & Kuo, Alex, (2020), " Using Long Short-Term Memory (LSTM) Neural Networks to Predict Emergency Department Wait Time ", The Importance of Health Informatics in Public Health during a Pandemic J. Mantas et al. (Eds.)
10. Dastres, Roza, Soori , Mohsen, (2021), "Artificial Neural Network Systems", International Journal of Imaging and Robotics (IJIR), 2021, 21 (2), pp.13-25. fahal-03349542f 43
11. Dastres, Roza, Soori , Mohsen, (2021), "Artificial Neural Network Systems", International Journal of Imaging and Robotics (IJIR), 2021, 21 (2), pp.13-25. fahal-03349542f
12. Ding, Zhuanxin; Granger , Clive W.J. ; F. Engle , Robert , (1993), " A long memory property of stock market returns and a new model ", Journal of Empirical Finance 1 , 83-106. North-Holland
13. Gutierrez, Alex Neri; Carranza , Alexis Rodriguez; ; Carrasco , Ana Gamarra, (2019), " Detecting Nonlinear Dynamics Using BDS Test and Surrogate Data in Financial Time Series ", Journal of Mathematics and System Science 9 , 46-53 doi: 10.17265/2159-5291/2019.02.002.
14. Hochreiter, S., and J. Schmidhuber, (1997), "Long short-term memory" Neural computation. Vol. 9, Number 8, , pp.1735–1780.
15. Idowu , Peter Adebayo; Chris Osakwe, Aderonke Anthonia Kayode; Emmanuel Rotimi Adagunodo, (2012), " prediction of Stock Market in Nigeria Using Artificial Neural Network ", I.J. Intelligent Systems and Applications,, 11, 68-74 Published Online October 2012 in MECS (<http://www.mecs-press.org/>) DOI: 10.5815/ijisa.2012.11.0
16. Raghunathan , Anand , (2018), " Approximate Computing for Long Short Term Memory (LSTM) Neural Networks ", IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems (Volume: 37)
17. Rodríguez-Hernandez, Carlos Felipe ; Musso, Mariel, Kyndt, Eva; Cascallar , Eduardo, (2021), " Artificial neural networks in academic performance prediction: Systematic implementation and predictor evaluation ", Computers and Education: Artificial Intelligence
18. Shaik, Muneer; Aditya, (2020), " The Comparison of GARCH and ANN Model for Forecasting Volatility: Evidence based on Indian Stock Markets Predicting Volatility using GARCH and ANN Models", The journal of prediction markets
19. Wall, C.; Zhang, L., Yy, Y. ; Mistry, K., (2021). "Deep recurrent neural networks with attention mechanisms for respiratory anomaly classification" . In Proceedings of 2021 International joint conference on neural networks (IJCNN 2021), 18-22 July 2021, [virtual conference]. Piscataway: IEEE [online], article 9533966. Available from: <https://doi.org/10.1109/IJCNN52387.2021.9533966>,
20. Yusofa, Fadhilah, Kanea, Ibrahim Lawal; Yusop, Zulkifli, (2014), " Hybrid of ARIMA-GARCH Modeling in Rainfall Time Series ", 63:2 (2013) 27–34 | www.jurnalteknologi.utm.my | eISSN 2180–3722 | ISSN 0127–9696.