

УДК 330.43, 519.246.8, 336.74

DOI: <https://doi.org/10.17323/ej.2026.33618>

## Сравнение современных методов прогнозирования доходностей криптовалют с бенчмарком SARIMA<sup>1</sup>

Синельникова-Мурылева Е.В., Шканов Б.А.

Статья посвящена сравнительному анализу современных методов прогнозирования доходностей криптовалют. Рассматриваются классические статистические модели (SARIMA), методы машинного обучения, нейросетевые архитектуры (LSTM, трансформеры) и метод группового учета аргументов (МГУА). Цель исследования – выявить сильные и слабые стороны различных подходов при краткосрочном и среднесрочном прогнозировании.

Эмпирический анализ проведен на временных рядах 13 крупнейших криптовалют за период от 3 до 10 лет. Данные были преобразованы в логарифмические доходности, использовались блочная кросс-валидация и автоматизированный подбор гиперпараметров. Рассматривались горизонты 1, 7 и 30 дней, а также рекурсивные и масштабируемые методы многошагового прогнозирования.

Результаты показали, что для краткосрочных горизонтов наиболее точными оказались модели МГУА, тогда как LSTM демонстрировала худшие показатели. На месячном горизонте лидерство перешло к трансформеру Chronos, применявшемуся в режиме обучения внутри контекста. SARIMA сохранила устойчивость на средних горизонтах и подтвердила роль надежного бенчмарка. Масштабируемые методы позволили снизить ошибки по сравнению с рекурсивным прогнозом.

Полученные выводы подчеркивают отсутствие универсального алгоритма и важность выбора метода в зависимости от горизонта и задач анализа.

---

<sup>1</sup> Данная статья подготовлена в рамках государственного задания РАНХиГС.

**Синельникова-Мурылева Елена Владимировна** – ведущий научный сотрудник, Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации. E-mail: [e.sinelnikova@ranepa.ru](mailto:e.sinelnikova@ranepa.ru)

**Шканов Булат Арманович** – Независимый исследователь, г. Москва, Российская Федерация; руководитель отдела анализа данных, Careem Technologies, Объединенные Арабские Эмираты. E-mail: [bulat.shkanov@mail.ru](mailto:bulat.shkanov@mail.ru)

Статья поступила: 30.09.2025/Статья принята: 19.02.2026.

**Ключевые слова:** доходности криптовалют; прогнозирование; LSTM; МГУА; SARIMA; трансформеры; временные ряды.

**Для цитирования:** Синельникова-Мурылева Е.В., Шканов Б.А. Сравнение современных методов прогнозирования доходностей криптовалют с бенчмарком SARIMA. *Экономический журнал ВШЭ*. 2026; 30(1): 102–127.

**For citation:** Sinelnikova-Muryleva E.V., Shkanov B.Ar. Comparison of Modern Methods for Cryptocurrency Return Forecasting with SARIMA Benchmark. *HSE Economic Journal*. 2026; 30(1): 102–127. (In Russ.)

## 1. Введение

Криптовалюты стали важным элементом современной финансовой системы, выступая в качестве инвестиционных активов и технологической основы для децентрализованных финансов (DeFi). Высокая волатильность криптовалют делает задачу прогнозирования их доходностей актуальной как для инвесторов и трейдеров, так и для исследователей в области финансовой экономики и анализа временных рядов. Доходности криптовалют характеризуются нелинейной динамикой и высокой чувствительностью к большому числу факторов. К ним относятся технологические особенности блокчейн-платформ (скорость транзакций, уровень децентрализации, обновления протоколов), макроэкономические условия и динамика глобальной ликвидности, структура ликвидности крипторынка, а также поведенческие и информационные факторы, включая активность розничных инвесторов и влияние новостного фона и социальных сетей. Существенную роль также играет структура участников рынка и концентрация капитала в отдельных криптовалютах, а также распространение производных инструментов с высоким кредитным плечом. Подробный анализ этих факторов представлен в наших более ранних исследованиях, посвященных фундаментальным драйверам криптовалютных рынков (см.: [Шканов, 2024; Shkanov, Alexandrov, 2024]). Высокая комплексность и динамичность этих факторов ограничивает эффективность традиционных линейных моделей и стимулирует применение современных методов анализа временных рядов, включая методы машинного обучения и нейросетевые архитектуры. Несмотря на ряд эмпирических исследований, в которых проводится сравнение различных методов моделирования динамики определенных криптовалют (см.: [Chen et al., 2019; Kilimci et al., 2021; Рабуцсу et al., 2023]), остается открытым вопрос сравнительной эффективности данных методов и устойчивости архитектур при применении к различным криптовалютам.

В прикладном анализе криптовалютных рынков широко используются методы технического анализа, включая полосы Боллинджера (Bollinger Bands), индекс относительной силы (RSI), а также различные комбинации скользящих средних и их пересечений. Эти индикаторы применяются для выявления краткосрочных трендов, состояний перекупленности и перепроданности рынка и часто используются трейдерами и аналитиками. В настоящем исследовании основной акцент сделан на сравнении методов прогнозирования, применяемых непосредственно к временным рядам доходностей криптовалют без использования дополнительных технических индикаторов. Такой подход поз-

воляет сопоставить способность различных моделей извлекать информацию непосредственно из структуры временных рядов. Включение технических индикаторов в качестве дополнительных признаков представляется перспективным направлением дальнейших исследований.

Таким образом, настоящее исследование направлено на обзор современных методов прогнозирования временных рядов криптовалютных доходностей и их эмпирическое сравнение, что позволит предоставить практические рекомендации для применения тех или иных методов в задачах краткосрочного и среднесрочного анализа рынка.

## 2. Обзор литературы

Начиная примерно с 2017 г. наблюдается взрывной рост числа научных работ, посвященных прогнозированию доходностей криптовалют. Хорошим примером обзора самых разнообразных подходов – от классических статистических методов моделирования до современных методов машинного обучения и глубоких нейросетей – является работа [Pečiulis et al., 2024].

### 2.1. Классические статистические модели. ARIMA

Простота и интерпретируемость ARIMA сделали ее отправной точкой во многих исследованиях крипторынков. Например, в работе [Chen et al., 2019] для прогноза Ethereum сравнивались несколько методов (линейная регрессия, наивный байесовский классификатор, метод опорных векторов, случайный лес, рекуррентная нейронная сеть и др.), и лучшим по рассматриваемым метрикам качества прогноза оказался именно ARIMA: точность прогноза направления изменения цены достигла ~61,2%. Этот неожиданный результат показывает, что даже простая линейная модель способна улавливать часть динамики высоковолатильного криптоактива. Схожим образом автор [Kilimci, 2020] при прогнозе доходности Bitcoin на основе настроений соцсетей обнаружил, что расширенная модель ARIMAX (ARIMA с экзогенными переменными) дала меньшую ошибку, чем сложная LSTM нейросеть. Однако в других случаях потенциал ARIMA ограничен: так, в одном сравнительном эксперименте ошибка прогноза (RMSE) для модели LSTM оказалась порядка 33,7, тогда как для ARIMA – около 439, т.е. почти в 13 раз больше [Tan, Kashef, 2019]. В целом, ARIMA хорошо работает на коротких промежутках и служит надежным базовым ориентиром, но не охватывает нелинейные и структурно сложные паттерны крипторынков.

### 2.2. Методы машинного обучения

Алгоритмы машинного обучения предлагают нелинейные подходы к прогнозированию доходностей, не требуя явных предположений о стохастической природе ряда. Решающее дерево разделяет данные по порогам признаков, формируя простые правила «если, то», однако одиночное дерево нестабильно и может переобучаться. Более эффективны ансамбли деревьев – случайный лес и градиентный бустинг (например, XGBoost [Chen, Guestrin, 2016]). Эти методы объединяют прогнозы множества деревьев, что повышает устойчивость и точность. Исследования демонстрируют, что ансамблевые модели

способны уловить сложные нелинейные зависимости. Например, сравнение алгоритмов на данных Bitcoin показало, что полносвязная нейронная сеть и случайный лес достигли более высокой точности прогноза направления движения цены (метрика F-статистики  $\sim 0,94$ ), тогда как логистическая регрессия в той же задаче дала заметно более низкий результат ( $\sim 0,85$ ) [Pabuçcu et al., 2023]. В том же исследовании методы машинного обучения (полносвязная нейронная сеть, случайный лес, метод опорных векторов, наивный байесовский классификатор) значительно превзошли линейную регрессию в задаче классификации роста/падения цены Bitcoin. Это указывает на наличие предсказуемых паттернов, которые могут выявляться сложными моделями. Тем не менее качество прогноза сильно зависит от информативности признаков. Без дополнительных данных точно предсказать движение криптовалют сложно. Например, авторы [Mallqui, Fernandes, 2018] сообщают, что точность прогноза направления для Bitcoin с помощью метода опорных векторов составляла лишь  $\sim 59,5\%$ , что немногим выше случайного угадывания. Однако стоит отметить, что включение альтернативных данных заметно улучшает результаты. Так, использование тональности новостей повысило точность моделей с 86 до 90% [Ranco et al., 2015].

### 2.3. Глубокие нейросетевые модели

Глубокие нейронные сети, благодаря многослойной архитектуре, способны аппроксимировать очень сложные нелинейные зависимости. Классические рекуррентные нейронные сети страдают от проблемы исчезающего градиента, поэтому на практике их сменили архитектуры с механизмом долгой краткосрочной памяти (LSTM). В литературе зафиксирован ряд случаев, когда LSTM-модель существенно превосходила традиционные подходы в точности криптопрогноза. Так, по данным сравнительного анализа [Костин, Белоусов, 2022], использование LSTM позволило сократить среднеквадратичную ошибку прогноза более чем на 90% по сравнению с моделью ARIMA. Даже если эта оценка выглядит экстремальной, большинство работ, например, [Aggarwal et al., 2019; Wu et al., 2018], сходятся в том, что LSTM, обученные на достаточном объеме данных, обычно дают меньшую ошибку (MAPE, RMSE) при прогнозировании доходности Bitcoin, Ethereum и др., чем ARIMA или метод опорных векторов. Например, авторы [Tandon et al., 2019] показали, что LSTM при прогнозе доходности Bitcoin на сутки вперед обеспечивает наилучший результат среди множества алгоритмов, превосходя по точности даже сложные гибридные схемы. LSTM применялись и для прогнозирования сразу нескольких криптовалют; в одном исследовании для прогноза доходности 5 крупнейших криптовалют на 10-дневном горизонте LSTM также продемонстрировала лучшую точность, хотя, что примечательно, классическая ARIMA оказалась на втором месте, не сильно уступив нейросети [Shamshad et al., 2023]. Это подтверждает, что успех моделей зависит от характера данных: на одних рынках нейросеть легко выявляет паттерны, на других поведение столь хаотично, что сложная модель лишь излишне переобучается. В работе [McNally et al., 2018] авторы сравнили LSTM и ARIMA для Bitcoin: LSTM дала немногим более высокую точность прогноза направления при существенно большей вычислительной затратности. Таким образом, роль LSTM в криптопрогнозировании крайне заметна: эта архитектура стала популярной в современных исследованиях, но гарантия успеха не абсолютна.

Помимо рекуррентных сетей используются и другие глубокие архитектуры, например, сверточные нейронные сети (CNN). В криптовалютном прогнозировании CNN часто

комбинируют с рекуррентными сетями: сверточные слои обрабатывают входные признаки за каждый день/час (например, определяя важные комбинации индикаторов), а далее LSTM улавливает последовательность этих сверток во времени. Такая гибридная CNN/LSTM-модель показала высокую точность на ряде наборов данных [Kilimci et al., 2021]. В еще одном примере работ авторы [Albariqi, Winarko, 2020] применили многослойный перцептрон (MLP) и сверточную сеть для прогнозирования Bitcoin и пришли к выводу, что CNN-экстракторы признаков могут улучшить результаты по сравнению с чисто рекуррентными архитектурами.

Еще одна новейшая технология – трансформеры, архитектуры на базе механизмов самовнимания, изначально революционизировавшие обработку естественного языка. В отличие от RNN, которые прогоняют последовательность шаг за шагом, трансформер рассматривает сразу весь контекст, выявляя глобальные зависимости [Singh, Bhat, 2024]. В литературе по криптовалютам применение трансформеров только начинается, но уже появляются примеры. В работе [Sridhar, Sanagavarapu, 2021] авторы представили модель на основе многоголового механизма самовнимания для прогноза доходности Dogecoin, показав, что их подход превосходит по точности традиционные рекуррентные нейронные сети на тех же данных. Другие авторы отмечают, что трансформеры хорошо справляются с выявлением межрыночных связей: например, в работе [Singh, Bhat, 2024] авторы построили трансформер для прогнозирования Ethereum, включив в их модель сразу несколько криптовалют и показатели настроений. Такой подход улучшил качество прогноза за счет учета кросс-корреляций между рынками. Более того, сравнение трансформеров с LSTM на криптовалютах показывает, что первые не уступают, а иногда и превосходят рекуррентные сети [Herremans, Low, 2022]. Преимущество трансформеров ярче проявляется на больших объемах данных и при наличии множества входных признаков, где способность к параллельной обработке и выделению важнейших сигналов особенно полезна. Ожидается, что внедрение трансформеров в эту сферу будет нарастать, открывая новые возможности повышения точности прогнозирования [John et al., 2024].

#### 2.4. Метод группового учета аргументов

Метод группового учета аргументов (МГУА, Group method of data handling (GMDH)) представляет собой самоорганизующийся подход к моделированию, при котором структура модели (например, нейросети) формируется автоматически с отбором наиболее значимых входов [Seifaddini, Habibdoust, 2022]. В ряде работ, как зарубежных, так и отечественных, показана возможность успешного применения МГУА для прогнозирования курсов цифровых валют.

Исследования показывают, что МГУА способен превзойти традиционные методы сглаживания и экстраполяции. В частности, в экспериментальном сравнении с методом Хольта – Винтерса (двухпараметрическим экспоненциальным сглаживанием) алгоритмы МГУА дали существенно более низкие ошибки прогноза на недельном и месячном горизонтах для различных криптовалют [Baiburin et al., 2020]. Авторы [Khan et al., 2023] исследовали прогнозирование волатильности рынка криптовалют с помощью различных методов. Их результаты показали, что МГУА сопоставим с современными методами с точки зрения качества прогноза.

В силу гибкости МГУА будущие работы могут исследовать его применение для выявления долгосрочных нелинейных трендов совместно с экономическими индикаторами (макроэкономической ситуацией, регуляторной средой и т.п.), что обозначено исследователями среди ключевых направлений развития [Seifaddini, Habibdoust, 2022].

### 3. Методология и инструментарий прогноза динамики криптовалют

На основе анализа современных методов прогноза динамики криптовалют, представленных в предыдущем разделе, в данном исследовании было принято решение использовать следующие методы математического моделирования: SARIMA, нейронная сеть LSTM, МГУА, трансформеры. Каждый из перечисленных методов является наиболее популярным в своей группе, что позволяет сравнить преимущества и недостатки каждой из групп на практике.

#### 3.1. SARIMA

Временные ряды криптовалют, помимо трендов, могут иметь сезонные паттерны (например, суточные циклы). Для учета сезонности введено расширение ARIMA – модель SARIMA (Seasonal ARIMA) [Box et al., 2015]. Она обозначается  $ARIMA(p, d, q)(P, D, Q)_s$ , где  $s$  – длина сезонного периода (например,  $s = 7$  для недельной сезонности на дневных данных,  $s = 24$  для суточной на почасовых). Параметры  $P, D, Q$  аналогичны  $p, d, q$ , но для сезонной компоненты.

Настройка таких моделей требует анализа сезонных коррелограмм. Для криптовалют явно выраженная долгосрочная сезонность может отсутствовать, но, как отмечалось, могут быть недельные или месячные циклы, поэтому SARIMA с соответствующим  $s$  на дневных данных может улучшить точность прогноза.

В реальных приложениях подбор наилучших  $p, d, q, P, D, Q$  не всегда тривиален – визуальный анализ ACF/PACF затруднен при сложных структурах данных, поэтому используются автоматизированные алгоритмы. Один из наиболее известных – подход, предложенный Р. Хиндманом и Е. Хандакаром [Hyndman, Khandakar, 2008]. Суть алгоритма заключается в следующем.

1. Определение начального дифференцирования  $d$  и  $D$ . Проводится несколько статистических тестов на единичный корень для определения начальных параметров  $d$  и  $D$ .

2. Для инициализации берется упрощенная модель, например  $ARIMA(0, d, 0)(0, D, 0)$  как базовая.

3. С помощью пошагового алгоритма перебираются различные комбинации  $p, q, P, Q$  вокруг начальной модели. Для каждой комбинации оценивается модель и вычисляется информационный критерий. Алгоритм добавляет или убирает по одному лагу AR или MA, оценивая изменение AIC. В итоге выбирается та комбинация, которая дает минимальный AIC (или BIC, по настройке) на обучающем наборе.

Алгоритм Хиндмана – Хандакара существенно ускоряет поиск оптимальной модели ARIMA, что подтверждено эмпирически на множестве рядов [Hyndman et al., 2008]. В контексте криптовалют такой автоподбор удобен, так как экономит время аналитика и позволяет быстро оценить базовые прогнозные модели.

В рамках данного исследования был реализован автоматический подбор параметров SARIMA по алгоритму Хандакара – Хиндмана.

### **3.2. Методы группового учета аргументов (МГУА) и их настройка**

Метод группового учета аргументов – это один из первых алгоритмов автоматического порождения моделей на основе данных, предложенный А.Г. Ивахненко в 1968 г. [Ivakhnenko, 1968]. В процессе обучения алгоритм не только подбирает численные параметры, но и самостоятельно определяет наиболее подходящую структуру итоговой модели. Вместо того, чтобы перед началом обучения ограничивать алгоритм одной моделью, МГУА задает целый класс моделей.

Метод сам определяет и структуру модели (какие переменные и сочетания включить), и ее сложность (число слоев), ориентируясь на принцип баланса сложность/точность: добавление новых слоев продолжается, пока это дает выигрыш на валидации. Данный подход реализует «жадный» перебор функций, поэтому МГУА способен аппроксимировать достаточно сложные нелинейные зависимости.

В рамках данного исследования были реализованы методы МГУА Multi и Ria [Stepashko, 2018].

### **3.3. LSTM**

Решением проблемы затухающих градиентов стала архитектура Long Short-Term Memory (LSTM), предложенная Ш. Хохрейтером и Ю. Шмидхубером [Hochreiter, Schmidhuber, 1997]. LSTM – это особый вид рекуррентной сети, внедряющей механизм управляемой памяти через так называемые врата и внутренние состояния. Благодаря своему устройству LSTM-ячейка способна долго хранить важную информацию: например, если определенный паттерн на множестве предыдущих шагов подсказывает будущий рост, LSTM может через состояние  $C_t$  пронести этот сигнал десятки и сотни шагов, что невозможно для простой рекуррентной нейронной сети. LSTM показали свою эффективность в прогнозировании временных рядов, особенно финансовых, где важную роль играет долговременная память (например, длительный бычий тренд или циклы), а также в захвате сложных неравномерностей в данных.

### **3.4. Трансформер**

Архитектура трансформера – это одна из самых значимых инноваций в области глубокого обучения, предложенная в работе [Vaswani et al., 2017] в 2017 г., которая произвела революцию в обработке последовательностей данных. Преимущества трансформеров над рекуррентными нейронными сетями и нейронными сетями LSTM для временных рядов:

- 1) всю последовательность можно обрабатывать одновременно, тогда как RNN работают шаг за шагом;
- 2) механизм самовнимания лучше схватывает дальние связи;
- 3) трансформеры более гибкие: их можно обучать на очень больших объемах данных, масштабируя ширину и количество слоев, тогда как обучение столь же глубоких LSTM крайне затруднительно.

Однако у трансформеров есть и проблемная сторона: они требуют много данных и вычислений и могут переобучаться на коротких рядах, если не использовать регуляризацию. В последнее время эта проблема решается посредством обучения внутри контекста.

Обучение внутри контекста (in-context learning) – это метод, при котором языковая модель обучается решать задачу не через традиционное обновление параметров, а путем предоставления примеров или инструкций в рамках текущего контекста ввода. Модель, не изменяя своих внутренних параметров, использует предоставленные данные в виде последовательности текста для выполнения задачи. Благодаря эффекту суперпозиции, векторному представлению и индуктивным головам трансформера, полученная модель в режиме обучения внутри контекста адаптируется под предоставленные данные на лету, анализируя контекстные подсказки и примерные ответы, что позволяет ей адаптироваться к новым задачам без дополнительного этапа специального обучения [Radford et al., 2017]. Этот подход особенно эффективен в современных языковых моделях, которые могут воспринимать несколько примеров задач в виде текста и использовать их для генерации соответствующих ответов [Radford et al., 2018]. Это означает, что модель может адаптироваться и выполнять задачи, учитывая контекст, в котором она работает, без необходимости отдельного этапа обучения.

Прорыв в области обучения внутри контекста в обработке естественного языка позволил перенести данный навык в область прогнозирования временных рядов и применять предобученные трансформеры для прогнозирования на новых данных без необходимости дообучения. Одним из новейших достижений в этом направлении является модель Chronos, разработанная Amazon [Ansari et al., 2024]. Chronos представляет собой семейство заранее обученных моделей для прогнозирования временных рядов на основе архитектуры трансформера, а точнее, модифицированной архитектуры T5 [Raffel et al., 2019]. Подход Chronos велит рассматривать временной ряд как «текст», составленный из условных «токенов», представляющих значения ряда. Поскольку значения – это непрерывные числа, их переводят в дискретные токены с помощью квантизации и масштабирования [Ansari et al., 2024]. Например, диапазон значений нормируется и разбивается на конечное число интервалов, каждому интервалу сопоставляется токен (целое число). Исходный временной ряд  $y_1, y_2, \dots, y_t$  преобразуется в последовательность токенов  $z_1, z_2, \dots, z_t$ . Далее применяется стандартный трансформер для языковых последовательностей: модель обучается предсказывать продолжение последовательности токенов с помощью few-shot learning<sup>2</sup>.

---

<sup>2</sup> Few-shot обучение – это метод машинного обучения, при котором модель способна выполнять новую задачу после того, как запрос к ней был предоставлен с минимальным количеством обучающих примеров. В отличие от традиционного подхода, где для эффективного обучения требуются большие объемы данных, few-shot обучение позволяет модели обобщать и адаптировать свои знания на основе всего нескольких примеров (обычно от одного до нескольких десятков). Этот подход

Amazon обучила данную модель на десятках публично доступных наборах данных временных рядов, а также на искусственных данных, синтезированных другими моделями для разнообразия. Результатом явилась большая модель для временных рядов, подобная языковым моделям для текста. Данная модель может применяться к новым рядам с небольшой донастройкой (few-shot learning) на конкретном ряде. В рамках данного исследования была реализована именно эта архитектура и подготовлена реализация запросов категории few-shot для ее обучения.

### 3.5. Масштабирование данных и многошаговый прогноз

В современной практике прогнозирования временных рядов с использованием методов машинного обучения принято обучать модели на задачу одношагового предсказания [Marcellino et al., 2006]. Это означает, что при наличии, например, дневных данных модель оптимизирована для прогнозирования следующего дня, а не сразу нескольких шагов вперед. Однако при необходимости получения прогнозов на несколько шагов возникает фундаментальная проблема: стандартный рекурсивный подход, при котором результат предыдущего шага используется как вход для следующего, приводит к экспоненциальному накоплению ошибок.

#### 3.5.1. Рекурсивный прогноз

При рекурсивном прогнозировании каждая ошибка, допущенная на одном шаге, транслируется в последующие предсказания. Если  $\varepsilon_i$  – ошибка прогноза на момент  $i$ , то прогноз на  $i + 1$  вычисляется с учетом  $\varepsilon_i$  в качестве входного сигнала. При наличии автокорреляции ошибок эта ошибка не случайна, а может сохранять свою структуру, что приводит к ее систематическому накоплению.

При условии стационарности предполагается, что

$$(1) \quad \text{Var}(\varepsilon_i) = \sigma^2, \text{Cov}(\varepsilon_i, \varepsilon_j) = \rho^{|i-j|} \sigma^2,$$

где  $\rho$  – коэффициент автокорреляции между ошибками. Обозначим суммарную ошибку за  $n$  шагов как

$$(2) \quad S = \sum_{i=1}^n \varepsilon_i.$$

Тогда, используя свойства дисперсии суммы случайных величин, получаем

$$(3) \quad \text{Var}(S) = n\sigma^2 + 2\sigma^2 \sum_{1 \leq i < j \leq n} \rho^{|i-j|}.$$

---

особенно полезен в ситуациях, где данных для обучения недостаточно, но от модели требуется высокая точность и способность к переносу знаний на новые задачи.

Чтобы упростить двойную сумму, сделаем замену переменной: пусть  $k = i - j$ . Тогда для каждого фиксированного  $k$  (от 1 до  $n$ ) число пар  $(i, j)$  с разностью  $k$  будет равно  $n - k$ . Следовательно,

$$(4) \quad \sum_{1 < i < j < n} \rho^{|i-j|} = \sum_{k=1}^{n-1} (n-k) \rho^k.$$

Таким образом, окончательная форма дисперсии накопленной ошибки представляется в виде

$$(5) \quad \text{Var}\left(\sum_{i=1}^n \varepsilon_i\right) = \sigma^2 \left( n + 2 \sum_{k=1}^{n-1} (n-k) \rho^k \right),$$

что демонстрирует экспоненциальное расширение доверительного интервала прогноза с увеличением горизонта. Такой эффект особенно критичен для моделей, обученных на одношаговый прогноз, где ошибка одного шага может быстро перерасти в существенную неточность на дальнем горизонте.

### 3.5.2. Масштабируемый прогноз

Чтобы минимизировать эффект накопления ошибок, автором предложено прибегнуть к альтернативной стратегии, называемой масштабируемым прогнозированием. Суть подхода заключается в агрегировании исходного временного ряда по интервалу, равному требуемому горизонту прогноза. Таким образом, вместо последовательного предсказания на один шаг вперед модель обучается на агрегированных данных, что позволяет напрямую получать прогнозы на нужный промежуток времени. Для агрегирования временного ряда рассматриваются три основных варианта.

1. Агрегирование по среднему значению. При таком подходе значения исходного ряда на каждом интервале заменяются их арифметическим средним. Это позволяет сгладить высокочастотные колебания, однако может привести к потере локальных особенностей динамики ряда.

2. Агрегирование по медиане. Замена значений ряда медианой интервала обладает большей устойчивостью к выбросам по сравнению со средним, что обеспечивает более стабильный прогноз при наличии аномальных значений.

3. Прореживание (выбор последнего значения интервала). В этом случае для каждого интервала прогнозируется значение, соответствующее концу интервала. Такой метод позволяет сохранить наиболее актуальные изменения динамики, однако он менее устойчив к случайным флуктуациям.

Агрегирование временного ряда приводит к изменению его статистических свойств. С одной стороны, применение операторов среднего или медианы позволяет уменьшить дисперсию случайных шумов и, соответственно, снизить автокорреляцию ошибок. С другой стороны, метод агрегации вводит собственное смещение, которое может влиять на точность прогноза. При обучении модели на агрегированных данных дисперсия ошибки прогнозирования будет связана не только с исходной ошибкой модели, но и с вариацией агрегирующего оператора.

Математически можно рассматривать процесс агрегирования как применение сверточного оператора  $A$  к исходному ряду  $X_t$ , где агрегированное значение

$$(6) \quad \tilde{X}_k = A(X_t, X_{t+1}, \dots, X_{t+H-1})$$

для интервала длиной  $H$  на  $k$ -ом интервале. Прогнозируя непосредственно  $X_{k+1}$ , мы фактически минимизируем ошибку по функции потерь, адаптированной к агрегированному ряду, что позволяет снизить экспоненциальный рост ошибок в рекурсивном подходе.

Таким образом, выбор стратегии многошагового прогнозирования (рекурсивного или масштабируемого) зависит от компромисса между сохранением детальной динамики и снижением накопления ошибок. Агрегация временного ряда посредством вычисления среднего, медианы или выбора последнего значения интервала позволяет адаптировать модель к прогнозированию на заданный горизонт, уменьшая автокорреляцию ошибок и расширяя доверительных интервалов.

#### 4. Прогнозирование доходности криптовалют: эмпирический эксперимент

В данном разделе представлены дизайн и результаты экспериментов по тестированию алгоритмов прогноза отдельных криптовалют на разные горизонты прогноза в условиях масштабирования и без него. Все скрипты, использованные для проведения вычислительных экспериментов и получения представленных в статье результатов, размещены и доступны в репозитории [https://github.com/Shkanov/crypto\\_experiments\\_models](https://github.com/Shkanov/crypto_experiments_models).

*Эмпирическая стратегия исследования.* Подходы, используемые для обучения моделей и прогнозирования динамики криптовалют:

- 1) нейронная сеть LSTM (далее – LSTM);
- 2) SARIMA. Автоподбор SARIMA моделей по алгоритму Хандакара – Хиндмана;
- 3) трансформер Chronos от Amazon в режиме few-shot learning (далее – Transformer);
- 4) МГУА Multi (далее – GMDH1);
- 5) МГУА Ria (далее – GMDH2).

Для модели SARIMA подбор гиперпараметров осуществлялся автоматически с использованием алгоритма Хандакара – Хиндмана [Hyndman, Khandakar, 2008]. В рамках этого подхода перебирались значения параметров  $(p, d, q)$  и  $(P, D, Q, s)$  с целью минимизации значения информационного критерия (AIC). Для каждой криптовалюты были выбраны наиболее подходящие параметры на обучающей выборке, обеспечивающие наилучшие прогнозные характеристики.

В рамках группы методов машинного обучения и глубокого обучения были протестированы различные подходы, включая полносвязные нейронные сети, метод опорных векторов, ансамблевые методы (случайный лес и градиентный бустинг), а также архитектура LSTM. Оценка качества моделей проводилась с использованием блочной кросс-валидации, учитывающей временную структуру данных. По результатам сравнения на валидационных выборках наилучшие результаты показала модель LSTM, продемонстрировавшая минимальные значения ошибок прогноза (MAPE и RMSE) по большинству криптова-

люот и горизонтов. В связи с этим в настоящем исследовании в качестве представителя глубоких обучающих моделей используется именно LSTM. Для модели LSTM гиперпараметры подбирались с помощью блочной кросс-валидации (с учетом времени) на тренировочной выборке с целью минимизации ошибки прогноза по метрике MAPE. Были протестированы различные архитектуры и режимы регуляризации. Поиск оптимальных гиперпараметров осуществлялся жадным поиском по сетке. Наиболее оптимальными оказались и впоследствии использовались следующие настройки: число скрытых нейронов – 64; количество LSTM-слоев – 2; функция активации – гиперболический тангенс; dropout – 0,2; оптимизатор – Adam; скорость обучения – 0,001; размер батча – 32; количество эпох – 100 с использованием ранней остановки по валидационной ошибке.

Методы GMDH Multi и GMDH Ria (соответственно GMDH1 и GMDH2) реализуют подход к построению модели на основе самоорганизации и отсеивания неэффективных регрессионных узлов. Поиск оптимальных гиперпараметров осуществлялся жадным поиском по сетке с помощью блочной кросс-валидации на тренировочной выборке (с учетом времени). Наиболее эффективными в наших экспериментах для обоих методов оказались следующие настройки: квадратичный полином (второй степени), позволяющий выявлять нелинейные зависимости без излишней сложности; максимальная глубина модели (уровни слоев) – 4 уровня (компромисс между выразительностью и устойчивостью к шуму); максимальное число узлов на уровне – до 50.

Для модели на основе трансформера (Chronos) был реализован подход *few-shot learning* без явного этапа дообучения. Для генерации прогнозов в модели Chronos использовалась стохастическая схема семплирования с тремя независимыми траекториями (*num samples* = 3) и температурой = 1,0, соответствующей исходному распределению вероятностей модели. Выбор следующего значения ограничивался 50 наиболее вероятными вариантами (*topK* = 50) без дополнительного усечения по вероятностной массе (*topP* = 1,0), что обеспечивает устойчивость прогнозов при сохранении их стохастического характера. Данные гиперпараметры были получены посредством жадного поиска по сетке с использованием блочной кросс-валидации на тренировочной выборке.

Базу для проведения экспериментов представляют временные ряды 13 криптовалют. Они были отобраны из списка в 50 известных криптовалют по размеру их капитализации на момент проведения исследования (ноябрь 2024 г.). Все временные ряды – дневные данные на интервале от 3 до 10 лет. Данные покрывают интервалы стабильности и высокой волатильности. В табл. 1 представлена статистика используемых данных.

Данные делились на тренировочную, валидационную и тестовую части в пропорции 70/15/15. Разбиение выполнялось по времени, без утечки информации из будущего. Также применялась блочная кросс-валидация для отбора гиперпараметров.

Для обеспечения стационарности и корректности применения методов машинного обучения все исходные ценовые ряды криптовалют были трансформированы в логарифмические доходности по формуле:

$$y_t = \log\left(\frac{p_t}{p_{t-1}}\right),$$
 где  $p_t$  – цена актива в момент времени  $t$ .

Такая трансформация позволяет устранить эффект экспоненциального роста цен и приводит ряды к приближенной стационарности, что является необходимым условием для большинства прогнозных моделей.

Таблица 1.

## Входные данные криптовалют для экспериментов

Код крипто- валюты	Крипто- валюта	Начало периода	Конец периода	Число наблюдений		
				1- дневных	7- дневных	30- дневных
ADA	Cardano	2017-11-09	2024-11-25	1000	368	86
BNB	BNB	2017-11-09	2024-11-25	1000	368	86
BTC	Bitcoin	2014-11-25	2024-11-25	1000	522	122
DOGE	Dogecoin	2017-11-09	2024-11-25	1000	368	86
DOT	Polkadot	2020-08-20	2024-11-25	1000	223	52
ETH	Etherium	2017-11-09	2024-11-25	1000	368	86
LTC	Litecoin	2014-11-26	2024-11-25	1000	522	122
MATIC	MATIC	2019-04-28	2024-11-25	1000	292	68
SHIB	Shiba Inu	2020-08-01	2024-11-25	1000	226	53
SOL	Solana	2020-04-10	2024-11-25	1000	242	57
TON	Toncoin	2020-08-29	2024-11-25	1000	222	52
TRX	TRON	2017-11-09	2024-11-25	1000	368	86
XRP	Ripple	2017-11-09	2024-11-25	1000	368	86

После построения прогноза логарифмических доходностей на заданный горизонт полученные значения преобразуются обратно в уровни цен путем экспоненцирования и накопления приростов. Это позволяет интерпретировать результаты прогноза в терминах будущих цен, что удобно для прикладных задач, таких как оценка уровней поддержки/сопротивления или формирование торговых решений.

В качестве бэнчмарка рассматривались результаты прогноза с известным и популярным алгоритмом SARIMA. Дополнительно сравнивались различные режимы масштабирования: среднее, медиана, прореживание.

В качестве метрик качества прогноза используются следующие [Hyndman, Koehler, 2006]:

$$(7) \quad MSE = \frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2,$$

$$(8) \quad RMSE = \sqrt{MSE},$$

$$(9) \quad MAE = \frac{1}{N} \sum_{t=1}^N |\hat{y}_t - y_t|,$$

$$(10) \quad MAPE = \frac{100\%}{N} \sum_{t=1}^N \left| \frac{\hat{y}_t - y_t}{y_t} \right|,$$

$$(11) \quad R^2 = 1 - \frac{\frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2}{\frac{1}{N} \sum_{t=1}^N (\bar{y}_t - y_t)^2}.$$

В табл. 2 представлены сегменты экспериментов для одношаговых прогнозов. Всего было проведено 455 одношаговых экспериментов.

Таблица 2.

## Сегменты экспериментов для одношаговых прогнозов

Алгоритмы	Количество криптовалют	Режим масштабирования	Шаг	Общее число экспериментов
5 алгоритмов	13	1	1 день	65
5 алгоритмов	13	3	7 дней	195
5 алгоритмов	13	3	30 дней	195

В табл. 3 представлены сегменты экспериментов для сравнения многошагового рекурсивного прогноза и многошагового масштабируемого прогноза. Всего было проведено 40 экспериментов.

Таблица 3.

## Сегменты экспериментов для сравнения рекурсивного и масштабируемого прогнозов

Алгоритмы	Количество криптовалют	Шаг	Горизонт	Режимы	Итого
5 алгоритмов	1	1 день	7 дней	3 масштабируемых и 1 рекурсивный	20
5 алгоритмов	1	1 день	30 дней	3 масштабируемых и 1 рекурсивный	20

Все дальнейшие эксперименты поделены на группы:

1. Сравнение качества прогнозирования динамики криптовалют вышеперечисленными методами на горизонте прогнозирования 1, 7 и 30 дней (три группы).

2. Сравнение качества прогнозирования при применении рекурсивного прогноза и масштабируемого прогноза на 7- и 30-дневном горизонте (две группы).

*Сравнение качества прогнозирования динамики криптовалют на горизонтах прогнозирования 1, 7 и 10 дней.* В данной серии экспериментов рассматривались следующие горизонты прогноза: 1, 7, 30 дней. На каждом горизонте для каждой криптовалюты выбирались алгоритмы, обеспечивающие лучшие и худшие прогнозы с использованием всех указанных выше мер. Результаты рассмотрения с мерой MAPE показаны в табл. 4. Применение других мер показали результаты, совпадающие с представленными.

**Таблица 4.**

**Сравнение 5 алгоритмов на 13 криптовалютах в мере MAPE  
на горизонте 1, 7, 30 дней**

Крипто-валюта	1-дневный прогноз		7-дневный прогноз		30-дневный прогноз	
	2 худших алгоритма	2 лучших алгоритма	2 худших алгоритма	2 худших алгоритма	2 лучших алгоритма	2 худших алгоритма
ADA	LSTM, SARIMA	GMDH1, GMDH2	LSTM, Transformer	SARIMA, GMDH1	LSTM, SARIMA	Transformer, GMDH2
BNB	LSTM, Transformer	SARIMA, GMDH2	LSTM, Transformer	GMDH1, GMDH2	LSTM, SARIMA	Transformer, GMDH1
BTC	LSTM, Transformer	SARIMA, GMDH2	LSTM, Transformer	SARIMA, GMDH2	LSTM, GMDH1	SARIMA, Transformer
DOGE	LSTM, SARIMA	GMDH1, GMDH2	LSTM, GMDH1	SARIMA, GMDH2	LSTM, Transformer	GMDH1, GMDH2
DOT	LSTM, Transformer	GMDH1, GMDH2	LSTM, GMDH2	SARIMA, Transformer	Недостат. данных	Недостат. данных
ETH	LSTM, Transformer	SARIMA, GMDH2	LSTM, Transformer	SARIMA, GMDH2	LSTM, SARIMA	Transformer, GMDH1
LTC	LSTM, Transformer	GMDH1, GMDH2	LSTM, Transformer	GMDH1, GMDH2	LSTM, Transformer	GMDH1, GMDH2
MATIC	LSTM, SARIMA	GMDH2, Transformer	LSTM, Transformer	GMDH1, GMDH2	LSTM, GMDH1	SARIMA, Transformer
SHIB	LSTM, Transformer	SARIMA, GMDH2	LSTM, SARIMA	GMDH1, GMDH2	Недостат. данных	Недостат. данных
SOL	LSTM, Transformer	SARIMA, GMDH2	LSTM, Transformer	GMDH1, GMDH2	LSTM, GMDH1	SARIMA, Transformer
TON	LSTM, Transformer	GMDH1, GMDH2	LSTM, GMDH1	SARIMA, Transformer	Недостат. данных	Недостат. данных
TRX	LSTM, GMDH1	SARIMA, Transformer	LSTM, Transformer	GMDH1, GMDH2	LSTM, GMDH2	SARIMA, Transformer
XRP	Transformer, SARIMA	GMDH1, GMDH2	LSTM, SARIMA	GMDH1, GMDH2	LSTM, Transformer	GMDH1, SARIMA

На рис. 1 представлено сравнение качества прогнозирования доходностей криптовалют различными моделями на горизонтах 1, 7 и 30 дней с включением наивных бенчмарков. В качестве наивных моделей использованы:

- Naive Previous Value, при которой прогноз доходности на следующий период принимается равным доходности предыдущего периода, и
- Naive Mean, при которой прогноз равен среднему значению доходностей за 7 предыдущих периодов. Эти модели не используют обучения и отражают минимально возмож-

ный уровень прогностической информации, основанный лишь на инерции или усреднении временного ряда.

Столбцы на графике отображают средние значения ошибки прогноза (MAPE), агрегированные по всем криптовалютам и временным окнам, а вертикальные отрезки соответствуют 95-процентным доверительным интервалам для оценки средней ошибки.




Рис. 1. Сравнение прогностической точности моделей с наивными бенчмарками

Сравнение качества прогнозирования на однодневном прогнозе: видно, что, как правило, по качеству прогноза лидируют модели МГУА, реже SARIMA и иногда трансформер. Обе наивные модели – как инерционная (*Naive Previous Value*), так и усредняющая (*Naive Mean*) – демонстрируют более высокую ошибку по сравнению с этими методами, что указывает на наличие краткосрочной предсказуемой структуры в доходностях криптовалют. Модель LSTM, напротив, в среднем уступает не только более продвинутым алгоритмам, но и наивным бенчмаркам, что свидетельствует о ее низкой устойчивости в данной постановке задачи. В целом, SARIMA, оба варианта МГУА и трансформер показывают близкое и конкурентное качество прогнозирования, тогда как наивные модели формируют более слабый базовый уровень точности.

Сравнение качества прогнозирования на 7-дневном прогнозе: выводы для недельного горизонта в целом совпадают с результатами однодневного прогноза. Наиболее успешными по качеству остаются модели МГУА и SARIMA, иногда к ним присоединяется трансформер. Наивные модели демонстрируют более высокую ошибку, особенно инерционная версия, что указывает на ограниченность простых эвристик при прогнозировании накопленных доходностей за неделю. В то же время усредняющая наивная модель приближается по качеству к более сложным алгоритмам, отражая сглаживание шумов при агрегировании доходностей. LSTM вновь оказывается в числе аутсайдеров и существенно уступает как специализированным моделям временных рядов, так и наивным бенчмаркам.

Сравнение качества прогнозирования на 30-дневном прогнозе: при увеличении горизонта прогнозирования лидерство переходит к трансформеру, который в среднем демонстрирует наименьшую ошибку. Модели SARIMA и МГУА остаются конкурентоспособными, но несколько уступают трансформеру по точности. Наивные модели, особенно вариант на основе среднего, заметно приближаются к этим методам по качеству прогноза. При этом LSTM вновь показывает наихудшие результаты и существенно проигрывает как более сложным моделям, так и простым наивным бенчмаркам.

Результаты однодневного, недельного и месячного прогнозов для 13 криптовалют были обобщены следующим образом: для каждого горизонта было подсчитано, сколько

раз каждый алгоритм оказывался лучшим (один из двух) и худшим (один из двух). Применительно к мере MAPE результаты показаны в табл. 5. Применение других мер показали результаты, совпадающие с представленными.

Таблица 5.

**Сравнение 5 алгоритмов на разных горизонтах прогноза  
для 13 криптовалют в мере MAPE**

Алгоритм	Однодневный прогноз, число лучших и худших случаев	Недельный прогноз, число лучших и худших случаев	Месячный прогноз, число лучших и худших случаев
SARIMA	6/4	6/1	5/3
GMDH1	6/1	8/2	5/3
GMDH2	12/0	10/2	3/1
GMDH*	12/1	11/3	6/4
LSTM	0/12	0/13	0/10
Transformer	2/9	2/8	7/3

*Примечание:* в строке (\*) показаны суммарные результаты для обоих алгоритмов GMDH1 и GMDH2.

Резюмируем практические выводы:

- для однодневного и недельного прогнозов лучший результат показывает нейроподобный алгоритм GMDH2 (12/0 и 10/2 соответственно), и второй результат показывает комбинаторный алгоритм GMDH1 (6/1 и 8/2 соответственно);
- для месячного прогноза лучший результат показывает трансформер (7/3), и второй результат показывают комбинаторный алгоритм GMDH1 (5/3) и SARIMA (5/3);
- рекуррентная нейросеть LSTM всегда оказывается среди худших алгоритмов.

GMDH2 является устойчивым лидером для однодневных и 7-дневных прогнозов. Трансформер лидирует на 30-дневных прогнозах, при этом иногда остается в числе худших. Однако, как было показано в предыдущих разделах, отрыв трансформера от остальных моделей незначителен. Обратная картина наблюдается с LSTM.

Также стоит подчеркнуть, что трансформер в данных экспериментах применялся в режиме обучения внутри контекста (few-shot learning), без стадии обучения на тренировочных данных и без соответствующих вычислительных затрат. Обучение произошло внутри контекста, в моменте вывода модели. Это очень важное преимущество данного метода.

#### 4.1. Сравнение многошаговых прогнозов на 7-дневных данных


В данной серии экспериментов исследовалось качество трех способов масштабирования, которые использовались для сведения многошагового прогноза к одношаговому на 7-дневном горизонте. Точность такого прогноза сравнивались с точностью прогноза при применении традиционной рекурсии. Результаты представлены в табл. 6.

Таблица 6.

**Точность прогноза на 7-дневном горизонте в мере MAPE  
с использованием традиционной рекурсии и масштабирования**

Алгоритм	Рекурсия	Масштабирование		
		среднее	медиана	прореживание
SARIMA	0,03	0,05	0,06	0,06
GMDH1	0,05	0,05	0,05	0,06
GMDH2	0,05	0,05	0,05	0,06
LSTM	0,32	0,15	0,24	0,15
Трансформер	0,05	0,05	0,06	0,07

Для наглядности результаты представлены в виде графика на рис. 2.



**Рис. 2.** Сравнение рекурсивного и масштабируемых многошаговых прогнозов на 7-дневном горизонте

Рекурсия имеет преимущество перед масштабированием только с алгоритмом SARIMA. При этом ошибка при прогнозе с рекурсией в 1,5–2 раза меньше, чем при масштабировании, но все ошибки оказываются весьма малыми. Масштабирование по среднему и медианному значениям дает практически одинаковые результаты для алгоритмов GMDH и трансформер. Масштабирование прореживанием практически всегда уступает двум другим вариантам.

#### 4.2. Сравнение многошаговых прогнозов на 30-дневных данных

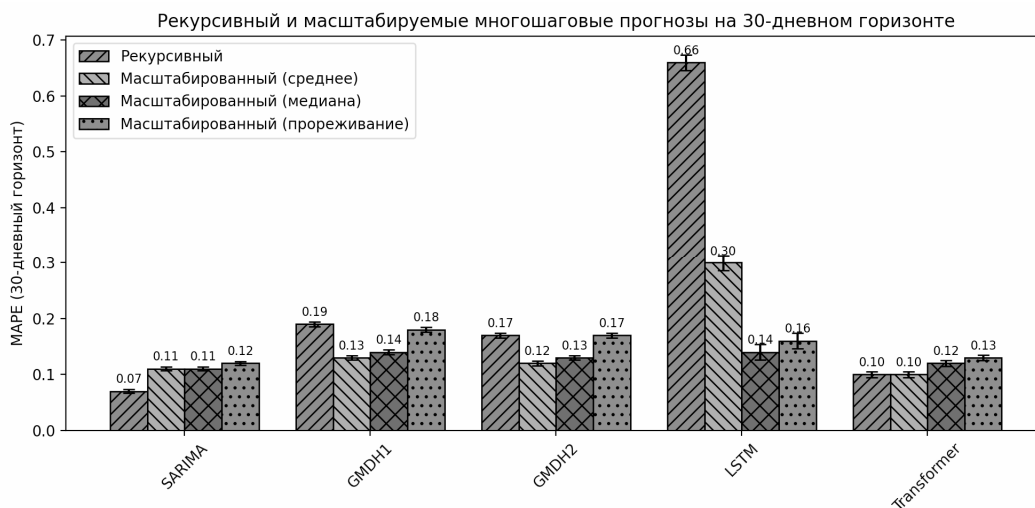
В данной серии экспериментов исследовалось качество трех способов масштабирования, которые использовались для сведения многошагового прогноза к одношаговому на 30-дневном горизонте прогноза. Точность такого прогноза вновь сравнивались с точностью прогноза при применении традиционной рекурсии. Результаты представлены в табл. 7.

Таблица 7.

**Точность прогноза на 30-дневном горизонте в мере MAPE с использованием традиционной рекурсии и масштабирования**

Алгоритм	Рекурсия	Масштабирование		
		среднее	медиана	прореживание
SARIMA	0,07	0,11	0,11	0,12
GMDH1	0,19	0,13	0,14	0,18
GMDH2	0,17	0,12	0,13	0,17
LSTM	0,66	0,30	0,14	0,16
Трансформер	0,10	0,10	0,12	0,13

Для наглядности результаты представлены в виде графика на рис. 3.



**Рис. 3.** Сравнение рекурсивного и масштабируемых многошаговых прогнозов на 30-дневном горизонте

Выводы по полученным результатам совпадают с выводами по 7-дневному прогнозу. Одношаговый масштабируемый прогноз практически всегда лучше многошагового рекурсивного прогноза, кроме SARIMA. Рекурсивный многошаговый прогноз приводит к накоплению ошибок, что снижает качество прогноза.

## 5. Заключение

Данное исследование было направлено на сравнительный анализ современных методов прогнозирования криптовалютных доходностей с фокусом на моделях временных рядов. Был проведен обзор существующей литературы и методов, включая классические статистические подходы, методы машинного обучения, нейросетевые архитектуры, метод группового учета аргументов (МГУА), а также гибридные и ансамблевые модели. Точность прогноза существенно зависит от характеристик данных, горизонта прогноза, информативности признаков и способа агрегации информации. Отдельное внимание было уделено ограничению универсальности моделей: не существует алгоритма, стабильно превосходящего альтернативы на всех активах и при всех условиях.

Далее была описана методология эмпирического исследования, в котором сравнительный анализ производился на 13 криптовалютах с разными горизонтами прогноза (1, 7 и 30 дней). Были реализованы и протестированы четыре группы моделей: SARIMA, LSTM, GMDH (в двух вариантах) и трансформер (Chronos от Amazon). Для оценки точности использовалась метрика MAPE, а также сравнены подходы к многошаговому прогнозированию: традиционный рекурсивный и масштабируемый (агрегирование по среднему, медиане, прореживанию). Подход был построен на единообразной обработке данных, автоматическом подборе гиперпараметров и учете сезонности, что повысило сопоставимость результатов.

Результаты экспериментов на различных горизонтах прогнозирования:

- для однодневного прогноза на краткосрочном горизонте модели МГУА (особенно Ria) показали наилучшие результаты, тогда как LSTM стабильно демонстрировал наихудшие показатели;
- для 7-дневного прогноза тенденция сохраняется. МГУА лидируют, подтверждая свою устойчивость при прогнозировании на неделю, а LSTM вновь оказывается на последнем месте. При этом применение масштабирования (усреднение и медиана) дает результаты лучше рекурсивного прогноза, за исключением SARIMA, где рекурсия имеет небольшое преимущество;
- для 30-дневного прогноза, т.е. при увеличении горизонта прогнозирования, наблюдается переход лидерства к трансформеру, хотя SARIMA и МГУА остаются конкурентоспособными. При этом абсолютные ошибки существенно выше, что отражает естественную сложность долгосрочного прогнозирования в условиях высокой волатильности доходностей криптовалют. Данный факт показывает, что трансформер применимым в долгосрочном прогнозе, что особенно ценно в условиях отсутствия вычислительных и временных затрат на тренировку модели, так как трансформер составлял прогнозы в режиме обучения внутри контекста.

Эксперименты с многошаговыми прогнозами показали, что рекурсивный подход приводит к накоплению ошибок, особенно заметному на более длительном горизонте (30 дней). Методы масштабирования, особенно при использовании средних и медианных

значений, позволяют снизить эту ошибку, обеспечивая более стабильные результаты. При этом метод прореживания оказался менее эффективным по сравнению с другими вариантами масштабирования.

Для однодневного и 7-дневного анализа предпочтительны модели МГУА, тогда как для 30-дневных прогнозов оптимальными оказываются модели на основе трансформера. SARIMA остается стабильным бенчмарком, особенно на среднесрочных интервалах. При этом применение методов масштабирования существенно улучшает качество многошагового прогнозирования, снижая эффект накопления ошибок.

Практическая применимость рассмотренных в работе моделей была дополнительно проверена в последующем исследовании, посвященном портфельной оптимизации на основе прогнозируемых доходностей [Шканов, 2025]. В указанной работе прогнозы, полученные с использованием SARIMA, GMDH, LSTM и трансформерных моделей в текущем исследовании, использовались в качестве входных сигналов для построения инвестиционных портфелей и проведения бэктест-симуляций на исторических данных. Портфели формировались путем оптимизации весов активов на каждом шаге в соответствии с заданными критериями риска и доходности. Полученные на исторических данных результаты показывают, что прогнозные сигналы, полученные с помощью моделей временных рядов, могут быть успешно преобразованы в реализуемые торговые стратегии, обеспечивая улучшение соотношения риск – вознаграждение по сравнению с наивными подходами (такими как равновзвешенные или buy-and-hold портфели). Таким образом, эмпирический анализ точности прогнозирования, представленный в данной статье, имеет прямую прикладную интерпретацию в задачах управления портфелем и алгоритмической торговли.

Полученные результаты также подтверждают, что выбор модели прогнозирования должен учитывать как временной горизонт анализа, так и особенности структуры данных криптовалютных рынков. Простые статистические модели сохраняют свою актуальность в качестве бенчмарков, тогда как современные методы машинного обучения и трансформерные архитектуры могут обеспечивать преимущества на более длинных горизонтах прогнозирования. Это свидетельствует о целесообразности комбинирования различных подходов и дальнейшего исследования гибридных моделей, объединяющих статистические методы и современные архитектуры глубокого обучения.

\* \*  
\*

#### СПИСОК ЛИТЕРАТУРЫ

Костин Н.А., Белоусов А.А. Труды Международной научно-технической конференции [Конференция]. Реализация и исследования решения задачи прогнозирования динамики курса криптовалют с помощью моделей авторегрессии. Издательство Самарского научного центра РАН, 2022. С. 170–173.

Шканов Б.А. Факторы ценообразования криптовалют // Вестник Самарского университета. Экономика и управление. 2024. №15 (1). С. 225–237.

Шканов Б.А. Комплексный подход к оптимизации инвестиционного портфеля на основе современных методов математического моделирования // п-Economy. 2025. №18 (2). С. 179–201.

*Aggarwal A., Gupta I., Garg N., Goel A.* Deep Learning Approach to Determine the Impact of Socio Economic Factors on Bitcoin Price Prediction. 12<sup>th</sup> International Conference on Contemporary Computing (IC3). 2019. P. 1–5.

*Albariqi R., Winarko E.* Prediction of Bitcoin Price Change using Neural Networks. International Conference on Smart Technology and Applications (ICoSTA). 2020. P. 1–4.

*Ansari A.F., Stella L., Turkmen C., Zhang X., Mercado P., Shen H., Shchur O., Rangapuram S.S., Arango S.P., Kapoor S., Zschiegner J., Maddix D.C., Wang H., Mahoney M.W., Torkkola K., Wilson A.G., Bohlke-Schneider M., Wang Y.* Chronos: Learning the Language of Time Series // Transactions on Machine Learning Research. 2024.

*Bayburin B., Mogilev P., Alexandrov M., Cardiff J., Koshulko O.* Joint Mid-Term Forecast of Cryptocurrencies in Technique of Inductive Modelling (on Example of XRP, Waves, ETH). 31<sup>st</sup> Conference of FRUCT Association. 2020.

*Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M.* Time Series Analysis: Forecasting and Control. 5<sup>th</sup> ed. John Wiley and Sons Inc. 2015. Vol. 5.

*Chen M., Narwal N., Schultz M.* Predicting Price Changes in Ethereum // International Journal of Computation Science and Engineering. 2019.

*Chen T., Guestrin C.* XGBoost: A Scalable Tree Boosting System. The 22<sup>nd</sup> ACM SIGKDD International Conference. 2016. P. 785–794.

*Herremans D., Low K.* Forecasting Bitcoin Volatility Spikes from Whale Transactions and CryptoQuant Data Using Synthesizer Transformer Models [Report]. 2022.

*Hochreiter S., Schmidhuber J.* Long Short-Term Memory // Neural Computation. 1997. 9(8). P. 1735–1780.

*Hou A.J., Wang W., Chen C.Y., Härdle W.K.* Pricing Cryptocurrency Options // Journal of Financial Econometrics. 2020. 18(2). P. 250–279.

*Hyndman R.J., Khandakar Y.* Automatic Time Series Forecasting: The Forecast Package for R // Journal of Statistical Software. 2008. 27(3). P. 1–22.

*Hyndman R.J., Koehler A.B.* Another Look at Measures of Forecast Accuracy // International Journal of Forecasting. 2006. 22(4). P. 679–688.

*Ivakhnenko A.G.* The Group Method of Data Handling – a Rival of the Method of Stochastic Approximation // Soviet Automatic Control. 1968. 13 (3). P. 43–55.

*Ji S., Kim J., Im H.* A Comparative Study of Bitcoin Price Prediction Using Deep Learning // Mathematics. 2019. 7(10). P. 898.

*John D., Binnewies S., Stantic B.* Cryptocurrency Price Prediction Algorithms: A Survey and Future Directions [Report]. 2024.

*Khan F., Khan F., Shaikh P.* Forecasting Returns Volatility of Cryptocurrency by Applying Various Deep Learning Algorithms // Future Business Journal. 2023. 9.

*Kilimci H., Yildirim M., Kilimci Z.* The Prediction of Short-Term Bitcoin Dollar Rate (BTC/USDT) Using Deep and Hybrid Deep Learning Techniques. 5<sup>th</sup> International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). 2021. P. 633–637.

*Kilimci Z.* Sentiment Analysis Based Direction Prediction in Bitcoin using Deep Learning Algorithms and Word Embedding Models // International Journal of Intelligent Systems and Applications. 2020. 8. P. 60–65.

*Mahfooz A., Phillips J.* Conditional Forecasting of Bitcoin Prices Using Exogenous Variables // IEEE Access. 2024. 1. P. 1.

*Marcellino M., Stock J.H., Watson M.W.* A Comparison of Direct and Iterated Multistep AR Methods for Forecasting Macroeconomic Time Series // Journal of Econometrics. 2006. 135(1–2). P. 499–526.

*McNally S., Roche J., Caton S.* Predicting the Price of Bitcoin Using Machine Learning. 26<sup>th</sup> Euromicro International Conference on Parallel, Distributed and Network-based Processing (PDP). 2018. P. 339–343.

*Pabuçcu H., Ongan S., Ongan A.* Forecasting the Movements of Bitcoin Prices: An Application of Machine Learning Algorithms [Report]. 2023.

- Pečiulis T., Ahmad N., Menegaki A.N., Bibi A.* Forecasting of Cryptocurrencies: Mapping Trends, Influential Sources, and Research Themes // *Journal of Forecasting*. 2024. 43.
- Radford A., Jozefowicz R., Sutskever I.* Learning to Generate Reviews and Discovering Sentiment. 2017.
- Radford A., Narasimhan K., Salimans T., Sutskever I.* Improving Language Understanding by Generative Pre-Training. 2018.
- Ranco G., Aleksovski D., Caldarelli G., Grčar M., Mozetic I.* The Effects of Twitter Sentiment on Stock Price Returns // *PloS one*. 2015. 10.
- Seifaddini M., Habibdoust A.* Improving Bitcoin Price Prediction Power by Time-Scale Decomposition and GMDH-Type Neural Network: A Comparison of Different Periods and Features // *Journal of Mathematical Modeling (JMM)*. 2023. Vol. 11. № 1.
- Serafini G., Ping Y., Zhang Q., Brambilla M., Wang J., Hu Y., Li B.* Sentiment-Driven Price Prediction of the Bitcoin based on Statistical and Deep Learning Approaches. *International Joint Conference on Neural Networks (IJCNN)*. 2020. P. 1–8.
- Shamshad H., Ullah F., Ullah A., Kebande V.R., Ullah S., Al-Dhaqm A.* Forecasting and Trading of the Stable Cryptocurrencies with Machine Learning and Deep Learning Algorithms for Market Conditions // *IEEE Access* 2023. 2023. 1. P. 99.
- Shkanov B., Alexandrov M.* Social Influence, Market Manipulators, Hardware and Software As New Factors for Cryptocurrency Pricing: A Survey // *Computación y Sistemas*. 2024. 28 (3). P. 1201–1207.
- Singh S., Bhat M.* Transformer-Based Approach for Ethereum Price Prediction Using Crosscurrency Correlation and Sentiment Analysis [Report]. 2024.
- Sridhar S., Sanagavarapu S.* Multi-Head Self-Attention Transformer for Dogecoin Price Prediction. *14<sup>th</sup> International Conference on Human System Interaction (HSI) At: Gdańsk, Poland*. 2021.
- Tan X., Kashef R.* Predicting the Closing Price of Cryptocurrencies: A Comparative Study. *E-Learning and Information Systems. DATA '19: Proceedings of the Second International Conference on Data Science*. 2019. P. 1–5.
- Tandon S., Tripathi S., Saraswat P., Dabas C.* Bitcoin Price Forecasting Using LSTM and 10-fold Cross Validation. *International Conference on Signal Processing and Communication (ICSC)*. 2019.
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A., Kaiser L., Polosukhin I.* Attention Is All You Need. 2017.
- Wu C.H., Lu C.C., Ma Y.F., Lu R.S.* A New Forecasting Framework for Bitcoin Price with LSTM. *IEEE International Conference on Data Mining Workshops (ICDMW)*. 2018.

## Comparison of Modern Methods for Cryptocurrency Return Forecasting with SARIMA Benchmark

Elena Sinelnikova-Muryleva<sup>1</sup>, Bulat Shkanov<sup>2</sup>

<sup>1</sup> The Russian Presidential Academy of National Economy and Public Administration.  
82, build. 1, Vernadsky Avenue, Moscow, 119571, Russian Federation.  
E-mail: e.sinelnikova@ranepa.ru

<sup>2</sup> Careem Technologies.  
United Arab Emirates, Dubai, Media City, Shatha Tower, 38<sup>th</sup> floor, postal code 0000.  
E-mail: bulat.shkanov@mail.ru

This paper presents a comparative analysis of modern methods for forecasting cryptocurrency returns. It considers classical statistical models (SARIMA), machine learning techniques, neural network architectures (LSTM, Transformers), and the Group Method of Data Handling (GMDH). The aim is to identify the strengths and limitations of different approaches in short- and medium-term forecasting.

The empirical analysis is based on time series of 13 major cryptocurrencies over 3 to 10 years. Data were transformed into logarithmic returns, and block cross-validation with automated hyperparameter tuning was applied. Forecasting horizons of 1, 7, and 30 days were examined, along with recursive and scalable multi-step forecasting methods.

Results show that GMDH models achieved the highest accuracy on short-term horizons, while LSTM consistently underperformed. For monthly forecasts, the Chronos Transformer, applied in a few-shot in-context learning regime, outperformed other models. SARIMA remained a reliable benchmark on medium horizons. Scalable approaches reduced error accumulation compared to recursive forecasting.

These findings highlight the absence of a universal algorithm and emphasize the importance of selecting methods according to horizon and analytical objectives.

**Key words:** cryptocurrency return; forecasting; LSTM; GMDH; SARIMA; Transformers; time series.

**JEL Classification:** C51, C53, C55, C58, G17.

*This article was written on the basis of the RANEPA state assignment research programme.*

---

**Elena Sinelnikova-Muryleva** – Leading Researcher.

**Bulat Shkanov** – Independent researcher, Moscow, Russian Federation, Head of Data Science in Careem Technologies.

\* \*  
\*

## References

- Aggarwal A., Gupta I., Garg N., Goel A. (2019) Deep Learning Approach to Determine the Impact of Socio Economic Factors on Bitcoin Price Prediction. *12<sup>th</sup> International Conference on Contemporary Computing (IC3)*, pp. 1–5.
- Albariqi R., Winarko E. (2020) Prediction of Bitcoin Price Change using Neural Networks. *International Conference on Smart Technology and Applications (ICoSTA)*, pp. 1–4.
- Ansari A.F., Stella L., Turkmen C., Zhang X., Mercado P., Shen H., Shchur O., Rangapuram S.S., Arango S.P., Kapoor S., Zschiegner J., Maddix D.C., Wang H., Mahoney M.W., Torkkola K., Wilson A.G., Bohlke-Schneider M., Wang Y. (2024) Chronos: Learning the Language of Time Series. *Transactions on Machine Learning Research*.
- Bayburin B., Mogilev P., Alexandrov M., Cardiff J., Koshulko O. (2020) Joint Mid-Term Forecast of Cryptocurrencies in Technique of Inductive Modelling (on Example of XRP, Waves, ETH). *31<sup>st</sup> Conference of FRUCT Association*.
- Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. (2015) *Time Series Analysis: Forecasting and Control*. 5<sup>th</sup> ed. John Wiley and Sons Inc. Vol. 5.
- Chen M., Narwal N., Schultz M. (2019) Predicting Price Changes in Ethereum. *International Journal of Computation Science and Engineering*.
- Chen T., Guestrin C. (2016) XGBoost: A Scalable Tree Boosting System. *The 22<sup>nd</sup> ACM SIGKDD International Conference*, pp. 785–794.
- Herremans D., Low K. (2022) *Forecasting Bitcoin Volatility Spikes from Whale Transactions and CryptoQuant Data Using Synthesizer Transformer Models* [Report].
- Hochreiter S., Schmidhuber J. (1997) Long Short-Term Memory. *Neural Computation*, 9, 8, pp. 1735–1780.
- Hou A.J., Wang W., Chen C.Y., Härdle W.K. (2020) Pricing Cryptocurrency Options. *Journal of Financial Econometrics*, 18, 2, pp. 250–279.
- Hyndman R.J., Khandakar Y. (2008) Automatic Time Series Forecasting: The Forecast Package for R. *Journal of Statistical Software*, 27, 3, pp. 1–22.
- Hyndman R.J., Koehler A.B. (2006) Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22, 4, pp. 679–688.
- Ivakhnenko A.G. (1968) The Group Method of Data Handling – a Rival of the Method of Stochastic Approximation. *Soviet Automatic Control*, 13, 3, pp. 43–55.
- Ji S., Kim J., Im H. (2019) A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics*, 7, 10, p. 898.
- John D., Binnewies S., Stantic B. (2024) *Cryptocurrency Price Prediction Algorithms: A Survey and Future Directions* [Report].
- Khan F., Khan F., Shaikh P. (2023) Forecasting Returns Volatility of Cryptocurrency by Applying Various Deep Learning Algorithms. *Future Business Journal*, 9.
- Kilimci H., Yildirim M., Kilimci Z. (2021) The Prediction of Short-Term Bitcoin Dollar Rate (BTC/USDT) using Deep and Hybrid Deep Learning Techniques. *5<sup>th</sup> International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, pp. 633–637.
- Kilimci Z. (2020) Sentiment Analysis Based Direction Prediction in Bitcoin Using Deep Learning Algorithms and Word Embedding Models. *International Journal of Intelligent Systems and Applications*, 8, pp. 60–65.
- Kostin N., Belousov A. (2022) Implementation and Research of a Solution for Forecasting Cryptocurrency Exchange Rate Dynamics Using Autoregressive Models. *International Scientific Conference Pro-*

ceedings "Advanced Information Technologies and Scientific Computing", Publishing House of the Samara Scientific Center of the Russian Academy of Sciences, pp. 170–173 (In Russ.)

Mahfooz A., Phillips J. (2024) Conditional Forecasting of Bitcoin Prices Using Exogenous Variables. *IEEE Access*, 1, p. 1.

Marcellino M., Stock J.H., Watson M.W. (2006) A Comparison of Direct and Iterated Multistep AR Methods for Forecasting Macroeconomic Time Series. *Journal of Econometrics*, 135(1–2), pp. 499–526.

McNally S., Roche J., Caton S. (2018) Predicting the Price of Bitcoin Using Machine Learning. *26<sup>th</sup> Euro-micro International Conference on Parallel, Distributed and Network-based Processing (PDP)*, pp. 339–343.

Pabuçcu H., Ongan S., Ongan A. (2023) *Forecasting the Movements of Bitcoin Prices: An Application of Machine Learning Algorithms* [Report].

Pečiulis T., Ahmad N., Menegaki A.N., Bibi A. (2024) Forecasting of Cryptocurrencies: Mapping Trends, Influential Sources, and Research Themes. *Journal of Forecasting*, 43.

Radford A., Jozefowicz R., Sutskever I. (2017) *Learning to Generate Reviews and Discovering Sentiment*.

Radford A., Narasimhan K., Salimans T., Sutskever I. (2018) *Improving Language Understanding by Generative Pre-Training*.

Ranco G., Aleksovski D., Caldarelli G., Grčar M., Mozetic I. (2015) The Effects of Twitter Sentiment on Stock Price Returns. *PloS one*, 10.

Seifaddini M., Habibdoust A. (2023) Improving Bitcoin Price Prediction Power by Time-Scale Decomposition and GMDH-Type Neural Network: A Comparison of Different Periods and Features. *Journal of Mathematical Modeling (JMM)*, 11, 1.

Serafini G., Ping Y., Zhang Q., Brambilla M., Wang J., Hu Y., Li B. (2020) Sentiment-Driven Price Prediction of the Bitcoin based on Statistical and Deep Learning Approaches. *International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8.

Shamshad H., Ullah F., Ullah A., Kebande V.R., Ullah S., Al-Dhaqm A. (2023) Forecasting and Trading of the Stable Cryptocurrencies with Machine Learning and Deep Learning Algorithms for Market Conditions. *IEEE Access* 2023, 1, p. 99.

Shkanov B.A. (2024) Pricing Factors of Cryptocurrencies. *Vestnik of Samara University. Economics and Management*, 15, 1, pp. 225–237. (In Russ.)

Shkanov B.A. (2025) Comprehensive Approach to Portfolio Optimization Based on Modern Mathematical Methods.  *$\pi$ -Economy*, 18 (2), pp. 179–201. (In Russ.)

Shkanov B., Alexandrov M. (2024) Social Influence, Market Manipulators, Hardware and Software As New Factors for Cryptocurrency Pricing: A Survey. *Computación y Sistemas*, 28 (3), pp. 1201–1207.

Singh S., Bhat M. (2024) *Transformer-Based Approach for Ethereum Price Prediction Using Cross-currency Correlation and Sentiment Analysis* [Report].

Sridhar S., Sanagavarapu S. (2021) Multi-Head Self-Attention Transformer for Dogecoin Price Prediction. *14<sup>th</sup> International Conference on Human System Interaction (HSI) At: Gdańsk, Poland*.

Tan X., Kashef R. (2019) Predicting the Closing Price of Cryptocurrencies: A Comparative Study. *E-Learning and Information Systems. DATA '19: Proceedings of the Second International Conference on Data Science*, pp. 1–5.

Tandon S., Tripathi S., Saraswat P., Dabas C. (2019) Bitcoin Price Forecasting Using LSTM and 10-fold Cross Validation. *International Conference on Signal Processing and Communication (ICSC)*.

Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A., Kaiser L., Polosukhin I. (2017) *Attention Is All You Need*.

Wu C.H., Lu C.C., Ma Y.F., Lu R.S. (2018) A New Forecasting Framework for Bitcoin Price with LSTM. *IEEE International Conference on Data Mining Workshops (ICDMW)*.