

# МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В ПРИКЛАДНЫХ ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ДИНАМИЧНО ИЗМЕНЯЮЩИХСЯ ДАННЫХ

DOI: 10.36724/2072-8735-2025-19-8-49-63

**Леохин Юрий Львович,**  
Московский технический университет связи и информатики, Москва, Россия, [y.l.leokhin@mtuci.ru](mailto:y.l.leokhin@mtuci.ru)

**Manuscript received** 07 June 2025;  
**Accepted** 12 July 2025

**Дымкова Светлана Сергеевна,**  
Московский технический университет связи и информатики, Москва, Россия, [s.s.dymkova@mtuci.ru](mailto:s.s.dymkova@mtuci.ru)

**Фатхулин Тимур Джалилевиич,**  
Московский технический университет связи и информатики, Москва, Россия, [t.d.fatkhulin@mtuci.ru](mailto:t.d.fatkhulin@mtuci.ru)

**Ключевые слова:** значение, прогноз, метод, модель, криптовалюта, машинное обучение, алгоритм

В работе рассматривается проблема повышения точности прогнозирования динамично изменяющихся данных на примере курсов криптовалют. Целью работы является исследование и разработка методов машинного обучения, используемых в прикладных задачах для прогнозирования динамично изменяющихся данных. Актуальность работы обусловлена тем, что существующие методы и модели не всегда позволяют достичь достаточной точности и надежности в прогнозировании котировок в условиях высокой волатильности и сложности криптовалютных рынков. Таким образом, имеется потребность в дальнейшем углубленном исследовании и разработке новых подходов и методов для решения этой проблемы. Объектом исследования являются финансовые котировки криптовалют. Предметом исследования являются показатели эффективности методов машинного обучения, используемых для прогнозирования котировок. Для оценки качества предсказаний моделей выбрана метрика Mean Squared Error (MSE - среднеквадратичная ошибка), которая помогает измерять точность модели, выявляя ошибки прогноза. Также предложены дополнительные качественные показатели, такие как верное предсказание точек максимумов и минимумов, что является важным для анализа колебаний цен криптовалют. Модели прогнозирования создавались с использованием библиотеки TensorFlow и графического ускорителя T4. Для оптимизации использовался алгоритм Adam, обучение происходило с применением техники мини-пакетов. Методологической основой работы послужили следующие методы исследования: сравнение, описание, измерение, метод научной абстракции, а также анализ и обобщение. В заключении приведены основные выводы, полученные в результате проведенного исследования.

#### Информация об авторах:

**Леохин Юрий Львович,** Московский технический университет связи и информатики, Ректорат, Проректор по научной работе, профессор, д.т.н., Москва, Россия. [orcid.org/0000-0003-3321-4497](https://orcid.org/0000-0003-3321-4497)

**Дымкова Светлана Сергеевна,** Московский технический университет связи и информатики, к.т.н., Москва, Россия. [orcid.org/0000-0003-1945-9850](https://orcid.org/0000-0003-1945-9850)

**Фатхулин Тимур Джалилевиич,** Московский технический университет связи и информатики, кафедра "Математическая кибернетика и информационные технологии", доцент, к.т.н., Москва, Россия. [orcid.org/0000-0003-0998-1055](https://orcid.org/0000-0003-0998-1055)

#### Для цитирования:

Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д. Методы машинного обучения в прикладных задачах прогнозирования динамично изменяющихся данных // Т-Comm: Телекоммуникации и транспорт. 2025. Том 19. №8. С. 49-63.

#### For citation:

Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, "Machine learning methods in applied problems of forecasting dynamically changing data", T-Comm, 2025, vol. 19, no.8, pp. 49-63. (in Russian)

### Введение

Прогнозирование динамически изменяющихся величин имеет значение для разных областей науки и техники. Так, это может потребоваться в сфере связи, финансов, автомобильного транспорта и т.п. [1, 2, 7, 8, 10].

В оптических транспортных сетях часто требуется спрогнозировать пропускную способность того или иного участка волоконно-оптической линии связи [3, 5, 6]. Особенно важно верно прогнозировать возможность использования ресурсов в программно-конфигурируемых оптических сетях при их мониторинге [4, 7, 8]. Зависимость необходимой полосы пропускания имеется от типа участка линии связи – магистральный и зонный. Значения требуемой пропускной способности изменяется в разное время суток (наибольшие пики пропускной нагрузки на линии связаны с рабочим графиком компаний и организаций), имеется ее зависимость и от месяца года, и от событий, происходящих в тот или иной промежуток времени (например, влияние сезона отпусков). Внедрение новых технологий передачи данных, дающих возможность значительно увеличить пропускную способность каналов связи, также влияет на качество прогнозирования характеристик волоконно-оптических систем передачи [7, 8]. Порой новая технология позволяет на порядок изменить значения прогнозируемых величин, что требует внедрения новых методов прогнозирования. Использование передовых когерентных технологий формирования оптического сигнала, переносящего информацию на скоростях в десятки Гбит/с, как раз заставило значительно пересмотреть методы прогнозирования пропускной способности линий связи [2].

В сфере экономики и финансов прогнозирование значений котировок, индексов, курсов валют имеет первостепенное значение [9, 11]. Причем важно как прогнозирование на ближайшие дни, так и на месяцы вперед. Здесь факторами, влияющими на значение тех или иных величин, служат как естественные для финансовых рынков закономерности, так и внешние непредсказуемые заблаговременно обстоятельства, связанные, например, с вводом санкций или пошлин отдельными государствами или компаниями. Влияние также оказывают и спекулятивные процессы, целью которых служит вброс недостоверной информации для влияния на значения важных экономических показателей в разных отраслях [12]. Также необходимо обеспечить прогнозирование спроса [9, 12]. Он может повлиять на необходимость корректировки прогнозирования других макро и микроэкономических показателей.

Таким образом, при прогнозировании динамически изменяющихся величин важно обращать внимание на их корреляцию с определенными факторами и необходимо правильно подобрать методы для прогнозирования. Долгое время широкое распространение имели методы, основанные на теории вероятности и математической статистике. Они требовали долгого сбора данных для проведения анализа и в настоящих быстро меняющихся условиях потеряли эффективность. К тому же методы аппроксимации, такие как интерполяция или экстраполяция, зачастую не применимы ко многим задачам, связанным с финансовыми рынками. Развитие вычислительной техники, появление высокопроизводительных процессоров позволило начать внедрение мето-

дов, связанных с машинным обучением. Выбрав необходимый для решаемой задачи и предметной области метод машинного обучения и реализующий его алгоритм, появляется возможность создать на его основе модель, которая будет эффективно и точно прогнозировать динамически изменяющиеся величины, в том числе и для финансового сектора. Важно понимать, что разработанная модель будет применима только к определенному типу данных (например, данные о котировках криптовалют, данные о спросе на различные виды товаров) [1, 9, 13]. Это является естественным ограничением, накладываемым на модель прогнозирования. Поиску наиболее подходящих для прогнозирования значений котировок криптовалюты Биткойн посвящено настоящее исследование.

### Постановка задачи исследования

В настоящее время во многих сферах жизни имеется необходимость в прогнозировании значений динамически изменяющихся числовых величин с высокой степенью точности. Одной из таких сфер является экономика, в частности определение трендов курсов криптовалют. Криптовалюты, такие как "Bitcoin", "Ethereum" и другие, стали объектом значительного интереса со стороны инвесторов и трейдеров, благодаря их высокой волатильности и потенциалу для получения высокой прибыли. Однако, в силу сложной и непредсказуемой природы криптовалютных рынков, анализ и прогнозирование их котировок является сложной задачей.

Одной из основных проблем, которую необходимо решить в данном исследовании, является разработка эффективных методов анализа больших данных в области криптовалюты, что позволило бы определять оптимальный портфель инвестиций и прогнозировать котировки. Принимая во внимание низкую предсказуемость изменений, высокую волатильность и сложность моделирования криптовалютных рынков, можно объяснить трудности в прогнозировании и принятии обоснованных инвестиционных решений. Также проблемой является огромный объем данных, собираемых с различных источников, требующий специализированных методов и инструментов для их обработки и анализа.

Актуальность данной темы обусловлена несколькими факторами. Во-первых, криптовалюты становятся все более важным активом на финансовых рынках, привлекая внимание инвесторов и трейдеров. Во-вторых, рост популярности и значимости криптовалют сопровождается высокой волатильностью и непредсказуемостью их ценовых движений, что создает потребность в разработке надежных методов прогнозирования и управления рисками. В-третьих, прогресс в области анализа данных и машинного обучения предоставляет новые возможности для обработки и анализа больших объемов данных, что способствует развитию инновационных подходов к анализу криптовалютных рынков.

Разработка и применение эффективных методов и моделей прогнозирования котировок позволит инвесторам и трейдерам принимать обоснованные решения и управлять рисками. Это может значительно повысить эффективность инвестиционных стратегий в сфере криптовалют и способствовать достижению желаемых финансовых результатов.

Для реализации сформулированной выше цели необходимо решить следующие задачи:

- проанализировать сферу применения криптовалют и определить ее основные характеристики;
- определить требования, влияющие на выбор метода машинного обучения для прогнозирования, и метрики оценки его эффективности;
- исследовать существующие методы анализа и прогнозирования котировок криптовалют, выявить их преимущества и недостатки;
- обосновать выбор модифицируемых методов анализа больших данных в области криптовалют и определить пути по их улучшению;
- разработать алгоритмическое и программное обеспечение, реализующие модифицируемый метод прогнозирования;
- исследовать эффективность разработанной модели прогнозирования на основе анализа исторических данных.

### Теоретические исследования

#### *Анализ сферы применения криптовалют и определение ее основных характеристик*

Под понятием криптовалюты понимается, как правило, цифровой актив, который осуществляет регулирование оборота счетных единиц и регулирование их выпуска с использованием блокчейна. Взаиморасчеты при этом происходят внутри сети с равноправными участниками, или в пиринговой сети [10]. Информация о всех транзакциях в такой сети хранится в блокчейне, который, в свою очередь, представляет собой зашифрованный криптографический распределенный реестр последовательно объединенных в цепь блоков [9]. Первой криптовалютой был "Bitcoin" в блокчейне, созданном в 2008 году [10]. На прогнозировании именно этой криптовалюты, с учетом ее популярности, сосредоточено настоящее исследование.

Рынок криптовалюты представляет собой децентрализованную и цифровую экономическую систему, основанную на использовании криптографии для обеспечения безопасности транзакций и контроля создания новых единиц цифровых активов. Криптовалюты, такие как "Bitcoin", "Ethereum" и другие, функционируют на базе технологии блокчейн, которая является распределенным реестром транзакций, подтверждаемых и поддерживаемых сетью участников [10].

Рынок криптовалюты отличается высокой степенью волатильности и нестабильности, что связано с различными факторами, включая изменения в регулировании, макроэкономической политике, технологических инновациях и др. Криптовалюты не имеют физического обеспечения или центрального регулятора, что добавляет дополнительные сложности и риски в процессе анализа и прогнозирования их котировок.

В силу своей децентрализованной природы, рынок криптовалюты предлагает широкий спектр данных для исследования и анализа. Данные включают информацию о ценах, объемах торгов, трендах, новостных событиях, социальных медиа и других факторах, которые могут оказывать влияние на ценовую динамику и инвестиционные решения.

Прогнозирование котировок имеет важное значение при инвестициях в криптовалюту, поскольку позволяет инвесто-

рам принимать обоснованные решения и достигать более эффективного использования своих ресурсов.

Прогнозирование котировок криптовалюты основано на анализе исторических данных и различных факторов, которые могут влиять на ценовую динамику [9, 13]. Точные прогнозы позволяют оценивать потенциальную доходность и риски инвестиций, дают возможность принимать правильные, подкрепленные информацией, решения, находить оптимальное время для покупки/продажи активов.

Приступая к рассмотрению источников данных об объемах торгов, рыночной капитализации, актуальных ценах, необходимо понимать, что таких источников несколько. Все они дают информацию о различных характеристиках криптовалютных активов.

**1. Биржевые данные.** Чтобы получить информацию о ценах, объемах торгов, временных метках и других связанных параметрах, достаточно обратиться к торговым данным криптовалютных бирж посредством API (Application Programming Interface) [4, 9].

**2. Рыночные данные.** Существуют специализированные платформы и сервисы, которые предоставляют исторические и текущие данные о котировках криптовалютных активов. Данные могут включать цены от различных бирж, объемы торгов, рыночную капитализацию, данные о ликвидности и другие статистические показатели.

**3. Блокчейн данные.** Криптовалюты, такие как "Bitcoin", имеют публичные блокчейны, которые хранят информацию о каждой транзакции и состоянии сети. Данные могут быть использованы для получения информации о транзакциях, адресах кошельков, временных метках и других характеристиках сети [10].

**4. Социальные медиа и новостные источники.** Социальные медиаплатформы, форумы и новостные порталы могут быть источниками информации о криптовалютах. Анализ текстовых данных из таких источников может помочь в определении, например, новостных событий, которые могут влиять на рынок.

Фильтрация данных также важный этап в анализе данных криптовалюты. При работе с большим объемом данных неизбежно возникают проблемы, связанные с неточностями, ошибками и выбросами. Целью фильтрации данных является удаление или исправление таких проблемных наблюдений, чтобы обеспечить надежность и качество данных для дальнейшего анализа [9, 14, 15]. Процесс фильтрации включает следующие шаги [14, 15].

**Шаг 1. Удаление дубликатов.** Дубликаты в данных могут возникать из-за ошибок или повторных записей. Идентификация и удаление дубликатов позволяет избежать искажений в анализе и обеспечить единообразие данных.

**Шаг 2. Устранение отсутствующих значений.** Отсутствующие значения могут возникать по разным причинам, таким как ошибки сбора данных или неполные записи. Необходимо определить и обработать отсутствующие значения, выбрав подходящую стратегию заполнения, например, средними значениями или интерполяцией.

**Шаг 3. Обработка выбросов.** Выбросы представляют собой значения, которые значительно отличаются от общего распределения данных. Они могут возникать из-за ошибок измерений или аномальных событий. Обработка выбросов включает их идентификацию и принятие решения о том,

следует ли исключить выбросы или использовать специальные методы, такие как робастные оценки или усеченные средние значения.

**Шаг 4. Корректировка ошибок данных.** Иногда данные могут содержать ошибки, которые могут исказить результаты анализа. Например, синтаксические или семантические ошибки. Важно идентифицировать и исправить такие ошибки, чтобы обеспечить точность данных.

**Шаг 5. Фильтрация по заданным критериям.** В зависимости от конкретных требований и целей анализа, может потребоваться применение фильтрации данных согласно заданным критериям. Например, можно фильтровать данные по определенному временному периоду, определенным криптовалютам или другим характеристикам.

**Шаг 6. Валидация данных.** Значимым шагом является проверка и валидация данных после очистки и фильтрации, которая позволяет убедиться в правильности и соответствии данных требованиям и заданным критериям [9].

Можно сделать вывод, что применение методов имеет значимость для обеспечения надежности, точности и качества данных в процессе анализа криптовалюты.

Преобразование данных в удобный формат также неотъемлемая часть при прогнозировании. Целью процесса является изменение представления данных таким образом, чтобы они стали более удобными для анализа и понимания. Преобразование данных может включать следующие шаги [15].

**Шаг 1. Преобразование форматов данных.** Возможно, данные в начальном формате не очень удобны для анализа. В таком случае, требуется преобразование формата данных в другой, более подходящий для проведения анализа. Например, данные могут быть преобразованы из формата текстового файла в формат таблицы или базы данных, что облегчает их обработку и анализ.

**Шаг 2. Извлечение и создание признаков.** При анализе важно определить ключевые признаки или переменные, которые могут иметь влияние на прогнозирование котировок и оптимизацию портфеля. Может включать извлечение временных характеристик, статистических метрик, технических индикаторов и других связанных параметров. Создание этих признаков позволяет улучшить модели прогнозирования и оптимизации портфеля.

**Шаг 3. Нормализация и стандартизация данных.** Данные могут иметь различные шкалы и диапазоны значений. Нормализация и стандартизация данных позволяют привести их к общему масштабу и уровню изменчивости.

**Шаг 4. Агрегация данных.** В зависимости от конкретных целей анализа, возможно, требуется агрегировать данные на разных временных периодах. Например, данные по минутным ценам криптовалюты могут быть агрегированы в часовые, дневные или недельные данные, что позволяет выявить долгосрочные тренды и уменьшить шум, связанный с краткосрочной волатильностью.

**Шаг 5. Преобразование переменных.** Иногда преобразование переменных может быть полезно для улучшения моделирования и анализа данных [9]. Например, можно применить логарифмическое преобразование для сглаживания выбросов или применить функции преобразования, такие как экспоненциальное сглаживание или разности между значениями.

Преобразование данных обеспечивает лучшую интерпретацию и анализ данных криптовалюты, а также повышает эффективность и точность моделей прогнозирования.

*Определение требований к методам машинного обучения для прогнозирования и метрик оценки их эффективности*

Котировки цифровых валют всегда в движении, это одна из отличительных черт рынка. Существует несколько различных способов прогнозирования. Рассмотрим их подробнее.

Методология прогнозирования котировок криптовалюты с использованием анализа временных рядов. Данный подход основан на статистическом анализе последовательности наблюдений котировок с течением времени. Данная методология включает ряд моделей и алгоритмов, предсказывая будущие значения временного ряда на основе анализа его структурных и стохастических компонентов [9, 16-19].

Анализ временного ряда начинается с визуализации и исследования исторических данных котировок, что позволяет определить основные характеристики временного ряда, такие как тренды, сезонность, цикличность и случайная составляющая.

Важным предположением для анализа временных рядов является стационарность, то есть отсутствие систематических изменений в статистических свойствах ряда с течением времени. Если временной ряд не является стационарным, требуется применить методы преобразования, такие как дифференцирование или преобразование Бокса-Кокса, для достижения стационарности.

Свойства временного ряда определяют выбор модели, которая содержит такие компоненты как сезонность, случайную составляющую, тренды, цикличность. С целью определения оптимального порядка модели применяются методы анализа автокорреляции и частной автокорреляции.

После подгонки модели на исторических данных необходимо оценить ее производительность и точность. Для этого используются статистические метрики: средняя абсолютная ошибка (MAE), коэффициент детерминации (R-квадрат), среднеквадратическая ошибка (MSE). Необходимо протестировать модель на устойчивость и способность обобщения на новые данные [9] после чего возможно использовать модель для прогнозирования будущих значений котировок криптовалюты. Прогнозы могут быть сделаны на основе различных горизонтов времени, от краткосрочных до долгосрочных. Прогнозы могут быть оценены с использованием метрик прогнозной точности и сравнены с фактическими значениями для оценки качества модели.

Анализ временных рядов включает методы, необходимые для принятия правильных решений об инвестициях и оптимизации портфеля, так как он дает возможность исследовать и предсказывать тенденции котировок и их поведение. Методы и инструменты анализа временных рядов основаны на статистических и динамических свойствах временных данных и нацелены на прогнозирование котировок криптовалюты.

Применение статистических моделей для прогнозирования является важной методологией в области анализа. Статистические модели используют математические и статистические методы для описания и предсказания временных данных котировок криптовалюты.

Данные модели основываются на статистических свойствах данных и предполагают, что будущие значения котировок будут зависеть от предшествующих наблюдений.

Выбор подходящей статистической модели зависит от свойств временного ряда котировок. Это может включать модели ARIMA (авторегрессия интегрированного скользящего среднего), GARCH (общая авторегрессия условной гетероскедастичности), ARCH (авторегрессия условной гетероскедастичности) и другие. Выбор модели основан на анализе автокорреляций, стационарности и других статистических свойств временного ряда.

С целью достижения наилучшего соответствия между моделью и наблюдаемыми данными необходимо произвести подгонку модели, которая состоит в определении параметров модели с учетом исторических данных котировок криптовалюты. Оценка параметров производится с помощью метода наименьших квадратов и метода максимального правдоподобия [9].

После подгонки модели необходимо провести ее валидацию на отложенных данных или с использованием кросс-валидации, что позволяет оценить производительность модели и ее способность обобщаться на новые данные [9]. Валидация модели может включать оценку прогностической точности, такую как средняя абсолютная ошибка (MAE) или среднеквадратическая ошибка (MSE).

После успешной валидации модели можно использовать ее для прогнозирования будущих значений котировок криптовалюты. Прогнозы могут быть представлены в виде точечных оценок или диапазонов прогноза, учитывая статистическую неопределенность.

Применение статистических моделей для прогнозирования котировок криптовалюты позволяет учитывать и анализировать статистические свойства временных данных для повышения точности прогнозов и принятия правильных инвестиционных решений.

Методы машинного обучения для прогнозов котировок криптовалюты нацелены на автоматическое извлечение исторических закономерностей и взаимосвязей с целью предсказания значений котировок в будущем. Именно поэтому следующим подходом анализа данных и обучения моделей на их основе является применение методов машинного обучения для прогнозирования котировок криптовалют. В этом подходе для обеспечения чистоты и согласованности данных выполняется предварительная обработка данных котировок криптовалют. Эта предобработка предполагает такие методы, как стандартизация и нормализация данных, заполнение пропущенных значений, удаление выбросов и т.п.

От целей прогнозирования и характеристик данных зависит выбор модели машинного обучения для прогнозирования котировок криптовалюты. К таким моделям относятся методы глубокого обучения, регрессионные модели, нейронные сети, ансамблевые методы.

Как только модель выбрана, происходит ее обучение на исторических данных котировок. Для этого данные разделяют на две выборки (обучающую и проверочную), подгоняют параметры модели на основе обучающих данных, после чего модель оптимизируют для максимального повышения ее производительности.

В заключение обучения проводится валидация модели для оценки ее производительности, а также проверки спо-

собности модели обобщаться на новые данные. Валидация осуществляется на проверочных данных. Для оценки модели используются следующие метрики: средняя абсолютная ошибка (MAE), среднеквадратическая ошибка (MSE) и коэффициент детерминации (R-квадрат).

Для оценки качества предсказания моделью курса "Bitcoin" в настоящем исследовании предлагается использовать метрику Mean Squared Error (MSE). MSE является одной из наиболее популярных метрик оценки качества моделей в задачах регрессии в машинном обучении. Она используется для измерения среднего квадрата разностей между предсказанными значениями модели и истинными значениями целевой переменной.

Метрика среднеквадратичная ошибка особенно полезна для выявления грубых ошибок. Эта метрика позволяет выбрать модель, выдающую наименьшее количество грубых ошибок в прогнозе, так как при использовании этой метрики ошибка возводится в квадрат и большая ошибка особенно заметна. Соответственно, выбрана будет та модель, которая дает минимальное значение среднеквадратичной ошибки.

Это позволяет оценивать предсказание тренда для курса "Bitcoin". Исходя из практических потребностей, помимо использования среднеквадратичной оценки предложено ввести следующие качественные показатели: верное предсказание моделью точек максимумов и минимумов курса биткойна, верное определение курса "Bitcoin".

После успешной валидации модели она может быть использована для прогнозирования будущих значений котировок криптовалюты. Прогнозы могут быть представлены в виде точечных оценок или диапазонов прогноза, учитывая статистическую неопределенность.

Таким образом, методы машинного обучения дают возможность строить модели с максимальной точностью предсказывающие котировки криптовалют. Методам машинного обучения доступны автоматическая обработка больших объемов данных и обнаружение сложных взаимосвязей с целью построения моделей предсказания котировок. Предложенный подход доказывает высокую эффективность в области финансового прогнозирования.

### Экспериментальные исследования

#### *Исследование существующих методов анализа и прогнозирования котировок криптовалют*

Для того чтобы выбрать конкретный метод машинного обучения необходимо выделить факторы, влияющие на выбор модели машинного обучения для целей исследования. Существует более 100 методов Машинного обучения и выбор конкретного метода анализа для прогнозирования котировок криптовалют выделяют ряд критериев, определяющих выбор конкретного подхода [9]. Далее представлены критерии, существенные для рассматриваемой предметной области:

1. Горизонт прогнозирования (краткосрочная или долгосрочная задача);
2. Сложность структуры данных (присутствие нелинейных зависимостей, пропусков, шумов);
3. Вычислительные ресурсы (наличие оборудования для глубоких нейронных сетей, распределённые системы);

4. Сезонность (наличие или отсутствие периодических колебаний в временном ряду);

5. Устойчивость к резким изменениям (волатильность, информационный шум);

6. Применимость конкретного метода (научная обоснованность алгоритма и его проверенная эффективность);

7. Актуальность (наличие свежих исследований и открытых библиотек).

Сочетание данных факторов позволяет определить, какой алгоритм будет наиболее эффективен для анализа временных рядов криптовалюты. Так, методы, учитывающие нелинейные закономерности и временные зависимости, доказали наибольшую эффективность при прогнозировании котировок. Далее представлены методы, применение которых актуально для рассматриваемой задачи, а именно для прогнозирования курса криптовалют.

При работе с последовательными данными, например, с временными рядами используют **рекуррентные нейронные сети (RNN) и их варианты** [9]. Они учитывают временную зависимость. Рекуррентные нейронные сети полезны при работе с волатильными временными рядами, а их вариант – Long-Short-Term-Memory – запоминает долгосрочные зависимости и контролирует забывание данных через специальные механизмы. LSTM используется для краткосрочного и долгосрочного прогнозирования. GRU (Gated Recurrent Unit): упрощенная версия LSTM. Эта версия требует меньше вычислительных ресурсов и работает быстрее, при этом она обеспечивает не меньшую точность [14].

**Свёрточные нейронные сети (CNN)** [9, 14]. Архитектура этих сетей применяется к временным рядам, особенно в моделях CNN-LSTM. Свёрточные слои помогают выделять значимые временные паттерны, которые затем передаются в слои LSTM для анализа последовательностей [14].

**Гибридные модели** [9]. Эти модели объединяют несколько архитектур, что позволяет учитывать как краткосрочные, так и долгосрочные тренды. Некоторые из самых популярных гибридных моделей для криптовалют включают: Сочетание свёрточных и рекуррентных слоев CNN-LSTM, что позволяет одновременно анализировать короткие временные зависимости и долгосрочные. Гибридная модель LSTM-ARIMA, где ARIMA используется для устранения сезонных компонент, а LSTM прогнозирует остаточные тренды.

**Алгоритмы градиентного бустинга** [9, 13]. Эти модели хорошо работают с временными рядами, особенно когда можно учесть дополнительные факторы, влияющие на цену. XGBoost – один из самых популярных алгоритмов для временных данных с нелинейными зависимостями. Подходит для высокоразмерных данных и показывает высокую точность [13]. LightGBM и CatBoost – оптимизированные бустинговые алгоритмы, которые могут работать быстрее на больших наборах данных и поддерживают категориальные признаки.

**Модели на основе трансформеров** [9]. Трансформеры предъявляют высокие вычислительные требования. Однако, при необходимости анализа временных зависимостей трансформеры очень подходят для прогнозирования. Специально разработанная для временных рядов модель Temporal Fusion Transformer (TFT), учитывает как краткосрочные, так и долгосрочные зависимости. Facebook, создал для времен-

ных рядов модель Prophet с четко выраженной сезонностью и трендами. Prophet хорошо справляется с данными, которые имеют регулярные паттерны, но для криптовалютных курсов подходит хуже из-за высокой волатильности.

**Автокорреляционные модели временных рядов** [17]. Эти методы применяются в случае стационарных временных рядов и часто используются как базовые для анализа данных. ARIMA (AutoRegressive Integrated Moving Average): применима для данных с автокорреляцией. Требует стационарных данных и применяется для прогнозирования краткосрочных трендов. SARIMA (Seasonal ARIMA): модификация ARIMA, позволяющая учитывать сезонные паттерны. ARCH/GARCH (AutoRegressive Conditional Heteroskedasticity/Generalized ARCH): модели для прогнозирования волатильности и изменения амплитуды временных рядов [17].

**Классические регрессионные модели** [9]. Эти модели подходят для простых линейных данных и редко используются для прогнозирования криптовалютных курсов, поскольку не могут учитывать сложные зависимости и волатильность. Линейная регрессия: подходит для линейных данных и может использоваться как базовая модель для оценки зависимости между ценой и временными факторами. Полиномиальная регрессия может использоваться для данных с нелинейной зависимостью, но работает менее эффективно, чем нейронные сети и бустинговые модели, на данных криптовалют.

С учетом характеристик предметной области и приведенного выше анализа в настоящем исследовании рассмотрим более детально пять следующих методов прогнозирования, а также построим модель прогнозирования на основе исторических данных.

1. ARIMA – модель временных рядов, применимая для анализа стационарных данных.

2. LSTM – нейронная сеть, подходящая для обработки временных данных с нелинейными зависимостями.

3. GRU – аналог LSTM, но с более упрощенной архитектурой.

4. Prophet – модель от Facebook, предназначенная для анализа данных с сезонными компонентами.

5. XGBoost – бустинговый алгоритм, эффективный для обработки сложных наборов данных.

Каждый из методов имеет свои преимущества и недостатки, которые можно увидеть на основе практического анализа.

Проведем краткий анализ для прогнозирования котировок "Bitcoin" за 2024 на основе выбранных моделей. В качестве исходных данных используется историческая котировка "Bitcoin" за первую половину 2024 года. Данные загружаются с помощью API CoinGecko и преобразуются для применения к моделям. Для оценки точности каждой модели используются метрики MSE.

Для сравнения методов в виде таблицы и графиков с реальными историческими данными, добавим дополнительные шаги в код и представим результаты в структурированной форме. Это включает расчет метрик точности для каждого метода и отображение фактических данных вместе с прогнозируемыми значениями на графиках. Также выведем таблицу со сравнением метрик MSE (Mean Squared Error) для оценки качества прогноза каждой модели.

1. Загрузка и предобработка данных: загружаются данные о ценах "Bitcoin" за первое полугодие 2024 года с API CoinGecko. Данные нормализуются для использования в нейронных сетях.

2. Построение и обучение моделей:

○ *ARIMA:* используется для анализа временных рядов, построение предсказаний на тестовой выборке.

○ *LSTM и GRU:* нейронные сети, обучаемые на нормализованных данных [9].

○ *Prophet:* модель от Facebook для прогнозирования временных рядов с учетом сезонных компонентов.

○ *XGBoost:* бустинговый алгоритм для нелинейных зависимостей.

3. Оценка точности: метрики MSE вычисляются для каждой модели, что позволяет оценить отклонение прогнозов от фактических данных (табл. 1).

4. Визуализация: на графике показаны фактические данные и прогнозы всех моделей за выбранный период (рис. 1).




Рис. 1. Сравнение прогнозов различных моделей с фактическими данными (первое полугодие 2024)

Рассмотрим результаты моделирования на основе меры качества регрессии MSE. Как было сказано выше, эта метрика позволяет выявить большие ошибки. Соответственно, MSE помогает выбрать модель, которая дает меньше больших ошибок прогноза [9, 13].

Таблица 1

Значения MSE при сравнении моделей

Модель	MSE
ARIMA	4,68
LSTM	2,22
GRU	2,32
Prophet	7,56
XGBoost	2,31

Для всех моделей значения MSE представлены в таблице 1. Эти метрики указывают на отклонение прогнозов от фактических данных и помогают выявить сильные и слабые стороны каждой модели. Модель LSTM показала наименьшую ошибку по метрике (MSE = 2,22), что указывает на ее высокую способность минимизировать крупные отклонения от фактических значений. GRU и XGBoost также продемонстрировали хорошие результаты, близкие к LSTM, что позволяет считать их конкурентоспособными для краткосроч-

ного прогнозирования волатильных временных рядов. Prophet и ARIMA показали менее точные результаты, что объясняется их более низкой адаптивностью к высоковолатильным и непредсказуемым данным криптовалют.

На основе этих данных можно сделать вывод, что нейронные сети LSTM и GRU демонстрируют лучшие результаты по сравнению с классическими моделями, такими как ARIMA и Prophet, и представляют собой подходящий выбор для прогнозирования краткосрочных трендов на волатильных рынках. LSTM, GRU и XGBoost следует рекомендовать для краткосрочных прогнозов цен криптовалют, где точность и способность адаптироваться к колебаниям цены играют решающую роль. Prophet может быть полезен в ситуациях, когда данные демонстрируют ярко выраженные сезонные или циклические компоненты. Однако его применение на криптовалютных рынках следует ограничить, так как его точность оказывается ниже. ARIMA может быть использована как базовая модель для анализа долгосрочных трендов, однако для криптовалютных данных её применение ограничено из-за недостатка гибкости при работе с волатильными рядами.

*Обоснование выбора и исследование модифицируемых методов анализа больших данных в области криптовалют*

Сравнение моделей на основе исторических данных котировок "Bitcoin" за первое полугодие 2024 года с помощью загрузки данных в API CoinGecko показало, что:

- модели **LSTM** и **GRU** показали наилучшие результаты по **точности прогнозирования**, обеспечив минимальные ошибки MSE. Таким образом, эти модели больше других подходят для анализа волатильных временных рядов, таких как криптовалюты.

- **XGBoost** также продемонстрировал хорошие результаты, близкие к LSTM и GRU, и является конкурентоспособным инструментом для краткосрочного прогнозирования.

- **Prophet** и **ARIMA** менее эффективны для прогнозирования котировок криптовалют из-за их слабой адаптивности к высоковолатильным и непредсказуемым данным, что ограничивает их использование в таких задачах.

- для краткосрочного прогнозирования криптовалют следует рекомендовать нейронные сети (LSTM, GRU) и XGBoost, так как они показывают наилучшую адаптивность и точность.

С учетом полученных результатов, анализа преимуществ и недостатков рассматриваемых моделей было принято решение о модификации моделей LSTM и GRU, а также об использовании в исследовании временных сверточных нейронных сетей (Temporal Convolutional Network – TCN), которые также решено применить для прогнозирования котировок. Временные сверточные нейронные сети (TCN) предложены как альтернатива RNN для анализа временных рядов. TCN используют расширенную свертку, что позволяет увеличить область восприятия модели без значительного увеличения вычислительной сложности. Преимущества TCN включают возможность параллельной обработки данных, меньшую склонность к проблемам взрыва или затухания градиентов, а также гибкость в настройке гиперпараметров. Эти особенности делают TCN перспективным инструментом для анализа волатильных временных рядов, таких как котировки криптовалют.

Модификация методов и моделей заключается в:

1. изменении архитектур стандартных моделей прогнозирования;
2. исследовании эффективности измененных моделей прогнозирования;
3. получении гибридных архитектур моделей прогнозирования путем объединения архитектур стандартных моделей прогнозирования;
4. исследовании эффективности гибридной модели прогнозирования.

Разработанный алгоритм (алгоритмическое обеспечение) анализа больших данных в области прогнозирования курса криптовалюты представляет собой реализацию каждого шага модифицированного метода.

Данные для **обучения** были взяты с сайта [investing.com](https://investing.com), который позволяет скачивать данные о котировках начиная с 2015 г. в формате csv. В качестве данных были взяты котировки с 7 января 2015 года по 7 февраля 2021 г. Всего данные содержали 2222 записей (рис. 2). В качестве **тестовой выборки** использовались котировки с 7 февраля 2021 г. Всего в выборке 72 записи (рис. 3). Для предсказания была выбрана длина временного окна равная 60 – это количество предыдущих измерений, используемых для предсказания. Модели создавались с использованием библиотеки **TensorFlow** и графического ускорителя T4. Для **оптимизации** использовался алгоритм **Adam**, обучение происходило с применением техники мини-пакетов.

Все модели из рассмотренные ниже были созданы с использованием библиотеки TensorFlow 2.15 для Python 3.11 на платформе Google Colab. Для ускорения вычислений использовался графический ускоритель T4. В качестве оптимизационного алгоритма был выбран Adam, имеющий более быструю сходимость, обусловленную адаптивной скоростью обучения.




Рис. 2. Обучающая выборка

Обучение моделей происходило с применением техники мини-пакетов (ошибка рассчитывается для каждого элемента набора данных, но веса обновляются только после обработки всего пакета). Этот метод представляет собой компромисс между обычным градиентным спуском и стохастическим градиентным спуском.




Рис. 3. Тестовая выборка

Все модели обучались в течении 100 эпох с фиксированным размером батча равным ста. В целях недопущения переобучения применяются слои «dropout», отключающие нейроны, параметр слоя «dropout» фиксирован и равен 20.

Разработаем модели нейронных сетей на основе рекуррентного блока управляемой памяти GRU. Рассмотрим подробнее структуру модели нейронной сети на основе блоков GRU (рис. 4, 5, 8):

1. Входной слой:  $input\_shape=(n\_steps, n\_features)$  определяет форму входных данных. Мы используем 60 предыдущих значений курса "Bitcoin" для предсказания следующего значения.
2. Слои с рекуррентным блоком управляемой памяти GRU.
3. Слой Dropout для предотвращения переобучения.
4. Выходной слой: состоит из одного нейрона, так как мы предсказываем одно значение (курс "Bitcoin").

Значения ошибки MSE при обучении модели для разного количества блоков GRU показаны на рис. 6 и 9.

Результаты предсказания модели из 4 и 8 блоков GRU показаны на рис. 7 и 10.




Рис. 4. Структура модели нейронной сети на основе GRU




Рис. 5. Структура модели нейронной сети на основе 4 блоков GRU




Рис. 6. Значения ошибки MSE при обучении модели нейронной сети на основе 4 блоков GRU




Рис. 7. Результаты предсказания модели из 4х блоков GRU




Рис. 8. Структура модели нейронной сети на основе 8 блоков GRU



Рис. 9. Значения ошибки MSE при обучении модели нейронной сети на основе 8 блоков GRU




Рис. 10. Результаты предсказания модели из 8 блоков GRU

Сравнение результатов предсказания курса "Bitcoin" на тестовой выборке моделями нейронных сетей на основе 4 и 8 блоков GRU показывает, что модели в целом верно определяют курс "Bitcoin", при этом модель на основе 4 блоков GRU более точно предсказывает тенденцию изменения курса, в то время как модель состоящая из 8 блоков GRU обеспечивает меньшее расхождение со значением курса.

Теперь разработаем модели нейронных сетей на основе блоков долгосрочной краткосрочной памяти LSTM. Структура модели нейронной сети на основе разного количества блоков LSTM представлена на рисунках 11, 12 и 15.




Рис. 11. Структура модели нейронной сети на основе LSTM

Рассмотрим подробнее структуру модели нейронной сети на основе блоков LSTM:

1. Входной слой: `input_shape=(n_steps, n_features)` определяет форму входных данных. Мы используем 60 предыдущих значений курса "Bitcoin" для предсказания следующего значения.
2. Слой с долгосрочной краткосрочной памятью LSTM.
3. Слой Dropout для предотвращения переобучения.
4. Выходной слой: состоит из одного нейрона, так как мы предсказываем одно значение (курс "Bitcoin").

Значения ошибки MSE при обучении модели для разного количества блоков LSTM показаны на рисунках 13 и 16.

Результаты предсказания модели из 4 и 8 блоков LSTM показаны на рисунках 14 и 17.




Рис. 12. Структура модели нейронной сети на основе 4 блоков LSTM

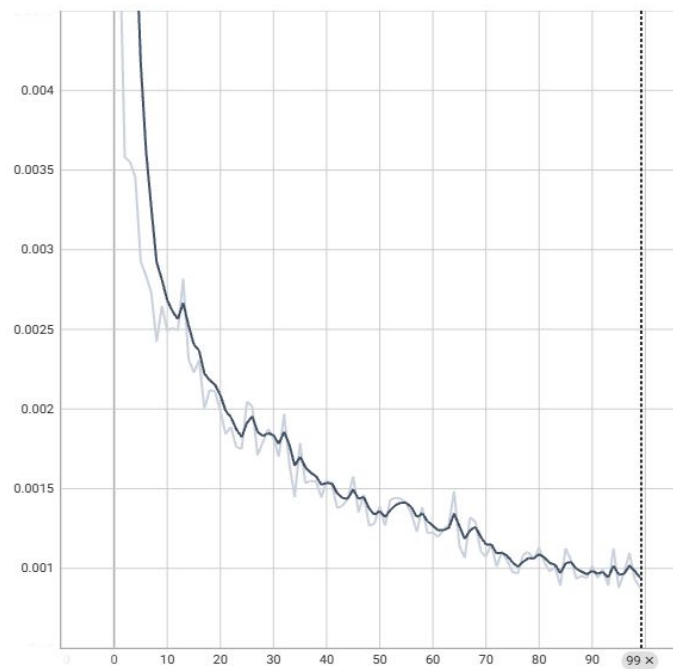


Рис. 13. Значения ошибки MSE при обучении модели нейронной сети на основе 4 блоков LSTM




Рис. 14. Результаты предсказания модели из 4х блоков LSTM




Рис. 15. Структура модели нейронной сети на основе 8 блоков LSTM




Рис. 16. Значения ошибки MSE при обучении модели нейронной сети на основе 8 блоков LSTM




Рис. 17. Результаты предсказания модели из 8 блоков LSTM

При сравнении результатов предсказания курса "Bitcoin" на тестовой выборке моделями нейронных сетей на основе 4 и 8 блоков LSTM можно отметить следующее. Несмотря на расхождения с точным значением курса "Bitcoin", модель на основе 4 блоков LSTM точно предсказывает тенденцию изменения курса, точки максимумов и минимумов. Модель, состоящая из 8 блоков LSTM не позволяет предсказывать значение курса "Bitcoin".

Модель, состоящая из чередующихся слоев GRU и LSTM (структура показана на рис. 18) верно предсказывает тренды курса "Bitcoin", в то же время ей удалось уменьшить разрыв с номинальными значениями курса.




Рис. 18. Структура модели нейронной сети на основе GRU и LSTM

Эти выводы можно сделать, проанализировав значения ошибки MSE при обучении модели (рис. 19) и результаты предсказания модели (рис. 20).




Рис. 19. Значения ошибки MSE при обучении модели нейронной сети на основе GRU и LSTM




Рис. 20. Результаты предсказания модели на основе GRU и LSTM

Теперь разработаем модели нейронных сетей на основе временной сверточной нейронной сети. Подбираемыми параметрами являются факторы расширения TCN. Структура модели нейронной сети на основе TCN представлена на рисунке 21.



Рис. 21. Структура модели нейронной сети на основе TCN

Рассмотрим подробнее структуру модели нейронной сети на основе блоков TCN:

1. Входной слой:  $input\_shape=(n\_steps, n\_features)$  определяет форму входных данных. Мы используем 60 предыдущих значений курса "Bitcoin" для предсказания следующего значения.

2. Слой TCN: этот слой представляет собой основной блок временной сверточной сети. Он содержит несколько уровней свертки с разными коэффициентами расширения ядра (dilation rates), что позволяет захватывать длинные зависимости во временных рядах. Так же в слое TCN используются пропускные соединения между слоями, для улучшения обучения модели.

3. Слой Dropout: используется для предотвращения переобучения.

4. Полносвязанный слой: используется для дополнительной обработки информации перед финальным выводом.

5. Выходной слой: состоит из одного нейрона, так как мы предсказываем одно значение (курс "Bitcoin").

Структура модели нейронной сети на основе TCN с разными факторами расширения представлена на рисунках 22 и 25. Значения ошибки MSE при обучении модели нейронной сети на основе TCN представлены на рисунках 23 и 26. Результаты предсказания модели на основе TCN представлены на рисунках 24 и 27.




Рис. 22. Структура модели нейронной сети на основе TCN с фактором расширения {1, 2, 4, 8}




Рис. 23. Значения ошибки MSE при обучении модели нейронной сети на основе TCN с фактором расширения {1, 2, 4, 8}




Рис. 24. Результаты предсказания модели на основе TCN с фактором расширения {1, 2, 4, 8}




Рис. 25. Структура модели нейронной сети на основе TCN с фактором расширения {1, 3, 5, 7}




Рис. 26. Значения ошибки MSE при обучении модели нейронной сети на основе TCN с фактором расширения {1, 3, 5, 7}




Рис. 27. Результаты предсказания модели на основе TCN с фактором расширения {1, 3, 5, 7}

Сравнение результатов предсказания курса "Bitcoin" на тестовой выборке моделями нейронных сетей на основе блоков TCN показало, что модели нейронных сетей на основе блоков TCN с факторами расширения {1, 2, 4, 8} и {1, 3, 5, 7} имеют схожее предсказание курса "Bitcoin". Они верно отслеживают тренд курса "Bitcoin" и в сравнении с другими моделями их расхождение с точным значением курса "Bitcoin" минимальное, однако их предсказание точек максимумов и минимумов смещено.

В Таблице 2 приведены результаты проведенных экспериментов и обозначена применимость той или иной модели для прогнозирования курсов криптовалют.

Таблица 2

Сравнительная характеристика рассмотренных моделей

Модель	MSE	Верное предсказание точек максимума и минимума	Верное предсказание тренда курса
GRU-4	0,72344	ДА	ДА
GRU-8	0,41623	НЕТ	ДА
LSTM-4	0,66723	ДА	ДА
LSTM-8	-	НЕТ	НЕТ
GRU-LSTM-4	0,52634	НЕТ	ДА
TCN{1,2,4,8}	0,46421	НЕТ	ДА
TCN{1,3,5,7}	0,46034	НЕТ	ДА

Сравнивая в совокупности все модели можно сделать следующий вывод: все модели, за исключением модели на основе 8 блоков LSTM (LSTM-8) верно предсказывают тренд курса "Bitcoin". При этом наименьшее расхождение с номинальным значением стоимости "Bitcoin" имеет модель на основе 8 блоков GRU (GRU-8). Наиболее точным предсказанием точек максимума и минимума обладает модель на основе 4-х блоков LSTM (LSTM-4). Наиболее сбалансированными выглядят модели на основе временной сверточной нейронной сети TCN{1,2,4,8} и TCN{1,3,5,7}.

**Заключение**

В результате проведенного исследования можно сделать вывод о том, что для прогнозирования значений динамично изменяющихся числовых величин на примере курсов криптовалют методами машинного обучения следует использовать не одну, а несколько моделей прогнозирования. Методы машинного обучения, такие как LSTM и GRU, продемонстрировали максимальную точность прогнозирования котировок криптовалют благодаря их способности учитывать

долгосрочные и краткосрочные зависимости в данных. Градиентный бустинг (XGBoost) показал высокую производительность на данных с нелинейными зависимостями, однако уступил нейронным сетям в задачах прогнозирования волатильных временных рядов. Классические методы, такие как ARIMA и Prophet, оказались менее эффективными для анализа криптовалютных данных из-за их слабой адаптивности к высокой волатильности.

Разработанный алгоритм прогнозирования, основанный на моделях LSTM и GRU, обеспечил минимальные отклонения прогнозов от фактических данных, что подтверждается низкими значениями метрик MSE. На основании проведенного исследования предложены рекомендации по дальнейшему совершенствованию методов прогнозирования криптовалютных котировок. В частности, рекомендуется изучение гибридных архитектур, сочетающих CNN, GRU и TCN, а также применение более сложных методов обработки временных рядов, таких как трансформеры и attention-механизмы.

**Литература**

1. Дымкова С.С., Кретова И.С., Варламов О.В. Научометрический анализ результатов рецензирования материалов конференции TIRVED2024 // Т-Comm: Телекоммуникации и транспорт. 2024. Том 18. №12. С. 19-26.
2. Портнов Э.Л., Фатхулин Т.Д. Технологии достижения высоких скоростей передачи в современных когерентных DWDM-системах связи // Т-Comm: Телекоммуникации и транспорт. 2015. Т. 9. №8. С. 34-37.
3. Деарт В.Ю., Фатхулин Т.Д. Анализ современного состояния транспортных сетей с целью внедрения технологии программно-конфигурируемых сетей (SDN) // Т-Comm: Телекоммуникации и транспорт. 2017. Том 11. №6. С. 4-9.
4. Deart V., Fatkhulin T. Analysis of the functioning of a multi-domain transport software-defined network with controlled optical layer // 2017 21st Conference of Open Innovations Association (FRUCT), Helsinki, Finland, 2017, pp. 79-87, DOI: 10.23919/FRUCT.2017.8250168
5. Деарт В.Ю., Фатхулин Т.Д. Анализ транспортных программно-конфигурируемых сетей (Т-SDN) с управляемым оптическим уровнем с целью получения модели, позволяющей оценить возможность предоставления сервиса Bandwidth on Demand // Т-Comm: Телекоммуникации и транспорт. 2018. Т.12. №4. С. 35-42.
6. Деарт В.Ю., Фатхулин Т.Д. Анализ процесса создания суперканала с необходимой пропускной способностью в сети, построенной по технологии транспортных программно-конфигурируемых сетей (Т-SDN) // Т-Comm: телекоммуникации и транспорт. 2018. Том 12. №10. С. 23-30.
7. Leokhin Y.L., Fatkhulin T.D. Approach to Estimating the Probability of Providing "Cloud" Services in the SDN // 2020 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.
8. Y. L. Leokhin and T. D. Fatkhulin, "Evaluation of Service Availability in Software-Defined Optical Network," 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122
9. Вишневский В.М., Леохин Ю.Л., Фатхулин Т.Д., Занегин А.В. Методы машинного обучения в решении задачи прогнозирования спроса на отдельные виды товаров // Т-Comm: Телекоммуникации и транспорт. 2024. Том 18. №10. С. 34-43.
10. Ринас Н.А., Золкин А.Л., Каберова А.Р., Скибин Ю.В. Влияние автоматизации и искусственного интеллекта на социальное неравенство // Экономика и управление: проблемы, решения. 2025. Т. 7, № 1(154). С. 116-125. DOI 10.36871/ek.up.p.r.2025.01.07.015. EDN BGBKZZ.

11. Беспалова В.В., Каберова А.Р., Белинская Д.Б. и др. Методический подход к управлению устойчивостью развития региона // Экономика и управление: проблемы, решения. 2024. Т. 11, № 11(152). С. 88-93. DOI 10.36871/ek.up.p.r.2024.11.11.011. EDN GDEJYC.

12. Драгуленко В.В., Золкин А.Л., Есина О.И., Каберова А.Р. Влияние численности населения на экономический рост и развитие стран // Экономика и управление: проблемы, решения. 2024. Т. 11, № 9(150). С. 67-75. DOI 10.36871/ek.up.p.r.2024.09.11.009. EDN ANEUBG.

13. Леохин Ю.Л., Фатхулин Т.Д., Занегин А.В. Модификация метода градиентного усиления для прогнозирования спроса на отдельные виды товаров. Научные технологии в космических исследованиях Земли. 2025. Т. 18. № 2, в печати.

14. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д. Research and Development of Image Improvement Tools // T-Comm: Телекоммуникации и транспорт. Т. 18, № 10, в печати.

15. Leokhin Yu., Fatkhulin T., Boitsov K. Computer Vision Methods in Applied Problems of Classifying Objects in Images // 2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2025.

16. Leokhin Y., Fatkhulin T., Zanegin A., Rakhmatova A. Researching the Efficiency of Machine Learning Methods Used in Forecasting Demand for Certain Types of Goods // 2025 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russian Federation, 2025, pp. 1-8, DOI: 10.1109/IEEECONF64229.2025.10948113.

17. Fatkhulin T., Leokhin Y., Zanegin A., Rakhmatova A. Development and Research of a Modified Gradient Boosting Method Effectiveness to Solve Applied Problems of Time-Series Forecasting // 2025 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/IEEECONF64229.2025.10948023.

18. Бузаев А.С., Таташев А.Г., Яшина М.В., Лавров О.С., Носов Е.А. Восстановление динамики транспортного потока на основе детерминированно-стохастической модели и данных с интеллектуально транспортных систем // T-Comm: Телекоммуникации и транспорт. 2019. Т. 13. № 10. С. 35-44.

19. Pavlov S.V., Dokuchaev V.A., Maklachkova V.V., Mytenkov S.S. Features of supporting decision making in modern enterprise infocommunication systems // T-Comm: Телекоммуникации и транспорт 2019. Т. 13. № 3. С. 71-74.

## MACHINE LEARNING METHODS IN APPLIED PROBLEMS OF FORECASTING DYNAMICALLY CHANGING DATA

**Yuri L. Leokhin**, Moscow Technical University of Communications and Informatics, Moscow, Russia, [y.l.leokhin@mtuci.ru](mailto:y.l.leokhin@mtuci.ru)  
**Svetlana S. Dymkova**, Moscow Technical University of Communications and Informatics, Moscow, Russia, [s.s.dymkova@mtuci.ru](mailto:s.s.dymkova@mtuci.ru)  
**Timur D. Fatkhulin**, Moscow Technical University of Communications and Informatics, Moscow, Russia, [t.d.fatkhulin@mtuci.ru](mailto:t.d.fatkhulin@mtuci.ru)

### Abstract

The paper considers the problem of increasing the accuracy of forecasting dynamically changing data using cryptocurrency rates as an example. The aim of the paper is to research and develop machine learning methods used in applied problems for forecasting dynamically changing data. The relevance of the work is due to the fact that existing methods and models do not always allow achieving sufficient accuracy and reliability in forecasting quotes in conditions of high volatility and complexity of cryptocurrency markets. Thus, there is a need for further in-depth research and development of new approaches and methods to solve this problem. The object of the study is financial quotes of cryptocurrencies. The subject of the study is the performance indicators of machine learning methods used to forecast quotes. To assess the quality of model predictions, the Mean Squared Error (MSE) metric was chosen, which helps measure the accuracy of the model by identifying forecast errors. Additional quality indicators were also proposed, such as the correct prediction of maximum and minimum points, which is important for analyzing cryptocurrency price fluctuations. Forecasting models were created using the TensorFlow library and the T4 graphics accelerator. The Adam algorithm was used for optimization, training was performed using the mini-packet technique. The following research methods served as the methodological basis for the work: comparison, description, measurement, scientific abstraction method, as well as analysis and generalization. The conclusion provides the main findings obtained as a result of the study.

**Keywords:** value, forecast, cryptocurrency, method, machine learning, model, algorithm

### References

- [1] S.S. Dymkova, I.S. Kretova, O.V. Varlamov, "Conference papers per-reviewing results: TIRVED-2024 scientometric research", *T-Comm*, vol. 18, no.12 pp. 19-26. (in Russian)
- [2] E.L. Portnov, T.D. Fatkhulin, "Technologies aimed at achieving high speed transmission in modern coherent DWDM communication systems". *T-Comm*. 2015. Vol 9. No.8, pp. 34-37. (in Russian).
- [3] V.Yu. Deart, T.D. Fatkhulin, "Analysis of current state of transport networks with the purpose of introducing software defined networks (SDN) technology", *T-Comm*, 2017, vol. 11, no.6, pp. 4-9. (in Russian).

- [4] V. Deart and T. Fatkhulin, "Analysis of the functioning of a multi-domain transport software-defined network with controlled optical layer," *2017 21st Conference of Open Innovations Association (FRUCT)*, Helsinki, Finland, 2017, pp. 79-87, DOI: 10.23919/FRUCT.2017.8250168.
- [5] V.Yu. Deart, T.D. Fatkhulin, "Analysis of transport software-defined networks (T-SDN) with controlled optical layer to obtain a model providing assesment of the possibility of bandwidth on demand service", *T-Comm*, 2018, vol. 12, no.4, pp. 35-42. (in Russian)
- [6] V.Yu. Deart, T.D. Fatkhulin, "Analysis of the process of creating a superchannel with the necessary capacity in the network organized according to transport software-defined networks (T-SDN) technology", *T-Comm*, 2018, vol. 12, no.10, pp. 23-30. (in Russian).
- [7] Y.L. Leokhin and T. D. Fatkhulin, "Approach to Estimating the Probability of Providing "Cloud" Services in the SDN," *2020 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.
- [8] Y.L. Leokhin and T.D. Fatkhulin, "Evaluation of Service Availability in Software-Defined Optical Network," *2021 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122.
- [9] V.M. Vishnevsky, Yu.L. Leokhin, T.D. Fatkhulin, A.V. Zanegin, "Machine learning methods in solving the problem of forecasting demand for specific types of goods", *T-Comm*, vol. 18, no. 10, pp. 34-43. (in Russian)
- [10] N.A. Rinas, A.L. Zolkin, A.R. Kaberova, Yu.V. Skibin, "The Impact of Automation and Artificial Intelligence on Social Inequality", *Economy and Management: Problems, Solutions*, 2025, Vol. 7, No. 1(154), pp. 116-125. DOI 10.36871/ek.up.p.r.2025.01.07.015. (in Russian)
- [11] V.V. Bepalova, A.R. Kaberova, D.B. Belinskaya et al., "Methodological approach to managing the sustainability of regional development", *Economy and Management: Problems, Solutions*, 2024, Vol. 11, No. 11(152), pp. 88-93. DOI 10.36871/ek.up.p.r.2024.11.11.011. (in Russian)
- [12] V.V. Dragulenko, A.L. Zolkin, O.I. Esina, A.R. Kaberova, "The Impact of Population on Economic Growth and Development of Countries", *Economy and Management: Problems, Solutions*, 2024, Vol. 11, No. 9(150), pp. 67-75. DOI 10.36871/ek.up.p.r.2024.09.11.009. (in Russian)
- [13] Yu.L. Leokhin, T.D. Fatkhulin, A.V. Zanegin, "The Gradient Boosting Method Modification to Forecast Demand for Individual Types of Goods", *H&ES Reserch*. 2025, Vol. 16, No. 2. (in Russian)
- [14] Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, "Research and Development of Image Improvement Tools", *T-Comm*, vol. 18, no. 10, In print.
- [15] Yu. Leokhin, T. Fatkhulin, K. Boitsov, "Computer Vision Methods in Applied Problems of Classifying Objects in Images", *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2025.
- [16] Y. Leokhin, T. Fatkhulin, A. Zanegin and A. Rakhmatova, "Researching the Efficiency of Machine Learning Methods Used in Forecasting Demand for Certain Types of Goods", *2025 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russian Federation, 2025, pp. 1-8, DOI: 10.1109/IEEECONF64229.2025.10948113
- [17] T. Fatkhulin, Y. Leokhin, A. Zanegin and A. Rakhmatova, "Development and Research of a Modified Gradient Boosting Method Effectiveness to Solve Applied Problems of Time-Series Forecasting", *2025 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/IEEECONF64229.2025.10948023
- [18] A.S. Bugaev, A.G. Tatashev, M.V., Yashina, O.S. Lavrov, E.A. Nosov, "Reconstruction of traffic flow dynamics based on deterministicstochastic model and data obtained from intelligent transport systems," *T-Comm*. 2019. Vol. 13, no. 10, pp. 35-44. DOI 10.24411/2072-8735-2018-10315
- [19] S.V. Pavlov, V.A. Dokuchaev, V.V. Maklachkova, S.S. Mytenkov, "Features of supporting decision making in modern enterprise infocommunication systems," *T-Comm*. 2019. Vol. 13, no. 3, pp. 71-74.

#### Information about authors:

**Yuri L. Leokhin**, Moscow Technical University of Communications and Informatics, Rectorate, Vice-Rector for Scientific Work, full professor, Dr. Sc. (Tech.), Moscow, Russia. [orcid.org/0000-0003-3321-4497](https://orcid.org/0000-0003-3321-4497)

**Svetlana S. Dymkova**, Moscow Technical University of Communications and Informatics, Candidate Sc. (Tech.), Moscow, Russia. [orcid.org/0000-0003-1945-9850](https://orcid.org/0000-0003-1945-9850)

**Timur D. Fatkhulin**, Moscow Technical University of Communications and Informatics, Dpt. of MC and IT, Docent, Candidate Sc. (Tech.), Moscow, Russia. [orcid.org/0000-0003-0998-1055](https://orcid.org/0000-0003-0998-1055)