تقييم كفاءة الشبكات العصبية الاصطناعية متعددة الطبقات (MLP) في التنبؤ بأسعار الذهب باستخدام مؤشر الدولار الأمريكي خلال الفترة(2025–1990)

علاء سام بلدية*

(الإيداع: 16 تشرين الثاني 2026، القبول: 2 حزيران 2026)

الملخص:

يُعد الذهب من أهم الأصول المالية والاستثمارية التي تحظى باهتمام واسع في الأسواق العالمية، نظراً لدوره كملاذ آمن في أوقات الأزمات الاقتصادية والتقلبات النقدية. وتتأثر أسعار الذهب بعدد كبير من العوامل الاقتصادية، وفي مقدمتها تحركات مؤشر الدولار الأمريكي، الأمر الذي يجعل عملية التنبؤ بأسعار الذهب من القضايا المهمة في مجال التحليل المالي واتخاذ القرارات الاستثمارية. هدفت هذه الدراسة إلى بناء نموذج تنبؤ باستخدام الشبكات العصبية الاصطناعية من نوع الشبكة متعددة الطبقات (MLP) لتحليل العلاقة بين أسعار الذهب ومؤشر الدولار الأمريكي خلال الفترة الممتدة بين عامي (1990–2025)، اعتماداً على بيانات شهرية تاريخية. وقد استخدم النموذج خمس متغيرات مدخلة شملت مؤشر الدولار الحالي، والقيم المتأخرة لكل من الذهب والدولار، إضافة إلى الفروق الأولى للمتغيرين، وذلك بهدف تمكين النموذج من التقاط الأنماط الزمنية والعلاقات غير الخطية بين المتغيرات.

وأظهرت نتائج الدراسة تمتع النموذج بدرجة عالية من الكفاءة والدقة التنبؤية، حيث بلغ الخطأ النسبي لعينة التدريب (0.001)، بينما بلغ لعينة الاختبار (0.002)، وهي قيم منخفضة جداً تشير إلى قدرة النموذج على تحقيق تنبؤات دقيقة وفعالة. كما أظهرت النتائج أن استخدام القيم المتأخرة والفروق الأولى ساهم في تعزيز الأداء التنبؤي للنموذج وتحسين قدرته على تفسير التغيرات في أسعار الذهب.

كما بينت الدراسة وجود علاقة ديناميكية معقدة بين مؤشر الدولار وأسعار الذهب، حيث استطاع النموذج التقاط التأثيرات غير الخطية بين المتغيرات بصورة أفضل من النماذج الإحصائية التقليدية. وقد ساعدت الطبقة المخفية للشبكة العصبية في اكتشاف الأنماط الكامنة داخل البيانات المالية، مما انعكس إيجاباً على جودة النتائج.

وتوصلت الدراسة إلى أن نماذج الشبكات العصبية الاصطناعية تمثل أداة فعالة في تحليل السلاسل الزمنية المالية والتنبؤ بالأسعار المستقبلية، خاصة في الأسواق التي تتسم بدرجة عالية من التقلب وعدم الاستقرار. كما توصي الدراسة بالتوسع في استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في مجالات التحليل المالي وإدارة المخاطر، مع إمكانية تطوير النموذج مستقبلاً من خلال إدخال متغيرات اقتصادية إضافية مثل أسعار الفائدة والتضخم وأسعار النفط والسياسات النقدية العالمية.

الكلمات مفتاحية: مؤشر الدولار، أسعار الذهب، الشبكات العصبية الاصطناعية.

***دكتوراه – اختصاص إحصاء وبرمجة –كلية الاقتصاد**

Evaluating the efficiency of multi-layer artificial neural networks (MLPs) in predicting gold prices using the US Dollar Index during the period (1990–2025)

Alaa Sam baladiya*

(Received: 16 November 2026, Accepted: 2 June 2026)

Abstract:

Gold is one of the most important financial and investment assets, attracting widespread attention in global markets due to its role as a safe haven during times of economic crises and monetary volatility. Gold prices are affected by a large number of economic factors, most notably the movements of the US Dollar Index. This makes gold price prediction a crucial issue in financial analysis and investment decision-making.

This study aimed to build a prediction model using artificial neural networks, specifically a multi-layered network (MLP), to analyze the relationship between gold prices and the US Dollar Index during the period from 1990 to 2025, based on historical monthly data. The model used five input variables: the current Dollar Index, the lagging values of both gold and the dollar, and the initial differences between the two variables. This enabled the model to capture time patterns and non-linear relationships between the variables.

The study results demonstrated the model's high efficiency and predictive accuracy. The relative error for the training sample was 0.001, while for the test sample it was 0.002—very low values indicating the model's ability to make accurate and effective predictions. The results also showed that using lagging values and first differences contributed to enhancing the model's predictive performance and improving its ability to explain changes in gold prices.

The study also revealed a complex dynamic relationship between the dollar index and gold prices. The model was able to capture the nonlinear effects between variables better than traditional statistical models. The hidden layer of the neural network helped uncover underlying patterns within the financial data, positively impacting the quality of the results.

The study concluded that artificial neural network models are an effective tool for analyzing financial time series and predicting future prices, especially in highly volatile and unstable markets. The study recommends expanding the use of artificial intelligence and machine learning techniques in financial analysis and risk management, with the potential for future model development by incorporating additional economic variables such as interest rates, inflation, oil prices, and global monetary policies.

Keywords: Dollar Index, Gold Prices, Artificial Neural Networks.

PhD – Specialization in Statistics and Programming – Faculty of Economics

المقدمة:

تشكل أسعار الذهب محورًا أساسيًا في النظام المالي العالمي، حيث تمتاز بحساسية عالية للتغيرات الاقتصادية والجيوسياسية. ويعتبر الذهب أحد أهم أدوات التحوط ضد التضخم ومخزنًا للقيمة في فترات عدم اليقين الاقتصادي والسياسي. ونظرًا لتعقيد العوامل المؤثرة على أسعار الذهب، أصبحت الأساليب الذكية مثل الشبكات العصبية Artificial Neural Networks الخيار الأمثل لنمذجة السلوك السعري غير الخطي وتحليل السلاسل الزمنية.

تتميز الشبكات العصبية بقدرتها على التعلم من البيانات التاريخية واستخلاص الأنماط المعقدة التي تفشل الطرق الإحصائية التقليدية في كشفها. في هذا البحث، سنستكشف قدرة الشبكات العصبية من نوع Multilayer Perceptron (MLP) على التنبؤ بأسعار الذهب بناءً على البيانات التاريخية، مع التركيز على العلاقة بين الذهب ومؤشر الدولار الأمريكي (DXY).

مشكلة البحث:

تكمن الإشكالية الأساسية في صعوبة التنبؤ بأسعار الذهب بسبب تداخل العوامل الاقتصادية والمالية والسياسية المؤثرة عليه. كتأثير تأخر سعر الذهب (Lag1) على التنبؤات المستقبلية، والتغيرات في مؤشر الدولار، ومدى كفاءة النموذج في التعامل مع سلاسل زمنية، لذلك يحاول هذا البحث الإجابة عن التساؤل الرئيسي: هل يمكن للشبكات العصبية من نوع MLP الاعتماد على القيمة التاريخية لسعر الذهب ومؤشر الدولار لتقديم تنبؤات دقيقة مفيدة للمستثمرين؟

أهمية البحث:

يقدم البحث نموذجاً تطبيقياً لاستخدام Multilayer Perceptron في دراسة العلاقات الاقتصادية غير الخطية، وهو ما يسهم في توسيع استخدام أساليب التعلم الآلي في البحوث الاقتصادية والمالية.

من الناحية الأكاديمية:

- تقديم نموذج تنبؤي غير خطي متطور لتحليل السلاسل الزمنية المالية
- اختبار قدرة الشبكات العصبية على التعامل مع مجموعات بيانات محدودة.

من الناحية العملية:

- دعم قرارات المستثمرين والمؤسسات المالية في إدارة المحافظ الاستثمارية
- توفير أداة تنبؤية تساعد في التخطيط المالي طويل المدى

هدف البحث:

بناء نموذج تنبؤ باستخدام الشبكات العصبية الاصطناعية لتقدير أسعار الذهب اعتماداً على مؤشر الدولار الأمريكي خلال الفترة (1990–2025)، وقياس كفاءة النموذج في التنبؤ بالأسعار المستقبلية. مما يساعد الأفراد والمستثمرين على التخطيط وحساب أسعار الذهب.

منهجية البحث:

تم الاعتماد على المنهج الوصفي التحليلي لجمع البيانات وتحليلها حيث تم جمع البيانات الشهرية للفترة من 1990 إلى 2025 من مصادر موثوقة مثل:

- مجلس الذهب العالمي (World Gold Council)

- الاحتياطي الفيدرالي الأمريكي (Federal Reserve)

وفي القسم العملي تم اعتماد أساليب السلاسل الزمنية، مع استخدام الشبكات العصبية الاصطناعية لتحليل البيانات بالاعتماد على بيانات شهرية تاريخية تم تحليلها باستخدام برنامج SPSS.

حدود البحث:

- الحدود الزمنية: اقتصرت الدراسة على البيانات الشهرية للفترة الممتدة بين عامي (1990–2025)، وذلك بهدف تحليل العلاقة بين أسعار الذهب ومؤشر الدولار الأمريكي خلال مدة زمنية طويلة تتضمن العديد من المتغيرات والأزمات الاقتصادية العالمية.
- الحدود المكانية: تركزت الدراسة على الأسواق المالية العالمية، نظراً لارتباط أسعار الذهب ومؤشر الدولار الأمريكي بالاقتصاد العالمي والأسواق الدولية، دون التقيّد باقتصاد دولة محددة.

الدراسات السابقة:

أولاً: دراسة غسان إدلبي، غسان الساكت، آية سريو (2021) بعنوان: **مقارنة بين تقنيات الذكاء الاصطناعي للتنبؤ بأسعار معدني الذهب والنحاس. مجلة جامعة حلب.**

هدفت الدراسة إلى بناء نموذج للتنبؤ بأسعار معدني الذهب والنحاس باستخدام تقنية أشجار الغابات العشوائية والشبكات العصبية وشعاع الدعم الآلي ونظام الاستدلال الضبابي المبني على شبكة عصبية تكيفية، بالاعتماد على البيانات التاريخية للمعدنين، وتوصل البحث إلى أن التقنيات الأربعة قادرة على التنبؤ بدقة جيدة بأسعار المعدنين مع أفضلية لتقنية الشبكات العصبية بمعامل ارتباط قدره 0.9967 للذهب و0.995 للنحاس تليها تقنية شعاع الدعم الآلي.

ثانياً: دراسة العتيبي والغامدي (2021) بعنوان: **دور مؤشرات الدولار الأمريكي في تفسير تقلبات أسعار الذهب.** مجلة الدراسات المالية والمصرفية. السعودية

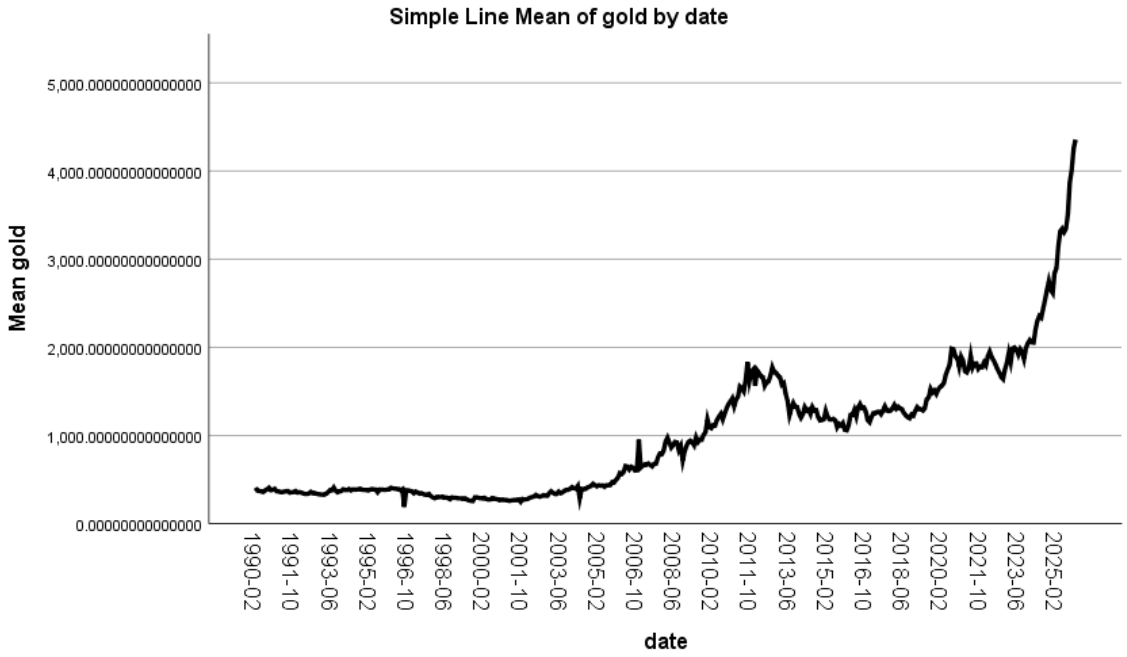
هدفت الدراسة إلى تحليل وقياس مدى مساهمة مؤشرات الدولار الأمريكي وتأثيرها القياسي في تفسير تقلبات أسعار الذهب. وقد توصلت الدراسة إلى وجود علاقة عكسية قوية مستقرة بين الطرفين، مدفوعة بتسعير الذهب بالدولار وتأثير أسعار الفائدة الفيدرالية، مع تأكيد دور الذهب كملاذ آمن في الأجل الطويل.

الإطار النظري:

يعرض الملحق رقم (1) والموجود في الملاحق، البيانات الشهرية المستخدمة في الدراسة خلال الفترة الممتدة من عام 1990 وحتى عام 2025، والتي شملت متغيرين رئيسيين هما أسعار أونصة الذهب بالدولار الأمريكي ومؤشر الدولار الأمريكي.

وتمثل هذه الفترة الزمنية الممتدة أكثر من ثلاثة عقود، الأمر الذي يمنح الدراسة قدرة أكبر على تحليل التغيرات الاقتصادية والمالية التي شهدها الاقتصاد العالمي، بما في ذلك فترات الأزمات المالية والتضخم والتقلبات النقدية والتغيرات في السياسة النقدية الأمريكية. كما تُظهر البيانات وجود تقلبات واضحة في أسعار الذهب ومؤشر الدولار عبر الزمن، وهو ما يعكس الطبيعة الديناميكية للأسواق المالية العالمية. وتساعد هذه البيانات الزمنية الطويلة نموذج الشبكات العصبية على التعلم من الأنماط التاريخية واكتشاف العلاقات غير الخطية بين المتغيرات، بما يعزز من دقة التنبؤات المستقبلية.

الرسم البياني للسلسلة الزمنية لسعر الذهب:



الشكل رقم (1) السلسة الزمنية لسعر الذهب

حيث نلاحظ من الشكل البياني رقم (1) السابق أن السلوك الحركي للمنحنى السعري ينقسم إلى أربع مراحل هيكلية كبرى:

أ. مرحلة الركود السعري والاستقرار الأفقي (1990 – 2004)

اتسم السلوك السعري في هذه الحقبة بالاستقرار الممتد (Stationary Process)، حيث تحركت الأسعار ضمن نطاق عرضي ضيق أدنى مستوى 500 وحدة. يُعزى هذا الثبات الأكاديمي إلى انخفاض معدلات التضخم العالمي، والنمو الاقتصادي المستدام في الدول المتقدمة، مما حد من الجاذبية الاستثمارية للملاذات الآمنة.

ب. مرحلة الصعود الهيكلي الأول والتصحيح (2005 – 2018)

- النمو المتسارع (2005 – 2012): كسر الذهب اتجاهه الأفقي منطلقاً في موجة صعود قوية بلغت ذروتها الأولى قرب مستوى 1,800 وحدة. ارتبط هذا التسارع مباشرة بتداعيات الأزمة المالية العالمية عام 2008، واتجاه البنوك المركزية لسياسات التيسير الكمي وخفض الفائدة.
- الحركة التصحيحية (2013 – 2018): شهدت هذه الفترة حركة تصحيحية استقرت خلالها الأسعار فوق حاجز 1,000 وحدة بقليل، مدفوعة ببدء تعافي الاقتصاد الأمريكي ورفع أسعار الفائدة التدريجي.

ج. مرحلة الزخم التصاعدي وتجاوز المقاومة (2019 – 2023)

عادت الأسعار لتسجيل طفرة نمو جديدة، نجح المنحنى خلالها في اختراق مستويات مقاومة تاريخية والتذبذب العرضي فوق حاجز 2,000 وحدة. وتُفسر هذه الموجة أكاديمياً بزيادة مستويات عدم اليقين في السوق العالمي نتيجة الأزمات الصحية (جائحة كورونا) والاضطرابات الجيوسياسية في أوروبا.

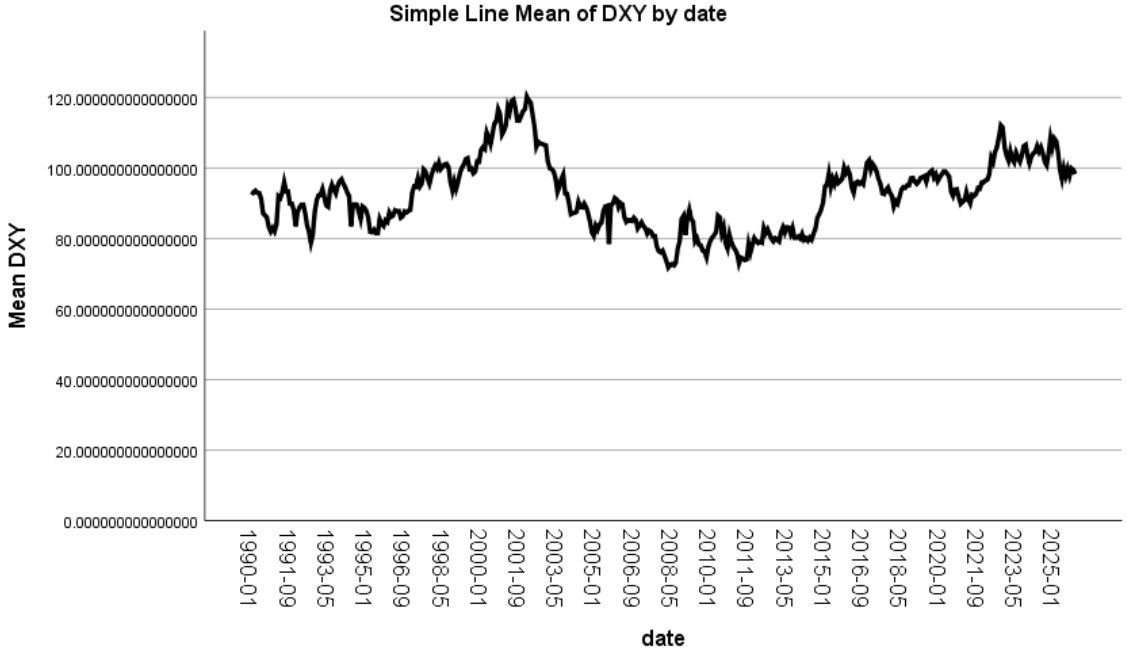
د. مرحلة الانفجار السعري الشبه رأسي (2024 – 2025)

تُمثل نهاية المنحنى صدمة سعرية إيجابية حيث اتخذ المنحنى اتجاهاً صعودياً حاداً وقريباً من الخط الرأسي متجاوزاً عتبة 4,000 وحدة. تعكس هذه القفزة القياسية تدافعاً مؤسسياً حاداً نحو التحوط، مدفوعاً بطلب مكثف من البنوك المركزية لتنويع الاحتياطيات النقدية ومخاوف التضخم التراكمي.

مؤشر الدولار الأمريكي:(DXY)

هو مقياس لقيمة الدولار الأمريكي مقابل سلة من العملات الرئيسية (اليورو، الين الياباني، الجنيه الإسترليني، الدولار الكندي، الكرونا السويدية، والفرنك السويسري). يعكس صحة الاقتصاد الأمريكي ويؤثر بشكل عكسي على أسعار الذهب في كثير من الأحيان.

الرسم البياني للسلسة الزمنية لمؤشر الدولار:



الشكل رقم (2) السلسة الزمنية لمؤشر الدولار

حيث نلاحظ من الشكل البياني رقم (2) بأن سلوك مؤشر (DXY) يتسم بطبيعة دورية تذبذبية، ويمكن تقسيم حركته التاريخية إلى أربع مراحل مفصلية:

أ. مرحلة التذبذب وضبط الاستقرار (1990 – 1995)

تحرك المؤشر في نطاق عرضي متذبذب بين مستويات 80 و100 نقطة. تعكس هذه الفترة تداعيات ركود عام 1990 في الولايات المتحدة، تلاها بدء دورة رفع أسعار الفائدة من قبل الفيدرالي عام 1994، مما خلق حالة من التوازن السعري في النطاق المتوسط للمؤشر.

ب. الطفرة الاقتصادية الصاعدة وفقاعة التكنولوجيا (1996 – 2002)

شهدت هذه الحقبة موجة صعود هيكلية قوية (Bull Market) دفعت بالمؤشر إلى تسجيل ذروته التاريخية الكبرى فوق مستوى 120 نقطة بين عامي 2001 و2002. ارتبط هذا القوة الفائقة للدولار بالتدفقات النقدية الضخمة نحو الأسواق الأمريكية خلال فقاعة دوت كوم (.com)، مدفوعة بمعدلات نمو اقتصادي مرتفعة وجاذبية أسعار الفائدة الأمريكية حينها.

ج. الدورة الهابطة الطويلة والأزمة المالية العالمية (2003 – 2014)

- الهبوط الهيكلي (2003 – 2007): دخل المؤشر في اتجاه هابط مستمر (Bear Trend) نتيجة العجز المزدوج (الموازنة والتجارة) في أمريكا وتخفيض الفائدة عقب انفجار فقاعة التكنولوجيا.
- القاع التاريخي (2008): سجل المؤشر أدنى مستوياته التاريخية دون 75 نقطة بالتزامن مع اندلاع الأزمة المالية العالمية، وتبني الفيدرالي لسياسة التيسير الكمي الصفرية.
- الاستقرار العرضي (2009 – 2014): تأرجح المؤشر في مستويات منخفضة (بين 75 و88 نقطة) مع استمرار ضخ السيولة في النظام المالي العالمي واقتصادات الأسواق الناشئة.

د. دورة تشديد السياسة النقدية والاضطرابات العالمية (2015 – 2025)

- القفزة الأولى (2015): اختراق قوي نحو الأعلى تجاوز مستوى 100 نقطة مع إنهاء برامج التيسير الكمي وبدء التلميح لرفع الفائدة الأمريكية.
- حقبة الجائحة والاضطرابات (2020 – 2021): تذبذب حاد تخلله هبوط مؤقت نتيجة ضخ السيولة الطارئة خلال أزمة كورونا، ليستقر المؤشر حول 90 نقطة.
- القمة الأخيرة الحادة (2022 – 2023): صعود صاروخي مفاجئ قارب مستوى 115 نقطة، مدفوعاً بأسرع دورة تشديد نقدي ورفع لأسعار الفائدة من الفيدرالي منذ عقود لمكافحة التضخم، إلى جانب جاذبيته كملاذ آمن إثر الحرب الروسية الأوكرانية.
- الاستقرار الختامي (2024 – 2025): تراجع نسبي متبوع بحركة عرضية متذبذبة أعلى مستويات 100 نقطة بقليل، تعكس بدء استقرار معدلات الفائدة وترقب الأسواق لتوجهات السياسة النقدية الجديدة.

الشبكات العصبية الاصطناعية:

هي أنظمة حوسبة مصممة لمحاكاة طريقة عمل الدماغ البشري في معالجة المعلومات. تتكون من عقد مترابطة تشبه الخلايا العصبية البيولوجية، وتتميز بقدرتها على التعلم من البيانات دون الحاجة إلى برمجة صريحة. **(إدلبي، ياسين. سريو، آية. ساكت، غسان (2021)).**

Multilayer Perceptron (MLP):

يعتبر MLP أحد أبسط وأشهر أنواع الشبكات العصبية، ويتكون من ثلاث طبقات رئيسية:

طبقة الإدخال :(Input Layer) تستقبل البيانات الأولية

طبقة مخفية :(Hidden Layer) تقوم بمعالجة البيانات واستخلاص الأنماط

طبقة الإخراج :(Output Layer) تنتج النتائج النهائية

دوال التنشيط:(Activation Functions)

(Hyperbolic Tangent) Tanh تستخدم في الطبقات المخفية وتنتج قيم بين −1 و 1

:Linear/Identity تستخدم في طبقات الإخراج للتنبؤ بقيم مستمرة

الإطار العملي:

الجدول رقم (1): الإحصاءات الوصفية لبيانات الدراسة

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
gold	432	191.300000000000	4357.10000000000000	994.488194444444800	752.658748052793300
DXY	432	71.8000000000000	120.200000000000000	92.4166435185185530	10.2141190930546800
Valid N (listwise)	432				

الجدول من إعداد الباحث اعتماداً على برنامج SPSS

يوضح الجدول رقم (1) السابق، الإحصاءات الوصفية الخصائص العامة لمتغيرات الدراسة، حيث بلغ عدد المشاهدات المستخدمة في التحليل (432) مشاهدة شهرية، ما يوفر قاعدة بيانات مناسبة لبناء نموذج تنبؤ باستخدام تقنيات الشبكات العصبية الاصطناعية. وقد بلغ الحد الأدنى لسعر الذهب (191.3) دولاراً للأونصة، بينما بلغ الحد الأعلى (4357.1) دولاراً، في حين وصل المتوسط الحسابي إلى نحو (994.49) دولاراً بانحراف معياري مرتفع بلغ (752.66). وتشير هذه النتائج إلى وجود تقلبات كبيرة في أسعار الذهب خلال فترة الدراسة، الأمر الذي يعكس تأثر الذهب بالأزمات الاقتصادية العالمية والتوترات الجيوسياسية وتغيرات السياسة النقدية.

أما بالنسبة لمؤشر الدولار الأمريكي، فقد بلغ متوسطه الحسابي (92.42) نقطة، مع حد أدنى بلغ (71.8) وحد أعلى بلغ (120.2)، بينما بلغ الانحراف المعياري (10.21)، وهو ما يدل على وجود تذبذبات ملحوظة في قوة الدولار الأمريكي خلال المدة المدروسة. ويعكس الارتفاع النسبي في قيم الانحراف المعياري وجود درجة عالية من التباين والتقلب داخل البيانات، وهو ما يجعل استخدام نماذج الشبكات العصبية الاصطناعية مناسباً، نظراً لقدرتها على التعامل مع العلاقات المعقدة وغير الخطية مقارنة بالنماذج الإحصائية التقليدية.

توزيع بيانات البحث:

الجدول رقم (2): توزيع بيانات البحث

Case Processing Summary

		N	Percent
Sample	Training	293	68.0%
	Testing	138	32.0%
Valid		431	100.0%

Excluded	0	
Total	431	

الجدول من إعداد الباحث اعتماداً على برنامج SPSS

يوضح هذا الجدول آلية توزيع بيانات الدراسة المستخدمة في بناء نموذج الشبكات العصبية الاصطناعية، حيث بلغ إجمالي عدد المشاهدات الصالحة للتحليل (431) مشاهدة شهرية حيث تم فقدان مشاهدة واحدة نتيجة إنشاء المتغيرات الزمنية المتأخرة والفروق الأولى. ما يعكس اكتمال قاعدة البيانات وخلوها من القيم المفقودة المؤثرة على عملية التقدير.

وقد جرى تقسيم البيانات إلى عينة تدريب (Training Sample) بلغت (293) مشاهدة وبنسبة (68%) من إجمالي البيانات، وعينة اختبار (Testing Sample) بلغت (138) مشاهدة بنسبة (32%). وتُستخدم عينة التدريب في تعليم النموذج واستخلاص الأنماط والعلاقات الكامنة بين المتغيرات، بينما تُستخدم عينة الاختبار للتحقق من كفاءة النموذج وقدرته على التنبؤ ببيانات لم يسبق له التعامل معها أثناء مرحلة التدريب.

ويُعد هذا التقسيم مناسباً في تطبيقات الذكاء الاصطناعي والتعلم الآلي، إذ يحقق توازناً بين كفاءة التعلم ودقة الاختبار، كما يساعد في الحد من مشكلة الإفراط في التعلّم(Overfitting) ، والتي تحدث عندما يحفظ النموذج بيانات التدريب دون امتلاك قدرة حقيقية على التعميم والتنبؤ.

الجدول رقم (3): معلومات الشبكة العصبية

Network Information

Input Layer	Covariates	1	DXY
		2	LAGS(gold,1)
		3	DIFF(gold,1)
		4	LAGS(DXY,1)
		5	DIFF(DXY,1)
	Number of Units[a]		5
	Rescaling Method for Covariates		Standardized
Hidden Layer(s)	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1[a]		3
	Activation Function		Hyperbolic tangent
Output Layer	Dependent Variables	1	gold
	Number of Units		1
	Rescaling Method for Scale Dependents		Standardized
	Activation Function		Identity
	Error Function		Sum of Squares

a. Excluding the bias unit

المصدر: من إعداد الباحث اعتماداً على برنامج SPSS

يوضح الجدول الخصائص الفنية والبنية المعمارية للشبكة العصبية الاصطناعية المستخدمة في الدراسة، حيث تضمنت طبقة الإدخال خمس متغيرات مستقلة شملت مؤشر الدولار الأمريكي(DXY) ، والقيمة المتأخرة لسعر الذهب، والفروق الأولى لسعر الذهب، إضافة إلى القيمة المتأخرة لمؤشر الدولار والفروق الأولى له.

ويشير استخدام القيم المتأخرة (Lagged Variables) والفروق الأولى (First Differences) إلى اعتماد الدراسة على منهجية السلاسل الزمنية، بهدف تمكين النموذج من التقاط التأثيرات الزمنية والتغيرات الديناميكية قصيرة الأجل في الأسواق المالية، وهو ما يعزز القدرة التنبؤية للنموذج.

كما احتوى النموذج على طبقة مخفية واحدة مكونة من ثلاث عقد عصبية، وهي المسؤولة عن معالجة البيانات واكتشاف العلاقات غير الخطية بين المتغيرات. ويُعد اختيار عدد محدود من العقد المخفية أمراً مهماً لتجنب تعقيد النموذج بصورة مبالغ فيها، مع الحفاظ على كفاءته في التعلّم.

وقد استخدمت الشبكة دالة التنشيط Hyperbolic Tangent في الطبقة المخفية، والتي تتميز بقدرتها على تمثيل العلاقات المعقدة وغير الخطية داخل البيانات الاقتصادية والمالية، بينما تم استخدام دالة Identity في طبقة الإخراج لكون المتغير التابع (سعر الذهب) متغيراً كمياً مستمراً.

كذلك تم اعتماد أسلوب التقييس المعياري (Standardization) للمتغيرات قبل إدخالها إلى النموذج، وذلك بهدف توحيد مقاييس البيانات وتقليل تأثير الفروقات الكبيرة بين القيم، الأمر الذي يساهم في تسريع عملية التعلم وتحسين استقرار النموذج أثناء التدريب.

سادسًا: تقييم أداء النموذج الموسع

الجدول رقم (4): تقييم أداء النموذج

Model Summary

Training	Sum of Squares Error	.200
	Relative Error	.001
	Stopping Rule Used	1 consecutive step(s) with no decrease in error[a]
	Training Time	0:00:00.02
Testing	Sum of Squares Error	.164
	Relative Error	.002

Dependent Variable: gold

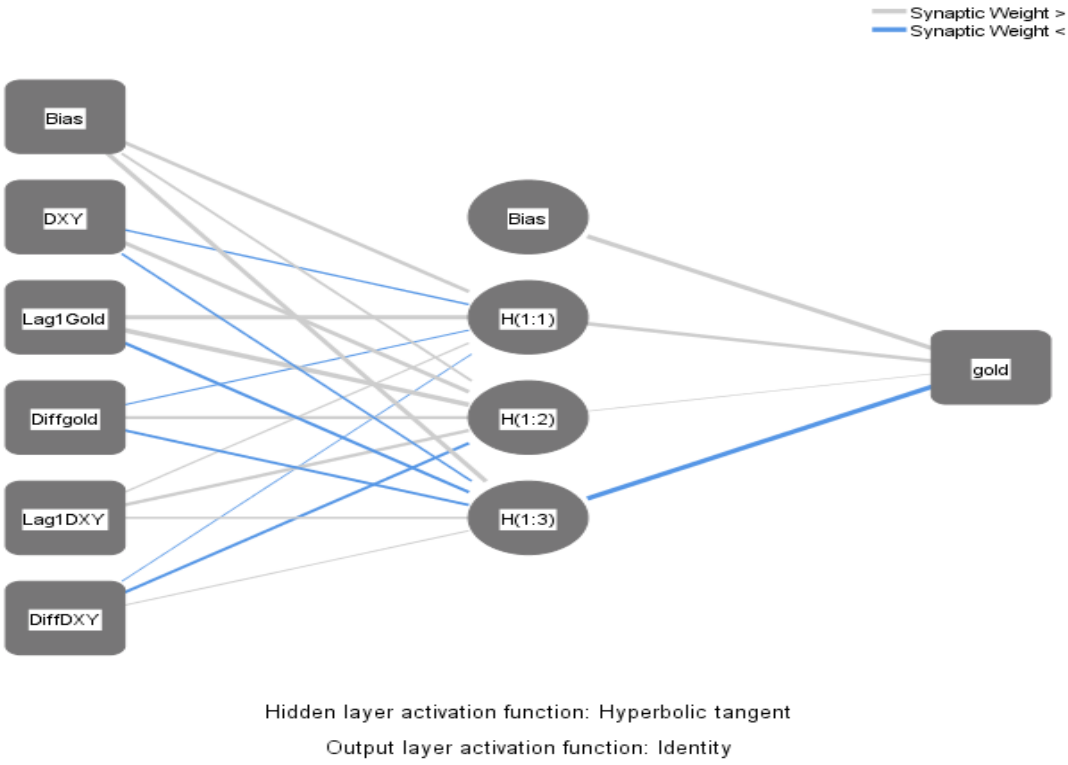
a. Error computations are based on the testing sample.

المصدر: من إعداد الباحث اعتماداً على برنامج SPSS

يبين الجدول مؤشرات تقييم أداء نموذج الشبكات العصبية الاصطناعية، والتي تعكس مستوى كفاءة النموذج في تفسير وتحليل بيانات الدراسة. فقد بلغ مجموع مربعات الخطأ (Sum of Squares Error) لعينة التدريب (0.200)، في حين بلغ لعينة الاختبار (0.164)، وهي قيم منخفضة تشير إلى محدودية الفجوة بين القيم الحقيقية والقيم المتنبأ بها بواسطة النموذج.

كما أظهرت النتائج انخفاضاً كبيراً في قيمة الخطأ النسبي(Relative Error) ، حيث بلغت (0.001) لعينة التدريب و(0.002) لعينة الاختبار، وهي قيم تقترب كثيراً من الصفر، مما يدل على تمتع النموذج بدرجة عالية جداً من الدقة التنبؤية والكفاءة الإحصائية.
ويلاحظ أيضاً أن الفرق بين خطأ التدريب وخطأ الاختبار محدود للغاية، وهو مؤشر مهم على قدرة النموذج على التعميم وعدم وقوعه في مشكلة الإفراط في التعلّم(Overfitting) ، إذ حافظ النموذج على مستوى أداء مرتفع حتى عند اختباره على بيانات جديدة لم تُستخدم أثناء التدريب.
كما يوضح الجدول أن عملية التدريب توقفت بعد خطوة واحدة دون انخفاض إضافي في الخطأ، وهو ما يشير إلى وصول النموذج إلى حالة الاستقرار وتحقيق أفضل أداء ممكن وفقاً لبنية الشبكة المستخدمة.
وبناءً على هذه النتائج يمكن الاستنتاج أن نموذج الشبكات العصبية المستخدم يتمتع بقدرة عالية على تفسير العلاقة بين مؤشر الدولار وأسعار الذهب، كما يمتلك كفاءة مرتفعة في التنبؤ بتحركات الذهب المستقبلية.

يوضع الشكل مخطط القيمة الحقيقية مقابل المتوقعة



الشكل رقم (3) مخطط الشبكة العصبية

يوضح الشكل رقم (3) السابق، البنية الهيكلية لنموذج الشبكات العصبية الاصطناعية المستخدم في الدراسة، حيث تتكون الشبكة من طبقة إدخال تضم خمس متغيرات مستقلة تمثلت في مؤشر الدولار، والقيم المتأخرة والفروق الأولى لكل من الذهب والدولار، بالإضافة إلى طبقة مخفية واحدة تحتوي على ثلاث عقد عصبية، ثم طبقة إخراج تضم المتغير التابع المتمثل في سعر الذهب.

وتوضح الخطوط الرابطة بين العقد الأوزان التشابكية (Synaptic Weights) التي تعكس قوة واتجاه العلاقة بين المتغيرات، حيث تشير الخطوط الرمادية إلى الأوزان الموجبة، بينما تشير الخطوط الزرقاء إلى الأوزان السالبة. كما يلاحظ أن بعض المتغيرات تمتلك تأثيراً أقوى على المتغير التابع نتيجة سماكة الروابط بينها وبين العقد العصبية.

وقد استخدمت الشبكة دالة التنشيط Hyperbolic Tangent في الطبقة المخفية، لما تتمتع به من قدرة على تمثيل العلاقات غير الخطية المعقدة، في حين استخدمت دالة Identity في طبقة الإخراج لكون المتغير التابع متغيراً كمياً مستمراً. ويعكس الشكل قدرة النموذج على معالجة العلاقات المتشابكة بين المتغيرات الاقتصادية وتحسين دقة التنبؤ بأسعار الذهب.

النتائج:

1- أظهرت نتائج الدراسة وجود علاقة ديناميكية معقدة وغير خطية بين مؤشر الدولار الأمريكي وأسعار الذهب خلال الفترة الممتدة بين عامي (1990–2025)، حيث تبين أن تحركات مؤشر الدولار تؤثر بصورة مباشرة وغير مباشرة في الاتجاهات السعرية للذهب، مع اختلاف قوة التأثير عبر الزمن تبعاً للظروف الاقتصادية والمالية العالمية.

2- أثبت نموذج Multilayer Perceptron المستخدم في الدراسة كفاءة مرتفعة في تحليل السلاسل الزمنية المالية، إذ تمكن من التقاط الأنماط الخفية والعلاقات غير الخطية التي يصعب على النماذج الإحصائية التقليدية تفسيرها بدقة.

3- بينت نتائج تقييم الأداء انخفاض قيم الخطأ النسبي لكل من عينة التدريب وعينة الاختبار، حيث بلغت (0.001) و(0.002) على التوالي، مما يدل على تمتع النموذج بدرجة عالية من الدقة التنبؤية والقدرة على محاكاة التحركات الفعلية لأسعار الذهب.

4- أظهرت النتائج أن الفجوة المحدودة بين نتائج التدريب والاختبار تعكس قدرة النموذج على التعميم وعدم اقتصاره على حفظ بيانات التدريب فقط، الأمر الذي يشير إلى انخفاض احتمالية تعرض النموذج لمشكلة الإفراط في التعلم.(Overfitting)

5- أظهرت الدراسة أن الشبكات العصبية الاصطناعية قادرة على التعامل بكفاءة مع البيانات الاقتصادية ذات التذبذب المرتفع وعدم الاستقرار، وهو ما يجعلها ملائمة لتحليل الأسواق المالية العالمية التي تتسم بسرعة التغير وتعقيد العلاقات بين المتغيرات.

التوصيات:

1- التوسع في استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في الدراسات الاقتصادية والمالية، نظراً لقدرتها العالية على تحليل البيانات الضخمة واكتشاف العلاقات غير الخطية بين المتغيرات.

2- اعتماد نماذج الشبكات العصبية الاصطناعية ضمن المؤسسات المالية وشركات الاستثمار والبنوك المركزية للمساعدة في بناء توقعات مستقبلية أكثر دقة للأسواق المالية وأسعار الأصول.

3- توجيه المستثمرين إلى عدم الاعتماد على المؤشرات التقليدية فقط عند اتخاذ القرارات الاستثمارية، والاستفادة من النماذج الذكية الحديثة التي توفر تقديرات أكثر دقة للمخاطر والعوائد المستقبلية.

المراجع العربية:

1. **الجهني، أ. (2020).** "**تنبؤ أسعار الذهب باستخدام الشبكات العصبية الاصطناعية: دراسة قياسية للفترة (2000–2019)**". *مجلة العلوم الاقتصادية والإدارية*، 26(2)، 45–67. المملكة العربية السعودية

2. **العتيبي، م.، والغامدي، ر. (2021).** "**دور مؤشر الدولار الأمريكي في تفسير تقلبات أسعار الذهب: نموذج انحدار غير خطي**". *مجلة الدراسات المالية والمصرفية*، 15(3)، 112–130. المملكة العربية السعودية

3. **إدلبي، ياسين. سريو، آية. ساكت، غسان (2023)** " **التنبؤ بتقلبات وأسعار المعادن باستخدام تقنيات الذكاء الاصطناعي**"، رسالة ماجستير غير منشورة، جامعة حلب

4. **إدلبي، ياسين. سريو، آية. ساكت، غسان (2021)** " **مقارنة بين تقنيات الذكاء الاصطناعي للتنبؤ بأسعار معدني الذهب والنحاس**، سلسلة العلوم الاقتصادية، مجلة بحوث جامعة حلب، العدد 44

المراجع الإنجليزية:

1- **Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998).** "**Forecasting with artificial neural networks: The state of the art**". *International Journal of Forecasting, 14*(1), 35-62.USA

2- **Yakubu, A. S., & Adewumi, A. O. (2020).** "**Gold price prediction using a multilayer perceptron neural network model with USDX and inflation as exogenous variables**". *Resources Policy, 68*, 101732.NEGERIA

3- **Adhikari, R., & Agrawal, R. K. (2013).** "**An introductory study on time series modeling and forecasting**". *arXiv preprint arXiv:1302.6613*.INDIA