

## پیش‌بینی قیمت طلای ۱۸ عیار با استفاده از تکنیک‌های یادگیری ماشین و یادگیری عمیق

علی اصغر میری<sup>۱</sup>، مصطفی خونیک<sup>۲\*</sup>، علی یگانه<sup>۳</sup>

<sup>۱</sup> گروه مهندسی صنایع و سیستم‌ها، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

<sup>۲\*</sup> گروه مهندسی صنایع و سیستم‌ها، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

<sup>۳</sup> گروه مهندسی صنایع و سیستم‌ها، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

ایمیل نویسنده مسئول: mo.khooniki@mail.um.ac.ir

### چکیده

در این تحقیق، هدف شناسایی و پیش‌بینی روند قیمت طلا ۱۸ عیار با استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق است. برای این منظور، از داده‌های روزانه قیمت طلا در بازار ایران طی سال‌های ۱۳۹۳ تا ۱۴۰۳ استفاده شده است. این داده‌ها شامل اطلاعات کندلی قیمت طلا شامل قیمت شروع، قیمت پایانی، بالاترین و پایین‌ترین قیمت طلا در هر روز بوده و به‌طور دقیق روند تغییرات روزانه قیمت را نشان می‌دهند. در این پژوهش تلاش شده است تا با استفاده از الگ‌های زمانی گذشته و همچنین قیمت روز جاری، پیش‌بینی دقیقی از قیمت روز بعدی طلا انجام شود. برای تحلیل و پیش‌بینی قیمت طلا، از مدل‌های مختلفی از جمله مدل‌های شبکه عصبی و یادگیری ماشین استفاده شد. نتایج حاصل از اجرای این مدل‌ها نشان داد که مدل SARIMAX دقیق‌ترین پیش‌بینی قیمت روز بعدی را در مقایسه با سایر مدل‌ها داشت. در این مطالعه همچنین به بررسی اثر برخی متغیرهای کلان اقتصادی مانند قیمت دلار، قیمت نفت برنت و شاخص کل بورس بر پیش‌بینی قیمت طلا پرداخته شد که نتایج نشان داد، این متغیرها نتوانسته‌اند اطلاعات مفیدی برای پیش‌بینی بهتر قیمت طلا به ارمغان بیاورند و عملکرد مدل‌هایی با متغیرهای کلان اقتصادی، ضعیف‌تر از مدل‌هایی شامل اطلاعات روزانه طلا بود. برای بهبود دقت پیش‌بینی‌ها، مدل‌های ترکیبی مانند ترکیب شبکه‌های عصبی LSTM و CNN و همچنین مدل‌های جایگزینی CNN نیز مورد استفاده قرار گرفتند. این مدل‌ها به‌ویژه در استخراج ویژگی‌های پیچیده‌تر از داده‌ها زمانی مفید بودند، اما بهترین عملکرد متعلق به مدل SARIMAX با لگ زمانی ۱ بود. در نهایت، برای ارزیابی قابلیت تعمیم مدل‌ها و دقت پیش‌بینی‌ها، نتایج به‌وسیله داده‌های جهانی قیمت انس طلا نیز بررسی شدند. این مقایسه نشان داد که نتایج پیش‌بینی با استفاده از داده‌های طلای ۱۸ عیار به‌طور مشابه به پیش‌بینی با داده‌های انس جهانی طلا بود و مدل SARIMAX همچنان بهترین عملکرد را در هر دو حالت ارائه داد.

**واژگان کلیدی:** پیش‌بینی قیمت طلا، مدل‌های شبکه عصبی، پیش‌بینی سری زمانی، مدل‌های هیبریدی.

## Forecasting the Price of 18-Carat Gold using Machine Learning and Deep Learning Techniques

Ali Asghar Miri<sup>1</sup>, Mostafa Khooniki<sup>\*2</sup>, Ali Yeganeh<sup>3</sup>

<sup>1</sup> Department of Industrial Engineering and Systems, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

<sup>\*2</sup> Department of Industrial Engineering and Systems, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

<sup>3</sup> Department of Industrial Engineering and Systems, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

Corresponding Author's Email: [mo.khooniki@mail.um.ac.ir](mailto:mo.khooniki@mail.um.ac.ir)

### Abstract

*In this study, the primary objective is to identify and forecast the price trend of 18-carat gold in the Iranian market using machine learning and deep learning algorithms. To this end, daily gold price data spanning the years 1393 to 1403 were utilized, including full candlestick-format information opening price, closing price, intraday high, and intraday low which accurately capture the day to day dynamics of gold price fluctuations. The forecasting framework was constructed based on lagged historical price values as well as the current day's price, aiming to generate precise predictions for next day's gold price. Several models from both classical machine learning and neural network families were implemented for analysis and prediction. The results of running these models showed that SARIMAX model had the most accurate prediction of next day's price compared to other models. This study examined the potential contribution of selected macroeconomic indicators including USD/IRR exchange rate, Brent crude oil price, and Tehran Stock Exchange overall index to improving forecast accuracy, which findings demonstrated that these variables could not provide useful information for better gold price forecasting, and performance of models with macroeconomic variables was weaker than models including gold's daily price data. To further enhance predictive accuracy, several hybrid deep learning architectures such as combined LSTM-CNN models and permutation-based CNN structures were also explored. These models proved particularly useful for extracting complex temporal patterns; however, but the best performance belonged to SARIMAX model with a time lag of 1. Finally, to assess model generalizability and robustness, forecasting outcomes were evaluated against global gold ounce price data. The comparative analysis showed consistent results: forecasting based on 18 carat domestic gold data closely mirrored predictions derived from global gold ounce prices, and SARIMAX remained the superior performer across both datasets.*

**Keywords:** Gold price forecasting, Neural network models, Time series prediction, Hybrid forecasting models.

## 1. مقدمه

طلا به عنوان یکی از ارزشمندترین فلزات در طول تاریخ نقشی محوری در اقتصاد، تجارت و فرهنگ جوامع ایفا کرده است. در میان انواع طلا، طلای ۱۸ عیار به دلیل ترکیب متعادل میان خلوص و استحکام به عنوان گزینه‌های کلیدی در صنعت جواهرسازی و سرمایه‌گذاری شناخته می‌شود. پیش‌بینی قیمت این فلز به ویژه در بازه‌های زمانی پر نوسان همواره برای فعالان بازار، سیاستگذاران اقتصادی و سرمایه‌گذاران حائز اهمیت بوده است. با این حال پیش‌بینی قیمت طلا به دلیل تأثیرپذیری از عوامل پیچیده‌ای همچون نوسانات بازار جهانی، تحولات ژئوپلیتیک، نرخ تورم، تقاضای صنعتی و رفتارهای سفته‌بازانه، به چالشی مهم تبدیل شده است [1].

در سالهای اخیر روشهای تحلیلی متنوعی برای مدلسازی سری‌های زمانی مالی توسعه یافته‌اند. مدل‌های کلاسیک آماری مانند مدل خودهمبسته یکپارچه میانگین متحرک<sup>۱</sup> به دلیل توانایی در شناسایی الگوهای خطی و فصلی، به‌طور گسترده در پیش‌بینی قیمت کالاها مورد استفاده قرار گرفته‌اند. از سوی دیگر، روش‌های یادگیری ماشین، نظیر ماشین بردار پشتیبان<sup>۲</sup> با تمرکز بر مدلسازی روابط غیرخطی، امکان تحلیل داده‌ها با ابعاد بالا را فراهم می‌کنند. در لایه پیشرفته‌تر معماری‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی<sup>۳</sup>، شبکه‌های حافظه کوتاه مدت بلندمدت<sup>۴</sup> و ترنسفورمرها با قابلیت استخراج ویژگی‌های پیچیده از داده‌های ترتیبی و توجه به وابستگی‌های بلندمدت، افق‌های جدیدی را در پیش‌بینی مالی گشوده‌اند. هر یک از این روشها مزایا و محدودیت‌های خاص خود را دارند [2].

برای نمونه LSTM در پردازش داده‌های وابسته به زمان عملکردی برجسته دارد، درحالی‌که ترنسفورمرها با مکانیزم توجه خود امکان مدلسازی روابط غیرهمجوار در سری‌های زمانی را بهبود بخشیده‌اند. هدف این مقاله، بررسی تطبیقی توانایی روش‌های یادشده در پیش‌بینی قیمت طلای ۱۸ عیار با استفاده از داده‌های تاریخی قیمت، شاخص‌های اقتصادی کلان و سایر متغیرهای مؤثر است. با توجه به ماهیت پویا و چندبعدی بازار طلا، ترکیب رویکردهای سنتی و نوین می‌تواند به درک جامع‌تری از روندهای آتی بیانجامد. در این راستا، پژوهش حاضر به مقایسه دقت و کارایی مدل‌های ARIMA، SVR، CNN، LSTM و ترنسفورمرها می‌پردازد و نقش هریک را در کاهش خطای پیش‌بینی و افزایش قابلیت اطمینان نتایج تحلیل میکند. سپس با استفاده از رویکردهای ترکیبی برای بهبود مدل‌ها تلاش می‌کنیم. یافته‌های این مطالعه نه تنها به بهینه‌سازی استراتژیهای سرمایه‌گذاری کمک خواهد کرد، بلکه چارچوبی علمی برای ادغام روشهای مختلف در حوزه پیش‌بینی مالی ارائه میدهد.

ساختار این مقاله به این شرح خواهد بود در بخش دوم، مبانی نظری و پیشینه پژوهش مرور می‌شود. بخش سوم به توصیف داده‌ها و روش شناسی اختصاص دارد. بخش چهارم به ارائه نتایج و تحلیل مقایسه مدل‌ها می‌پردازد و در نهایت، بخش پنجم نتیجه‌گیری و پیشنهادات آتی را شامل می‌شود.

## 2. پیشینه پژوهش

در سال‌های اخیر، توجه به طلا به عنوان یک ابزار سرمایه‌گذاری، به‌ویژه به‌دلیل ویژگی‌های آن در تنوع دارایی‌ها، پوشش ریسک و پناهگاه امن، افزایش یافته است. این افزایش علاقه به طلا در شرایطی است که اقتصادهای جهانی تحت فشارهای متعدد، از جمله بحران‌های اقتصادی، نوسانات

<sup>1</sup> ARIMA

<sup>2</sup> Support Vector Regression (SVR)

<sup>3</sup> Convolutional Neural Network (CNN)

<sup>4</sup> LSTM

ارزی و مشکلات ژئوپولیتیکی قرار دارند. با این حال تحلیل دقیق و پیش‌بینی پرمیوم ریسک طلا و عوامل مؤثر بر آن هنوز کمتر مورد توجه قرار گرفته است. در حالی که بیشتر تحقیقات در این زمینه بر روی تحلیل خود قیمت طلا متمرکز بوده‌اند، کمتر به پیچیدگی‌های مرتبط با تحلیل ریسک‌های مربوط به آن پرداخته شده است. در این راستا، مطالعات متعددی انجام شده که به‌طور ویژه به مسئله پرمیوم ریسک طلا پرداخته‌اند. مدل‌های پیش‌بینی قیمت طلا در ابتدا بر اساس روش‌های ساده و تک‌متغیره مانند رگرسیون خطی طراحی شدند که تلاش داشتند با استفاده از عواملی مانند نرخ تورم، نرخ ارز و عرضه پول، قیمت آینده طلا را پیش‌بینی کنند [3].

این مدل‌ها به دلیل سادگی قادر به شبیه‌سازی پیچیدگی‌های بازار طلا و خصوصیات زمانی و غیرخطی این بازار نبودند. در واقع مدل‌های خطی نتوانستند عوامل متعددی که می‌توانند بر قیمت طلا تأثیر بگذارند، از جمله نوسانات اقتصادی جهانی و تحولات سیاسی را به‌طور دقیق در نظر بگیرند. در ادامه با توجه به نیاز تحلیل دقیق‌تر و جامع‌تر، پژوهشگران به سراغ مدل‌های پیشرفته‌تری مانند شبکه‌های عصبی و یادگیری ماشین رفتند. مطالعه مروری ده‌ساله‌ای نشان می‌دهد که تکنیک‌های یادگیری ماشین شامل ماشین بردار پشتیبان، جنگل تصادفی، درخت تصمیم و شبکه‌های عصبی، به‌صورت گسترده در پیش‌بینی قیمت طلا به‌کار رفته و عملکرد بهتری نسبت به روش‌های کلاسیک ارائه کرده‌اند [4].

اولین استفاده‌های جدی از شبکه‌های عصبی برای پیش‌بینی قیمت طلا توسط Grudnitski و Osburn (1993) صورت گرفت که این رویکرد زمینه‌ساز توسعه بیشتر استفاده از تکنیک‌های هوش مصنوعی و یادگیری ماشین برای پیش‌بینی دقیق‌تر قیمت طلا شد. برخی از مطالعات نشان داده‌اند که استفاده از شبکه‌های عصبی چرخشی<sup>5</sup> نسبت به مدل‌های پیش‌بینی خطی و شبکه‌های عصبی پیش‌رو<sup>6</sup>، دقت بالاتری در پیش‌بینی قیمت طلا دارد [5]. علاوه بر این پژوهشگران به دنبال استفاده از مدل‌های هیبریدی هستند که ترکیب چندین تکنیک مختلف را در خود جای دهند. این رویکرد نه تنها توانسته به بهبود دقت پیش‌بینی‌ها کمک کند بلکه توانسته است رفتارهای پیچیده و غیرخطی بازار طلا را به‌طور مؤثرتری مدل‌سازی کند. همچنین پژوهش‌های جدید مبتنی بر یادگیری عمیق نشان داده‌اند که مدل‌های DL حتی در شرایط بحرانی مانند پاندمی‌ها نیز قادرند الگوهای پنهان سری‌زمانی قیمت طلا را استخراج کرده و دقت پیش‌بینی را بهبود دهند [6].

یکی از موفق‌ترین مدل‌ها در این حوزه، مدل CNN-LSTM است که نشان داده‌شده است ترکیب لایه‌های LSTM و پیچشی می‌تواند خطای پیش‌بینی قیمت طلا را به‌طور چشمگیری کاهش دهد [7]. در این مدل‌ها شبکه عصبی پیچشی برای استخراج ویژگی‌ها و الگوهای پیچیده از داده‌ها و شبکه LSTM برای ذخیره اطلاعات زمانی و دینامیک‌های بلندمدت بازار استفاده می‌شود. در مطالعات دیگر به‌ویژه در مدل‌سازی پرمیوم ریسک طلا، عواملی مانند پرمیوم ریسک و ریسک جهش قیمت به‌عنوان مهم‌ترین عوامل تأثیرگذار شناسایی شدند [8]. در مطالعه‌ای، نشان داده‌شد که متغیرهایی مانند اسپرد پیش‌فرض<sup>7</sup> به‌طور مستقیم بر پیش‌بینی پرمیوم ریسک طلا تأثیر دارند [9]. در این زمینه، پژوهشگران به استفاده از داده‌های کلان و ترکیب آن با روش‌های یادگیری ماشین توجه کرده‌اند. این رویکرد جدید نشان داده است که می‌تواند به شبیه‌سازی استراتژی‌های آربیتراژ مالی با استفاده از مجموعه‌ای از پیش‌بینی‌ها کمک کند. در یک چارچوب پیشرفته‌تر، ادغام همزمان داده‌های کلان اقتصادی، متغیرهای مالی و حتی داده‌های احساسات بازار در مدل‌های ترکیبی کلاسیک و هوشمند توانسته است دقت پیش‌بینی قیمت طلا را به‌طور قابل توجهی ارتقا دهد [10]. در واقع استفاده از داده‌های کلان و روش‌های یادگیری ماشین توانسته است به شبیه‌سازی رفتار بازار در شرایط مختلف و طراحی استراتژی‌های بهینه برای سرمایه‌گذاران کمک کند [11,12]. به عنوان نمونه، مدل‌های هیبریدی مبتنی بر LSTM-

<sup>5</sup> RNN

<sup>6</sup> Feed-forward Neural Networks

<sup>7</sup> Default Spread


Autoencoder نیز معرفی شده‌اند که با فشرده‌سازی داده و استخراج ویژگی‌های عمیق، ساختارهای زمانی پیچیده قیمت طلا را با دقت بیشتری مدل‌سازی می‌کنند [13].

در زمینه تخمین پرمیوم ریسک، پژوهش‌هایی نیز در راستای استفاده از روش‌های یادگیری ماشین به‌ویژه در تحلیل پرمیوم ریسک سهام، اوراق قرضه و صندوق‌های پوشش ریسک انجام شده است [14-16]. در همین راستا، مدل‌های مبتنی بر یادگیری عمیق ویژه سری‌زمانی نیز پیشنهاد شده‌اند که در تحلیل نوسانات و روندهای میان‌مدت قیمت طلا عملکرد قابل توجهی نشان داده‌اند [17]. در یکی از این تحقیقات، عملکرد پیش‌بینی پرمیوم ریسک طلا با استفاده از چندین الگوریتم یادگیری ماشین و مجموعه‌ای از پیش‌بین‌ها ارزیابی شد. در این مطالعه الگوریتم‌های مختلفی همچون روش‌های منظم‌سازی برای رگرسیون خطی (Ridge, LASSO, و Elastic Net)، روش‌های تصمیم‌گیری نظیر جنگل‌های تصادفی و درخت‌های رگرسیون تقویت‌شده و همچنین شبکه‌های عصبی مورد بررسی قرار گرفتند [18].

مطالعات مقایسه‌ای جدید نیز نشان داده‌اند که استفاده از چندین مدل یادگیری ماشین از جمله نزدیکترین همسایگی، ماشین بردار پشتیبان، جنگل تصادفی و مدل‌های درختی می‌تواند چشم‌انداز دقیق‌تری از رفتار قیمتی طلا ارائه دهد [19]. نتایج این پژوهش نشان داد که ترکیب پیش‌بینی‌ها معمولاً عملکرد بهتری نسبت به مدل‌های پیش‌بینی تک‌بعدی دارد. همچنین، مطالعات مشابهی در زمینه پیش‌بینی بازده‌های طلا و سهام از مدل‌های خطی نشان داده‌اند که استفاده از چندین پیش‌بین به‌طور همزمان ممکن است به بهبود عملکرد پیش‌بینی‌ها منجر شود. در نهایت، باید اشاره کرد که هرچند ترکیب چندین روش پیش‌بینی می‌تواند دقت مدل‌ها را بهبود بخشد، در برخی از موارد استفاده همزمان از مجموعه‌ای وسیع از پیش‌بین‌ها، به‌ویژه زمانی که داده‌ها به‌طور دقیق مدل‌سازی نمی‌شوند، به بهبود قابل توجهی در عملکرد پیش‌بینی منتهی نخواهد شد [20]. بنابراین نیاز به توجه به جزئیات مدل‌سازی و انتخاب بهینه پیش‌بینی‌ها برای دستیابی به بهترین نتایج پیش‌بینی همچنان احساس می‌شود.

### 3. توصیف داده‌ها و روش‌شناسی پژوهش

در این پژوهش از سری زمانی داده‌های قیمت طلای ۱۸ عیار در بازه زمانی ۱۳۹۳/۹/۱۲ تا ۱۴۰۳/۹/۱۲ استفاده شده است. این داده‌ها از سایت TGJU استخراج شده‌اند و شامل ستون‌های تاریخ، قیمت باز شدن، بالاترین قیمت، پایین‌ترین قیمت و قیمت پایانی هستند. در واقع این داده‌ها مربوط به اطلاعات کندلی قیمت روزانه طلا بوده‌است. یک کندل مطابق شکل (1) تعریف می‌شود.



شکل (1): نمونه کندل‌های صعودی و نزولی

هدف این مطالعه، پیش‌بینی قیمت روز بعد طلا با بهره‌گیری از روش‌های مختلف یادگیری ماشین و یادگیری عمیق شامل آریمای ماشین بردار پشتیبان، LSTM، CNN و ترنسفورمر و روش‌های ترکیبی است. پیش از اعمال مدل‌ها، داده‌ها به‌طور کامل پیش‌پردازش شدند. این مرحله

شامل بررسی مقادیر گم‌شده، حذف داده‌های نامعتبر، نرمال‌سازی و تفاضل‌گیری برای حذف روند و ایستا کردن سری زمانی بود. داده‌ها سپس به دو بخش آموزش (۸۰٪) و آزمون (۲۰٪) تقسیم شدند. قابل ذکر است، در تمامی روش‌ها برای تعیین پارامترهای اصلی از روش اعتبارسنجی متقاطع K-Fold با  $CV=5$  استفاده شده است.

برای ارزیابی عملکرد مدل‌ها، از معیارهای ریشه میانگین مربعات خطا<sup>۸</sup>، میانگین مطلق خطا<sup>۹</sup>، میانگین درصدی مطلق خطا<sup>۱۰</sup>، ضریب تعیین<sup>۱۱</sup>، معیار اطلاعات آکائیک<sup>۱۲</sup> و معیار اطلاعات بیزین<sup>۱۳</sup> استفاده شد. این معیارها توانایی مدل‌ها در توضیح واریانس داده‌ها، میزان خطای پیش‌بینی و میانگین اختلاف بین مقادیر واقعی و پیش‌بینی‌شده را ارزیابی می‌کنند. نتایج این ارزیابی‌ها به صورت مقایسه‌ای ارائه شده‌اند تا بهترین روش برای پیش‌بینی قیمت طلای ۱۸ عیار شناسایی شود.

#### 4. پیاده‌سازی مدل‌های پیش‌بینی‌کننده

در این بخش، ۹ رویکرد متفاوت برای پیش‌بینی قیمت روز آتی طلای ۱۸ عیار شرح داده می‌شود. هر یک از این مدل‌ها با استفاده از داده‌های آموزشی برازش داده شده و سپس عملکرد آن‌ها با استفاده از داده‌های تست با معیارهای مختلف ارزیابی شده است.

##### 4.1. مدل آریما

مدل  $ARIMA^{14}$ ، یکی از روش‌های پایه‌ای و قدرتمند در تحلیل سری‌های زمانی است. این مدل با ترکیب سه مؤلفه خودهمبسته (AR)، تفاضل‌گیری (I) و میانگین متحرک (MA)، قادر است روندها، الگوهای فصلی و وابستگی‌های زمانی موجود در داده‌ها را مدل‌سازی کند. در پیش‌بینی قیمت طلا، که تحت تأثیر عواملی چون نوسانات بازار، تحولات اقتصادی و تقاضای جهانی قرار دارد،  $ARIMA$  می‌تواند با شناسایی الگوهای خطی در داده‌های تاریخی، پیش‌بینی‌های کوتاه‌مدت نسبتاً دقیقی ارائه دهد. به دلیل ماهیت غیرخطی و پویای بازار این مدل در مواجهه با تغییرات ناگهانی یا روابط پیچیده‌تر با محدودیت‌هایی روبه‌رو است. نمودار سری زمانی قیمت پایانی طلا پس از پردازش در شکل (2) نمایش داده شده است.

<sup>8</sup> RMSE

<sup>9</sup> MAE


<sup>10</sup> MAPE

<sup>11</sup>  $R^2$

<sup>12</sup> AIC

<sup>13</sup> BIC

<sup>14</sup> Auto Regressive Integrated Moving Average (ARIMA)



شکل (2) : نمودار مربوط به قیمت پایانی طلا


بر اساس نمودار شکل (2)، سری زمانی قیمت طلا ایستا به نظر نمی‌رسد و دارای روند است. برای ایستا کردن سری زمانی، از تفاضل‌گیری استفاده می‌شود. در این روش تغییرات متوالی قیمت‌ها محاسبه می‌شود تا روند حذف گردد. پس از اعمال تفاضل‌گیری، برای بررسی ایستایی سری، آزمون دیکی فولر<sup>15</sup> اجرا شد که نتایج آن در جدول (1) ارائه شده است.

جدول (1) : نتایج آزمون دیکی فولر پس از یک‌بار تفاضل‌گیری

| مقدار                   | شاخص               |
|-------------------------|--------------------|
| -8.823                  | آمار آزمون $ADF$   |
| $1.850 \times 10^{-14}$ | مقدار $p$ -value   |
| -3.432                  | مقدار بحرانی (1%)  |
| -2.862                  | مقدار بحرانی (5%)  |
| -2.567                  | مقدار بحرانی (10%) |


بر اساس نتایج آزمون دیکی فولر، مقدار  $p$ -value تقریباً صفر بوده که به‌طور قابل توجهی کوچک‌تر از سطح معنی‌داری 0.05 است. در نتیجه، فرض صفر مبنی بر وجود ریشه واحد رد می‌شود و سری زمانی قیمت طلا ایستا تشخیص داده می‌شود. شکل (3) روند قیمت طلا پس از اعمال تفاضل‌گیری را نمایش می‌دهد.

<sup>15</sup> Dickey-Fuller Test



شکل (3): نمودار مربوط به قیمت پایانی طلا پس از یکبار تفاضل‌گیری

برای تعیین مقادیر بهینه مرتبه خودرگرسیون  $(p)$  و مرتبه میانگین متحرک  $(q)$  در  $ARMA$ ، نمودارهای  $ACF^{16}$  و  $PACF^{17}$  مطابق شکل (4) ترسیم شدند. این نمودارها امکان بررسی روابط خود همبستگی در داده‌ها را فراهم کرده و بر اساس آن می‌توان تعداد مناسب تأخیر را برای مدل انتخاب کرد.




شکل (4): نمودار مربوط به  $ACF$  و  $PACF$

<sup>16</sup> Autocorrelation Function

<sup>17</sup> Partial Autocorrelation Function

در نمودارهای ACF و PACF مشاهده می شود که پس از لگ اول، کاهش ناگهانی و قابل توجهی در همبستگی مشاهده می شود. این الگو نشان می دهد که سری زمانی عمدتاً به یک تأخیر اولیه وابسته است و پس از آن اثر خودرگرسیون و میانگین متحرک به طور چشمگیری کاهش می یابد. در نتیجه، بهترین مقادیر برای پارامترهای مدل ARMA برابر با  $p=1$  و  $q=1$  تعیین شد. برای بهبود عملکرد و بهره گیری از متغیرهای اثرگذار مانند قیمت آغازین، بیشترین و کمترین قیمت، از مدل SARIMAX استفاده شد تا پیش بینی دقیق تری حاصل شود. نمودار شکل (5)، عملکرد مدل بر روی داده های آموزش و آزمون را نشان می دهد.




شکل (5): نمودار پیش بینی داده های یادگیری و آزمون در مقایسه با داده های واقعی

مدل پیشنهادی عملکرد کلی خود را در پیش بینی تغییرات قیمت ها نشان می دهد. هرچند این مدل قادر به پیش بینی دقیق نوسانات شدید قیمت در برخی مقاطع نبوده است، اما به طور کلی نتایج حاصل از آن حاکی از عملکرد قابل قبول و رضایت بخشی می باشد. ارزیابی مدل روی داده های آزمون انجام شده و نتایج آن در جدول (2) ذکر شده است.

جدول (2): نتایج نهایی مدل SARIMAX براساس داده های آزمون

| شاخص  | مقدار     |
|-------|-----------|
| RMSE  | 148737.69 |
| MAE   | 87038.39  |
| MAPE  | 0.3430    |
| $R^2$ | 0.9997    |
| AIC   | 60964.68  |
| BIC   | 60999.76  |

در شکل (6)، پیش بینی های داده های آزمون، با استفاده از تبدیل برگشتی به حالت اولیه (بدون تفاضل) بازگشت داده شدند. تا نتایج به صورت واقعی و مطابق با داده های اولیه نمایش یابند.



شکل (6) : نمودار مقادیر واقعی و مقادیر پیش‌بینی شده داده‌های آزمون براساس مدل SARIMAX

نتایج نشان می‌دهد که مدل SARIMAX در پیش‌بینی قیمت پایانی روز بعد تلا عملکرد مطلوبی داشته و توانسته است نوسانات بازار و روند کلی را به خوبی شبیه‌سازی کند. ارزیابی با معیارهای مختلف از جمله RMSE و MAE بیانگر دقت بالای مدل است.


## 4.2. مدل ماشین بردار پشتیبان

مدل ماشین بردار پشتیبان به عنوان یکی از روش‌های قدرتمند یادگیری ماشین، قادر است الگوهای پیچیده موجود در داده‌های تاریخی را شناسایی کرده و به‌ویژه در شرایط نوسانات شدید بازار عملکرد مناسبی ارائه دهد. با این حال، انتخاب پارامترهای بهینه و کرنل مناسب از چالش‌های اصلی در استفاده از SVR محسوب می‌شود. در این مطالعه، برای پیش‌بینی قیمت پایانی طلای ۱۸ عیار، از کرنل خطی استفاده شد. در این مدل، قیمت‌های باز شدن، بیشترین، کمترین و پایانی طی ۲۵ روز گذشته به عنوان ویژگی‌ها در نظر گرفته شدند تا قیمت پایانی روز ۲۶ام پیش‌بینی شود. نتایج حاصل در جدول (3) نمایش داده شده و نمودار مقایسه قیمت واقعی و پیش‌بینی شده برای داده‌های آزمون در شکل (6) ارائه شده است.

جدول (3) : نتایج نهایی مدل رگرسیون پشتیبانی برداری با کرنل خطی براساس داده‌های آزمون

| مقدار      | شاخص           |
|------------|----------------|
| 1163594.92 | RMSE           |
| 836424.63  | MAE            |
| 0.0286     | MAPE           |
| 0.9738     | R <sup>2</sup> |
| 16040.14   | AIC            |
| 16053.20   | BIC            |

همان‌طور که در شکل (7) مشاهده می‌شود، مقایسه قیمت واقعی و پیش‌بینی شده نشان می‌دهد که مدل توانسته در داده‌های آموزش عملکرد مناسبی داشته باشد. همچنین، واضح است که مدل در داده‌های آزمون توانسته است تا روند کلی قیمت را دنبال کند، هرچند دقت پیش‌بینی در این بخش نسبت به داده‌های آموزش کاهش یافته است. به‌طور کلی، نتایج نشان می‌دهد که SVR با کرنل خطی قادر است الگوهای اصلی سری زمانی قیمت طلا را شناسایی کرده و روند کلی را بازتولید کند. با این حال، محدودیت‌هایی در پیش‌بینی دقیق نوسانات کوتاه‌مدت وجود دارد که می‌تواند ناشی از ماهیت غیرخطی بازار و حساسیت مدل به انتخاب ویژگی‌ها باشد.



شکل (7): نمودار قیمت و پیش‌بینی قیمت برای داده‌های آموزش و آزمون

### 4.3. مدل شبکه عصبی LSTM


مدل LSTM یکی از انواع شبکه‌های عصبی بازگشتی است که توانایی یادگیری وابستگی‌های بلندمدت در داده‌ها را دارد. این مدل می‌تواند با استفاده از واحدهای حافظه ویژه، اطلاعات مهم را برای مدت طولانی حفظ کرده و مشکل کاهش گرادینان در RNN‌های سنتی را برطرف سازد. کارایی مدل LSTM به عوامل متعددی وابسته است، از جمله انتخاب تعداد لایه‌ها و واحدهای حافظه، تنظیم نرخ یادگیری، استفاده از تکنیک‌های جلوگیری از بیش‌برازش مانند Dropout، پیش‌پردازش مناسب داده‌ها و تایم‌استپ بهینه برای ورودی‌ها. بر اساس تحلیل‌ها و آزمایش‌های تجربی، تایم‌استپ برابر با 2 در نظر گرفته شد. این انتخاب امکان شبیه‌سازی همزمان وابستگی‌های کوتاه‌مدت و بلندمدت را فراهم کرده و دقت پیش‌بینی‌ها را افزایش می‌دهد.

جدول (4)، جزئیات معماری مدل LSTM را نشان می‌دهد که شامل لایه‌ها، ابعاد خروجی و تعداد پارامترهای قابل یادگیری هر بخش است. این معماری به‌گونه‌ای طراحی شده تا بتواند وابستگی‌های کوتاه‌مدت و بلندمدت موجود در داده‌های سری زمانی قیمت طلا را به‌خوبی مدل‌سازی کند.

جدول (4) : معماری مدل LSTM

| Layer (Type)        | Output Shape   | Param   |
|---------------------|----------------|---------|
| lstm (LSTM)         | (None, 2, 400) | 648000  |
| dropout (Dropout)   | (None, 2, 400) | 0       |
| lstm_1 (LSTM)       | (None, 2, 400) | 1281600 |
| dropout_1 (Dropout) | (None, 2, 400) | 0       |
| lstm_2 (LSTM)       | (None, 400)    | 1281600 |
| dropout_2 (Dropout) | (None, 400)    | 0       |
| dense (Dense)       | (None, 1)      | 401     |

مدل طراحی شده شامل سه لایه متوالی LSTM با 400 واحد حافظه است که خروجی دو تایم استپ گذشته را برای پیش بینی استفاده می کنند. به منظور کاهش خطر بیش برآزش، پس از هر لایه LSTM یک لایه Dropout قرار داده شده است. مجموع پارامترهای قابل یادگیری مدل برابر با 3,213,801 بوده که شامل وزن ها و بایاس های لایه های LSTM و Dense می باشد. در نهایت، خروجی مدل به یک لایه Dense با تنها یک نورون ختم می شود که وظیفه پیش بینی قیمت پایانی روز بعد را بر عهده دارد و تعداد پارامترهای آن برابر با 401 است. فرآیند آموزش با داده های نرمال شده، با استفاده از بهینه ساز Adam و تنظیمات آموزشی شامل 50 دوره، اندازه دسته 10 و نرخ یادگیری 0.0001 آموزش داده شده است. خروجی مدل بر روی داده های آموزش و آزمون در شکل (8) نمایش داده شده است.



شکل (8) : نمودار مقادیر واقعی و مقادیر پیش بینی شده براساس مدل LSTM

بر اساس نمودار نشان داده شده در شکل (8)، مدل در اغلب دوره ها قادر به پیش بینی مناسب نوسانات و روند کلی قیمت ها بوده است. با این حال، در برخی بخش ها به ویژه در روزهای پایانی سری زمانی، کاهش دقت مشاهده می شود که بیانگر چالش مدل در پیش بینی تغییرات شدید و ناگهانی قیمت ها است. عملکرد کمی مدل بر اساس داده های آزمون، در جدول (5) گزارش شده است.

جدول (5) : نتایج نهایی مدل LSTM براساس داده های آزمون

| مقدار       | شاخص  |
|-------------|-------|
| 710183.09   | RMSE  |
| 505314.90   | MAE   |
| 50.97       | MAPE  |
| 0.9942      | $R^2$ |
| 6455786.16  | AIC   |
| 22506070.42 | BIC   |

به طور کلی، مدل LSTM توانسته است با دقت بالا روند کلی قیمت ها را پیش بینی کند و مقدار  $R^2$  نزدیک به 1 نشان دهنده توانایی مدل در توضیح واریانس داده هاست. با این حال، مقادیر نسبتاً بزرگ RMSE و MAE نشان می دهد که مدل در پیش بینی جزئیات نوسانات کوتاه مدت با محدودیت هایی مواجه است.

#### 4.4. مدل شبکه عصبی پیچشی

شبکه های عصبی پیچشی به دلیل توانایی در استخراج ویژگی های محلی و سلسله مراتبی، اخیراً در پیش بینی سری های زمانی مالی نیز مورد توجه قرار گرفته اند. در مسئله پیش بینی قیمت طلا، این شبکه ها با اعمال فیلترهای پیچشی بر داده های تاریخی (قیمت باز شدن، بیشترین، کمترین و پایانی)، قادر به شناسایی الگوهای کوتاه مدت و نوسانات پنهان هستند. در مدل توسعه یافته، ابتدا از لایه های Conv1D برای استخراج ویژگی ها استفاده شد. لایه اول شامل 64 فیلتر با کرنل سایز 2 و تابع فعال سازی ReLU بود که پس از آن لایه های MaxPooling1D و Dropout (0.1) قرار گرفتند. لایه دوم نیز شامل 50 فیلتر مشابه بود و خروجی آن پس از Flatten به دو لایه Dense داده شد: لایه اول با 64 نورون و ReLU و لایه دوم با یک نورون برای پیش بینی قیمت پایانی. مدل با بهینه ساز Adam و تابع خطای MSE آموزش داده شد. فرآیند آموزش با داده های نرمال شده، 100 ایپاک، اندازه بچ 16 و استفاده از Early Stopping برای جلوگیری از بیش برآش انجام گرفت. در جدول (8)، معماری مدل ترکیبی CNN نمایش داده شده است.

جدول (6) : معماری مدل CNN

| Layer (Type)        | Output Shape  | Param       |
|---------------------|---------------|-------------|
| Conv1D              | (None, 2, 64) | 576         |
| Dropout             | (None, 2, 64) | 0           |
| Conv1D              | (None, 2, 32) | 4128        |
| Dropout             | (None, 2, 32) | 0           |
| Dense               | (None, 50)    | 3250        |
| Dense               | (None, 1)     | 51          |
| <b>Total Params</b> |               | <b>8005</b> |

ورودی شبکه دارای ابعاد (578, 2, 4) است که شامل 578 رکورد با 4 ویژگی و پنجره زمانی 2 می باشد. مجموع پارامترهای قابل یادگیری برابر با 8,005 است. مقدار  $R^2 = 0.9927$  نشان دهنده دقت بالای مدل در پیش بینی است.

## بهبود با جایگشت زمانی

یکی از محدودیت های CNN، ناتوانی در شناسایی مستقیم توالی های زمانی می باشد. برای رفع این مشکل، کلیه جایگشت های ممکن از قیمت های  $n$  روز گذشته محاسبه و به عنوان ورودی به شبکه داده شد.

• تعداد جایگشت ها برابر با  $n!$


• تعداد ورودی ها برابر با  $n! \times 4$

این رویکرد امکان شناسایی روابط پیچیده تر و وابستگی های زمانی را فراهم کرده و موجب بهبود دقت پیش بینی شد. بهترین پنجره زمانی برابر با 4 تعیین گردید و ورودی شبکه ابعاد (24, 16, 578) داشت. مجموع پارامترها به 44,225 رسید و مقدار  $R^2 = 0.9937$  حاصل شد که نسبت به روش اولیه بهبود نشان می دهد. نتایج هر دو روش در جدول (7) درج شده است.

جدول (7): نتایج نهایی مدل CNN براساس داده های آزمون

| شاخص  | مقدار       |           |
|-------|-------------|-----------|
|       | بدون جایگشت | با جایگشت |
| RMSE  | 620069.77   | 574520.04 |
| MAE   | 410109.90   | 376891.41 |
| MAPE  | 0.0140      | 0.0128    |
| $R^2$ | 0.9927      | 0.9937    |
| AIC   | 38334.83    | 110780.22 |
| BIC   | 73233.22    | 303582.37 |

نتایج جدول (7) نشان می دهد که مدل CNN توانسته است روند کلی و نوسانات قیمت طلا را با دقت بالا پیش بینی کند. استفاده از جایگشت زمانی موجب بهبود عملکرد مدل و افزایش افق پیش بینی شده است. در شکل (9) مشاهده می شود که مدل علاوه بر دنبال کردن روند، توانسته مقادیر قیمت روز آتی را با دقت مناسبی بازتولید نماید.



شکل (9): داده های واقعی و پیش بینی برای شبکه CNN با جایگشت (راست) و بدون جایگشت (چپ)

#### 4.5. مدل شبکه عصبی ترنسفورمر

مدل های ترنسفورمر<sup>۱۸</sup> با تکیه بر مکانیزم توجه<sup>۱۹</sup>، انقلابی در پردازش داده های ترتیبی مانند متن و سری های زمانی ایجاد کرده اند. در حوزه پیش بینی قیمت طلا، این مدل ها با توانایی بی نظیر در شناسایی وابستگی های بلندمدت و غیرهمجوار در داده های گذشته، به عنوان یک رویکرد نوین مطرح شده اند. ترنسفورمرها با تحلیل همزمان تمامی نقاط زمانی، قادرند تأثیر عوامل اقتصادی کلان، شوک های بازار، یا رویدادهای ژئوپلیتیک را بر قیمت طلا، حتی در بازه های زمانی دور، مدل سازی کنند. در جدول (8)، معماری مدل ترنسفورمر ارائه شده است.

جدول (8): معماری مدل Transformer

| Layer (Type)             | Output Shape   | Param | Connected to                          |
|--------------------------|----------------|-------|---------------------------------------|
| input_layer_8            | (None, 2, 4)   | 0     | -                                     |
| multi_head_attention_8   | (None, 2, 4)   | 6,084 | input_layer_8, input_layer_8          |
| dropout_39               | (None, 2, 4)   | 0     | multi_head_attention_8                |
| layer_normalization_16   | (None, 2, 4)   | 8     | dropout_39                            |
| add_16                   | (None, 2, 4)   | 0     | layer_normalization_16, input_layer_8 |
| conv1d_24                | (None, 1, 256) | 2,304 | add_16                                |
| layer_normalization_17   | (None, 1, 4)   | 8     | conv1d_25                             |
| add_17                   | (None, 2, 4)   | 0     | layer_normalization_17, add_16        |
| multi_head_attention_9   | (None, 2, 4)   | 6,084 | add_17                                |
| dropout_42               | (None, 2, 4)   | 0     | multi_head_attention_9                |
| layer_normalization_18   | (None, 2, 4)   | 8     | dropout_42                            |
| add_18                   | (None, 2, 4)   | 0     | layer_normalization_18, add_17        |
| conv1d_26                | (None, 1, 256) | 2,304 | add_18                                |
| dropout_43               | (None, 1, 256) | 0     | conv1d_26                             |
| conv1d_27                | (None, 1, 4)   | 1,028 | dropout_43                            |
| layer_normalization_19   | (None, 1, 4)   | 8     | conv1d_27                             |
| add_19                   | (None, 2, 4)   | -     | layer_normalization_19, add_18        |
| global_average_pooling1d | (None, 2)      | -     | add_19                                |
| dense_16                 | (None, 128)    | 384   | global_average_pooling1d              |
| dropout_44               | (None, 128)    | -     | dense_16                              |
| dense_17                 | (None, 1)      | 129   | dense_16                              |
| <b>Total Params</b>      |                |       | <b>19,377</b>                         |

مدل ترنسفورمر به کار گرفته شده برای پیش بینی قیمت طلا با بهره گیری از توجه چندسری<sup>۲۰</sup> وابستگی های زمانی غیرهمجوار را شناسایی کرده و با بلوک های رمزگذار، ویژگی های مهم را استخراج می کند. ورودی مدل دارای ابعاد (578, 2, 4) شامل 578 رکورد، پنجره زمانی 2 و 4 ویژگی (بازشدن، بیشترین، کمترین، پایانی) است. مجموع پارامترهای قابل یادگیری 19,377 است. در معماری مدل ترنسفورمر، بخش FFN پیچشی شامل دو لایه Conv1D است که وظیفه پردازش و غنی سازی ویژگی های استخراج شده را بر عهده دارند. پس از آن، یک لایه

<sup>18</sup> Transformer

<sup>19</sup> Attention


<sup>20</sup> Multi-Head Attention

GlobalAveragePooling1D به منظور کاهش ابعاد و استخراج ویژگی‌های کلی به کار گرفته می‌شود. در نهایت، لایه‌های Dense و Dropout اضافه شده‌اند تا ضمن کاهش خطر بیش‌برازش، خروجی نهایی مدل با یک نورون تولید شود که پیش‌بینی قیمت پایانی روز بعد را ارائه می‌دهد.

مدل ترنسفورمر با برخورداری از دقت بالا ( $R^2=99.33\%$ ) توانسته است واریانس سری زمانی قیمت طلا را به خوبی توضیح دهد. استفاده از توجه چندسری برای شناسایی وابستگی‌های دورتر و به کارگیری شبکه تغذیه‌ای پیشرو پیچشی (FFN) برای تقویت ویژگی‌های محلی، این مدل را به ابزاری کارآمد در مواجهه با داده‌های مالی پرنوسان تبدیل کرده است. علاوه بر این، با وجود پیچیدگی نسبتاً کم (19,377 پارامتر)، مدل عملکردی رقابتی و پایدار ارائه می‌دهد و به عنوان گزینه‌ای مناسب برای پیش‌بینی کوتاه‌مدت قیمت طلا شناخته می‌شود. نتایج نهایی مدل ترنسفورمر در جدول (9) و شکل (10) نمایش داده شده است.

جدول (9) : نتایج نهایی مدل Transformer براساس داده‌های آزمون


| مقدار     | شاخص  |
|-----------|-------|
| 593425.14 | RMSE  |
| 394170.19 | MAE   |
| 0.0136    | MAPE  |
| 0.9933    | $R^2$ |
| 61131.82  | AIC   |
| 145640.78 | BIC   |



شکل (10) : نمودار مقادیر واقعی و مقادیر پیش‌بینی‌شده براساس مدل Transformer

#### 4.6. مدل ترکیبی روش تجزیه مد تجربی مکمل با شبکه عصبی پیچشی

برای بهبود عملکرد شبکه پیچشی، از روش تجزیه مد تجربی مکمل<sup>21</sup> استفاده شد تا سری زمانی قیمت طلا به توابع مد ذاتی<sup>22</sup> تجزیه گردد. این تجزیه امکان جداسازی نوسانات کوتاه مدت و روندهای میان مدت و بلندمدت را فراهم می کند. در این مطالعه، IMF های 1 و 2 به دلیل نوسان بالا حذف شدند و IMF های 3 تا 10 به همراه قیمت پایانی طلا به عنوان ویژگی های ورودی مدل در نظر گرفته شدند. در شکل (11)، IMF های استخراج شده از قیمت پایانی طلا رسم شده است.



شکل (11): IMF های استخراج شده از قیمت پایانی طلا

<sup>21</sup> Ensemble Empirical Mode Decomposition (EEMD)

<sup>22</sup> Intrinsic Mode Functions (IMF)

مطابق معماری ارائه شده در جدول (10)، ورودی شبکه دارای ابعاد (578, 12, 9) است که شامل 578 رکورد، پنجره زمانی 12 و ویژگی می‌باشد. معماری مدل شامل یک لایه Conv1D با 64 فیلتر و کرنل سایز 2 و تابع فعال‌سازی ReLU، یک لایه MaxPooling1D، یک لایه Dropout (0.05)، Flatten، و در نهایت دو لایه Dense است. مدل با بهینه‌ساز Adam و تابع خطای MSE کامپایل شده و با استفاده از Early Stopping آموزش داده شد. مجموع پارامترهای قابل یادگیری برابر با 13,569 است.


جدول (10): معماری مدل CNN

| Layer (Type)        | Output Shape  | Param         |
|---------------------|---------------|---------------|
| Conv1D              | (None, 2, 64) | 576           |
| MaxPooling1D        | (None, 2, 64) | 0             |
| Dropout             | (None, 2, 64) | 0             |
| Flatten             | (None, 384)   | 0             |
| Dense               | (None, 32)    | 12,320        |
| Dense               | (None, 1)     | 33            |
| <b>Total Params</b> |               | <b>13,569</b> |

ترکیب EEMD و CNN موجب شد تا مدل بتواند همزمان از مزایای تجزیه سری زمانی و قابلیت CNN در استخراج ویژگی‌های محلی بهره‌مند شود. نتایج نشان دادند که این رویکرد دقت بالایی در پیش‌بینی قیمت پایانی طلا داشته و شاخص  $R^2$  با مقدار 0.9927، بیانگر توان مدل در توضیح واریانس داده‌ها است. نتایج نهایی مدل EEMD-CNN در جدول (11) و شکل (12) نمایش داده شده است.

جدول (11): نتایج نهایی مدل EEMD-CNN براساس داده‌های آزمون

| مقدار     | شاخص  |
|-----------|-------|
| 620069.77 | RMSE  |
| 410109.90 | MAE   |
| 0.0140    | MAPE  |
| 0.9927    | $R^2$ |
| 49462.83  | AIC   |
| 108617.89 | BIC   |



شکل (12): نمودار مقادیر واقعی و مقادیر پیش بینی شده براساس مدل ترکیبی EEMD-CNN

#### 4.7. مدل ترکیبی شبکه عصبی پیچشی و شبکه حافظه کوتاه مدت بلند

این ترکیب از مزایای هر دو روش بهره مند است. CNN در استخراج ویژگی های محلی از داده های سری زمانی توانمند بوده و LSTM قادر به مدل سازی وابستگی های زمانی طولانی مدت و الگوهای پیاپی است. در این ساختار، ابتدا CNN ویژگی های اصلی داده های ورودی را استخراج کرده و سپس LSTM با استفاده از این ویژگی ها روندها و وابستگی های زمانی را شناسایی می کند. معماری مدل CNN-LSTM در جدول (12) نمایش داده شده است.


جدول (12): معماری مدل ترکیبی CNN-LSTM

| Layer (Type)        | Output Shape  | Param         |
|---------------------|---------------|---------------|
| Conv1D              | (None, 2, 64) | 576           |
| MaxPooling1D        | (None, 2, 64) | 0             |
| Dropout             | (None, 2, 64) | 0             |
| Conv1D              | (None, 2, 32) | 4128          |
| MaxPooling1D        | (None, 2, 32) | 0             |
| Dropout             | (None, 2, 32) | 0             |
| LSTM                | (None, 2, 50) | 16,600        |
| Dropout             | (None, 2, 50) | 0             |
| LSTM                | (None, 50)    | 0             |
| Dropout             | (None, 50)    | 20,200        |
| Dense               | (None, 50)    | 2,550         |
| Dense               | (None, 1)     | 51            |
| <b>Total Params</b> |               | <b>44,105</b> |

مدل ترکیبی CNN-LSTM شامل دو لایه پیش‌بینی برای استخراج ویژگی‌های محلی، لایه‌های Max Pooling و Dropout برای کاهش ابعاد و جلوگیری از بیش‌برازش، و دو لایه LSTM با 50 واحد برای مدل‌سازی وابستگی‌های زمانی طولانی‌مدت است. در ادامه، یک لایه Dense با 50 نورون و یک لایه خروجی تک‌نورونی برای پیش‌بینی قیمت طلا به کار گرفته شده است. ورودی مدل دارای ابعاد (4, 2, 578) بوده و مجموع پارامترهای قابل یادگیری برابر با 44,105 است. نتایج نشان می‌دهد که مدل با  $R^2 = 99.47\%$  عملکرد بسیار دقیق داشته و نسبت به روش‌های منفرد بهبود قابل توجهی در معیارهای ارزیابی ارائه کرده است. نتایج نهایی مدل CNN-LSTM، در جدول (13) و در شکل (14) نمایش داده شده است.

جدول (13): نتایج نهایی مدل ترکیبی CNN-LSTM براساس داده‌های آزمون

| مقدار     | شاخص  |
|-----------|-------|
| 525245.87 | RMSE  |
| 330331.65 | MAE   |
| 0.0113    | MAPE  |
| 0.9947    | $R^2$ |
| 103436.39 | AIC   |
| 295715.40 | BIC   |




شکل (13): نمودار مقادیر واقعی و مقادیر پیش‌بینی‌شده براساس مدل ترکیبی CNN-LSTM

#### 4.8. اضافه کردن متغیرهای اثرگذار و کلان اقتصادی

در این بخش، به جای استفاده از اطلاعاتی مانند قیمت شروع، بیشترین و کمترین قیمت‌ها برای هر روز، تنها قیمت پایانی مورد بررسی قرار گرفته است. همچنین، به منظور ارزیابی تأثیرات عوامل اقتصادی کلان بر قیمت طلا، چندین متغیر اقتصادی دیگر به مدل افزوده شده‌اند. این متغیرها

شامل قیمت دلار، قیمت نفت برنت و شاخص کل بازار بورس می باشند. هر یک از این متغیرها به طور بالقوه می توانند بر قیمت طلا تأثیرگذار باشند و می توانند نمایانگر عواملی مهم در بازارهای مالی و اقتصادی باشند.

پس از قرار دادن این متغیرهای جدید در مدل و آموزش مدل ها با استفاده از دو روش پیش بینی ARIMA و LSTM، نتایج نشان دهنده این واقعیت است که در هر دو حالت، مدل نتوانسته است به بهبود قابل توجهی در پیش بینی ها دست یابد. در واقع، به نظر می رسد که اطلاعات گذشته قیمت طلا، از جمله قیمت های شروع، بیشترین و کمترین قیمت های روزانه، تأثیر بیشتری بر دقت پیش بینی ها دارند. این اطلاعات می توانند الگوهای قوی تری از روندهای گذشته قیمت طلا را به مدل ارائه دهند و در نتیجه به بهبود عملکرد مدل های پیش بینی کمک کنند. نمودار مربوط به مدل LSTM در شکل (14) نشان داده شده است که در مقایسه با حالت استفاده از اطلاعات گذشته طلا، مدل به نسبت عملکرد ضعیف تری داشته است.



شکل (14): نمودار پیش بینی مدل LSTM بر اساس شاخص های مهم اقتصادی

#### 4.9. استفاده از قیمت انس جهانی

در این بخش، داده های مربوط به انس جهانی طلا شامل قیمت آغازین، بیشترین، کمترین و پایانی به کار گرفته شد. با حفظ پارامترهای تعیین شده در مدل های پیشین، دو مدل SARIMAX و LSTM مجدداً با داده های جدید آموزش داده شده و عملکرد آن ها بر روی داده های آزمون ارزیابی گردید. نتایج حاصل از این ارزیابی ها در جدول (14) آمده است.

جدول (14): مقایسه نتایج نهایی مدل ها با استفاده از داده های مختلف طلا

| شاخص           | 18-karat Gold/IR |          | Gold /USD   |          |
|----------------|------------------|----------|-------------|----------|
|                | LSTM             | SARIMAX  | LSTM        | SARIMAX  |
| R <sup>2</sup> | 0.9942           | 0.9997   | 0.9919      | 0.9993   |
| AIC            | 6419773.18       | 60964.68 | 6433639.44  | 15384.00 |
| BIC            | 22470057.43      | 60999.76 | 22492718.59 | 15419.09 |

نتایج نشان داد که استفاده از داده‌های انس جهانی موجب بهبود نسبی در معیارهای AIC و BIC شد، اما از نظر شاخص  $R^2$ ، عملکرد مدل‌ها اندکی ضعیف‌تر بود. در مجموع، تغییر مقیاس داده‌ها از بازار داخلی به قیمت دلاری جهانی نتوانست به بهبود چشمگیر دقت پیش‌بینی‌ها منجر شود و اثر قابل توجهی بر عملکرد مدل‌ها نداشت. این یافته بیانگر آن است که انتخاب مقیاس دلاری به‌تنهایی عامل تعیین‌کننده‌ای در ارتقای کیفیت پیش‌بینی قیمت طلا نیست.

## 5. بحث و نتیجه‌گیری


هدف این پژوهش، پیش‌بینی قیمت روز بعدی طلای ۱۸ عیار با استفاده از مدل‌های یادگیری ماشین و یادگیری عمیق است. داده‌های مورد استفاده شامل قیمت‌های روزانه طلا در بازار ایران طی سال‌های ۱۳۹۳ تا ۱۴۰۳ بود که با استفاده از این داده‌ها، مدل‌های مختلف پیش‌بینی ارزیابی شدند. در جدول (۱۵)، نتایج حاصل از مدل‌های مختلف نشان می‌دهد که مدل SARIMAX با مقدار  $R^2$  برابر ۰.۹۹۹۷، بهترین عملکرد را در پیش‌بینی قیمت طلا در روز بعدی نسبت به سایر مدل‌ها داشته است.

جدول (۱۵): مقایسه نتایج نهایی مدل‌ها برای داده‌های طلا ۱۸ عیار

| شاخص                         | RMSE     | MAE      | MAPE   | $R^2$  | AIC       | BIC        |
|------------------------------|----------|----------|--------|--------|-----------|------------|
| مدل                          |          |          |        |        |           |            |
| <b>SARIMAX</b>               | 148737.7 | 87038.4  | 0.3430 | 0.9997 | 60964.69  | 60999.8    |
| <b>SVR</b>                   | 1163595  | 836424.6 | 0.0286 | 0.9738 | 16040.14  | 16053.2    |
| <b>LSTM</b>                  | 710183.1 | 505314.9 | 50.97  | 0.9942 | 6455786   | 22506070.4 |
| <b>CNN-not Permutations</b>  | 620069.8 | 410109.9 | 0.0140 | 0.9927 | 38334.84  | 73233.2    |
| <b>CNN-with Permutations</b> | 574520   | 376891.4 | 0.0128 | 0.9937 | 110780.20 | 303582.4   |
| <b>Transformer</b>           | 593425.1 | 394170.2 | 0.0136 | 0.9933 | 61131.83  | 145640.8   |
| <b>EMD-CNN</b>               | 620069.8 | 410109.9 | 0.0140 | 0.9927 | 49462.84  | 108617.9   |
| <b>CNN-LSTM</b>              | 525245.9 | 330331.7 | 0.0113 | 0.9947 | 103436.40 | 295715.4   |

برای بهبود نتایج، دو مدل ترکیبی معرفی گردید. در مدل اول از روش EEMD استفاده شد تا نویز و سیگنال‌های پنهان در داده‌ها استخراج و تاثیر آن‌ها را در پیش‌بینی‌ها بررسی کنیم. با این حال، نتایج این روش نشان داد که استفاده از EEMD با  $R^2$  برابر ۰.۹۹۲۷ نتوانسته بهبود محسوسی در مدل ایجاد کند.

مدل ترکیبی دوم نیز که با عنوان مدل ترکیبی شبکه عصبی پیچشی با شبکه حافظه کوتاه‌مدت بلند بود با اینکه معیارهای ارزیابی مدل‌های پایه را بهبود اندکی داد، اما همچنان نسبت به مدل SARIMAX عملکرد بهتری نداشت. برای مقایسه بهتر مدل‌ها، نمودار عنکبوتی معیارهای ارزیابی در شکل (۱۵) نشان داده شده است.



شکل (15): نمودار عنکبوتی معیارهای ارزیابی مدل‌های توسعه داده شده

برای بررسی نقش عوامل اقتصادی کلان در پیش‌بینی قیمت طلا، متغیرهایی مانند قیمت دلار، نفت برنت و شاخص کل بورس به مدل‌ها افزوده شد اما نتایج نشان دادند که این ویژگی‌ها بهبود قابل‌توجهی در عملکرد ایجاد نکرده‌اند. این امر بیانگر آن است که داده‌های تاریخی قیمت طلا شامل قیمت آغازین، بیشترین و کمترین قیمت، بیشترین اثر را بر دقت پیش‌بینی دارند. استفاده از داده‌های انس جهانی طلا با چهار نوع قیمت (آغازین، بیشترین، کمترین و پایانی) تنها موجب بهبود شاخص‌های AIC و BIC شد، در حالی که دقت مدل‌ها از نظر  $R^2$  اندکی کاهش یافت. در نتیجه، تغییر مقیاس داده‌ها به قیمت دلاری جهانی نتوانست دقت پیش‌بینی‌ها را ارتقا دهد. به طور کلی، یافته‌ها نشان می‌دهند که مدل SARIMAX با داده‌های روزانه طلای ۱۸ عیار بهترین عملکرد را در پیش‌بینی قیمت طلا در بازار ایران ارائه می‌دهد و داده‌های جهانی تأثیر قابل‌توجه‌ای بر بهبود نتایج ندارند.

## 6. پیشنهادات آتی

برای مطالعات آینده می‌توان موارد زیر را پیشنهاد داد:

- بررسی شاخص‌های اقتصادی، مانند نرخ تورم و نرخ بهره روی دقت پیش‌بینی‌ها.
- بررسی استفاده از داده‌های فرکانس بالا برای پیش‌بینی تغییرات لحظه‌ای قیمت طلا.
- تحلیل تأثیر سیاست‌های اقتصادی ایران بر قیمت طلا.
- استفاده از روش‌های یادگیری تقویتی برای پیش‌بینی قیمت طلا.
- استفاده از نرخ سایر فلزات، مانند نقره، مس، پلاتین و غیره برای پیش‌بینی قیمت طلا.

## منابع

[1] Amini A, Kalantari R. Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning. PLoS One 2024; 19(3): e0298426. <https://doi.org/10.1371/journal.pone.0298426>.

- [2] Bao G, Niu Y, Cui B, Ji W. Revealing the correlation between economic indicators and gold prices for forecasting: Medium term forecast framework with data patch. *Expert System Application* 2025; 129594. <https://doi.org/10.1016/j.eswa.2025.129594>.
- [3] Ismail Z, Ismail Z, Yahya A, Shabri A. Forecasting Gold Prices Using Multiple Linear Regression Method. *Am J Application Sci* 2009; 6:1509–14.
- [4] Das S, Nayak J, Rao BK, Vakula K, Routray AR. Gold price forecasting using machine learning techniques: Review of a decade. In: *Computational Intelligence in Pattern Recognition. Advances in Intelligent Systems and Computing*, vol. 1349. Springer; 2022. [https://doi.org/10.1007/978-981-16-2120-8\\_36](https://doi.org/10.1007/978-981-16-2120-8_36).
- [5] Parisi A, Parisi F, Díaz D. Forecasting gold price changes: Rolling and recursive neural network models. *Journal of Multinational Financial Management* 2008; 18:477–87. <https://doi.org/10.1016/j.mulfin.2007.12.002>.
- [6] Khani MM, Vahidnia S, Abbasi A. A deep learning-based method for forecasting gold price with respect to pandemics. *SN Computing Science* 2021;2(4):335. <https://doi.org/10.1007/s42979-021-00769-7>.
- [7] Livieris IE, Pintelas E, Pintelas P. A CNN–LSTM model for gold price time-series forecasting. *Neural Computing Application* 2020; 32:17351–60. <https://doi.org/10.1007/s00521-020-04867-x>.
- [8] Nguyen DBB, Prokopczuk M, Wese Simen C. The risk premium of gold. *J Int Money Finance* 2019; 94:140–59. <https://doi.org/10.1016/j.jimonfin.2019.02.011>.
- [9] Dichtl H. Forecasting excess returns of the gold market: Can we learn from stock market predictions? *Journal of Commodity Markets* 2020; 19. <https://doi.org/10.1016/j.jcomm.2019.100106>.
- [10] Taneva-Angelova G, Raychev S, Ilieva G. A framework for gold price prediction combining classical and intelligent methods with financial, economic, and sentiment data fusion. *International Journal Financial Study* 2025; 13(2):102. <https://doi.org/10.3390/ijfs130200102>.
- [11] Krauss C, Do XA, Huck N. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *Eur J Oper Res* 2017; 259:689–702. <https://doi.org/10.1016/j.ejor.2016.10.031>.
- [12] Huck N. Large data sets and machine learning: Applications to statistical arbitrage. *Eur J Oper Res* 2019; 278:330–42. <https://doi.org/10.1016/j.ejor.2019.04.013>.
- [13] Saini, A., Singh, R. K., & Sinha, P. (2025). Forecasting gold price using hybrid deep neural network LSTM-autoencoder. *Discover Artificial Intelligence*, 5(1), 1-19.
- [14] Wu W, Chen J, Yang Z, Tindall ML. A Cross-Sectional Machine Learning Approach for Hedge Fund Return Prediction and Selection. 2019.
- [15] Krauss C, Do XA, Huck N. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *Eur J Oper Res* 2017; 259:689–702. <https://doi.org/10.1016/j.ejor.2016.10.031>.

- [16] Bianchi D, Büchner M, Tamoni A, Buckmann M, Chen H, Dinc S, et al. Bond Risk Premia with Machine Learning, n.d.
- [17] Zangana, H. M., & Obeyd, S. R. (2024). Deep learning-based gold price prediction: A novel approach using time series analysis. *SISTEMASI*, 13(6), 2581-2591.
- [18] Díaz JD, Hansen E, Cabrera G. Gold risk premium estimation with machine learning methods. *Journal of Commodity Markets* 2023; 31. <https://doi.org/10.1016/j.jcomm.2022.100293>.
- [19] Kong R. Machine learning models for gold price prediction: A comparative analysis and evaluation. *Highlights Bus Econ Management (FTMM)* 2024; 40:429–435.
- [20] Drobetz W, Hollstein F, Otto T, Prokopczuk M. Estimating Security Betas via Machine Learning. *SSRN Electronic Journal* 2021. <https://doi.org/10.2139/ssrn.3933048>.