

Научная статья

УДК 336.767.2

DOI: <https://doi.org/10.18721/JE.18211>

EDN: <https://elibrary/ZMOFVE>



КОМПЛЕКСНЫЙ ПОДХОД К ОПТИМИЗАЦИИ ИНВЕСТИЦИОННОГО ПОРТФЕЛЯ НА ОСНОВЕ СОВРЕМЕННЫХ МЕТОДОВ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ

Б.А. Шканов  

Институт экономической политики им. Е.Т. Гайдара,
Москва, Российская Федерация

 bulat.shkanov@mail.ru

Аннотация. В данной статье представлен интегрированный подход к формированию инвестиционного портфеля, сочетающий современные методы прогнозирования временных рядов и гибкую настройку оптимизации инвестиционного портфеля. В условиях высокой волатильности рынка цифровых активов традиционные модели, такие как Марковица и CAPM, без точных прогнозов доходности теряют эффективность, поскольку не учитывают динамически изменяющиеся рыночные условия. В данной работе предложен подход, включающий адаптивный выбор моделей прогнозирования для каждого актива и оптимизацию весов портфеля на основе прогнозных данных. Для прогнозирования цен активов используются модели ARIMA, Chronos Forecasting, GMDH и LSTM, что позволяет учитывать различные аспекты рыночной динамики. На основе прогнозов рассчитывается ковариационная матрица доходностей и производится оптимизация портфеля с учетом различных стратегий: разрешение коротких позиций, минимизация риска, достижение заданного уровня доходности. Данный подход тестировался на данных из библиотеки ufinance с различными конфигурациями параметров, включая число активов, горизонт прогнозирования и способы масштабирования данных. Результаты экспериментов показывают, что предложенный подход обеспечивает среднюю фактическую доходность портфеля на уровне 55,2%, а доля портфелей с положительной доходностью достигает 83,3%. Использование медианы в качестве стратегии масштабирования увеличивает среднюю доходность до 66,9% при 92,6% успешных портфелей. Данный подход представляет собой инструмент для инвесторов, который позволяет адаптировать стратегии к изменяющимся рыночным условиям и повышать эффективность управления портфелем цифровых активов. Кроме того, предложенный подход демонстрирует высокий уровень гибкости благодаря возможности настройки различных параметров оптимизации. Например, варьирование горизонта прогнозирования позволяет учитывать краткосрочные и долгосрочные тренды рынка, а выбор стратегии масштабирования влияет на точность предсказаний. Оптимизация портфеля выполняется с учетом различных метрик, что делает данный подход применимым как для консервативных, так и для агрессивных инвестиционных стратегий. Дальнейшие исследования могут включать расширение набора прогнозных моделей, интеграцию альтернативных стратегий оптимизации, а также применение предложенного подхода к традиционным финансовым рынкам. Это позволит повысить точность прогнозирования и эффективность управления инвестициями в условиях высокой неопределенности и волатильности цифровых активов.

Ключевые слова: оптимизация инвестиционного портфеля, машинное обучение, прогнозирование доходности, прогнозирование цен, временные ряды

Для цитирования: Шканов Б.А. (2025) Комплексный подход к оптимизации инвестиционного портфеля на основе современных методов математического моделирования. П-Economy, 18 (2), 179–201. DOI: <https://doi.org/10.18721/JE.18211>



COMPREHENSIVE APPROACH TO PORTFOLIO OPTIMIZATION BASED ON MODERN MATHEMATICAL MODELING METHODS

B.A. Shkanov  

Gaidar Institute for Economic Policy, Moscow, Russian Federation

 bulat.shkanov@mail.ru

Abstract. In this study, an integrated approach to portfolio optimization is presented, combining modern time series forecasting methods and flexible settings for portfolio optimization. In conditions of high volatility in the digital asset market, traditional models such as Markowitz and CAPM lose their effectiveness without accurate return forecasts, as they do not account for dynamically changing market conditions. In this work, an approach is proposed that includes the adaptive selection of forecasting models for each asset and the optimization of portfolio weights based on forecast data. For asset price forecasting, ARIMA, Chronos Forecasting, GMDH, and LSTM models are employed, which allows various aspects of market dynamics to be taken into account. Based on the forecasts, a covariance matrix of returns is calculated and portfolio optimization is performed considering different strategies: allowing short positions, risk minimization, and achieving a predetermined level of return. The approach was tested on data from yfinance with various parameter configurations, including the number of assets, forecast horizon, and data scaling approaches. The experimental results show that the proposed approach yields an average realized portfolio return of 55.2%, with the proportion of portfolios achieving positive returns reaching 83.3%. Using the median as the scaling strategy increases the average return to 66.9%, with 92.6% of the portfolios being successful. This approach serves as a tool for investors, allowing strategies to be adapted to changing market conditions and enhancing the efficiency of digital asset portfolio management. Furthermore, the proposed approach demonstrates a high degree of flexibility due to the ability to adjust various optimization parameters. For example, varying the forecast horizon allows both short-term and long-term market trends to be taken into account, while the choice of scaling strategy influences prediction accuracy. Portfolio optimization is carried out considering various metrics, making the approach applicable to both conservative and aggressive investment strategies. Further research may include expanding the set of forecasting models, integrating alternative optimization strategies, and applying the proposed approach to traditional financial markets. This would enhance forecasting accuracy and the effectiveness of investment management under conditions of high uncertainty and volatility in digital assets.

Keywords: investment portfolio optimization, machine learning, returns prediction, price prediction, time series

Citation: Shkanov B.A. (2025) A comprehensive approach to portfolio optimization based on modern mathematical modeling methods. *П-Economy*, 18 (2), 179–201. DOI: <https://doi.org/10.18721/JE.18211>

Введение

В условиях высоковолатильного и непредсказуемого рынка криптовалют традиционные портфельные модели (например, модель Марковица) с их допущениями о том, что доходность активов в прошлом останется прежней в будущем, зачастую теряют эффективность. Одновременно достижения машинного обучения и прогнозирования временных рядов открывают пути к более точной оценке рыночной динамики и рисков.

Обзор литературы показал, что современные подходы формирования инвестиционного портфеля в случае использования прогнозов динамики цифровых активов сталкиваются со следующими ограничениями:

- предлагается использовать только один подход прогнозирования доходности для различных активов;



- оптимизация портфеля не предоставляет гибкости (например, нет возможности настроить горизонт инвестирования).

Для решения указанных ограничений в настоящей работе предлагается комплексный подход, который, во-первых, системно подбирает наиболее точные модели прогнозирования для каждого криптоактива (ARIMA Канова–Хансена, GMDH, LSTM, Chronos Forecasting от Amazon Science), а во-вторых, связывает результаты этих прогнозов с гибкими подходами оптимизации портфеля. Проведенные эксперименты подтверждают устойчивость и положительную доходность портфелей, сформированных предложенным подходом, даже в условиях существенной рыночной неопределенности, что подчеркивает ее практическую значимость для инвесторов и исследователей.

Обзор литературы

Обзор литературы разделен на три части. В первой – обзор подходов формирования инвестиционного портфеля, во второй – обзор факторов ценообразования криптовалют, в третьей – обзор современных подходов использования методов машинного обучения для формирования инвестиционного портфеля.

Формирование инвестиционного портфеля

Научно-практические подходы к управлению финансами выработали обширный набор методик оптимизации инвестиционного портфеля, который охватывает широкий круг задач – от увеличения доходности и снижения рисков до поиска оптимального соотношения между ними.

1. Теории рационального поведения инвесторов. К данному направлению относят классический подход к построению оптимального портфеля, разработанный Г. Марковицем [1], а также модель CAPM [2] и другие схожие концепции. Они исходят из предположения, что инвесторы действуют рационально, опираясь на имеющуюся рыночную информацию и свои предпочтения в отношении риска и доходности, чтобы найти оптимальное распределение активов.

2. Поведенческие теории. В этих работах акцент смещается на нерациональные аспекты инвестиционных решений: эмоции, психологические и поведенческие искажения. Подобные теории помогают выявлять рыночные аномалии и случаи переоценки стоимости активов, объясняя их особенностями поведения людей, а не только классической логикой.

3. Факторные модели и арбитражная теория ценообразования (АРТ) [3]. Главное внимание в этих концепциях уделяется факторам риска, которые влияют на доходность активов. Факторные модели рассматривают широкий спектр рыночных показателей (например, стоимость капитала, размеры компании, цену акций), а АРТ утверждает, что стоимость каждого актива должна отражать ожидаемую доходность с учетом определенных факторов риска.

Несмотря на то, что уже сформировался обширный перечень способов оптимизации инвестиционного портфеля, актуальность разработки новых подходов обусловлена стремительной динамикой финансовых рынков, сложными взаимосвязями между их участниками, появлением новых типов активов и цифровых инструментов, а также необходимостью эффективной интеграции современных технологий.

Был проведен сравнительный анализ наиболее известных способов оптимизации инвестиционного портфеля:

- Метод Марковица (1952 г.). Предлагает искать соотношение активов, обеспечивающее максимальную доходность при фиксированном уровне риска или минимизацию риска при заданной доходности [1].

- Метод Роя–Шарпа (Sharpe's Single Index Model). Разработан У. Шарпом и рассматривает упрощенную схему оптимизации, учитывающую систематический риск каждого актива через один общий фактор риска (часто рыночный индекс) [3].

- КАПМ-модель (Capital Asset Pricing Model). Учитывает систематический риск актива для расчета его ожидаемой доходности. Применяется при поиске баланса между безрисковыми и рискованными инструментами в структуре портфеля [2].
- Метод Линдера (Linder's Model). Ориентирован на подбор оптимального соотношения между облигациями и акциями с учетом их взаимной корреляции, а также связи доходности с риском [24].
- Методы на базе квадратичного программирования. Широко используются в практике управления портфелями, решая задачу оптимизации через квадратичную целевую функцию и линейные ограничения [24].
- Метод Брутто (Brinson Model). Сосредотачивается на активном управлении, оценивая вклад каждого актива в итоговую доходность всего портфеля [24].
- Метод Блэка–Литтермана. Разработан Ф. Блэком и Р. Литтерманом в 1990 г. на базе комбинации идей Марковица и оценки систематического риска; позволяет адаптировать структуру портфеля под актуальные рыночные условия [24].
- Метод Дженкинса. Базируется на принципах динамического управления, при котором вес каждого актива в портфеле корректируется в ответ на изменения рыночной конъюнктуры [32].
- Генетические алгоритмы. Реализуют эволюционный подход к оптимизации портфеля, «имитируя» естественный процесс мутаций и отбора [27].
- Алгоритмические методы. Применяют разнообразные оптимизационные алгоритмы – от глобального поиска решений до эволюционных методов и машинного обучения [3].
- Метод экстремальных квантилей (Extreme Quantile Optimization). Направлен на учет критических сценариев и минимизацию потерь в подобных условиях. Вариацией данной методики считается «Минимакс» (Minimax Method), который стремится сократить максимальные убытки и свести к минимуму вероятность экстремальных потерь [23].

Факторы ценообразования криптовалют

Для того чтобы использовать прогнозы динамики криптовалют, необходимо определить значимые факторы ценообразования криптовалют – признаки, которые будут использоваться для прогнозирования динамики.

При анализе ценообразования криптовалют традиционно выделяют пять групп факторов: фундаментальные, макроэкономические, финансовые, поведенческие и инфраструктурные [4–6]. В работе [7] цены определяются сочетанием фундаментальных факторов – технологического прогресса, распространения криптовалют как платежного средства и изменений в регулировании – и спекулятивных компонентов, связанных с рыночными настроениями и ожиданиями инвесторов. Эконометрические модели демонстрируют, что технологические инновации и регулятивные изменения способствуют росту цен, а спекулятивные операции вызывают краткосрочную волатильность, что подтверждают исследования [8–10].

Систематический обзор в [11] подчеркивает влияние рыночных условий, макроэкономических показателей, социальных сетей и онлайн-активности на стоимость криптовалют, при этом биткойн остается наиболее изученным объектом (например, через анализ поисковых запросов и упоминаний в соцсетях) с рекомендацией расширить исследования на Dogecoin и Litecoin. Эти выводы согласуются с данными из [12, 13].

Ликвидность и объем торгов, как показано в [14, 15], существенно влияют на волатильность и реакцию рынка. Исследование [16] рассматривает ценообразование опционов (индекс CRIX и биткойн), где ключевыми факторами являются волатильность базового актива, рыночные ожидания и ликвидность, что подтверждено работой [17]. Рынки опционов способны усиливать волатильность базовых активов.

Shen и др. [18–20] эмпирически анализируют влияние поведенческих финансов, макроэкономических условий и рыночных трендов на краткосрочные и долгосрочные изменения цен.



Инфраструктурные факторы – сложность майнинга, его тип и хешрейт – также играют важную роль: увеличение сложности требует большей вычислительной мощности и инвестиций в оборудование, а халвинг биткойна в апреле 2024 года заметно повлиял на его стоимость и рынок в целом. Наконец, авторы [21, 22] демонстрируют, что концентрация майнинговых пулов и высокие затраты на энергию приводят к централизации, дефициту и повышенной волатильности цен.

С теоретической точки зрения данные факторы очень важны в прогнозировании доходности, однако в настоящей работе рассматриваются прогнозы только на исторических данных без привлечения внешней информации. Причина состоит в неполноте значений параметров, отражающих внешние факторы, и их несогласованности во времени с динамикой значений криптовалют. В настоящей работе полагается, что при большом объеме данных – как числа криптовалют, так и времени их наблюдения – эти факторы вполне проявятся в данных наблюдений.

Использование машинного обучения для формирования инвестиционного портфеля

Несмотря на обилие исследований, посвященных интеграции методов машинного обучения и оптимизационных алгоритмов в формировании инвестиционных портфелей, значительная часть работ лишь декларирует превосходство новых методик, при этом оставляя большое пространство для добавления гибкости.

Как правило, модели машинного обучения используются на этапе прогнозирования, а далее решается стандартная задача оптимизации: максимизация ожидаемой доходности при заданном риске либо максимизация доходности, либо минимизация риска при ограничениях на доходность. Классическая постановка – задача Марковица [1], где вектор ожидаемых доходностей заменяется на прогнозный, полученный от модели машинного обучения.

Распространенный подход – регулярная перекалибровка портфеля. Например, модель прогнозирует доходности N акций на следующий день/неделю, затем эти прогнозы используются в оптимизационной модели для вычисления долей портфеля. В простейшем случае оптимизация сводится к ранжированию активов: можно инвестировать больше в те, у которых прогноз выше. Так поступали, например, Fischer и Krauss [33], формируя равновзвешенный портфель из топ-10 акций с наибольшей прогнозной вероятностью роста. Более строгий подход – решать задачу:

$$\max_w \frac{w^T \hat{\mu}}{\sqrt{w^T \Sigma w}}, \text{ где } \hat{\mu} \text{ – вектор прогнозов доходности, } \Sigma \text{ – ковариационная матрица (может оце-}$$

ниваться по историческим данным либо также прогнозироваться). Так достигается максимизация ожидаемого коэффициента Шарпа.

Многие работы используют упрощения – например, принимают ковариацию равной исторической (или диагональной для независимых активов), чтобы сосредоточиться на улучшении $\hat{\mu}$. В результате сравнивается эффективность портфелей, построенных на основе прогнозов и на основе исторических средних или наивных стратегий.

Как правило, портфели с прогнозами демонстрируют более высокую доходность по сравнению с равновесным $1/N$ или рыночным индексом. Это отмечается как для традиционных рынков, так и для криптовалют [34]. Однако сама по себе задача оптимизации портфеля может быть усложнена различными ограничениями. В реальных условиях инвестор может накладывать запрет на короткие позиции, требования к диверсификации (не более M активов в портфеле) и т.п. Включение таких ограничений затрудняет аналитическое решение. Например, требование не более M активов делает задачу целочисленной (ограничение на кардинальность портфеля), решение которой требует перебора или специальных эвристик, как, например, было реализовано у Butler и Kwon [35] и у Chang и др. [36].

Многие исследования поэтому либо фиксируют заранее состав портфеля (например, топ-10 прогнозно лучших акций) перед оптимизацией, либо игнорируют ряд ограничений для упрощения. Тем не менее появляются работы, которые интегрируют ограничения непосредственно в

процедуру оптимизации с помощью дифференцируемых суррогатов. Так, Zhang и др. [37] предложили нейросетевой подход, где сеть напрямую выдает веса портфеля, оптимизируя коэффициент Шарпа, и при этом в целевую функцию встроены штрафы за превышение заданного числа активов, лимита на плечо и т.д. Это позволяет учесть ограничения (кардинальность, максимальную позицию на инструмент, использование заемных средств) прямо в обучении модели, чего традиционная двухшаговая схема «прогноз + оптимизация» обычно не делает.

Другая группа подходов – динамическое перераспределение и ребалансировка. Интервал, через который пересматриваются прогнозы и веса портфеля, играет большую роль. Большинство подходов используют фиксированный горизонт прогнозирования (например, дневной) и такую же частоту ребалансировки – это упрощает тестирование стратегии. Например, прогнозы LSTM на 1 день вперед применяются для ежедневного обновления портфеля криптовалют. Такой статический по структуре подход (когда модель и критерии не меняются со временем) не учитывает возможных смен режимов рынка. В последние годы появились методы, добавляющие уровень динамической адаптации. Один из вариантов – предварительно классифицировать состояния рынка и переключать стратегию. Li и др. [38] используют кластеризацию K -средних для идентификации режимов волатильности рынка и Байесовскую модель для прогнозирования переходов между режимами. В зависимости от предсказанного режима меняются и оптимальные веса (например, при высокой волатильности портфель смещается к минимальному риску). Такой режимный или адаптивный подход позволил достичь значительно более высоких показателей доходности портфеля по сравнению со статической стратегией. Другой подход – периодическое переобучение модели по мере поступления новых данных. Wang и др. [39] для крипто-портфеля применили ансамбль стратегий глубокого обучения с подкреплением (reinforcement learning), которое осуществляется через заданные интервалы времени, чтобы учесть нелинейные сдвиги распределения. Они показали, что регулярное обновление параметров модели повышает устойчивость результатов на вневыборочных периодах по сравнению с раз и навсегда обученной моделью. В контексте двухшаговых схем это эквивалентно тому, что модель-прогнозист регулярно дообучается на новых данных, а портфель пересчитывается с новыми прогнозами. В итоге тенденция такова, что динамические модели портфеля (с частой адаптацией к изменению рынка) начинают превосходить традиционные статические решения.

В исследовании Пономаревой и Шорохова [26] для прогнозирования доходностей российских акций была применена рекуррентная нейронная сеть LSTM. Описаны принцип построения оптимального портфеля и способ усовершенствования его точности с помощью модели прогнозирования будущих доходностей акции, основанной на методе машинного обучения. Рассмотрено обучение рекуррентной нейронной сети LSTM, способной вычислять вектор ожидаемых доходностей на следующий торговый день. С использованием полученных данных и подхода построения оптимального портфеля были получены доли, с которыми должны быть взяты активы в портфель, для достижения максимального дохода. Данный подход был применен на данных акций российских компаний и показал приемлемую точность. Однако данный метод не допускает возможности гибко изменять горизонт прогнозирования, динамически изменять состав компаний для анализа, задавать аппетит к доходности и возможность коротких позиций.

Добрина и Чернов [27] предложили объединение классического подхода Марковица с алгоритмами машинного обучения для улучшения оценки ожидаемых доходностей и рисков. В их подходе строится инвестиционный портфель, а затем с помощью моделей машинного обучения прогнозируются его изменения в будущем. Однако стоит обратить внимание на недостаток гибкости данного подхода – построение портфеля и дальнейшее прогнозирование его состояния могут привести к перезапуску оптимизации портфеля при прогнозировании падения его эффективности. Альтернативный подход – прогнозирование цен активов и оптимизация портфеля на каждый шаг инвестирования.



Коновалова и Абузов [28] изучают возможности комбинированного подхода, сочетающего генетические алгоритмы и машинное обучение. Используются нейронная сеть LSTM для построения прогнозов доходностей и генетические алгоритмы для поиска оптимальных весов инвестиционного портфеля. По мнению авторов, генетические алгоритмы добавляют гибкость и адаптивность, однако количественные показатели точности и эффективности нового подхода в исследовании не приводятся.

Zhang, Zohren и Roberts [29] исследуют использование глубокого обучения для оптимизации портфелей с целью максимизации коэффициента Шарпа, исключая традиционное прогнозирование доходностей. В основе подхода лежит применение LSTM для обработки временных рядов данных ETF (акций, облигаций, товаров и индекса волатильности), что снижает сложность выбора активов и повышает диверсификацию. Модель показала превосходные результаты в сравнении с традиционными методами (Марковица, максимальной диверсификации) на данных с 2011 по 2020 год, включая кризис COVID-19, благодаря эффективной переаллокации активов.

Полетаев и Спиридонова [30] предлагают метод уменьшения размерности данных при оптимизации портфеля, основанный на иерархической кластеризации ценных бумаг с использованием коэффициента корреляции Пирсона в качестве меры близости. Авторы исследуют влияние различных параметров кластеризации на качество оптимального решения и демонстрируют, что предложенный подход позволяет сократить вычислительные затраты при незначительном снижении доходности портфеля.

Corsaro и De Simone [31] предлагают усовершенствование классической модели Марковица путем добавления l_1 -регуляризационного члена к целевой функции. Это способствует получению разреженных решений, где капитал распределяется между ограниченным числом активов, что снижает транзакционные издержки и упрощает управление портфелем. Кроме того, l_1 -регуляризация ограничивает объем коротких позиций, что актуально в условиях рыночных ограничений на такие операции. Проведенные численные тесты демонстрируют эффективность предложенного подхода в достижении финансовых целей инвесторов.

Проанализировав литературу, можно выявить ряд общих ограничений и проблем, присущих современным подходам к оптимизации портфеля на базе прогнозов:

1. Недостаточная гибкость по горизонту прогнозирования и инвестирования. Многие исследования фиксируют единый горизонт (например, дневной прогноз и дневную же ребалансировку) и не тестируют работу модели на других интервалах [40]. Модель LSTM, обученная на дневных данных, может не подойти для прогнозов на месяц без переобучения. Это снижает практическую ценность: инвесторы могут иметь разные горизонты инвестирования, и отсутствие адаптивности по времени – минус. Кроме того, инвестиционные стратегии часто требуют согласования прогнозного горизонта с периодом удержания активов, что не всегда учитывается – например, модель может предсказывать недельную доходность, а портфель перестраивается ежемесячно, что приводит к рассинхронизации.

2. Использование только одного семейства моделей. Значительная часть работ фокусируется на одном типе модели (зачастую – деревья решений или только LSTM) и не рассматривает альтернативы. Однако известно, что качество прогнозов сильно зависит от природы данных и актива. В одних случаях лучше работают нелинейные деревья, в других – глубокие сети, в-третьих – даже простые линейные модели. Ограничение подхода одним модельным классом повышает риск, что выбранная модель не улавливает важных особенностей данных. Так, в работе [41] показано, что модель, отлично зарекомендовавшая себя на криптовалютах (рынок с высокой волатильностью), при прямом переносе на рынок акций дала существенно худшие результаты. Это свидетельствует о необходимости более гибкого выбора моделей. К сожалению, в литературе до сих пор редко встречается сравнение нескольких семейств моделей на одной задаче – обычно авторы берут наиболее успешный метод и демонстрируют его преимущество над базовым (ARIMA или $1/N$). Лишь

немногие обзоры (например, Ballings и др. [42], Berat Sezer и др., [43]) систематически сравнивали множество алгоритмов на финансовых данных.

3. Отсутствие адаптивного выбора моделей под каждый актив. Связанное с предыдущим, но более тонкое ограничение – даже если в работе используются, например, несколько моделей, зачастую они применяются универсально ко всем активам портфеля. Между тем разные акции или криптовалюты могут обладать разной динамикой – одна более трендовая, другая более циклическая, третья реагирует на макропоказатели. Идеально было бы для каждого актива (или кластера схожих активов) подбирать наилучшую модель прогноза. В имеющейся литературе такой подход почти не реализован – обычно строится единая модель (например, многомерная LSTM сразу на все активы либо отдельная модель одного типа на каждый актив). Адаптивный подбор модели под актив мог бы повысить точность – например, использовать ARIMA там, где ряд близок к стационарному, и использовать нейросеть там, где наблюдаются сложные нелинейности. Пока что эта идея больше предложена теоретически, чем реализована на практике. Некоторые авторы предлагают ансамбли моделей именно с расчетом на диверсификацию по активам, но прямой адаптации «один актив – одна модель» не встречается. Причины включают усложнение вычислений (нужно обучать множество моделей) и риск переобучения при малых данных по отдельным инструментам.

4. Ограничения в параметризации портфеля. Многие научные работы накладывают упрощающие допущения на задачу оптимизации, которые снижают гибкость стратегии. Например, часто запрещаются короткие позиции (отрицательные веса) – портфель получается только длинным, хотя в реальности хедж-фонды, например, активно используют короткие позиции. Это делается либо для удобства (исключить перенос риска через короткие продажи), либо из-за ограничений данных (не все акции можно «шортить»). Еще одно ограничение – фиксированное число активов в портфеле: чтобы упростить задачу, исследователи нередко заранее ограничивают, что будут инвестировать, например, в топ-10 или топ-20 акций по прогнозу [36]. Это обеспечивает некую диверсификацию и снижает размерность задачи, но опять же убирает из рассмотрения целый пласт возможных оптимальных решений (а именно различные комбинации большего числа активов с малыми долями). Также редко учитываются дополнительные цели и параметры, кроме доходности и риска. Например, у реального инвестора могут быть ограничения на отраслевую структуру, желаемый уровень прозрачности портфеля, лимиты на оборот (turnover) при ребалансировке и т.п. В академических работах такие детали часто опускаются – оптимизируются либо только доходность, либо максимум доходности при заданном риске. В результате метод оказывается менее пригоден к непосредственному применению, где таких ограничений множество. Отдельно стоит упомянуть, что параметры оптимизации зачастую фиксированы – например, уровень допустимого риска или целевой уровень по доходности берутся константой. В реальности их тоже можно было бы адаптировать под условия (скажем, повышать допустимый риск в благоприятных режимах рынка), но в рассматриваемых подходах это почти не встречается.

5. Отсутствие динамического изменения состава портфеля. Хотя формально все рассмотренные схемы предполагают какую-то периодическую ребалансировку, во многих исследованиях портфель формируется в начале тестового периода, и дальше его состав либо редко пересматривается, либо меняется незначительно. Например, если модель прогнозирует, что одни и те же пять акций стабильно в лидерах, портфель будет состоять из них на всем протяжении. Динамическое перераспределение – сильная сторона современных алгоритмов (особенно обучение с подкреплением), но в классических «прогноз + оптимизация» обычно реализуется как регулярная (например, ежемесячная) оптимизация заново. Это динамика, но не зависящая от состояния рынка (а только от календаря). Ограничение проявляется в том, что состав активов часто остается статичным – к примеру, ряд работ по криптовалютам фокусируется на распределении между несколькими крупнейшими монетами и не рассматривает возможность в течение процесса выйти



из одних альткоинов и войти в другие [41]. Иными словами, состав активов остается неизменным, меняются лишь веса. В реальности же инвестор по мере изменения прогнозов мог бы исключать одни инструменты и добавлять новые. Наличие транзакционных издержек и ограничений ликвидности, конечно, сдерживает частое перераспределение, но в научных работах эти факторы нередко вообще не моделируются. Поэтому отсутствие механизмов адаптивного изменения набора активов – заметный пробел. Некоторые свежие исследования предлагают решения – например, введение штрафа за изменение весов (чтобы контролировать оборот) или комбинирование прогнозной модели с классификатором, решающим, какие активы включать (feature selection).

Вышеперечисленные ограничения можно сгруппировать следующим образом:

- Данные подходы не допускают возможности гибко изменять горизонт инвестирования и прогнозирования, адаптивно выбирать наилучшие модели машинного обучения для каждого актива, динамически изменять состав активов для формирования портфеля, задавать аппетит к доходности и возможность коротких позиций.
- В подходах, использующих модели машинного обучения для прогнозирования будущих доходностей активов, в основном используется только одно семейство алгоритмов машинного обучения (часто LSTM или ARIMA), однако качество построенной модели нередко зависит от данных (временного ряда) и выбранного актива. Существует множество методов машинного обучения, успешно применяемых для прогнозирования динамики цифровых активов. Однако успешность того или иного подхода и точность прогноза зависят от данных. Нет универсального метода прогнозирования. Один и тот же метод прогнозирования может хорошо работать на данных одного актива и плохо на данных другого.

Цель, задачи и объект исследования

На основе анализа литературы и выявленных ограничений существующих подходов формирования инвестиционных портфелей с помощью машинного обучения в рамках данного исследования были поставлены следующие цель и задачи. Целью данного исследования являются разработка и апробация комплексного подхода оптимизации криптовалютного портфеля, основанного на интеграции современных методов машинного обучения. Объектом исследования являются процесс оптимизации портфеля криптовалют, включающий прогнозирование их доходности, а также применение автоматизированных систем управления инвестиционными решениями в условиях рыночной неопределенности. Исходя из данной цели и ограничений существующих подходов, в рамках исследования были поставлены следующие задачи:

- на основе обзора литературы выбрать современные методы машинного обучения для прогнозирования цен криптовалют;
- на основе прогнозов цен данными методами разработать подход оптимизации портфеля криптовалют, который предоставляет гибкость в выборке параметров данной оптимизации (горизонт инвестирования, требования к доходности, разрешение коротких позиций, количество активов);
- провести эксперименты и оценку качества оптимизации портфеля с помощью выбранной архитектуры.

Методы и материалы

Сбор и предобработка данных

Первая стадия работы включает получение данных о котировках ведущих криптовалют на основе API CoinGecko. В качестве входящих данных используется число – количество активов-кандидатов для сбора портфеля. Отбираются криптоактивы, отсортированные по рыночной капитализации от наибольшей на день анализа до наименьшей, после чего их тикеры валидируются для использования в библиотеке yfinance (с серверов Yahoo Finance). Загруженные временные

ряды очищаются от пропущенных значений, нормализуются и приводятся к единому формату временной дискретизации. Для масштабирования признаков используются различные стратегии с учетом специфики криптовалютных данных.

Второй параметр входных данных — горизонт прогнозирования — количество дней, на который планируется собрать портфель.

Третий параметр входных данных — стратегия масштабирования. Поскольку шаг временного ряда для скачивания данных из библиотеки `ufinance` всегда одинаковый — 1 день, при горизонте прогнозирования более 1 дня (например, 7 дней) необходимо агрегировать данные для данного горизонта прогнозирования. В данном подходе реализованы три стратегии такой агрегации:

- Усреднение. В качестве цены для каждого шага с заданным интервалом (горизонтом прогнозирования) принимается среднее арифметическое по всем дням, входящим в данный интервал.
- Медиана. В качестве цены для каждого шага с заданным интервалом (горизонтом прогнозирования) принимается медиана по всем дням, входящим в данный интервал.
- Прореживание. В качестве цены для каждого шага с заданным интервалом (горизонтом прогнозирования) принимается последняя цена в заданном интервале. Остальные дни не учитываются.

Построение прогнозов

В рамках данного исследования было принято использовать все методы прогнозирования цен, зарекомендовавшие себя в обзоре литературы. Для прогнозирования будущих цен криптоактивов применяются четыре основных подхода:

1. ARIMA [32]. Классическая модель линейного прогнозирования, хорошо учитывающая сезонность и тенденции в стационарных временных рядах. Применяется алгоритм Канова–Хансена [32] для оптимизации гиперпараметров модели в зависимости от прохождения теста на стационарность (расширенный тест Дики–Фуллера [32]) и критерия качества модели (критерий Акаике [32]).

2. Chronos Forecasting [44]. Библиотека глубокого обучения от Amazon Science, позволяющая строить масштабируемые и точные прогнозы для сложных временных рядов на основе архитектуры на базе трансформера T5 от команды Google [45]. С данной моделью используется способ обучения внутри контекста.

3. GMDH. Самоорганизующаяся модель группового учета аргументов, оптимизирующая внутренний и внешний критерий для достижения оптимальной структуры¹.

4. LSTM. Рекуррентная нейронная сеть, оптимизированная для работы с последовательными данными, способная запоминать долгосрочные зависимости и корректировать прогноз на основе новых трендов [46].

Предложенный в данной статье подход является адаптивным к каждому набору данных (индивидуально для каждого набора данных определяется наиболее точная модель прогнозирования).

Процесс построения прогнозов включает несколько этапов: загрузку ценовых данных с дневной частотой через библиотеку `ufinance`; группировку данных в соответствии с выбранным горизонтом инвестирования (усреднение, медиану или прореживание); разбиение данных на тренировочную и тестовую подвыборки, стандартизацию данных для устранения масштабных различий между активами; обучение каждой из четырех моделей на тренировочной выборке. Все модели обучаются на одинаковом количестве признаков (10 признаков); вычисление метрики MAPE на тестовом срезе:

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

¹ Ivakhnenko A.G. (1968) The Group Method of Data Handling – A Rival of the Method of Stochastic Approximation. *Soviet Automatic Control*, 1 (3), 43–55.



где n – количество наблюдений, y_i – фактическое значение цены, \hat{y}_i – предсказанное значение цены.

Следующий этап – выбор лучшей модели для каждого актива на основе минимального значения MAPE.

Оптимизация портфеля

После отбора наилучших моделей для каждой криптовалюты производится объединение прогнозных и фактических цен активов в единые наборы данных:

- тренировочный набор данных прогнозных цен активов;
- валидационный набор данных прогнозных цен активов;
- тренировочный набор данных фактических цен активов;
- валидационный набор данных фактических цен активов.

Объединение производится способом INNER JOIN – сохранением только тех строк, для которых данные присутствуют одновременно по каждой из криптовалют, исключая возможные несоответствия или пропуски, что необходимо для расчета ковариационной матрицы и построения портфеля по комбинации активов. Такой подход обеспечивает согласованность наборов данных и упрощает последующую аналитическую обработку.

На тренировочном наборе прогнозных цен рассчитывается ковариационная матрица доходностей. Валидационная выборка делится на две равные части: первая используется для определения оптимальных весов портфеля, вторая – для контроля и оценки качества построенного портфеля.

Расчет метрик портфеля

Для оптимизации портфеля и расчета метрик необходимы прогнозируемые (ожидаемые) и фактические (реализованные) доходности:

$$\text{прогнозируемая доходность актива } \hat{\mu}_{t+1} = \frac{\text{predicted price}_{t+1} - \text{actual price}_t}{\text{actual price}_t};$$

$$\text{фактическая доходность актива } \mu_{t+1} = \frac{\text{actual price}_{t+1} - \text{actual price}_t}{\text{actual price}_t},$$

где $\text{predicted price}_{t+1}$ – прогнозируемая цена криптоактива на горизонт прогнозирования ($t + 1$), $\text{actual price}_{t+1}$ – фактическая цена криптоактива на горизонт прогнозирования ($t + 1$), actual price_t – фактическая цена криптоактива на момент формирования портфеля (t).

Построение ковариационной матрицы. Для обеспечения положительной определенности ковариационной матрицы выполняется пошаговый отбор (forward selection) наиболее значимых признаков. Затем на тренировочном отрезке рассчитывается ковариационная матрица доходностей:

$$\Sigma = (R - \bar{R})(R - \bar{R})^T,$$

где R – матрица доходностей активов на тренировочной выборке.

В первой части реализованного подхода определяется функция, которая на вход принимает вектор весов w , вектор ожидаемых/фактических доходностей $\hat{\mu} / \mu$ и ковариационную матрицу Σ . Результатом ее работы являются две ключевые метрики портфеля:

1) ожидаемая доходность портфеля:

а) ожидаемая прогнозируемая доходность портфеля (в режиме расчета метрик по прогнозным доходностям):

$$\hat{r}_i = w^T \hat{\mu},$$

где $w = (w_1, w_2, \dots, w_N)$ – доли капитала, распределенные между N активами, а $\hat{\mu} = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_N)$ – вектор ожидаемых доходностей;

б) ожидаемая реализованная доходность портфеля (в режиме расчета метрик по фактическим доходностям):

$$r_i = w^T \mu,$$

где $w = (w_1, w_2, \dots, w_N)$ – доли капитала, распределенные между N активами, а $\mu = (\mu_1, \mu_2, \dots, \mu_N)$ – вектор реализованных доходностей.

2) волатильность (стандартное отклонение доходностей портфеля):

$$\hat{\sigma}_i = \sqrt{w^T \Sigma w},$$

где Σ – ковариационная матрица размерности $N * N$, в элементах которой содержится информация о парных взаимосвязях доходностей активов.

Псевдокод функции для вычисления этих метрик (на примере прогнозных доходностей):

1) вычисляет доходность портфеля $\hat{r}_i = w^T \hat{\mu}$;

2) вычисляет волатильность $\hat{\sigma}_i = \sqrt{w^T \Sigma w}$;

3) возвращает обе эти величины.

Настройка условий оптимизации

Вторая часть реализованного подхода формализует постановку задачи в традиционном виде минимизации риска (волатильности) при условии полного инвестирования $\sqrt{w^T \Sigma w} \rightarrow \min_w$ с основным ограничением $\sum_{i=1}^n w_i = 1$, обеспечивающим, что сумма весов равна 1 (весь капитал инвестирован).

Кроме того, в классической модели Марковица [1] часто рассматривается и дополнительное условие неотрицательности w_i , если не разрешены короткие позиции.

Запрет или разрешение коротких позиций

- Long-only (запрещены короткие позиции): вес $w_i \in [0, 1]$.
- С короткими позициями (short selling): вес w_i допускает отрицательные значения – например, $w_i \in [-1, 1]$.

Фиксация целевой доходности

При необходимости можно добавить еще одно равенство:

$$w^T \mu = target\ return,$$

задавая требуемый уровень ожидаемой доходности портфеля. В таком случае реализованная функция ищет минимальную волатильность при условии, что доходность не ниже заданного уровня.

Решение оптимизационной задачи

Для нахождения оптимального вектора весов w_i применяются стохастический или детерминированный методы. В данном случае используется алгоритм последовательного метода наименьших квадратов, который решает задачу нелинейного программирования с учетом ограничений. Псевдокод функции для оптимизации весов:

- 1) определяет число активов N ;
- 2) формирует набор ограничений:



$$\text{i. } \sum_{i=1}^n w_i = 1;$$

$$\text{ii. } w^T \mu = \textit{target return} \text{ (если } \textit{target return} \text{ задан);}$$

3) устанавливает границы весов ($w_i \in [0, 1]$ либо $w_i \in [-1, 1]$) в зависимости от параметра *allow short*;

4) выбирает начальное приближение в виде равномерного распределения $w_i = \frac{1}{N}$;

5) минимизирует цель: $\sqrt{w^T \Sigma w} \rightarrow \min_w$;

6) возвращаемый результат – вектор w , который соответствует портфелю с глобальным минимумом волатильности при заданных условиях (или портфелю, удовлетворяя дополнительному ограничению на доходность).

Оценка на тестовых данных

Первая половина валидационной выборки выступает для оценки весов и построения портфеля.

Вторая половина валидационного периода выступает в роли тестовой выборки для финальной оценки эффективности портфеля. Сравнительные результаты оцениваются на этом отрезке.

Ниже представлены основные метрики, используемые для оценки качества сформированного портфеля на выборке для построения портфеля и на тестовой выборке.

1. Среднеабсолютная ошибка доходности (Returns MAE). Для измерения точности прогнозов доходности используется следующая метрика, отражающая среднеабсолютную ошибку между прогнозируемой доходностью \hat{r}_t и фактической r_t :

$$MAE = \frac{1}{t} \sum_{i=1}^t |r_i - \hat{r}_i|,$$

где t – количество наблюдений, \hat{r}_t – прогноз доходности в момент времени t , а r_t – реализованная доходность в момент времени t . Чем меньше значение метрики, тем точнее отражаются фактические изменения доходности.

2. Суммарная доходность (Summed Returns). Для полноты анализа рассчитываются суммарные прогнозируемые $\Sigma \hat{r}_t$ и фактические Σr_t доходности за исследуемый период. Сопоставление этих величин дает представление о совокупном уровне дохода в рамках формируемой стратегии.

Все метрики вычисляются на обеих частях валидационной выборки – на подвыборке на оптимизации портфеля и на тестовой подвыборке, что позволяет оценить как процесс оптимизации портфеля, так и его способность к обобщению на новых наиболее свежих данных. Полученные результаты дают всестороннюю характеристику качества прогнозирования и эффективности принятых инвестиционных решений, позволяя своевременно корректировать модельные допущения и стратегию управления портфелем.

Результаты и обсуждение

Настройка экспериментов

Для верификации эффективности предложенного подхода были собраны несколько наборов исторических данных по криптовалютам через API CoinGecko и библиотеку ufinance. Сформированные временные ряды доходностей использовались для обучения и тестирования предложенных моделей. Оценка качества прогнозов осуществлялась по метрике MAPE, затем определялись оптимальные веса криптоактивов в портфеле.

Следующие параметры являются конфигурируемыми для каждого инвестора в зависимости от целей инвестирования:

- *top n* – количество активов для построения портфеля, отсортированные по рыночной капитализации на текущий день от топ-1 до топ- n (например, топ-5);

- *num scale steps* – горизонт инвестирования в днях (например, 7 дней);
- *scaling strategy* – способ масштабирования при горизонте инвестирования в несколько шагов (больше 1) – прогноз средней цены (average), прогноз медианной цены (median), прореживание – прогноз последней цены в конце интервала (undersampling).

Также есть еще два параметра оптимизации портфеля:

- *target return* – требуемый минимальный уровень доходности (например, 10%);
- *allow short* – запрет или допуск коротких позиций (например, True (да)).

В данном исследовании были выбраны различные комбинации данных параметров.

- *top n* – 5, 10, 15, 20, 25, 30;
- *num scale steps* – 7, 10, 30;
- *scaling strategy* – average, median, undersampling;
- *target return* – отсутствует, 10%, 50%;
- *allow short* – True (да), False (нет).

Таким образом, в данном исследовании были проведены эксперименты для каждой комбинации этих параметров – всего 324 эксперимента.

Исходная выборка – все исторические дневные данные цен криптоактивов с начала их размещения на криптобиржах (с 2009 года по день проведения экспериментов – 12 января 2025 года).

Вся выборка поделена на следующие подвыборки:

- тренировочная выборка – выборка для тренировки моделей прогноза цен – первые 70%;
 - вся выборка используется для построения ковариационной матрицы доходностей;
- валидационная выборка – выборка для расчета тестовых метрик качества моделей прогноза цен и выбора наиболее точных моделей – оставшиеся 30%;
 - выборка для оптимизации весов инвестиционного портфеля – первые 50% от вышеуказанных 30%, 15% от исходной выборки;
 - тестовая выборка – выборка для расчета метрик качества оптимизации инвестиционного портфеля – вторые 50% от вышеуказанных 30%, 15% от исходной выборки.

Для теста используются наиболее свежие данные на дату исследования – 12 января 2025 года – данные цен по 11 января 2025 года.

Результаты и анализ

В данной главе приводится анализ данных результатов экспериментов.

Средняя среднеабсолютная ошибка прогноза доходности портфеля на выборке для построения портфеля – 0.058, на выборке для тестирования портфеля – 0.132. Интерпретация данного показателя – в среднем, на тестовой выборке фактическая доходность построенного портфеля отличалась на 13,2% от предсказанной доходности данного портфеля, что является достаточно низким отклонением. Данный показатель на выборке для построения портфеля ожидаемо ниже, но незначительно, что говорит об устойчивости построенных портфелей в течение всего горизонта прогнозирования.

Рассмотрим подробнее тестовую выборку. Основная масса распределения среднеабсолютных ошибок прогнозирования доходностей сформированных портфелей на тестовой выборке близка к 0, среднее – 132, что говорит об устойчивости прогнозов. Далее рассмотрим распределение фактических реализованных доходностей по каждому из 324 экспериментов. Основная масса распределения находится справа от 0, среднее – 0.552. То есть в среднем данный подход формирования портфеля фактически принес дополнительно 55.2% к исходному депозиту. Доля портфелей с положительной фактической доходностью на тестовой выборке – 83.3% (270/324). Посмотрим на сегменты – *top n*, *num scale steps*, *scaling strategy*, *target return*, *allow short*.

Количество активов-кандидатов

Четкой зависимости качества построения портфеля от количества активов-кандидатов не наблюдается: средняя фактическая доходность сформированного портфеля (топ-5 – 0.496, топ-10



– 0.781, топ-15 – 0.408, топ-20 – 0.574, топ-25 – 0.597, топ-30 – 0.458), среднеабсолютная ошибка прогнозной доходности сформированного портфеля (0.05, 0.193, 0.167, 0.105, 0.134, 0.144 соответственно), а также доля сформированных портфелей с положительной доходностью на тестовой выборке (0.833, 0.796, 0.778, 0.852, 0.889, 0.852 соответственно) не изменяются в зависимости от количества активов-кандидатов. Данное наблюдение подчеркивает устойчивость рассматриваемого подхода формирования инвестиционного портфеля. Более тщательный анализ распределения оставляет вывод прежним. Таким образом, данный подход достаточно устойчив к количеству активов кандидатов для формирования портфеля.

Горизонт прогнозирования

Распределение фактических доходностей сформированных портфелей на тестовой выборке имеет похожую форму во всех трех вариантах горизонтов прогнозирования. Однако есть незначительная тенденция к росту фактических доходностей при увеличении горизонта прогнозирования. Среднее арифметическое растет от 0.504 для 7 дней, до 0.557 для 10 дней и для 0.595 на 30 дней (рис. 1).

При этом доля портфелей с положительной фактической доходностью сформированного портфеля на тестовой выборке примерно остается одинаковой (0.853 для 7 дней, 0.824 для 10 дней, 0.824 для 30 дней). Также незначительно растет и среднеабсолютное отклонение прогнозных доходностей от фактических на тестовой выборке (0.081 для 7 дней, 0.117 для 10 дней, 0.199 для 30 дней). Незначительный рост ошибки прогноза и рост фактической доходности обусловлены ростом неопределенности при увеличении горизонта прогнозирования – чем длиннее горизонт прогнозирования, тем выше неопределенность и волатильность.

Режим масштабирования

На рис. 2 представлены распределения фактических доходностей собранных портфелей на тестовой выборке для каждой из стратегий масштабирования. Видно, что среднее арифметическое и медиана примерно похожи (медиана незначительно лучше), однако прореживание значительно уступает остальным.

Данный вывод подтверждается при анализе доли портфелей с положительной доходностью на тестовой выборке – она максимальная у медианы (0.926) и минимальная с большим отрывом у прореживания (0.769). Среднее арифметическое – 0.806. Тот же вывод подтверждает среднеабсолютная ошибка – 0.115 при среднем арифметическом, 0.15 при медиане и выше (0.131) при прореживании. Таким образом, при обучении моделей машинного обучения для формирования инвестиционного портфеля следует избегать прореживание как режим масштабирования.

Целевая доходность

Следует отметить значительную разницу между режимами с заданной целевой доходностью и без нее. Сформированные портфели при заданной целевой доходности являются более агрессивными – фактическая реализованная доходность выше, если портфель сформирован при дополнительном ограничении на целевую доходность (0.766 при целевой доходности 10%, 0.794 при целевой доходности 50%), в отличие от варианта без ограничений на целевую доходность (0.097). Доля портфелей с положительной фактической доходностью сформированного портфеля на тестовой выборке в зависимости от режима целевой доходности: 0.806 без заданной целевой доходности, 0.852 при целевой доходности 10%, 0.843 при целевой доходности 50%. Рост доходности при более агрессивных инвестиционных целях достигается ценой роста волатильности портфеля – среднеабсолютная ошибка прогнозной доходности растет (рис. 3).

Таким образом, более агрессивные конфигурации с заданной целевой доходностью ведут к росту доходности портфеля, вместе с тем растет и риск.

Короткие позиции

Фактическая доходность портфеля при ограничении на короткие позиции незначительно (0.562) выше доходности портфеля с короткими позициями (0.542). Тот же вывод подтверждается

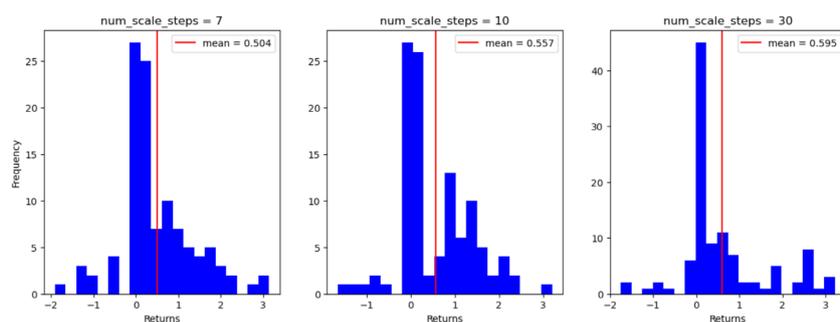


Рис. 1. Распределение фактической доходности сформированного портфеля на тестовой выборке для разных горизонтов прогнозирования
 Fig. 1. Distribution of factual returns of formed portfolios on different forecast horizons

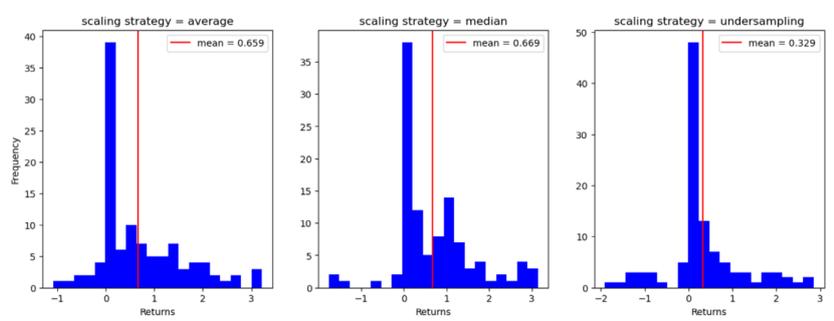


Рис. 2. Распределение фактической доходности сформированного портфеля на тестовой выборке для разных режимов масштабирования
 Fig. 2. Distribution of factual returns of formed portfolios on different scaling approaches

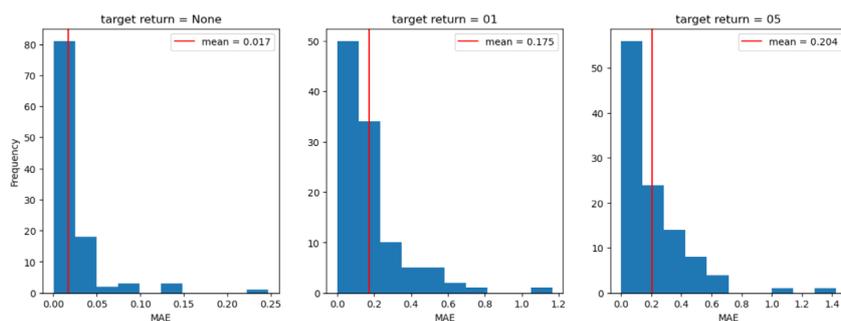


Рис. 3. Распределение среднеабсолютной ошибки прогнозной доходности сформированного портфеля на тестовой выборке для разных режимов целевой доходности
 Fig. 3. Distribution of mean absolute error of forecasted returns of formed portfolios on different target return modes

при анализе доли портфелей с положительной фактической доходностью на тестовой выборке – значительно выше с конфигурациями без коротких продаж: 0.759 без ограничения, 0.907 при ограничении. В конфигурациях с короткими позициями среднеабсолютная ошибка прогнозной доходности портфеля увеличивается более чем в 2 раза (с 0.081 до 0.183) в сравнении с конфигурациями без коротких продаж. Возможная гипотеза – короткие позиции на практике более



быстры в динамике, падения цен обычно более резки, чем их рост, отчего такие позиции и называются «короткими», а позиции на рост — «длинными». Возможно, тренды на падения цен имеют кардинально другую структуру и паттерны поведения, для которых требуется отдельный подход, в связи с чем качество оптимизации портфеля данным подходом не является оптимальным для совместных длинных и коротких позиций. Данную гипотезу следует проверить отдельно. Исследование коротких позиций выходит за рамки данной статьи. Таким образом, добавление возможности коротких продаж, скорее всего, увеличивает неопределенность портфеля, поскольку динамика цен при их падении отличается от динамики цен при растущем рынке, что требует отдельного исследования.

Выводы

Автор статьи представил подход к оптимизации портфеля криптовалют, объединяющий методы прогнозирования временных рядов с гибкими стратегиями оптимизации. Использование моделей ARIMA, Chronos Forecasting, GMDH и LSTM в сочетании с методами минимизации рисков и увеличения доходности позволило построить приемлемые по доходности портфели.

Предложенный подход включает несколько ключевых аспектов, способствующих ее успешной реализации:

1. Адаптивный выбор моделей прогнозирования. Подход предусматривает тестирование нескольких моделей на основе метрики MAPE и выбор наиболее подходящей для каждого актива, что минимизирует ошибки прогноза и повышает точность оценок будущих доходностей.

2. Масштабируемость. Предложенный подход формирования инвестиционного портфеля поддерживает различные горизонты прогнозирования и различное количество активов-кандидатов, позволяя инвесторам адаптировать стратегию к своим индивидуальным потребностям и предпочтениям.

3. Гибкость конфигурации портфеля. Возможность задавать целевые уровни доходности, учитывать ограничение на короткие позиции и варьировать состав активов является универсальным для широкого круга пользователей.

4. Сбалансированность риска и доходности. Экспериментальные результаты демонстрируют, что формирование инвестиционного портфеля предложенным подходом позволяет добиться положительной доходности, сохраняя приемлемый уровень риска даже при агрессивных инвестиционных стратегиях.

Эксперименты, проведенные на реальных данных, подтвердили, что предложенный подход способен генерировать положительные результаты в большинстве конфигураций. Среднеабсолютная ошибка прогнозов доходности составила 13,2% на тестовой выборке, что является приемлемым показателем для рынков с высокой волатильностью. Средняя фактическая доходность портфелей составила 55,2%, при этом доля портфелей с положительной доходностью достигла 83,3%. Если использовать только медиану как режим масштабирования, то средняя фактическая доходность портфелей достигает 66,9% от исходного депозита, а доля портфелей с положительной фактической доходностью достигает 92,6%.

Анализ влияния различных параметров на результаты оптимизации выявил важные закономерности:

- Увеличение горизонта прогнозирования приводит к росту доходности, но также увеличивает неопределенность прогнозов.
- Режимы масштабирования, основанные на усреднении и медианном значении, показали наилучшие результаты, тогда как прореживание существенно снижает точность прогнозов.
- Ограничение на короткие позиции уменьшает неопределенность и повышает точность оптимизации, однако приводит к снижению потенциальной доходности.
- Агрессивные стратегии с заданной целевой доходностью демонстрируют более высокую доходность, но сопровождаются повышенными рисками.

В работе были выявлены области, требующие дальнейшего изучения. Во-первых, помимо реализованного поиска оптимальных гиперпараметров ARIMA существует необходимость интеграции современных методов адаптивного поиска оптимальных гиперпараметров для LSTM и GMDH в зависимости от криптоактива и данных. Во-вторых, требуется проведение углубленного анализа динамики коротких позиций, так как их поведение имеет уникальные характеристики, которые не всегда могут быть точно учтены обобщающими подходами. В-третьих, помимо модифицированного традиционного подхода Г. Марковица можно применить другие подходы к оптимизации портфеля – например, генетические алгоритмы, упомянутые в обзорной части статьи. Наконец, целесообразно рассмотреть возможность интеграции дополнительных факторов риска и использования альтернативных стратегий оптимизации, таких как многокритериальные методы.

Заключение

Результаты данного исследования можно сформулировать следующим образом:

1. Предложен подход к оптимизации инвестиционного портфеля, объединяющий адаптивный выбор оптимальных моделей прогнозирования (ARIMA, Chronos Forecasting, GMDH, LSTM) с гибкой настройкой оптимизации. Это позволяет минимизировать ошибки прогнозов и эффективно управлять распределением активов даже в условиях высокой волатильности рынка.

2. Проведены 324 эксперимента с применением предложенного подхода, которые показали устойчивую положительную доходность, что демонстрирует потенциал предложенного подхода для практического применения в управлении инвестициями.

3. Подробно рассмотрено влияние таких параметров, как горизонт прогнозирования, стратегия масштабирования, целевая доходность и возможность коротких позиций, количество активов в портфеле. Полученные результаты дают обоснование выбора настроек для формирования устойчивых и гибких инвестиционных портфелей в зависимости от индивидуальных инвестиционных целей.

4. Открытие направлений для будущих исследований. Выявлены области для дальнейших исследований: интеграция адаптивного подбора гиперпараметров для моделей LSTM и GMDH, детальный анализ динамики коротких позиций, а также применение предложенного подхода к традиционным финансовым рынкам и другим классам активов.

Таким образом, автором предложен подход применения методов машинного обучения и прогнозирования временных рядов в задачах оптимизации инвестиционных портфелей – универсальный и адаптивный инструмент для повышения эффективности управления рисками и доходностью инвестиций.

СПИСОК ИСТОЧНИКОВ

1. Markowitz H. (1952) Portfolio Selection. *The Journal of Finance*, 7 (1), 77–91. DOI: <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
2. Sharpe, W.F. (1964) Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *Journal of Finance*, 19 (3), 425–442. DOI: <https://doi.org/10.1111/j.1540-6261.1964.tb02865.x>
3. Редькин Н.М. (2019) Оптимизация инвестиционного портфеля на российском фондовом рынке в контексте поведенческой теории. *Финансы: теория и практика*, № 23 (4), 99–116. DOI: <https://doi.org/10.26794/2587-5671-2019-23-4-99-116>
4. Михайлов А.Ю. (2017) Теория оценки стоимости криптоактивов. *Финансовая аналитика: проблемы и решения*, 10 (6), 691–700. DOI: <https://doi.org/10.24891/fa.10.6.691>
5. Briere M., Oosterlinck K., Szafarz A. (2015) Virtual Currency, Tangible Return: Portfolio Diversification with Bitcoins. *Journal of Asset Management*, 16 (6), 365–373. DOI: <https://doi.org/10.1057/jam.2015.5>



6. Popper N. (2015) *Digital Gold: The Untold Story of Bitcoin*, London: Penguin.
7. Михайлов А.Ю. (2018) Ценообразование на рынке криптоактивов и взаимосвязь с фондовыми индексами. *Финансовая аналитика: проблемы и решения*, 24 (3), 641–651. DOI: <https://doi.org/10.24891/fc.24.3.641>
8. Kukačka J., Kristoufek L. (2020) Fundamental and speculative components of the cryptocurrency pricing dynamics. *Financial Innovation*, 6, art. no. 61. DOI: <https://doi.org/10.1186/s40854-023-00465-7>
9. Hakim das Neves, R. (2020) Bitcoin pricing: impact of attractiveness variables. *Financial Innovation*, 6, art. no. 21. DOI: <https://doi.org/10.1186/s40854-020-00176-3>
10. Srokosz W., Kopyscianski T. (2015) Legal And Economic Analysis Of The Cryptocurrencies Impact On The Financial System Stability. *Journal of Teaching and Education*, 4, 619–627. [online] Available at: <https://universitypublications.net/jte/0402/pdf/F5N180.pdf> [Accessed 15.04.2025]
11. Sanshao P., Prentice C., Shams S., Sarker T. (2024) A systematic literature review on the determinants of cryptocurrency pricing. *China Accounting and Finance Review*, 26 (1), 1–30. DOI: <https://doi.org/10.1108/CAFR-05-2023-0053>
12. Madichie Ch., Ngwu F., Eze E., Maduka O. (2023) Modelling the dynamics of cryptocurrency prices for risk hedging: The case of Bitcoin, Ethereum, and Litecoin. *Cogent Economics and Finance*, 11 (1). DOI: <https://doi.org/10.1080/23322039.2023.2196852>
13. Sukomardojo T., Pamikatsih M., Arpianto Yu., Nuraini A., Fatmawati E. (2023) Cryptocurrency and Macro-Economic Stability: Impacts and Regulations. *International Journal of Science and Society*, 5 (4), 734–745. DOI: <https://doi.org/10.54783/ijssoc.v5i4.842>
14. Sovbetov Yh. (2018) Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litecoin, and Monero. *Journal of Economics and Financial Analysis*, 2 (2), 1–27. [online] Available at: <https://ssrn.com/abstract=3125347> [Accessed 15.04.2025]
15. Ghysels E., Nguyen G. (2019) Price Discovery of a Speculative Asset: Evidence from a Bitcoin Exchange. *Journal of Risk and Financial Management*, 12 (4), art. no. 164. DOI: <https://doi.org/10.3390/jrfm12040164>
16. Chen C., Hardle W.K., Hou A., Wang W. (2018) Pricing Cryptocurrency Options: The Case of Bitcoin and CRIX. *SSRN Electronic Journal*. DOI: <http://dx.doi.org/10.2139/ssrn.3159130>
17. Conlon Th., Mcgee R. (2020) Betting on Bitcoin: Does gambling volume on the blockchain explain Bitcoin price changes? *Economics Letters*, 191, art. no. 108727. DOI: <http://doi.org/10.1016/j.econlet.2019.108727>
18. Shen D., Urquhart A., Wang P. (2019) Does twitter predict Bitcoin? *Economics Letters*, 174, 118–122. DOI: <https://doi.org/10.1016/j.econlet.2018.11.007>
19. Zhang W., Shen D., Zhang Yo., Xiong X. (2013) Open source information, investor attention, and asset pricing. *Economic Modelling*, 33, 613–619. DOI: <https://doi.org/10.1016/j.econmod.2013.03.018>
20. Zhang Yo., Song W., Shen D., Zhang W. (2016) Market reaction to internet news: Information diffusion and price pressure. *Economic Modelling*, 56, 43–49. DOI: <https://doi.org/10.1016/j.econmod.2016.03.020>
21. Datta B., Hodor I. (2021) Cryptocurrency, Mining Pools' Concentration, and Asset Prices. *SSRN Electronic Journal*. DOI: <http://dx.doi.org/10.2139/ssrn.3887256>
22. Afjal M., Sajeev K. (2022) Interconnection between cryptocurrencies and energy markets: an analysis of volatility spillover. *OPEC Energy Review*, 46 (3), 287–309. DOI: <http://doi.org/10.1111/opec.12227>
23. Никитина Е.А., Мясникова Е.Б. (2017) Подходы к оптимизации портфеля ценных бумаг по критерию риска. *Известия ТулГУ*, 4–1, 24–36.
24. Bader B. (2016) Automated, Efficient, and Practical Extreme Value Analysis with Environmental Applications. *arXiv:1611.08261*. DOI: <https://doi.org/10.48550/arXiv.1611.08261>
25. Бальнин И.В. (2016) Оптимизация инвестиционного портфеля в контексте практической реализации рискориентированного подхода: многообразие методов и принципов. *Экономический анализ: теория и практика*, 10 (457), 79–92.
26. Пономарева Л.М., Шорохов С.Г. (2023) Построение оптимального инвестиционного портфеля с прогнозом доходностей активов методами машинного обучения. *Молодой ученый*, 21 (468), 131–135.
27. Добринина М.В., Чернов В.П. (2024) Оптимизация и прогнозирование портфеля ценных бумаг на основе методов машинного обучения. *Проблемы экономики и юридической практики*, 20 (4), 258–267. DOI: <https://doi.org/10.33693/2541-8025-2024-20-4-258-267>

28. Коновалова М.Е., Абузов А.Ю. (2024) Математическая модель оптимизации портфеля инвестиций с учетом риска и финансовых ограничений в управлении предприятием. *Фундаментальные исследования*, 1, 20–24; DOI: <https://doi.org/10.17513/fr.43551>
29. Zhang Z., Zohren S., Roberts S. (2020) Deep Learning for Portfolio Optimisation. *The Journal of Financial Data Science*, 2 (4), 8–20. DOI: <https://dx.doi.org/10.3905/jfds.2020.1.042>
30. Полетаев А.Ю., Спиридонова Е.М. (2020) Иерархическая кластеризация как метод снижения размерности в задаче оптимизации инвестиционного портфеля Марковица. *Моделирование и анализ информационных систем*, 27 (1), 62–71. DOI: <https://doi.org/10.18255/1818-1015-2020-1-62-71>
31. Corsaro S., De Simone V. (2018) Adaptive l1-regularization for short-selling control in portfolio selection. *Computational Optimization and Applications*, 72 (2), 457–478. DOI: <https://doi.org/10.1007/s10589-018-0049-4>
32. Wilson G.T. (2016) Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1. *Journal of Time Series Analysis*, 37 (5), 709–711. DOI: <https://doi.org/10.1111/jtsa.12194>
33. Fischer Th., Krauss Ch. (2018) Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270 (2), 654–669. DOI: <https://doi.org/10.1016/j.ejor.2017.11.054>
34. Zhang Ch., Zhang Z., Cucuringu M., Zohren S. (2021) A Universal End-to-End Approach to Portfolio Optimization via Deep Learning. *arXiv:2111.09170*. DOI: <https://doi.org/10.48550/arXiv.2111.09170>
35. Butler A., Kwon R. (2021) Integrating Prediction in Mean-Variance Portfolio Optimization. *SSRN Electronic Journal*. DOI: <https://doi.org/10.2139/ssrn.3788875>
36. Chang T.-J., Meade N., Beasley J.E., Sharaiha Y.M. (2000) Heuristics for cardinality constrained portfolio optimisation. *Computers & Operations Research*, 27 (13), 1271–1302.
37. Zhang Z., Zohren S., Roberts S. (2020) Deep Learning for Portfolio Optimization. *The Journal of Financial Data Science*, 2 (4), 8–20. DOI: <https://doi.org/10.3905/jfds.2020.1.042>
38. Uysal A.S., Li X., Mulvey J.M. (2021) End-to-End Risk Budgeting Portfolio Optimization with Neural Networks. *arXiv:2107.04636*. DOI: <https://doi.org/10.48550/arXiv.2107.04636>
39. Grover A., Wang E., Zweig A., Ermon S. (2018) Stochastic Optimization of Sorting Networks via Continuous Relaxations. *arXiv:1903.08850*. DOI: <https://doi.org/10.48550/arXiv.1903.08850>
40. Gurgul V., Lessmann S., Wolfgang K.K.H. (2023) Deep Learning and NLP in Cryptocurrency Forecasting: Integrating Financial, Blockchain, and Social Media Data. *arXiv:2311.14759*. DOI: <https://doi.org/10.48550/arXiv.2311.14759>
41. Li J. (2024) A Deep Reinforcement Learning Framework For Financial Portfolio Management. *arXiv:2409.08426*. DOI: <https://doi.org/10.48550/arXiv.2409.08426>
42. Ballings M., Van den Poel D., Hespels N., Gryp R. (2015) Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42 (20), 7046–7056. DOI: <https://doi.org/10.1016/j.eswa.2015.05.013>
43. Ozbayoglu A.M., Gudelek M.U., Berat Sezer O. (2020) Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, art. no. 106384. DOI: <https://doi.org/10.1016/j.asoc.2020.106384>
44. Ansari A.F., Stella L., Turkmen C., Zhang X. et al. (2024) Chronos: Learning the Language of Time Series. *Transactions on Machine Learning Research*, 10. DOI: <https://doi.org/10.48550/arXiv.2403.07815>
45. Raffel C., Shazeer N., Roberts A., Lee K., Narang Sh. et al. (2020) Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer. *Journal of Machine Learning Research*, 21, 1–67. DOI: <https://doi.org/10.48550/arXiv.1910.10683>
46. Hochreiter S., Schmidhuber J. (1997) Long Short-Term Memory. *Neural Computation*, 9 (8), 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>

REFERENCES

1. Markowitz H. (1952) Portfolio Selection. *The Journal of Finance*, 7(1), 77–91. DOI: <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>



2. Sharpe, W.F. (1964) Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *Journal of Finance*, 19 (3), 425–442. DOI: 10.1111/j.1540-6261.1964.tb02865.x
3. Redkin N.M. (2019) Investment Portfolio Optimization on Russian Stock Market in Context of behavioral theory. *Finance: Theory and Practice*, 23 (4), 99–116. <https://doi.org/10.26794/2587-5671-2019-23-4-99-116>
4. Mikhaylov A.Yu. (2017) A theory of cryptoasset valuation. *Financial Analytics: Science and Experience*, 10 (6), 691–700. DOI: <https://doi.org/10.24891/fa.10.6.691>
5. Briere M., Oosterlinck K., Szafarz A. (2015) Virtual Currency, Tangible Return: Portfolio Diversification with Bitcoins. *Journal of Asset Management*, 16 (6), 365–373. DOI: <https://doi.org/10.1057/jam.2015.5>
6. Popper N. (2015) Digital Gold: *The Untold Story of Bitcoin*, London: Penguin.
7. Mikhaylov A.Yu. (2018) Cryptoassets pricing and equity indices correlation. *Financial Analytics: Science and Experience*, 24 (3), 641–651. DOI: <https://doi.org/10.24891/fc.24.3.641>
8. Kukačka J., Kristoufek L. (2020) Fundamental and speculative components of the cryptocurrency pricing dynamics. *Financial Innovation*, 6, art. no. 61. DOI: <https://doi.org/10.1186/s40854-023-00465-7>
9. Hakim das Neves, R. (2020) Bitcoin pricing: impact of attractiveness variables. *Financial Innovation*, 6, art. no. 21. DOI: <https://doi.org/10.1186/s40854-020-00176-3>
10. Srokosz W., Kopyscianski T. (2015) Legal And Economic Analysis Of The Cryptocurrencies Impact On The Financial System Stability. *Journal of Teaching and Education*, 4, 619–627. [online] Available at: <https://universitypublications.net/jte/0402/pdf/F5N180.pdf> [Accessed 15.04.2025]
11. Sanshao P., Prentice C., Shams S., Sarker T. (2024) A systematic literature review on the determinants of cryptocurrency pricing. *China Accounting and Finance Review*, 26 (1), 1–30. DOI: <https://doi.org/10.1108/CAFR-05-2023-0053>
12. Madichie Ch., Ngwu F., Eze E., Maduka O. (2023) Modelling the dynamics of cryptocurrency prices for risk hedging: The case of Bitcoin, Ethereum, and Litecoin. *Cogent Economics and Finance*, 11 (1). DOI: <https://doi.org/10.1080/23322039.2023.2196852>
13. Sukomardojo T., Pamikatsih M., Arpianto Yu., Nuraini A., Fatmawati E. (2023) Cryptocurrency and Macro-Economic Stability: Impacts and Regulations. *International Journal of Science and Society*, 5 (4), 734–745. DOI: <https://doi.org/10.54783/ijssoc.v5i4.842>
14. Sovbetov Yh. (2018) Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litecoin, and Monero. *Journal of Economics and Financial Analysis*, 2 (2), 1–27. [online] Available at: <https://ssrn.com/abstract=3125347> [Accessed 15.04.2025]
15. Ghysels E., Nguyen G. (2019) Price Discovery of a Speculative Asset: Evidence from a Bitcoin Exchange. *Journal of Risk and Financial Management*, 12 (4), art. no. 164. DOI: <https://doi.org/10.3390/jrfm12040164>
16. Chen C., Hardle W.K., Hou A., Wang W. (2018) Pricing Cryptocurrency Options: The Case of Bitcoin and CRIX. *SSRN Electronic Journal*. DOI: <http://dx.doi.org/10.2139/ssrn.3159130>
17. Conlon Th., Mcgee R. (2020) Betting on Bitcoin: Does gambling volume on the blockchain explain Bitcoin price changes? *Economics Letters*, 191, art. no. 108727. DOI: <http://doi.org/10.1016/j.econlet.2019.108727>
18. Shen D., Urquhart A., Wang P. (2019) Does twitter predict Bitcoin? *Economics Letters*, 174, 118–122. DOI: <https://doi.org/10.1016/j.econlet.2018.11.007>
19. Zhang W., Shen D., Zhang Yo., Xiong X. (2013) Open source information, investor attention, and asset pricing. *Economic Modelling*, 33, 613–619. DOI: <https://doi.org/10.1016/j.econmod.2013.03.018>
20. Zhang Yo., Song W., Shen D., Zhang W. (2016) Market reaction to internet news: Information diffusion and price pressure. *Economic Modelling*, 56, 43–49. DOI: <https://doi.org/10.1016/j.econmod.2016.03.020>
21. Datta B., Hodor I. (2021) Cryptocurrency, Mining Pools' Concentration, and Asset Prices. *SSRN Electronic Journal*. DOI: <http://dx.doi.org/10.2139/ssrn.3887256>
22. Afjal M., Sajeev K. (2022) Interconnection between cryptocurrencies and energy markets: an analysis of volatility spillover. *OPEC Energy Review*, 46 (3), 287–309. DOI: <http://doi.org/10.1111/opec.12227>
23. Nikitina Ye.A., Myasnikova Ye.B. (2017) Approaches to Optimization of a Portfolio of Securities on the Criterion of Risk. *Proceedings of the TSU*, 4–1, 24–36.
24. Bader B. (2016) Automated, Efficient, and Practical Extreme Value Analysis with Environmental Applications. *arXiv:1611.08261*. DOI: <https://doi.org/10.48550/arXiv.1611.08261>

25. Balynin I.V. (2016) Optimization of Investment Portfolio as Part of Practical Implementation of a Risk-Based Approach: a Variety of Methods and Principles. *Economic Analysis: Theory and Practice*, 10 (457), 79–92.
26. Ponomareva L.M., Shorokhov S.G. (2023) Postroyeniye optimalnogo investitsionnogo portfelya s prognozom dokhodnostey aktivov metodami mashinnogo obucheniya [Building an optimal investment portfolio with asset return forecasting using machine learning methods]. *Young Scientist*, 21 (468), 131–135.
27. Dobrina M.V., Chernov V.P. (2024) Optimization and Forecasting of a Securities Portfolio Based on Machine Learning Methods. *Economic Problems and Legal Practice*, 20 (4), 258–267. DOI: 10.33693/2541-8025-2024-20-4-258-267
28. Konovalova M.Ye., Abuzov A.Yu. (2024) Mathematical Model of Investment Portfolio Optimization Taken into Risk and Financial Constraints in Enterprise Management. *Fundamental research*, 1, 20–24. DOI: <https://doi.org/10.17513/fr.43551>
29. Zhang Z., Zohren S., Roberts S. (2020) Deep Learning for Portfolio Optimisation. *The Journal of Financial Data Science*, 2 (4), 8–20. DOI: <https://dx.doi.org/10.3905/jfds.2020.1.042>
30. Poletaev A.Y., Spiridonova E.M. (2020) Hierarchical Clustering as a Dimension Reduction Technique for Markowitz Portfolio Optimization. *Modeling and Analysis of Information Systems*, 27 (1), 62–71. DOI: <https://doi.org/10.18255/1818-1015-2020-1-62-71>
31. Corsaro S., De Simone V. (2018) Adaptive l1-regularization for short-selling control in portfolio selection. *Computational Optimization and Applications*, 72 (2), 457–478. DOI: <https://doi.org/10.1007/s10589-018-0049-4>
32. Wilson G.T. (2016) Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1. *Journal of Time Series Analysis*, 37 (5), 709–711. DOI: <https://doi.org/10.1111/jtsa.12194>
33. Fischer Th., Krauss Ch. (2018) Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270 (2), 654–669. DOI: <https://doi.org/10.1016/j.ejor.2017.11.054>
34. Zhang Ch., Zhang Z., Cucuringu M., Zohren S. (2021) A Universal End-to-End Approach to Portfolio Optimization via Deep Learning. *arXiv:2111.09170*. DOI: <https://doi.org/10.48550/arXiv.2111.09170>
35. Butler A., Kwon R. (2021) Integrating Prediction in Mean-Variance Portfolio Optimization. *SSRN Electronic Journal*. DOI: <https://doi.org/10.2139/ssrn.3788875>
36. Chang T.-J., Meade N., Beasley J.E., Sharaiha Y.M. (2000) Heuristics for cardinality constrained portfolio optimisation. *Computers & Operations Research*, 27 (13), 1271–1302.
37. Zhang Z., Zohren S., Roberts S. (2020) Deep Learning for Portfolio Optimization. *The Journal of Financial Data Science*, 2 (4), 8–20. DOI: <https://doi.org/10.3905/jfds.2020.1.042>
38. Uysal A.S., Li X., Mulvey J.M. (2021) End-to-End Risk Budgeting Portfolio Optimization with Neural Networks. *arXiv:2107.04636*. DOI: <https://doi.org/10.48550/arXiv.2107.04636>
39. Grover A., Wang E., Zweig A., Ermon S. (2018) Stochastic Optimization of Sorting Networks via Continuous Relaxations. *arXiv:1903.08850*. DOI: <https://doi.org/10.48550/arXiv.1903.08850>
40. Gurgul V., Lessmann S., Wolfgang K.K.H. (2023) Deep Learning and NLP in Cryptocurrency Forecasting: Integrating Financial, Blockchain, and Social Media Data. *arXiv:2311.14759*. DOI: <https://doi.org/10.48550/arXiv.2311.14759>
41. Li J. (2024) A Deep Reinforcement Learning Framework For Financial Portfolio Management. *arXiv:2409.08426*. DOI: <https://doi.org/10.48550/arXiv.2409.08426>
42. Ballings M., Van den Poel D., Hespeels N., Gryp R. (2015) Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42 (20), 7046–7056. DOI: <https://doi.org/10.1016/j.eswa.2015.05.013>
43. Ozbayoglu A.M., Gudelek M.U., Berat Sezer O. (2020) Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, art. no. 106384. DOI: <https://doi.org/10.1016/j.asoc.2020.106384>
44. Ansari A.F., Stella L., Turkmen C., Zhang X. et al. (2024) Chronos: Learning the Language of Time Series. *Transactions on Machine Learning Research*, 10. DOI: <https://doi.org/10.48550/arXiv.2403.07815>
45. Raffel C., Shazeer N., Roberts A., Lee K., Narang Sh. et al. (2020) Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer. *Journal of Machine Learning Research*, 21, 1–67. DOI: <https://doi.org/10.48550/arXiv.1910.10683>



46. Hochreiter S., Schmidhuber J. (1997) Long Short-Term Memory. *Neural Computation*, 9 (8), 1735–1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>

СВЕДЕНИЯ ОБ АВТОРЕ / INFORMATION ABOUT AUTHOR

ШКАНОВ Булат Арманович

E-mail: bulat.shkanov@mail.ru

Bulat A. SHKANOV

E-mail: bulat.shkanov@mail.ru

ORCID: <https://orcid.org/0000-0003-1286-2620>

Поступила: 23.02.2025; Одобрена: 13.04.2025; Принята: 14.04.2025.

Submitted: 23.02.2025; Approved: 13.04.2025; Accepted: 14.04.2025.