

Short-Term Forecasting of Global Gold Prices Using a Hybrid Temporal Fusion Transformer Model

Morteza Mohammadlu ^{*1}, Seyed Mohsen Mirhosseini ²

^{1*} Department of Computer Engineering, Hi.C., Islamic Azad University, Hidas, Iran (Corresponding author), Email: morteza.mohammadlu@iaui.ir

² Department of Computer Engineering, Ka.C., Islamic Azad University, Karaj, Iran

ARTICLE INFO

Article history:

Received:20/06/2026

Received in revised form:28/07/2026

Accepted:12/09/2026

Available online:12/09/2026

Keywords:

Gold Price Forecasting,
Temporal Fusion Transformer
Deep Learning, Financial Time Series
Multi-Horizon Forecasting
Attention Mechanism, Interpretability

ABSTRACT

Accurate forecasting of gold prices, due to their nonlinear and non-stationary nature and their susceptibility to numerous economic and financial factors, is considered one of the complex problems in financial time-series analysis. The aim of this study is to design and evaluate an accurate, stable, and interpretable model for short-term forecasting of global gold prices using the Temporal Fusion Transformer (TFT) architecture.

The present study is applied in terms of purpose and quantitative, data-driven, and based on computational experiments in terms of methodology. The data used include daily gold market information over a ten-year period from 2014 to 2024. After data cleaning, normalization, and preprocessing, the dataset was temporally divided into training, validation, and test sets. The proposed model was implemented to forecast gold prices over 1-, 5-, 10-, and 22-day horizons, using variable selection networks, gated linear units, recurrent layers, and an interpretable multi-head attention mechanism. The performance of the model was compared with ARIMA, SARIMA, LSTM, GRU, standard Transformer, and Informer methods.

The results showed that the TFT model achieved the best performance among the compared methods, with an RMSE of USD 18.42 per ounce, MAE of USD 13.87 per ounce, MAPE of 0.89%, and a coefficient of determination (R^2) of 0.9534. Furthermore, the model achieved a directional accuracy of 72.5% and a prediction interval coverage of 79.8%. The Diebold–Mariano test also confirmed the statistically significant superiority of the proposed model over most benchmark methods. The findings indicate that, in addition to improving forecasting accuracy, the TFT model has an appropriate capability to provide prediction intervals and interpret the importance of influential variables and time periods. Therefore, it can be used as an effective tool for decision-making by investors and gold market analysts.

Article Type: Research Paper



©Authors

Journal of Intelligent Financial Management, 2025,
Vol. 2, No.2, pp. 245- 258

Publish by:

Tolou-e Binsh-e Ayandeh Scientific Institute

<https://doi.org/10.25843/JIFM.2025.8563.28103>

Cite: Mohammadlu,M and Mirhosseini,S M . (2026). Short-Term Forecasting of Global Gold Prices Using a Hybrid Temporal Fusion Transformer Model. Journal of Intelligent Financial Management, 2(2), 245-258.

پیش بینی کوتاه مدت قیمت جهانی طلا با استفاده از مدل تبدیلگر زمانی ترکیبی

مرتضی محمدلو^{۱*}، سید محسن میرحسینی^۲

۱ و ۲ - گروه مهندسی کامپیوتر، واحد هیدج، دانشگاه آزاد اسلامی، هیدج، ایران (نویسنده مسئول): ایمیل نویسنده مسئول: morteza.mohammadlu@iaui.ir

۲ - گروه مهندسی کامپیوتر، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران

چکیده	اطلاعات مقاله
پیش بینی دقیق قیمت طلا به دلیل ماهیت غیرخطی، غیرایستا و تأثیرپذیری آن از عوامل متعدد اقتصادی و مالی، یکی از مسائل پیچیده در تحلیل سری های زمانی مالی محسوب می شود. هدف این پژوهش، طراحی و ارزیابی مدلی دقیق، پایدار و تفسیرپذیر برای پیش بینی کوتاه مدت قیمت جهانی طلا با استفاده از معماری تبدیلگر همجوشی زمانی یا Temporal Fusion Transformer (TFT) است. پژوهش حاضر از نظر هدف، کاربردی و از نظر روش، کمی، داده محور و مبتنی بر آزمایش های محاسباتی است. داده های مورد استفاده شامل اطلاعات روزانه بازار طلا در دوره ده ساله ۲۰۱۴ تا ۲۰۲۴ است. پس از پاک سازی، نرمال سازی و آماده سازی داده ها، مجموعه داده به صورت زمانی به بخش های آموزش، اعتبارسنجی و آزمون تفکیک شد. مدل پیشنهادی با بهره گیری از شبکه های انتخاب متغیر، واحدهای خطی گیت دار، لایه های بازگشتی و سازوکار توجه چندسره تفسیرپذیر، برای پیش بینی قیمت طلا در افق های ۱، ۵، ۱۰ و ۲۲ روزه پیاده سازی شد. عملکرد مدل با روش های ARIMA، SARIMA، LSTM، GRU، Transformer استاندارد و Informer مقایسه گردید. نتایج نشان داد مدل TFT با دستیابی به مقادیر RMSE برابر ۱۸،۴۲ دلار بر اونس، MAE برابر ۱۳،۸۷ دلار بر اونس، MAPE برابر ۰،۸۹ درصد و ضریب تعیین ۰،۹۵۳۴، بهترین عملکرد را در میان روش های مقایسه شده داشته است. همچنین دقت جهتی مدل برابر ۷۲،۵ درصد و مقدار پوشش فاصله پیش بینی برابر ۷۹،۸ درصد به دست آمد. آزمون دابیولد-ماریانو نیز برتری معنادار مدل پیشنهادی را نسبت به اغلب روش های مینا تأیید کرد. یافته ها نشان می دهد مدل TFT، علاوه بر افزایش دقت پیش بینی، از توانایی مناسبی در ارائه فاصله های پیش بینی و تفسیر اهمیت متغیرها و دوره های زمانی اثر گذار برخوردار است و می تواند به عنوان ابزاری کارآمد برای تصمیم گیری سرمایه گذاران و تحلیلگران بازار طلا مورد استفاده قرار گیرد.	تاریخچه مقاله: تاریخ دریافت: ۱۴۰۵/۰۳/۳۰ تاریخ بازنگری: ۱۴۰۵/۰۵/۰۶ تاریخ پذیرش: ۱۴۰۵/۰۶/۲۱ تاریخ انتشار: ۱۴۰۵/۰۶/۲۱ کلیدواژه ها: پیش بینی قیمت طلا تبدیلگر همجوشی زمانی یادگیری عمیق سری زمانی مالی پیش بینی چندافقه سازوکار توجه تفسیرپذیری
نوع مقاله: پژوهشی  © نویسندگان استناد: محمدلو، مرتضی و میرحسینی، سید محسن. (۱۴۰۵). پیش بینی کوتاه مدت قیمت جهانی طلا با استفاده از مدل تبدیلگر زمانی ترکیبی. مدیریت مالی هوشمند، ۲(۲)، ۲۴۵-۲۵۸.	نشریه مدیریت مالی هوشمند، ۱۴۰۵، دوره ۲، شماره ۲، صفحه ۲۴۵-۲۵۸. ناشر: موسسه علمی طلوع بینش آینده https://doi.org/10.25843/JIFM.2025.8563.28103

مقدمه

طلا در نظام مالی معاصر، فراتر از یک کالای سرمایه‌گذاری، نقش لنگر ثبات در برابر آشفتگی‌های اقتصادی و سیاسی را ایفا می‌کند [۱] و به دلیل نقدشوندگی جهانی، استقلال از حاکمیت دولت‌ها و کارکرد تاریخی به عنوان سپر تورمی [۲]، به شاخصی حساس برای سنجش اعتماد عمومی به نظام پولی تبدیل شده است. در اقتصاد ایران که با تورم مزمن، بی‌ثباتی ارزی و تکان‌های برون‌زا دست و پنجه نرم می‌کند، طلا به کانون اصلی تصمیم‌گیری‌های سرمایه‌گذاری بدل شده، اما رفتار قیمتی آن از شبکه‌ای درهم‌تنیده از نیروهای پویا و غیرخطی پیروی می‌کند که گاه از منطق کلاسیک اقتصاد خارج است و در شرایط بحرانی الگوهای ناهمسو و غیرمنتظره بروز می‌دهد [۳]. این پیچیدگی ذاتی باعث شده است که هم مدل‌های پارامتریک سنتی و هم رویکردهای متعارف یادگیری ماشین در مواجهه با ماهیت ناپایدار، غیرخطی و وابسته به مسیر این سری زمانی دچار نقصان تبیین شوند و پژوهش‌های داخلی نیز یا به تحلیل‌های کوتاه‌مدت محدود مانده‌اند یا بدون در نظر گرفتن حافظه بلندمدت و تغییرات رژیم بازار، به پیش‌بینی‌هایی با خطای قابل توجه دست یافته‌اند [۳، ۴]. در پاسخ به این کاستی‌ها، پژوهش حاضر استفاده از معماری پیشرفته شبکه‌های عصبی بازگشتی دوطرفه همراه با سازوکار توجه را پیشنهاد می‌کند [۴، ۵] که توانایی تمرکز انتخابی بر بازه‌های زمانی حیاتی و به خاطر سپاری الگوهای بلندمدت را بدون افت گرادین فراهم می‌آورد و برخلاف مدل‌های سنتی که فرض ایستایی یا روابط خطی را تحمیل می‌کنند، به صورت تطبیقی وزن متغیرهای تأثیرگذار را در طول زمان تغییر داده و واکنش‌های نامتقارن بازار طلا به شوک‌های مثبت و منفی را شبیه‌سازی می‌کند [۴]. انتظار می‌رود این رویکرد نه تنها دقت پیش‌بینی را در افق‌های میان‌مدت و بلندمدت بهبود بخشد، بلکه از طریق نقشه‌های توجه، امکان شناسایی مهم‌ترین محرک‌های قیمتی را برای تحلیلگران بازار طلا فراهم آورد [۵] و بدین ترتیب فاصله میان اهمیت غیرقابل‌انکار پیش‌بینی دقیق قیمت طلا و نارسایی ابزارهای موجود را تا حد قابل توجهی کاهش دهد. پیش‌بینی قیمت طلا به دلیل ماهیت غیرخطی، ناپایا و تأثیرپذیری از متغیرهای کلان اقتصادی و رویدادهای ژئوپلیتیکی، همواره یکی از چالش‌برانگیزترین مسائل در حوزه مالی محسوب می‌شود. در سال‌های اخیر، پژوهش‌های متعددی به استفاده از مدل‌های یادگیری عمیق و ترکیبی برای بهبود دقت پیش‌بینی این سری‌های زمانی پیچیده پرداخته‌اند که در ادامه به مهم‌ترین آنها اشاره می‌شود. وو و همکاران (۲۰۲۶) در پژوهشی جامع، به مقایسه سه استراتژی مدل‌سازی شامل شبکه LSTM به تنهایی، شبکه توجه خود-پیچشی (Convolutional Self-Attention) و مدل ترکیبی LSTM-Attention پرداختند.

داده‌های مورد استفاده آنان شامل قیمت‌های تاریخی طلا و متغیرهای کلان اقتصادی مرتبط بود. نتایج تجربی ایشان نشان داد که مدل ترکیبی LSTM-Attention به طور معناداری از دو رویکرد دیگر عملکرد بهتری داشته و توانایی بالاتری در شناسایی ویژگی‌های پویای نوسانات قیمتی از خود نشان می‌دهد. این مدل نه تنها ادغام مؤثر LSTM و مکانیزم توجه را در پیش‌بینی سری‌های زمانی به نمایش می‌گذارد، بلکه ابزاری عملی برای تصمیم‌گیری مالی فراهم می‌آورد و بینش‌های ارزشمندی برای سرمایه‌گذاران در شرایط نوسانی بازار ارائه می‌دهد. به علاوه، آنان تأکید کردند که افزودن مکانیزم توجه به شبکه‌های بازگشتی، مشکل محو شدن گرادین در توالی‌های طولانی را تا حد زیادی کاهش می‌دهد [۶]. در پژوهشی دیگر، ممون و همکاران (۲۰۲۵) با تأکید بر تأثیر قابل توجه قیمت فلزات گرانبها بر بازارهای جهانی و اقتصاد، یک مدل نوآورانه مبتنی بر GRU بهبودیافته با مکانیزم توجه چندسره و اتصال پرش (Skip Connection) به نام MA-GRUS ارائه دادند. این مدل شامل مراحل مختلفی از پیش‌پردازش داده، ساخت مدل، آموزش، ارزیابی و بصری‌سازی است. لایه‌های GRU برای استخراج وابستگی‌های زمانی، مکانیزم توجه چندسره برای بهبود توانایی مدل در تمرکز بر اطلاعات مرتبط و قابل توجه، و اتصال پرش برای مقابله با مشکل محو شدن گرادین به کار گرفته شده‌اند.

ارزیابی مدل با استفاده از معیارهای MAE، MSE، RMSE، R^2 و زمان آموزش نشان داد که مدل پیشنهادی نه تنها از نظر دقت پیش‌بینی و نرخ خطا، عملکرد بهتری نسبت به مدل‌های LSTM، RNN، GRU، Bi-GRU و GRU دارای توجه دارد، بلکه به دلیل معماری ساده‌تر، پیاده‌سازی آسان‌تر و آموزش سریع‌تری نیز مشخص می‌شود [۷]. ژائو و همکاران (۲۰۲۵) نیز با در نظر گرفتن نوسانات اقتصادی جهانی و افزایش ریسک‌های ژئوپلیتیکی، طلا را به عنوان یک دارایی امن حیاتی معرفی کرده و یک چارچوب ترکیبی سه‌مرحله‌ای LSTM-Transformer-XGBoost پیشنهاد دادند. در مرحله اول، با استفاده از الگوریتم XGBoost، شش محرک کلیدی از میان سی و شش شاخص نامزد (شامل شاخص نزدک، قیمت بسته‌شدن S&P 500، قیمت آتی نقره، نرخ ارز USD/CNY، بازده اوراق یک‌ساله خزانه چین و ETF زغال سنگ) شناسایی شد. سپس، یک معماری یادگیری عمیق دوکاناله متشکل از LSTM برای حافظه بلندمدت زمانی و Transformer با مکانیزم خودتوجهی چندسره برای رمزگشایی روابط پنهان در سیگنال‌های بدون ساختار (مانند احساسات بازار و سیاست‌های اقلیمی) ادغام گردید. از نوآوری‌های کلیدی این پژوهش می‌توان به معماری تعاملی دوطرفه LSTM-Transformer با مکانیزم توجه متقابل، چارچوب پارتیشن‌بندی سلسله‌مراتبی پویا و مکانیزم تطبیقی دوحلقه اشاره کرد. نتایج نشان داد که رویکرد ترکیبی

مذکور توانسته است محدودیت‌های رویکردهای تک‌مدلی را در مواجهه با روندهای بلندمدت، نوسانات ناگهانی و نویز چندمنبعی به طور معناداری کاهش دهد [۸]. یانگ و همکاران (۲۰۲۵) در پژوهشی دیگر به چالش پیش‌بینی سری‌های زمانی بلندمدت قیمت طلا به دلیل ماهیت غیرخطی و وابستگی‌های پیچیده زمانی پرداختند. ایشان یک روش یادگیری عمیق مبتنی بر توجه به نام TCN-QV ارائه دادند که ترکیبی از شبکه‌های پیچشی زمانی (TCN) با مکانیزم توجه و روش کوانتیل (Quantile) است. مدل پیشنهادی آنها قادر است هم وابستگی‌های کوتاه‌مدت و هم الگوهای بلندمدت را در سری‌های زمانی قیمت طلا مدل‌سازی کند. نتایج تجربی نشان داد که مدل TCN-QV از نظر معیارهای RMSE، MAE و MAPE عملکرد بهتری نسبت به مدل‌های پایه شامل LSTM، GRU و Transformer ساده دارد. علاوه بر این، مدل توانست فاصله‌های اطمینان معتبری برای پیش‌بینی‌های خود ارائه دهد که برای مدیریت ریسک در بازار طلا حائز اهمیت است. یافته‌های این پژوهش نشان می‌دهد که ترکیب شبکه‌های پیچشی با مکانیزم توجه می‌تواند به طور مؤثری مشکل محو شدن گرادیان در توالی‌های طولانی را برطرف سازد [۹]. لین و همکاران (۲۰۲۶) نیز با تأکید بر نقش محوری قیمت طلا در سیستم مالی جهانی و مواجهه آن با نوسانات کوتاه‌مدت، روندهای بلندمدت و تغییرات مکرر رژیم، یک معماری جدید مبتنی بر CNN ارائه دادند که پیچش معمولی را با پیچش گسترده (Dilated Convolution) ترکیب کرده و یک پیچش چندمقیاس موازی ایجاد می‌کند. این معماری سپس از یک ضریب گیتینگ قابل آموزش استفاده می‌کند که قبل از ورود به LSTM با دو شاخه حاصل ضرب نقطه‌ای می‌شود.

آزمایش‌های مقایسه‌ای و فرسایشی با دو مجموعه آموزشی با نسبت‌های آزمون ۶:۴ و ۸:۲ انجام شد. نتایج نشان داد که در نسبت ۸:۲، مدل موازی با گیت (DilatedCNN-LSTMs) بهترین عملکرد را با RMSE برابر ۱۵,۳۱ و MAE برابر ۱۰,۲۲ به دست آورد. ایشان نتیجه گرفتند که زمانی که نسبت مجموعه آموزشی زیاد است، گیتینگ می‌تواند به طور مؤثری سوگیری را کاهش داده و تعمیم را بهبود بخشد. این روش به متغیرهای برون‌زا نیاز ندارد، هزینه پایین و قابلیت تکرارپذیری بالایی دارد [۱۰]. مرور پژوهش‌های فوق نشان می‌دهد که به‌کارگیری مکانیزم‌های توجه، معماری‌های ترکیبی و رویکردهای مبتنی بر پیچش، روند غالب در بهبود پیش‌بینی قیمت طلا بوده است. هر یک از مدل‌های مذکور با ارائه راهکارهایی برای مقابله با چالش‌هایی نظیر محو شدن گرادیان، شناسایی محرک‌های کلیدی و مدل‌سازی الگوهای بلندمدت، نقاط قوت خاصی در این حوزه ارائه می‌دهند و زمینه را برای توسعه مدل‌های کارآمدتر فراهم می‌سازند.

طلا به عنوان یکی از اصلی‌ترین دارایی‌های امن در بازارهای مالی جهانی، نقشی بنیادین در مدیریت ریسک و حفظ ارزش سرمایه در شرایط عدم اطمینان اقتصادی ایفا می‌کند و در دوره‌های تورم بالا، تنش‌های ژئوپلیتیکی و کاهش قدرت خرید ارزهای فیات، به سرعت مورد توجه سرمایه‌گذاران قرار می‌گیرد. در اقتصاد ایران نیز به دلیل محدودیت‌های ساختاری، نوسانات شدید نرخ ارز و تورم مزمن، طلا همواره یکی از مهم‌ترین ابزارهای سرمایه‌گذاری و ذخیره ارزش بوده است، اما قیمت آن تحت تأثیر مجموعه‌ای گسترده از متغیرهای اقتصاد کلان، مالی و رفتاری نظیر شاخص دلار، نرخ بهره واقعی، انتظارات تورمی، وضعیت بازارهای انرژی، سیاست‌های پولی و ریسک سیستماتیک قرار دارد که الگوهایی پیچیده، غیرخطی و اغلب غیرایستا در سری زمانی آن ایجاد می‌کنند. روش‌های آماری کلاسیک مانند ARIMA، GARCH و VAR اگرچه برای مدل‌سازی نوسانات کوتاه‌مدت مفیدند، اما در تحلیل روابط غیرخطی و ساختارهای بلندمدت کارایی محدودی دارند و مدل‌های یادگیری ماشین سنتی نظیر جنگل تصادفی و XGBoost نیز با وجود عملکرد بهتر نسبت به مدل‌های آماری، فاقد توانایی لازم در مدل‌سازی وابستگی‌های زمانی پیچیده، انتخاب پویای متغیرها و سازگاری با تغییرات ناگهانی ساختاری هستند. شبکه‌های عصبی بازگشتی پیشرفته‌تری همچون LSTM و GRU نیز با چالش‌هایی نظیر محو شدن گرادیان در توالی‌های طولانی، ناتوانی در تمرکز انتخابی بر بازه‌های کلیدی، ضعف در تفسیرپذیری و حساسیت زیاد به نویز مواجه‌اند و از سوی دیگر، بررسی ادبیات پژوهش داخلی نشان می‌دهد که اکثر مطالعات ایران همچنان مبتنی بر مدل‌های سنتی یا نسخه‌های ساده شبکه‌های عصبی هستند و تاکنون پژوهش منسجمی با بهره‌گیری از الگوریتم‌های پیشرفته یادگیری عمیق برای استخراج روابط پیچیده و ارائه پیش‌بینی قابل اتکا صورت نگرفته است؛ از این رو مسئله اصلی پژوهش، توسعه مدلی است که با توانایی یادگیری الگوهای غیرخطی، ساختارهای زمانی بلندمدت و تعاملات چندمتغیره، محدودیت‌های روش‌های پیشین را برطرف کرده و دقت پیش‌بینی قیمت طلا را بهبود بخشد.

مواد و روشها

۲-۱- روش پیشنهادی

در این بخش، به تشریح کامل معماری Temporal Fusion Transformer (TFT) به عنوان روش اجرای پژوهش برای پیش‌بینی قیمت جهانی طلا پرداخته می‌شود. انتخاب این معماری به عنوان روش پژوهش حاضر، مبتنی بر توانایی منحصر به فرد آن در ترکیب همزمان مزایای شبکه‌های عصبی بازگشتی (برای پردازش محلی و وابستگی‌های کوتاه‌مدت)، مکانیزم توجه (برای شناسایی الگوهای بلندمدت و تمرکز انتخابی بر بازه‌های زمانی حیاتی)، و شبکه‌های گیتینگ (برای حذف اجزای غیر ضروری و افزایش انعطاف‌پذیری) است. در ادامه، هر یک از مؤلفه‌های اصلی این معماری به تفصیل تشریح می‌شوند.

۱. نمای کلی معماری TFT

معماری TFT بر اساس یک ساختار رمزگذار-رمزگشا (Encoder-Decoder) طراحی شده است که به طور خاص برای پذیرش سه نوع ورودی متمایز در مسائل پیش‌بینی چندافقه بهینه گردیده است. این سه نوع ورودی عبارتند از: الف) متغیرهای ایستا؛ ویژگی‌هایی که در طول زمان تغییر نمی‌کنند و به کل سری زمانی تعلق دارند. در پژوهش حاضر، این متغیرها شامل ویژگی‌های شناسایی‌کننده سری قیمت طلا (مانند بازه زمانی مورد بررسی و مشخصات کلی داده) هستند. ب) متغیرهای زمانی معلوم؛ متغیرهایی که مقادیر آینده آن‌ها از قبل مشخص است. در این پژوهش، این دسته شامل شاخص‌های تقویمی مانند روز هفته، ماه سال، شاخص‌های فصلی و سایر متغیرهای برنامه‌ریزی شده می‌شود. ج) متغیرهای زمانی ناشناخته؛ متغیرهایی که تنها مقادیر گذشته آن‌ها در دسترس است و برای پیش‌بینی آینده باید مدل‌سازی شوند. در پژوهش حاضر، این دسته شامل قیمت تاریخی طلا (هدف اصلی)، شاخص دلار آمریکا، قیمت نفت، شاخص S&P 500، قیمت نقره و سایر متغیرهای کلان اقتصادی است.

۲. مراحل پردازش در معماری TFT

پردازش داده‌ها در معماری TFT از چندین مرحله متوالی و به هم پیوسته عبور می‌کند. در ادامه، هر یک از این مراحل به صورت دقیق تشریح می‌شود:

۱. جاسازی:

نخستین گام در معماری TFT، تبدیل داده‌های ورودی خام به فضای برداری با ابعاد بالا از طریق لایه‌های جاسازی^۱ است. برای متغیرهای مقداری، این تبدیل از طریق یک یا چند لایه کاملاً متصل^۲ انجام می‌شود که ورودی را به یک بردار با ابعاد d_model نگاشت می‌کند. برای متغیرهای طبقه‌ای، یک لایه جاسازی اختصاصی هر مقدار طبقه‌ای را به یک بردار پیوسته با ابعاد d_model تبدیل می‌کند. این فرایند جاسازی مزایای متعددی دارد: کاهش ابعاد داده، افزایش کارایی محاسباتی، کاهش خطر بیش‌برازش^۳، و قابلیت یادگیری روابط معنایی بین مقادیر مختلف.

در پژوهش حاضر، با توجه به تنوع متغیرهای ورودی (شامل متغیرهای مقداری مانند قیمت‌ها و شاخص‌ها و متغیرهای طبقه‌ای مانند شاخص‌های فصلی)، لایه‌های جاسازی به گونه‌ای طراحی می‌شوند که همه ورودی‌ها به یک فضای برداری یکپارچه با ابعاد $d_model = 64$ نگاشت گردند.

۲. شبکه‌های انتخاب متغیر:

پس از مرحله جاسازی، داده‌ها وارد شبکه‌های انتخاب متغیر می‌شوند. این شبکه‌ها یکی از نوآوری‌های کلیدی TFT هستند که به مدل اجازه می‌دهند در هر گام زمانی، به طور خودکار مرتبط‌ترین متغیرها را شناسایی کرده و بر آن‌ها تمرکز کند.

¹ Static Covariates

² Known Future Inputs

³ Observed Inputs

⁴ Embedding

⁵ Fully Connected

⁶ Overfitting

این قابلیت به ویژه در مسائل پیش‌بینی مالی که با ده‌ها متغیر بالقوه تأثیرگذار مواجه هستیم، از ارزش بالایی برخوردار است. مکانیزم عملکرد این شبکه‌ها به این صورت است که برای هر متغیر ورودی، یک وزن نرمال شده (با استفاده از تابع Softmax) محاسبه می‌شود که نشان‌دهنده میزان اهمیت آن متغیر در پیش‌بینی است. سپس خروجی نهایی به صورت مجموع وزنی جاسازی متغیرها محاسبه می‌گردد. در پژوهش حاضر، با توجه به تعداد نسبتاً زیاد متغیرهای تأثیرگذار بر قیمت طلا (شامل شاخص دلار، نرخ بهره، قیمت نفت، تورم، شاخص‌های ریسک و غیره)، این قابلیت می‌تواند به طور خودکار تعیین کند که در هر دوره زمانی خاص (مثلاً دوره تورمی یا دوره ثبات اقتصادی)، کدام متغیرها بیشترین اهمیت را دارند.

۳. لایه‌های گیتینگ و شبکه‌های باقیمانده گیت‌دار:

یکی دیگر از نوآوری‌های مهم TFT، استفاده از لایه‌های گیتینگ و شبکه‌های باقیمانده گیت‌دار (GRN) است. این مؤلفه‌ها به مدل این انعطاف را می‌دهند که میزان پردازش غیرخطی مورد نیاز برای هر بخش از داده را به طور تطبیقی تعیین کند. در مواردی که داده‌ها ساده هستند یا دارای نویز زیادی می‌باشند، مکانیزم گیتینگ می‌تواند مسیرهای غیرخطی پیچیده را مسدود کرده و تنها از نگاشت‌های خطی استفاده کند که از بیش‌برازش جلوگیری می‌نماید. ساختار GRN به صورت زیر تعریف می‌شود:

$$\text{GRN}_{\omega}(a, c) = \text{LayerNorm}(a + \text{GLU}_{\omega}(\eta_1)) \quad (1)$$

$$\eta_1 = W_{1,\omega}\eta_2 + b_{1,\omega} \quad (2)$$

$$\eta_2 = \text{ELU}(W_{2,\omega}a + W_{3,\omega}c + b_{2,\omega}) \quad (3)$$

که در آن a ورودی اصلی، c بردار زمینه^۳ اختیاری، ELU تابع فعال‌سازی، و GLU یک واحد خطی گیت‌دار است. لایه‌های GLU به صورت زیر تعریف می‌شوند:

$$\text{GLU}_{\omega}(\gamma) = \sigma(W_{4,\omega}\gamma + b_{4,\omega}) \odot (W_{5,\omega}\gamma + b_{5,\omega}) \quad (4)$$

در پژوهش حاضر، لایه‌های GRN در نقاط مختلف معماری TFT از جمله در شبکه‌های انتخاب متغیر، رمزگذار متغیرهای ایستا، و رمزگشای توجه به کار گرفته می‌شوند تا مدل بتواند به صورت تطبیقی با پیچیدگی داده‌های بازار طلا سازگار شود.

۴. رمزگذار متغیرهای ایستا

پس از اتمام مراحل جاسازی، انتخاب متغیر و گیتینگ، داده‌ها وارد رمزگذار متغیرهای ایستا می‌شوند. این مؤلفه، بردارهای جاسازی شده متغیرهای ایستا (ویژگی‌های کل سری زمانی) را دریافت کرده و چهار بردار زمینه متفاوت تولید می‌کند که در سایر بخش‌های معماری مورد استفاده قرار می‌گیرند.

بردار زمینه برای انتخاب متغیر زمانی (c_s): برای بهبود فرایند انتخاب متغیر در گام‌های زمانی مختلف

بردار زمینه برای غنی‌سازی رمزگشا (c_e): برای افزایش کیفیت بازنمایی در لایه توجه

بردارهای مقدار پنهان اولیه برای رمزگذار LSTM (c_h, c_c): برای شرطی‌سازی رمزگذار LSTM بر روی ویژگی‌های ایستا.

در پژوهش حاضر، متغیرهای ایستا شامل اطلاعات کلی درباره سری زمانی قیمت طلا (مانند محدوده زمانی، میانگین کلی، انحراف معیار، و ویژگی‌های ساختاری بازار) هستند که از طریق رمزگذار ایستا به بردارهای زمینه تبدیل شده و سایر اجزای مدل را شرطی می‌کنند.

۵. رمزگذار سری زمانی با LSTM (Temporal Covariate Encoder)

مرحله بعد، رمزگذار سری زمانی است که از یک شبکه LSTM (حافظه کوتاه‌مدت طویل) برای پردازش داده‌های متغیر زمانی (اعم از معلوم و ناشناخته) استفاده می‌کند. این لایه نقش حیاتی در مدل‌سازی وابستگی‌های کوتاه‌مدت و محلی در سری زمانی قیمت طلا ایفا می‌کند. دلیل انتخاب LSTM به جای RNN ساده، توانایی آن در یادگیری وابستگی‌های طولانی‌تر و مقاومت نسبی در برابر مشکل محو شدن

¹ Gating layer

² Gated Residual Networks

³ Context Vector

⁴ Gated Linear Unit

گرایان است. خروجی این رمزگذار شامل دنباله‌ای از وضعیت‌های پنهان است که اطلاعات مربوط به هر گام زمانی را در خود ذخیره کرده است.

در پژوهش حاضر، با توجه به ماهیت سری زمانی قیمت طلا که شامل نوسانات روزانه، الگوهای هفتگی، فصلی و وابستگی‌های بلندمدت است، استفاده از لایه LSTM در رمزگذار می‌تواند به خوبی این وابستگی‌های محلی را مدل‌سازی کند.

۶. رمزگشای همجوشی زمانی (Temporal Fusion Decoder)

پس از رمزگذار LSTM، داده‌ها وارد رمزگشای همجوشی زمانی می‌شوند که شامل دو بخش اصلی است: الف) لایه توجه چندسر تفسیرپذیر (Interpretable Multi-Head Attention): این لایه هسته اصلی قابلیت تفسیرپذیری TFT است. برخلاف مکانیزم توجه استاندارد در ترنسفورمرها که ابعاد و مقادیر توجه به راحتی قابل تفسیر نیستند، در TFT از یک نسخه تفسیرپذیر استفاده می‌شود. در این نسخه، وزن‌های توجه به گونه‌ای محاسبه می‌شوند که حتماً مقداری نامنفی داشته و به طور مستقیم نشان‌دهنده میزان اهمیت هر گام زمانی گذشته در پیش‌بینی آینده هستند. رابطه اصلی محاسبه توجه به صورت زیر است:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_{\text{attn}}}}\right)V \quad (5)$$

این مکانیزم چندسر (Multi-Head) به مدل اجازه می‌دهد تا به طور همزمان به الگوهای متفاوت در داده توجه کند (مثلاً یک سر بر الگوهای فصلی، سر دیگر بر شوک‌های ناگهانی تمرکز کند). در پژوهش حاضر، از ۴ سر توجه استفاده می‌شود و وزن‌های توجه نهایی برای شناسایی بازه‌های زمانی حیاتی (مانند دوره‌های بحرانی اقتصادی، زمان اعلام نرخ بهره توسط فدرال رزرو، یا زمان انتشار آمار تورم) استخراج و تحلیل می‌گردند.

ب) لایه خروجی برای پیش‌بینی چندک: از یک رویکرد مبتنی بر رگرسیون چندک (Quantile Regression) برای تولید پیش‌بینی‌های فاصله‌ای استفاده می‌کند. به جای پیش‌بینی یک مقدار نقطه‌ای واحد، مدل به طور همزمان چندین چندک (معمولاً ۱۰٪، ۵۰٪ و ۹۰٪) را پیش‌بینی می‌کند. فاصله بین چندک ۱۰٪ و ۹۰٪، یک فاصله اطمینان ۸۰٪ را تشکیل می‌دهد که عدم قطعیت پیرامون پیش‌بینی را نشان می‌دهد. تابع هزینه مورد استفاده در آموزش مدل، تابع چندک (Quantile Loss) است:

$$\mathcal{L}(y, \hat{y}, q) = \sum_i \sum_t \max(q \cdot (y_{i,t} - \hat{y}_{i,t}), (q - 1) \cdot (y_{i,t} - \hat{y}_{i,t})) \quad (6)$$

در پژوهش حاضر، مدل TFT به گونه‌ای آموزش داده می‌شود که به طور همزمان سه چندک ۱۰٪، ۵۰٪ و ۹۰٪ را برای قیمت طلا پیش‌بینی کند و بدین ترتیب فاصله اطمینان ۸۰٪ برای هر پیش‌بینی ارائه دهد.

۳. قابلیت تفسیرپذیری در معماری TFT

یکی از مهم‌ترین مزایای TFT نسبت به سایر مدل‌های یادگیری عمیق، قابلیت تفسیرپذیری ذاتی آن است. این قابلیت در سه سطح قابل تحلیل است:

- سطح اول: اهمیت متغیرها؛ شبکه‌های انتخاب متغیر در TFT، وزن‌های نرمال‌شده‌ای را برای هر متغیر ورودی تولید می‌کنند که نشان‌دهنده میزان اهمیت آن متغیر در پیش‌بینی است. این وزن‌ها هم در سطح جهانی (برای کل سری زمانی) و هم در سطح محلی (برای هر گام زمانی) قابل استخراج و تحلیل هستند. در پژوهش حاضر، این قابلیت امکان شناسایی مهم‌ترین متغیرهای تأثیرگذار بر قیمت طلا (مانند شاخص دلار، نرخ بهره، قیمت نفت و ...) را در دوره‌های مختلف زمانی فراهم می‌آورد.
- سطح دوم: الگوهای توجه زمانی؛ مکانیزم توجه تفسیرپذیر در TFT، وزن‌های توجهی تولید می‌کند که نشان می‌دهد مدل در هنگام پیش‌بینی هر نقطه در آینده، به کدام گام‌های زمانی گذشته بیشتر توجه کرده است. این الگوها می‌توانند رفتارهای فصلی (مثلاً توجه بیشتر به همان ماه در سال گذشته)، روندها (توجه بیشتر به روزهای اخیر) یا وقایع خاص را آشکار سازند.
- سطح سوم: پیش‌بینی فاصله‌ای؛ همان‌طور که پیشتر اشاره شد، TFT به جای پیش‌بینی نقطه‌ای، چندک‌های مختلف را پیش‌بینی می‌کند. این فاصله‌های اطمینان اطلاعات ارزشمندی در مورد عدم قطعیت پیرامون هر پیش‌بینی فراهم می‌آورند. برای مثال، اگر

¹ Temporal Attention Patterns

² Prediction Intervals

فاصله اطمینان ۸۰٪ بسیار گسترده باشد، نشان‌دهنده عدم قطعیت بالای مدل در آن پیش‌بینی خاص است که می‌تواند سرمایه‌گذاران را به احتیاط بیشتر در تصمیم‌گیری دعوت کند.

فلوچارت مدل پیشنهادی، در شکل ۱ نمایش داده شده است:



شکل ۱. فلوچارت مدل پیشنهادی

مجموعه داده

دیتاست پیشنهادی برای ارزیابی مدل پیشنهادی، مجموعه‌ای از داده‌های واقعی قیمت روزانه طلا در بازه زمانی ۱۰ ساله از ۱۹ ژانویه ۲۰۱۴ تا ۲۲ ژانویه ۲۰۲۴ است که از منبع معتبر Nasdaq [11] گردآوری شده است. این دیتاست شامل متغیرهای کلیدی مالی برای هر روز معاملاتی شامل قیمت باز شدن (Open)، بالاترین قیمت (High)، پایین‌ترین قیمت (Low)، قیمت بسته شدن (Close) و حجم معاملات (Volume) می‌باشد که برای پیش‌بینی سری‌های زمانی و مدل‌سازی مالی بسیار مناسب است. این بازه زمانی ۱۰ ساله شرایط مختلف بازار از جمله بحران‌های اقتصادی، تغییرات نرخ بهره و نوسانات ژئوپلیتیکی را پوشش می‌دهد که برای ارزیابی robustness مدل پیشنهادی ایده‌آل است.

معیارهای ارزیابی

RMSE - Root Mean Square Error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

این معیار ریشه میانگین مجذور خطاها را محاسبه می‌کند و به خطاهای بزرگ جریمه بیشتری می‌دهد. واحد این معیار همان واحد متغیر هدف (دلار بر اونس برای قیمت طلا) است و هرچه مقدار آن کمتر باشد، دقت مدل بالاتر است.

MAE - Mean Absolute Error

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

میانگین قدر مطلق خطاها را محاسبه می‌کند و بر خلاف RMSE به داده‌های پرت (Outlier) حساسیت کمتری دارد. این معیار تفسیر ساده‌تری دارد و نشان می‌دهد به طور متوسط مدل چقدر از مقدار واقعی فاصله دارد.

MAPE - Mean Absolute Percentage Error:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (9)$$

خطا را به صورت درصدی نسبت به مقدار واقعی بیان می‌کند و برای مقایسه بین دیتاست‌های با مقیاس مختلف مناسب است. در پیش‌بینی قیمت طلا، MAPE کمتر از ۵٪ نشان‌دهنده دقت عالی، بین ۵ تا ۱۰٪ نشان‌دهنده دقت خوب و بالای ۲۰٪ نشان‌دهنده دقت ضعیف است.

R^2 - Coefficient of Determination

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

نشان می‌دهد چه درصدی از واریانس داده‌های واقعی توسط مدل توضیح داده شده است. مقدار این معیار بین ۰ تا ۱ است (هرچند می‌تواند منفی نیز شود) و هرچه به ۱ نزدیک‌تر باشد، مدل عملکرد بهتری دارد. مقدار بالای ۰/۸ معمولاً بسیار خوب محسوب می‌شود.

PICP - Prediction Interval Coverage Probability

$$PICP = \frac{1}{n} \sum_{i=1}^n \mathbf{1}[L_i \leq y_i \leq U_i] \times 100\% \quad (11)$$

درصدی از نقاط واقعی که درون فاصله پیش‌بینی (بین کران پایین و بالای مدل) قرار می‌گیرند را محاسبه می‌کند. مقدار ایده‌آل برای این معیار باید به سطح اطمینان اسمی نزدیک باشد. مثلاً برای فاصله ۸۰٪، PICP باید حدود ۸۰٪ باشد. اگر PICP خیلی کمتر باشد، مدل بیش از حد خوش‌بینانه است و اگر خیلی بیشتر باشد، فواصل بیش از حد باز هستند.

جدول ۱. راهنمای متغیرها در فرمول‌ها

y_i	مقدار واقعی (Actual value)
$\hat{y}_i$	مقدار پیش‌بینی شده (Predicted value)
$\bar{y}$	میانگین مقادیر واقعی
n	تعداد نمونه‌ها
L_i	کران پایین فاصله پیش‌بینی
U_i	کران بالای فاصله پیش‌بینی
$\mathbf{1}[\cdot]$	تابع نشانگر (Indicator function)
q	کوانتایل (Quantile)
ε	عدد بسیار کوچک (مثلاً 10^{-8})

۴- نتایج

نتایج شبیه‌سازی روش پیشنهادی به شرح زیر است:

جدول ۲. معیارهای اصلی ارزیابی مدل TFT پیشنهادی

معیار ارزیابی	مقدار	واحد	وضعیت مطلوب	تفسیر
RMSE	18.42	USD/oz	✓	خطای ریشه میانگین مربعات - عالی
MAE	13.87	USD/oz	✓	خطای مطلق متوسط - عالی
MAPE	0.89	درصد	✓	خطای درصدی مطلق - عالی (زیر ۱٪)
R^2	0.9534	-	✓	ضریب تعیین - ۹۵,۳٪ تغییرات توضیح داده شده

PICP	79.80	درصد	✓	پوشش فاصله اطمینان - نزدیک به هدف ۸۰٪
PINRW	0.0234	-	✓	پهنای نرمالیزه فاصله - فواصل دقیق

جدول شماره ۲ نتایج شش معیار اصلی ارزیابی را برای مدل Temporal Fusion Transformer پیشنهادی نشان می‌دهد. بر اساس این نتایج، مدل TFT موفق به دستیابی به RMSE معادل ۱۸/۴۲ دلار بر اونس و MAE برابر ۱۳/۸۷ دلار بر اونس شده است که نشان‌دهنده دقت بسیار بالای مدل در پیش‌بینی قیمت طلا می‌باشد. مقدار MAPE معادل ۰/۸۹ درصد بیانگر این است که خطای نسبی مدل کمتر از یک درصد است که در حوزه پیش‌بینی سری‌های زمانی مالی یک نتیجه استثنایی محسوب می‌شود.

ضریب تعیین R^2 برابر ۰/۹۵۳۴ نشان می‌دهد که مدل پیشنهادی قادر است بیش از ۹۵ درصد از تغییرات قیمت طلا را توضیح دهد. همچنین معیار PICP با مقدار ۷۹/۸۰ درصد بسیار نزدیک به سطح اطمینان هدف (۸۰ درصد) بوده که حاکی از کالیبراسیون مناسب فواصل پیش‌بینی است. در نهایت، مقدار PINRW برابر ۰/۰۲۳۴ نشان می‌دهد که پهنای فواصل پیش‌بینی در مقایسه با میانگین قیمت طلا بسیار باریک و قابل قبول است.

جدول ۳. مقایسه عملکرد روش‌های مختلف بر اساس RMSE و R^2

روش پیش‌بینی	RMSE (USD/oz)	MAE (USD/oz)	MAPE (%)	R^2	MDA (%)
ARIMA	42.56	34.23	2.15	0.7234	52.3
SARIMA	38.91	31.45	1.98	0.7512	54.7
LSTM	26.34	19.87	1.32	0.8745	61.2
GRU	24.78	18.92	1.25	0.8812	62.8
Transformer استاندارد	21.56	16.34	1.08	0.9123	67.3
Informer	20.13	15.67	0.98	0.9256	69.1
روش پیشنهادی	18.42	13.87	0.89	0.9534	72.5

جدول شماره ۳ به مقایسه عملکرد مدل TFT پیشنهادی با شش روش مطرح دیگر شامل ARIMA، SARIMA، LSTM، GRU، Transformer استاندارد و Informer می‌پردازد. نتایج نشان می‌دهد که مدل TFT با RMSE برابر ۱۸/۴۲ و R^2 برابر ۰/۹۵۳۴ بهترین عملکرد را در بین تمام روش‌های مقایسه دارد. روش‌های کلاسیک ARIMA و SARIMA با RMSE به ترتیب ۴۲/۵۶ و ۳۸/۹۱ ضعیف‌ترین عملکرد را داشته‌اند که نشان می‌دهد مدل‌های خطی توانایی لازم برای مدل‌سازی پیچیدگی‌های بازار طلا را ندارند. روش‌های مبتنی بر یادگیری عمیق مانند LSTM و GRU عملکرد بهتری دارند اما همچنان از مدل TFT عقب‌تر هستند. جالب توجه است که مدل Transformer استاندارد با RMSE 21.56 و Informer با RMSE 20.13 عملکرد خوبی دارند اما مدل TFT با بهره‌گیری از معماری خاص خود شامل شبکه انتخاب متغیر و واحدهای خطی گیت‌دار، موفق به ثبت بهترین مقادیر در تمام معیارهای RMSE، MAE، MAPE، R^2 و MDA شده است. همچنین دقت جهتی MDA مدل TFT با ۷۲/۵ درصد به طور معنی‌داری بهتر از سایر روش‌ها است که برای اهداف معاملاتی بسیار حائز اهمیت می‌باشد.

جدول ۴. مقایسه عملکرد در افق‌های پیش‌بینی مختلف بر اساس RMSE

روش پیش‌بینی	h=1 روز	h=5 روز	h=10 روز	h=22 روز
ARIMA	42.56	58.23	72.15	95.67
SARIMA	38.91	53.67	67.34	89.23
LSTM	26.34	34.56	48.92	71.34
GRU	24.78	32.89	46.23	68.91
Transformer استاندارد	21.56	28.34	39.87	58.23
Informer	20.13	26.78	37.12	54.67
روش پیشنهادی	18.42	24.15	33.56	49.87

جدول شماره ۴ عملکرد روش‌های مختلف را در چهار افق پیش‌بینی متفاوت شامل ۱ روز، ۵ روز، ۱۰ روز و ۲۲ روز (معادل یک ماه معاملاتی) مورد بررسی قرار می‌دهد. نتایج به وضوح نشان می‌دهد که با افزایش افق پیش‌بینی، خطای تمام روش‌ها افزایش می‌یابد، اما نرخ افزایش

خطا در روش‌های مختلف متفاوت است. مدل TFT پیشنهادی در افق ۱ روزه با RMSE برابر ۱۸/۴۲ بهترین عملکرد را دارد و این برتری در افق‌های بلندتر بیشتر نمایان می‌شود به طوری که در افق ۲۲ روزه، RMSE مدل TFT برابر ۴۹/۸۷ است در حالی که این مقدار برای LSTM 71.34 و برای Transformer استاندارد ۵۸/۲۳ می‌باشد. این موضوع نشان‌دهنده توانایی بالای مدل TFT در حفظ دقت پیش‌بینی در بازه‌های زمانی طولانی‌تر است که ناشی از مکانیزم توجه چندهدفه و ساختار حافظه بلندمدت LSTM دوطرفه در معماری آن می‌باشد. روش‌های کلاسیک مانند ARIMA و SARIMA با افزایش افق پیش‌بینی دچار افت شدید عملکرد شده‌اند که نشان می‌دهد این مدل‌ها قادر به یادگیری الگوهای بلندمدت در داده‌های قیمت طلا نیستند.

جدول ۲. نتایج آزمون دایبولد-ماریانو (Diebold-Mariano Test)

مقایسه روش‌ها	آماره DM	p-value	نتیجه در سطح ۹۵٪
TFT vs ARIMA	-4.82	0.0000	✓ تفاوت معنی‌دار
TFT vs SARIMA	-4.53	0.0000	✓ تفاوت معنی‌دار
TFT vs LSTM	-3.21	0.0013	✓ تفاوت معنی‌دار
TFT vs GRU	-2.98	0.0029	✓ تفاوت معنی‌دار
TFT vs Transformer	-2.34	0.0193	✓ تفاوت معنی‌دار
TFT vs Informer	-1.87	0.0614	X تفاوت غیر معنی‌دار*

* در سطح اطمینان ۹۰٪ تفاوت معنی‌دار است ($p\text{-value} < 0.10$)

جدول شماره ۵ نتایج آزمون آماری دایبولد-ماریانو را ارائه می‌دهد که برای مقایسه معناداری آماری تفاوت بین عملکرد دو مدل پیش‌بینی به کار می‌رود. در این آزمون، فرض صفر مبنی بر برابری دقت پیش‌بینی دو مدل مورد بررسی قرار می‌گیرد. نتایج نشان می‌دهد که مدل TFT در مقایسه با ARIMA، SARIMA، LSTM، GRU و Transformer استاندارد، دارای آماره DM منفی و p-value کمتر از ۰/۰۵ است که بیانگر تفاوت معنادار آماری در سطح اطمینان ۹۵ درصد می‌باشد. به عبارت دیگر، برتری مدل TFT نسبت به این روش‌ها صرفاً تصادفی نبوده و از نظر آماری معنی‌دار است. در مقایسه با مدل Informer، آماره DM برابر -۱/۸۷ و p-value برابر ۰/۰۶۱۴ به دست آمده است که در سطح اطمینان ۹۵ درصد معنادار نیست اما در سطح اطمینان ۹۰ درصد ($p\text{-value} < 0.10$) معنادار محسوب می‌شود. این نتیجه نشان می‌دهد که اگرچه مدل TFT عملکرد بهتری نسبت به Informer داشته است، اما این تفاوت در سخت‌گیرانه‌ترین سطح آماری کاملاً اثبات نمی‌شود و نیاز به بررسی با داده‌های بیشتر دارد.

جدول ۶. مقایسه زمان اجرا و پیچیدگی محاسباتی


روش پیش‌بینی	زمان آموزش (دقیقه)	زمان استنتاج (نمونه/ms)	تعداد پارامتر (میلیون)
ARIMA	0.5	0.8	0.01
SARIMA	0.8	1.2	0.02
LSTM	45.0	2.3	1.20
GRU	42.0	2.1	1.10
Transformer استاندارد	78.0	3.4	2.80
Informer	65.0	2.8	2.40
روش پیشنهادی	89.0	3.1	3.20

جدول شماره ۶ به مقایسه سه معیار مرتبط با کارایی محاسباتی روش‌های مختلف شامل زمان آموزش، زمان استنتاج و تعداد پارامترهای مدل می‌پردازد. همان‌طور که انتظار می‌رفت، روش‌های کلاسیک ARIMA و SARIMA با زمان آموزش کمتر از ۱ دقیقه و تعداد پارامتر ناچیز، سریع‌ترین روش‌ها هستند اما در مقابل دقت پایینی دارند. در سوی دیگر، مدل TFT پیشنهادی با ۳/۲۰ میلیون پارامتر، بیشترین زمان آموزش (۸۹ دقیقه) را به خود اختصاص داده است که ناشی از معماری پیچیده آن شامل LSTM دوطرفه، شبکه انتخاب متغیر و مکانیزم توجه چندهدفه می‌باشد. با این حال، زمان استنتاج مدل TFT برابر ۳/۱ میلی‌ثانیه برای هر نمونه است که با توجه به کاربرد واقعی سیستم در معاملات آنالاین، کاملاً قابل قبول می‌باشد. برای مقایسه، مدل Transformer استاندارد با ۲/۸۰ میلیون پارامتر، زمان آموزش ۷۸ دقیقه و زمان استنتاج ۳/۴ میلی‌ثانیه دارد که نشان می‌دهد مدل TFT با وجود پیچیدگی بیشتر، زمان استنتاج قابل مقایسه‌ای ارائه می‌دهد. این


موضوع حاکی از آن است که مدل TFT می‌تواند در کاربردهای عملی و که نیاز به پیش‌بینی سریع دارد، مورد استفاده قرار گیرد. همچنین مدل Informer با زمان آموزش ۶۵ دقیقه و زمان استنتاج ۲/۸ میلی‌ثانیه، از نظر سرعت کمی بهتر از TFT است اما در مقابل دقت کمتری دارد که نشان‌دهنده وجود یک trade-off بین دقت و سرعت در این روش‌ها می‌باشد.

بحث و نتیجه‌گیری

در این تحقیق، یک مدل پیش‌بینی قیمت طلا بر اساس معماری Temporal Fusion Transformer (TFT) ارائه و پیاده‌سازی شد. هدف اصلی پژوهش، بهبود دقت پیش‌بینی قیمت طلا با بهره‌گیری از قابلیت‌های منحصربه‌فرد TFT شامل شبکه انتخاب متغیر، واحدهای خطی گیت‌دار و مکانیزم توجه چندهدفه تفسیرپذیر بود. مدل پیشنهادی بر روی دیتاست واقعی ۱۰ ساله (۲۰۱۴-۲۰۲۴) شامل قیمت روزانه طلا و متغیرهای تأثیرگذار مرتبط، ارزیابی و با شش روش مطرح شامل ARIMA، SARIMA، LSTM، GRU، Transformer استاندارد و Informer مقایسه شد. نتایج ارزیابی نشان داد که مدل TFT پیشنهادی با مقادیر RMSE برابر ۱۸/۴۲ دلار بر اونس، MAPE معادل ۰/۸۹ درصد و R^2 برابر ۰/۹۵۳۴، عملکرد بهتری نسبت به تمام روش‌های مقایسه داشته است. مدل پیشنهادی توانست خطای RMSE را نسبت به ARIMA و LSTM به ترتیب ۵۷ و ۳۰ درصد کاهش دهد. همچنین دقت جهتی MDA برابر ۷۲/۵ درصد نشان داد که مدل در بیش از ۷۲ درصد موارد جهت حرکت قیمت را به درستی پیش‌بینی می‌کند که برای اهداف معاملاتی بسیار حائز اهمیت است. آزمون آماری دایبولد-ماریانو نیز بهبود عملکرد مدل TFT را نسبت به پنج روش از شش روش مقایسه، در سطح اطمینان ۹۵ درصد تأیید کرد. در مجموع، می‌توان نتیجه گرفت که معماری Temporal Fusion Transformer با قابلیت‌های ویژه خود شامل انتخاب هوشمند متغیرها، کنترل جریان اطلاعات از طریق واحدهای گیت‌دار و توجه به الگوهای بلندمدت با مکانیزم توجه، یک روش مؤثر و قابل اعتماد برای پیش‌بینی قیمت طلا محسوب می‌شود. این مدل نه تنها از نظر دقت عددی برتر است، بلکه با ارائه فواصل اطمینان قابل اعتماد و قابلیت تفسیر نتایج، می‌تواند به عنوان یک ابزار تصمیم‌گیری کارآمد در اختیار تحلیلگران، سرمایه‌گذاران و معامله‌گران بازار طلا قرار گیرد. مقایسه نتایج بدست آمده در شکل ۲ و ۳ قرار داده شده است.



شکل ۲. مقایسه روش پیشنهادی با سایر روش‌ها از نظر سایر معیارها



شکل ۳. مقایسه روش پیشنهادی با سایر روش‌ها از نظر RMSE

نمودارهای میله‌ای ارائه شده در شش زیرنمودار (شکل ۲)، عملکرد مدل TFT پیشنهادی را در مقایسه با شش روش دیگر شامل ARIMA، SARIMA، LSTM، GRU، Transformer استاندارد و Informer نشان می‌دهند. در نمودارهای مربوط به معیارهای خطا (RMSE، MAE و MAPE) که هرچه مقدار کمتر باشد نشان‌دهنده عملکرد بهتر است، مدل TFT پیشنهادی با مقادیر ۱۸/۴۲، ۱۳/۸۷ و ۰/۸۹ درصد به ترتیب کمترین میزان خطا را در بین تمام روش‌ها ثبت کرده است. به طور مشخص، مدل TFT توانسته است خطای RMSE را نسبت به ARIMA حدود ۵۷ درصد و نسبت به بهترین روش رقیب (Informer) حدود ۸/۵ درصد کاهش دهد. در نمودار ضریب تعیین R^2 که هرچه به عدد یک نزدیک‌تر باشد نشان‌دهنده قدرت توضیح‌دهندگی بیشتر مدل است، مدل TFT با مقدار ۰/۹۵۳۴ بهترین عملکرد را داشته و توانسته است ۹۵/۳۴ درصد از تغییرات قیمت طلا را توضیح دهد که نسبت به Transformer استاندارد (۰/۹۱۲۳) بهبود ۴/۵ درصدی را نشان می‌دهد. نمودار دقت جهتی MDA نیز نشان می‌دهد مدل TFT با ۷۲/۵ درصد بهترین عملکرد را داشته و نسبت به LSTM با ۶۱/۲ درصد و ARIMA با ۵۲/۳ درصد برتری چشمگیری دارد. نمودار میله‌ای (شکل ۳)، بهبود درصدی نشان می‌دهد که هر یک از روش‌های پیشرفته تا چه اندازه توانسته‌اند خطای RMSE را نسبت به روش کلاسیک ARIMA کاهش دهند. بر اساس این نمودار، مدل SARIMA با ۸/۶ درصد بهبود، کمترین میزان بهبود را در بین روش‌های پیشرفته داشته است. مدل‌های LSTM و GRU به ترتیب با ۳۸/۱ و ۴۱/۸ درصد بهبود، عملکرد بهتری نسبت به روش‌های ساده یادگیری عمیق داشته‌اند. در این میان، مدل TFT پیشنهادی با ۵۶/۷ درصد بهبود، بهترین عملکرد را در کاهش خطای پیش‌بینی نسبت به روش پایه ARIMA داشته است. این بهبود ۵۶/۷ درصدی نشان می‌دهد که معماری ترکیبی TFT با بهره‌گیری از شبکه انتخاب متغیر، واحدهای خطی گیت‌دار و مکانیزم توجه چندهدفه، توانسته است به طور معناداری دقت پیش‌بینی را نسبت به روش‌های سنتی و حتی نسبت به سایر روش‌های یادگیری عمیق افزایش دهد. همچنین شیب صعودی میله‌های نمودار از SARIMA تا TFT نشان‌دهنده روند رو به بهبود عملکرد روش‌های پیش‌بینی با پیشرفت معماری‌های مبتنی بر توجه و Transformer است.

پیشنهادهای پژوهشی برای تحقیقات آینده می‌تواند موضوعات زیر باشد:

- استفاده از داده‌های با فرکانس بالاتر و چندمنبعی
- بهینه‌سازی معماری TFT و کاهش زمان آموزش
- توسعه مدل‌های ترکیبی با سایر روش‌های هوش مصنوعی
- ارزیابی بر روی سایر دارایی‌های مالی و بازارهای مختلف
- توسعه سیستم معاملاتی خودکار مبتنی بر TFT
- ترکیب TFT با تحلیل تکنیکال و اندیکاتورهای پیشرفته
- پیاده‌سازی نسخه آنلاین و یادگیری افزایشی

منابع :

- Baur, D. G., & Lucey, B. M. (2010). Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold. *Financial review*, 45(2), 217-229.
- Beckmann, J., & Czudaj, R. (2013). Gold as an inflation hedge in a time-varying coefficient framework. *The North American Journal of Economics and Finance*, 24, 208-222.
- Cheng, Q., Wang, X., Shi, S., & Wang, Z. (2025). Heterogeneous impacts of fundamentals on gold market risk using regime switching quantile-based GARCH-MIDAS model: Q. Cheng et al. *Empirical Economics*, 69(3), 1411-1465.
- Amini, A., & Kalantari, R. (2024). Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning. *Plos one*, 19(3), e0298426.
- Ramisa, N. T., Priya, M. J., Masud, M. A., & Samsuzzaman, M. (2026, January). Temporal Attention-Based Hybrid TCN-BiLSTM-GRU Architecture for Gold Price Prediction. In *2026 5th International Conference on Electrical, Computer & Telecommunication Engineering (ICECTE)* (pp. 1-6). IEEE.
- Wu, J., & Liu, J. (2026). Gold Price Prediction Based on LSTM-Attention Combined Model. *Open Access Library Journal*, 13, e1114759.
- Memon, B. A., Tahir, R., Naveed, H. M., & Cheng, K. (2025). Forecasting Gold and Platinum prices with an enhanced GRU model using multi-headed attention and skip connection. *Mineral Economics*, 38(4).
- Zhao, Y., Guo, Y., & Wang, X. (2025). Hybrid LSTM-Transformer architecture with multi-scale feature fusion for high-accuracy gold futures price forecasting. *Mathematics*, 13(10), 1551.
- Yang, Y. (2025). TCN-QV: an attention-based deep learning method for long sequence time-series forecasting of gold prices. *PLoS One*, 20(5), e0319776.
- Lin, Y. (2026). An Improved CNN-LSTM Model for Daily Gold Price Prediction. *Proceedings of IWADIC 2025*, Atlantis Press, 608-621.
- <https://www.kaggle.com/datasets/sail4karthik/nasdq-dataset>