



Modeling gold price volatility predictions in the global market

Tavassoli, M.¹ || Rabiei, M.² || Fathi Hafshejani, K.³

Type of Article: **Research**

10.22126/pse.2024.11110.1151

Received: 14 September 2024; Accepted: 28 October 2024

P.P: 647-698

Abstract

Gold is widely used by investors as a hedge against other financial assets, underscoring its critical importance. Sharp fluctuations in gold prices have highlighted the need to identify and understand the factors influencing these price changes. The gold market is known for its volatility, and accurate predictions about its future can significantly impact decision-making. Understanding the gold price and making correct forecasts can help inform decisions about buying and selling gold in global markets, and determine the most favorable times for transactions and investments. Therefore, it is crucial to accurately predict the gold price from various perspectives. This study aims to model and predict gold price volatility in the global market. The research is applied in nature and utilizes monthly data from 2010 to 2022. We evaluated 35 factors potentially affecting gold price volatility. GARCH models and stochastic volatility approaches were employed to extract gold price volatility, while TVPDMA, TVPDMS, and BMA models were used to identify the most significant variables driving volatility. Results indicate that SV models outperform GARCH models in accurately extracting volatility. Among the TVPDMA, TVPDMS, and BMA models, the BMA model demonstrated superior accuracy. Findings reveal that 12 key variables—including the dollar index, oil prices, gold imports and exports, global interest rates, cryptocurrency index, Relative Strength Index (RSI), Moving Average Convergence Divergence (MACD), Fibonacci Retracement, Average Directional Index (ADX), stock oscillator, and DeMark and Fibonacci Pivot Points—showed the highest likelihood of presence and significance in predicting price volatility. The results suggest that internal factors have a greater impact on gold price volatility than external factors.

Keywords: Gold price Predictions, Oil Price, GARCH, Bayesian Averaging.

JEL Classification: C15, C3, E31, E37, C22.

1. Ph.D Student, Department of Information Technology Management, South Tehran Branch, Islamic Azad University, Tehran, Iran.

Email: st_mahdieh_tavassoli@azad.ac.ir

2. Assistant Professor, Department of Economics, Modeling and Optimization Research Center in Engineering Sciences, South Tehran Branch, Islamic Azad University, Tehran, Iran (Corresponding Author).

Email: Dr_mahnaz_rabiei@azad.ac.ir

3. Assistant Professor, Department of Industrial Management, South Tehran Branch, Islamic Azad University, Tehran, Iran.

Email: fathi@azad.ac.ir

1. Introduction

Gold is used by investors as a hedge against (A tool to preserve the money value) other financial assets and is vital in this regard. The extreme fluctuations in its price have doubled the importance of identifying the factors affecting its price changes. The gold market is one of the most turbulent markets. Its prediction can positively influence the decisions made in this regard. It is possible to facilitate the decision-making process of buying and selling gold in the global markets and determine the best time to do transactions and investments in light of knowing the price of gold and correctly predicting it. Thus, the correct prediction of gold price is crucial from several aspects.

2. Theoretical Framework

The forces of supply and demand in the market affect the gold price, like any other commodity. However, many factors influence its supply and demand and its price since it is a very sensitive and strategic commodity. The gold price plays a vital role in monetary and financial systems. Predicting the future trend of gold and other precious metals prices will be effective for investors, financial managers, and central banks worldwide. In addition, the gold treasury is used to manage inflation and strengthen the economic position of countries. Predicting the gold rate is vital in political, economic, commercial, and investment fields. It is considered one of the most volatile and most profitable financial tools. Thus, small changes in its price can give a high percentage of profit or loss to the trader. Prediction and modeling of volatility is a vital issue in policymaking, commodity pricing, resource allocation, and risk management. Additionally, predicting fluctuations is vital in economic markets. Thus, it has been the focus of scholars and brokers for years.

Gold is an essential commodity used for financial purposes and is a part of international reserves in most state banks. It defines the basic role of that bank in the world's economy. Gold is the most common choice for investment among all precious metals. The capability to predict gold price fluctuations with high accuracy is essential for the global economy and commodity markets. Additionally, predicting gold price fluctuations is a serious concern in the financial industry. Small improvements in prediction accuracy can yield huge benefits. Gold and crude oil are strategic resources used extensively in various national economic activities and social security.

3. Methodology

The method of this study is applied. The purpose of the present study is to identify the most important variables affecting the fluctuation of gold prices. This issue was investigated in the present study due to the research gap in modeling this precious metal. In most studies conducted in this field, variables were included in the model based on the researchers' opinions. However, the optimal gold price prediction model was extracted in the present study based on dynamic and selective nonlinear Bayesian models, and the researcher did not apply his personal opinion in determining the variables. This study is one of the exploratory studies. The time horizon of this study is 12 years from 2010 to 2022.

4. Discussion

Investors look for factors that affect gold when they want to invest in it. According to the results, this study presents the significant factors that affect the gold price. Investors must consider all the factors affecting its price before making investment decisions. This issue enhances the investor's knowledge about changes in its price. The results of this study will help investors avoid any possible losses and set the right time to invest in the gold market. Thus, the investor must consider all these factors and monitor their changes. According to the results, SV models are more accurate than GARCH models in extracting fluctuations. According to the results, SV models are more accurate than GARCH models in extracting fluctuations. The BMA model had higher accuracy compared to the TVPDMA and TVPDMS models. According to the results, 12 effective variables including dollar index, oil price, gold import and export, global interest rate, cryptocurrency index, RSI (interest rate strength index), MACD (monthly average convergence divergence differential), Fibonacci retracement, ADX (Average Directional Index), oscillator (stock volatility), Pivot Point DeMark Pivot Point Fibonacci had the highest probability of presence and significant level in predicting price volatility.

5. Conclusion and Suggestions

The results indicate that the internal factors affecting the gold price fluctuations are more effective than the external factors. According to the results, non-linear approaches have a much higher power to predict gold price fluctuations than linear approaches, and investors and policymakers active in this market should monitor the changes in global macro and micro indices and pay more attention to the 12 variables.

6. Ethical Considerations

6.1. Compliance with ethical guidelines

The authors of the article declare that research ethics have been followed in this study.

6.2. Funding

No funding received from public, commercial or not-for-profit agencies.

6.3. Authors' contribution

The authors of the article declare that he has conducted all aspect of this study.

6.4. Conflict of interest

The author declares any conflicts of interest.

6.5. Acknowledgments

I greatly appreciate the valuable comments and suggestions from the respective reviewers, as they have significantly improved the quality of the article.





مدل سازی پیش بینی نوسانات قیمت طلا در بازار جهانی

مهدیه توسلی^۱ || مهناز ربیعی^۲ || کیامرث فتحی هفشجانی^۳

نوع مقاله: پژوهشی

10.22126/pse.2024.11110.1151

تاریخ دریافت: ۱۴۰۳/۰۶/۲۴؛ تاریخ پذیرش: ۱۴۰۳/۰۸/۰۷

صص: ۶۴۷-۶۸۶

چکیده

طلا توسط سرمایه‌گذاران به عنوان پوشش (ابزاری برای حفظ ارزش پول) در برابر سایر دارایی‌های مالی استفاده شده است و از این جنبه اهمیت بسیار بالایی دارد. نوسانات شدید در قیمت طلا اهمیت شناسایی و فرایند اثرگذاری عوامل مؤثر بر تغییرات قیمت آن را دوچندان کرده است. بازار طلا یکی از بازارهای پرتلاطم است که پیش‌بینی آینده آن می‌تواند در تصمیم‌گیری‌ها تأثیر مثبتی بر جای بگذارد. با آگاهی از قیمت طلا و پیش‌بینی صحیح آن می‌توان فرایند تصمیم‌گیری خریدوفروش طلا در بازارهای جهانی را تسهیل و بهترین زمان اجرای معاملات و سرمایه‌گذاری‌ها را تعیین کرد؛ لذا پیش‌بینی صحیح قیمت طلا از جهات مختلف حائز اهمیت است. در این تحقیق اقدام به مدل‌سازی پیش‌بینی نوسانات قیمت طلا در بازار جهانی شده است. تحقیق حاضر کاربردی است و از داده‌های ماهانه در بازه زمانی ۲۰۱۰ تا ۲۰۲۲ استفاده کرده است. ۳۵ عامل مؤثر بر ایجاد نوسانات قیمت طلا ارزیابی شده است. به منظور استخراج نوسان قیمت طلا از رویکرد مدل‌های گارچ و نوسان تصادفی و برای شناسایی مهم‌ترین متغیرهای مؤثر بر ایجاد نوسان از مدل‌های TVPDM، TVPDMS و BMA استفاده شده است. بر اساس نتایج، مدل‌های SV نسبت به مدل‌های گارچ در استخراج نوسانات از دقت بالاتری برخوردارند. از میان مدل‌های TVPDMA، TVPDMS و BMA، مدل BMA دقت بالاتری دارد. بر اساس نتایج، ۱۲ متغیر مؤثر شاخص دلار، قیمت نفت، واردات و صادرات طلا، نرخ بهره جهانی، شاخص رمزارزها، RSI (شاخص قدرت نرخ بهره)، MACD (دیفرانسیل ماهیانه درصدی حرکت متوسط)، Retracement (بازگشت فیبوناچی)، ADX (شاخص جهت در بازار)، Oscillator (نوسان سهام)، Pivot Point DeMark و Pivot Point Fibonacci بالاترین احتمال حضور و سطح معناداری را در پیش‌بینی قیمت نوسان دارند. نتایج بیانگر این واقعیت است که عوامل داخلی مؤثر بر نوسانات قیمت طلا بیش از عوامل بیرونی بر این نوسانات اثرگذارند.

واژه‌های کلیدی: پیش‌بینی قیمت طلا، قیمت نفت، گارچ، میانگین‌گیری بیزین.

طبقه‌بندی JEL: C15، C3، E31، E37، C22.

۱. دانشجوی دکتری، گروه مدیریت فناوری اطلاعات، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

Email: st_mahdieh_tavassoli@azad.ac.ir

۲. استادیار، گروه اقتصاد، مرکز تحقیقات مدل‌سازی و بهینه‌سازی علوم مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول).

Email: dr_mahnaz_rabiei@azad.ac.ir

۳. استادیار، گروه مدیریت صنعتی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

Email: fathi@azad.ac.ir

۱. مقدمه

طلا بهترین جایگزین نسبت به سایر دارایی‌های مالی مانند مسکن، ارز، سهام، رمزارز برای سرمایه‌گذاری سرمایه‌گذاران در سطح جهانی است. سرمایه‌گذاران در طول بحران مالی به طلا به‌عنوان سرمایه‌گذاری پشتیبان روی می‌آورند؛ زیرا ممکن است طلا به‌عنوان پوششی در برابر تورم استفاده شود (Ding et al, 2022). علاوه بر این، سرمایه‌گذاران در شرایط نامطمئن اقتصادی به‌سمت بازار طلا به‌عنوان پوششی در برابر عدم اطمینان حرکت خواهند کرد (Mainal et al, 2023). در دوره کووید-۱۹ طلا مهم‌ترین مأمن سرمایه‌گذاران بود (Wen et al, 2022). اکثر کشورها در این بازه ذخایر ارزی خود را به طلا تبدیل نمودند.

طلا یکی از محبوب‌ترین دارایی‌ها برای سرمایه‌گذاری سرمایه‌گذاران در بازارهای جهانی است (Hashim et al, 2022). به همین علت تعیین علل مؤثر بر نوسانات قیمت طلا مورد توجه محققین و سرمایه‌گذاران قرار گرفته است (Qian et al, 2019). طلا فلزی باارزش و گران‌بهاست و به‌عنوان دارایی املاک و مستغلات و دارایی‌های مالی مورد استفاده قرار گرفته است. قیمت طلا در بلندمدت در حال افزایش است، اما در کوتاه‌مدت کاملاً پرنوسان است (Mainal et al, 2023). امدی عیسی^۱ و همکاران (۲۰۲۰) بیان کرده‌اند که طلا پتانسیل حفظ قدرت خرید را برای سرمایه‌گذاران دارد؛ بنابراین، همه می‌توانند از ابزار سرمایه‌گذاری طلا برای گسترش سود خود در آینده نیز استفاده کنند (Dalam et al, 2019).

در مدل‌سازی نوسانات قیمت طلا به چند بُعد باید توجه داشت:

اول بررسی نوسانات سایر بازارها و دارایی‌ها بر قیمت طلاست. افزایش نرخ بهره باعث کاهش ارزش دلار و افزایش قیمت طلا می‌شود (Ibid). لیا^۲ و همکاران (۲۰۲۱) و هاشیم^۳ و همکاران (۲۰۲۲) نشان دادند که ذخایر طلا و قیمت انرژی عوامل مؤثر بر قیمت طلا هستند. آن‌ها بدین نتیجه دست یافتند که ذخایر طلا و محصولات انرژی رابطه مثبتی با قیمت طلا دارند. قیمت بالای طلا می‌تواند دلیل تورم بالا باشد (Apergis et al, 2019). با این حال، به‌وضوح توضیح داده نشده است که آیا نرخ تورم می‌تواند بر نوسانات قیمت طلا تأثیر بگذارد یا خیر. لانگ^۴ و همکاران (۲۰۲۲) نشان دادند نرخ ارز بر قیمت طلا اثرگذار است. با این حال، اقدامات نامشخصی توسط آن‌ها برای حل مشکل نوسانات قیمت طلا انجام شده است. ذکر یا^۵ و همکاران (۲۰۱۵) نشان دادند که تعداد کمی از شاخص‌های کلان اقتصادی بر افزایش و کاهش قیمت طلا تأثیر دارند. بر اساس نتایج تحقیقات آن‌ها نرخ بیکاری و تولید ناخالص داخلی نیز بر نوسانات قیمت طلا اثرگذارند. پلاکنداراس^۶ و همکاران (۲۰۲۲) بیان داشتند که برای پیش‌بینی صحیح قیمت طلا باید به عوامل درونی و بیرونی مؤثر بر آن توجه نمود.

1. Md Isa
2. Liya
3. Hashim
4. Long
5. Zakaria
6. Plakandaras

دوم توجه به استفاده از مدل های مختلف اقتصادسنجی است. محققان متعددی اثبات کردند که رویکردهای غیرخطی در پیش بینی قیمت طلا دقت بالاتری از رویکردهای خطی دارند (Cohen & Aiche, 2023). سوم نبود یک مدل مشخص در حوزه مدل سازی نوسانات قیمت طلاست. یک چالش کلیدی پیش بینی نوسانات قیمت طلا، عدم اطمینان محققان در مورد عوامل تعیین کننده آن است. در مطالعات تجربی و نظری، طیف وسیعی از مدل ها به عنوان مدل های مختلف پیش بینی نوسانات قیمت طلا معرفی شده اند؛ در واقع گستردگی طیف متغیرهای توضیحی مؤثر، این پرسش اساسی را در میان محققان مطرح کرده است که چه متغیرهایی باید در الگوی تجربی نوسانات قیمت طلا وارد شوند؟ این مشکل با عنوان نااطمینانی مدل شناخته می شود (Deniz & Stengos, 2023). بی توجهی به مسئله نااطمینانی مدل می تواند به تورش و عدم کارایی در برآورد پارامترها منجر شود که نتیجه آن پیش بینی های نامناسب و استنتاج آماری نادرست است؛ بنابراین، در مطالعات تجربی لازم است نااطمینانی مدل مدنظر قرار گیرد. یکی از روش های مناسب برای مشکل نااطمینانی مدل متوسط گیری از تمامی مدل ها یا روش میانگین گیری مدل بیزی^۱ است (Koop & Potter, 2024). توجه به این ابعاد سه گانه منجر به شکل گیری مسئله اصلی تحقیق حاضر شده است و اینکه در نتیجه، مدل سازی پیش بینی نوسانات قیمت طلا در بازار جهانی با تأکید بر رویکردهای بیزین غیرخطی چگونه است؟ برای دست یافتن به سؤال اصلی تحقیق سؤالات فرعی زیر قابل طرح است:

کاراترین رویکرد برای استخراج نوسان قیمت طلا کدام رویکرد است؟

مهم ترین متغیرهای غیرشکننده مؤثر بر قیمت طلا کدام اند؟

پس از مقدمه، در بخش دوم پیشینه و در بخش سوم روش پژوهش ارائه شده است. بخش چهارم به یافته های برآورد مدل و در نهایت، بخش پنجم به بحث و نتیجه گیری اختصاص یافته است.

۲. مبانی نظری

۲-۱. عوامل مؤثر بر قیمت طلا

قیمت طلا تحت تأثیر عرضه و تقاضا در بازار است؛ اما به دلیل استراتژیک بودن، عوامل زیادی بر نوسانات قیمت آن اثر می گذارد. طلا نقشی کلیدی در سیستم های پولی و مالی دارد و پیش بینی قیمت آن برای سرمایه گذاران، بانک های مرکزی و مدیران مالی از اهمیت بالایی برخوردار است. این فلز همچنین در مدیریت تورم و تقویت موقعیت اقتصادی کشورها کاربرد دارد. به دلیل نوسانات بالای طلا، تغییرات کوچک در قیمت آن می تواند تأثیر زیادی بر سود و زیان معامله گران داشته باشد.

مهم ترین عوامل مؤثر بر قیمت طلا عبارتند از:

(۱) **تقاضای طلا:** تقاضای طلا در چین و هند بالا است و عوامل فرهنگی و مذهبی در آسیای شرقی، هند و خاورمیانه نیز بر آن تأثیر دارند. این تقاضا لزوماً با نوسانات اقتصادی جهانی همبستگی ندارد. (Simakova, 2011).

(۲) **عرضه طلا:** کاهش کل عرضه طلا موجب افزایش قیمت و افزایش روند صعودی طلا می‌شود. چنین فرایند مشهودی در سال ۲۰۲۰ که عرضه جهانی به‌صورت محسوسی کاهش یافت قابل مشاهده بود (World Gold Council, 2020).

(۳) **هزینه مصرف خصوصی:** مصرف نهایی خانوار شامل هزینه‌های مصرفی کالاها و خدمات است. افزایش هزینه‌های مصرف خصوصی رشد اقتصادی را کاهش داده و باعث افزایش قیمت طلا می‌شود.

(۴) **افزایش تقاضای طلای هند و چین:** کاهش ارزش دلار باعث افزایش تقاضا برای طلا در این کشورها و در نتیجه رشد قیمت جهانی آن می‌شود (Ding et al, 2022; Adekoya et al, 2023).

(۵) **اعیاد و مناسبت‌ها:** تقاضا برای طلا در اعیاد و مناسبت‌های خاص افزایش می‌یابد (Huseynli, 2023).

(۶) **ارتباط بین طلا و تورم:** معمولاً در دوران تورم، قیمت طلا افزایش می‌یابد، اما در بحران‌های اقتصادی این رابطه ممکن است معکوس شود.

(۷) **شاخص بهای مصرف‌کننده:**^۱ افزایش نرخ تورم معمولاً تقاضا برای طلا را افزایش می‌دهد (Selvanathan & Selvanathan, 2022).

(۸) **تورم ناشی از به‌کارگیری سیاست‌های انبساطی پولی بانک‌های مرکزی:** این سیاست‌ها موجب افزایش قیمت‌ها و تقویت تقاضا برای طلا می‌شود (Huseynli, 2023).

(۹) **تأثیر نرخ مبادله دلار (ارزش دلار):** قیمت طلا در بازارهای جهانی بر اساس دلار تعیین می‌شود؛ بنابراین، تغییرات ارزش دلار تأثیر مستقیمی بر قیمت طلا دارد. کاهش ارزش دلار باعث افزایش قیمت طلا و بالعکس می‌شود. همچنین، طلا نقش محافظتی در برابر نوسانات ارزی برای سرمایه‌گذاران دلاری دارد.

(۱۰) **شاخص دلار آمریکا:** کاهش ارزش دلار موجب ورود سرمایه به بازار طلا و افزایش تقاضای بانک‌های مرکزی برای ذخایر طلا می‌شود که قیمت آن را بالا می‌برد. در مقابل، فروش رسمی طلا توسط کشورها و مؤسسات جهانی عامل اصلی کاهش قیمت آن است.

(۱۱) **عامل سفته‌بازی:**^۲ بازارهای قرارداد آتی و سفته‌بازی‌ها می‌توانند تقاضا و قیمت طلا را افزایش دهند (Berg, 2011).

1. CPI

2. Speculation Factor

(۱۲) ارتباط بین طلا و نرخ بهره بانکی: کاهش نرخ بهره باعث افزایش تقاضا برای طلا به عنوان یک دارایی جایگزین می شود (Selvanathan & Selvanathan, 2022).

(۱۳) ارتباط بین طلا و قیمت نفت: طلا و نفت هر دو کالاهای کمیاب و استراتژیک هستند و به دلیل رابطه نزدیک با تورم جهانی، همبستگی مستقیم دارند (Huseynli, 2023).

(۱۴) ارتباط بین طلا و قیمت سهام: عموماً رابطه مثبتی میان طلا و سهام وجود دارد؛ اما در بحران مالی ۲۰۰۷-۲۰۰۹، سرمایه گذاران به طلا به عنوان پناهگاه امن روی آوردند (Hashim et al, 2022).

(۱۵) ارتباط بین طلا و تولید ناخالص داخلی: طلا به دلیل نقدشوندگی بالا به راحتی به سرمایه تبدیل می شود، اما ارتباط آن با تولید ناخالص داخلی ضعیف یا منفی است (Selvanathan & Selvanathan, 2022).

(۱۶) ارتباط بین طلا و وقایع جغرافیایی-سیاسی: بحران های سیاسی و نظامی می توانند تقاضا برای طلا را افزایش دهند (Hashim et al, 2022).

(۱۷) ارتباط طلا با شرایط بحرانی: در بحران های مالی مانند بحران ۲۰۰۷-۲۰۰۸ و پاندمی کووید-۱۹، به دلیل عدم اطمینان مالی و اقتصادی، تقاضا برای طلا افزایش یافت (Hashim et al, 2022).

(۱۸) هرج و مرج و جنگ در کشورهای تولیدکننده نفت: بحران های سیاسی در کشورهای تولیدکننده نفت موجب افزایش تقاضا برای طلا می شود (Selvanathan & Selvanathan, 2022).

(۱۹) بحران های اقتصادی آمریکا و بدتر شدن وضعیت اقتصادی جهان: بحران های اقتصادی مانند ۱۱ سپتامبر ۲۰۰۱ و بحران مالی ۲۰۰۸ موجب افزایش تقاضا و قیمت طلا شدند (Selvanathan & Selvanathan, 2022).

(۲۰) بحران بدهی دولت آمریکا و کشورهای منطقه یورو و ژاپن: بحران بدهی و کاهش ارزش دلار باعث افزایش تقاضا برای طلا به عنوان پناهگاه امن سرمایه گذاران می شود.

(۲۱) SPDR: صندوق های سرمایه گذاری طلا مانند SPDR^۱ بر قیمت طلا تأثیرگذارند و افزایش قیمت طلا موجب رشد تقاضا برای سهام این صندوق ها می شود (Long et al, 2022).

(۲۲) تعهدات باز^۲: به معنای تقاضای بیشتر برای طلاست (Long et al, 2022).

(۲۳) فروش رسمی: اعلام خرید و فروش طلا از سوی بزرگترین دارندگان، معمولاً تقاضا و قیمت طلا را کاهش می دهد.

1. Standard and Poor's Depository Receipt

2. OPEN INTEREST

۲۴) **قیمت مسکن:** افزایش یا کاهش قیمت مسکن بر قیمت طلا تأثیرگذار است و در زمان کاهش تعداد معاملات مسکن، تقاضا برای طلا افزایش می‌یابد (Selvanathan & Selvanathan, 2022).

۲۵) **هزینه مصرفی دولت و سرمایه ناخالص:** افزایش هزینه مصرفی دولت موجب کاهش رشد اقتصاد و افزایش قیمت طلا می‌شود.

۲۶) **ورود بانک مرکزی کشورها به بازار طلا:** ورود بانک‌های مرکزی به بازار طلا معمولاً باعث افزایش قیمت آن می‌شود (Selvanathan & Selvanathan, 2022).

۲۷) **صندوق بین‌المللی پول و فروش طلا:** فروش ذخایر طلای بانک‌های مرکزی در گذشته قیمت طلا را کاهش می‌داد، اما اکنون کاهش ارزش دلار و رشد قیمت طلا نشان‌دهنده شرایط پیچیده اقتصادی است (سرافراز و افسر، ۱۳۹۶).

۲۸) **قیمت مس و سایر فلزات اساسی:** افزایش قیمت مس می‌تواند موجب افزایش قیمت طلا و کاهش آن می‌تواند تأثیر معکوس داشته باشد (Long et al, 2022).

۲۹) **نوسانات بازار طلا:** عواملی همچون تحلیل‌های تکنیکال و رفتارهای هیجانی نیز بر قیمت طلا تأثیرگذارند (Ibid).

۳. پیشینه پژوهش

پیش‌بینی نوسان قیمت‌ها در بازارهای مالی حیاتی است. طلا به‌عنوان اهرمی برای کنترل نوسانات تورمی استفاده می‌شود و اطلاع از روندهای آتی قیمت آن، تصمیم‌گیری سرمایه‌گذاران و دولتمردان را بهبود می‌بخشد. پیش‌بینی و مدل‌سازی نوسانات موضوع مهمی در سیاست‌گذاری، قیمت‌گذاری کالا، تخصیص منابع و مدیریت ریسک دارد. به‌علاوه، پیش‌بینی نوسانات وظیفه‌ای ضروری در بازارهای اقتصادی است که سالها مورد توجه فرهیختگان و کارگزاران بوده است (Fang et al, 2018). طلا به‌عنوان کالای مهم مالی، بخشی از ذخایر بین‌المللی در بانک‌های دولتی است و نقش اساسی در اقتصاد جهانی دارد.

۳-۱. مطالعات خارجی

دینگ^۱ و همکاران (۲۰۲۲) به بررسی ریسک سیاسی بر قیمت طلا پرداخته‌اند. بر اساس نتایج، رابطه مثبتی بین ریسک سیاسی و قیمت طلا وجود دارد. همچنین نرخ ارز و نرخ بهره بر بازده طلا تأثیر منفی دارد. ماینال^۲ و همکاران (۲۰۲۳) و سایلاج^۱ و همکاران (۲۰۲۲) ارتباط قیمت طلا و متغیرهای مختلف را بررسی کرده‌اند و بدین نتیجه دست یافته‌اند که متغیرهای تورم، تولید ناخالص داخلی، شاخص‌های بازار سهام، قیمت

1. Ding

2. Mainal

نفت خام و نرخ ارز خارجی تأثیر معناداری بر قیمت طلا دارد؛ اما متغیر کسری بودجه دولت تأثیر معناداری بر قیمت این متغیر ندارد.

حسینلی^۲ (۲۰۲۳) به بررسی رابطه علی بین قیمت جهانی نفت و قیمت طلا پرداخته است. او برای تعیین وجود رابطه بلندمدت بین دو متغیر از آزمون انگل گرنجر استفاده کرده و نتیجه گرفته است که رابطه علیت یک طرفه از قیمت طلا به قیمت نفت، قبل از همه گیری وجود دارد.

نیسارگا و ماریستی^۳ (۲۰۲۳) به بررسی عوامل مؤثر بر قیمت طلا در هند پرداخته اند. نتایج بیانگر تأثیر معنادار مابین متغیرهاست.

چنگانی^۴ و همکاران (۲۰۲۴) به تعیین روند قیمت با استفاده از مدل های تک متغیره و چندمتغیره اقدام کرده اند. نتایج نشان می دهد مدل های چندمتغیره تصحیح خطای برداری نسبت به مدل های تک متغیره از دقت بالاتری در پیش بینی قیمت طلا برخوردارند.

هوراک^۵ و همکاران (۲۰۲۴) روند قیمت طلا در سال های ۲۰۰۰ تا مارس ۲۰۲۳ را بررسی کرده اند که نتایج مطالعاتشان نشان می دهد رایج ترین عناصر مؤثر بر توسعه تاریخی قیمت طلا جنبه های سیاسی، اقتصادی، فناوری و اجتماعی بوده است. علاوه بر این، شبکه های عصبی مصنوعی قادر به پیش بینی دقیق روند قیمت طلا و در نتیجه تقلید منحنی توسعه قیمت واقعی هستند.

۳-۲. مطالعات داخلی

کاظم زاده و همکاران (۱۳۹۸) در پژوهش خود به پیش بینی قیمت طلا در ایران با استفاده از رگرسیون داده ها و با تواتر متفاوت طی دوره ۱۳۷۶-۱۳۹۶ پرداخته اند. برای این منظور از متغیرهای سری زمانی به صورت سالیانه، فصلی، ماهیانه و حتی روزانه و با تجمیع آن ها در یک رگرسیون استفاده کرده اند. در این رگرسیون از داده های ماهیانه نرخ ارز، شاخص کل بورس و قیمت اونس جهانی و از متغیرهای مجازی مانند نوسانات سیاسی، هیجانات بازار و فصل تابستان به عنوان متغیرهای تأثیرگذار بر سکه طلا بهره برداری شده است. اعتبارسنجی مدل حاکی از آن است که مدل پیشنهادی قدرت پیش بینی دقیق تری در دامنه داده های پرتواتر دارد.

خانی و همکاران (۱۴۰۰) اقدام به بررسی رهیافت پویایی سیستم برای پیش بینی قیمت طلا در ایران در بازه زمانی ۱۳۸۹-۱۴۰۵ پرداخته اند. شبیه سازی با نرم افزار Venism انجام شده است. این مقاله در سناریوهای مختلفی به شبیه سازی تغییر حجم نقدینگی، شاخص قیمت مصرف کننده و نرخ بهره بانکی بر بازار طلا پرداخته است. نتایج نشان می دهد قیمت طلا نه تنها متأثر از قیمت اونس جهانی و ارزش دلار است، بلکه کنترل نقدینگی و مهار تورم نقش به سزایی در ثبات بازار طلا خواهد داشت. نتایج مؤید این موضوع است که حجم نقدینگی و

1. Sailaja

2. Huseynli

3. Nisarga & Marisetty

4. Changani

5. Horak

شاخص قیمت مصرف‌کننده تأثیر مستقیم و نقش قابل توجهی در افزایش قیمت طلا دارد. همچنین، یافته‌ها نشان می‌دهد که تغییر نرخ بهره بانکی تأثیری بر تغییر قیمت طلا تأثیر ندارد.

حسینی و نمکی (۱۴۰۲) با استفاده از مدل‌های یادگیری عمیق و به‌طور مشخص‌تر شبکه حافظه بلند کوتاه‌مدت (LSTM)، روند حرکت قیمتی طلا را پیش‌بینی کرده‌اند. با توجه به نتایج و مقادیر خطای به‌دست‌آمده، شبکه LSTM می‌تواند به‌عنوان ابزاری قدرتمند به‌منظور پیش‌بینی قیمت طلا مورد استفاده قرار بگیرد.

گرگ‌بندی و موسوی (۱۴۰۲) به پیش‌بینی روند کوتاه‌مدت قیمت طلا در بازار فارکس با استفاده از شبکه‌های عصبی عمیق پرداخته‌اند. نتایج بیانگر این است که مدل طراحی‌شده تا حداقل دقت ۶۰ درصد در پیش‌بینی روند کوتاه‌مدت قیمت طلا می‌تواند با دقت عمل کند.

ابراهیمی و همکاران (۱۴۰۳) مدل‌های مختلف یادگیری ماشین برای پیش‌بینی قیمت طلا را بررسی کرده‌اند. به این منظور، ابتدا روش‌های مختلف آنالیز سری‌های زمانی در دسته یادگیری سطحی مانند الگوریتم ژنتیک، رگرسیون و آرمیا اعمال شده و سپس روش LSTM که نوعی شبکه عصبی بازگشتی (RNN) در دسته یادگیری عمیق برای مدل‌سازی سری‌های زمانی با هدف پیش‌بینی قیمت طلاست بررسی شده است. نتایج نشان‌دهنده برتری و پایداری LSTM و نیز روش رگرسیون است.

در جمع‌بندی نتایج تحقیق با تحقیقات مشابه می‌توان بیان کرد که در تحقیق حاضر برخلاف تحقیقات پیشین، به هردو بُعد عوامل داخل و خارج بازار مؤثر بر نوسانات طلا پرداخته شده و برای اولین بار در تحقیقات داخلی به مدل‌سازی نوسانات این بازار بر اساس رویکردهای بیزین غیرخطی پرداخته شده است.

۴. روش‌شناسی پژوهش

این پژوهش کاربردی به شناسایی مهم‌ترین متغیرهای مؤثر بر نوسان قیمت طلا می‌پردازد و از مدل‌های بیزی غیرخطی پویا برای پیش‌بینی استفاده می‌کند. تحقیق به‌صورت اکتشافی و بدون دخالت نظر شخصی در انتخاب متغیرها انجام شده و دوره زمانی آن از سال ۲۰۱۰ تا ۲۰۲۲ است. فرایند تحقیق در نمودار ۱ نمایش داده شده است.



نمودار ۱. فرایند انجام تحقیق

بر اساس این نمودار، ابتدا نوسانات قیمت طلا استخراج شده است. برای انجام این کار از دو رویکرد مدل گارچ و مدل نوسان تصادفی و مقایسه دقت آن‌ها بهره گرفته شده است. در ادامه بر اساس مبانی نظری و تجربی، متغیرهای مؤثر بر نوسانات قیمت طلا در سطح داخلی و خارجی استخراج و بر اساس مدل‌های میانگین‌گیری بیزین، پویا و انتخابی مهم‌ترین متغیرهای غیرشکننده مؤثر بر نوسان قیمت طلا شناسایی شده است. بر اساس نتایج آن‌ها نیز مدل بهینه نوسانات قیمت طلا استخراج شده است.

جدول ۱. عوامل مؤثر بر نوسانات قیمت طلا

عوامل	شاخص	محققان
عوامل کلان	دلار	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020); Sharma et al (2021); Ding et al (2022)
	نرخ وجوه فدرال رزرو	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020)
	CPI	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020)
	بیکاری	Zakaria et al (2015)
	نرخ ارز	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020); Zhang et al (2020); Ding et al (2022)
	قیمت نفت	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020); Zhang et al (2020); Tanin et al (2022); Daga & James (2020)
	بازدهی سهام داو جونز	Qian et al (2019); Nisarga & Marisetty (2023); Sailaja et al (2020); Sharma et al (2021); Ding et al (2022)
	بازدهی سهام S&P 500	Sailaja et al (2020); Sharma et al (2021); Ding et al (2022)
	تولید ناخالص داخلی	Sailaja et al (2020)
	کسری بودجه	Sailaja et al (2020)
	واردات و صادرات طلا	Pradeep & Karunakaran (2022); Vallabh (2022)
	ریسک ژئوپلیتیک	Chiang (2022)
	نااطیمانی اقتصادی	Chiang (2022)
	بیماری‌های اپیدمی	Tanin et al (2022)
	نرخ بهره جهانی	Choudhary (2021); Ding et al (2022)
	ریسک سیاسی	Ding et al (2022)
	قیمت پلاتین	Yuan et al (2020)
	قیمت پالادیم	Yuan et al (2020)
	قیمت نقره	Yuan et al (2020)
	شاخص رمزارزها	Yuan et al (2020)
عوامل خرد	RSI (شاخص قدرت نرخ بهره)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
(درون بازار)	SMA (میانگین متحرک ساده)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)

Bands ^۱ (نوارهای بولینجر)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
MACD ^۲ (دیفرانسیل ماهیانه درصدهای حرکت متوسط)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Retracement ^۳ (بازگشت فیبوناچی)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
ADX ^۴ (شاخص جهت در بازار)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Oscillator (نوسان سهام)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
ATR ^۵ (متوسط دامنه حقیقی)	Sadeghi (2019); Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Ichimoku Cloud ابر	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
پیوت پوینت	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Pivot Point Woodie	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Pivot Point DeMark	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Pivot Point Camarilla	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Pivot Point Floor	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)
Pivot Point Fibonacci	Ishaq et al (2019); Hoo et al (2021); Zhao (2017)

در ادامه به بررسی رویکردها و مدل‌های برآوردی پرداخته می‌شود. در بخش اول مدل‌های گارچ و نوسان تصادفی و در بخش دوم مدل‌های TVP-DMA و BMA بررسی شده است. در جدول ۱، عوامل داخلی و خارجی مؤثر بر نوسان قیمت طلا ارائه شده و در مقابل هر متغیر، مرجع آن ذکر شده است.

۴-۱. مدل‌های گارچ و نوسان تصادفی

با توجه به اهمیت موضوع، روش‌های متفاوتی برای برآورد نوسان‌پذیری وجود دارد. در تحقیق حاضر دو رویکرد گارچ چندمتغیره و نوسان تصادفی ارائه شده توسط بولرسو^۶ (۱۹۸۶) و پون و گرنجر^۷ (۲۰۰۳) به کار رفته است. پس از مدل‌های GARCH، مدل نوسان‌پذیری تصادفی (SV) معرفی شدند (Taylor, 1986; Jacquier et al, 2002). مدل‌های نوسان‌پذیری تصادفی نوسان‌پذیری را متغیری مشاهده‌ناپذیر لحاظ می‌کنند. ضمن آنکه این مدل زمانی حاصل می‌شود که گشتاور دوم شرطی صرفاً نه یک متغیر لحاظ‌نشده، بلکه دارای یک پویایی درونی نیز باشد؛ بنابراین، مدل نوسان‌پذیری تصادفی شامل دو فرایند تصادفی جداگانه است:

$$y_t - \mu_t = Z_t \quad (۱)$$

1. Bollinger Bands
2. Moving Average Convergence Divergence
3. Fibonacci
4. Average Directional Movement
5. Average True Range
6. Bollerslev
7. Poon & Granger

$$\mu_t = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} + \begin{bmatrix} b_1 & b_2 \\ b_3 & b_4 \end{bmatrix} \begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} \quad (2)$$

y_t نوسان قیمت طلاست و با استفاده از معادله ۱، ابتدا میانگین و روند متغیر استخراج می شود و سری Z_t که جزء اخلاص معادله ۱ است به دست می آید. در واقع از این معادله متغیر روندزایی و میانگین زدایی شده تا در معادله بعدی به کار برود. μ_t داده های قیمت نوسانات طلاست که از یک فرایند اتورگرسیو مرتبه اول $AR(1)$ تبعیت می کند (Lee et al, 2020). حال بر اساس مطالعات مختلف داریم:

$$Z_t = H_t^{\frac{1}{2}} \varepsilon_t \quad \varepsilon_t \sim iid N_2(0_2, I_2) \quad (3)$$

که H_t عبارت است از:

$$H_t = \begin{bmatrix} \exp\{h_{1t}\} & 0 \\ 0 & \exp\{h_{2t}\} \end{bmatrix} \quad (4)$$

که در Z_{it} (Z_t در متغیرهای مختلف) متغیر مربوط به نوسان پذیری متغیر λ_t در دوره زمانی λ_t است. هریک از معادلات Z_t به طور جداگانه ارائه شده و می توان از آن ها لگاریتم گیری کرد. ماتریس رابطه ۴ به صورت روابط ۵ و ۶ قابل ارائه اند.

$$\log(Z_{it}) = 0.5h_{it} + e_{it} \quad e_t \sim iid N_2(0_2, I_2) \quad (5)$$

$$\begin{bmatrix} h_{1t+1} \\ h_{2t+1} \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 \\ 0 & \phi_{22} \end{bmatrix} \begin{bmatrix} h_{1t} \\ h_{2t} \end{bmatrix} + \begin{bmatrix} \eta_{1t} \\ \eta_{2t} \end{bmatrix} \quad \eta_t \sim iid N_2(0_2, \begin{bmatrix} \sigma_{\eta 1}^2 & \sigma_{\eta 12}^2 \\ \sigma_{\eta 2}^2 & \sigma_{\eta 22}^2 \end{bmatrix}) \quad (6)$$

متغیر h_{it} متغیر مشاهده ناپذیر است.

۴-۱-۲. مدل TVP-DMA

برای توصیف اینکه فرایند روش DMA چگونه است، فرض می شود که K مدل زیرمجموعه از متغیرهای z_t به عنوان تخمین زن وجود دارند و $z^{(k)}$ با $k = 1, 2, \dots, K$ بیانگر K مدل زیرمجموعه فوق می باشند. بر این اساس، با فرض وجود K مدل زیرمجموعه در هر مقطع از زمان، مدل فضا-حالت به صورت زیر توصیف می شود:

$$y_t = z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \quad (7)$$

$$\theta_{t+1}^{(k)} = \theta_t^{(k)} + \mu_t^{(k)} \quad (8)$$

در این معادلات، $\varepsilon_t^{(k)} \sim N(0, H_t^{(k)})$ و $\mu_t^{(k)} \sim (0, Q_t^{(k)})$ و $\vartheta_t = (\theta_t^{(1)}, \dots, \theta_t^{(k)})$ $L_t \in$ و $\{1, 2, \dots, K\}$ بیانگر این است که از K مدل مورد بررسی، کدام مدل کارا تر است. تخمین یک مدل متفاوت در هر زمان توسط مدل پویای میانگین گیری امکان پذیر است (Koop & Korobilis, 2009). تفاوت مدل های DMA با مدل های DMS در این واقعیت است که در مدل های DMS صرفاً مدلی که بالاترین سطح احتمال

وقوع را دارد به عنوان مدل بهینه تعیین می شود؛ اما در مدل های DMA از میان مدل های برآوردی اقدام به میانگین گیری می شود. برای مقایسه مدل ها نیز از دو شاخص محاسبه خطا بهره گرفته می شود که در ادامه آمده است:

$$MSFE = \frac{\sum_{t=\tau_0}^T [y_t - E(y_t | Data_{t-h})]^2}{T - \tau_0 + 1} \quad (9)$$

$$MAFE = \frac{\sum_{t=\tau_0+1}^T [y_t - E(y_t | Data_{t-h})]}{T - \tau_0 + 1} \quad (10)$$

که در آن، $Data_{t-h}$ اطلاعات به دست آمده از دوره $t-h$ است و h همان افق زمانی پیش بینی است. $E(y_t | Data_{t-h})$ نیز پیش بینی نقطه ای y_t است (Koop & Korobilis, 2020).

۴-۱-۳. روش BMA

مواجهه با انبوهی از مدل های بالقوه و همچنین تعدد عوامل و منابع مؤثر بر نوسان قیمت طلا می تواند به نااطمینانی در تصریح مدل مناسب منجر شود و کارایی ضرایب برآوردی را با مشکلات جدی روبه رو سازد (Moral-Benito, 2012). رگرسیون های خطی با قدری تساهل، با تمرکز بر ضرایب چند متغیر معین، از موارد مهمی مانند نااطمینانی در تصریح مدل صرف نظر می کرده اند (Levine & Renelt, 1992)؛ لذا باید نوع نگاه به رگرسیون های رشد تغییر کند و رهیافتی جهان شمول مورد توجه قرار گیرد تا ابهام حاصل از نااطمینانی در تصریح مدل، دقت و اعتبار برآوردها را مخدوش نسازد (Ghosh & Samanta, 2001). قضاوت های بیزی بر اساس قضیه بیز یک نتیجه گیری ساده از احتمال شرطی است. تابع احتمال، همراه با توزیع قبلی پارامتر، برای به دست آوردن توزیع پسین ضرب می شوند. برای محاسبه احتمال پارامتر θ ، با وجود اطلاعات D ، توزیع پسین $Pr(\theta | D)$ قضیه بیز به صورت زیر به دست می آید:

$$Pr(\theta | D) = Pr(D | \theta) * \frac{Pr(\theta)}{Pr(D)} \quad (11)$$

جایی که اطلاعات موجود است:

$$Pr(D) = \int Pr(D | \theta) Pr(\theta) d\theta \quad (12)$$

توزیع پسین $Pr(D | \theta)$ ، هنگامی که داده های D وجود دارد، به صورت زیر محاسبه می شود:

$$Pr(\text{توزیع قبلی}) \times Pr(\text{احتمال وقوع حضور متغیر غیرشکنده در مدل}) \propto Pr(\text{توزیع پسین})$$

در صورت غیرشکنده بودن متغیر، از تعامل توزیع پسین و پیشین توابع مشترک و پیشین مزدوج حاصل می شود که توانایی پیش بینی متغیر را در توضیح دهنده متغیر وابسته افزایش می دهد. در این تحقیق، برای تجزیه و تحلیل از توزیع های گاما و عادی استفاده شده است.

۵. یافته‌های پژوهش

در این تحقیق، بر اساس رویکرد هاروی^۱ و همکاران (۱۹۹۴)، مدل نوسان پذیری تصادفی برآورد شده است. برای محاسبه اثر گارچ در قیمت طلا این مراحل طی شد: برای محاسبه نوسانات قیمت طلا ابتدا لازم بود مدل آرما یا اریمای بهینه سری قیمت طلا در بازه زمانی مذکور استخراج شود. برای این کار، سپری کردن مراحل زیر لازم بود: قبل از هر کاری باید درباره مانا یا نامانا بودن سری قیمت طلا اطمینان حاصل شود. با توجه به مانا بودن قیمت طلا لازم است از روش آرما برای تعیین مدل بهینه بهره گرفته شود. در ادامه باید وقفه بهینه آرما بر اساس شاخص‌های آکائیک تعیین شود. بر اساس پیشنهاد اولیه نمودار AC و PAC، وقفه پیشنهادی وقفه یک برای AR و یک برای MA مورد ارزیابی قرار گرفت. در جدول ۲ آزمون LM-TEST ارائه شده است.

جدول ۲. نتایج آماره آکائیک در وقفه بهینه آرما قیمت طلا

متغیر	مقدار آکائیک در وقفه (۱و۱)
میزان آماره آکائیک	(۴/۹۰)

(منبع: محاسبات تحقیق).

بر اساس نتایج شاخص آکائیک، در حالتی که مدل کمترین آکائیک را داشته باشد، وقفه (۱و۱) برای مدل محاسبه شد. به منظور اطمینان از بهینه بودن مدل، جزء اخلاص مدل را و نیز مانایی جزء اخلاص مدل آرما بهینه را محاسبه می‌کنیم. در صورت مانا بودن جزء اخلاص، مراحل باکس-جنکینز به درستی انجام شده است:

جدول ۳. نتایج آزمون دیکی فولر جز اخلاص آرما بهینه مخارج دولتی

متغیر	با روند و عرض از مبدأ
جزء اخلاص مدل بهینه آرما	-۸/۸۴
قیمت طلا (در سطح)	(۰/۰۰۰۰)

(منبع: محاسبات تحقیق).

در نهایت، برای برآورد آزمون آرچ اقدام شده و در صورت وجود اثر آرچ، مدل گارچ برآورد و نوسانات قیمت طلا استخراج شده است:

جدول ۴. نتایج آزمون آرچ قیمت طلا

Variance Equation				
C	-0.609645	0.210425	-2.897203	0.0038
RESID(-1)^2	-0.956854	0.052148	-18.34880	0.0000

(منبع: محاسبات تحقیق).

با توجه به معناداری ضریب $RESID(-1)^2$ ، اثر آرج در داده‌های زمانی تأیید می‌شود. در جدول ۵ مدل گارچ سری نوسانات قیمت طلا استخراج شده است:

جدول ۵. نتایج مدل گارچ قیمت طلا

Variance Equation				
C	4018.384	97.42437	41.24619	0.0000
RESID(-1)^2	0.986056	0.135936	7.253805	0.0000
GARCH(-1)	-0.538119	0.202947	-2.651522	0.0080


(منبع: محاسبات تحقیق)

با توجه به معناداری ضریب $GARCH(-1)$ ، وجود مدل گارچ در داده‌های سری زمانی نوسانات قیمت طلا تأیید می‌شود. در این بخش به منظور استخراج نوسان قیمت طلا از دو رویکرد گارچ و نوسان تصادفی بهره گرفته می‌شود. نتایج آن نیز در جدول ۶ ارائه شده است:

جدول ۶. مقایسه نتایج گارچ و نوسان تصادفی

میزان خطا MSFE	معادله واریانس				معادله میانگین			
	$\sigma_{\eta12}$	$\sigma_{\eta1}^2$	φ_1	λ_1	b2	b1	a1	
۰/۰۳۷۲	۰/۰۸۱	-۰/۵۶	۰/۹۹	۴۱۹۰/۳۱۱	۰/۱۷	۰/۸۱	۰/۲۳۵	نوسان
	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	تصادفی
۰/۰۹۳۶	-	-۰/۵۳	۰/۹۸	۴۰۱۸/۳۸۴	۰/۱۳	۰/۷۸	۰/۲۲	گارچ
		(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۰۰)	(۰,۰۱۳)	

با توجه به نتایج، مشاهده می‌شود که مدل نوسان تصادفی از دقت بالاتری نسبت به مدل گارچ برخوردار است؛ در نتیجه مدل نوسان تصادفی برای استخراج نااطمینانی قیمت طلا به کار گرفته می‌شود. استخراج نوسان قیمت طلا در هر دو رویکرد در نمودار ۲ ارائه شده است. در این نمودار، نوسان استخراج شده قیمت طلا بر اساس روش‌های نوسان تصادفی و گارچ ترسیم شده و رنگ سبز نیز روند میانگین متحرک این نوسانات را ارائه کرده است. بر اساس نتایج، نوسان متغیر قیمت طلا از یک سیکل رفتاری تبعیت می‌کند که این امر می‌تواند به شرایط اقتصاد و رونق و رکودهای جهانی وابسته باشد.



نمودار ۲. استخراج نوسانات در مدل گارچ و نوسان تصادفی

در ادامه اقدام به تعیین مدل بهینه در مدل‌های پارامتر متغیر زمان بیزین شده است. بخشی از ادبیات مالی در دهه‌های اخیر میزان اطلاعات لازم برای دستیابی به برآورد قوی از پیش‌بینی متغیرهای اقتصادی و مالی را بررسی کرده‌اند (Forni et al, 2003; Bernanke & Boivin, 2003; Marcellino et al, 2003; Forni et al, 2004; Artis et al, 2005; Stock & Watson 2005, 2006; Boivin & Ng, 2006; Schumacher, 2007; Angelini et al, 2010; D'Agostino & Giannone, 2013; Greve et al, 2020). استخراج اطلاعات مفید از داده‌های با حجم بالا می‌تواند موجبات بهبود پیش‌بینی را ایجاد کند (Forni et al, 2004; Stock & Watson 2005, 2006; Naser, 2014).

ترکیب مدل‌های TVP و DMS و DMA میزان بیش‌برازشی در داخل نمونه را کاهش می‌دهد (Gupta et al, 2014). با توجه به اینکه مدل‌های DMS و DMA به مقادیر گذشته ضرایب و احتمال وابسته‌اند، در جدول ۹ به تحقیقاتی که از این مقادیر بهره گرفته‌اند اشاره شده است:

جدول ۷. مقادیر (α, λ) در مدل‌های DMS و DMA

مقادیر الفا و لاندا	محققان
$(\alpha = 0/95, \lambda = 1)$	لی و همکاران (۲۰۲۲)؛ کوپ و همکاران (۲۰۱۹)؛ کابودی و همکاران (۲۰۲۱)؛ بکمن و همکاران (۲۰۲۰)؛ کوپ و همکاران (۲۰۲۰)؛ دی فیلیپو (۲۰۱۵)؛ گوپتا و همکاران (۲۰۱۴)؛ شیخلی و همکاران (۱۴۰۱)؛ کریمی و همکاران (۱۴۰۰)؛ رحیمی و همکاران (۱۴۰۲).
$(\alpha = 1, \lambda = 1)$	لی و همکاران (۲۰۲۲)؛ کوپ و همکاران (۲۰۱۹)؛ کابودی و همکاران (۲۰۲۱)؛ بکمن و همکاران (۲۰۲۰)؛ کوپ و کورویلیس (۲۰۱۱)؛ کوپ و کورویلیس (۲۰۰۹)؛ بالیسار و همکاران (۲۰۱۸)؛ شیخلی و همکاران (۱۴۰۱)؛ کریمی و همکاران (۱۴۰۰)؛ رحیمی و همکاران (۱۴۰۲).
$(\alpha = 0/99, \lambda = 1)$	لی و همکاران (۲۰۲۲)؛ کوپ و همکاران (۲۰۱۹)؛ کابودی و همکاران (۲۰۲۱)؛ بکمن و همکاران (۲۰۲۰)؛ کوپ و کورویلیس (۲۰۱۱ و ۲۰۱۲)؛ فریرا و پالما (۲۰۱۵)؛ بانسیک و مورتو (۲۰۱۵)؛ ناصر و علاعلی (۲۰۱۸)؛ شیخلی و همکاران (۱۴۰۱)؛ کریمی و همکاران (۱۴۰۰)؛ رحیمی و همکاران (۱۴۰۲).

لی و همکاران (۲۰۲۲): کوپ و همکاران (۲۰۱۹): کابودی و همکاران (۲۰۲۱): بکمن و همکاران (۲۰۲۰): رافتری و همکاران (۲۰۰۷ و ۲۰۱۰): کوپ و کورویلیس (۲۰۱۲): بلموته و کوپ (۲۰۱۴): سالیله (۲۰۱۵): فریرا و پالما (۲۰۱۵): دی فیلیپو (۲۰۱۵): ای و همکاران (۲۰۱۴): رایس و کرن (۲۰۱۶): ناصر (۲۰۱۴): دراچل (۲۰۱۶): ناصر و علاعلی (۲۰۱۸): شیخلی و همکاران (۱۴۰۱): کریمی و همکاران (۱۴۰۰): رحیمی و همکاران (۱۴۰۲)	$(\alpha = \lambda = 0/99)$
لی و همکاران (۲۰۲۲): کوپ و همکاران (۲۰۱۹): کابودی و همکاران (۲۰۲۱): بکمن و همکاران (۲۰۲۰): نیکولتی و پارسو (۲۰۱۲): کوپ و کورویلیس (۲۰۱۲): بلموته و کوپ (۲۰۱۳): سالیله (۲۰۱۵): فریرا و پالما (۲۰۱۵): دی فیلیپو (۲۰۱۵): ناصر (۲۰۱۴): باور و همکاران (۲۰۱۶): دراچل (۲۰۱۶): شیخلی و همکاران (۱۴۰۱): کریمی و همکاران (۱۴۰۰): رحیمی و همکاران (۱۴۰۲)	$(\alpha = \lambda = 0/95)$
لی و همکاران (۲۰۲۲): کوپ و همکاران (۲۰۱۹): کابودی و همکاران (۲۰۲۱): بکمن و همکاران (۲۰۲۰): نیکولتی و پارسو (۲۰۱۲): باور و همکاران (۲۰۱۶): دراچل (۲۰۱۶): شیخلی و همکاران (۱۴۰۱): کریمی و همکاران (۱۴۰۰): رحیمی و همکاران (۱۴۰۲)	$(\alpha = \lambda = 0/90)$

در ادامه نتایج اعمال α و λ های مختلف برای تبیین مدل بهینه ارائه شده است. α و λ های مختلف موجب برآورد ضریب های متفاوت و به تبع آن پیش بینی متفاوت برای نوسان قیمت طلا خواهد شد. لازم به ذکر است در این بخش از پیش بینی درون نمونه ای بهره گرفته شده است؛ چرا که هدف، تعیین مدل بهینه برای متغیرهای غیرشکننده است. در این به بررسی این موضوع پرداخته می شود که تخمین مدل بر اساس مدل های TVP کارایی بالاتری دارد یا بر اساس مدل های سنتی OLS. به منظور تعیین این امر، ارزش راست نمایی دو مدل در جدول ۱۰ نمایش داده شده است:

جدول ۸. تست راست نمایی در مقایسه کارایی مدل های TVP با OLS

ROW	lnL	LR
OLS	۱۱۰/۱۲	$\chi^2 = 29.82^{***}$
TVP	۵۱۹/۴۵	

***: در سطح ۱٪ معنادار است.

(منبع: محاسبات تحقیق).

برای مقایسه رویکردهای خطی و غیرخطی از آزمون نسبت راست نمایی بهره گرفته می شود. در صورتی که مدل غیرخطی توانایی بالاتری نسبت به مدل خطی داشته باشد، مقدار راست نمایی بالاتری خواهد داشت. نتایج تست LR در جدول ۸ نشان می دهد که مدل TVP نرخ راست نمایی بالاتری (۵۱۹/۴۵) بزرگتر از ۱۱۰/۱۲ است)، در مقایسه با مدل OLS دارد؛ در نتیجه، تخمین مدل بر اساس رویکردهای TVP (غیرخطی) نسبت به مدل های OLS (خطی) از کارایی بالاتری برخوردار است. این نتایج مؤید نظریه کنووا (۲۰۰۲)، کنووا و سیکارلی (۲۰۰۴)، کوگلی و سارجنت (۲۰۰۱)، کوگلی و پرسکات (۱۹۷۳)، کوپ و کورویلیس (۲۰۱۳)، کوپ و همکاران (۲۰۱۹) و جیکوب (۲۰۲۲) است.

۵-۱. یافته‌های مدل بهینه در رویکرد BMA-TVP-DMA&TVP-DMS

دوره زمانی آموزش پیش‌بینی از ۲۰۱۰ تا ۲۰۲۰ و در دوره زمانی بررسی عملکرد پیش‌بینی از ۲۰۲۱ تا ۲۰۲۲ است.^۱ در ادامه نتایج اعمال λ و α های مختلف به منظور تبیین مدل بهینه ارائه شده است. λ و α های مختلف موجب برآورد ضریب‌های متفاوت و به تبع آن پیش‌بینی متفاوتی برای نوسان قیمت طلا خواهد شد. در این بخش، از پیش‌بینی درون‌نمونه‌ای بهره گرفته شده است؛ چرا که هدف، تعیین مدل بهینه برای متغیرهای با بالاترین سطح اثرگذاری بر متغیر نوسانات قیمت طلاست (جدول ۹). به منظور ارزیابی عملکرد پیش‌بینی (MSFE)^۲ از مربع میانگین خطای پیش‌بینی (MAFE)^۳ قدرمطلق میانگین خطای استفاده شده است (Koop & Korobilis, 2020; Lee et al, 2020).

جدول ۹. معیارهای عملکرد پیش‌بینی در افق‌های پیش‌بینی مختلف

دوره پیش‌بینی	h = 1					
	Log (PL)	MAFE	MSFE	MAPE	FEV	Bias
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.99)$	97.091	0.099	0.013	0.263	0.013	0.024
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.95)$	107.440	0.087	0.010	0.257	0.010	0.020
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.90)$	109.822	0.080	0.009	0.237	0.009	0.018
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.99)$	98.189	0.108	0.015	0.269	0.015	0.026
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.95)$	113.317	0.094	0.012	0.238	0.011	0.016
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.90)$	141.215	0.074	0.009	0.213	0.008	0.020
$TVP - AR(1) - X \quad DMA(\alpha = 0.99, \lambda = 1)$	93.769	0.102	0.014	0.273	0.013	0.023
$TVP - AR(1) - X \quad DMA(\alpha = 0.95, \lambda = 1)$	100.028	0.094	0.011	0.311	0.010	0.032
$TVP - AR(1) - X \quad BMA(\alpha = \lambda = 1)$	154.450	0.019	0.003	0.148	0.029	0.006
دوره پیش‌بینی	h = 4					
	Log (PL)	MAFE	MSFE	MAPE	FEV	Bias
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.99)$	91.969	0.104	0.014	0.257	0.014	0.028
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.95)$	101.591	0.087	0.011	0.241	0.010	0.022
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.90)$	103.298	0.081	0.009	0.225	0.009	0.019
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.99)$	92.101	0.111	0.016	0.264	0.015	0.029
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.95)$	105.706	0.096	0.012	0.235	0.012	0.013
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.90)$	129.596	0.081	0.010	0.226	0.010	0.013
$TVP - AR(1) - X \quad DMA(\alpha = 0.99, \lambda = 1)$	88.753	0.104	0.014	0.260	0.013	0.022
$TP - AR(1) - X \quad DMA(\alpha = 0.95, \lambda = 1)$	96.746	0.093	0.010	0.272	0.010	0.029
$TVP - AR(1) - X \quad BMA(\alpha = \lambda = 1)$	131.356	0.023	0.004	0.140	0.003	0.020
دوره پیش‌بینی	h = 8					
	Log (PL)	MAFE	MSFE	MAPE	FEV	Bias
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.99)$	86.608	0.108	0.015	0.726	0.015	0.015
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.95)$	95.939	0.087	0.010	0.532	0.010	0.017
$TVP - AR(1) - X \quad DMA(\alpha = \lambda = 0.90)$	97.342	0.080	0.008	0.420	0.008	0.018
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.99)$	83.776	0.113	0.016	0.731	0.016	0.013
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.95)$	100.942	0.100	0.015	0.609	0.013	0.012
$TVP - AR(1) - X \quad DMS(\alpha = \lambda = 0.90)$	120.040	0.086	0.011	0.566	0.011	0.016

۱. در این رویکرد از بخشی از داده‌ها برای آموزش مدل و از بخشی برای پیش‌بینی و محاسبه میزان دقت مدل‌ها بهره گرفته می‌شود.

2. Mean Square Forecast Error

3. Mean Absolute Forecast Error

$TVP - AR(1) - X$	$DMA(\alpha = 0.99, \lambda = 1)$	88.951	0.103	0.013	0.752	0.013	0.015
$TVP - AR(1) - X$	$DMA(\alpha = 0.95, \lambda = 1)$	96.019	0.087	0.010	0.626	0.008	0.017
$TVP - AR(1) - X$	$BMA(\alpha = \lambda = 1)$	110.180	0.023	0.002	0.104	0.006	0.002

بر اساس نتایج، مدل BMA در تمامی بازه‌های زمانی $h=1,4,8$ از عملکرد مطلوب‌تری برخوردار است. به همین دلیل، در ادامه به بررسی نتایج این مدل پرداخته می‌شود. در این مرحله بر اساس رویکرد کوپ و همکاران (۲۰۱۹)، بر اساس میزان احتمال توزیع پسین و پیشین در سه مرحله متوالی، از ۳۵ متغیر معرفی شده ۱۲ متغیر انتخاب شد. در رویکرد کوپ و همکاران، در هر مرحله متغیرهایی که اثر ضعیفی بر متغیر نوسان قیمت طلا داشته باشند از مدل حذف می‌شوند تا در نهایت متغیرهایی در مدل باقی بمانند که بالاترین تأثیر و احتمال را دارند. به عبارتی، در این مدل - همانند رویکردهای اولویت‌بندی در مدل‌های کیفی - در مدل‌های کمی اقدام به شناسایی و اولویت‌بندی مهم‌ترین عوامل مؤثر بر نوسان قیمت طلا خواهد شد. یعنی ۱۲ متغیر مقدار احتمال پسین بیشتری نسبت به احتمال پیشین داشتند و این ۱۲ متغیر سطح احتمال پسین بالاتر از سطح آستانه ۰/۲۸۵ داشتند.

برای دستیابی به نتیجه می‌بایست محاسبات روی تمام مدل‌ها در فضای مدل انجام شود. با توجه به تعداد متغیرهای بررسی شده، تعداد مدل‌های موجود (بر اساس حضور یا عدم حضور هر متغیر)، در فضای مدل برابر ۳۵ مدل است که بیش از ۳۴،۳۵۹،۷۳۸،۳۶۸ مدل رگرسیونی را دربر می‌گیرد. به عبارت دیگر، فضای مدل شامل ۳۵ مدل است که با توجه به فرض عدم اطمینان مدل، یعنی به دور از اعمال نظر شخصی در انتخاب مدل، می‌بایست همه مدل‌ها بررسی و از اطلاعات همه مدل‌ها برای دستیابی به نتیجه استفاده شود. به پیروی از سالی مارتین^۱ و همکاران، مقدار k در این پژوهش مساوی ۱۰ در نظر گرفته شده است. این عدد بازگوکننده این مطلب است که انتظار می‌رود در نهایت ۱۰ متغیر به عنوان متغیرهای غیرشککننده توسط فرایند محاسبات معرفی شود؛ اما کاملاً روشن است که امکان دارد در نهایت تعداد کمتر و یا بیشتر از ۱۰ متغیر غیرشککننده باشند.

در ابتدا با به دست آوردن نمونه‌ای شامل ۱ میلیون رگرسیون از فضای مدل، ضرایب و احتمال پسین هر متغیر محاسبه شد. در ادامه ۱ میلیون رگرسیون به نمونه اول اضافه شد و محاسبات برای ۲ میلیون رگرسیون انجام شد و ضرایب و احتمالات پسین به دست آمد. با ادامه این روند، در نمونه‌ای که شامل ۱۰ میلیون رگرسیون بود، همگرایی حاصل گردید. بر این اساس، دیگر نیازی به افزایش حجم نمونه به منظور تعیین متغیرهای غیرشککننده وجود ندارد (جدول ۶). به منظور غیرشککننده معرفی کردن یک متغیر لازم است دو شرط تحقق یابد: (۱) افزایش احتمال پسین هر متغیر نسبت به احتمال پیشین؛ (۲) بالا بودن سطح احتمال پسین از سطح آستانه تعریف شده («سطح آستانه اولیه = ۱۰ تقسیم بر ۳۵ = ۰/۲۸۵»). شایان ذکر است که در مرحله اول (جدول ۱۰) به دلیل فرض عدم اطمینان مدل، از اطلاعات غیرداده‌ای و در مرحله دوم به دلیل دستیابی سریع‌تر به همگرایی از اطلاعات داده‌ای استفاده شده است. همچنین متغیرهایی که احتمال پسینی کمتر از احتمال پیشین در نظر

گرفته شده داشتند، به دلیل شکننده بودن در مقابل سایر متغیرها، از مدل خارج شدند (در مرحله اول ۲۰ متغیر غیرشکننده بودند که در مرحله دوم با این متغیرها که احتمال پسین بیشتری نسبت به احتمال پیشین داشته اند محاسبات ادامه می یابد).

جدول ۱۰. مرحله اول فرایند نمونه گیری و محاسبات با فرض $K = 10$

متغیر		نمونه اول شامل ۱ میلیون رگرسیون		نمونه اول شامل ۱۰ میلیون رگرسیون	
		ضریب	احتمال	ضریب	احتمال
		پیشین	پیشین	پسین	پسین
شاخص دلار		0.037	0.238	0.152	0.369
نرخ وجوه فدرال رزرو		0.075	0.284	0.123	0.376
CPI		0.028	0.196	0.126	0.343
بیکاری		-0.172	0.155	-0.202	0.205
نرخ ارز		-0.080	0.167	-0.146	0.409
قیمت نفت		-0.092	0.116	-0.140	0.623
بازدهی سهام داو جونز		0.169	0.138	0.206	0.218
بازدهی سهام S&P 500		0.033	0.111	0.089	0.338
تولید ناخالص داخلی		0.092	0.168	0.159	0.176
کسری بودجه		0.028	0.229	0.078	0.255
واردات و صادرات طلا (از میانگین حجم واردات و صادرات طلای جهانی بهره گرفته شده است)		0.107	0.140	0.160	0.484
ریسک ژئوپلیتیک (از شاخص GPR جهت محاسبه این شاخص بهره گرفته شده است)		0.057	0.255	0.088	0.307
نااطیمانی اقتصادی (از شاخص EUI بهره گرفته شده است)		0.089	0.187	0.146	0.350
بیماری های اپیدمی		0.045	0.550	0.055	0.616
نرخ بهره جهانی		0.196	0.206	0.326	0.867
ریسک سیاسی (از شاخص ICGR بهره گرفته شده است)		0.117	0.109	0.129	0.255
قیمت پلاتین		0.118	0.175	0.227	0.259
قیمت پالادیم		0.068	0.159	0.116	0.264
قیمت نقره		0.062	0.286	0.098	0.374
شاخص رمز ارزها (از شاخص قیمتی بیت کوین به عنوان جایگزین این		0.117	0.519	0.251	0.824

۱. پیشنهاد محقق به مدل میانگین گیری بیزین ۱۰ متغیر بوده است که مدل ۱۲ متغیر را پیشنهاد داده است؛ با توجه به تعداد کم اختلاف دو رویکرد، از ۱۲ متغیر که جامع تر بوده بهره گرفته شده است.

				شاخص بهره گرفته شده است)
0.622	0.134	0.525	0.045	RSI (شاخص قدرت نرخ بهره)
0.251	0.128	0.141	0.118	SMA (میانگین متحرک ساده)
0.221	0.036	0.136	0.020	Bands (نوارهای بولینجر)
0.458	0.032	0.282	0.022	MACD (دیفرانسیل ماهیانه درصدهای حرکت متوسط)
0.615	-0.136	0.495	-0.069	Retracement (بازگشت فیبوناچی)
0.495	-0.323	0.489	-0.239	ADX (شاخص جهت در بازار)
0.566	0.166	0.465	-0.115	Oscillator (نوسان سهام)
0.232	0.062	0.084	0.032	ATR (متوسط دامنه حقیقی)
0.258	-0.209	0.175	-0.117	Ichimoku Cloud
0.224	0.125	0.140	0.097	پیوت پوینت
0.246	0.215	0.117	0.077	Pivot Point Woodie
0.852	0.248	0.365	0.453	Pivot Point DeMark
0.208	-0.111	0.181	-0.092	Pivot Point Camarilla
0.205	-0.029	0.104	-0.017	Pivot Point Floor
0.546	0.216	0.384	0.068	Pivot Point Fibonacci

(منبع: محاسبات تحقیق).

در این تحقیق، ابتدا نمونه‌ای شامل ۱۰۰ هزار رگرسیون از فضای مدل گرفته شد و ضرایب و احتمال پسین هر متغیر محاسبه گردید. سپس تعداد رگرسیون‌ها به ۲۰۰ هزار افزایش یافت و محاسبات مجدد انجام شد. این روند ادامه یافت تا همگرایی در نمونه‌ای با ۵۰۰ هزار رگرسیون حاصل شد. از این پس، نیازی به افزایش حجم نمونه نبود. برای شناسایی متغیرهای غیرشکننده، دو شرط باید محقق می‌شد: (۱) افزایش احتمال پسین نسبت به احتمال پیشین؛ (۲) بالاتر بودن سطح احتمال پسین از آستانه تعریف شده («سطح آستانه اولیه = ۱۰ تقسیم بر ۲۰ = ۰/۵۰»).

جدول ۱۱. مرحله دوم فرایند نمونه‌گیری و محاسبات با فرض $K = 10$





نمونه اول شامل ۱۰۰ هزار رگرسیون		نمونه اول شامل ۵۰۰ هزار رگرسیون		متغیر
احتمال پسین	ضریب پسین	احتمال پیشین	ضریب پیشین	
0.522	0.174	0.372	0.042	شاخص دلار
0.430	0.141	0.325	0.086	نرخ وجوه فدرال رزرو
0.392	0.144	0.224	0.032	CPI
0.467	-0.167	0.191	-0.091	نرخ ارز
0.712	-0.160	0.433	-0.105	قیمت نفت
0.386	0.102	0.127	0.038	بازدهی سهام S&P 500
0.553	0.183	0.460	0.122	واردات و صادرات طلا

0.351	0.101	0.291	0.065	ریسک ژئوپلیتیک
0.400	0.167	0.214	0.102	نااطمینانی اقتصادی
0.404	0.063	0.329	0.051	بیماری های اپیدمی
0.691	0.373	0.235	0.224	نرخ بهره جهانی
0.427	0.112	0.327	0.071	قیمت نقره
0.742	0.287	0.593	0.134	شاخص رمزارزها
0.711	0.153	0.600	0.051	RSI (شاخص قدرت نرخ بهره)
0.523	0.037	0.322	0.025	MACD (دیفرانسیل ماهیانه درصد های حرکت متوسط)
0.703	-0.155	0.566	-0.079	Retracement (بازگشت فیبوناچی)
0.566	-0.369	0.559	-0.273	ADX (شاخص جهت در بازار)
0.647	0.190	0.531	-0.131	Oscillator (نوسان سهام)
0.974	0.283	0.417	0.518	Pivot Point DeMark
0.624	0.247	0.439	0.078	Pivot Point Fibonacci

(منبع: محاسبات تحقیق).

در ادامه، پس از اعمال مراحل مختلف بر روی ۱۲ متغیر باقی مانده، متغیرهای غیرشکسته شناسایی شدند. در نهایت، پس از سه مرحله، متغیرهایی که احتمال پسین ورود بیشتری نسبت به احتمال پیشین داشتند انتخاب شدند. فهرست این متغیرها در جدول ۱۲ ارائه شده است:

جدول ۱۲. اولویت بندی متغیرهای مؤثر بر نوسان قیمت طلا در مدل بهینه^۱

نماد	متغیر	نمونه شامل + / ۵ میلیون رگرسیون		نسبت رگرسیون ها با $ t - \geq 2 $ $stat$	اولویت	توزیع مشترک
		ضریب احتمال پسین	ضریب احتمال پسین			
Z1	شاخص دلار	0.174	0.522	0.543	۱۲	
Z2	قیمت نفت	-0.160	0.712	0.740	۳	
Z3	واردات و صادرات طلا	0.183	0.553	0.575	۱۰	
Z4	نرخ بهره جهانی	0.373	0.691	0.719	۶	

۱. برای محاسبات بخش میانگین گیری بیزین، از نرم افزار MATLAB نسخه ۲۰۲۱ بهره گرفته شده است.

	۲	0.772	0.742	0.287	شاخص رمزارزها	Z5
	۴	0.739	0.711	0.153	RSI (شاخص قدرت نرخ بهره)	Z6
	۱۱	0.544	0.523	0.037	MACD (دیفرانسیل ماهانه درصدهای حرکت متوسط)	Z7
	۵	0.731	0.703	-0.155	Retracement (بازگشت فیبوناچی)	Z8
	۹	0.589	0.566	-0.369	ADX (شاخص جهت در بازار)	Z9
	۷	0.673	0.647	0.190	Oscillator (نوسان سهام)	Z10
	۱	0.913	0.974	0.283	Pivot Point DeMark	Z11
	۸	0.649	0.624	0.247	Pivot Point Fibonacci	Z12


(منبع: محاسبات تحقیق).

نمودارهای ارائه شده توزیع های پسین، پیشین و مشترک میان متغیرها را نشان می دهند. نتایج حاکی از این است که متغیرهای دوازده گانه عملکرد مناسبی دارند؛ اما با افزایش سطح پراکندگی و توزیع مشترک، عملکرد آنها کاهش می یابد. با استفاده از تابع بیزین، علاوه بر ضریب اثرگذاری، احتمال تأثیر ضریب نیز باید مدنظر قرار بگیرد. برآورد مدل بیزین مدل ریاضی تحقیق را به صورت زیر ارائه می دهد:

$$\begin{aligned}
 &= 0.174 \text{ Pr}(0.522) Z1 - 0.160 \text{ Pr}(0.740) Z2 \\
 &+ 0.183 \text{ Pr}(0.553) Z3 + 0.373 \text{ Pr}(0.691) Z4 \\
 &+ 0.287 \text{ Pr}(0.742) Z5 + 0.153 \text{ Pr}(0.711) Z6 \\
 &+ 0.037 \text{ Pr}(0.523) Z7 - 0.155 \text{ Pr}(0.703) Z8 \\
 &- 0.369 \text{ Pr}(0.566) Z9 + 0.190 \text{ Pr}(0.647) Z10 \\
 &+ 0.283 \text{ Pr}(0.974) Z11 + 0.247 \text{ Pr}(0.624) Z12
 \end{aligned}
 \tag{۱۳}$$

در مدل های بیزین، به جای یک مدل، مدل های متعددی برآورد و میانگین گیری می شود؛ بنابراین، تکیه بر آماره t یک مدل کافی نیست و باید از نسبت آماره t برای سنجش اهمیت متغیرها استفاده کرد. برای مثال،

نسبت ۰,۵۴۳ برای شاخص دلار نشان می دهد که در ۵۴۳ هزار حالت، این متغیر در ۱۰۰ هزار مدل با آماره t بزرگ تر از ۲ معنادار بوده است.



نمودار ۳. میانگین احتمال پسین ساده و تجمعی ۱۰۰۰ مدل برتر

(منبع: محاسبات تحقیق).

بر اساس نتایج نمودار ۴، واضح است که ۱۰۰۰ مدل برتر در حالت تجمعی قادر به توضیح بیش از ۹۹ درصد تغییرات نوسانات قیمت طلا هستند (مشاهده در محور عمودی نمودار ۳). نتایج نشان می دهند که مدل مفهومی تحقیق در نمودار ۴ به طور دقیق نمایش داده شده است.



نمودار ۴. مدل نهایی تحقیق

(منبع: محاسبات تحقیق).

۶. نتیجه‌گیری و پیشنهادها

این مطالعه به شناسایی عوامل مؤثر بر نوسان قیمت طلا پرداخت و نشان داد که سرمایه‌گذاران باید تمامی این عوامل را پیش از تصمیم‌گیری برای سرمایه‌گذاری در نظر بگیرند تا از تغییرات قیمت طلا آگاه باشند و از ضرر و زیان احتمالی جلوگیری کنند. نتایج نشان می‌دهد که مدل‌های نوسان‌پذیری تصادفی (SV) نسبت به مدل‌های گارچ از دقت بالاتری در پیش‌بینی نوسانات قیمت طلا برخوردارند. همچنین، از میان مدل‌های مختلف، مدل BMA بیشترین دقت را در شبیه‌سازی نوسانات قیمت طلا دارد.

در این تحقیق، ۱۲ متغیر مهم شناسایی شدند که بر نوسان قیمت طلا تأثیرگذارند: شاخص دلار، قیمت نفت، واردات و صادرات طلا، نرخ بهره جهانی، شاخص رمزارزها، RSI، MACD، بازگشت فیبوناچی، ADX، نوسان سهام، و نقاط محوری DeMark و Fibonacci. این مطالعه همچنین نشان داد که عوامل درون بازار (عوامل کلان اقتصادی و بازارهای مالی) بیشترین تأثیر را در توضیح نوسانات قیمت طلا دارند و رویکردهای غیرخطی نسبت به مدل‌های خطی قادر به پیش‌بینی نوسانات با دقت بالاتری هستند.

نتایج تحقیق با مطالعات پیشین همچون نیسارگا و ماریستی (۲۰۲۳)، حسینلی (۲۰۲۳)، دینگ و همکاران (۲۰۲۲)، چیئو و لی (۲۰۲۰)، و دیگران هم‌راستا است و تأکید می‌کند که ارتباط معناداری بین متغیرهای اقتصادی و نوسان قیمت طلا وجود دارد و مدل‌های غیرخطی از مدل‌های کلاسیک رگرسیون در شبیه‌سازی نوسانات قیمت طلا موفق‌تر عمل می‌کنند (نیسارگا و ماریستی، ۲۰۲۳؛ حسینلی، ۲۰۲۳؛ دینگ و همکاران، ۲۰۲۲؛ چیئو و لی، ۲۰۲۰).

تعارض منافع

در پژوهش حاضر تعارض منافی وجود ندارد.

درصد مشارکت نویسندگان

نویسندگان ضمن رعایت اخلاق نشر اعلام می‌کنند که این پژوهش برگرفته از رساله دکتری است و نویسندگان با سهم یکسان در این پژوهش مشارکت داشته‌اند.

سپاس‌گزاری

نویسندگان از داوران ناشناس که به بهبود کیفیت مقاله کمک کردند تشکر می‌کنند.

منابع

- ابراهیمی، عرفان؛ مؤیدی، فاطمه، قاسمی، محسن. (۱۴۰۳). «پیش بینی قیمت طلا بر اساس یادگیری عمیق بازگشتی بلندمدت»: دومین کنفرانس ملی تحول دیجیتال و سیستم های هوشمند، لارستان.
<https://civilica.com/doc/2040036>
- حسینی، حسن؛ نمکی، علی. (۱۴۰۲). «پیش بینی قیمت طلا با استفاده از شبکه حافظه بلند کوتاه مدت LSTM»: نخستین همایش ملی اقتصاد هوشمند و توسعه مالی، تهران.
<https://civilica.com/doc/1816468>
- خانی، فاطمه؛ جعفری صمیمی، احمد؛ طهرانچیان، امیرمنصور؛ احسانی، محمدعلی. (۱۴۰۰). «آثار بازار پول بر بازار طلا با رویکرد پویایی شناسی سیستمی». مدل سازی اقتصادی، ۱۵(۵۴)، ۱-۱۹.
https://journals.iau.ir/article_684491.html
- سرفراز، لیلا؛ افسر، امیر. (۱۳۸۴). «بررسی عوامل مؤثر بر قیمت طلا و ارائه مدل پیش بینی بر مبنای شبکه های عصبی فازی»: پژوهش های رشد و توسعه پایدار (پژوهش های اقتصادی)، ۵(۱۶)، ۱۴۹-۱۶۵.
<https://sid.ir/paper/86705/fa>
- کاظم زاده، عماد؛ ابراهیمی سالاری، تقی؛ بهنام، مهدی. (۱۳۹۸). «پیش بینی نرخ رشد قیمت سکه طلا در ایران با استفاده از الگوی رگرسیون داده ها با تواتر متفاوت (میداس)»: اقتصاد کاربردی، ۹(۲۸)، ۴۳-۵۳.
<https://sanad.iau.ir/Journal/jae/Article/804208>
- گرگ بندی، ساره؛ موسوی، سید مرتضی. (۱۴۰۲). «پیش بینی روند کوتاه مدت قیمت طلا در بازار فارکس با استفاده از شبکه های عصبی عمیق»: ششمین کنفرانس ملی فناوری های نوین در مهندسی برق و کامپیوتر، اصفهان.
<https://civilica.com/doc/2024194>

References

- Adekoya, O. B.; Ghaemi asl, M.; Oliyide, J. A. & Izadi, P. (2023). "Multifractality and cross-correlation between the crude oil and the European and non-European stock markets during the Russia-Ukraine war". *Resources Policy*, 80(C), 103134.
<https://doi.org/10.1016/j.resourpol.2022.103134>
- Apergis, N.; Cooray, A.; Khraief, N. & Apergis, I. (2019). "Do gold prices respond to real interest rates? Evidence from the Bayesian Markov Switching VECM model". *Journal of International Financial Markets, Institutions and Money*, 60, 134-148.
<https://doi.org/10.1016/j.intfin.2018.12.014>
- Bollerslev, T. (1986). "Generalized Autoregressive Conditional Heteroskedasticity". *Journal of Econometrics*, 31, 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Changani, J. G. (2024). "Factors influencing gold price movements: a time series analysis perspective". Available at SSRN 4815102. <http://dx.doi.org/10.2139/ssrn.4815102>

- Chiang, T. (2022). "Geopolitical risks and gold price volatility". *Journal of Risk and Financial Management*, 15(4), 189–201.
- Chong, T. T. & Lai, M. M. (1999). "Efficiency of the Hong Kong stock market". *Applied Financial Economics*, 9(3), 293-304.
- Choudhary, P. (2021). "An influence of analysis on the indian gold price with sensex and nifty in India". *Journal of Advances and Scholarly Research in Allied Education*, 16(5), 1414-1419. <https://ignited.in/index.php/jasrae/article/view/11122/22048>
- Cohen, G. & Aiche, A, (2023). "Forecasting gold price using machine learning methodologies". *Chaos, Solitons & Fractals*, 175(Part 2), 114079. <https://doi.org/10.1016/j.chaos.2023.114079>
- Daga, V. & James, L. (2020). "Effect of macroeconomic factors on the price of gold in India". https://ijcrt.org/papers/IJCRT_192457.pdf
- Dalam, A. M.; Abd-Rashid, N, K. & Padli, J. (2019). "Factors determining gold prices in Malaysia". *Universiti Malaysia Terengganu Journal of Undergraduate Research*, 1(2), 75–82. <https://doi.org/10.46754/umtjur.v1i2.69>
- Deniz, P. & Stengos, T. (2023). "Revisiting the determinants of consumption: A Bayesian model averaging approach". *Journal of Risk and Financial Management*, 16(3), 1-13. <http://dx.doi.org/10.3390/jrfm16030190>
- Ding, Q.; Huang, J.; Gao, W. & Zhang, H. (2022). "Does political risk matter for gold market fluctuations? A structural VAR analysis". *Research in International Business and Finance*, 60, 101618. <https://doi.org/10.1016/j.ribaf.2022.101618>
- Ebrahimi, E.; Moayedi, F. & Ghasemi, M. (2024). "Gold price forecasting based on long-term recurrent deep learning". *Second National Conference on Digital Transformation and Intelligent Systems*, Larestan. [In Persian]. <https://civilica.com/doc/2040036>
- Fang, L.; Chen, B.; Yu, H. & Qian, Y. (2018). "The importance of global economic policy uncertainty in predicting gold futures market volatility: A GARCH-MIDAS approach". *Journal of Futures Markets*, 38(3), 413-422. <https://doi.org/10.1002/fut.21897>
- Gargbandi, S. & Mousavi, S. M. (2023). "Forecasting the short-term trend of gold price in the forex market using deep neural networks". *6th National Conference on New Technologies in Electrical and Computer Engineering*, Isfahan. [In Persian]. <https://civilica.com/doc/1876625>
- Ghosh, J. K. & Samanta, T. (2001). "Model selection – An overview". *Current Science*, 80(9), 1135-1144. <https://www.jstor.org/stable/24105770>

- Harvey, A.; Ruiz, E. & Shephard, N. (1994). "Multivariate stochastic variance models". *The Review of Economic Studies*, 61(2), 247-264. <https://doi.org/10.2307/2297980>
- Hashim, S. L. (2022). "Analyses of factors influence the price of gold in Malaysia". *Advanced International Journal of Business, Entrepreneurship and SMEs*, 4(11), 16-22. <https://doi.org/10.35631/aijbes.411002>
- Horak, J., Vochozka, M., & Kaisler, D. (2024). "Investment instruments: The power of neural networks in predicting gold price trends". *Forum Scientiae Oeconomia*, 12(1), 72-95. <http://bazekon.icm.edu.pl/bazekon/element/bwmeta1.element.ekon-element-000171686264>
- Hoseyni, H. & Namaki, A. (2014). "Gold price forecasting using LSTM long short term memory network". *The First National Conference on Smart Economy and Financial Development*, Tehran. [In Persian]. <https://civilica.com/doc/1816468>
- Huseynli, N. (2023). "Analyzing the relationship between oil prices and gold prices before and after COVID-19". *International Journal of Energy Economics and Policy*, 13(2), 373-378. <https://doi.org/10.32479/ijeep.13820>
- Jacquier, E.; Polson, N. G. & Rossi, P. E. (2002). "Bayesian Analysis of Stochastic Volatility Models". *Journal of Business & Economic Statistics, American Statistical Association*, 20(1), 69-87. <https://doi.org/10.2307/1392199>
- Kazemzadeh, E.; Ebrahimi salari, T. & Behname, M. (2019). "Predicting the growth rate of gold coin prices in Iran using the variable frequency data regression model (MIDAS)". *Applied Economics*, 9(28), 43-53. [In Persian]. <https://sanad.iau.ir/Journal/jae/Article/804208>
- Khan, Kh.; Su, C. W. & Zhu, M. N. (2022). "Examining the behavior of energy prices to COVID-19 uncertainty: A quantile on quantile approach". *Energy*, 239(E), 122430, <https://doi.org/10.1016/j.energy.2021.122430>
- Khani, f.; Jafari samimi, A.; Tehranchian, A. M. & Ehsani, M. (2021). "The effects of money market on gold market with a systemic dynamics approach". *Journal of Economic Modelling*, 15(54), 1-19. [In Persian]. https://journals.iau.ir/article_684491.html
- Koop, G & Potter, S. (2024). "Forecasting in dynamic factor models using Bayesian model averaging". *The Econometrics Journal*, 7(2), 550-565. <https://doi.org/10.1111/j.1368-423X.2004.00143.x>
- Koop, G. & Korobilis, D. (2009). "Bayesian Multivariate Time Series Methods for Empirical Macroeconomics". Working Paper series 47_09, Rimini Centre for Economic Analysis. <https://ideas.repec.org/p/pramprapa/20125.html>

- Koop, G. & Korobilis, D. (2020). "Bayesian dynamic variable selection in high dimensions". *MPRA Paper 100164*, University Library of Munich, Germany. <https://dx.doi.org/10.2139/ssrn.3246472>
- Lee, S. W. & Kim, H. Y. (2020). "Stock market forecasting with super-high dimensional time-series data using ConvLSTM, trend sampling, and specialized data augmentation". *Expert Systems with Applications*, 161, 113704. <https://doi.org/10.1016/j.eswa.2020.113704>
- Levine, R. & Renelt, D. (1992). "A Sensitivity Analysis of Cross-Country Growth Regressions". *The American Economic Review*, 82(4), 942-963. <https://www.jstor.org/stable/2117352>
- Liya, A.; Qin, Q.; Kamran, H. W.; Sawangchai, A.; Wisetsri, W. & Raza, M. (2021). "How macroeconomic indicators influence gold price management". *Business Process Management Journal*, 27(7), 2075-2087. <https://doi.org/10.1108/BPMJ-12-2020-0579>
- Long, P. D.; Hien, B. Q. & Ngoc, P. T. B. (2022). "Impacts of inflation on the gold price and exchange rate in Vietnam: time-varying vs fixed coefficient cointegrations". *Asian Journal of Economics and Banking*, 6(1), 88-96. <https://doi.org/10.1108/ajeb-07-2021-0083Md>
- Mainal, S. A.; Mohd selamat, A. H.; Abd-Majid, N. D. S. & Noorzee, K. N. I. (2023). "Factors influencing the price of gold in Malaysia". *Information Management and Business Review*, 15(3(I), 195-205. [https://doi.org/10.22610/imbr.v15i3\(I\).3529](https://doi.org/10.22610/imbr.v15i3(I).3529)
- Md Isa, M. A.; Latif, A. R.; Nasrul, F.; Zaharum, Z. & Noh, M. K. A. (2020). "Relational study between macroeconomic variables and gold price: Latest Malaysian evidence". *Advanced International Journal of Business, Entrepreneurship and SMEs*, 2(6), 01-09. <https://gaexcellence.com/aijbes/article/view/174>
- Moral-Benito, E. (2012). "Determinants of economic growth: A bayesian panel data approach". *Review of Economics and Statistics*, 94(2), 566-579. https://doi.org/10.1162/REST_a_00154
- Nisarga, M. & Marisetty, N. (2023). "A study on various factors impact on the gold price in India". *Asian Journal of Economics, Business and Accounting*, 23(20), 254-265. <http://dx.doi.org/10.2139/ssrn.4587897>
- Poon, S. H. & Granger C. W. J. (2003). "Forecasting Volatility in Financial Markets: A Review". *Journal of Economic Literature*, 41(2), 478-539. <https://www.aeaweb.org/articles?id=10.1257/002205103765762743>
- Pradeep, K. V. & Karunakaran, N. (2022). "Gold price dynamics in India: A pre-postliberalization comparison". *Journal of Management Research and Analysis*, 9(2), 102-107. <https://www.jmra.in/html-article/16785>

- Qian, Y.; Ralescu, D. A. & Zhang, B. (2019). "The analysis of factors affecting global gold price". *Resources Policy*, 64, 101478. <https://doi.org/10.1016/j.resourpol.2019.101478>
- Sadeghi, M. (2019). "An investigation of technical indicators on gold price volatility: A case study of RSI, SMA, Bollinger Bands, MACD, ATR and Ichimoku Cloud". *Quarterly Journal of Financial Research*, 12(3), 45–60.
- Sailaja, V. N.; Kumar, A. K. & Kota, P. V. S. (2022). "A study on macro-economic variables and their impact on gold price in India". *International Journal of Development Research*, 26(5), 1-16. <https://www.abacademies.org/abstract/a-study-on-macro-economic-variables-and-their-impact-on-gold-price-in-india-15156.html>
- Sarfaraz, L. & Afsar, A. (2005). "A study of factors affecting gold price based on a Neuro-Fuzzy model of forecast". *Journal of Sustainable Growth and Development (The Economic Research)*, 5(16), 149-165. [In Persian]. <https://sid.ir/paper/86705/en>
- Selvanathan, S. & Selvanathan, E. A. (2022). "The nexus between oil and gold prices during the COVID-19 pandemic". *Financial Transformations beyond the COVID-19 Health Crisis*, 447-474. http://dx.doi.org/10.1142/9781800610781_0015
- Tanin, T. I.; Sarker, A.; Brooks, R. & Do, H. X. (2022). "Does oil impact gold during COVID-19 and three other recent crises?" *Energy Economics*, 108(1), 105938. <https://doi.org/10.1016/j.eneco.2022.105938>
- Taylor, S. J. (1986). *Modelling Financial Time Series*. Chichester, UK: Wiley.
- Vallabh, P. (2022). "Policy uncertainty and gold price in India". *IIMA Working Paper Series*, No. 2022-06-01. <https://www.iima.ac.in/sites/default/files/2022-11/Policy%20Uncertainty%20and%20gold%20price%20in%20India.pdf>
- Wen, F; Tong, X. & Ren, X. (2022). "Gold or Bitcoin, which is the safe haven during the COVID-19 pandemic?" *International Review of Financial Analysis*, 81, <https://doi.org/10.1016/j.irfa.2022.102121>
- World Gold Council. (2020). "Gold Demand Trends Full year and Q4 2020". <https://www.gold.org/goldhub/research/gold-demand-trends/gold-demand-trends-full-year-and-q4-2020/15507>
- Yuan, F.; Lee, C. & Chiu, C. (2020). "Using market sentiment analysis and genetic algorithm-based least squares support vector regression to predict gold prices". *International Journal of Computational Intelligence Systems*, 13(1), 234-246. <https://doi.org/10.2991/ijcis.d.200214.002>
- Zakaria, H.; Abdul-Shukur, N.; Affandi, S. & Wan-Mahmood, W. (2015). "Factors affecting the price of gold in Malaysia". *Journal of Basic and Applied Scientific Research*, 5(7), 41–46. <https://www.semanticscholar.org/paper/Factors-Zakaria>

- Zhang, P. & Ci, H. (2020). "Deep belief network for gold price forecasting". *Revue de la Politique Economique*, 69(3), 1806-1830.
<https://doi.org/10.1016/j.resourpol.2020.101806>
- Zhao, Y. (2017). "Evaluating the effectiveness of technical indicators in gold market analysis: Emphasis on RSI, SMA, Bollinger Bands, MACD, ATR, and Ichimoku Cloud". *International Journal of Economics and Finance*, 9(1), 55-70.



پیوست‌ها

Dependent Variable: PGOLD

Method: ARMA Generalized Least Squares (Gauss-Newton)

Date: 10/15/24 Time: 00:04

Sample: 2010M01 2022M12

Included observations: 156

Convergence achieved after 5 iterations

Coefficient covariance computed using outer product of gradients

d.f. adjustment for standard errors & covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.239520	0.040826	5.866857	0.0000
AR(1)	0.785380	0.068788	11.41736	0.0000
MA(1)	0.230911	0.010211	22.61394	0.0000
R-squared	0.524605	Mean dependent var	1.243919	
Adjusted R-squared	0.518391	S.D. dependent var	0.185430	
S.E. of regression	0.128685	Akaike info criterion	4.908988	
Sum squared resid	2.533649	Schwarz criterion	4.980337	
Log likelihood	99.64105	Hannan-Quinn criter.	5.015166	
F-statistic	84.41889	Durbin-Watson stat	1.998452	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.79			
Inverted MA Roots	.13			

Null Hypothesis: RESID has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=13)

	t-Statistic
Elliott-Rootenber-Stock DF-GLS test statistic	-8.844434
Test critical values: 1% level	-2.580065
5% level	-1.942910
10% level	-1.615334

*MacKinnon (1996)

DF-GLS Test Equation on GLS Detrended Residuals

Dependent Variable: D(GLSRESID)

Method: Least Squares

Date: 10/15/24 Time: 00:07

Sample (adjusted): 2010M03 2022M12

Included observations: 154 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
GLSRESID(-1)	-0.275176	0.031112	-8.844434	0.0000
R-squared	0.137503	Mean dependent var		-0.000223
Adjusted R-squared	0.137503	S.D. dependent var		0.139164
S.E. of regression	0.129243	Akaike info criterion		-1.247773
Sum squared resid	2.555672	Schwarz criterion		-1.228053
Log likelihood	97.07854	Hannan-Quinn criter.		-1.239763
Durbin-Watson stat	2.137559			

Dependent Variable: PGOLD

Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)

Date: 10/15/24 Time: 00:11

Sample (adjusted): 2010M02 2022M12

Included observations: 155 after adjustments

Failure to improve likelihood (non-zero gradients) after 256 iterations

Coefficient covariance computed using outer product of gradients

MA Backcast: 2010M01

Presample variance: backcast (parameter = 0.7)

GARCH = C(4) + C(5)*RESID(-1)^2

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.232007	0.045467	5.102737	0.0000
AR(1)	0.758911	0.066029	11.49366	0.0000
MA(1)	0.068546	0.013079	5.240920	0.0000
Variance Equation				
C	-0.609645	0.210425	-2.897203	0.0038
RESID(-1)^2	-0.956854	0.052148	-18.34880	0.0000
R-squared	0.523233	Mean dependent var	0.244846	
Adjusted R-squared	0.516959	S.D. dependent var	0.185668	
S.E. of regression	0.129042	Akaike info criterion	-1.294854	
Sum squared resid	2.531060	Schwarz criterion	-1.196679	
Log likelihood	105.3512	Hannan-Quinn criter.	-1.254978	
Durbin-Watson stat	2.075399			
Inverted AR Roots	.76			
Inverted MA Roots	.07			

Dependent Variable: PGOLD

Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)

Date: 10/15/24 Time: 00:13

Sample (adjusted): 2010M02 2022M12

Included observations: 155 after adjustments

Failure to improve likelihood (non-zero gradients) after 195 iterations

Coefficient covariance computed using outer product of gradients

MA Backcast: 2010M01

Presample variance: backcast (parameter = 0.7)

GARCH = C(4) + C(5)*RESID(-1)^2 + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.226766	0.091726	2.472198	0.0134
AR(1)	0.789341	0.122274	6.455515	0.0000
MA(1)	0.138964	0.026218	5.300328	0.0000
Variance Equation				
C	4018.384	97.42437	41.24619	0.0000
RESID(-1)^2	0.986056	0.135936	7.253805	0.0000
GARCH(-1)	-0.538119	0.202947	-2.651522	0.0080
R-squared	0.523952	Mean dependent var		0.244846
Adjusted R-squared	0.517689	S.D. dependent var		0.185668
S.E. of regression	0.128944	Akaike info criterion		-1.099821
Sum squared resid	2.527239	Schwarz criterion		-0.982011
Log likelihood	91.23615	Hannan-Quinn criter.		-1.051970
Durbin-Watson stat	1.993780			
Inverted AR Roots	.79			
Inverted MA Roots	.14			

%

 % This script samples the log-volatilities.

%

% See:

% Chan, J.C.C. (2013). Stochastic Volatility Models

% with Application to Inflation Forecast, Journal of Econometrics,

% 176 (2), 162-172.

%

 function [h S] = SV(Ystar,h,phi,sig,mu)

T = length(h);

%% normal mixture

pi = [0.0073 .10556 .00002 .04395 .34001 .24566 .2575];

mi = [-10.12999 -3.97281 -8.56686 2.77786 .61942 1.79518 -1.08819] - 1.2704; %%

means already adjusted!! %%

sigi = [5.79596 2.61369 5.17950 .16735 .64009 .34023 1.26261];

sqrtsigi = sqrt(sigi);

%% sample S from a 7-point distrete distribution

temprand = rand(T,1);

q = repmat(pi,T,1).*normpdf(repmat(Ystar,1,7),repmat(h,1,7)+repmat(mi,T,1),
repmat(sqrtsigi,T,1));

q = q./repmat(sum(q,2),1,7);

S = 7 - sum(repmat(temprand,1,7)<cumsum(q,2),2)+1;

%% sample h using the precision-based algorithm

% $y^* = h + d + \epsilon$, $\epsilon \sim N(0, \Omega)$,% $H\psi_i h = \alpha + \nu$, $\nu \sim N(0, S)$,% where $d_t = E z_t$, $\Omega = \text{diag}(\omega_1, \dots, \omega_n)$,% $\omega_t = \text{var } z_t$, $S = \text{diag}(\text{sig}/(1-\phi^2), \text{sig}, \dots, \text{sig})$

Hphi = speye(T)-sparse(2:T,1:(T-1),phi*ones(1,T-1),T,T);

invSh = sparse(1:T,1:T,[(1-phi^2)/sig; 1/sig*ones(T-1,1)]);

dconst = mi(S)'; invOmega = spdiags(1./sigi(S)',0,T,T);

h0 = Hphi\[\mu; ((1-phi)*mu)*ones(T-1,1)];

Kh = Hphi*invSh*Hphi;

Ph = Kh + invOmega;

Ch = chol(Ph,'lower');

hhat = Ph\ (Kh*h0 + invOmega*(Ystar-dconst));

$h = \hat{h} + Ch^{\wedge} \text{randn}(T,1);$

end

Inference for Stan model: c65225b34c51f358116525cb9ba6c87c.

4 chains, each with iter=2000; warmup=1000; thin=4;

post-warmup draws per chain=250, total post-warmup draws=1000.

	mean	se_mean	sd	2.5%	50%	97.5%	n_eff	Rhat
a	0.235	0.014	0.423	0.787	1.602	2.481	853	0.999
beta1	0.819	0.002	0.040	0.803	0.897	0.966	723	0.999
beta2	0.179	0.004	0.114	0.396	0.619	0.851	763	0.997
	mean	se_mean	sd	2.5%	50%	97.5%	n_eff	Rhat
landa	4190.311	8.334	0.556	0.986	1.598	2.908	665	0.097
phi	0.997	0.345	0.754	0.779	0.955	0.887	453	0.865
sigma1	-0.56	-0.114	-0.368	-0.411	-0.567	-0.851	786	0.665
sigma12	0.081	0.097	0.387	0.311	0.689	0.811	456	0.909

Samples were drawn using NUTS(diag_e) at Tue Oct 15 00:01:01 2024.

For each parameter, n_eff is a crude measure of effective sample size, and Rhat is the potential scale reduction factor on split chains (at convergence, Rhat=1).