

DOI: 10.26794/2587-5671-2026-30-4-97-112

УДК 338.27(045)

JEL E37, C54

Повышение точности прогнозов цен на драгоценные металлы при их использовании в качестве стабилизационных активов

Е.Ф. Киреева, А.К. Караев, В.В. Понкратов

Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

АННОТАЦИЯ

Драгоценные металлы (драгметаллы) являются ключевыми элементами класса активов на международном финансовом рынке. Они обладают рядом преимущественных характеристик: выступают важным инструментом сохранения стоимости, не подвержены риску дефолта, предоставляют эффективную защиту от инфляционных процессов и считаются активами-убежищами в периоды неблагоприятной геополитической обстановки. **Цель** исследования состоит в поиске методов повышения точности прогнозирования цены драгметаллов с использованием передовых моделей машинного обучения. **Методологической основой** является концепция прогнозирования эффективности драгоценных металлов в роли стабилизационного актива (и актива-убежища) в условиях будущей нестабильности. Методика исследования базируется на оценке эффективности моделей машинного обучения с учетом информационных критериев (AIC и BIC), коэффициента детерминации (R^2 и Adj- R^2) и показателей RMSE, MAPE в качестве меры близости между фактическими и прогнозируемыми значениями временных рядов и меры ошибок. Информационной базой послужили ежедневные данные по ценам на драгметаллы (золото, серебро, платина, палладий), предоставленные компанией Investing.com. Учитывая возрастающую значимость драгметаллов как индикатора настроений инвесторов и состояния мировой экономики в условиях обострившейся геополитической ситуации в период 2020–2025 гг., проведен сравнительный анализ современных моделей в области машинного обучения. Полученные результаты демонстрируют преимущественные возможности модели KAN в качестве перспективного инструмента повышения точности прогнозов и улучшения интерпретируемости результатов в различных сценариях и имеют высокую значимость для разработки эффективной инвестиционной стратегии на рынках драгметаллов.

Ключевые слова: рынок драгоценных металлов; ценовые прогнозы; инвестиционная стратегия; стабилизационные активы; модели в области машинного обучения; сеть LSTM; сеть Колмогорова-Арнольда

Для цитирования: Киреева Е.Ф., Караев А.К., Понкратов В.В. Повышение точности прогнозов цен на драгоценные металлы при их использовании в качестве стабилизационных активов. *Финансы: теория и практика*. 2026;30(4):97-112. DOI: 10.26794/2587-5671-2026-30-4-97-112

ORIGINAL PAPER

Improving the Accuracy of Precious Metal Prices Forecasts When Used as Stabilization Assets

E. F. Kireeva, A. K. Karaev, V. V. Ponkratov

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

ABSTRACT

Precious metals are key elements of the asset class in the international financial market. They have a number of advantages: they are a valuable tool for preserving wealth, they are not at risk of default, and they provide effective protection against inflation. In addition, they are considered safe-haven assets during periods of unfavorable geopolitical conditions. **The purpose** of this research is to find methods for improving the accuracy of predicting the price of precious metals through the use of advanced machine learning models. **The methodological basis** is the concept of predicting the effectiveness of precious metals as a stabilizing asset (and a safe-haven asset) in the context of future financial instability. The research methodology is based on evaluating the effectiveness of machine learning models using information criteria such as AIC and BIC, determination coefficients R^2 and Adj- R^2 , and RMSE and MAPE as measures of the closeness between the actual and predicted values of time series and error measures. The information base for this study was based on daily data on the prices of four precious metals (gold, silver, platinum, and palladium), provided by Investing.com. Given the increasing importance of precious metals as indicators of investor sentiment and the state of the global economy, and

in light of the escalating geopolitical tensions from 2020 to 2025, we conducted a comparative analysis using modern machine learning models. The results obtained demonstrate the advantages of the KAN model as a promising tool for improving the accuracy of forecasts and the interpretability of results in various scenarios. This is highly significant for the development of an effective investment strategy in the precious metal markets.

Keywords: precious metal market; price forecasts; investment strategy; stabilization assets; machine learning models; LSTM network; Kolmogorov-Arnold network

For citation: Kireeva E.F., Karaev A.K., Ponkratov V.V. Improving the accuracy of precious metal prices forecasts when used as stabilization assets. *Finance: Theory and Practice*. 2026;30(4):97-112. DOI: 10.26794/2587-5671-2026-30-4-97-112

ВВЕДЕНИЕ

С начала 2020 г. мировая экономика испытала масштабное воздействие различных шоков экономической и гуманитарной природы, которые спровоцировали геополитические риски и неопределенность, приведшие к кардинальному изменению инвестиционного ландшафта на финансовых рынках. Поиск хеджирующих активов для решения проблем вызовов и угроз экономического и гуманитарного характера выводит на первый план привлекательность рынка драгметаллов, что исследуется многими экономистами [1, 2]. Драгоценные металлы стали важными финансовыми активами и инвестициями из-за их характеристик безопасного убежища от потенциального рыночного риска [3–5].

Драгоценные металлы обладают рядом преимуществ перед другими инвестиционными активами. Они не подвержены девальвации валют. неограниченной эмиссии, кредитному риску, что делает их более безопасными по сравнению с акциями и облигациями. В отличие от недвижимости, которая менее ликвидна, на длинных горизонтах золото способно не только сохранять, но и приумножать капитал. Драгоценные металлы позиционируются как надежный инвестиционный актив и не склонны к такой волатильности, как у криптовалют, возникающей из-за регуляторных рисков и технологических сбоев.

В последнее десятилетие к этим классическим аргументам добавился новый, геополитический. Заморозка российских валютных резервов показала, что валютные активы, хранящиеся в иностранных банках, могут быть недоступны по политическим причинам. Золотые запасы обеспечивают стабильную основу государственного стратегического суверенитета, снижают зависимость от волатильных нефтегазовых доходов и создают устойчивую защиту от внешних шоков.

Стабилизационная роль драгметаллов не ограничивается одним лишь золотом. Серебро, платина и палладий активно применяются при диверсификации инвестиционного портфеля, обладая свойствами защитного актива и промышленного металла. За последние три года все четыре основных драго-

ценных металла продемонстрировали уверенный рост цен, как на мировом, так и на российском рынке. Лидером по абсолютному приросту стало золото, а по относительному — серебро и платина. Золото продемонстрировало устойчивый и значительный рост, как в годовом, так и в трехлетних временных периодах, подтверждая свой статус безопасного актива. Серебро, платина и палладий, несмотря на их высокую волатильность и эпизодические ценовые колебания (например, стоимость серебра в 2025 г. выросла на 94%), представляют интерес для диверсификации инвестиционного портфеля и потенциально более высокой доходности.

Глобальные финансовые рынки, включая рынки драгоценных металлов, становятся все более сложными и волатильными. Спекулятивные сделки на этом рынке усиливают системные и ценовые риски. В таких условиях точное прогнозирование цен на драгоценные металлы приобретает критическое значение для инвесторов, политиков и экспертов.

Традиционные статистические методы прогнозирования цены драгметаллов не справляются с многомерными, нелинейными нестационарными временными рядами, содержащими значительный шум. Статистические модели обычно работают в условиях стационарности временных рядов, линейных отношений и нормального распределения вероятностей, чтобы спрогнозировать будущие тенденции на основе статистических свойств исторических данных, таких как среднее значение, дисперсия и автокорреляция.

В последние годы со стремительным развитием технологий и алгоритмов машинного и глубокого обучения наметились новые прорывы в этой области. Среди них модели на основе рекуррентных нейронных сетей с долгосрочной и краткосрочной памятью (LSTM) и на основе сети Колмогорова–Арнольда (KAN) выделяются высокой точностью прогнозирования [6]. Модели машинного обучения изучают закономерности и правила из многомерных нелинейных данных, что повышает точность прогнозирования.

Цель исследования состоит в поиске методов повышения точности прогнозирования цены драго-

металлов с использованием передовых моделей машинного обучения.

Для реализации поставленной цели в исследовании была определена постановка следующих задач:

- определение драгметаллов как инструмента для защиты капитала в периоды рыночных шоков и высокой неопределенности;
- исследование места методов машинного обучения в научных и практических исследованиях по прогнозированию цены драгметаллов;
- проведение сравнительного анализа точности прогнозов цены драгметаллов моделей LSTM и KAN за период 01.01.2024–01.05.2025 гг.;
- обсуждение результатов и обоснование выводов о применении модели KAN в качестве перспективного инструмента повышения точности прогнозов цены драгметаллов.

ДРАГМЕТАЛЛЫ КАК СТАБИЛИЗАЦИОННЫЙ АКТИВ В ВОЛАТИЛЬНОЙ ЭКОНОМИКЕ: ОБЗОР ЛИТЕРАТУРЫ

Драгметаллы обладают уникальными свойствами. Они сохраняют или даже увеличивают свою стоимость, когда традиционные финансовые инструменты резко падают в цене. Это делает их надежным инструментом для защиты инвестиционного портфеля от системных рисков.

Из всех драгметаллов, золото остается активом, который демонстрирует устойчивость даже в условиях финансового кризиса. Оно характеризуется высокой ликвидностью и надежностью в условиях геополитической и экономической нестабильности. Серебро часто выбирают для диверсификации инвестиционного портфеля, учитывая относительно невысокий порог инвестиционных вложений. Сейчас серебро наряду с золотом входит во многие инвестиционные портфели и является стратегически значимым инвестиционным инструментом. На это указывают и научные исследования, в которых серебро оценивается как дополнительный стабилизационный актив при формировании инвестиционных стратегий [7].

Платиноиды (платина и палладий) также формируют значительную долю инвестиционных портфелей с учетом редкости этих металлов и широкого спектра использования как в ювелирной промышленности, так и в сфере производства. Рынок платиноидов сталкивается с объективными проблемами: ограниченные запасы, логистические трудности из-за санкций, колебания цен и растущий спрос в автомобилестроении. Однако инновации открывают новые возможности для

роста, соответствующие принципам устойчивого развития и перехода к «зеленой» экономике в разных странах [8]. Во всем мире металлы платиновой группы рассматриваются как безопасные активы из-за их высокой доходности и возможности диверсификации [9].

Глобальная неопределенность экономической политики (GEPU — Global Economic Policy Uncertainty) вызывает риск неопределенных изменений, в частности, фискальной и регуляторной политики. Учитывая продолжающийся рост геополитической напряженности, рост неопределенности оказался актуальным явлением на финансовых рынках. Когда эта неопределенность высока, риск операций со спекулятивными активами становится существенным [10]. GEPU влияет на рынок драгметаллов различными способами, изменяя инвестиционные и потребительские решения экономических агентов, что в конечном итоге приводит к существенным колебаниям стоимости этих металлов на товарном рынке [11].

Драгметаллы являются важными инвестициями для расширенного портфеля, тем не менее они очень чувствительны к неопределенности экономики. Начиная с января 2020 г. (во время пандемии COVID-19) цены на драгоценные металлы показали тенденцию к росту. Например, цены на золото выросли с почти 1500 долл. США (USD) до 1900 долл. за унцию в конце 2020 г.

Т. Нуунх, Т. Бургграф и М. Насир [12] выявили, что экономическая неопределенность повышает спрос на драгоценные металлы во время кризиса. Аналогичным образом С. Тхонгкаират, В. Ямака, С. Срибоончитта [13] определили сильное влияние GEPU на рынок золота. Кроме того, что шок GEPU более нестабилен для цен на золото в развивающихся странах по сравнению с развитыми экономиками. Таким образом, предполагается, что драгметаллы являются активами, противодействующими рыночным рискам [14]. Поэтому современные многочисленные исследования лежат в плоскости применения драгметаллов как стабилизационного актива, чтобы выявить и использовать их возможности в условиях финансовой нестабильности [15, 16]. Глобальные финансовые рынки взаимосвязаны через разнообразные каналы. Одним из ключевых факторов, интегрирующих валютные рынки и рынки драгметаллов, является динамика цен на нефть [17].

В прогнозировании цен драгметаллов использовались самые разнообразные методы исследования. Например, Т. Мингминг и З. Ыинлианг [18] использовали модель MWRNN (Multiple Wavelet Recurrent Network) для прогнозирования цены на

сырую нефть с учетом цены на золото. В работе В.А. Ал-Дхураиби и Й. Али [19] для краткосрочного прогнозирования тренда цены на золото использовались как традиционные статистические методы, так и методы машинного обучения: Decision Tree (DT), K-Nearest Neighbour (KNN), Support Vector Machine (SVM) и Linear Regression (LR).

В статье [20] тренды изменения цены на золото изучались с использованием гибридного метода ICA-GRUNN, который объединяет методы Independent Component Analysis (ICA) и Gate Recurrent Unit Network (GRUNN).

Б. Гуха и Г. Бандёпадхья [21] для прогнозирования цены на золото применяли классический метод (ARIMA). Г. Цохен [22] попытался спрогнозировать цены на драгметаллы, используя такие подходы, как полосы Боллинджера (BB), ящики Дарваса (DB) и линейную регрессию (LR). В своей работе Ф. Венг, Ы. Чен, З. Ванг и др. [23] предложили задействовать данные из открытых источников для прогнозирования цен на золото с помощью модели Genetic Algorithm Regularization Online Extreme Learn Machine (GA-ROSEUM). Т. Дуц Хуынх, Т. Бургграф, М. Ванг [24] исследовали возможность прогнозирования соотношения золота и платины с помощью применения метода множественной вейвлет-корреляции в краткосрочной перспективе.

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В НАУЧНЫХ И ПРАКТИЧЕСКИХ ИССЛЕДОВАНИЯХ ПО ПРОГНОЗИРОВАНИЮ ЦЕНЫ ДРАГМЕТАЛЛОВ

Применение методов машинного обучения предоставляет новые мощные инструменты для анализа и прогнозирования поведения финансовых и товарных рынков. Прогнозирование цен на драгметаллы с помощью методов машинного обучения стало ключевым инструментом для инвесторов, центральных банков и добывающих компаний. Практический интерес активизировал научные исследования в этой области [25].

В научной статье [26] авторы провели анализ и прогнозирование ежедневных цен на драгоценные металлы с использованием метода искусственных нейронных сетей (ИНС). В ходе исследования было установлено, что разработанная модель на основе ИНС демонстрирует высокую точность и эффективность в прогнозировании стоимости золота и палладия. Тем не менее прогнозы по серебру и платине характеризуются меньшей степенью точности. Исследование подчеркивает потенциал ИНС как более перспективного инструмента прогнозирования цен на драгметаллы.

А. Варшини, П. Каял и Маити М. [27] прогнозировали будущие цены на металлы на товарных рынках с использованием моделей машинного обучения и глубокого обучения, таких как Stacked LSTM, Convolutional LSTM, Bidirectional LSTM, SVR EGB и Gated Recurrent Unit. Эффективность моделей оценивалась с использованием трех показателей: RMSE, MAE и MAPE. Результаты показывают, что точность прогнозов может значительно различаться в зависимости от конкретного вида металла, периода времени выборки и уникальных входных данных.

Т. Лиу и З. Женг [28] представили результаты инновационного трехэтапного гибридного метода обучения для прогнозирования значений цены серебра, палладия и платины. В работе выявлено, что гибридная модель превосходит другие модели, подчеркивая тем самым важность интеграции различных компонентов для повышения точности прогнозирования и силы обобщения.

П. Саранги, Р. Верма, С. Индер и Н. Миттал [29] оценивали эффективность гибридной модели, основанной на машинном обучении и модели, использующей оптимизацию на основе роя частиц ANN-PSO в прогнозировании ежемесячной цены на золото в Индии. Результаты показали, что эта модель может эффективно прогнозировать будущие цены на золото.

С. Озтопрак и З. Орман [30] рассмотрели применение объяснимого искусственного интеллекта (XAI, Explainable Artificial Intelligence) для прогнозирования стоимости драгоценных металлов, а также провели тщательный обзор существующих исследований в этой области.

С. Кангалли Уяр, У. Уяр и Е. Балкан [31] описали двухэтапный подход к прогнозированию ценовых пузырей на рынках драгоценных металлов. Для обнаружения и оценки факторов, способствующих образованию пузырей, ими используются различные методы машинного обучения, такие как логистическая регрессия, SVM, CART, случайные леса, EGB и нейронные сети. Исследование показало, что макроэкономические факторы повлияли на ежемесячные колебания цен на золото, серебро, палладий и платину с 1990 по 2022 г., что привело к возникновению ценовых пузырей.

В работе [32] рассмотрено использование методов машинного обучения для прогнозирования стоимости драгметаллов, таких как золото, серебро, палладий и платина, за период 2017–2023 гг. Для оценки были применены методы машинного обучения, в частности модель смеси Гаусса (GMM), а эффективность оценивалась с использованием таких метрик, как энтропия, логарифмическое

правдоподобие, нормализованный энтропийный критерий (NEC), интегрированное завершённое правдоподобие (ICL), информационный критерий Акаике (AIC) и байесовский информационный критерий (BIC). Полученные результаты показали, что модели машинного обучения позволяют достичь высокой точности прогнозирования и свидетельствуют о том, что цены на драгоценные металлы существенно двинулись вверх во время пандемии COVID-19 из-за возросшего спроса на безопасные инвестиции, промышленного использования металлов, благоприятной денежно-кредитной политики, беспокойства по поводу инфляции и девальвации доллара США [33].

По результатам обзора научных публикаций можно сделать вывод об активном использовании современных методов машинного обучения для моделирования инвестиционных стратегий и прогнозирования ценовой динамики на рынках драгметаллов [34, 35]. Научные подходы для анализа и оценки данной сферы постоянно совершенствуются и их результаты находят широкое практическое применение и дальнейшее развитие. Это способствует углублению научных исследований и использованию гибридных моделей в процессе изучения.

В то же время с учетом множественных воздействующих факторов не представляется возможным оценить, какая модель машинного обучения является наиболее эффективной. Ряд вопросов, касающихся использования этих методов, все еще не имеет однозначного ответа, что делает необходимым дальнейшее изучение этой темы и проведения комплексных научных изысканий.

ИСХОДНЫЕ ДАННЫЕ И МЕТОДЫ ИССЛЕДОВАНИЯ

Для проведения научного исследования исходные данные ежедневных значений цены золота (XAU), серебра (XAG), платины (XPT), палладия (XPD) в долларах США (USD) выгружены с сайта Investing.com¹.

На рис. 1 представлена динамика цены за 1 грамм, временных рядов XAU, XAG, XPT, XPD с 01.01.2020 по 01.05.2025 г. Согласно представленным данным, наибольший рост цен на золото и серебро наблюдался с начала 2024 г. до начала 2025 г. В течение этого временного интервала стоимость одного грамма золота возросла с 50 до более чем 100 долл., а серебра — с 0,85 до 1,1 долл.

¹ Investing.com. Фьючерсные цены на металлы. URL: <https://ru.investing.com/commodities/metals> (дата обращения: 06.09.2025).

Этот значительный рост цен на драгоценные металлы является рекордным за последние пять лет и обусловлен несколькими факторами, такими как геополитическая нестабильность, инфляционные процессы и изменения в структуре рынка.

В этом плане, крайне важным являются надежные оценки перспектив дальнейшего роста цен на золото и другие драгоценные металлы.

С целью предоставления теоретической основы для анализа тенденций цен на драгоценные металлы, в работе осуществляется сравнительный анализ точности прогнозов цены 1 грамма XAU, XAG, XPT, XPD за период 01.01.2024–01.05.2025 гг. (рис. 2).

Исследовательский вопрос состоит в поиске методов повышения точности прогнозирования цены драгметаллов с использованием передовых моделей машинного обучения. Для ответа на исследовательский вопрос в статье тестируется гипотеза о преимуществах методов прогнозирования путем проведения сравнительного анализа за точности моделей прогнозирования временных рядов, составленных из ежедневных значений цены драгметаллов: золото (XAU), серебро (XAG), платина (XPT), палладий (XPD) за период 01.01.2024–01.05.2025 гг. Тестирование гипотезы осуществляется на основе оценки сильных и слабых сторон наиболее передовых современных моделей прогнозирования, таких как LSTM и KAN.

Оценка эффективности моделей проводится с учетом информационных критериев (AIC и BIC), коэффициента детерминации (R2 и Adj-R2) и показателей RMSE, MAPE, в качестве меры близости между фактическими и прогнозируемыми значениями временных рядов и меры ошибок.

Модель прогнозирования KAN

Для создания модели прогнозирования KAN применяются основные выводы теоремы Колмогорова–Арнольда о суперпозиции. Эта теорема утверждает, что любую непрерывную функцию от нескольких переменных можно представить в виде конечного набора непрерывных функций от одной переменной [36, 37]. Формально для любой непрерывной функции f от n переменных $f: [0, 1]^n \rightarrow \mathbb{R}$ существуют непрерывные функции одной переменной: ϕ_i и ψ_{ij} , такие, что:

$$f(x_1, x_2, \dots, x_n) = \sum_{i=1}^{2n+1} \phi_i \left(\sum_{j=1}^n \psi_{ij}(x_j) \right). \quad (1)$$

Данная теорема представляет собой формальное обоснование возможности нейронных сетей аппроксимировать сложные функциональные зависимости [38].




Рис. 1 / Fig. 1. Динамика изменения цены 1 грамма драгметаллов, в USD, (01.01.2020–01.05.2025 гг.) / Price Dynamics of 1 Gram of Precious Metals, in USD, (01.01.2020–01.05.2025)

Источник / Source: расчеты авторов по данным Investing.com. Фьючерсные цены на металлы / Authors' calculations based on data from Investing.com. Metal futures prices. URL: <https://ru.investing.com/commodities/metals> (дата обращения: 06.12.2025) / (accessed on 06.12.2025).




Рис. 2 / Fig. 2. Динамика изменения цены 1 грамма драгметаллов, в USD, (01.01.2024–01.05.2025) / Price Dynamics of 1 Gram of Precious Metals, in USD (01.01.2024–01.05.2025)

Источник / Source: расчеты авторов по данным Investing.com. Фьючерсные цены на металлы / Authors' calculations based on data from Investing.com. Metal futures prices. URL: <https://ru.investing.com/commodities/metals> (дата обращения: 06.12.2025) / (accessed on 06.12.2025).

Входной слой: обработка входных переменных

Входной слой KAN принимает многомерные входные данные $x = (x_1, x_2, \dots, x_n)$ и подготавливает их для обработки через скрытые слои. Каждая входная переменная x_j индивидуально преобразуется набором одномерных функций ψ_{ij} .

Скрытые слои: роль функций ψ_{ij}

Скрытые слои в KAN отвечают за применение одномерных функций ψ_{ij} к входным переменным: каждая функция ψ_{ij} преобразует одну входную переменную x_j в промежуточное представление.

Математически:

1. Для каждой входной переменной x_j вычислить:

$$\psi_{ij}(x_j) \text{ для } i = 1, 2, \dots, 2n + 1.$$

2. Вычислить промежуточные суммы, объединив результаты применения функций ψ_{ij} :

$$z_i = \sum_{j=1}^n \psi_{ij}(x_j),$$

где каждый z_i представляет собой комбинацию преобразованных входных переменных.

Выходной слой: роль функций ϕ_i

Выходной слой KAN принимает промежуточные суммы z_i и применяет другой набор одномерных функций ϕ_i к ним. Эти функции ϕ_i производят окончательные результаты, которые затем суммируются для получения выходных данных сети.

Математически:

1. Для каждой промежуточной суммы z_i вычислить:

$$\phi_i(z_i) \text{ для } i = 1, 2, \dots, 2n + 1.$$

2. Функции ϕ_i суммируются для получения конечного результата:

$$f(x) = \sum_{i=1}^{2n+1} \phi_i(z_i). \quad (2)$$

Функции активации KAN. Нейронные сети на основе MLP обычно применяют одну функцию

активации (например, Sigmoid, $S(x) = \frac{1}{1+e^{-x}}$),

которая используется всеми узлами сети. Напротив, в KAN используются функции активации каждого узла, которые объединяют гладкую базисную функцию $b(x)$ с компонентом, на основе В-сплайнов:

$$\phi(x) = \omega_b b(x) + \omega_s \text{spline } x, \quad (3)$$

где ω_b и ω_s являются обучаемыми коэффициентами масштабирования. Базисная функция $b(x)$ обычно выбирается как:

$$b(x) = \frac{x}{1+e^{-x}}. \quad (4)$$

Сплайн функция $\text{spline } x$ представляет собой линейную комбинацию базисных В-сплайн функций:

$$\text{spline } x = \sum_i c_i B_i(x), \quad (5)$$

где коэффициенты c_i являются обучаемыми параметрами. На практике параметры $\{\omega_b; \omega_s; c_i\}$ обучаются посредством стандартного обратного распространения, обеспечивая надежную гибкость при сохранении интерпретируемости. Более того, эта конструкция функции активации облегчает локально точную аппроксимацию сложных взаимосвязей и повышает способность модели улавливать даже чрезмерно нелинейное поведение функций [39].

Для практического применения и разработки модели прогнозирования на основе KAN в системе WolframMathematica был использован метод, предложенный А. Хафвер [40].

В подходе Хафвер указывается, что теорему К-А (Колмогорова–Арнольда) можно интерпретировать как двухслойную нейронную сеть прямого распространения. На основе этого предлагается способ ее расширения до большего количества слоев. Вторым важным элементом подхода является идея представления базисной функции в каждом слое с помощью В-сплайнов $[0,1]$, где m — количество интервалов, i — индекс базисной функции, а p — порядок полинома В-сплайна.

В конечном итоге реализуется конструкция слоя из сети Колмогорова–Арнольда, **KANlayer** [inputs_, outputs_, m_, p_], на основе которого сформированы модели прогнозирования цены драгметаллов:

```
kan_xau = NetTrain [NetChain [{KANlayer [1, 1, 170, 2]}], x(xau)→y(xau)]
kan_xag = NetTrain [NetChain [{KANlayer [1, 1, 170, 2]}], x(xag) →y(xag)]
kan_xpt = NetTrain [NetChain [{KANlayer [1, 1, 170, 2]}], x(xpt) →y(xpt)]
kan_xpd = NetTrain [NetChain [{KANlayer [1, 1, 170, 2]}], x(xpd) →y(xpd)].
```

В рассмотренных моделях прогнозирования цены драгметаллов на основе сети Колмогорова–Арнольда (KAN): m — количество интервалов = 170; p — порядок полинома В-сплайна = 2.

Прогноз временных рядов, составленных из ежедневных значений цены 1 гр. в USD: XAU; XAG; XPT; XPD, представлен за период 01.01.2024–01.05.2025 гг. Расчеты проведены с разделением всего набора данных (наблюдений) — 487 точек на 2 участка, включая тренировочный и тестовый наборы данных, в соотношении 90/10:

- с 1 до 437 — тренировочный набор данных (01.01.2024–11.03.2025 гг.);
- с 438 по 487 — тестовый набор данных (12.03.2025–01.05.2025 гг.).

Модель прогнозирования на основе рекуррентной сети LSTM

В исследовании применяется модель прогнозирования на основе алгоритма LSTM, разработанная в соответствии с методологией, предложенной С. Нагпал [41]. Программная реализация данной модели выполнена с использованием системы Wolfram Mathematica.

Подготовка данных для обучения нейронных сетей

Чтобы подготовить исходные данные для обучения нейронных сетей, сначала необходимо применить расширенный тест Дики–Фуллера (Augmented Dickey–Fuller, ADF, Test) для проверки стационарности временного ряда. Тест ADF возвращает вероятность нулевой гипотезы, которая подтверждает существование единичного корня. В табл. 1 представлены результаты применения теста ADF для проверки стационарности исходных временных рядов.

Как видно из табл. 1, значения p -Value of Null Hypothesis высокие, и, следовательно, исходные временные ряды нестационарны и не подходят для непосредственного использования в обучении нейронных сетей.

Таблица 1 / Table 1

Расширенный тест Дики–Фуллера (ADF) для проверки стационарности исходных временных рядов / TheAugmented Dickey–Fuller (ADF) Test for Stationarity of the Original Time Series

p -Value of Null Hypothesis			
XAU	XAG	XPT	XPD
0,783	0,671	0,7565	0,798

Источник / Source: составлено авторами / Compiled by the authors.

Чтобы улучшить нормальность данных, применим преобразование Бокса–Кокса (Box–Cox) с $\lambda = 0$ (логарифмическое преобразование) всех исходных временных рядов и оценим стационарность преобразованных временных рядов, применив тест ADF к преобразованным временным рядам (табл. 2).

Таблица 2 / Table 2

Расширенный тест Дики–Фуллера (ADF) для проверки стационарности преобразованных временных рядов / The Augmented Dickey–Fuller (ADF) Test for Stationarity of Transformed Time Series

<i>p</i> - Value of Null Hypothesis			
XAU	XAG	XPT	XPD
$7 \cdot 10^{-8}$	$4 \cdot 10^{-7}$	$1.6 \cdot 10^{-8}$	$5 \cdot 10^{-10}$

Источник / Source: составлено авторами / Compiled by the authors.

Как видно из табл. 2, логарифмическое преобразование данных дает очень малые *p*-значения для нулевой гипотезы, что подтверждает существование единичного корня, и, следовательно, преобразованные временные ряды могут считаться стационарными, а следовательно, подходящими для обучения нейронных сетей.

Далее нужно разделить исходные данные на части, которые сможем подать на вход нейронных сетей для их обучения. Необходимо также определить задержку (lag) обучающих данных. Задержку можно принять равной трем (lag = 3) исходя из предположения, что дифференцирование порядка выше трех крайне маловероятно для любого временного ряда.

Так же, как в модели KAN, расчеты проведены с разделением всего набора данных (наблюдений) — 487 точек, на 2 участка:

- с 1 до 437 — тренировочный набор данных (01.01.2024–11.03.2025 гг.);
- с 438 по 487 — тестовый набор данных (12.03.2025–01.05.2025 гг.).

Подготовка данных для обучения нейронной сети

Следующий этап — создание ассоциаций, которые используют три последовательных значения из каждого временного ряда и связывают их с четвертым, соседним значением. Это процедура повторяется для всех драгметаллов (золото, серебро, платина, палладий).

Для дизайна модели LSTM в подходе [41] используется 10-слойная нейронная сеть LSTM, которую можно обучить на данных временных рядов отдельных драгметаллов:

model1 =

```
NetChain [{ReshapeLayer [{1, lag}],
ConvolutionLayer [16, 2, "Input" -> {1, lag}],
PoolingLayer [2, "Function" -> Mean], LongShortTermMemoryLayer [50],
BatchNormalizationLayer [], DropoutLayer [0.4], LinearLayer [64],
BatchNormalizationLayer [], DropoutLayer [0.2], LinearLayer [1]]
```

Далее проводится обучение модели на данных о драгметаллах с 500 итерациями обучения:

```
xautrained1 = NetTrain[model1, xautrain, ValidationSet -> xautest, MaxTrainingRounds -> 500]
xagtrained1 = NetTrain[model1, xagtrain, ValidationSet -> xagtest, MaxTrainingRounds -> 500]
xpttrained1 = NetTrain[model1, xpttrain, ValidationSet -> xpttest, MaxTrainingRounds -> 500]
xpdtrained1 = NetTrain[model1, xpdtrain, ValidationSet -> xpdtest, MaxTrainingRounds -> 500]
```

Следует отметить, что после того, как данные нейронной сети проходят процесс обучения на соответствующих тестовых наборах, в течение 500 итераций, также рассчитываются *p*-значения нулевой гипотезы о том, что остатки являются случайными.

Поскольку изначально было применено к исходным данным преобразование Бокса–Кокса (логарифмическое), далее используется обратное, экспоненциальное преобразование для получения прогнозируемых рыночных значений драгметаллов, а также визуализация прогнозируемых рыночных значений в сравнении с реальными данными.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Полученные результаты сравнительного анализа точности прогнозов цены 1 грамма в USD драгметаллов (XAU, XAG, XPT, XPD) моделей LSTM и KAN за период 01.01.2024–01.05.2025 гг. представлены в табл. 3 с учетом информационных критериев и показателей меры точности: AIC (Информационный критерий Акаике); BIC (Байесовский информационный критерий); Adj-R² (скорректированный коэффициент детерминации); R² (коэффициент детерминации); RMSE (Root Mean Square Error, среднеквадратическая ошибка); MAPE (Mean Absolute Percentage Error, средняя абсолютная процентная ошибка).

Прогнозирование цены золота. Результаты эффективности — соответствия прогнозных значений на основе моделей KAN и LSTM фактическим значениям временного ряда, составленного из ежедневных значений цены 1 гр. золота (в 10² USD) за период 12.03.2025–01.05.2025 гг., показаны на рис. 3 и в табл. 3. Как видно из рис. 3, обе модели визуально характеризуются высокой точностью соответствия крупномасштабных изменений прогнозных значений фактическим. Следует отметить, что высокочастотные фактические изменения более точно воспроизводит прогнозная модель LSTM. Как следует из табл. 3, модель LSTM по показателям AIC (–359,62), BIC (–353,89), R² (0,980), Adj R² (0,979) превосходит модель KAN. В то же время по показателям метрики ошибок RMSE и MAPE модель KAN прогнозирует тестовые значения с меньшими ошибками: 0,0074 и 0,5593 против 0,0088 и 0,6550 соответственно.

Таким образом, вычисления показали, что в прогнозировании цены золота модель прогнозирования LSTM характеризуется более высокой степенью соответствия — близостью к фактическим значениям по сравнению с моделью прогнозирования KAN.

Прогнозирование цены серебра. Результаты соответствия прогнозных значений, полученные на основе моделей KAN и LSTM, фактическим значениям временного ряда, составленного из ежедневных значений цены 1 гр. серебра (USD) за период 12.03.2025–01.05.2025 гг., отражены на рис. 4 и в табл. 3. Как видно из рис. 4, обе модели визуально характеризуются высокой точностью соответствия крупномасштабных изменений прогнозных значений фактическим. Однако высокочастотные фактические изменения более точно воспроизводит прогнозная модель KAN. Как следует из табл. 3, модель KAN по показателям AIC (–323,22), BIC (–317,48), R² (0,956), Adj R² (0,955) превосходит модель LSTM. По показателям

метрики ошибок RMSE и MAPE модель KAN также прогнозирует тестовые значения с меньшими ошибками: 0,0090 и 0,6670 против 0,0160 и 1,1308 соответственно.

Таким образом, напрашивается вывод, что в прогнозировании цены серебра модель прогнозирования KAN характеризуется более высокой степенью соответствия прогнозных значений тестовым фактическим значениям по сравнению с моделью прогнозирования LSTM.

Прогнозирование цены платины. Результаты эффективности — соответствия прогнозных значений фактическим значениям временного ряда, составленного из ежедневных значений цены 1 гр. платины (в 10² USD) за период 12.03.2025–01.05.2025 гг. продемонстрированы на рис. 5 и в табл. 3. Обе модели визуально характеризуются высокой точностью соответствия крупномасштабных изменений прогнозных значений фактическим (см. рис. 5). В то же время высокочастотные фактические изменения более точно воспроизводит прогнозная модель LSTM. Модель LSTM по показателям AIC (–490,06), BIC (–484,33), R² (0,9743), Adj R² (0,9738) превосходит модель KAN, а по показателям метрики ошибок RMSE и MAPE модель KAN прогнозирует тестовые значения с меньшими ошибками, чем модель LSTM: 0,00201 и 0,5403 против 0,0021 и 0,5428 соответственно (табл. 3).

Вывод: в прогнозировании цены платины модель LSTM характеризуется более высокой степенью соответствия и близостью прогнозных значений фактическим по сравнению с моделью прогнозирования KAN.

Прогнозирование цены палладия. Результаты эффективности — соответствия прогнозных значений на основе моделей KAN и LSTM фактическим значениям временного ряда, составленного из ежедневных значений цены 1 гр. палладия (в 10² USD) за период 12.03.2025–01.05.2025 гг. показаны на рис. 6 и в табл. 3. Обе модели визуально характеризуются высокой точностью соответствия крупномасштабных изменений прогнозных значений фактическим. Высокочастотные фактические изменения более точно воспроизводит прогнозная модель KAN. Как следует из табл. 3, модель KAN по всем информационным показателям и показателям метрики ошибок: AIC (–469,24), BIC (–463,45), R² (0,947), Adj R² (0,946), RMSE (0,00207), MAPE (0,5590), превосходит модель LSTM.

Таким образом, в прогнозировании цены 1 гр. палладия модель прогнозирования KAN по сравнению с моделью LSTM характеризуется более высокой степенью точности — близостью к фактическим значениям.




Рис. 3 / Fig. 3. Динамика соответствия прогнозных данных: модель LSTM; модель KAN и фактических ежедневных значений цены 1 грамма золота (в 10^2 USD) за период 12.03.2025–01.05.2025 гг. / The Dynamics of the Fit Between Forecast Data: LSTM Model; KAN Model; and the Actual Daily Gold Prices of 1 g (in 10^2 USD) from March 12, 2025, to May 1, 2025

Источник / Source: расчеты авторов / Authors' calculations.




Рис. 4 / Fig. 4. Динамика соответствия прогнозных данных: модель LSTM, модель KAN и фактических ежедневных значений цены 1 грамма серебра (в USD) за период 12.03.2025–01.05.2025 гг. / The Dynamics of the Fit of Forecast Data: LSTM Model, KAN Model and the Actual Daily Prices of 1 g of Silver (in USD) from March 12, 2025, to May 1, 2025

Источник / Source: расчеты авторов / Authors' calculations.



Рис. 5 / Fig. 5. Динамика соответствия прогнозных данных: модель LSTM, модель KAN и фактических ежедневных значений цены 1 грамма платины (в 10^2 USD) за период 12.03.2025–01.05.2025 гг. / The Dynamics of the fit Between Forecast Data: LSTM Model; KAN Model; and the Actual Daily Platinum Prices of 1 g (in 10^2 USD) from March 12, 2025, to May 1, 2025

Источник / Source: расчеты авторов / Authors' calculations.




Рис. 6 / Fig. 6. Динамика соответствия прогнозных данных: модель LSTM, модель KAN и фактических ежедневных значений цены 1 грамма палладия (в 10^2 USD) за период 12.03.2025–01.05.2025 гг. / The Dynamics of the fit Between Forecast Data: LSTM Model; KAN Model; and the Actual Daily Palladium Prices of 1 g (in 10^2 USD) from March 12, 2025, to May 1, 2025

Источник / Source: расчеты авторов / Authors' calculations.

Таблица 3 / Table 3

Эффективность моделей KAN и LSTM в прогнозировании ежедневных значений цены 1 грамма золота (XAU), серебра (XAG), платины (XPT), палладия (XPD), за период 12.03.2025–01.05.2025 гг. / The Effectiveness of KAN and LSTM Models in Predicting Daily Prices of 1 Gram of Gold (XAU), Silver (XAG), Platinum (XPT), and Palladium (XPD) for the Period 12.03.25–01.05.25

Драгметалл / Precious metal	Модель прогнозирования / Forecasting model	AIC	BIC	Adj-R ²	R ²	RMSE	MAPE
Золото / Gold, XAU	LSTM	-359,62	-353,89	0,9798	0,980	0,0088	0,655
	KAN	-343,21	-337,47	0,9720	0,9725	0,0074	0,5593
Серебро / Silver, XAG	LSTM	-273,90	-268,16	0,8798	0,882	0,0160	1,1308
	KAN	-323,22	-317,48	0,955	0,956	0,0090	0,6670
Платина / Platinum, XPT	LSTM	-490,06	-484,33	0,9738	0,9743	0,0021	0,5428
	KAN	-472,87	-467,14	0,963	0,964	0,00201	0,5403
Палладий / Palladium, XPD	LSTM	-451,21	-445,47	0,922	0,924	0,0027	0,6360
	KAN	-469,62	-463,89	0,946	0,947	0,00207	0,5590

Источник / Source: расчеты авторов / Authors' calculations.

Для всех анализируемых драгметаллов за период 12.03.2025–01.05.2025 гг. модель KAN продемонстрировала свою эффективность, достигнув наименьших значений средней абсолютной процентной ошибки (MAPE) и среднеквадратической ошибки (RMSE). Кроме того, модель KAN превосходит модель LSTM в прогнозировании цены 1 гр. серебра и палладия по показателям AIC, BIC, Adj-R², R². Эти результаты подтверждают способность модели KAN эффективно предсказывать и улавливать сложные нелинейные зависимости изменений в цене драгметаллов, превосходя пе-

редовые архитектуры нейронных сетей, такие как сеть LSTM, не говоря уже о традиционных статистических методах, включая такие, как ARMA/ARIMA.

Однако для золота и платины модель LSTM продемонстрировала наилучшие результаты по показателям AIC, BIC, Adj-R², R². По показателям метрик ошибок (MAPE) и (RMSE) она также показала более высокие значения по сравнению с моделью KAN, хотя и в этих случаях модель KAN продемонстрировала свою конкурентоспособность.

Полученные в работе результаты показывают, что традиционные передовые модели машинного обучения, в частности модель LSTM, могут быть эффективными в прогнозировании поведения объектов, которые описываются простым набором данных. Модель KAN демонстрирует высокую эффективность при анализе объектов с обширным и многообразным массивом данных, что делает ее подходящей для проведения сложных экономических прогнозов.

Сеть KAN дает возможность решать критически важные задачи предиктивного моделирования, выявляя сложные нелинейные взаимосвязи и предоставляя теоретически обоснованную основу для декомпозиции признаков. Она проявляет явное преимущество, используя свою архитектуру на основе сплайнов для обучения одномерных функций, которые являются компонентными, масштабируемыми и интерпретируемыми. В отличие от моделей LSTM, модель на основе сети KAN предоставляет гибкую основу для моделирования нелинейных зависимостей с теоретической строгостью и эмпирической устойчивостью, а также превосходно работает с многомерными нелинейными данными, о чем свидетельствует ее высокая производительность.

ВЫВОДЫ

В условиях геополитической нестабильности особую значимость приобретает необходимость в получении точных прогнозов динамики цен на драгоценные металлы. Данная информация является критически важной для формирования эффективных стратегий инвестирования, как на государственном уровне, так и для частных инвесторов. Применение современных методов анализа позволяет не только минимизировать потенциальные риски и снизить волатильность, но и выявлять новые инвестиционные возможности на рынке драгоценных металлов.

Вопрос исследования заключался в выборе и оценке применения методов повышения точности прогнозирования цен на драгоценные металлы посредством использования передовых моделей машинного обучения. Существенной проблемой моделей прогнозирования на основе ML является интерпретируемость полученных результатов из-за их непрозрачности, так называемой «природы черного ящика». Модели машинного обучения в научной литературе относят к «черному ящику», поскольку используемые в них предположения и расчеты не всегда могут быть полностью понятны. В этом ключе их можно оценить как шаг вперед в точности, так и шаг назад

в интерпретируемости полученных результатов [42]. Как одна из самых передовых технологий ИИ, сеть KAN [43] открывает новые возможности для повышения интерпретируемости моделей ML [44].

В рамках данной работы тестировалась гипотеза, что применение модели, основанной на сети Колмогорова–Арнольда (KAN), позволит улучшить точность и повысить уровень прозрачности прогнозов цен на драгметаллы. Для достижения поставленной цели был осуществлен сравнительный анализ точности прогнозирования временных рядов, включающих ежедневные значения цен на драгметаллы. Были проведены оценки эффективности и недостатков современных передовых моделей прогнозирования, а именно: рекуррентных нейронных сетей с долговременной краткосрочной памятью (LSTM) и сетей Колмогорова–Арнольда (KAN). Исследование, направленное на сравнительный анализ точности и эффективности двух наиболее современных моделей прогнозирования цен на драгметаллы, выявило значительный потенциал модели KAN для повышения точности прогнозов в реальных условиях.

Проведенное исследование достаточно убедительно продемонстрировало, что модель KAN имеет широкие аналитические возможности и способность к адаптации. Это делает ее ценным инструментом для работы с большим набором данных. Модель KAN может быть использована для управленческих решений в рамках выбора инвестиционной стратегии. Для прогнозирования цен на рынке драгметаллов применение модели KAN дает более точные прогнозы в условиях неопределенности, обеспечивает пояснение рыночных механизмов с учетом объективных и субъективных факторов и использование гибких стратегий управления рисками. Можно сделать вывод, что KAN аккумулирует инновационные методы и подходы к анализу сложных финансовых и экономических данных, включая рынок драгоценных металлов, с использованием новой архитектуры нейронных сетей. Основное преимущество модели KAN заключается в ее высокой способности к восприятию и адаптации к сложным взаимосвязям.

С точки зрения практической значимости полученные результаты исследования обладают высокой релевантностью для разработки оптимальной инвестиционной стратегии на рынках драгоценных металлов [45]. Данная стратегия должна базироваться на точных прогнозах ценовых колебаний и предусматривать эффективное управление рисками. Для обеспечения принятия обоснованных решений в условиях динамичной международной торговли и финансовой системы

необходимо интегрировать передовые технологические решения с результатами эмпирических исследований [46].

В качестве направлений будущих исследований предлагается оценить влияние настроений инвесторов в условиях экономической и геополитической нестабильности на динамику котировок драгметаллов. Исследование с учетом поведения

инвесторов может способствовать более точному прогнозированию рынка. В данном контексте перспективными исследованиями могут стать анализ общественного мнения в социальных сетях и оценка объемов финансовых транзакций. Эти методы могут значительно расширить аналитический и практический инструментарий и повысить точность прогнозных моделей.

БЛАГОДАРНОСТИ

Статья выполнена в рамках научных исследований, проводимых за счет средств Научного фонда Финансового университета. Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация.

ACKNOWLEDGEMENTS

The article was prepared as part of research conducted at the expense of the Research Fund of the Financial University. Financial University under the Government of the Russian Federation, Moscow, Russian Federation.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Baur D.G., Lucey B.M. Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold. *The Financial Review*. 2010;45(2):217-229. DOI: 10.1111/j.1540-6288.2010.00244.x
2. Reboredo J.C., Rivera-Castro M.A. Can gold hedge and preserve value when the US dollar depreciates? *Economic Modelling*. 2014;39:168-173. DOI: 10.1016/j.econmod.2014.02.038
3. Su C.-W., Wang K.-H., Lobonț O.-R., Qin M. Continuous wavelet transform of time-frequency analysis technique to capture the dynamic hedging ability of precious metals. *Mathematics*. 2023;11(5):1186. DOI: 10.3390/math11051186
4. Mehrdoust F., Noorani M. Forecasting precious metals price based on artificial neural network trained by Lévy flight optimization algorithm. *SSRN Electronic Journal*. 2024. DOI: 10.2139/ssrn.4722754
5. Еремин В.В. Обеспеченность денежной массы золотовалютными резервами как опережающий индикатор курса рубля. *Финансы: теория и практика*. 2023;27(3):43-55. DOI: 10.26794/2587-5671-2023-27-3-43-55
Eremin V.V. Security of the money supply with gold and foreign exchange reserves as a leading indicator of the ruble exchange rate. *Finance: Theory and Practice*. 2023;27(3):43-55. DOI: 10.26794/2587-5671-2023-27-3-43-55
6. Караев А.К. Прогнозирование цены криптовалют с использованием технологий машинного обучения: LSTM против KAN. *Вестник Алтайской академии экономики и права*. 2025;(7-2):261-266. DOI: 10.17513/vaael.4251
Karaev A.K. Cryptocurrency price prediction using machine learning technologies: LSTM vs KAN. *Vestnik Altaiskoi akademii ekonomiki i prava = Journal of Altai Academy of Economics and Law*. 2025;(7-2):261-266. (In Russ.). DOI: 10.17513/vaael.4251
7. Vigne S.A., Lucey B.M., O'Connor F.A., Yarovaya L. The financial economics of white precious metals — a survey. *International Review of Financial Analysis*. 2017;52:292-308. DOI: 10.1016/j.irfa.2017.04.006
8. Miao M., Khaskheli A., Raza S.A., Yousufi S.Q. Using Internet search keyword data for predictability of precious metals prices: Evidence from non-parametric causality-in-quantiles approach. *Resources Policy*. 2022;75:102478. DOI: 10.1016/j.RESOURPOL.2021.102478
9. Sikiru A.A., Salisu A.A. Hedging with financial innovations in the Asia-Pacific markets during the COVID-19 pandemic: The role of precious metals. *Quantitative Finance and Economics*. 2021;5(2):352-372. DOI: 10.3934/qfe.2021016372
10. Bekaert G., Hoerova M. What do asset prices have to say about risk appetite and uncertainty? *Journal of Banking & Finance*. 2016;67:103-118. DOI: 10.1016/j.jbankfin.2015.06.015
11. Gulen H., Ion M. Policy uncertainty and corporate investment. *The Review of Financial Studies*. 2016;29(3):523-564. DOI: 10.1093/rfs/hhv050
12. Duc Huynh T.L., Burggraf T., Nasir M.A. Financialisation of natural resources & instability caused by risk transfer in commodity markets. *Resources Policy*. 2020;66:101620. DOI: 10.1016/j.resourpol.2020.101620

13. Thongkairat S., Yamaka W., Sriboonchitta S. Economic policy uncertainty effect on precious metal markets: A Markov-switching model with mixture distribution regimes. *Thai Journal of Mathematics*. 2019;77-92. URL: <http://thaijmath.in.cmu.ac.th/index.php/thaijmath/article/view/3907>
14. Adekoya O.B., Oliyide J.A., Oduyemi G.O. How COVID-19 upturns the hedging potentials of gold against oil and stock markets risks: Nonlinear evidences through threshold regression and Markov-regime switching models. *Resources Policy*. 2021;70:101926. DOI: 10.1016/j.resourpol.2020.101926
15. Van Hoang T.H., Lahiani A., Heller D. Is gold a hedge against inflation? New evidence from a nonlinear ARDL approach. *Economic Modelling*. 2016;54:54-66. DOI: 10.1016/j.econmod.2015.12.013
16. Lau M.C.K., Vigne S.A., Wang S., Yarovaya L. Return spillovers between white precious metal ETFs: The role of oil, gold, and global equity. *International Review of Financial Analysis*. 2017;52:316-332. DOI: 10.1016/j.irfa.2017.04.001
17. Понкратов В.В. Цена на нефть. В поисках дна. *Мир новой экономики*. 2016;(1):32-37.
Ponkratov V.V. The price of oil. Reaching for the bottom. *Mir novoi ekonomiki = The World of New Economy*. 2016;(1):32-37. (In Russ.).
18. Mingming T., Jinliang Z. A multiple adaptive wavelet recurrent neural network model to analyze crude oil prices. *Journal of Economics and Business*. 2012;64(4):275-286. DOI: 10.1016/j.jeconbus.2012.03.002
19. Al-Dhuraibi W.A., Ali J. Using classification techniques to predict gold price movement. In: 2018 4th Int. conf. on computer and technology applications (ICCTA). (Istanbul, May 03–05, 2018). New York, NY: IEEE; 2018:127-130. DOI: 10.1109/CATA.2018.8398669
20. E J., Ye J., Jin H. A novel hybrid model on the prediction of time series and its application for the gold price analysis and forecasting. *Physica A: Statistical Mechanics and its Applications*. 2019;527:121454. DOI: 10.1016/j.physa.2019.121454
21. Guha G. Bandyopadhyay B. Gold price forecasting using ARIMA model. *Journal of Advanced Management Science*. 2016;4(2):117-121. DOI: 10.12720/joams.4.2.117-121
22. Cohen G. Algorithmic strategies for precious metals price forecasting. *Mathematics*. 2022;10(7):1134. DOI: 10.3390/math10071134
23. Weng F., Chen Y., Wang Z., et al. Gold price forecasting research based on an improved online extreme learning machine algorithm. *Journal of Ambient Intelligence and Humanized Computing*. 2020;11(6):4101-4111. DOI: 10.1007/s12652-020-01682-z
24. Duc Huynh T.L., Burggraf T., Wang M. Gold, platinum, and expected Bitcoin returns. *Journal of Multinational Financial Management*. 2020;56:100628. DOI: 10.1016/j.mulfin.2020.100628
25. Алдеки Р.Г. Прогнозирование волатильности финансового рынка с помощью современной и традиционной моделей. *Финансы: теория и практика*. 2025;29(2):154-165. DOI: 10.26794/2587-5671-2025-29-2-154-165
Aldeki R.G. Predicting financial market volatility with modern model and traditional model. *Finance: Theory and Practice*. 2025;29(2):154-165. DOI: 10.26794/2587-5671-2025-29-2-154-165
26. Аравинд М. Аномальная доходность торгуемых золотых ETF в условиях кризиса: оценка контр-стратегий против стратегий следования за трендом. *Финансы: теория и практика*. 2024;28(6):69-79. DOI: 10.26794/2587-5671-2024-28-6-69-79
Aravind M. Abnormal return of NSE traded gold ETFs in crisis settings: An appraisal of contrarian versus momentum strategies. *Finance: Theory and Practice*. 2024;28(6):69-79. DOI: 10.26794/2587-5671-2024-28-6-69-79
27. Varshini A., Kayal P., Maiti M. How good are different machine and deep learning models in forecasting the future price of metals? Full sample versus sub-sample. *Resources Policy*. 2024;92:105040. DOI: 10.1016/j.resourpol.2024.105040
28. Liu T., Zheng Z. Negotiation assistant bot of pricing prediction based on machine learning. *International Journal of Intelligence Science*. 2020;10(2):9-21. DOI: 10.4236/ijis.2020.102002
29. Sarangi P.K., Verma R., Inder S., Mittal N. Machine learning based hybrid model for gold price prediction in India. In: 2021 9th Int. conf. on reliability, Infocom technologies and optimization (trends and future directions). (ICRITO). (Noida, September 03–04, 2021). New York, NY: IEEE; 2021:1-5. DOI: 10.1109/icrito51393.2021.9596391
30. Oztoprak S., Orman Z. Precious metal prediction by using XAI in the perspective of digital transformation. In: Sandhu K., ed. *Emerging challenges, solutions, and best practices for digital enterprise transformation*. Hershey, PA: IGI Global; 2021:284-298. DOI: 10.4018/978-1-7998-8587-0.ch015

31. Kangalli Uyar S. G., Uyar U., Balkan E. Fundamental predictors of price bubbles in precious metals: A machine learning analysis. *Mineral Economics*. 2024;37(1):65-87. DOI: 10.1007/s13563-023-00404-z
32. Alharbi M.H. Applying machine learning techniques to analyze and explore precious metals. *Technology and Investment*. 2024;15(4):183-197. DOI: 10.4236/ti.2024.154011
33. Yuandong S., Khaskheli A., Raza S.A., Yousufi S. Q. How COVID-19 influences prices of oil and precious metals: Comparison between data extracted from online searching trends and actual events. *Resources Policy*. 2022;78:102916. DOI: 10.1016/j.resourpol.2022.102916
34. Караев А.К., Сидин Е.Г., Гueva Л.Х. Нелинейная динамика между ценой на золото и индексом доллара США (2020-2025 гг.). *Экономическое развитие России*. 2025;32(10):257-262.
Karaev A. K., Sidin Ye.G., Gueva L. Kh. Nonlinear dynamics between the price of gold and the US dollar index (2020-2025). *Ekonomicheskoe razvitie Rossii = Russian Economic Development*. 2025;32(10):257-262. (In Russ.).
35. Караев А.К., Понкратов В.В. Нелинейная динамика взаимосвязи между ценой на золото и индексом доллара США. *Менеджмент и бизнес-администрирование*. 2025;(3):104-112. DOI: 10.33983/2075-1826-2025-3-104-112
Karaev A. K., Ponkratov V. V. Nonlinear dynamics of the relationship between the price of gold and the US dollar index. *Menedzhment i biznes-administrirovanie = Management and Business Administration*. 2025;(3):104-112. (In Russ.). DOI: 10.33983/2075-1826-2025-3-104-112
36. Колмогоров А.Н. О представлении непрерывных функций многих переменных в виде суперпозиций непрерывных функций меньшего числа переменных. *Доклады Академии наук СССР*. 1956;108(2):179-182.
Kolmogorov A.N. On the representation of continuous functions of several variables as superpositions of continuous functions of fewer variables. *Doklady Akademii nauk SSSR = Proceedings of the USSR Academy of Sciences*. 1956;108(2):179-182. (In Russ.).
37. Колмогоров А.Н. О представлении непрерывных функций многих переменных суперпозицией непрерывных функций одного переменного и сложением. *Доклады Академии наук СССР*. 1957;114(5):953-956.
Kolmogorov A.N. On the representation of continuous functions of several variables by superposition of continuous functions of one variable and addition. *Doklady Akademii nauk SSSR = Proceedings of the USSR Academy of Sciences*. 1957;114(5):953-956. (In Russ.).
38. Liu Z., Wang Y., Vaidya S., et al. KAN: Kolmogorov-Arnold networks. 2025. DOI: 10.48550/arXiv.2404.19756
39. Cho S.-Y., Lee S., Kim H.-G. Forecasting VIX using interpretable Kolmogorov-Arnold networks. *Expert Systems with Applications*. 2025;294:128781. DOI: 10.1016/j.eswa.2025.128781
40. Hafver A. Kolmogorov-Arnold networks (KANs) in Wolfram language. Wolfram Community. Aug. 23, 2024. URL: <https://community.wolfram.com/groups/-/m/t/3254225>
41. Nagpal S. Cryptocurrency price prediction with recurrent neural networks. Wolfram Community. 2022. URL: <https://community.wolfram.com/groups/-/m/t/2443748>
42. Puoti F., Pittorino F., Roveri M. Quantifying cryptocurrency unpredictability: A comprehensive study of complexity and forecasting. In: *AIML Systems'24: Proc. 4th Int. conf. on AI-ML systems*. New York, NY: Association for Computing Machinery; 2025:1-8. DOI: 10.1145/3703412.3703420
43. Liu Z., Ma P., Wang Y., Matusik W., Tegmark M. Kan 2.0: Kolmogorov-Arnold networks meet science. 2024. DOI: 10.48550/arXiv.2408.10205
44. Ning L., Dai Z., Fan W., et al. Joint universal adversarial perturbations with interpretations. 2024. DOI: 10.48550/arXiv.2408.01715
45. Сотников Д.С., Журавлева О.В., Варвус С.А., Бueвич А.П. Роль золота в современной экономике. *Финансы: теория и практика*. 2025;29(2):238-250. DOI: 10.26794/2587-5671-2025-29-2-238-250
Sotnikov D.S., Zhuravleva O.V., Varvus S.A., Buevich A.P. The role of gold in the modern economy. *Finance: Theory and Practice*. 2025;29(2):238-250. DOI: 10.26794/2587-5671-2025-29-2-238-250
46. Беленчук С.И., Водянова В.В., Ларионова А.Д., Минченков М.А., Заплетин М.П. Манипулирование ценой на золото: влияние на международную валютную систему. *Финансы: теория и практика*. 2025;29(6):227-242. DOI: 10.26794/2587-5671-2025-29-6-227-242
Belenchuk S.I., Vodionova V.V., Larionova A.D., Minchenkov M.A., Zapletin M.P. Gold price manipulation: Impact on the international monetary system. *Finance: Theory and Practice*. 2025;29(6):227-242. DOI: 10.26794/2587-5671-2025-29-6-227-242

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS



Елена Федоровна Киреева — доктор экономических наук, профессор, заместитель директора Института исследований социально-экономической трансформации и финансовой политики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Elena F. Kireeva — Dr. Sci. (Econ.), Prof., Deputy Director of the Institute for Research on Socio-Economic Transformation and Financial Policy, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0003-2917-7347>

efkireeva@fa.ru



Алан Канаматович Караев — доктор технических наук, профессор, главный научный сотрудник Института исследований социально-экономической трансформации и финансовой политики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Alan K. Karaev — Dr. Sci. (Econ.), Prof., Chief Research Fellow at the Institute for Research on Socioeconomic Transformation and Financial Policy, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0002-5120-7816>

akkaraev@fa.ru



Вадим Витальевич Понкратов — кандидат экономических наук, директор Института исследований социально-экономической трансформации и финансовой политики, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация

Vadim V. Ponkratov — Cand. Sci. (Econ.), Director of the Institute for Research on Socio-Economic Transformation and Financial Policy, Financial University under the Government of the Russian Federation, Moscow, Russian Federation

<https://orcid.org/0000-0001-7706-5011>

Автор для корреспонденции / Corresponding author:

vponkratov@fa.ru

Заявленный вклад авторов:

Е.Ф. Киреева — разработка концепции статьи, написание аннотации и введения, интерпретация результатов.

А.К. Караев — проведение расчетов моделей и их настройка, формулировка выводов в заключения исследования.

В.В. Понкратов — сбор данных и анализ научных исследований по прогнозированию цен на драгоценные металлы, описание модели и проведенных экспериментов, предобработка и постобработка данных.

Authors' declared contribution:

E.F. Kireeva — developed the article concept, wrote the abstract and introduction, and interpreted the results.

A.K. Karaev — conducted model calculations and configured them, and formulated the conclusions.

V.V. Ponkratov — collected data and analyzed scientific research on precious metal price forecasting, described the model and experiments, and performed pre-processing and post-processing of the data.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила в редакцию 03.03.2026; после рецензирования 29.04.2026; принята к публикации 22.05.2026.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 03.03.2026; revised on 29.04.2026 and accepted for publication on 22.05.2026.

The authors read and approved the final version of the manuscript.

Переводчик Н.И. Соколова