

ФЕДЕРАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЦЕНТР
«ИНФОРМАТИКА И УПРАВЛЕНИЕ» РОССИЙСКОЙ АКАДЕМИИ НАУК



На правах рукописи
УДК 004.89

Макаров Иван Сергеевич

**РАЗРАБОТКА МЕТОДОВ ПРОГНОЗИРОВАНИЯ
ТОЧЕК РАЗВОРОТА НА МНОГОМЕРНЫХ
ВРЕМЕННЫХ РЯДАХ ФИНАНСОВЫХ РЫНКОВ НА
ОСНОВЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ С
ПОДКРЕПЛЕНИЕМ**

Специальность 1.2.1 —
«Искусственный интеллект и машинное обучение»

Диссертация на соискание учёной степени
кандидата технических наук

Научный руководитель:
д. ф.-м. н., проф.
Цурков Владимир Иванович

Москва — 2024

Оглавление

	Стр.
Введение	4
Глава 1. Построение системы автоматической торговли	13
1.1 Обзор основных компонент биржевой торговли	14
1.2 Возможности систем автоматической торговли	24
1.3 Долгосрочные и краткосрочные стратегии	27
1.4 Стратегии на основе технического анализа	34
1.5 Тестирование и валидация торговых стратегий	42
1.6 Выводы к первой главе	47
Глава 2. Построение среднесрочной торговой стратегии	49
2.1 Математическая формулировка стратегии	50
2.2 Определение статистических свойств MFTS	51
2.2.1 Самоподобие	53
2.2.2 Непохожесть	57
2.2.3 Корреляция	59
2.2.4 Волатильность	61
2.3 Формирование входного вектора для моделей	64
2.4 Разметка шагов временного ряда на 3 класса	69
2.5 Обучение с учителем модели классификации	70
2.6 Обучение с подкреплением модели типа DQN	72
2.7 Выводы ко второй главе	79
Глава 3. Адаптация модели для криптовалютного рынка	80
3.1 Дополнительные признаки на основе ленты сделок	80
3.2 Фильтрация сигналов алгоритмической стратегии	86
3.3 Результаты бэктестирования итоговой стратегии	90
3.4 Выводы к третьей главе	92
Заключение	93

Список литературы	94
Список рисунков	109
Список таблиц	111

Введение

Актуальность данной работы обусловлена высокой и до сих пор растущей популярностью систем автоматизированной торговли как среди крупных компаний, так и среди частных лиц. Во-первых, автоматизация процессов торговли позволяет снизить затраты на ручной труд и во много раз повысить эффективность работы, и, следовательно, привести к значительному снижению затрат. Это особенно актуально для крупных компаний, где автоматизация может привести к значительной экономии времени и денег. Во-вторых, в связи с увеличением количества транзакций и торгуемых активов на рынке, общее количество информации в сфере торговли постоянно растет. Одновременно с этим, из-за развития беспроводных технологий, уменьшается среднее время на одну совершающую транзакцию. Поэтому для прогнозирования финансовых временных рядов необходима разработка алгоритмов и моделей, способных обрабатывать большие объемы данных за короткие сроки, что недоступно людям. Машинное обучение позволяет автоматизировать многие задачи, которые ранее требовали участия человека. Одновременно с этим, модели машинного и глубокого обучения способны анализировать большие объемы данных и, в связи с этим, принимать более точные и обоснованные решения, что особенно важно в сфере финансов, где ошибки могут иметь серьезные последствия. Современные модели машинного обучения могут работать с различными категориями данных, такими как тексты, изображения, временные ряды. Таким образом открывается возможность обрабатывать разнородную информацию, связанную с финансовыми рынками, с помощью различных моделей, которые потом могут быть объединены в один общий торговый модуль. Например, помимо самих временных рядов цен и объемов активов, следует рассматривать экономические новости и работать с ними как с текстовыми данными для предсказания дальнейшего движения рынка после выхода новости. Таким образом, используя различные источники данных и подходящие для них модели машинного обучения, можно более точно предсказываться движение рынка, используя одну систему.

1. Исследование, разработка и внедрение систем автоматизированной торговли и инвестиционных стратегий являются основной функцией управляющих финансовых организаций и обычно сводятся к решению раз-

личных задач многокритериальной оптимизации на многомерных временных рядах финансовых рынков. Далее для этого будет использоваться аббревиатура MFTS (Multidimensional Financial Time Series - многомерные временные ряды финансовых рынков). В некоторых ситуациях временные ряды могут играть вспомогательную роль. Например, в краткосрочной торговле определенные задачи арбитража решаются посредством нахождения единичных неоптимальностей в микроструктуре рынка без учета исторических данных. Однако в большинстве задач требуется анализ истории. В техническом анализе используется предыстория изменения цены актива, торговых объемов, индикаторов и осцилляторов. Также могут использоваться апериодические временные ряды, содержащие информацию о совершаемых на рынке сделках. Подобные компоненты будут рассматриваться в третьей главе данной работы. В фундаментальном анализе в качестве предыстории может использоваться последовательность отчетов компаний, публикаций, новостей, сообщений в социальных сетях, которые конвертируются в числовой формат в процессе выделения вторичных признаков рассматриваемого многомерного временного ряда.

2. Большинство задач предполагает обработку больших объемов данных и требует специализированных алгоритмов для этого. Размерность многомерного временного ряда может достигать нескольких десятков или сотен, что также относится к количеству временных шагов. Для уменьшения размерности пространства векторов в работе используются автономные кодеры, которые обозначены в архитектуре итоговой модели в главе 3. Для работы с Московской биржей используется инфраструктура, которая позволяет получать все необходимые данные в реальном времени, обрабатывать их, отсылать сигналы на биржу, а также сохранять исторические данные для дальнейших исследований. Для криптовалютного рынка в рамках данной работы были разработаны коннекторы к криптовалютным биржам для работы по API и отдельный сервер [1], решающий те же самые задачи, что и аналогичная система для Московской биржи.

3. Наиболее актуальными считаются исследования комбинированных моделей, которые позволяют сочетать в себе одновременно технический и фундаментальный анализ, т. е. обработку данных различных типов. В данной работе рассматривается комбинированный многомерный временной ряд, состоящий из регулярных и апериодических временных рядов, образованных на основе различных источников разнотипных данных, таких как числа, текст и другие. В частности, анализируются сделки других участников рынка, а также учитывается дополнительная фундаментальная информация об активах, например, график выплаты дивидендов для акций, политики дополнительной эмиссии монет и токенов в криптовалютных проектах, время работы и наложение торговых сессий различных бирж.
4. Исследование, разработка и внедрение систем автоматизированной торговли и инвестиционных стратегий способствуют развитию финансовой отрасли в России. В настоящее время огромное количество российских управляющих компаний полагаются на устаревшие примитивные системы технического анализа, дивидендную политику компаний, а иногда и на инсайдерскую торговлю или административные ресурсы. Далеко не все компании практикуют применение высокотехнологичных решений для обработки больших объемов данных многомерных временных рядов финансовых рынков, наподобие систем машинного обучения с подкреплением, в реальном времени.
5. В соответствии с посланием Президента России Федеральному Собранию Российской Федерации от 29 февраля 2024 года, капитализация российского фондового рынка к 2030 году должна удвоиться по сравнению с нынешним уровнем и составить 66% ВВП. Важно, чтобы у граждан была возможность надежно инвестировать свои сбережения в развитие страны и получать при этом дополнительные доходы. Для осуществления озвученных целей требуется разработка и внедрение как компонент инфраструктуры, так и систем принятия решений в финансовой отрасли. Отдельно стоит упомянуть рынок криптовалют. В послании Федеральному собранию данный аспект не озвучивался, однако в Государственной Думе ведутся обсуждения на тему регулирования

этой отрасли. В мире, в частности в США, ОАЭ и некоторых других странах, вопросы регулирования частично решены и криптовалюты активно внедряются среди частных и институциональных инвесторов посредством BTC-ETF фондов, а также в повседневной жизни. В связи с этим в данной работе предлагаются определенные решения, которые могут быть внедрены в России после решения вопросов, связанных с регулированием и оборотом цифровых валют. Помимо криптовалют в России уже на данный момент активно внедряются цифровые финансовые активы. Цифровые финансовые активы ЦФА — это цифровые права, включающие денежные требования и возможность осуществления прав по эмиссионным ценным бумагам и права участия в капитале непубличного акционерного общества. Они выпускаются в информационной системе на основе распределенного реестра и могут быть объектом сделок купли-продажи и иных сделок, предусмотренных законом. В настоящее время на начало 2024 года Сбер организовал площадку для торговли ЦФА, однако данная площадка функционирует пока еще только в тестовом режиме и не оснащена торговыми стратегиями и средствами для автоматизации торговли. Объем торгов также пока еще очень низкий на этих площадках.

6. Перспективным направлением решения обозначенных далее задач на многомерных временных рядах являются модели машинного обучения с подкреплением на основе архитектур DQN, Actor-Critic и других.

Целью данной работы является разработка и исследование методов решения задач прогнозирования точек разворота на многомерных временных рядах финансовых рынков на основе моделей машинного обучения с подкреплением. В качестве результата данной работы предлагается обученная и протестированная модель, являющаяся ядром полнофункциональной автоматизированной торговой системы [2]. Для достижения поставленной цели должны быть решены изложенные ниже задачи, в которых детально обозначены требования к модели, методике ее обучения, тестирования и оценки финансовых показателей, а также инфраструктурным компонентам полнофункциональной автоматизированной торговой системы.

Для достижения поставленной цели были решены следующие **задачи**:

1. Определены статистические свойства многомерных финансовых временных рядов, а именно, свойства стационарности, самоподобия, корреляции и волатильности. Понимание данных свойств необходимо при формировании выборок данных для обучения и тестирования моделей машинного обучения.
2. Оценена применимость моделей классического машинного обучения с учителем при решении задач прогнозирования на многомерных финансовых временных рядах. Нейронная сеть, обученная решению задачи классификации на размеченных данных используется в качестве базовой модели.
3. Разработана среда для обучения с подкреплением моделей на основе нейронных сетей с рекуррентными слоями типа LSTM; построена архитектура моделей; обучены и оценены модели; выполнено ансамблирование нескольких моделей в единую экспертную систему.
4. Построены дополнительные вторичные признаки для многомерных финансовых временных рядов криптовалютного рынка на основе биржевой ленты сделок. Лента сделок отражает действия других участников рынка, в частности, крупных игроков. Декодирование этой информации и выделение важных сигналов позволяет подстраиваться под тех, кто обладает большей информацией о перспективах актива или рынка.
5. Разработано гибридное решение посредством сочетания алгоритмической стратегии и модели машинного обучения, фильтрующей сигналы алгоритмической стратегии. Таким образом организован процесс решения двух оптимизационных задач: первая задача посвящена определению пары оптимальных параметров алгоритмической стратегии методом поиска на двумерной сетке, вторая задача посвящена обучению с подкреплением модели фильтрации сигналов алгоритмической стратегии. Доказано, что такой подход дает лучшие результаты в терминах финансовых показателей.

Основные положения, выносимые на защиту:

1. Доказано, что применение моделей машинного обучения позволяет достичь более высоких результатов в терминах доходности и других финансовых показателей, если они используются в качестве фильтра сигналов исходной алгоритмической стратегии, построенной на классических индикаторах или осцилляторах технического анализа, таких как экспоненциально сглаженные скользящие средние, полосы Боллинджера, индексы относительной силы и другие сглаживающие инструменты.
2. Предложен двухэтапный метод оптимизации гибридной стратегии, в рамках которого на первом этапе решается задача многокритериальной оптимизации для поиска наиболее стабильных параметров алгоритмической стратегии, а на втором этапе выполняется обучение с подкреплением DQN модели машинного обучения на данных многомерных временных рядов, дополненных сигналами исходной жесткой алгоритмической стратегии.
3. Сформированы дополнительные вторичные признаки для криптовалютного рынка, а именно апериодические признаки на основе биржевой ленты сделок. Предложена гибридная модель многомерного временного ряда, сочетающая в себе данные различных типов из нескольких источников. Разработана архитектура модели на основе нейронной сети типа DQN с модулем автокодировщика, позволяющего снизить размерность дополненного признаками временного ряда.

Научная новизна работы заключается в том, что предложен подход использования комбинированного многомерного временного ряда, сочетающего в себе первичные признаки, и вторичные, вычисленные алгоритмически, такие как уровни поддержки и сопротивления, индикаторы, осцилляторы и другие. Разработана среда для обучения с подкреплением моделей совершению торговых операций, в которой в качестве награды модели используется достигнутая ею доходность на тестовом периоде. Разработана архитектура модели машинного обучения на основе нейронной сети типа DQN (Deep Q-Network), предназначенная для прогнозирования точек разворота. Реализована комбинированная модель из жесткой алгоритмической стратегии и модели машинного обучения с подкреплением, фильтрующей сигналы алгоритмической стратегии. Обученные в разработанной среде модели встроены в систему автоматизированной

торговли, в которой являются компонентами активной среднесрочной инвестиционной стратегии и показывают лучшую результативность, чем альтернативные модели и методы, обученные с учителем решению задач классификации и регрессии на размеченных данных или построенные на средствах технического анализа алгоритмические стратегии.

Теоретическая значимость работы заключается в оригинальном решении задачи прогнозирования точек разворота на временных рядах за счет использования дополнительных апериодических вторичных признаков, и предложенном двухэтапном методе оптимизации гибридной стратегии, которая основана на классической алгоритмической стратегии, сигналы которой фильтруются посредством модели машинного обучения на архитектуре DQN (Deep Q-Network).

Практическая ценность обусловлена разработанной автоматизированной торговой системой, в составе которой реализована активная среднесрочная инвестиционная стратегия на основе прогнозирования точек разворота на временных рядах финансовых рынков посредством комбинирования базовой алгоритмической стратегии и модели машинного обучения с подкреплением. Данная система была внедрена в качестве одного из программных решений в ООО "Интеллектуальные Системы Управления" [3].

Степень достоверности результатов подтверждена экспериментальной проверкой результатов предлагаемых методов на реальных исследования в рецензируемых научных изданиях и конференциях по машинному обучению, воспроизводимостью результатов исследования при использовании различных тестовых наборов данных из публичных репозиториев данных, в том числе сторонними организациями; публикациями и докладами результатов.

Апробация работы произведена автором на следующих конференциях:

1. 2021 International Conference Engineering and Telecommunication
2. 2022 International Conference Engineering and Telecommunication

Основные результаты по теме диссертации изложены в 10 печатных изданиях [4–13], 4 из которых изданы в журналах, рекомендованных ВАК, 6 опубликованы в качестве тезисов докладов перечисленных выше конференций.

Личный вклад соискателя в работах с соавторами заключается в следующем: [1] - постановка задачи; определение статистических свойств многомерных временных рядов финансовых рынков; построение выборок данных; [2, 3, 4, 7] – проектирование и реализация моделей машинного обучения с учителем; [5, 6] - проектирование и реализация моделей машинного обучения с подкреплением; [8, 9, 10] – построение дополнительных вторичных признаков для многомерных временных рядов криптовалютного рынка; усовершенствование моделей; оценка и сравнение результатов. Содержание диссертации и основные положения, выносимые на защиту, отражают персональный вклад автора в опубликованных работах. Подготовка к публикации полученных результатов проводилась совместно с соавторами, причем вклад диссертанта был определяющим. Все представленные результаты получены лично автором.

Проработанность темы отражена в многочисленных монографиях и публикациях. Методы технического анализа, послужившие основой для построения первых систем автоматизированной торговли, подробно описаны в [14–16]. Системы технического анализа используются в настоящее время, например, подобные системы описаны в работах [17–19]. В тоже время современные системы зачастую сочетают в себе методы классического технического анализа, математическую статистику и модели машинного обучения [20–23]. Примерно с серединой 2000-ых годов модели машинного обучения начали активно применяться для решения различных задач на финансовых рынках [24–26], в том числе и на криптовалютных рынках [27]. Одной из областей применения моделей машинного обучения является высокочастотная торговля, основной задачей в которой является выявление отклонений в микроструктуре рынка. В статьях [28–30] описаны некоторые задачи высокочастотной торговли и способы их решения. В статье [31] показан процесс построения алгоритмической торговой стратегии для низколатентной финансовой системы. Необходимо отметить, что системы высокочастотной торговли требуют специализированного оборудования и соглашений с организаторами торгов, поэтому в данной работе рассматриваются менее требовательные среднесрочные торговые стратегии. Основной акцент сделан на решении задач прогнозирования на многомерных временных рядах финансовых рынков с помощью методов машинного обучения с подкреплением, в частности моделей DQN (Deep Q-Network) [32]. Подобные задачи рассматриваются во многих работах, например, в статьях [33;34] задачи ставятся в терминах

классификации и регрессии для параметров многомерных временных рядов. Во второй главе данной диссертации представлены модели, обученные решению задач бинарной и тернарной классификации. В статьях [35–37] описаны решения, основанные на построении ансамблей моделей машинного обучения. Оригинальная методика ансамблирования обученных нейронных сетей также используется в одном из решений, представленных автором в данной диссертации. Одним из современных подходов в машинном обучении является обучение с подкреплением, которое применяется для решения различных задач, в том числе и на финансовых рынках. Основные концепции данного подхода можно найти в статьях [38–40]. Модели обучения с подкреплением часто используются для решения вспомогательных задач высокочастотной торговли, например, такое применение описано в статье [41]. В современных системах автоматизированной торговли модели машинного обучения редко применяются для непосредственного прогнозирования стоимости активов. Вместо этого применяются статистические или алгоритмические стратегии, поверх которых используются модели машинного обучения [42; 43]. В третьей главе данной диссертации показано оригинальное применение нейронной сети и алгоритма обучения с подкреплением для фильтрации сигналов базовой алгоритмической стратегии. Дополнительно стоит отметить, что модели и методы машинного обучения применяются на финансовых рынках не только для решения задач прогнозирования. В статьях [44; 45] представлены способы решения задач составления портфеля и риск-менеджмента с помощью различных моделей машинного обучения.

Диссертация состоит из введения, трех глав и заключения. Полный объём текста диссертации составляет 111 страниц с 37 рисунками и 4 таблицами. Список литературы содержит 182 наименования источников.

Глава 1. Построение системы автоматической торговли

В данной главе рассмотрены основные концепции биржевой торговли и особенности функционирования криптовалютных рынков, которые были учтены в процессе разработки системы автоматической торговли и среднесрочной инвестиционной стратегии с переворотом позиций. В частности, рассмотрены способы использования уровней поддержки и сопротивления, а также некоторых других средств технического анализа. Описаны разработанные автором инфраструктурные компоненты, а именно система анализа данных в реальном времени на основе торгового терминала Quik и система бэктестирования среднесрочных стратегий.

В разделе 1.1 рассмотрены типы заявок, маржинальная торговля, особенности фьючерсов, биржевые индексы и функционал блокчейнов. Помимо этого были обозначены скользкие места предметной области, которые избегались в ходе исследований. В разделе 1.2 описана разработанная автором инфраструктура системы автоматической торговли на основе торгового терминала Quik 8.0. Предложена высокопроизводительная архитектура системы обработки финансовых данных различных типов в реальном времени средствами технического и фундаментального анализа. В разделе 1.3 для 30 криптовалютных активов с наибольшей рыночной капитализацией построена матрица корреляции временных рядов, на основе которой можно сделать вывод о сильной скореллированности всего криптовалютного рынка. При включении различных криптовалютных активов в портфель следует выполнять диверсификацию за счет различных торговых или инвестиционных стратегий, а не за счет удержания различных активов. В разделе 1.4 описана разработанная автором примитивная алгоритмическая стратегия на основе индикаторов и осцилляторов технического анализа, которая используется в качестве базовой стратегии в главах 2 и 3. Также показана важность учета уровней поддержки и сопротивления в процессе технического анализа графиков цен активов. Информация об уровнях используется в главе 2 в качестве компонент многомерных временных рядов и входных векторов моделей машинного обучения. В разделе 1.5 описана разработанная автором система тестирования и валидации среднесрочных торговых стратегий. Демонстрационные отчеты данной системы представлены в таблицах 1.9, 1.10

и на рисунке 1.11. Данная система используется далее для проверки трех разработанных стратегий, а также в процессе решения двупараметрической задачи оптимизации алгоритмической стратегии в главе 3. Сформулированы требования к финансовым показателям стратегий на основе коэффициентов Шарпа и Сортино.

1.1 Обзор основных компонент биржевой торговли

В рамках современной финансовой системы, биржи выполняют функцию организаторов торговли широким спектром финансовых инструментов, включая валюты, товары, акции, облигации, фьючерсы и опционы [46; 47]. В ходе торговых операций на рынке устанавливается равновесная цена базового актива P в единицах котируемого актива, что достигается за счет непрерывного уравновешивания спроса и предложения [48]. В данном контексте под «базовым» активом понимается актив, который приобретается, а под «котируемым» активом - актив, который продается. Торговые операции осуществляются в лотах, размеры L которых определяется нормативными документами торговой площадки, и каждый лот соответствует заданному объему базового актива.

Трейдеры могут выставлять заявки на покупку и продажу, которые классифицируются на лимитные и рыночные. Лимитные заявки регистрируются на бирже и отображаются в биржевом стакане заявок, известном также как Level 2 на американском рынке. Заявки на продажу именуются «асками» (от англ. «ask»), а заявки на покупку - «бидами» (от англ. «bid»). Каждая заявка содержит информацию о цене размещения P и торговом объеме $V = n \cdot L$ в лотах. Заявка остается в стакане до тех пор, пока не будет исполнена другим участником рынка или отменена трейдером. В отличие от лимитных, рыночные заявки не регистрируются в стакане заявок и исполняются немедленно по наилучшей доступной цене P_{best} . Рыночные заявки одних участников торгов удовлетворяют лимитные заявки других. Одна рыночная заявка может быть исполнена за счет нескольких лимитных заявок или части одной лимитной заявки, в зависимости от текущей ликвидности в стакане. При работе с крупными позициями необходимо проводить анализ стакана для предотвращения значи-

тельного проскальзывания цены. Большие игроки часто делят свои сделки на серию мелких сделок, что позволяет распределить исполнение крупной позиции на протяжении нескольких часов или дней. В рамках данной работы рассматривается обслуживание капитала до 20 млн USD, который управляет с помощью среднесрочной торговой стратегии на нескольких ведущих криптовалютных биржах, используя популярные и капиталоемкие активы и финансовые инструменты. Установленные ограничения позволяют осуществлять серии операций по средней цене P_{avg} с проскальзыванием $S = |P_{avg} - P_{best}| / P_{best} < 0.002$ от текущей наилучшей доступной цены P_{best} в течение временного интервала $\tau_{series} < 5$ (минут), что было реализовано в окончательной версии системы.

В дополнение к лимитным и рыночным заявкам, в торговле на финансовых рынках используются и другие типы ордеров, такие как айсберг-заявки, стоп-лосс и тейк-профит ордера. Айсберг-заявка представляет собой крупный ордер на покупку или продажу, который отображается на рынке лишь частично, что позволяет институциональным инвесторам скрыть реальный объем своих позиций и минимизировать влияние на цену актива. В рамках данной работы айсберг-заявки не используются, однако крупные ордера объема V разбиваются на серию из N_{series} сделок объема v исполняемую за время τ_{series} таким образом, что $V = N_{series} \cdot v$. Стоп-лосс ордер является инструментом защиты от потенциальных убытков, который автоматически закрывает позицию при достижении ценой установленного трейдером уровня P_{stop} . Этот тип ордера позволяет ограничить потери в случае неблагоприятного движения рынка. В данной работе используется трейлинг стоп-лосс ордер, который автоматически корректируется в соответствии с изменениями рыночной цены P , сохраняя заранее определенное расстояние $\delta = 0.1 \cdot P_{avg}$ от нее, где P_{avg} - средняя цена открытия позиции. Такой подход позволяет защитить позицию от потерь при обратном движении цены, не снижая при этом потенциальную прибыль при ее росте. Тейк-профит ордер используется для фиксации прибыли, автоматически закрывая позицию при достижении ценой P установленного трейдером уровня P_{take} . Он позволяет трейдерам зафиксировать прибыль в случае благоприятного движения рынка. В данной работе не предусмотрено использование тейк-профит ордеров, поскольку закрытие прибыльных позиций осуществляется в соответствии с сигналами системы принятия решений трендовой торговой стратегии, а не на основе жестко заданных алгоритмических параметров.

Заявка	Видимость	Проскальзывание	Использование
рыночная	нет	есть	стратегия
лимитная	да	отсутствует	нет
стоп-лосс	нет	есть	трейлинг
тейк-профит	да	отсутствует	нет
айсберг	частично	отсутствует	нет

Таблица 1 — Особенности рассматриваемых и используемых торговых заявок.

В процессе анализа стакана заявок на бирже, критически важно учитывать спред котировок, который представляет собой разность между ценами предложения и спроса по определенному активу. К примеру, если оптимальная покупательская цена актива P_{bid} составляет 100 у.е., в то время как наилучшая продажная цена той же актива P_{ask} равна 105 у.е., то спред котировок $s = P_{ask} - P_{bid}$ или 5 у.е. Данный показатель является одним из ключевых индикаторов ликвидности рынка: чем ниже спред, тем выше ликвидность. Спред также может служить основой для расчета комиссионных сборов брокера или дилера, обычно выражаемых в процентах от величины спреда как $r_{tax} \cdot s$. В рамках данной работы спред не оказывает значительного воздействия на эффективность торговых стратегий, благодаря использованию высоколиквидных финансовых инструментов с низким спредом $s < 0.1\%$ и применению среднесрочных стратегий с ограниченным количеством транзакций. Помимо стакана заявок, биржи предоставляют информацию о завершенных сделках через ленту сделок, известную как Level 1 на американском рынке. Лента сделок отражает все исполненные ордера участников рынка по каждому торгуемому инструменту в режиме реального времени. В работе данные о совершенных сделках используются для формирования вторичных признаков входного вектора моделей принятия решений и обработки данных.

Основным торгуемым финансовым инструментом в рамках данной работы являются бессрочные фьючерсные контракты на криптовалютные ак. Фьючерсные контракты являются соглашениями о купле-продаже базового актива, где условия цены P_f и срока T_{exp} поставки определяются сторонами, в то время как остальные характеристики актива зафиксированы в спецификации контракта [49]. Фьючерсы можно рассматривать как стандартизованные версии форвардных контрактов, торгуемых на централизованных рынках. Основное отличие между форвардами и фьючерсами заключается в том, что форварды

представляют собой индивидуальные сделки, проводимые вне биржевого пространства, тогда как фьючерсы являются биржевыми инструментами с многократным исполнением. Фьючерсы обладают определенным сроком экспирации T_{exp} , который представляет собой дату истечения контракта и необходимости исполнения поставки базового актива. Например, при истечении фьючерсного контракта на нефть 15 июня, покупатель обязан приобрести нефть, а продавец — продать ее по цене P_f , установленной в контракте, до указанной даты. В дополнение, существуют бессрочные фьючерсные контракты, не имеющие срока экспирации, что позволяет участникам рынка поддерживать позиции на неопределенный срок. Такие контракты часто применяются на товарных рынках, включая нефть, золото, серебро и другие, обеспечивая трейдерам возможность извлекать прибыль от колебаний цен на базовые активы без обязательства их покупки или продажи в конкретный момент времени. Цена фьючерсного контракта P_f определяется таким образом, чтобы инвестору было равнозначно выгодно как приобретение актива на спотовом рынке с немедленной поставкой, так и заключение фьючерсного контракта на этот актив с учетом соответствующего срока экспирации. Расчет цены фьючерсного контракта P_f с датой экспирации может быть произведен по следующей формуле:

$$P_f(t, T) = P_{base}(t) \cdot (1 + r)^{(T_{exp} - t)}, \quad (1.1)$$

где P_{base} - стоимость базового актива в момент времени t , r - ставка дисконтирования, T_{exp} - дата экспирации. Разница между ценой базового актива и ценой фьючерса называется базисом и может быть как положительной, так и отрицательной. Ситуация, когда цена на фьючерсный контракт выше, чем цена на базовый актив, называется контанго. Обратная ситуация называется бэквордацией. В данной работе используются исторические данные некоторых фьючерсов на товары с МОЕХ в процессе анализа данных и выявления моделей и методов, наиболее подходящих для решения поставленных задач [50]. Финальная модель, предложенная в рамках данной работы, ориентирована на управление портфелем фьючерсных контрактов с плечом на BTC, ETH и другие криптоактивы. Финансовый инструмент, известный как «плечо», предоставляет трейдерам возможность усиливать свои позиции на рынке за счет использования заемных средств. Это дает трейдеру способность приобретать или продавать объем активов, превышающий его текущие собственные средства. Например,

при наличии 1000 у.е. на счету, трейдер может воспользоваться плечом 1:10 для покупки актива на сумму 10000 у.е., используя лишь 1000 у.е. собственных средств. Плечо может значительно увеличить потенциальную прибыль, однако, оно также усиливает риски, поскольку при снижении цены актива, потери могут превысить первоначальные инвестиции. В случае неблагоприятного движения рынка, брокер может произвести ликвидацию позиции для минимизации рисков. Если трейдер использует исключительно собственные средства, то для полной потери инвестиций цена актива должна упасть до нуля. Однако, при использовании плеча 1:20, достаточно снижения цены всего на 5%, чтобы вызвать ликвидацию позиции, так как дальнейшее движение цены ставит под угрозу заемные средства брокера. В современных условиях брокеры обычно автоматически закрывают такие позиции, чтобы избежать рисков, связанных с предоставлением заемных средств. Подобная практика известна на финансовых рынках как маржинальная торговля и используется в данной работе.

На фондовом рынке в качестве базового актива выступают ценные бумаги, такие как акции компаний или государственные облигации, а котируемым активом является валюта. Акции представляют собой долевые инструменты, выпускаемые компаниями с целью привлечения капитала. Владельцы акций получают статус совладельцев компании и право на долю в ее прибыли в виде дивидендов, а также возможность участвовать в управлении компании через голосование на собрании акционеров [51]. Существуют два основных типа акций: обыкновенные и привилегированные. Обыкновенные акции предоставляют право на получение дивидендов и участие в управлении, в то время как привилегированные акции гарантируют фиксированный дивиденд, но не дают права голоса в управлеченческих решениях. В рамках данной работы анализируются акции 50 российских компаний, входящих в индекс МОЕХ.

Традиционно, акции рассматриваются как инструменты для долгосрочного инвестирования с целью получения дивидендов, которые являются частью прибыли компании, распределяемой среди акционеров в форме наличных средств или дополнительных акций [52]. Дивиденды служат вознаграждением за вложения акционеров, способствующие развитию компании. Размер и периодичность выплат дивидендов зависят от финансовых результатов компании и решений ее совета директоров. В случае отсутствия прибыли, дивиденды могут быть сокращены или не выплачиваться вовсе. На российском фондовом

рынке существуют компании, выплачивающие дивиденды, в том числе так называемые «голубые фишки» [53]. Однако, целью данной диссертации является разработка среднесрочных трендовых торговых стратегий, ориентированных на изменения стоимости базовых активов, а не на получение дивидендов.

В процессе анализа данных фондового рынка необходимо учитывать дивидендные отсечки, представляющие собой временные точки, когда происходит выплата дивидендов. Это связано с тем, что в день выплаты дивидендов часто наблюдается гэп на графике стоимости акций, то есть разрыв между ценой открытия текущего дня и ценой закрытия предыдущего. Гэп, достигающий в некоторых случаях нескольких процентов, может внести значительную погрешность в результаты работы систем анализа данных и принятия инвестиционных решений. В рамках данного исследования использовался дивидендный календарь сервиса Smart Lab [54] для отслеживания дивидендных выплат, что позволило получить как исторические, так и данные в реальном времени во время тестирования прототипа. Однако, после перехода на криптовалютный рынок, данный модуль был исключен из использования. Следует также отметить, что явление гэпа характерно для торговых площадок, которые прекращают работу на ночь или на выходные. В результате, на открытии биржи после такого перерыва цена активов может существенно отличаться от цены закрытия предыдущей торговой сессии. Расписание торгов на МОEX доступно на её официальном сайте [55]. В отличие от традиционных бирж, криптовалютные платформы функционируют круглосуточно, что исключает возникновение ценовых разрывов.

В данной работе анализируются торговые стратегии, оперирующие как длинными, так и короткими позициями. Длинная позиция означает покупку актива с целью последующей продажи по более высокой цене, что приводит к получению прибыли в единицах котируемого актива. Эта стратегия соответствует долгосрочной инвестиционной стратегии «купи и держи» и рассматривается в данной работе в качестве эталона. Короткая позиция предполагает более сложную схему: заем актива у брокера или другого участника рынка, последующую продажу по текущей высокой цене и выкуп по более низкой цене в будущем. Этот подход позволяет получать прибыль на понижении стоимости актива, но сопряжен с более высокими рисками и потенциально меньшей доходностью. Например, если актив был приобретен по цене 50 у.е. и продан по цене 100 у.е., рост стоимости актива составит 100%. В случае открытия короткой позиции

при цене актива 100 у.е. с расчетом на снижение до 50 у.е., величина движения цены составит 50%, несмотря на равное изменение в абсолютных единицах. При открытии короткой позиции взимается комиссия, пропорциональная размеру и сроку займа, что увеличивает стоимость использования заемных средств.

Отдельно следует рассмотреть биржевые индексы, которые используются в данной работе при проверке корреляции временных рядов. Биржевые индексы представляют собой индикаторы, отражающие динамику цен на акции компаний, торгующихся на фондовых биржах [56]. Они рассчитываются на основе цен акций выбранного набора компаний, входящих в индекс, и используются для оценки общего состояния экономики страны или региона, а также эффективности инвестиций в акции [57; 58]. Биржевые индексы могут быть общего характера, как S&P 500 [59] в США, или специализированными, как NASDAQ Biotechnology Index [60] для биотехнологической отрасли. При расчете индекса учитываются такие параметры, как капитализация компаний, количество акций в обращении и их цена, а также некоторые другие параметры. Методика расчета каждого индекса может изменяться со временем. Индексы часто используются в качестве ориентиров для приостановки торгов на биржах и служат бенчмарками для инвестиционных фондов, стремящихся превзойти их доходность. Индекс Доу-Джонса [61], один из самых старых и известных биржевых индексов, был создан Чарльзом Доу в 1896 году и отражает динамику цен на акции 30 крупнейших компаний, торгующихся на Нью-Йоркской фондовой бирже (NYSE) [62]. Индекс I_{DJIA} является одним из основных индикаторов состояния экономики США и рассчитывается по следующей формуле:

$$I_{DJIA}(t) = \frac{1}{N} \sum_{i=1}^N (P_i(t) \cdot M_i(t)), \quad (1.2)$$

где N - общее количество компаний, изначально 30 крупнейших промышленных компаний США, $P_i(t)$ - стоимость акции i -ой компании в момент времени t , $M_i(t)$ - коэффициент масштабируемого среднего для i -ой компании в момент времени t , который изменяется всякий раз, когда входящие в расчетную формулу акции подвергаются сплиту или консолидации. Сплит акций — это процесс, при котором количество акций компании увеличивается, но их общая стоимость остается неизменной. Это может происходить по разным причинам, например, для увеличения ликвидности акций или для привлечения новых

инвесторов. Консолидация является обратным процессом. Подобная методика расчета позволяет сохранить сопоставимость индекса с учётом изменений во внутренней структуре входящих в него акций. Индекс Доу Джонса обладает недостаточной репрезентативностью и диверсификацией. Например, если одна компания заметно меньше по капитализации, чем другая, но стоимость одной её акции выше, то она сильнее влияет на индекс. По этой причине для анализа рынка рекомендуется использовать другие индексы, например, S&P 500 или Russel 2000 [63]. На данный момент основными российскими биржами являются Московская биржа (МОЕХ) [64] и Санкт-Петербургская биржа (SPBE) [65]. В данной работе в процессе исследования будут использоваться данные по двум российским индексам [66] - МОЕХ (IMOEX) [67] и РТС (RTSI) [68]. Индекс МОЕХ, который ранее назывался индекс ММВБ — это один из основных ценных фондовых индексов России, который отражает изменения цен на акции 50 крупнейших российских компаний [69], торгующихся на фондовой секции МОЕХ. Расчет индекса I_{MOEX} производится по следующей формуле:

$$I_{MOEX}(t) = I_{MOEX}(0) \cdot \sum_{i=1}^N \frac{C_i(t)}{C_i(0)}, \quad (1.3)$$

где $I_{MOEX}(0)$ - значение индекса в начальный момент времени, N - общее количество компаний, на данный момент 50 крупнейших компаний России, $C_i(t)$ - рыночная капитализация i -ой компании в момент времени t , $C_i(0)$ - рыночная капитализация i -ой компании на начальную дату. При расчете рыночной капитализации учитываются цена и количество соответствующих акций, что выражается значением коэффициента free-float. Free-float — это доля акций компании, которые находятся в свободном обращении на рынке. Это акции, которые не принадлежат крупным акционерам или самой компании. Free-float рассчитывается как отношение количества акций, находящихся в свободном обращении, к общему количеству акций компании. Он показывает, какая часть акций компании доступна для покупки и продажи на рынке. Расчет индекса производится в режиме реального времени в рублях. Таким образом, значение индекса пересчитывается при совершении каждой сделки на МОЕХ с акциями,ключенными в базу расчета индекса. Вторым важным для российского рынка индексом является индекс РТС, расчёт которого начался 1 сентября 1995 года

со 100 пунктов. Индексы МОEX и РТС имеют единую базу расчета. Индекс РТС также рассчитывается на МОEX, но вычисляется в долларах США.

Криптовалюты представляют собой цифровые активы, использующие криптографические методы для обеспечения безопасности транзакций и управления процессом эмиссии новых единиц [70–72]. Они являются децентрализованными финансовыми инструментами, не подлежащими контролю со стороны центральных банков или государственных органов. Ведение учета и обращение криптовалют осуществляется через блокчейн — технологию распределенного реестра, хранящего данные о всех проведенных транзакциях. Каждая транзакция фиксируется в отдельном блоке, который последовательно встраивается в цепочку блоков, обеспечивая тем самым прозрачность и надежность системы, поскольку каждый участник сети может верифицировать транзакции.

Многообразие криптовалют характеризуется уникальными особенностями и сферами применения каждой из них. К наиболее известным криптовалютам относятся биткоин (BTC) [73], эфириум (ETH) [74], лайткоин (LTC) [75] и ripple (XRP) [76]. Согласно позиции регуляторов, таких как Комиссия по ценным бумагам и биржам США (SEC) [77], BTC классифицируется как товар и подлежит соответствующему регулированию. Предполагается, что аналогичное положение будет применено и к ETH. Остальные криptoактивы на момент проведения исследования рассматриваются как ценные бумаги. Регулирование криптовалютного рынка находится на начальной стадии развития, что сопровождается значительным количеством рыночных манипуляций, инсайдерской торговлей и мошенничеством [78; 79]. В контексте криptoактивов различают монеты и токены. Монета функционирует на базе собственного блокчейна, в то время как токен создается на основе уже существующего блокчейна. Для полного понимания данного исследования не требуется глубоких знаний о принципах работы блокчейн-технологий. Для самостоятельного изучения рекомендуется ознакомиться с технической документацией биткоина (white paper BTC) [80], описывающей ключевые характеристики и технические аспекты данной технологии.

Криптовалютные биржи классифицируются на централизованные (CEX) и децентрализованные (DEX). Централизованные биржи функционируют под управлением одной организации или группы лиц, которые осуществляют контроль над операциями. В отличие от них, децентрализованные биржи представляют собой платформы, управляемые коллективом пользователей и алгоритма-

ми, обеспечивающими автономную торговлю. На момент проведения данного исследования к ведущим децентрализованным биржам относятся Uniswap [81], PancakeSwap [82] и dYdX [83]. В рамках данного анализа акцент делается на централизованных биржах, таких как Binance [84], Bybit [85] и Gate [86], поскольку они предоставляют высокую ликвидность для рассматриваемых активов и инструментов, а также располагают развитым API [87] для создания программных интерфейсов коннекторов и автоматических торговых систем.

Торговые пары на криптовалютных биржах обычно состоят из двух криптовалютных активов. В данном исследовании в качестве котируемого актива выступает стейблкоин USDT [88], выпущенный компанией Tether [89]. Стейблкоин — это тип криптовалюты, стоимость которой привязана к стоимости другого актива, например, к фиатной валюте, такой как доллар США. Основная цель стейблкоина — обеспечение стабильности цены и снижение волатильности, характерной для большинства криптовалют. Для поддержания связи со стоимостью базового актива стейблкоины используют механизм обеспечения. Например, стейблкоин, привязанный к доллару США, может подкрепляться долларовыми резервами, размещенными на банковских счетах. Это гарантирует стабильность цены стейблкоина, так как его стоимость всегда соответствует стоимости базового актива. В качестве альтернативы USDT может выступать стейблкоин USDC [90], выпущенный компанией Circle [91]. Стейблкоины USDT и USDC поддерживаются на различных блокчейнах, включая Ethereum [92], Solana [93] и Tron [94], и могут перемещаться между блокчейнами с использованием специальных мостов или через биржевые платформы. Кроме обеспечения фиатной валютой, существуют стейблкоины, подкрепленные залогом или алгоритмические стейблкоины, однако они не рассматриваются в данной работе из-за их относительной ненадежности и склонности к отклонениям от соотношения 1 к 1. В случае алгоритмического стейблкоина рса 1 к 1. В случае с алгоритмическим стейблкоином USTC [95] проекта Terra [96], отклонение от паритета в мае 2022 года привело к катастрофическим последствиям.

1.2 Возможности систем автоматической торговли

В рамках организационной структуры биржевых операций, серверы некоторых участников рынка могут быть размещены в торговом зале или в непосредственной близости к нему. Это особенно важно для участников, занимающихся высокочастотной торговлей (HFT). Высокочастотная торговля представляет собой методологию совершения сделок на финансовых биржах, характеризующуюся использованием специализированных алгоритмов и программного обеспечения, обеспечивающих минимальную задержку в обработке данных и реакции на рыночные события [97–99]. Трейдеры, практикующие HFT, применяют высокоскоростные вычислительные системы для анализа рыночных данных и автоматизации процесса совершения сделок [100]. Способность проводить тысячи транзакций в секунду позволяет им извлекать прибыль из микроскопических колебаний цен. В HFT используются разнообразные стратегии, включая межбиржевой и статистический арбитраж, маркет-мейкинг и скальпинг, а также алгоритмы машинного обучения для оптимизации принятия торговых решений [101]. Высокочастотная торговля может принести значительную прибыль, однако она также связана с определенными рисками. Исследования указывают на то, что HFT может способствовать увеличению волатильности на рынке и повышению рисков для других его участников. Популярность HFT в последние годы обусловлена сильным прогрессом в области информационных технологий и доступностью высокопроизводительных вычислительных систем [102]. Для эффективности высокочастотной торговли критически важно размещение серверов участников в непосредственной близости к серверам биржи, что позволяет сократить время передачи данных за счет уменьшения длины физического сетевого соединения. В такой инфраструктуре ключевую роль играют инженеры и програмисты, обеспечивающие бесперебойную работу биржевых систем, торговых терминалов и других сервисов [103–105]. В последующих разделах работы будет представлен обзор основных торговых и инвестиционных стратегий, а также технологий и инструментов, применяемых в каждом из них.

Торговый терминал Quik [106], или Quickly Updatable Information Kit,веден в эксплуатацию в 1999 году и на текущий момент широко применяется в деятельности более чем 350 банков, инвестиционных фондов и управляющих

компаний, что составляет примерно 80% доли рынка. Настоящее исследование предполагает использование указанной российской программной платформы для обеспечения доступа к операциям на фондовом рынке через сеть интернет [107]. На рисунке 1.1 изображено функциональное пространство торгового терминала Quik. На заднем плане видно стандартное окно с экономическими новостями и окно для запуска пользовательских плагинов. На переднем плане расположены две консоли с выводом информации от пользовательского плагина. В данном контексте, система не выполняет самостоятельные торговые операции, а лишь предоставляет рекомендации трейдеру. Данный торговый терминал дает возможность запускать пользовательские плагины для автоматизации процессов на бирже, которые способны оперативно получать, обрабатывать и отправлять команды на биржу для управления позициями. Приведенный рисунок был заимствован автором из собственной диссертации, защищенной в 2020 году при подготовке магистерской работы, посвященной разработке плагина для торгового терминала Quik на базе многоагентной системы [108]. Многоагентная система представляет собой совокупность взаимодействующих активных или пассивных интеллектуальных агентов и широко применяется для решения задач, которые затруднительно или даже вовсе невозможно решить с применением централизованных компьютерных систем с монолитным ядром.

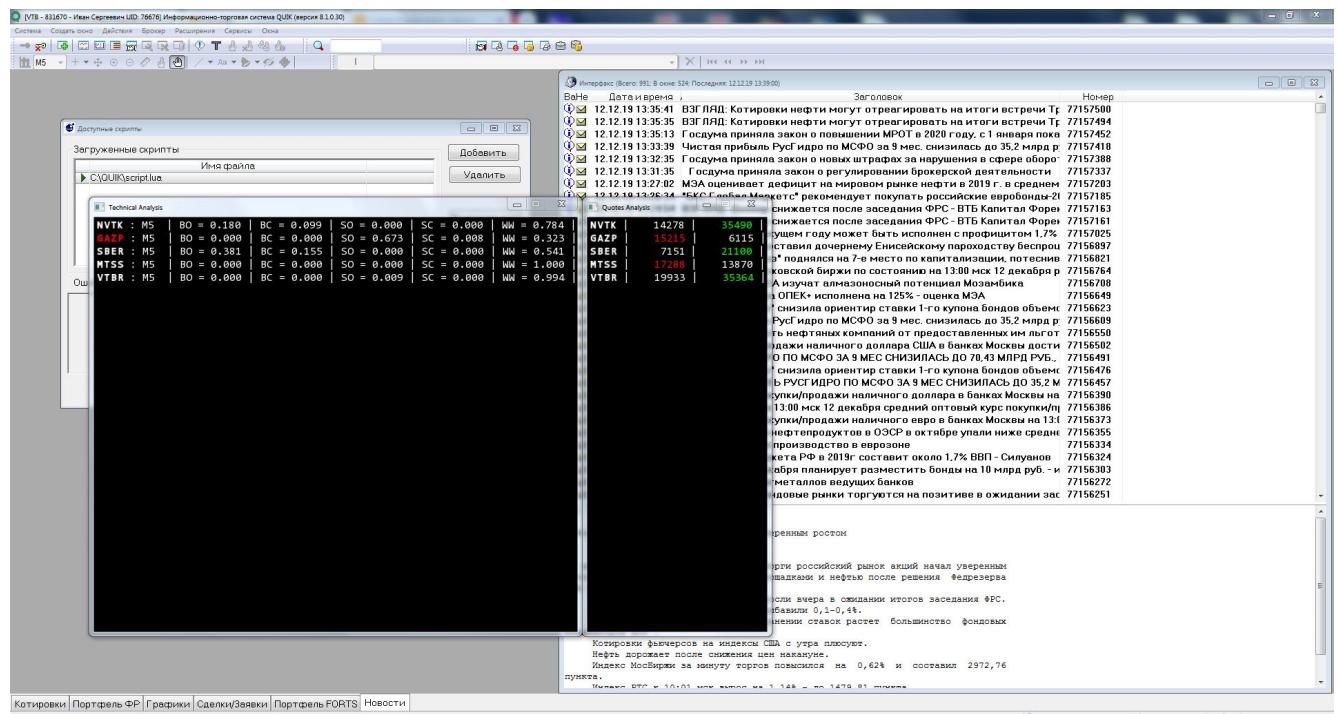


Рисунок 1.1 — Рабочее пространство торгового терминала Quik 8.0.

На рисунке 1.2 представлена структура автономной высокопроизводительной многоагентной системы в реальном времени, разработанной для операций с активами на фондовой секции МОEX. Взаимодействие с серверами МОEX осуществляется через терминал QUIK версии 8.1.0.30, функционирующий под управлением операционной системы Windows 10 x64. Особое внимание следует уделить тому, что модуль сбора данных работает как независимый процесс, и для эффективного межпроцессного обмена данными через общую память требуется одинаковая разрядность процессов. Главная система также использует 64-битную архитектуру, что диктуется необходимостью применения фреймворка Tensorflow [109] для обработки входящих данных. Все собранные данные хранятся в кэше терминала. Терминал QUIK предоставляет возможность запуска пользовательских скриптов на языке LUA [110] для дальнейшей обработки данных с использованием внешних алгоритмов. Ввиду ограниченных возможностей языка LUA по сравнению с C++, основная обработка данных производится на сервере на C++, который обозначен на схеме как System. Скрипты LUA в рамках терминала QUIK работают через DLL-библиотеку [111], которая активируется из терминала. Этот плагин использует LUA-CPP API для доступа к данным в кэше терминала, после чего осуществляет их форматирование и записывает в соответствующие сегменты создаваемой им общей памяти. Для улучшения производительности в общей памяти используется общий контейнер, при этом для его корректной работы необходимо, чтобы разрядность взаимодействующих процессов была одинаковой, как уже было указано, используется 64-битная архитектура. Сервер функционирует как отдельный процесс, аналогично процессу терминала. На сервере выполняется обработка данных в специальных модулях технического и фундаментального анализа.

Торговые системы, такие как QUIK, позволяют участникам рынка размещать заявки на покупку или продажу активов [112]. Эти системы гарантируют прозрачность и безопасность транзакций. Биржи, в свою очередь, проводят клиринг и расчеты по сделкам. Клиринг представляет собой процесс проверки и подтверждения транзакций, а расчеты - это процесс перевода денежных средств и активов между участниками рынка. Биржи также предоставляют механизм «поставка против платежа», который обеспечивает поставку активов только после получения оплаты, и ведут учет всех транзакций, что позволяет участникам рынка иметь полную информацию о своих операциях и контролировать

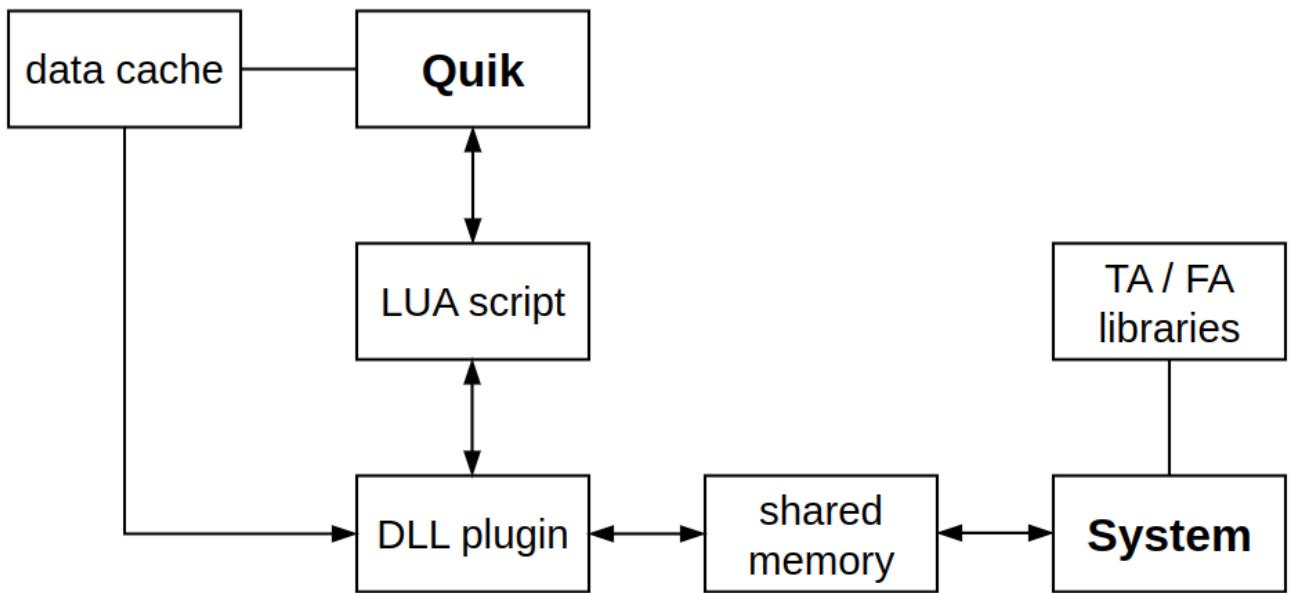


Рисунок 1.2 — Архитектура системы автоматической торговли для QUIK.

свои позиции. Это способствует снижению рисков и повышению безопасности сделок. Современные биржи подчиняются строгим регуляторным нормам и правилам, установленным государственными органами или саморегулирующимися организациями. На сегодняшнем этапе развития биржевой торговли активно используются машинное обучение, блокчейн и другие новейшие технологии.

1.3 Долгосрочные и краткосрочные стратегии

Инвестиционные стратегии классифицируются на основе временного горизонта вложений и могут быть категоризированы как долгосрочные, среднесрочные и краткосрочные. Долгосрочные стратегии характеризуются удержанием инвестиционных позиций на протяжении значительных периодов времени, которые могут охватывать несколько лет или даже десятилетий. Эти стратегии, по существу, отличаются от традиционных методов управления активами, поскольку они предполагают минимальное количество транзакций и подразумевают долгосрочное удержание активов. Существует несколько подтипов долгосрочных инвестиционных стратегий, каждый из которых имеет свои уникальные характеристики и предполагает различные уровни участия инвестора.

Стратегия инвестирования «купи и держи» представляет собой методологию, при которой инвесторы приобретают акции или другие финансовые активы с намерением сохранять их в своем портфеле на протяжении значительного временного промежутка. Этот подход игнорирует краткосрочные колебания рыночных цен и основывается на гипотезе о том, что рынок имеет тенденцию к росту в долгосрочной перспективе, что позволяет инвесторам реализовать прибыль, если они проявляют терпение и не продают активы во время временных рыночных флуктуаций. В последующем анализе данная стратегия будет использоваться в качестве эталона для оценки доходности и других финансовых показателей по сравнению с разработанными стратегиями активного управления портфелем. При реализации долгосрочных инвестиционных стратегий ключевым аспектом является не столько управление существующей позицией, сколько выбор соответствующего актива и определение оптимального момента для входа в позицию, учитывая, что стоимость ошибки в данном контексте может быть значительной. Следует отметить, что среди всех активов, подходящих для стратегии «купи и держи», криптовалюта BTC демонстрирует наиболее высокую эффективность. На рисунке 1.3 представлены данные, показывающие, что с конца 2017 года по начало 2024 года стоимость BTC выросла приблизительно на 1300%, при этом криптовалюта обладала значительной рыночной капитализацией. На момент проведения данного исследования рыночная капитализация BTC превысила 1 триллион долларов США [113]. Важно обратить внимание на периоды резкого увеличения и последующего снижения стоимости актива, которые коррелируют с процессом халвинга. Криптовалюты характеризуются значительно более высокой волатильностью по сравнению с традиционными финансовыми активами, такими как акции, облигации или товары.

Для визуализации изменений стоимости активов в данном исследовании используются японские свечи [114; 115]. Каждая свеча, окрашенная в красный или зеленый цвет, соответствует одному интервалу в дискретном временном ряду, который может быть минутой, часом или днем. Красный цвет свечи указывает на снижение цены за данный интервал, в то время как зеленый цвет свидетельствует о ее росте. Тонкие линии, расположенные выше и ниже тела свечи, отражают внутридневные колебания цены. Таким образом, каждая свеча характеризуется четырьмя ключевыми параметрами: ценой открытия P_{open} , максимальной и минимальной ценами P_{max} и P_{min} , а также ценой закрытия

P_{close} , и одним дополнительным параметром — объемом торгов V , представляющим общую стоимость сделок, совершенных за данный временной шаг.

В рамках исследовательской работы целесообразно провести сопоставление с классическими финансовыми рынками. На рисунке 1.4 показано, что рост индекса Московской Биржи (МОЕХ) с определённого временного отсчёта составил приблизительно 56%, что значительно уступает росту первой криптовалюты. Индекс S&P 500 за аналогичный период времени продемонстрировал прирост на уровне 96%, что подтверждается независимыми данными. Тем не менее, данный показатель превышает результаты BTC более чем в 13 раз. Следует отметить, что волатильность индекса МОЕХ, выраженная в процентном соотношении, значительно ниже по сравнению с активами первого эшелона криптовалютного рынка. В целом, фазы роста индекса МОЕХ характеризуются относительной стабильностью без резких колебаний. Увеличение волатильности преимущественно наблюдается в периоды экономических кризисов, например, в марте 2020 года, связанного с глобальным распространением коронавирусной инфекции, и в феврале 2022 года, обусловленного началом специальной военной операции на территории Украины. Кроме BTC, существуют иные криptoактивы, которые могли продемонстрировать ещё более значительный рост, достигая нескольких десятков тысяч процентов за сопоставимый временной интервал, однако в данном сравнении они не рассматриваются из-за относительно небольшой капитализации и нестабильности проектов, которые они представляют.

Стратегия инвестирования, известная как «покупай низко, продавай высоко» (Buy Low, Sell High), основывается на принципе приобретения активов в момент их недооценки и последующей реализации при их переоценке. Данная методика требует от инвестора способности к глубокому анализу рыночных условий для определения текущей стоимости активов. В контексте стратегии «индексное инвестирование» (Index Investing), инвесторы осуществляют вложения в такие индексы, как S&P 500 или Dow Jones Industrial Average, путём покупки акций всех компаний, входящих в состав индекса, и их долгосрочного удержания [116; 117]. Этот подход позволяет инвесторам распределить инвестиционные риски за счёт диверсификации портфеля и обеспечить участие в общем росте рынка. Стратегия «инвестирование в дивидендные акции» (Dividend Investing) предполагает выбор акций компаний с высокими дивидендными выплатами.



Рисунок 1.3 — Свечной график стоимости BTCUSDT с биржи Binance.



Рисунок 1.4 — Свечной график значений индекса Московской биржи.

платами, что обеспечивает инвесторам регулярный доход в виде дивидендов и потенциал для прироста капитала благодаря увеличению стоимости акций.

В современной финансовой практике термин «краткосрочная торговля» часто ассоциируется с разработкой и применением систем высокочастотной торговли (HFT), где продолжительность удержания торговой позиции может ва-

рьороваться от нескольких микросекунд до нескольких часов или даже дней. Стратегии HFT могут охватывать различные подходы, включая скальпинг, треугольный арбитраж, статистический арбитраж, межбиржевой арбитраж и маркет-мейкинг, среди прочих [118; 119]. В рамках данного исследования особое внимание уделяется статистическому арбитражу, который связан с корреляционными свойствами временных рядов различных активов. Статистический арбитраж представляет собой торговую стратегию, базирующуюся на использовании статистических данных и математических моделей для предсказания будущих ценовых движений активов. Данная стратегия исходит из предположения о предсказуемости цен активов на основе анализа исторических данных и статистических моделей. Ключевая концепция статистического арбитража заключается в использовании этих моделей для определения моментов, когда активы являются переоцененными или недооцененными, с последующей торговлей в целях извлечения прибыли. Например, на криптовалютном рынке наблюдается высокая корреляция между активами. В качестве доминирующего актива выступает BTC, за ним следует ETH, а затем — другие альткоины. Большинство монет, особенно из первого эшелона, тенденциозно следуют за динамикой BTC. На рисунке 1.5 иллюстрируется матрица корреляции, составленная автором на основе анализа скоррелированности ценовых графиков 30 ведущих криптовалют по капитализации. В исследовании использовались минутные свечные графики стоимости активов. В качестве базовой валюты в валютных парах во всех аналогичных случаях выступает USDT. Для каждой пары криптовалют на каждом временном шаге проводилось сравнение направления движения цены. Совпадение направлений указывает на наличие корреляции, в то время как противоположные направления движения свидетельствуют об антикорреляции. Коэффициент корреляции выражается с помощью следующей формулы:

$$C_{ij} = \frac{1}{N} \sum_{i=0}^N (PD_i \cdot PD_j > 0 ? 1 : 0), \quad (1.4)$$

где i и j - индексы рассматриваемых временных рядов, N - общее количество временных шагов, PD - Price Deviation. Под знаком суммы для компактности используется тернарный оператор. В рамках данного анализа коэффициентов корреляции, следует отметить, что в расчет принимаются исключительно те случаи, когда изменения цен активов совпадают по направлению. Таким обра-

зом, вычисляется пропорция временных интервалов, в течение которых активы демонстрировали идентичное поведение. Важно подчеркнуть, что криптовалютный рынок характеризуется высокой степенью корреляции, что, в свою очередь, обусловлено общими механизмами функционирования и регулирования данных активов. Присутствие такой значительной корреляции между активами делает невозможным создание диверсифицированного портфеля из различных криптовалют, что требует применения разнообразных стратегий, включая трендовые и контртрендовые подходы. В последующих разделах исследования будет проведен анализ корреляции активов, обращающихся на МОEX. Стратегии статистического арбитража включают в себя поиск индивидуальных активов, чье поведение в определенный момент времени отклоняется от общей динамики рынка. Это могут быть, например, недооцененные или переоцененные активы. На основе выявленных коэффициентов корреляции и других статистических данных можно разработать стратегию, которая будет осуществлять динамическое балансирование портфеля активов и корректировку позиций в активах.

Современные стратегии высокочастотной торговли (HFT) характеризуются полной автоматизацией и осуществляются с использованием специализированного оборудования. Эффективность HFT зависит не только от применения интегрированных программно-аппаратных решений, но и от выполнения ряда дополнительных условий. К таким условиям относятся, например, заключение договоров с торговыми площадками о снижении комиссионных сборов, доступ к закрытым программным интерфейсам (API), а также стратегическое размещение торговых серверов в непосредственной близости к серверам биржи. Учитывая вышеуказанные спецификации, в данной работе не рассматриваются подходы к краткосрочной торговле. Вместо этого, акцент смещается на среднесрочные торговые стратегии, при которых торговые позиции поддерживаются в течение временного промежутка от нескольких часов до нескольких дней, а процесс обработки данных и принятия решений может занимать до нескольких минут. В сегменте среднесрочной торговли участвуют различные фонды, частные и институциональные инвесторы, а также индивидуальные участники с ограниченным капиталом и базовыми знаниями в области инвестиций. В отличие от краткосрочной торговли, где конкуренция является высокой, среднесрочная торговля характеризуется меньшей конкурентной напряженностью, и результаты стратегий могут проявляться в течение нескольких недель или

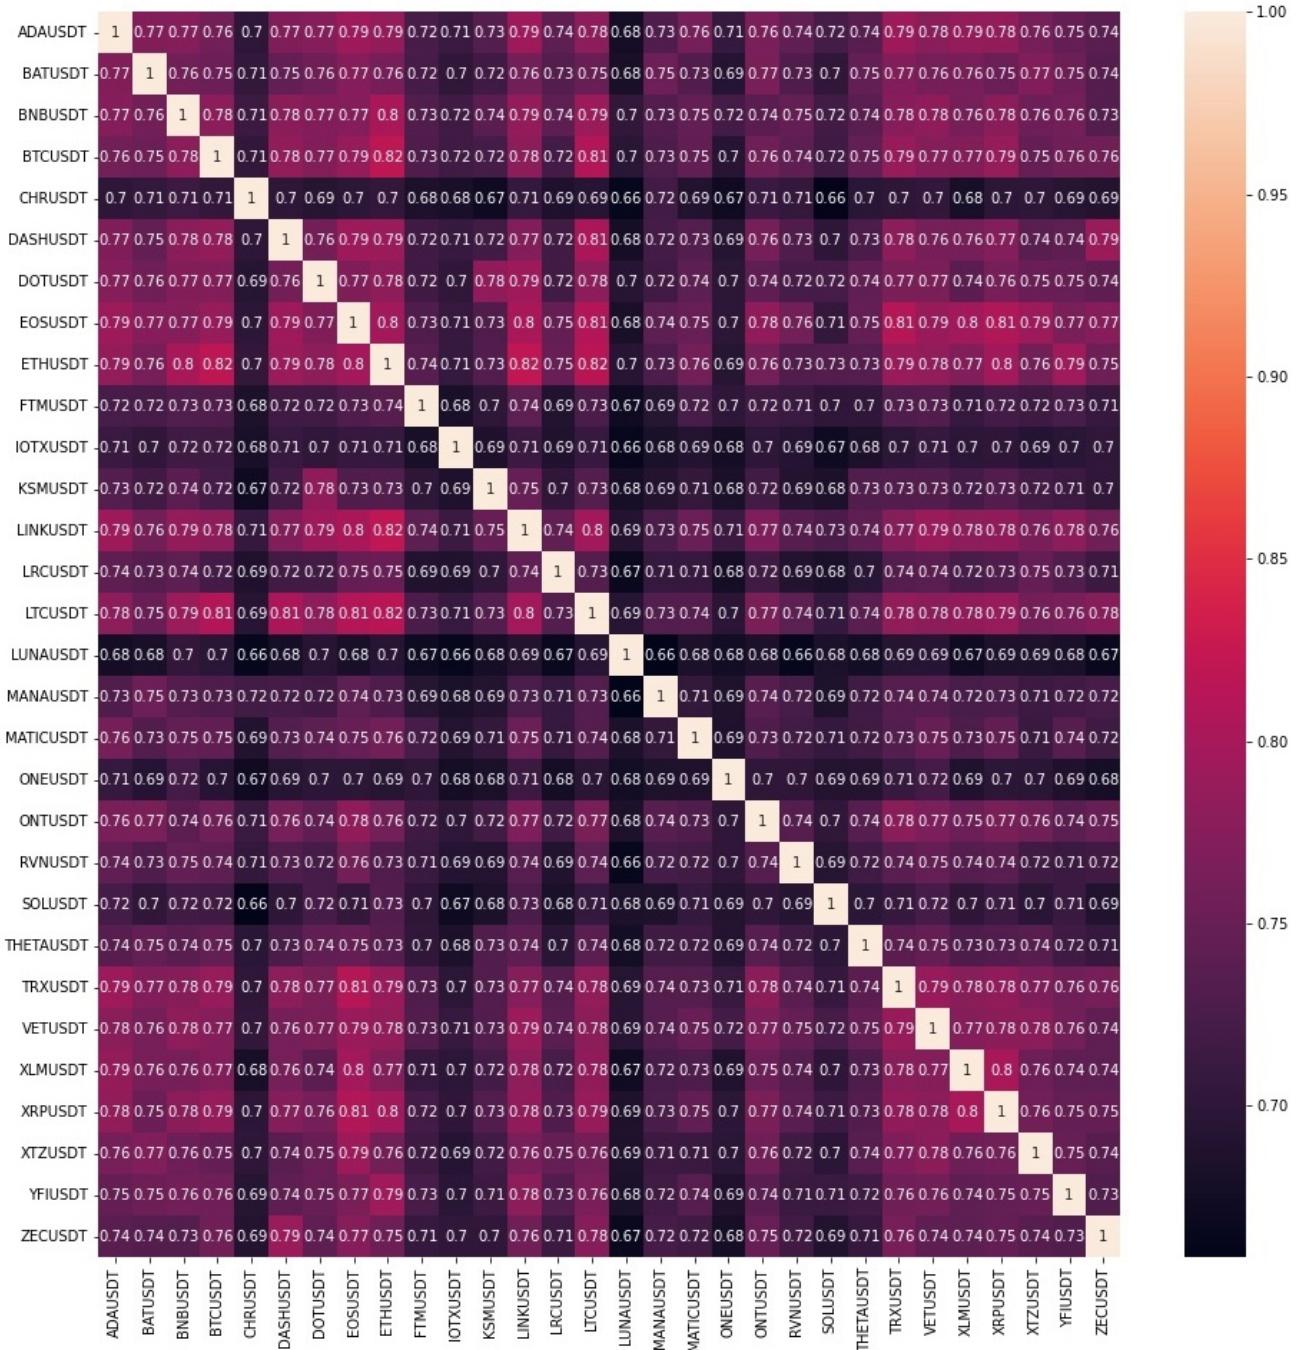


Рисунок 1.5 — Матрица корреляции стоимостей 30 основных криптовалют.

месяцев, в то время как для оценки итогов долгосрочной торговли может потребоваться несколько лет [120;121]. Для тестирования и реализации описанных алгоритмов и моделей не требуется специализированное оборудование; все технологии могут быть реализованы с использованием стандартного компьютера. Детальные требования и спецификации представлены в технической документации, прилагаемой к исходному коду в соответствующих репозиториях.

1.4 Стратегии на основе технического анализа

Технический анализ финансовых рынков представляет собой методологию прогнозирования будущих ценовых колебаний на основе изучения прошлых данных о ценах и объемах торгов [14; 15]. Этот метод опирается на допущение, что все значимые факторы, влияющие на стоимость актива, уже отражены в его текущей цене, и что ценовые паттерны имеют тенденцию к повторению. В рамках технического анализа используются графические представления, различные индикаторы и аналитические инструменты для идентификации трендов, определения уровней поддержки и сопротивления, а также выявления сигналов, указывающих на потенциальные изменения в динамике цен [122; 123]. Предполагается, что существующие тренды в движении стоимости актива продолжат свое направление до тех пор, пока не проявятся очевидные признаки их смены. Для определения возможных точек входа и выхода на рынке применяются разнообразные индикаторы, в том числе скользящие средние, осцилляторы и графические модели, оценивающие паттерны на графиках [16; 124–128].

В данном исследовании особое внимание уделяется использованию различных технических индикаторов и осцилляторов. Среди ключевых технических индикаторов выделяются скользящие средние, которые применяются для сглаживания краткосрочных колебаний цен активов путем вычисления среднего значения данных за определенный временной интервал. Например, десятидневная скользящая средняя рассчитывается как среднее значение цен закрытия за последние десять дней. Скользящие средние могут быть использованы для определения общего направления тренда, выявления точек потенциального разворота и установления уровней поддержки и сопротивления. Существует несколько видов скользящих средних, включая простую скользящую среднюю (SMA), экспоненциальную скользящую среднюю (EMA) и взвешенную скользящую среднюю (WMA), каждый из которых имеет свои уникальные характеристики и может быть предпочтительнее в зависимости от конкретных условий рынка. Скользящая средняя типа SMA рассчитывается по следующей формуле:

$$SMA(t) = \frac{1}{N} \sum_{i=0}^{N-1} P_{close}(t - i), \quad (1.5)$$

где N - количество временных шагов в окне индикатора, $P_{close}(t - i)$ - цена закрытия свечи на i -ом с конца временном шаге. Полученное значение простой скользящей средней относится к последней точке рассматриваемого окна. В случае временных рядов, в частности, для финансовых рынков, имеет смысл придавать больший вес наиболее актуальным последним времененным шагам. Для этого можно использовать экспоненциально взвешенную скользящую среднюю ЕМА, которая рассчитывается по следующей формуле:

$$EMA(t) = \alpha \cdot P_{close}(t) + (1 - \alpha) \cdot EMA(t - 1), \quad (1.6)$$

$$EMA(0) = P_{close}(0), \quad \alpha = \frac{2}{N + 1}, \quad (1.7)$$

где α - сглаживающая константа, $P_{close}(t)$ - цена закрытия свечи на последнем временном шаге, $EMA(t - 1)$ - значение индикатора на предыдущем временном шаге, $EMA(0)$ - значение индикатора на начальном временном шаге, $P_{close}(0)$ - цена закрытия свечи на начальном временном шаге, N - количество временных шагов в окне индикатора. В заключение, необходимо признать, что временные ряды финансовых рынков обладают многомерной структурой и включают в себя не только ценовые показатели, но и другие параметры, такие как объемы торговли на каждом измеряемом интервале времени. Объем торговли определяется как суммарное количество проданных или купленных ценных бумаг или контрактов за установленный временной промежуток. Этот показатель может быть применен для анализа состояния рынка и предсказания будущих ценовых колебаний. К примеру, увеличение торгового объема может свидетельствовать о возрастающем интересе к определенному активу, что, в свою очередь, может способствовать повышению его стоимости. Сокращение торгового объема может быть индикатором уменьшения интереса к активу, что может привести к падению его стоимости. В рамках технического анализа, данные о торговых объемах могут использоваться для корректировки оценок стоимости активов на каждом временном этапе. Например, взвешенная по объемам скользящая средняя WMA рассчитывается по следующей формуле:

$$WMA(t) = \sum_{i=0}^{N-1} (P_{close}(t - i) \cdot V(t - i)) / \sum_{i=0}^{N-1} V(t - i), \quad (1.8)$$

где N - количество временных шагов в окне индикатора, $P_{close}(t-i)$ - цена закрытия на i -ом с конца временном шаге, $V(t-i)$ - торговый объем на i -ом с конца временном шаге. Из перечисленных выше скользящих средних наиболее употребительной является ЕМА, в частности, именно она будет рассматриваться в данной работе далее. Торговая стратегия на основе скользящего среднего может быть использована для определения момента входа в рынок и выхода из него. Например, если цена актива поднимается выше скользящего среднего, это может указывать на начало восходящего тренда и возможность покупки актива. Если же цена актива опускается ниже скользящего среднего, это может указывать на начало нисходящего тренда и возможность продажи актива.

В дополнение к индикаторам, технический анализ включает в себя использование осцилляторов. Осциллятор индекса относительной силы (RSI) является одним из широко применяемых инструментов данного класса. RSI применяется для оценки динамики тренда и определения степени перекупленности или перепроданности актива на рынке. Данный осциллятор вычисляет скорость изменения ценовых показателей, представляя результат в форме числового индекса. Расчет RSI осуществляется на основании данных о ценах закрытия за выбранный временной интервал и включает сопоставление количества дней с повышенной ценой закрытия по отношению к среднему значению за данный период с количеством дней с пониженной ценой закрытия. При расчете индикатора используется положительные и отрицательные изменения цены для каждого временного шага, которые рассчитываются следующим образом:

$$\begin{aligned} U(t) &= P_{close}(t) - P_{close}(t-1), D = 0, \text{ если } P_{close}(t) > P_{close}(t-1), \\ D(t) &= P_{close}(t-1) - P_{close}(t), U = 0, \text{ если } P_{close}(t) < P_{close}(t-1), \end{aligned} \quad (1.9)$$

где $P_{close}(t)$ - цена закрытия на последнем временном шаге, $P_{close}(t-1)$ - цена закрытия на предпоследнем временном шаге, при этом $U(t) = D(t) = 0$, если $P_{close}(t) = P_{close}(t-1)$. Далее выполняется сглаживание полученных значений с помощью экспоненциально сглаженной скользящей средней ЕМА с периодом N , таким образом рассчитывается так называемая относительная сила, на основе которой вычисляется итоговое значение индикатора:

$$RS(t) = \frac{EMA(U(t), N)}{EMA(D(t), N)} \quad (1.10)$$

$$RSI(t) = 100 - \frac{100}{1 + RS(t)} = 100 \cdot \frac{EMA(U(t), N)}{EMA(U(t), N) + EMA(D(t), N)} \quad (1.11)$$

В случае, когда знаменатель дроби, используемой для расчета индекса относительной силы (RSI), равен нулю, значение индекса принимается за 100. Стратегии торговли, основанные на RSI, могут быть эффективно применены для определения оптимальных точек входа и выхода с рынка. Например, значение RSI, превышающее 70, может сигнализировать о перекупленности актива, что предполагает потенциальную продажу. В то же время, показатель RSI ниже 30 может указывать на перепроданность, что может быть интерпретировано как возможность для покупки. Комплексные торговые стратегии часто включают в себя множество различных индикаторов и осцилляторов, что позволяет более точно отсеивать неверные сигналы [129]. На рисунке 1.6 демонстрируется использование экспоненциальной скользящей средней (EMA) с периодом в 9 дней и RSI с периодом в 14 дней на недельном графике для криптовалюты BTC. Эти параметры являются оптимальными для применения данных инструментов технического анализа на более длительных временных рамках, таких как дневные и более продолжительные. Отмечается, что для BTC типичны ситуации перекупленности, определяемые по RSI, что коррелирует с глобальным восходящим трендом и повышенным интересом инвесторов к активу.

В рамках технического анализа, уровни поддержки и сопротивления представляют собой ключевые инструменты для оценки потенциального поведения цен. Эти уровни можно рассматривать как виртуальные барьеры на ценовом графике, которые при приближении к ним могут спровоцировать отскок цены, то есть изменение направления движения цены, или, в случае пробития, подтвердить продолжение текущего тренда [130–132]. На рисунке 1.7 уровень поддержки визуализирован в виде горизонтального прямоугольника, что символизирует допустимый диапазон колебаний цены вокруг данного уровня. Уровни поддержки и сопротивления могут формироваться по различным причинам, в том числе из-за психологического влияния круглых значений цены [133]. Принято считать, что чем большее количество раз цена отскакивает от уровня, тем он становится более значимым и надежным. Как показано на рисунке, до момента, отмеченного синей стрелкой, уровень поддержки выдержал пять внут-



Рисунок 1.6 — Демонстрация индикаторов ЕМА и RSI на BTCUSDT.

ридневных отскоков в течение двух месяцев. Особое внимание следует уделить явлению ложного пробоя, которое иллюстрируется стрелкой. Ложный пробой характеризуется кратковременным закреплением цены ниже уровня поддержки, создавая иллюзию его преодоления. Это может привести к активации стоп-лосс ордеров у инвесторов, осуществляющих покупку на данных уровнях. Ложные пробои уровней поддержки и сопротивления являются распространенным явлением на рынке и заслуживают особого внимания в качестве одного из паттернов технического анализа [134]. Они представляют собой одну из основных трудностей для стратегий, основанных на уровнях и линиях тренда.

Для демонстрации возможностей средств технического анализа для данной работы была разработана комбинированная стратегия, которая основана на использовании собственного индикатора AWVB или Average Weighted Volume Bias. При расчете значений индикатора AWVB используются значения объемов Taker Buy и Taker Sell для базового актива, взвешивание по относительному разбросу цены актива за один временной шаг, а также сглаживание при



Рисунок 1.7 — Демонстрация ложного пробоя поддержки на BTCUSDT.

помощи простого скользящего среднего. Мейкеры — это участники рынка, которые создают ордера на покупку или продажу активов. Они предлагают цену, по которой они готовы купить или продать актив. Тейкеры — это участники рынка, которые принимают ордера, созданные мейкерами. Они выбирают из предложенных мейкерами цен ту, которая наиболее выгодна для них. В данной стратегии используются данные, показывающие объемы покупки и продажи со стороны тейкеров. Рассмотрим процесс вычисления значений индикатора. На первом этапе вычисляются взвешенные по ценовому отклонению значения смещения объемов для каждого временного шага по следующей формуле:

$$WVB_i = PD_i \cdot (VTB_i - VTS_i), \quad (1.12)$$

где VTB_i - Volume Taker Buy i -ого временного шага, VTS_i - Volume Taker Sell i -ого временного шага, а PD_i - Price Deviation - относительный разброс цены актива на i -ом временном шаге, вычисляемый следующим образом:

$$PD_i = \frac{PH_i - PL_i}{PO_i}, \quad (1.13)$$

где PH_i - Price High - максимальная цена, PL_i - Price Low - минимальная цена, PO_i - Price Open - цена открытия на i -ом временном шаге. Взвешивание по относительному разбросу цены актива придает большее значение смещению объемов для временных шагов, содержащих активное движение цены. На свечном графике стоимости актива такие временные шаги соответствуют свечам с

длинными тенями. После вычисления значений WVB_i для каждого временного шага выполняется суммирование значений WVB_i за N временных шагов:

$$S_i = \sum_{j=i-N+1}^i WVB_j, \quad (1.14)$$

где WVB_j - взвешенные значения смещения объемов, а N - первый регулируемый гиперпараметр индикатора. Данное суммирование выполняется с целью локально сгладить значения WVB . Например, если в течение первых $N - 1$ временных шагов наблюдаются значения WVB , соответствующие повышению стоимости актива, а на N -ом - значение WVB , соответствующее понижению стоимости актива, то благодаря суммированию будут проигнорированы локальные колебания в пределах нескольких временных шагов в зависимости от значения N . На следующем шаге для каждого временного шага вычисляется значение простой скользящей средней $SMA(S, M)$ по M значениям S :

$$SMA_i = \frac{\sum_{j=i-M+1}^i S_j}{M}, \quad (1.15)$$

где S_j - значения, вычисленные для каждого временного шага, кроме $M - 1$ первых, а M - второй регулируемый гиперпараметр индикатора. Важно отметить, что среднее значение $V_{bias} = VTB - VTS$ за некоторое количество временных шагов изменяется в течение всего временного ряда. На рисунке 1.8, построенном по данным V_{bias} для БТС с 2017 по 2021 год, можно заметить данное изменение. По горизонтальной оси отложены временные шаги (один временной шаг соответствует одним суткам), по вертикальной оси отложены значения V_{bias} . Следует отметить, что в период активного роста БТС в конце 2020 - начале 2021 года наблюдается отрицательное среднее значение V_{bias} , т. е. это означает, что объем продаж по рынку превышает объем покупок по рынку. Значения SMA_i являются итоговыми значениями индикатора AWVB.

Стратегия основана на том, чтобы сравнивать значение S_i для i -ого временного шага со значением SMA_i для того же самого i -ого временного шага. Если $S_i > SMA_i$, то следует устанавливать длинную позицию, а если $S_i < SMA_i$, то следует устанавливать короткую позицию. Однако близость значения S_i к значению SMA_i может свидетельствовать о неопределенности, поэтому предлагается ввести третий гиперпараметр D , задающий минимально необходимое

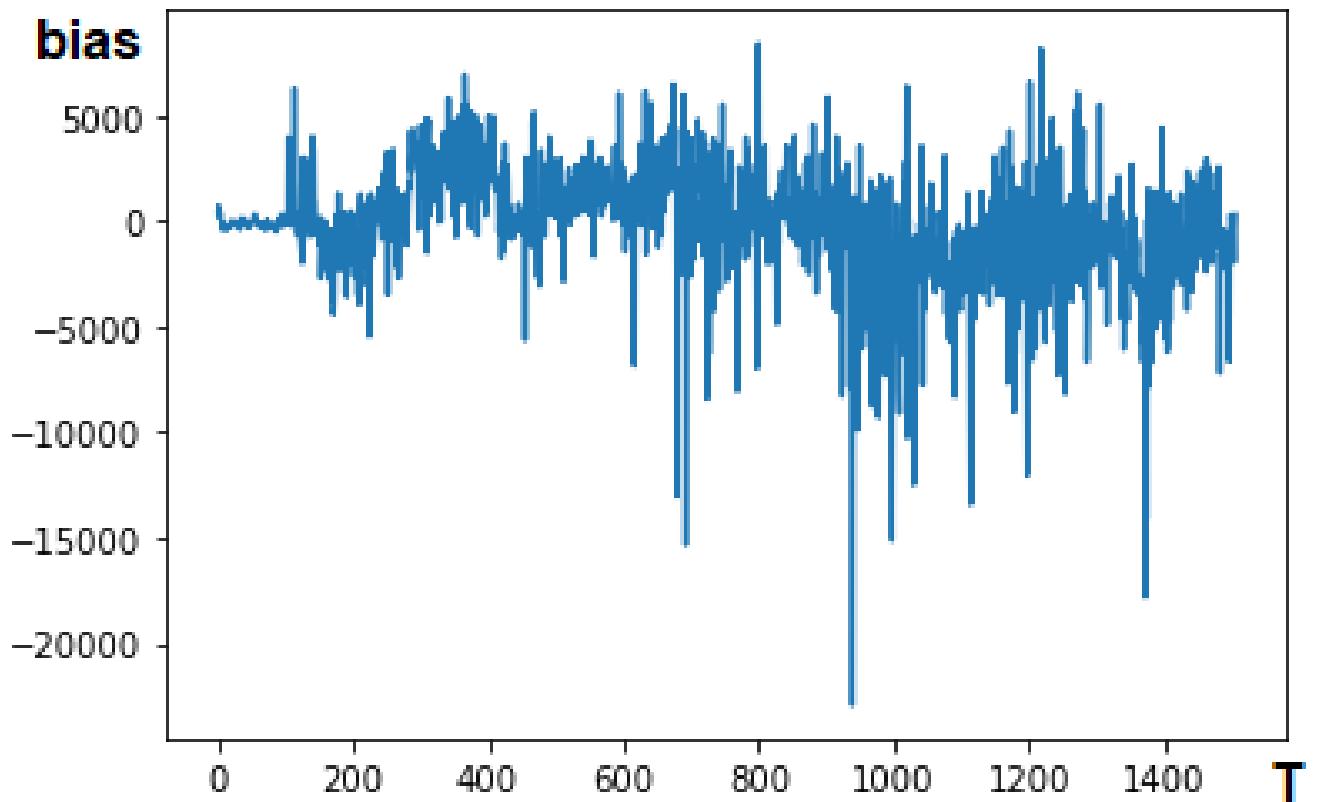


Рисунок 1.8 – График зависимости V_{bias} от временного шага на BTCUSDT.

отклонение S_i от SMA_i для установки длинной или короткой позиции. Если текущее отклонение меньше минимального, то рекомендуется устанавливать нулевую позицию. Условие сравнение оформлено следующим образом:

$$\frac{|S_i - SMA_i|}{SMA_i} \vee D, \quad (1.16)$$

где D - третий регулируемый гиперпараметр индикатора. Оптимальные значения гиперпараметров N , M и D могут быть подобраны поиском по многомерной сетке. Для BTC оптимальными являются значения $N = 8$, $M = 60$ и $D = 0.35$ для дневного таймфрейма. Стоит отметить, что значение D связано с волатильностью стоимости актива и для более волатильных активов, например, XRP оптимальное значение D составляет 0.05. Данная стратегия использовалась в ранних версиях системы в качестве одного из алгоритмов для формирования компонент входного вектора моделей в составе системы принятия решений. Как самостоятельное решение данная стратегия не может применяться, так как имеет неудовлетворительные показатели, например коэффициент Шарпа и максимальную просадку, о которых будет рассказано далее. Читатель может самостоятельно подобрать оптимальные параметры для интересующих

его активов сеточным методом многокритериальной оптимизации и провести бэктестирование стратегии. Бэктестирование стратегий — это процесс проверки эффективности торговой стратегии на исторических данных. Бэктестирование позволяет трейдерам оценить, насколько хорошо стратегия работала в прошлом и как она может работать в будущем. Для этого используются исторические данные о ценах активов, на которых основана стратегия. В данной работе для проверки стратегий используется система бэктестирования, полностью разработанная автором. Существуют также и публичные системы бэктестирования, доступные широкому кругу пользователей, например, QuantConnect [135].

1.5 Тестирование и валидация торговых стратегий

В рамках текущего исследования был разработан модуль для бэктестирования стратегий, что позволяет оценить их эффективность как на уровне отдельных активов, так и в контексте диверсифицированного портфеля [136]. Стандартизованный отчет о результатах бэктестирования портфеля, включающего в себя восемь криптовалютных активов за период с 2019 по 2023 год, представлен в таблице 1.9. В процессе тестирования применялась стандартная комиссия биржи за исполнение рыночных ордеров, составляющая 0.04% от объема позиции. Несмотря на то, что биржи могут предложить сниженные комиссии при достаточном торговом объеме, для обеспечения объективности тестирования использовалась максимальная ставка комиссии. Важно отметить, что комиссия взимается как при открытии, так и при закрытии позиции. Исходный размер инвестиций составил 8000 USDT, распределенных поровну между активами портфеля — по 1000 USDT на каждый. В данном портфеле каждый актив управляет независимо, без взаимного влияния средств между активами, что делает отчет по портфелю агрегацией восьми независимых отчетов. В рамках стратегии для каждого актива устанавливается трейлинг стоп-лосс на уровне 10%, что является значительным показателем, однако уместным в условиях высокой волатильности криптовалютного рынка. Волатильность, выраженная степень изменчивости цены актива за определенный временной интервал,

может быть количественно оценена для свечного графика как стандартное отклонение ценовых колебаний внутри свечи за несколько временных шагов.

В представленном отчете особое внимание уделяется отсутствию функции трейлинг тейк-профит. Как было указано ранее, для закрытия позиций используются либо сигналы стратегии, либо стоп-лосс, в то время как механизм тейк-профита не применяется. Из анализа отчета следует, что доходность предложенной стратегии превышает показатели стратегии «купи и держи». Однако стоит отметить, что в отчете для бенчмарка выделена начальная сумма в размере 1000 USDT, что эквивалентно сумме, выделенной для каждого актива. Таким образом, при исходной сумме инвестиций в 8000 USDT, бенчмарк-стратегия может принести свыше 41000 USDT дохода. При сравнении этих данных становится очевидно, что доходность разработанной стратегии несущественно превышает показатели бенчмарк-стратегии. Тем не менее, результаты могут значительно измениться в пользу разработанной стратегии, если начать тестирование не с минимальных значений 2019 года, а с более позднего времени. Бэктестирование предоставляет возможность реинвестирования прибыли и расчета сложного процента, однако эта функция редко используется в тестах, так как она усложняет визуальную оценку итогового графика доходности.

Стратегия характеризуется таймфреймом в четыре часа, что указывает на периодичность проведения анализа данных и обновления сигналов. Таймфрейм трейлинга установлен в пять минут, что также применимо к другим стратегиям, рассмотренным в данной работе. Это означает, что проверка условий активации стоп-лосса и его корректировка при необходимости выполняются каждые пять минут. Такой интервал позволяет избежать реакции стратегии на кратковременные скачки цен, которые являются характерными для криптовалютного рынка. В таблице представлена полная статистика по сделкам, включая длинные и короткие позиции, включая их количество и время удержания.

В заключительной части таблицы приведены ключевые показатели, имеющие значение для финансовых аналитиков: коэффициенты Шарпа, Сортино и Кальмара [137]. Последний из них не рассчитывается для криптовалютных активов по договоренности с заказчиком. Коэффициент Шарпа, названный в честь Уильяма Шарпа, лауреата Нобелевской премии по экономике за разработку теории оценки финансовых активов, представляет собой показатель эффективности инвестиционного портфеля, учитывающий как доходность, так и

риска [138]. Он рассчитывается как отношение средней доходности портфеля за вычетом доходности безрискового актива к волатильности портфеля, выраженной через стандартное отклонение доходности [139]. Волатильность отражает степень изменения доходности портфеля во времени и является мерой риска. Высокая волатильность указывает на больший риск. Коэффициент Шарпа показывает, какую дополнительную доходность инвестор получает за каждую единицу принятого риска. Коэффициент Шарпа вычисляется по формуле:

$$R_{Sharpe} = \frac{E(R) - r}{\sigma_R} = \frac{E(R) - r}{\sqrt{\text{var}(R)}}, \quad (1.17)$$

где R - помесячные доходности торговой стратегии, r - безрисковая доходность, например, это может быть банковский депозит или ценная бумага казначейства США; в данной работе коэффициент Шарпа рассчитывается для месячных значений доходности, поэтому для r выбрано значение $0.01/12$, что эквивалентно 1% годовых безрисковой доходности портфеля в USD. Такое значение на самом деле является малым по сравнению с доходностью R и им можно пренебречь. Для коэффициента Шарпа с месячным расчетом автором в качестве приемлемых принимаются значения не менее 0.5 для криптовалютного рынка и не менее 1.0 для классического рынка при условии проведения теста продолжительностью не менее 24 месяцев. Для более жёсткой оценки вместо предложенного коэффициента Шарпа можно использовать информационный индекс, который является обобщением коэффициента Шарпа, использующим вместо безрискового актива более рисковый индекс, например, S&P 500.

Финансовые активы зачастую подчиняются ненормальному распределению, в связи с чем стандартное отклонение не полностью отражает все грани риска. Например, схемы финансовых пирамид могут демонстрировать высокие значения эмпирического коэффициента Шарпа до момента их краха. В соответствии с рекомендациями финансового консультанта, автор данного исследования также применяет коэффициент Сортино для оценки инвестиционных стратегий. Коэффициент Сортино, названный в честь его создателя Фрэнка Сортино, который ввел его в 1994 году, является мерой эффективности инвестиционного портфеля, учитывающей как доходность, так и риск. Данный коэффициент рассчитывается как отношение средней доходности портфеля к его негативной волатильности, то есть стандартному отклонению убыточных доходностей, исключая положительные изменения доходности, что позволяет

сфокусироваться на потенциальных убытках. Для расчета коэффициента Сортино в данной диссертации используется следующая формула:

$$R_{Sortino} = \frac{E(R) - r}{\sigma_{R_-} \sqrt{\frac{N_-}{N}}} = \frac{E(R) - r}{\sqrt{\text{var}(R_-) \frac{N_-}{N}}}, \quad (1.18)$$

где R - помесячные доходности торговой стратегии, r - безрисковая доходность, R_- - помесячные доходности торговой стратегии, меньшие значения $r/12$, N_- - количество месяцев с доходностью ниже $r/12$, N - суммарное количество месяцев тестового периода. Коэффициент Сортино наказывает только те доходы, которые падают ниже заданной пользователем цели или требуемой нормы доходности, в то время как коэффициент Шарпа наказывает как за повышательную, так и за понижательную волатильность в равной степени. Для коэффициента Сортино с месячным расчетом автором в качестве приемлемых принимаются значения не менее 7.0 для криптовалютного рынка и не менее 5.0 для классического рынка при условии проведения теста продолжительностью не менее 24 месяцев. Общая формула расчета коэффициента Сортино:

$$R_{Sortino} = \frac{R - T}{\sigma}, \quad \sigma = \sqrt{\int_{-\infty}^T (T - x)^2 f(x) dx}, \quad (1.19)$$

где R — средняя доходность портфеля, T — минимально допустимый уровень доходности портфеля, σ — волатильность вниз. Когда распределения доходности близки к симметричной, а целевая доходность близка к медиане распределения, коэффициенты Шарпа и Сортино будут давать схожие результаты. По мере увеличения асимметрии и отклонения целевых показателей от медианы можно ожидать, что результаты будут демонстрировать значительные различия. В таблице 1.9 коэффициенты имеют сильно отличающиеся значения, что обусловлено высокой волатильностью доходности вверх на длинных позициях. Помимо коэффициентов для финансовых стратегий также важна допустимая и максимальная просадки доходности или баланса портфеля. В данной работе этот аспект не учитывается в процессе обучения моделей и оптимизации стратегий, однако защитный механизм присутствует в итоговой системе как безусловно срабатывающий при достижении определенной просадки.

Отчет по бэктестированию инвестиционных стратегий включает таблицу, отражающую месячные доходы или ежемесячную рентабельность рассматрива-

Backtesting asset	8 assets	Backtest interval	2019 - 2023	Trading fee rate	0.04 %
Initial investments	8000.00	Strategy version	Intersector 3.0	Trailing stop-loss	10% fixed
Benchmark profit	5260.70	Strategy profit	64812.07	Trailing take-profit	disabled
Has reinvestment	False	Strategy timeframe	4h	Trailing timeframe	5m
Longs quantity	2795	Shorts quantity	2790	Trades quantity	5585
Longs with profit	1099	Shorts with profit	1109	Trades with profit	2208
Longs with loss	1696	Shorts with loss	1681	Trades with loss	3377
Longs total profit	90106.01	Shorts total profit	59302.48	Trades total profit	149408.49
Longs total loss	41512.93	Shorts total loss	43083.48	Trades total loss	84596.41
Long average profit	81.99	Short average profit	53.47	Trade average profit	67.67
Long average loss	24.48	Short average loss	25.63	Trade average loss	25.05
Long minimum hold	2.00 hours	Short minimum hold	0.42 hours	Trade minimum hold	0.42 hours
Long median hold	20.00 hours	Short median hold	20.00 hours	Trade median hold	20.00 hours
Long maximum hold	856.00 hours	Short maximum hold	860.00 hours	Trade maximum hold	860.00 hours
Sharpe coefficient	0.81	Sortino coefficient	14.81	Kalmar coefficient	undefined

Рисунок 1.9 — Общие результаты бэктестирования стратегии Intersector.

емой стратегии. В таблице 1.10 представлены месячные результаты для стратегии Intersector, анализ которой был осуществлен ранее. Данные в таблице рассчитываются исходя из стоимости активов на начало соответствующего месяца, а годовые показатели — относительно начала года. Следует подчеркнуть, что подобная доходность характерна исключительно для криптовалютного рынка и недостижима на традиционных финансовых рынках. Указанные результаты справедливы при управлении капиталом не более 20 млн USDT.

При увеличении объема управляемых средств необходима корректировка стратегии, что может привести к снижению ее рентабельности в процентном выражении. Последние 12 месяцев, отображенные в таблице месячных доходов, соответствуют честному тестированию, то есть проверке эффективности стратегии на данных, которые не использовались при обучении модели и оптимизации параметров. Завершающим элементом отчета является график доходности стратегии, сопоставленный с графиком бенчмарк-стратегии «купи и держи». На рисунке 1.11 можно увидеть сравнительное наложение данных графиков. График бенчмарка выделен темным цветом, в то время как график одной из разработанных стратегий — более светлым. Вертикальная шкала графика показывает стоимость активов в единицах котируемой валюты USDT.

	Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.	Annual
2019	+3.28	+20.49	+6.19	+17.99	+32.26	+3.74	-1.01	+7.59	+5.40	+4.45	+23.53	-1.85	+122.06
2020	+36.39	+23.27	+31.74	+9.90	+3.42	+11.17	+31.54	+1.41	+10.51	-5.57	+19.01	+25.28	+198.08
2021	+16.98	+100.87	+10.49	+72.41	+49.86	-8.55	+18.12	+27.59	+20.93	+5.43	+16.72	+16.65	+347.48
2022	+14.61	+13.81	+13.37	+11.63	+22.40	+9.41	+28.43	+2.91	-6.55	+5.64	+4.68	+4.79	+125.12
2023	+8.14	-6.48	-2.20	+7.02	-2.15	+13.08							+17.41

Рисунок 1.10 — Таблица месячных возвратов стратегии Intersector.

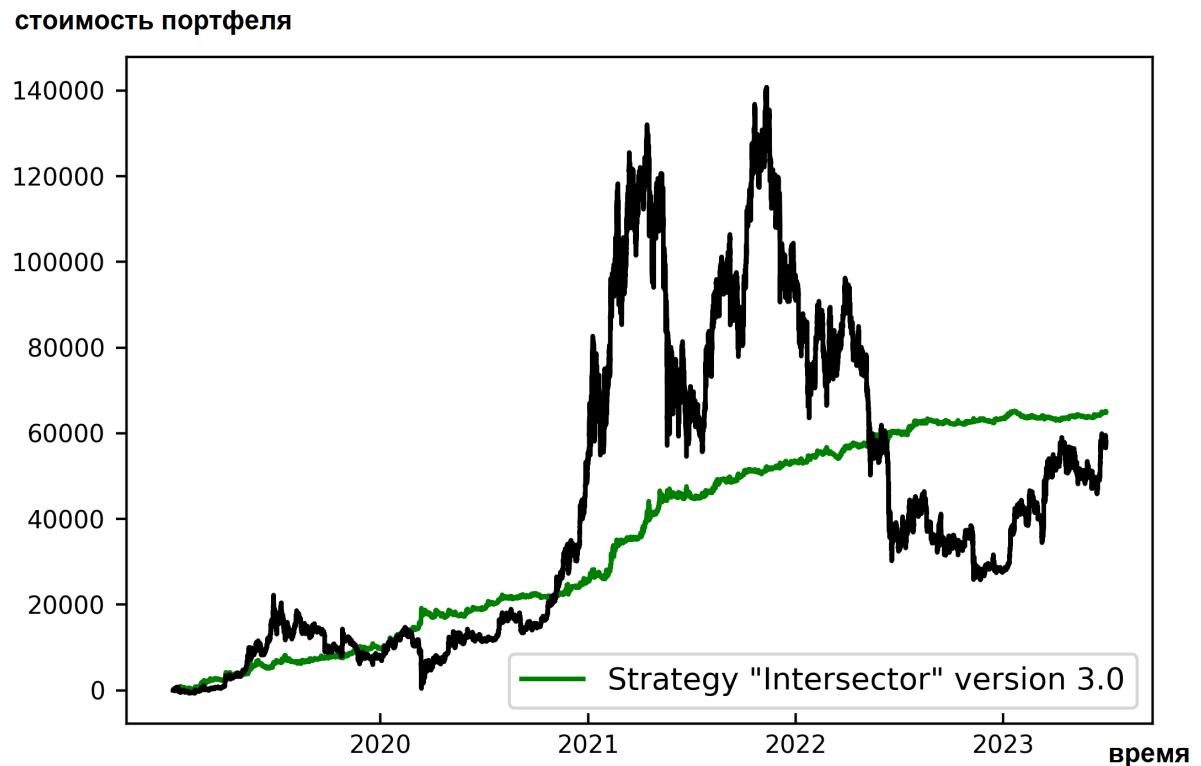


Рисунок 1.11 — Сравнение графиков доходности стратегии и бенчмарка.

1.6 Выводы к первой главе

В данной главе были описаны различные компоненты, которые будут использоваться при построении стратегий в главах 2 и 3. В частности, в главе 2 при построении входных векторов для моделей машинного обучения будет использоваться информация об уровнях поддержки и сопротивления. В главе 3 будет представлена гибридная модель, состоящая из алгоритмической стратегии на основе экспоненциально слаженной скользящей средней и модели, обученной с подкреплением для фильтрации сигналов базовой стратегии. Также в главе 2 в процессе определения статистических свойств многомерных вре-

менных рядов будут построены матрицы корреляции для активов МОЕХ в дополнение к матрице корреляции для криптоактивов, представленной в разделе 1.3. Все разработанные стратегии работают с фьючерсами, используют плечо, стоп-лосс ордера для защиты позиций и работают как с длинными, так и с короткими позициями. Для тестирования и валидации стратегий используется модуль бэктестирования, описанный в разделе 1.5.

Глава 2. Построение среднесрочной торговой стратегии

В данной главе рассмотрен полный цикл подготовки и разметки данных, а также архитектура и процессы обучения и тестирования моделей машинного обучения с учителем и с подкреплением. Приведены некоторые статистические свойства многомерных временных рядов финансовых рынков. Сформированы обучающая и тестовая выборки данных для моделей, а также выполнена разметка данных для решения задачи тернарной классификации. Также в главе описаны первые две версии моделей машинного обучения, ориентированных на решение задачи прогнозирования многомерных временных рядов финансовых рынков. Это модель, обученная с учителем, и модель, обученная с подкреплением. Во втором случае используется алгоритм DQN, а обученные по-разному за счет эпсилон-жадного алгоритма при исследования среды модели объединены в ансамбль.

В разделе 2.1 сформулировано определение торговой стратегии с переворотом позиций, а также сформулирована многокритериальная задача оптимизации с ограничениями, которую необходимо решить в процессе разработки стратегий. В разделе 2.2 приведены результаты исследования некоторых статистических свойств многомерных временных рядов финансовых рынков. В разделах 2.3 и 2.4 описана итоговая структура многомерного временного ряда и входного вектора для моделей машинного обучения с разметкой под тернарную задачу классификации. В итоговую структуру была включена информация об уровнях поддержки и сопротивления, описанных в главе 1. В разделе 2.5 приведено описание первой версии модели прогнозирования многомерных временных рядов финансовых рынков. В разделе 2.6 совмещено обучение отдельных моделей с использованием известного варианта оптимизации алгоритма DQN с двумя сетями и буфером воспроизведения и составлении ансамбля таких моделей. В этой части описывается среда, используемая для обучения с подкреплением, алгоритм DQN, результаты исследования ансамбля обученных глубоких нейронных сетей и использование этого алгоритма для применения на финансовых рынках. В качестве входного вектора используются те же вектора, что и для модели обучения с учителем.

2.1 Математическая формулировка стратегии

Определение торговой стратегии с переворотом позиций [140] следующее:

$$A_{i+1}(x) = S_\Theta(\vec{T}_{i-n+1}(x), \dots, \vec{T}_i(x)), \quad (2.1)$$

где S - стратегия с оптимизируемыми параметрами Θ . Здесь S_Θ - разработанный и оптимизированный алгоритм прогнозирования действий, $\vec{T}_i(x)$ - вектор MFTS для инструмента x на временном шаге i , n - количество шагов, $A_{i+1}(x)$ - рекомендуемое для инструмента x действие на временном шаге $i + 1$, при этом $A_i \in \{B, S, C, H\}$, где B - покупка, S - продажа, C - закрытие, H - удержание. Таким образом можно сформировать $\vec{A}(x) = \{A_n(x), A_{n+1}(x), \dots, A_N(x)\}$ - последовательность действий для инструмента x , для которой определяется функция $R(\vec{A}(x), x)$, вычисляющая награду за последовательность действий для инструмента x . Необходимо сразу обозначить, что все используемые в работе MFTS являются нестационарными многомерными временными рядами с глобальными трендами, что достаточно легко проверяется на практике через вычисление математического ожидания и стандартного отклонения цены активов в плавающем окне, а также подтверждается теоретически фактом наличия инфляции и увеличения денежной массы, используемой в качестве котирующегося актива. Далее приводится математическая формулировка многокритериальной задачи оптимизации для обучаемой модели. Численные значения констант, которые указаны в ограничениях, заданы для решения, ориентированного на криптовалютный рынок, аналогично для активов МОEX.

$$R(S_\Theta, x) = R(\vec{A}(x), x) \rightarrow \max, \text{ s.t.} \quad (2.2)$$

$$R(S_\Theta, x) > R(\vec{B}(x), x), \vec{B}(x) = \{B_n, H_{n+1}, \dots, H_N\} \forall x, \quad (2.3)$$

$$t_N - t_n > 360 \text{ суток при длительности временного шага } \Delta t = 1 \text{ час,} \quad (2.4)$$

$$R_{sharpe} = \frac{E(R_m)}{\sigma_{R_m}} > 0.5, R_{sortino} = \frac{E(R_m)}{\sigma_{R_{m-}}} > 5.0, \quad (2.5)$$

где $R(S)$ - чистая прибыль стратегии за тестовый период, t_n - момент времени начала тестового периода, t_N - момент времени окончания тестового периода, для криптовалютного рынка торговая сессия равняется 24 часам, т.к. биржи работают без выходных, I_{max} - капиталоемкость стратегии, $R(B)$ - функция прибыли бенчмарка «купи и держи» за тестовый период. Следует заметить, что для МОЕХ минимально допустимыми значениями коэффициентов Шарпа и Сортино являются значения 1.0 и 7.0 соответственно. Здесь следует сделать оговорку, что приведенная задача многокритериальной оптимизации сформулирована в общем случае для каждого актива в отдельности. В итоговой инвестиционной стратегии предполагается формирование портфеля стратегий, каждая из которых независимо от других управляет собственным активом. В данном случае портфель позволяет улучшить финансовые показатели относительно отдельных активов, если используются нескоррелированные стратегии. Так, например, просадка одной стратегии в одном активе нивелируется прибылью другой стратегии в другом активе. Обычно для этого используются стратегии разных классов, например, трендовые и контртрендовые, однако в рамках данной работы рассматриваются только трендовые стратегии.

2.2 Определение статистических свойств MFTS

В данной части работы представлены результаты исследования самоподобия, корреляции, волатильности и некоторых других статистических свойств временных рядов, встречающихся на финансовых рынках [141]. Рассматриваемые временные ряды представляют собой графики стоимости и объема торгов акций компаний, входящих в индекс МОЕХ, а также некоторых активов товарных рынков. Результаты данного исследования используются при подготовке данных для обучения моделей искусственного интеллекта, предназначенных для решения различных задач на подобных временных рядах [142]. Все описанные ниже результаты были опубликованы в статье [4].

Исследуемые данные представляют собой свечные графики, при этом рассматриваются графики с таймфреймами 1 час, 1 день, 1 неделя и 1 месяц. Максимальная длительность исследуемых временных рядов составляла 24 года, в частности, с 1 января 2000 года - для таких компаний как Лукойл. Для некоторых временных рядов длительность составляла менее 5 лет, например, для компании Яндекс. Графики в меньших таймфреймах, например, минутном или пятиминутном, не рассматриваются по причине сильной зашумленности данных. Данные для анализа получены с сервера Финама [143], которые представляли собой csv-файл, в каждой строке которого содержится набор из 7 элементов данных: дата (год, месяц, день), время(час, минута, секунда), максимальная и минимальная цены, цены закрытия и открытия и объём торгов соответствующей свечи. Для получения данных с сервера использовалось собственное программное обеспечение, реализованное посредством инструментария C++ и Python, в частности, с использованием библиотек requests [144] и urllib [145].

Из Python-скрипта отправлялся запрос на сервер по установленной форме. С сервера приходил ответ в виде txt-файла, содержащего данные свечного графика за требуемый промежуток времени в нужном таймфрейме и по указанному активу. Однако при попытке запросить данные слишком большого объема (более 10-ти лет для дневного таймфрейма) с сервера приходило сообщение об ошибке в связи с невозможностью сформировать файл необходимого размера. Для решения этой проблемы выполнялось сегментрование скачиваемого набора данных, после чего данные каждого сегмента поступали в виде отдельных пакетов и конкатенировались в единый файл с данными.

В последующих разделах описаны результаты исследования различных статистических свойств имеющихся временных рядов. Во-первых, рассмотрено приближение указанных временных рядов винеровским процессом, а также выполнена оценка свойства самоподобия посредством алгоритма DTW. Во-вторых, проведен анализ похожести временных рядов различных активов в одинаковом таймфрейме посредством собственной метрики. В-третьих, вычислена корреляция между временными рядами различных активов в одинаковых таймфреймах. В конце проведен анализ изменения волатильности для некоторых активов за имеющийся временной промежуток.

2.2.1 Самоподобие

В первую очередь решалась проблема нехватки данных многомерных временных рядов на старших таймфреймах. С учетом выходных дней и праздников за год существует около 200 временных шагов по одному активу на дневном таймфрейме. Этого недостаточно для качественного обучения моделей [146]. В связи с этим рассматривается гипотеза о самоподобии графика цены одного актива в разных таймфреймах, при подтверждении которой можно будет использовать данные разных таймфреймов для обучения одной и той же модели. На рынках торговля происходит в непрерывном режиме. Описание ценообразования этого процесса требует применения непрерывных моделей. Хорошим приближением для их исследования является модель Броуновского движения или Винеровский процесс. Актуальным свойством данного случайногопроцесса является свойство самоподобия [147]. Пусть $\{W_t\}_{t \geq 0}$ стандартный Винеровский процесс. Тогда каждый из следующих процессов также является Винеровским: $\{-W_t\}_{t \geq 0}$, $\{W_{t+s} - W_s\}_{t \geq 0}$, $\{aW(t/a^2)\}_{t \geq 0}$, $\{tW(1/t)\}_{t \geq 0}$. Далее вычисляются коэффициенты самоподобия графиков в различных таймфреймах в рамках одного и того же актива. Можно представить изменения цен закрытия актива в течение какого-то промежутка времени как временной ряд $T = \{t_1, t_2 \dots t_n\}$. Изменение цены фиксируется раз в час, день, неделю, месяц. Таким образом, получено четыре различных временных ряда, соответствующих данным таймфреймам. Попарное подобие этих временных рядов проверяется с помощью алгоритма динамической трансформации временной шкалы DTW (*Dynamic Time Warping*) [148]. Пусть два временных ряда $T = \{t_1, t_2 \dots t_n\}$ и $S = \{s_1, s_2 \dots s_m\}$ длины n и m соответственно. Коэффициент самоподобия определяется как минимальная стоимость преобразования T в S на основе евклидового расстояния между соответствующими компонентами. Он используется для оценки подобия паттернов на разных временных шкалах [149].

Здесь и далее в качестве примеров используются графики цены обычных акций компании ПАО «Сбербанк» в четырех таймфреймах. На следующем шаге составляется матрица расстояний, где на пересечении строки i и столбца j стоит расстояние между t_i и s_j элементами временных рядов T и S .

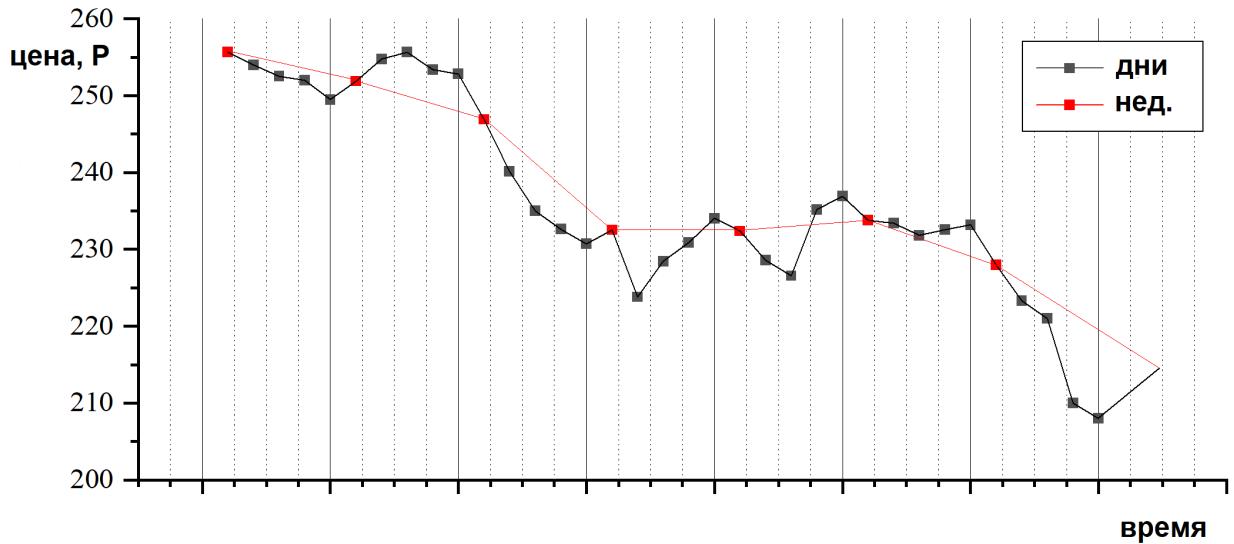


Рисунок 2.1 — Наложение графиков цены в дневном и недельном таймфреймах.

соответственно. В расчетах используется расстояние, определяемое следующим образом:

$$d(t_i, s_j) = |t_i - s_j| \quad (2.6)$$

Таким образом, матрица расстояний примет следующий вид:

$$\begin{pmatrix} d(t_1, s_1) & d(t_1, s_2) & \dots & d(t_1, s_m) \\ d(t_2, s_1) & d(t_2, s_2) & \dots & d(t_2, s_m) \\ \dots & \dots & \dots & \dots \\ d(t_n, s_1) & d(t_n, s_2) & \dots & d(t_n, s_m) \end{pmatrix} \quad (2.7)$$

Пусть $W = \{w_1, w_2 \dots w_k \dots w_K\}$ - путь трансформации такой, что следующая функция принимает свое минимальное значение, т.е. стоимость пути трансформации наименьшая:

$$DTW(T, S) = \min \left(\sum_{k=1}^K d(w_k) \right) / K \quad (2.8)$$

где $w_k = (i, j)$, $d(w_k) = d(t_i, s_j) = |t_i - s_j|$ граничные условия задаются равенствами $w_1 = (1, 1)$, $w_K = (n, m)$. Следующая задача: вычислить минимальную стоимость преобразования T в S . Путь трансформации W находится с помощью методов динамического программирования. Для матрицы трансфор-

мации γ значение на пересечении строки i и столбца j вычисляется следующим образом:

$$\gamma(i, j) = d(t_i, s_j) + \min(\gamma(i, j - 1), \gamma(i - 1, j), \gamma(i - 1, j - 1)) \quad (2.9)$$

В качестве примера для акций SBER приведена матрица трансформации, построенная для недельного и дневного таймфреймов, на которой отмечены клетки с нулевыми значениями, соответствующие наименьшей стоимости пути трансформации, который минимизирует расстояние между временными рядами.

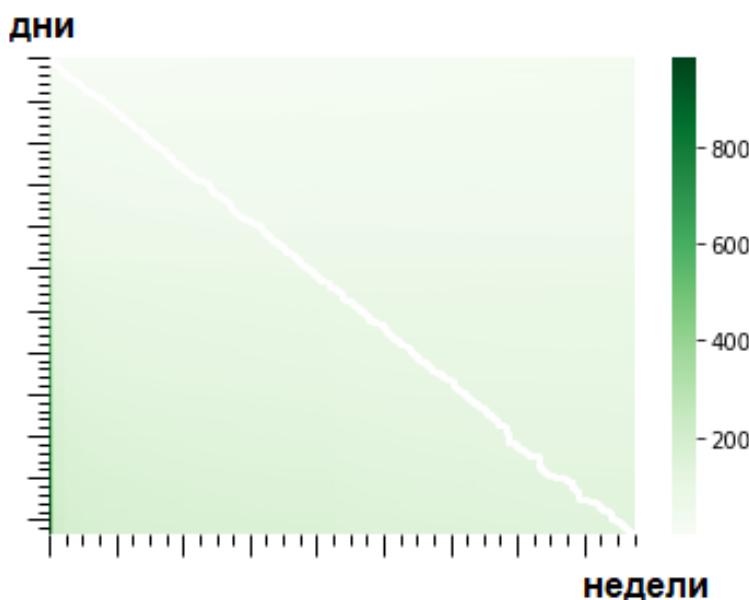


Рисунок 2.2 – Матрица и путь трансформации для графиков цены акций SBER.

Следует заметить, что в некоторых случаях данный алгоритм может привести к некорректным результатам. Например, когда большое количество точек первого ряда соответствуют одной точке второго ряда. Для предотвращения данной проблемы можно ограничить глубину рекурсии, задав параметр δ :

$$\gamma(i, j) = \begin{cases} d(t_i, s_j) + \min(\gamma(i, j - 1), \gamma(i - 1, j), \gamma(i - 1, j - 1)), & \text{если } |i - j| < \delta \\ \infty, & \text{иначе} \end{cases} \quad (2.10)$$

Таким образом, получена матрица самоподобия, в которой отражено сравнение графиков одного и того же актива в разных таймфреймах, см. рис. 2.3.

Algorithm 1: Алгоритм динамической трансформации временной шкалы.

```

for i in range(0, size(T)) do
    for j in range(0, size(S)) do
        D[i][j] = |T[i] - S[j]|
    end for
end for
γ[0][0] = D[0][0]
for i in range(1, size(T)) do
    γ[i][0] = D[i][0] + γ[i-1][0]
end for
for j in range(1, size(S)) do
    γ[0][j] = D[0][j] + γ[0][j-1]
end for
for i in range(1, size(T)) do
    for j in range(1, size(S)) do
        γ[i][j] = D[i][j] + min(γ[i-1][j-1], γ[i][j-1], γ[i-1][j])
    end for
end for
result = γ[size(T) - 1][size(S) - 1]

```

Большие значения в ячейках матрицы соответствуют большему различию временных рядов. Ноль соответствует полному совпадению графиков. Исследование показывает, что частота сбора данных влияет на их качество: с уменьшением длительности таймфрейма увеличивается уровень шума и снижается схожесть временных рядов. Эмпирические данные подтверждают, что характеристики самоподобия более выражены для временных рядов с более длительными таймфреймами, такими как неделя и месяц, по сравнению с более короткими, например, час и день. Тем не менее, анализ показывает, что даже при использовании более длительных таймфреймов различия в значениях самоподобия остаются значительными. В последующем этапе исследования, при обучении моделей, данные с различными таймфреймами, включая дневные, недельные и месячные, будут использоваться одновременно в обучающих выборках для моделей, не являющихся старшими по временной шкале.

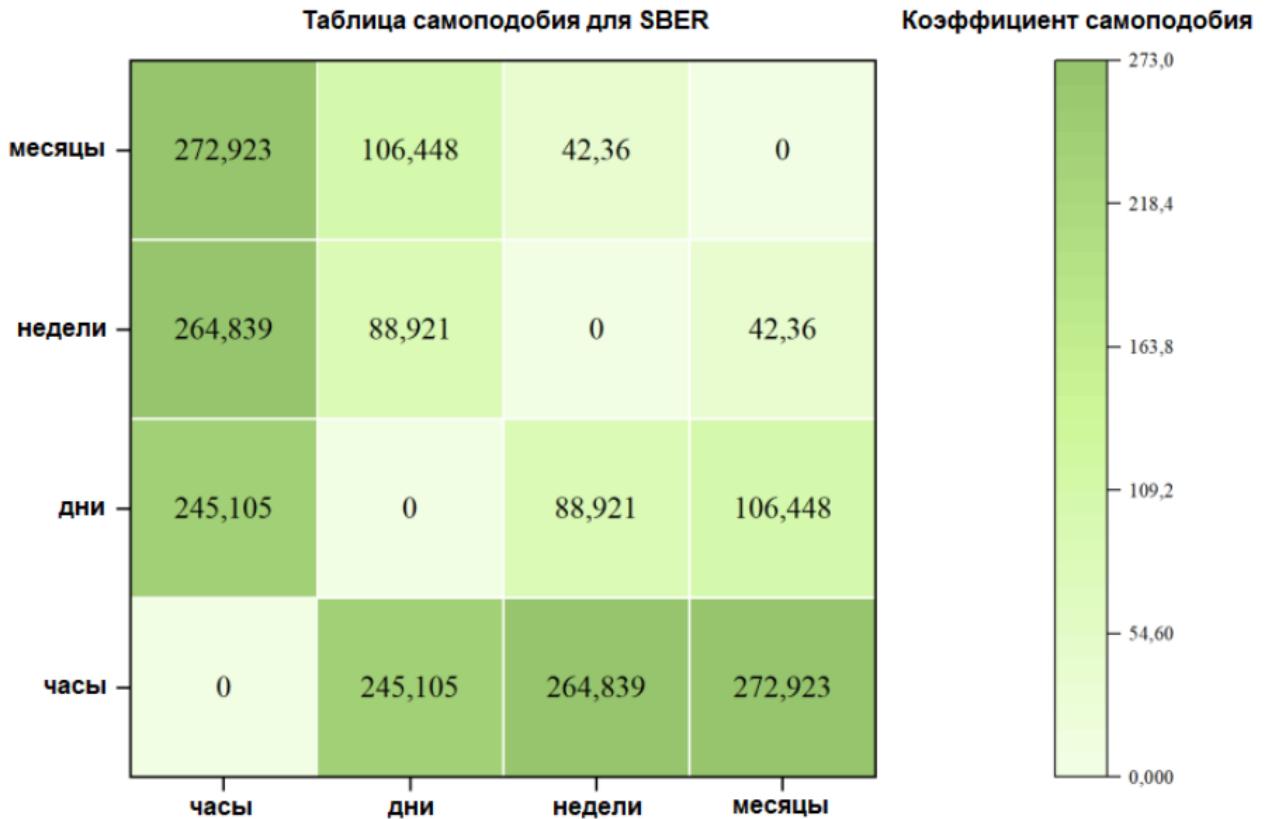


Рисунок 2.3 — Матрица самоподобия для четырех графиков цены акций SBER.

2.2.2 Непохожесть

С помощью приведенного ниже алгоритма можно выделить, поведение которых значительно отличается от других. Такие активы будут называться выбросами. Их следует рассматривать отдельно. Например, акции ВТБ обладают глобальным падающим трендом в отличие от большинства других активов, стоимость которых растет. Также можно отметить активы товарных рынков, поведение цен которых отличается от поведения цен на акции. Для их нахождения будут составлены матрицы непохожести для различных таймфреймов. В ячейках каждой матрицы будут записаны коэффициенты непохожести, соответствующие паре активов. Коэффициенты непохожести определяются следующим образом:

Пусть $p_{t_1}, p_{t_2}, \dots, p_{t_n}$ - числовой ряд, где p_{t_i} - цена закрытия данного актива в момент времени t_i . Дополнительный временной ряд составляется из про-

центных отклонений цены с течением времени d_1, d_2, \dots, d_{n-1} , элементы ряда вычисляются по формуле:

$$d_i = \frac{p_{t_{i+1}} - p_{t_i}}{p_{t_i}} \quad (2.11)$$

Далее осуществляется сортировка в порядке возрастания для данной пары активов D и S рядов процентных отклонений d_1, d_2, \dots, d_n и s_1, s_2, \dots, s_m . Если ряды отличаются по размеру (например, $m > n$), выполняется обрезка одного из них так, что отбрасываются первые $m - n$ точек. Принцип нахождения данного коэффициента для составленных рядов d_1, d_2, \dots, d_n и $s_{m-n+1}, s_{m-n+2}, \dots, s_m$ схематично можно представить в следующем виде, как показано на рис. 2.4.

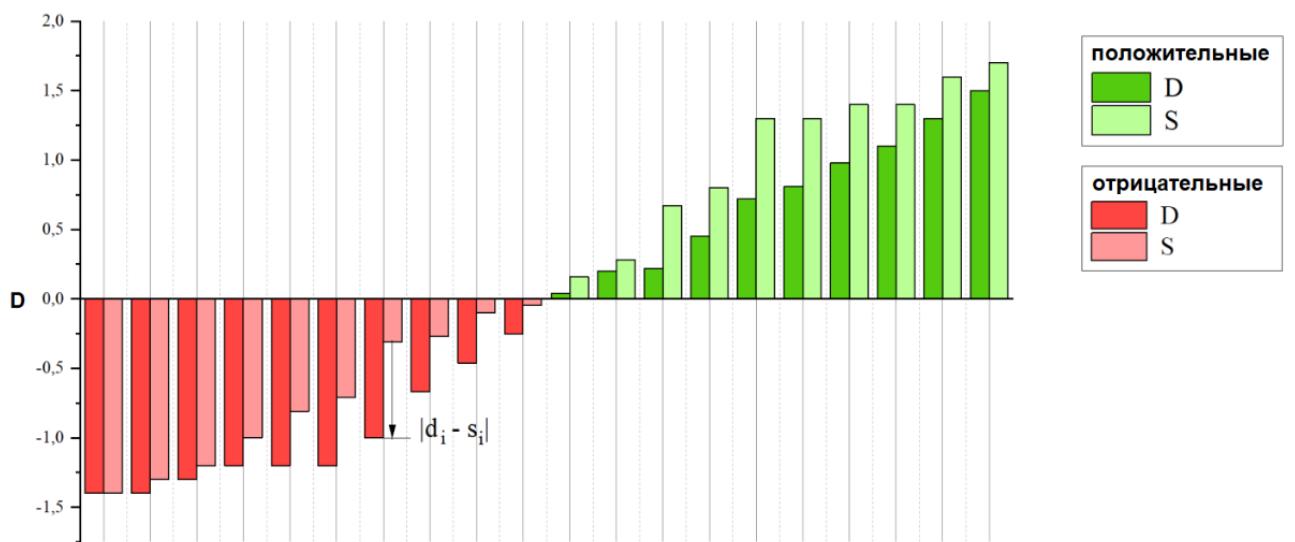


Рисунок 2.4 — Сопоставление двух временных рядов на предмет непохожести.

Окончательно, формула для нахождения коэффициента непохожести:

$$S = \sum_{i=1}^n n \frac{|d_i - s_i|}{n} \quad (2.12)$$

Далее рассматриваются матрицы коэффициентов непохожести. Более темные элементы матрицы соответствуют высоким значениям коэффициента непохожести. Таким образом, матрицы получились симметричны относительно диагонали, на которой стоят нули. Значение коэффициента непохожести близкое к нулю означает похожесть временных рядов рассматриваемых активов, в соответствии с предложенной метрикой. Чем больше коэффициент непохожести, тем меньше активы похожи друг на друга и тем ближе к темному цвету соответствующей клетки. Ниже приведен псевдокод описанного алгоритма.

Algorithm 2: Алгоритм вычисления коэффициента непохожести рядов.

```

for each time frame do
    for each pair of asset candles do
        (candles1, candles2) = pair
        n = min(len(candles1), len(candles2))
        candles1 = candles1[-n:]
        candles2 = candles2[-n:]
        deviations1 = sort((candles1[1:] - candles1[:-1]) / candles1[:-1])
        deviations2 = sort((candles2[1:] - candles2[:-1]) / candles2[:-1])
        for i in range(n-1) do
            sum +=  $\frac{|deviations_1[i] - deviations_2[i]|}{n - 1}$ 
        end for
    end for
end for

```

Активы, на пересечении которых стоит клетка, закрашенная близким к светлому цветом, имеют в целом похожий состав свечей, в то время как кресты означают, что какой-то актив сильно отличается по составу свечей от остальных, его следует трактовать его как выброс в данных. Из полученных результатов понятно, что в целом активы похожи друг на друга за исключением нескольких, например, *OZON* и товаров. Отличие *OZON* от остальных активов можно объяснить тем, что торговля этим активом началась недавно, в отличие других акций входящих в состав индекса МОЕХ. Так же можно отметить непохожесть графиков товарных активов и графиков стоимости акций. Это обусловлено тем, что торговля на товарных и фондовых рынках осуществляется по несколько различным правилам. В заключение из составленных матриц можно сделать вывод, что графики индексов, товаров и акций отличаются друг от друга по составу свечей в соответствии с описанной метрикой в силу различных тенденций развития.

2.2.3 Корреляция

Корреляция показывает статистическую взаимосвязь двух или нескольких случайных величин. Она характеризуется коэффициентом корреляции, ко-

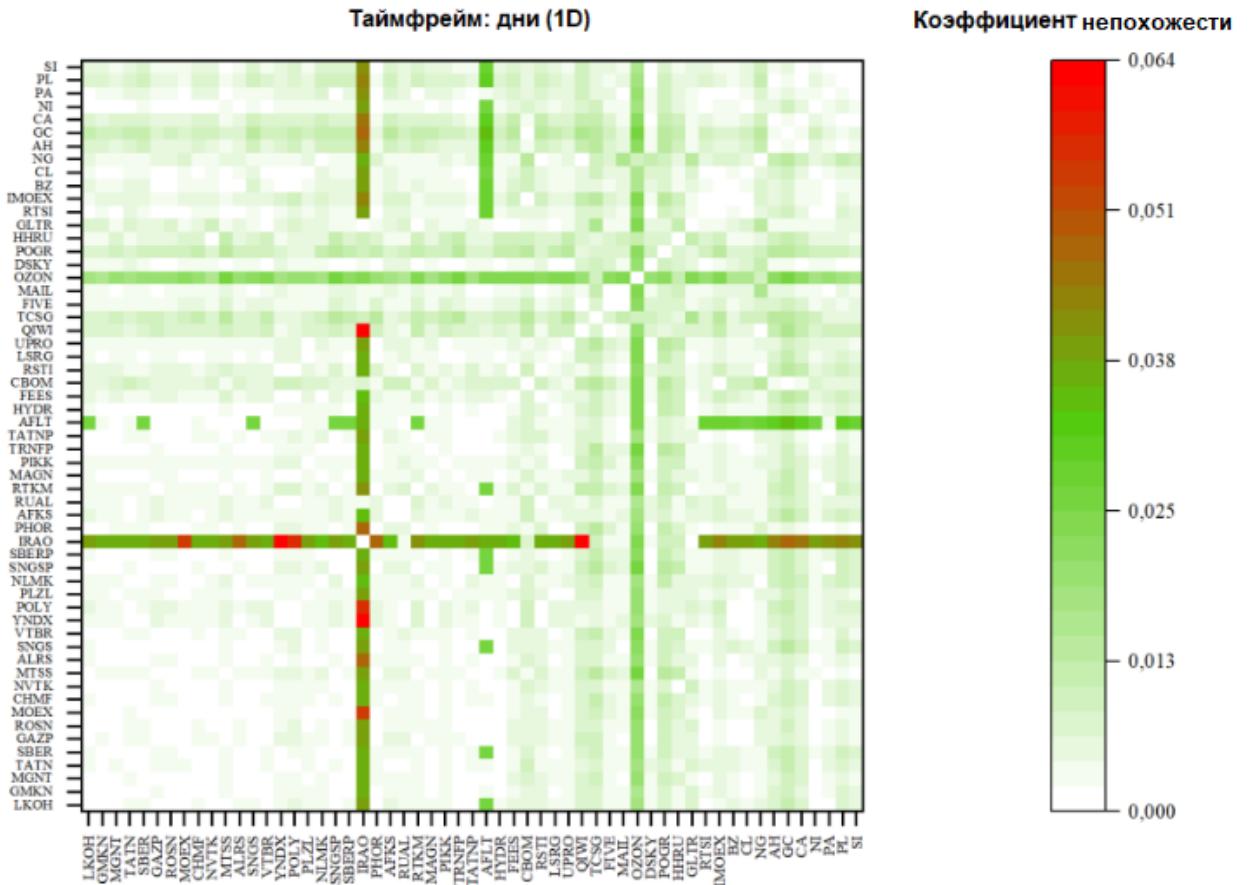


Рисунок 2.5 — Матрица коэффициентов непохожести для различных активов.

торый является мерой зависимости между двумя случайными величинами [150]. В случае независимости величин данный коэффициент равен нулю. Значение коэффициента корреляции лежит в пределах от -1 до +1. Чем он ближе к единице, тем больше взаимосвязь рассматриваемых величин, причем эта связь может быть как положительной, так и отрицательной. Как правило, первое означает, что увеличение одной величины влечет за собой увеличение второй, а в случае отрицательной - уменьшение.

Если в результате эксперимента получены n пар значений $(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)$ и если предполагается, что пары (x_i, y_i) являются независимыми двумерными величинами с одинаковым двумерным распределением, то можно записать выражение для выборочного коэффициента корреляции:

$$r = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}} \quad (2.13)$$

Пусть $p_{t_1}, p_{t_2}, \dots, p_{t_n}$ - числовой ряд, где p_{t_i} - цена закрытия данного актива в момент времени t_i . Для оценки того, насколько скоррелированы два ряда, соответствующие двум данным активам, используется коэффициент ранговой корреляции R по Спирмену:

$$R = 1 - \frac{6 \sum d^2}{n(n-1)(n+1)} \quad (2.14)$$

Практический расчет коэффициента ранговой корреляции по Спирмену включает следующие этапы. Во-первых, формируются дополнительные ряды d_1, d_2, \dots, d_n и s_1, s_2, \dots, s_n из процентных отклонений цены аналогично действиям, проделанным в пункте 3.2. Во-вторых, полученные значения рядов сортируются в порядке возрастания и получают свой порядковый номер от 1 до n . В заключение, на основе полученных матриц можно сделать вывод, что с помощью данного алгоритма не были выявлены явно скоррелированные или антикоррелированные активы. На рисунке 2.6 представлена матрица коэффициентов корреляции.

2.2.4 Волатильность

Волатильность - это статистическая мера разброса доходности для данной ценной бумаги или рыночного индекса [151]. Волатильность часто рассчитывается с использованием дисперсии и стандартного отклонения. Стандартное отклонение - это квадратный корень из дисперсии. Например, для ряда $p_{t_1}, p_{t_2}, \dots, p_{t_n}$, составленного из месячных цен закрытия некоторого актива значение волатильности σ^2 можно подсчитать следующим образом:

$$\bar{x} = \frac{p_{t_1} + p_{t_2} + \dots + p_{t_n}}{n} \quad (2.15)$$

$$\sigma^2 = \frac{(p_{t_1} - \bar{x})^2 + (p_{t_2} - \bar{x})^2 + \dots + (p_{t_n} - \bar{x})^2}{n} \quad (2.16)$$

Цель исследования волатильности заключается в том, чтобы выявить периоды резких всплесков волатильности графиков акций и исключить эти данные из рассмотрения. В периоды сильных изменений цены люди поддаются

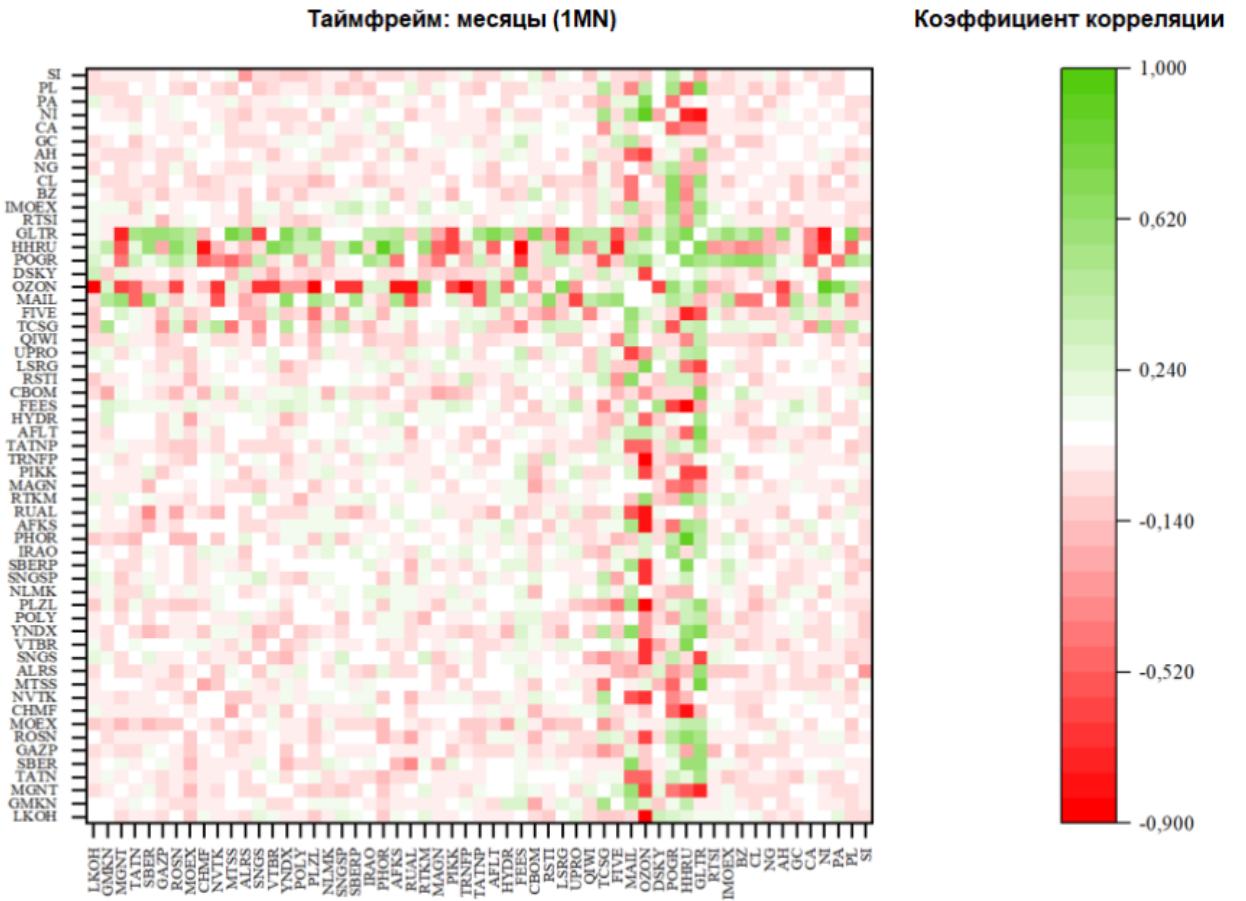


Рисунок 2.6 — Матрица коэффициентов корреляции для различных активов.

эмоциям и их поведение сложно подвергнуть техническому анализу [152]. Периоды резких всплесков волатильности будут рассмотрены на примере акций ПАО «Сбербанк». Графики волатильности строятся в соответствии с формулами выше. Пусть $p_{t_1}, p_{t_2}, \dots, p_{t_n}$ - числовой ряд, где p_{t_i} - цена закрытия данного актива в момент времени t_i . Новый ряд составляется из процентных отклонений цены с течением времени d_1, d_2, \dots, d_{n-1} , элемент рядда вычисляется по формуле:

$$d_i = \frac{|p_{t_{i+1}} - p_{t_i}|}{p_{t_i}} \quad (2.17)$$

Далее выполняется усреднение каждого элемента ряда для получения менее зашумленных графиков:

$$d_i = \frac{1}{20} \sum_{j=i}^{i+19} d_j \quad (2.18)$$

На рисунке 2.7 представлен итоговый график волатильности. На графике можно выделить три пика повышения волатильности, а именно, в 2009 году в связи с кризисом недвижимости [153], в 2014 году в связи с антиконституционным переворотом на Украине и в 2020 году в связи с пандемией коронавируса. Данные фрагменты временного ряда будут исключены из обучающей и тестовой выборок моделей по причине плохой применимости средств технического анализа в эти эмоциональные периоды.



Рисунок 2.7 — Сглаженный график волатильности стоимости акций SBER.

Полученные результаты исследования статистических свойств временных рядов финансовых рынков могут быть применены в процессе подготовки данных для обучения моделей, предназначенных для решения различных задач на подобных временных рядах. Установлено, что, во-первых, свечные графики в малых таймфреймах обладают меньшим самоподобием, чем свечные графики в больших таймфреймах, однако свечные графики в больших таймфреймах также не демонстрируют высокой степени самоподобия, поэтому при составлении выборки данных рекомендуется не смешивать данные свечных графиков различных таймфреймов; во-вторых, графики индексов, акций и товаров в одинаковом таймфрейме различаются по составу свечей, поэтому выборку данных для моделей следует составлять из временных рядов только одного класса; в-третьих, временные ряды акций компаний входящих в индекс МОЕХ и активов товарного рынка не обладают сильной корреляцией друг с другом, поэтому нет необходимости ликвидировать какие-либо компоненты выборки данных по причине корреляции. Дополнительно стоит отметить, что в периоды кризисов

на рынке наблюдаются всплески волатильности. В такие моменты поведение стоимости активов плохо описывается математическими моделями.

2.3 Формирование входного вектора для моделей

Для обучения моделей берутся данные на основе свечных графиков на дневном таймфрейме. Длительность используемых временных рядов составляет от 1 до 20 лет. Графики на меньших таймфреймах не рассматриваются из-за сильного шума данных. Исходные данные временного ряда получены из баз данных АО «Инвестиционный холдинг Финам» и содержат следующую информацию: дату и время, максимальную и минимальную цены, цены закрытия и открытия, а также торговый объем соответствующей свечи. В небольшой обучающей выборке использовались свечные графики 37 компаний, входящих в индекс МОEX. Всего туда включено 45 акций. Из обучающей выборки были исключены три компании: LKOH (ПАО «ЛУКОЙЛ»), GAZP (ПАО «Газпром») и RSTI (ПАО «Россети») из-за их использования для тестирования. Причины их выбора для тестирования заключаются в следующем. Акции LKOH демонстрируют глобальный растущий тренд. GAZP содержит флот, т.е. цена их акций колеблется в определенном диапазоне без четко определенного направления. RSTI долгое время сохраняет нисходящую тенденцию. Активы этих компаний позволяют проводить тестирование на различных типах данных. Данные на тестовой выборке представлены за шесть месяцев (с 1 января 2021 г. по 29 июля 2021 г.) и не пересекаются по времени с обучающей, благодаря чему не происходит перекрытия временных рядов. Была подготовлена большая обучающая выборка, включающая акции компаний, входящих как в индекс МОEX, так и в американский индекс S&P-500. В некоторых акциях происходят довольно сильные изменения направления. Столь сильные колебания наблюдаются преимущественно в начале временного ряда, поэтому начальные фрагменты всех временных рядов, содержащие столь сильные колебания, были вырезаны.

Для проведения исследования полученные исходные данные свечных графиков были подвергнуты ряду преобразований. Год был исключен из данных свечи, поскольку этот элемент данных не несет полезной информации для про-

Акция	Количество пятниц с ростом	Количество пятниц с падением
LKOH	517	475
GMKN	503	473
SBER	308	363
GAZP	379	392
ROSN	371	376
VTBR	301	377

Таблица 2 — Результаты анализа поведения цен акций по пятницам.

гнозирования временного ряда в будущем. Для кодирования номера дня использовалось One Hot Encoding. По данным полной даты для каждого дня рассчитывался номер дня недели, который кодировался с помощью One-Hot-Encode (ОНЕ). Таким образом дата кодировалась последовательностью из 31 нулей и единиц. Использование дня месяца и дня недели оправдано тем, что в течение месяца и в течение недели наблюдаются определенные тенденции, например, сокращение позиций в пятницу или в конце месяца. В частности, исследование поведения акций компаний, входящих в индекс МОEX, в пятницу было проведено по всем доступным данным. Результаты анализа показывают, что акции компаний банковского сектора по пятницам имеют тенденцию к снижению, а акции компаний нефтегазового сектора, наоборот, имеют тенденцию к росту.

Для кодирования часа внутри суток использовалась ОНЕ(24). Для данной части работы эта часть вектора неактуальна, т.к. используется дневной таймфрейм, однако в следующей главе будет использоваться 4-часовой таймфрейм для криптовалютного рынка, и эта кодировка будет использоваться. Данные о минуте и секунде свечи были полностью исключены, поскольку минимальный сплит свечей составляет один час. Включение в обучающую выборку данных о месяце, дне и дне недели одновременно оказывает негативное влияние на обучение модели, поскольку достаточно просто выделить по этим данным конкретный фрагмент временного ряда. Модель обучена не распознавать закономерности других элементов временного ряда, а просто запоминать дату. В итоговой кодировке даты и времени содержалась информация о дне месяца, дне недели и часе дня, закодированная последовательностью ОНЕ(62).

Невозможно использовать необработанные значения стоимости актива в обучающей выборке, поскольку разные активы имеют разные значения, поэтому необработанные значения стоимости актива были преобразованы в процент-

ное изменение. На рисунке 2.8 показаны процентные изменения актива относительно определенного значения цены.

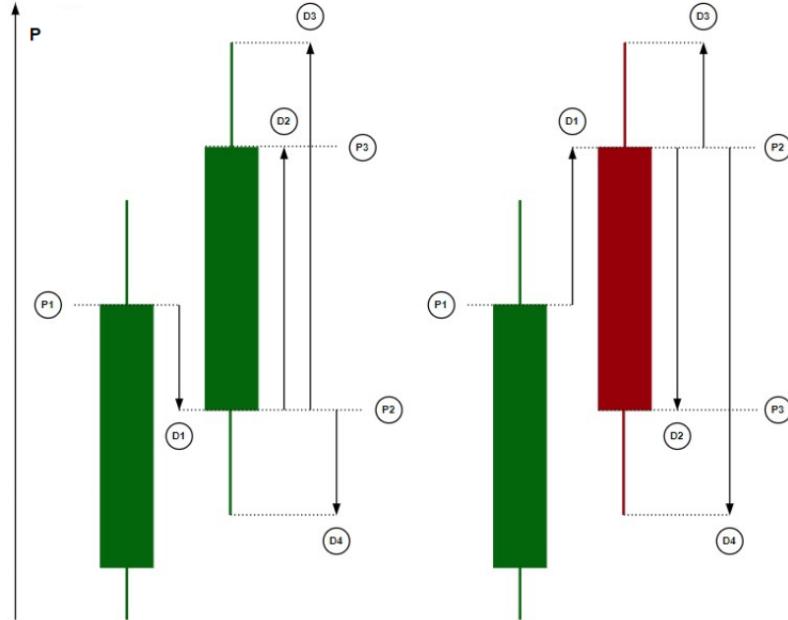


Рисунок 2.8 — Определение параметров процентных изменений цены.

$$\begin{aligned} D_1 &= \frac{P_2 - P_1}{P_1}, D_2 = \frac{P_3 - P_2}{P_2}, \\ D_3 &= \frac{P_{\max} - P_2}{P_2}, D_4 = \frac{P_2 - P_{\min}}{P_{\min}} \end{aligned} \quad (2.19)$$

$$D = \frac{P_3 - P_1}{P_1} \quad (2.20)$$

где P_1 — цена закрытия предыдущего дня, P_2 — цена открытия текущего дня, P_3 — цена закрытия текущего дня, P_{\min} и P_{\max} — минимальная и максимальная цены текущего дня соответственно. В этом случае D_3 и D_4 больше, чем 0, D , D_1 , D_2 — любой знак. Было проведено исследование процентного изменения стоимости актива. По результатам анализа значение D по данным всех активов распределяется нормально, что показано на рисунке 2.9. В итоговом формате входного вектора для моделей на каждом временном шаге использовалась предыстория из значений D для N последних свечей.

Значения диапазона $3 - \sigma$ находятся в диапазоне $[-0.1; 0.1]$, т.е. процентное изменение стоимости актива за день составляет не более 10%. Значения D для последних N -свеч были включены в обучающую выборку. При этом каждое значение умножалось на 10, таким образом достигалось нормальное распределение в диапазоне $[-1; 1]$, а значения вне этого диапазона были обрезаны до -1

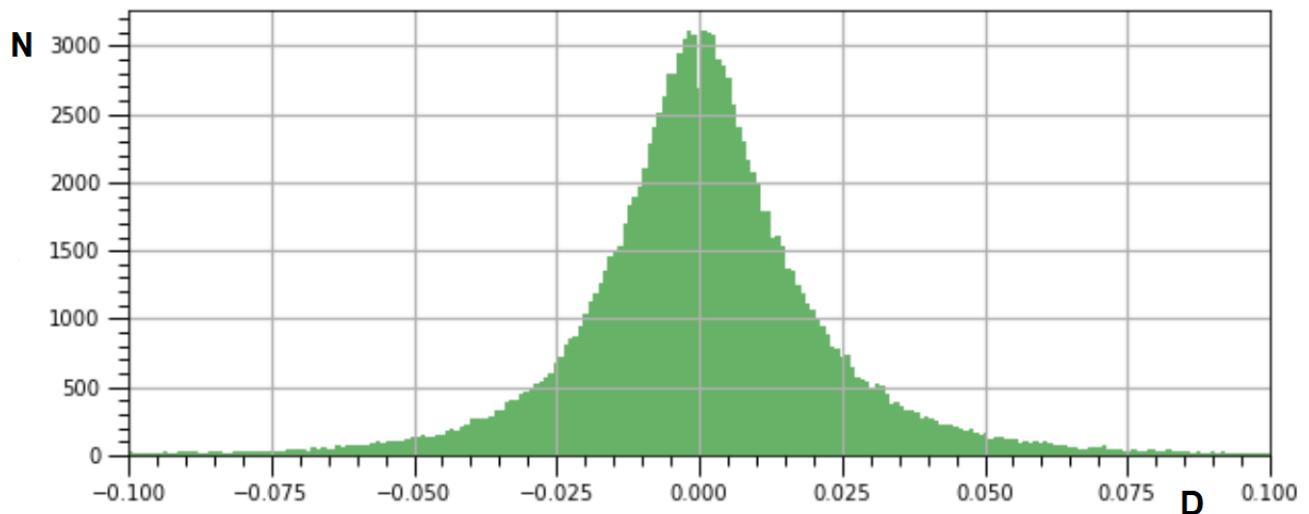


Рисунок 2.9 — Нормальное распределение процентных изменений цены.

и +1 соответственно. Помимо информации о стоимости актива также использовалась информация об объеме торгов V . Данные по объемам распределяются нормально, а процентные изменения объемов используются при составлении векторов обучающей выборки. Характерное процентное изменение объема составляет 50%, поэтому исходное нормальное распределение не масштабируется. В итоговом формате входного вектора для моделей на каждом временном шаге использовалась предыстория из значений V для N последних свечей.

В процессе анализа и прогнозирования временных рядов финансовых рынков часто используются уровни поддержки и сопротивления. В данной работе рассматриваются только горизонтальные уровни, определяемые локальными экстремумами. После того как цена преодолеет уровень сопротивления, он может превратиться в уровень поддержки, т.е. один и тот же уровень может проходить как локальные минимумы, так и локальные максимумы. Уровни определяются с помощью алгоритма обнаружения локальных экстремумов путем смещения окна фильтра фиксированной ширины (ширина измеряется в свечах). Каждый уровень характеризуется двумя параметрами. Первый — это его время жизни, которое измеряется в свечах и отсчитывается от первого локального экстремума, через который проходит этот уровень. Второй — сила уровня, которая соответствует количеству экстремумов, через которые этот уровень проходит в пределах погрешности. Максимальное время жизни уровня ограничено сверху, уровни превышающие этот лимит считаются устаревшими и не учитываются при анализе текущей ситуации. Нормализация прочности уровня S и

времени жизни уровня L осуществляется путем деления этих значений на максимальную прочность уровня и максимальное время жизни уровня, заданные как константы алгоритма нормализации данных.

$$\begin{aligned} S_{level}^{(norm)} &= \min(1.0; \frac{S_{level}}{S_{max}}) \\ L_{level}^{(norm)} &= \min(1.0; \frac{L_{level}}{L_{max}}) \end{aligned} \quad (2.21)$$

где $S_{level}^{(norm)}$ — нормированное значение силы уровня, $L_{level}^{(norm)}$ — нормированное значение времени жизни уровня, S_{level} и L_{level} — ненормированные значения силы и срока службы уровня, S_{max} и L_{max} — их заданные максимальные значения. Для каждой свечи каждого графика рассчитывается ближайший уровень поддержки (снизу) и сопротивления (сверху). Для некоторых свечей уровни могут отсутствовать. В этом случае все параметры равны нулю. Такая ситуация чаще всего возникает для свечей в начале графика, а также для свечей АТН (исторический максимум) и ATL (исторический минимум). Также для каждой свечи рассчитываются расстояния до ближайшего уровня сопротивления и до ближайшего уровня поддержки, которые измеряются в единицах стоимости актива:

$$D_{level} = \frac{P_{level} - P_{close}}{P_{close}} \quad (2.22)$$

где D_{level} — расстояние, P_{close} — цена закрытия свечи, P_{level} — цена уровня. Полученные процентные отклонения также имеют нормальное распределение, значения диапазона $3 - \sigma$ которого лежат в диапазоне $[-0,1; 0,1]$. Все процентные отклонения принимаются по модулю. В итоговом формате входного вектора для моделей на каждом временном шаге использовалась предыстория из 6 значений для каждой из N последних свечей, содержащая информацию о времени жизни, расстоянии до и силе ближайших к цене закрытия свечи уровней поддержки и сопротивления. Итоговая версия входного вектора содержит $8N + 62$ параметра, число N подбиралось экспериментально для разных таймфреймов, подробнее об этом будет рассказано в части про обучение с подкреплением. Элементы представленной здесь структуры входного вектора были описаны в статьях [5; 6; 9; 13].

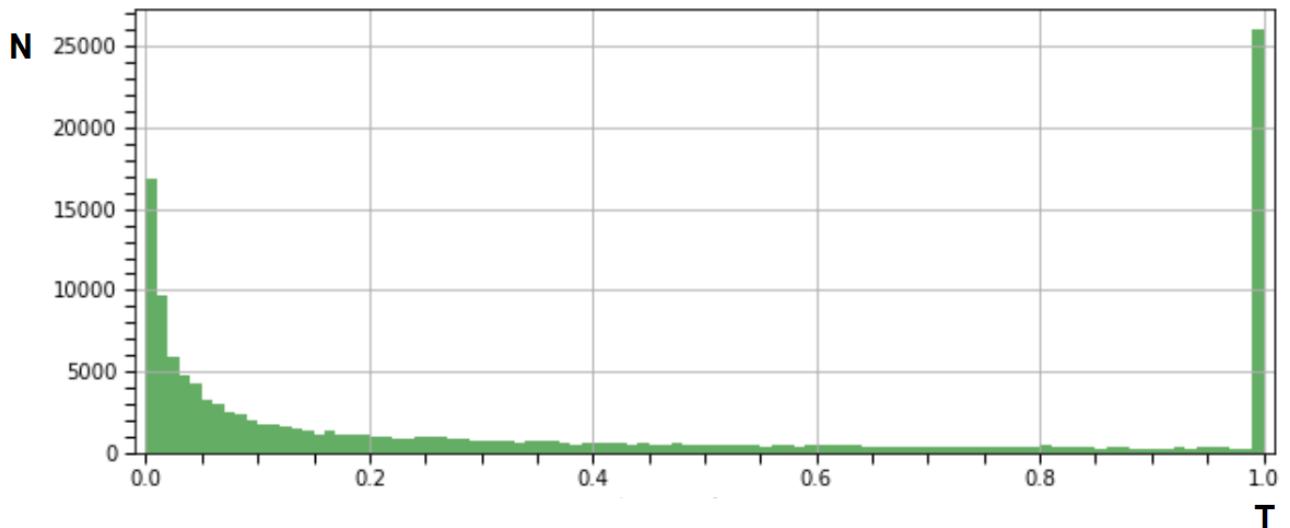


Рисунок 2.10 — Экспоненциальное распределение времени жизни уровней.

2.4 Разметка шагов временного ряда на 3 класса

В данной работе было подготовлено несколько типов разметки для решения задач классификации различного рода. Первый вариант простейшей разметки соответствует задаче прогнозирования движения цены вверх или вниз в ближайшие N_{cur} дней от текущего момента, N_{cur} лежит в диапазоне [1; 5]. Вторая версия разметки была получена с использованием алгоритма определения тренда с плавающей правой границей окна фильтра. В ходе экспериментов выяснилось, что значение точности лучше у разметки, полученной вторым методом. Далее в работе представлены результаты обучения и тестирования моделей на второй разметке, потому что точность на разметке первого типа 54 – 58%, на разметке второго типа 65 – 70%.

Первоначальный вариант разметки вторым способом подразумевает три класса: L, S, N . Отметка N означает, что на момент закрытия текущей свечи рекомендуется иметь нулевую позицию, L - что рекомендуется иметь длинную позицию, S - что рекомендуется иметь короткая позиция. Метка N соответствует моментам, когда на рынке нет определенного движения. В такие моменты можно либо продолжать удерживать существующую позицию до появления более четкого сигнала, либо установить нулевую позицию [154].

Метки типа N составляют около 10% от общего количества меток всех типов, поэтому было выполнено выравнивание обучающей и тестовой выборок

	Количество меток	Доля меток
Распределение меток в обучающей выборке	N: 12561 L: 56811 S: 51569	N:10% L: 46% S: 42%
Для отдельных активов		
RUAL D 1390	N: 131 L: 628 S: 631	N:9% L: 45% S: 45%
POGR D 74	N: 17 L: 15 S: 42	N:22% L: 20% S: 56%
FIVE D 677	N: 99 L: 301 S: 277	N:14% L: 44% S: 40%
MAGN D 3686	N: 342 L: 1719 S: 1625	N: 9% L: 46% S: 44%

Таблица 3 — Результаты алгоритма разметки для дневного таймфрейма.

до состояния, в котором количество меток каждого типа было одинаковым. Представленная здесь разметка была подробно изложена в статьях [5; 13].

2.5 Обучение с учителем модели классификации

Первая модель, которая рассматривалась в рамках данной работы - это модель обученная с учителем на описанной ранее разметке для решения задачи тернарной классификации. Первая версия данной модели была описана в статьях [5; 13]. Выходной сигнал модели - это наиболее вероятное состояние, которое должно быть реализовано на следующем временном шаге. Здесь можно обратить внимание на отличие подхода по сравнению с тем, который был описан в определении стратегии. Там использовалась терминология действий, совершаемых стратегией, рассматривалось множество из 4 действий. Здесь же рассматривается множество из трех состояний для упрощения реализации модели и процесса обучения и бэктестирования.

На рисунке 2.11 представлена архитектура модели. Модель имеет разветвленную топологию и содержит четыре точки входа, на которые разбивается

входной вектор - это предыстория цен, объемов, уровней и данные о временной метке. Далее для работы с предысторией временного ряда используются слои LSTM типа, которые конкатенируются и обрабатываются дополнительными полносвязанными слоями с выпадением 0.5 [155; 156]. Модель реализована посредством инструментария Keras и Tensorflow и имеет порядка 6 млн параметров [157–161].

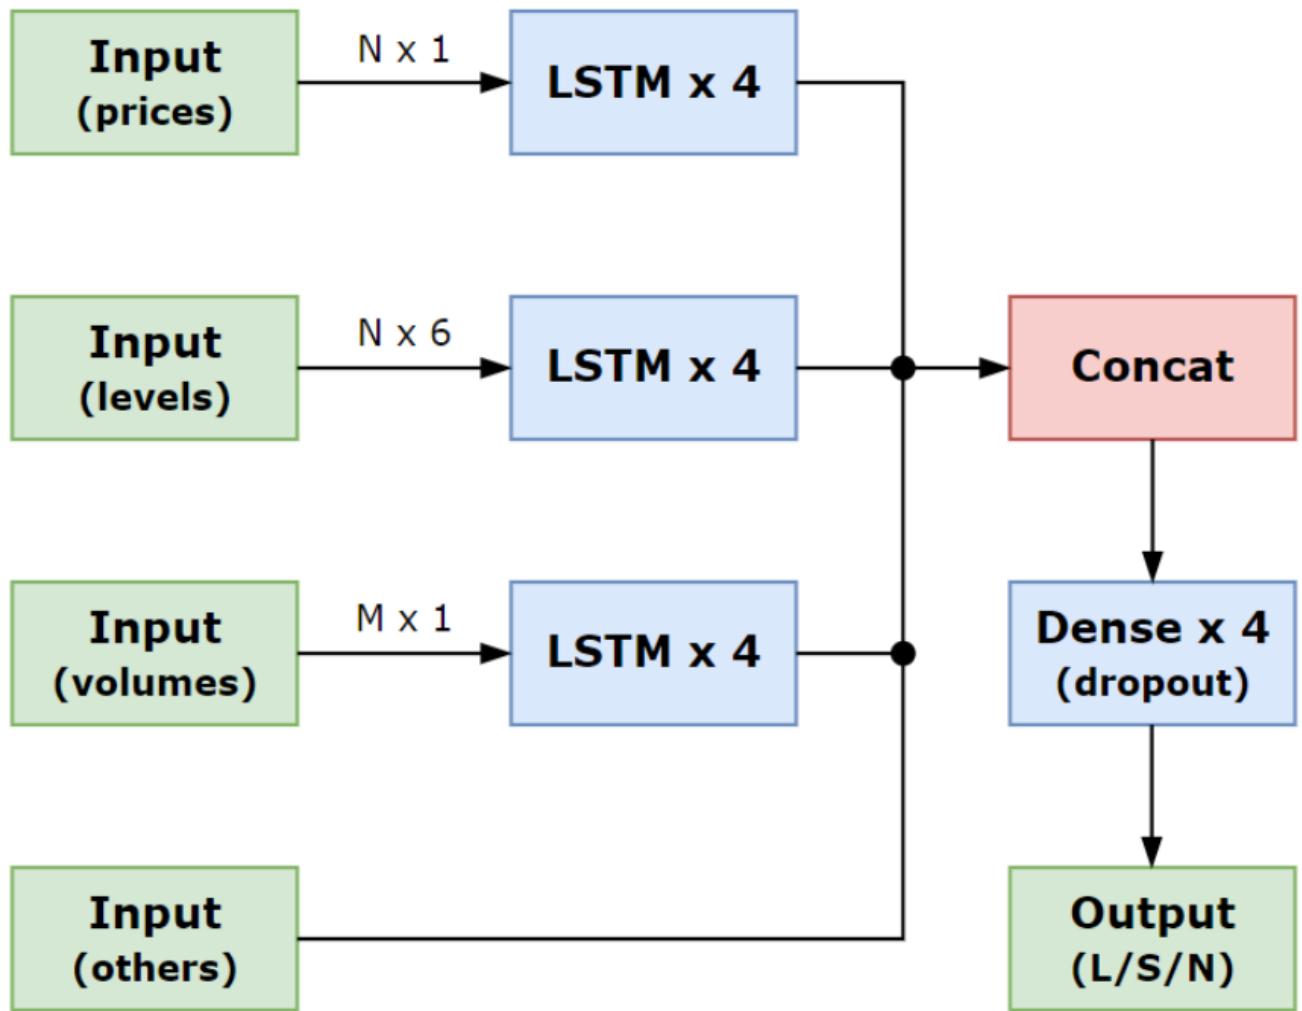


Рисунок 2.11 — Архитектура модели для решения задачи классификации.

В результате обучения модели на протяжении 10 эпох, что являлось оптимальным значением, было достигнуто значение метрики точности в 66.5% и доходность по результатам бэктестирования на тестовой выборке в 15% годовых за 2022 год [162; 163]. Коэффициент Шарпа составил примерно 0.22. Коэффициент Сортино составил примерно 1.38. Это довольно низкие показатели, ниже минимально необходимых, обозначенных ранее. Модель показала обучаемость в терминах машинного обучения, однако непригодна по финансовым показателям в реальных условиях [164; 165]. Низкие показатели модели обусловлены

в том числе достаточно примитивной разметкой и частыми переворотами позиций, что будет исправлено далее в подходе обучения с подкреплением [166]. Полный отчет модуля бэктестирования при полученных значениях коэффициентов Шарпа и Сортино приводить не имеет смысла.

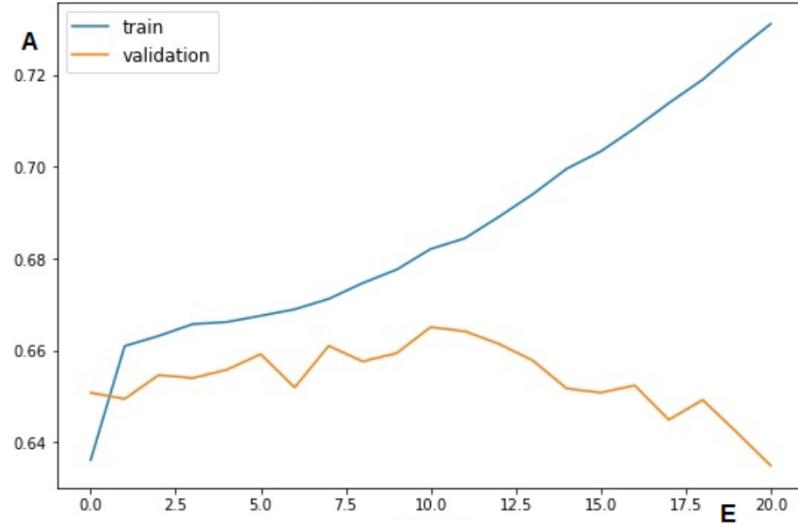


Рисунок 2.12 — График зависимости точности от количества эпох обучения.

2.6 Обучение с подкреплением модели типа DQN

В настоящее время алгоритмы обучения с подкреплением реализованы во многих областях и показывают лучшие результаты, чем существующие альтернативные решения [167–172]. Одним из актуальных направлений является разработка систем поддержки принятия решений при совершении операций с финансовыми активами [173]. Эти системы реализованы для решения задач прогнозирования многомерных временных рядов, а также поиска и классификации закономерностей.

Новизна данной работы заключается в совмещении обучения отдельных моделей с использованием известного варианта оптимизации алгоритма DQN с двумя сетями и буфером воспроизведения и составлении ансамбля таких моделей. Представленные ниже результаты были опубликованы автором в статье [7]. В классическом машинном обучении часто рассматриваются ансамбли слабых моделей. В данной работе рассматривается составление ансамбля сильных моделей, каждая из которых по отдельности способна качественно решить поставлен-

ную задачу, но с худшей производительностью (доходностью при совершении операций на финансовых рынках), чем в составе ансамбля. В процессе обучения моделей алгоритмом DQN присутствует фактор случайности, связанный с ϵ -жадным исследованием окружающей среды. В связи с этим обучение моделей осуществляется по-разному, поэтому был разработан критерий отбора обученных моделей для составления ансамбля. Показано, что эффективность такого ансамбля значительно превышает эффективность каждой отдельной модели.

В этой части описывается среда, используемая для обучения с подкреплением, алгоритм DQN, результаты исследования ансамбля обученных глубоких нейронных сетей и использование этого алгоритма для применения на финансовых рынках. В качестве входного вектора используются те же вектора, что и для модели обучения с учителем. Единственное отличие заключается в отсутствии разметки. Для обучения с подкреплением она не нужна. Проведено исследование зависимости эффективности моделей обучения от длительности используемой предыстории (предыстории процентного изменения стоимости актива). Проверялись значения $N = 5, 10, 20, 30, 40, 50, 60$. В ходе экспериментов было установлено, что наиболее оптимальное значение длины предыстории временного ряда на каждом шаге N составляет 60, что соответствует анализируемому фону за три месяца при продолжительности временного шага 1 торговые сутки, что соответствует количеству рабочих дней в одном месяце. На рисунке 2.13 горизонтальная ось показывает эпоху обучения, а вертикальная ось — общую прибыль. Видно, что большие значения N позволяют достичь более высоких значений прибыли за меньшее время. Эти результаты приведены для обучающей выборки. Аналогичная тенденция наблюдается и на тестовой выборке. При этом насыщение происходит в диапазоне значений N от 40 до 60, в связи с чем дальнейшее увеличение значений N не имеет смысла. Архитектура модели также не претерпела изменений относительно предыдущего раздела, изменился только способ обучения модели.

Алгоритмы обучения с подкреплением требуют определенной среды, в которой поведение обучающего агента оптимизируется для достижения наибольшего вознаграждения. Реализованная среда обучения с подкреплением представляет собой набор многомерных временных рядов, построенных на основе выборочных данных. Исходные данные каждого используемого многомерного временного ряда преобразуются в массив входных векторов состояния. Для раз-

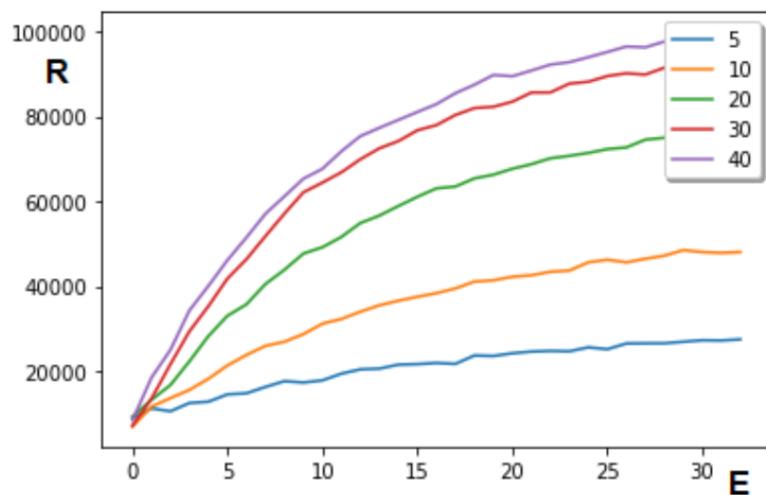


Рисунок 2.13 — Определение оптимальной длины предыстории ряда.

ных активов доступны исторические данные разной продолжительности, поэтому размеры описываемых массивов разные. Каждый такой массив будет называться уровнем по аналогии с уровнями в игре, а позиция на уровне будет соответствовать определенному состоянию. Количество уровней соответствует количеству активов в выборке. Реализованная среда представляет собой комбинацию уровней и в дальнейшем будет называться игрой.

Агент знает текущее состояние среды. В каждом состоянии у агента есть возможность совершить какое-то действие. Задача агента – завершить игру, т.е. ему необходимо пройти все состояния всех уровней, начиная с начального состояния первого уровня и заканчивая конечным состоянием конечного уровня, выполняя при этом такие действия, которые бы максимизировали его общая награда. По сути, этот процесс соответствует дискретному моделированию свечных графиков стоимости финансовых активов, при котором новая свеча появляется один раз в единицу времени, после чего разрешается совершить операцию по покупке или продаже этого актива.

В начале игры агент находится в исходном состоянии первого уровня. Окружение также содержит информацию о позиции, которую занимает агент в этом состоянии. Мы говорим о длинной или короткой позиции. Вознаграждение агента на каждом этапе рассчитывается исходя из его положения в текущем состоянии и процентного изменения стоимости актива, появляющегося в следующем состоянии. Например, вознаграждение агента увеличивается, если у него длинная позиция и стоимость актива увеличивается в следующем состоянии. Следует отметить, что позиция агента обнуляется при переходе с одного уров-

ня на другой. Каждая операция по изменению позиции агента имеет накладные расходы, называемые комиссией.

При классическом обучении с подкреплением агент выполняет действия, которые в рамках рассматриваемой задачи представляют собой покупку/продажу актива. Однако это не очень удобно с практической точки зрения, поскольку выполнить одни и те же действия, рекомендованные агентом, может быть невозможно в течение длительного времени. Например, агент рекомендует покупать определенный актив в течение десяти дней подряд. Это можно рассматривать как повышение позиции, но из-за неопределенности суммы повышения рекомендации агента могут не быть выполнены в реальной жизни.

В связи с этим было принято решение заменить действия (покупка/продажа) на рекомендуемые состояния для текущей позиции. То есть агент рекомендует, какую позицию следует открыть/закрыть в данный момент (длинную/короткую), и если это происходит несколько раз подряд, то текущую позицию следует оставить без изменений [174]. Действие рассчитывается как разница между рекомендуемой позицией и текущей. При таком подходе гарантируется возможность совершения любых действий. В данной работе ранее мы уже рассматривали замену действий на состояния при обсуждении обучения модели с учителем решению задачи тернарной классификации. При совершении операции прибыль не реинвестируется.

Для обучения модели был реализован и исследован алгоритм глубокого обучения с подкреплением (Q-learning) типа DQN с оптимизацией, представленной двумя сетями и буфером воспроизведения [175; 176]. Помимо этого были протестированы некоторые другие алгоритмы, например, исполнитель-критик, но при обучении этих алгоритмов алгоритм быстро переключился на стратегию Buy&Hold, в связи с чем дальнейшие исследования были посвящены модификациям алгоритма DQN.

Для обучения модели используется алгоритм глубокого обучения с подкреплением (Q-learning) типа DQN с двумя сетями и буфером воспроизведения. Основным элементом Q-обучения является так называемая Q-функция, которая рассчитывается как дисконтированная сумма вознаграждения на каждом этапе. В простейшем случае составляется таблица состояний и действий и эта функция рассчитывается для каждого шага. Но когда состояний слишком много или они непрерывны, сделать это невозможно и необходимо аппрокси-

мировать эту функцию с помощью нейронной сети, которой является модель DQN [177]. В данной работе мы используем оптимизацию данного алгоритма, включающую в себя две нейронные сети: быстро обновляемую (онлайн) и медленную (целевую), а также буфер воспроизведения.

Algorithm 3: Алгоритм обучения с подкреплением модели типа DQN.

```

for i in range(epochs) do
    current = environment.reset()
    while current != timeseries.end() do
        if epsilon-greedy research required then
            action = random(L, S, C)
        else
            action =  $M_{online}(current)$ 
        next, reward = environment.step(action)
        BUFFER  $\leftarrow$  current, action, next, reward
        current = next
    end if
    if  $M_{online}$  update required then
         $current_t, action_t, next_t, reward_t$  = random(BUFFER)
        update( $M_{online}, floss(reward_t + \gamma * M_{target}(next_t), M_{online}(current_t))$ )
    end if
    if  $M_{target}$  update required then
         $M_{target} = M_{online}$ 
    end if
    end while
end for

```

Обучение проводится циклично по K эпох. В начале каждой итерации запрашивается начальное состояние игры, после чего моделируется процесс пошагового прохождения игры до ее завершения. Во время игры агент выполняет эпсилон-жадное исследование среды. Это означает, что с некоторой вероятностью агент совершает в этом состоянии случайное действие (рекомендует установить случайную позицию). В противном случае действие в текущем состоянии запрашивается из быстрой (онлайн) модели. В данной работе используется фиксированное значение вероятности. Этот подход является наиболее распространенным в подобных алгоритмах. Благодаря нему модели могут обучаться немного по разному, что далее позволило составить ансамбль из подобных моделей, показывающий более высокую результативность по финансовым показателям, чем отдельно взятые модели. После этого полученное действие

передается в среду, которая возвращает следующее состояние и награду, которые вместе с текущим состоянием и действием сохраняются в буфер. Весовые коэффициенты быстрой модели обновляются после каждого пятого состояния, что соответствует прохождению одной торговой недели. Для этого из буфера формируется случайная выборка, состоящая из четверок, содержащих состояние, следующее состояние, действие и награду. Следующее состояние передается медленной (целевой) модели, по результатам прогнозирования которой выбирается наибольшее значение будущего вознаграждения. Общая ожидаемая награда рассчитывается по формуле:

$$y_i = r_i + \gamma \max_{a'_i} Q_\theta(s'_i, a'_i) \quad (2.23)$$

где i — индекс компонента буферной выборки, r_i — награда текущего шага, γ — коэффициент дисконтирования, Q_θ означает медленную целевую модель, s'_i — следующее состояние, a'_i — следующее действие. Значение гаммы указывает на важность учета будущих вознаграждений в текущий момент. Значение, равное единице, означает, что награды на всех шагах до конца игры имеют одинаковый вес, значение, равное нулю, означает, что ценность имеет только награда текущего шага. В этой работе используется значение 0,05. Данное значение выбрано в соответствии со среднесрочной торговой стратегией, которая предполагает удержание позиции от 1 до 20 дней. Использование 1 может привести к тому, что агент научится выполнять действия по стратегии «купи и держи».

Далее значение функции потерь рассчитывается на основе полученного значения y_i и значения Q-функции, предсказанного онлайн-моделью. Весовые коэффициенты онлайн-модели обновляются с помощью градиентного спуска на основе полученного значения функции потерь. Весовые коэффициенты целевой модели обновляются каждые 250 шагов, что соответствует прохождению одного года. Целевая модель обновляется путем перезаписи весовых коэффициентов онлайн-модели в целевую модель.

Для обучения моделей использовалась среда, состоящая из большого количества уровней, соответствующих количеству долей в обучающей выборке. Для тестирования использовалась среда, состоящая из трех уровней, соответствующих акциям ЛКОН (ПАО «ЛУКОЙЛ»), RSTI (ПАО «Россети») и GAZP (ПАО «Газпром»). Критерием прекращения обучения при размножении транзакции

в 100 условных единиц и без реинвестирования прибыли было суммарное вознаграждение по тесту, превышающее или равное 100* общую продолжительность тестовых данных в годах.

Как упоминалось во введении, для обучения нейронных сетей рассматривалось использование различных версий алгоритма DQN. Основная значимость этой работы заключается в создании ансамбля сильных моделей, обученных с использованием DQN, с двумя сетями и буфером воспроизведения. Данный ансамбль позволит качественно решить задачу с большей производительностью, чем каждая модель в отдельности. В процессе обучения моделей присутствует фактор случайности, в связи с чем модели обучались по-разному. Следовательно, в данной работе также был реализован критерий отбора обученных моделей для составления ансамбля.

В процессе обучения отдельных моделей было обнаружено, что из-за случайного изучения среды модели обучаются по-разному. В связи с этим было принято решение обучить несколько моделей и составить из них ансамбль. В ансамбле вес моделей считался одинаковым, и окончательное решение принималось большинством. Установлено, что использование ансамбля дает существенный прирост общего вознаграждения как на данных тестовой выборки за все время, так и за последние шесть месяцев. В таблице 4 представлены результативности ансамблей, состоящих из разного количества моделей. Как видно из таблицы, с увеличением количества моделей в ансамбле увеличивается и получаемая ими награда. Время, необходимое для функционирования ансамбля на каждом шаге, также увеличивается пропорционально, поэтому было решено сосредоточиться на ансамбле, содержащем 64 модели. Его эффективность приемлема для используемой среднесрочной торговой стратегии. Полученный ансамбль дает прибавку к вознаграждению за тестовый период примерно на 100% по отношению к каждой отдельной модели из ансамбля. Также использование ансамбля дает более плавный график роста вознаграждения без сильных просадок. Доходность одной модели составила от 40 до 56% годовых за 2022 г. Доходность ансамбля из 64 моделей составила примерно 90% годовых за 2022 г. с коэффициентом Шарпа 0.47 и коэффициентом Сортино 4.16, что уже достаточно близко к желаемым целевым показателям и может быть запущено в экспериментальном режиме на реальном счете.

M	R(3 года)	R(2022 г.)
22	$\approx 206\%$	$\approx 81\%$
24	$\approx 207\%$	$\approx 84\%$
26	$\approx 213\%$	$\approx 84\%$
32	$\approx 240\%$	$\approx 86\%$
44	$\approx 267\%$	$\approx 89\%$
58	$\approx 278\%$	$\approx 90\%$
64	$\approx 280\%$	$\approx 90\%$

Таблица 4 — Результативность работы разных ансамблей моделей.

2.7 Выводы ко второй главе

В результате определения статистических свойств многомерных временных рядов финансовых рынков были наложены ограничения на обучающую и тестовую выборки для моделей. Для расширения выборок использовались временные ряды со свойством самоподобия на различных таймфреймах. Было установлено, что свойство самоподобия лучше всего проявляется на паре старших таймфреймов. Также были получены результаты оценки непохожести временных рядов с целью исключения активов с особым поведением из обучающей выборки. В качестве дополнительных свойств были рассмотрены корреляция и волатильность, которые также были учтены в процессе формирования выборок. Была достигнута обучаемость модели машинного обучения с архитектурой с разветвленной топологией на основе LSTM-слоев для решения задачи прогнозирования, поставленной в терминах тернарной классификации. Тем не менее, финансовые показатели стратегии на основе данной модели оказались достаточно низкие. Ансамбль DQN-моделей показал гораздо более высокие результаты по сравнению с первой версией модели. В следующей главе будет представлена третья версия модели, основанная на комбинации жесткой алгоритмической стратегии и модели машинного обучения. Помимо этого будет дополнена структура многомерного временного ряда дополнительными вторичными признаками на основе ленты сделок, что предоставит моделям больше полезной информации в процессе решения задач прогнозирования.

Глава 3. Адаптация модели для криптовалютного рынка

В данной главе представлено оригинальное решение задачи прогнозирования точек разворота на многомерных временных рядах финансовых рынков за счет использования дополнительных апериодических вторичных признаков на основе ленты сделок и предложенном двухэтапном методе оптимизации гибридной стратегии, которая основана на классической алгоритмической стратегии, сигналы которой фильтруются посредством модели машинного обучения на архитектуре DQN. Здесь показано, что подобное использование моделей машинного обучения поверх жестких алгоритмических стратегий позволяет существенно повысить доходность стратегий. В конце главы приведен полный отчет модуля бэктестирования для итоговой версии стратегии.

В разделе 3.1 описаны дополнительные признаки многомерных временных рядов финансовых рынков. В разделе 3.2 представлена итоговая третья итерации модели и стратегии, предлагаемая автором как основной результат данной работы. В разделе 3.3 продемонстрированы отчеты модуля бэктестирования для итоговой третьей версии стратегии.

3.1 Дополнительные признаки на основе ленты сделок

Следующим шагом развития системы стала ее адаптация под современный криптовалютный рынок. Как было показано в главе 1, поведение цен криптовалютных активов обладает куда большей волатильностью, чем поведение цен активов классических рынков. В связи с этим требуется более быстрое реагирование на движения цены, поэтому основным рабочим таймфреймом стратегии был выбран часовой вместо дневного, используемого по умолчанию для работы с активами МОEX.

Также входной вектор был дополнен компонентами ленты сделок. Как было показано в главе 1, лента сделок содержит анонимную информацию о совершенных участниками торгов сделок по купле-продаже базового актива. На рисунке 3.1 продемонстрирован фрагмент ленты сделок для торговой пары

BTCUSDT на споте Binance. В первом столбце указан момент времени совершения сделки в UNIX-формате, во втором столбце указана сумма сделки в единицах котируемого актива, в данном случае это USDT. Легко заметить серию сделок на 1417.77 USDT. Таким образом некоторый участник торгов обслуживает свою крупную позицию. С помощью собственной автоматизированной торговой системы данный участник анализирует состояние стакана котировок и определяет оптимальное дробление для своих операций, чтобы не допустить сильного проскальзывания цены. Далее нас будут интересовать подобные серии сделок.

время	сумма
1641023458512,	141.36
1641023484432,	80.07
1641023486709,	942
1641023488942,	372.09
1641023546365,	28.29
1641023547821,	1980.3
1641023556375,	912.01
1641023576865,	84.87
1641023956137,	6000.75
1641024371991,	471.55
1641024557400,	235.5
1641024954122,	1416.9
1641025014165,	1417.77
1641025014188,	1417.77
1641025014433,	1417.77
1641025014968,	1417.77
1641025015205,	1417.77
1641025015439,	1417.77
1641025016458,	1417.77
1641025016710,	1417.77
1641025016933,	1417.77
1641025017160,	1417.77
1641025017429,	1417.77
1641025017696,	1417.77
1641025017933,	1417.77
1641025018183,	1417.77
1641025018673,	1417.77
1641025018936,	1417.77
1641025019183,	1417.77
1641025019209,	2362.95
1641025019426,	1417.77
1641025019907,	945.2
1641025019944,	47.26
1641025019969,	1417.8
1641025024266,	1417.95
1641025024540,	1417.95
1641025024793,	1417.95
1641025025065,	1417.95
1641025025312,	1417.95
1641025025556,	1417.95
1641025025835,	1417.95
1641025026067,	1417.95
1641025028341,	1418.61

Рисунок 3.1 — Фрагмент ленты сделок для BTCUSDT на споте Binance.

В первую очередь были рассмотрены серии сделок, совершаемые НФТ-фондами в рамках стратегий арбитража и маркет-мейкинга. Подобные серии сделок характеризуются малыми суммами отдельных сделок, большим количеством сделок и небольшими временными интервалами между сделками. Следует сразу отметить, что такие серии сделок могут растягиваться на несколько минут и даже часов, поэтому в них могут вклиниваться сделки других участников торгов, которые должны быть очищены в процессе подготовки данных. На

рисунке 3.2 приведена разметка фрагмента графика торговой пары BTCUSDT со спота Binance. Более темным цветом выделены временные периоды, на протяжении которых наблюдалась интересующие нас серии сделок. В данном случае рассматриваемая серия характеризуется сделками на сумму 0.005 BTC, количество сделок в серии составляет 100 и более, временной интервал между смежными сделками не превышает 5000 мс. На приведенном фрагменте графика данная серия сделок начиналась и заканчивалась 7 раз. Легко заметить, что она соответствует моментам повышения волатильности на рынке. Дело в том, что данная серия сделок имеет отношение к HFT фонду, практикующему межбиржевой арбитраж. В общей сложности во входном векторе MFTS для каждого временного шага методом ОНЕ было закодировано несколько десятков подобных серий сделок. Подробное описание всех серий в данной работе не приводится.

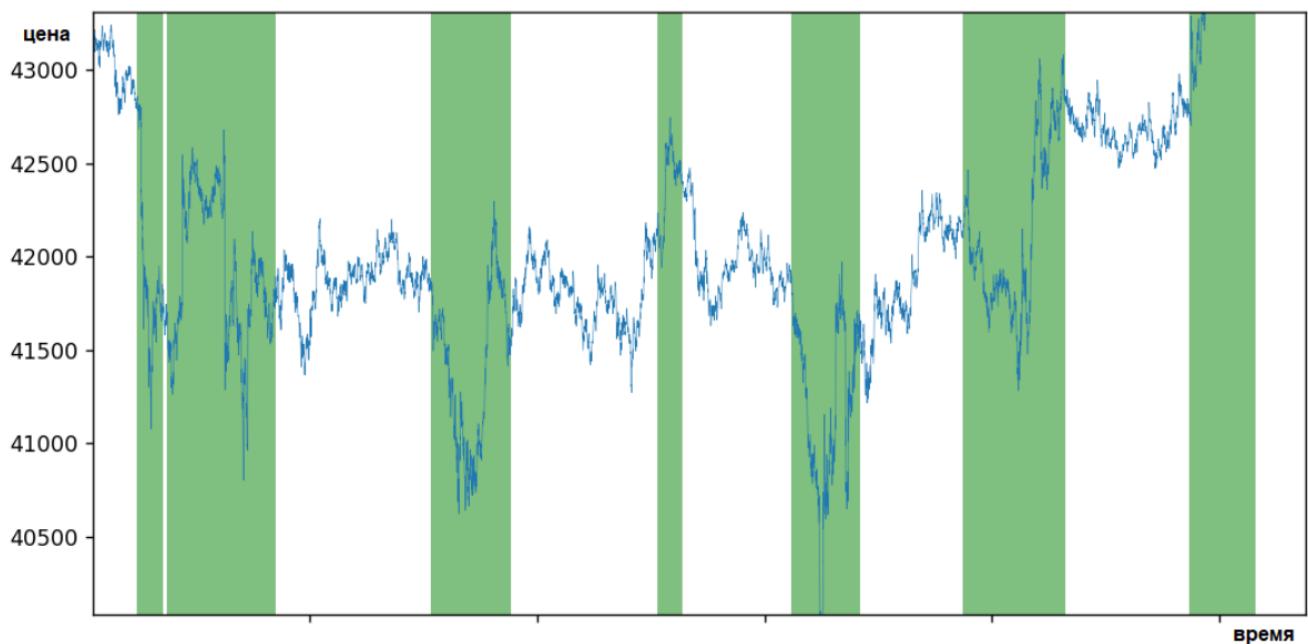


Рисунок 3.2 — Фрагмент разметки серий сделок на графике BTCUSDT.

В процессе работы над сериями сделок было проведено дополнительное исследование, посвященное кластеризации временных шагов MFTS по характеру сделок. Для каждой часовой свечи был построен ОНЕ вектор, отражающий присутствие или отсутствие той или иной серии сделок. Далее была выполнена кластеризация данных векторов методами DBSCAN и BIRCH. На рисунках 3.3, 3.4, 3.5 и 3.6 представлены результаты данной кластеризации. Наилучшие результаты были достигнуты при разделении множества векторов на 4 кластера. На рисунках видно, что разные кластеры соответствуют разным стадиям разви-

тия рыночных трендов, а именно: кластер номер 2 соответствует начальной фазе тренда, кластер номер 3 соответствует промежуточной фазе тренда, кластер номер 1 соответствует финальной фазе тренда, кластер номер 0 соответствует периодам отсутствия явно выраженных трендов. Наличие таких кластеров обусловлено тем, что на различных фазах рыночных трендов поведение основных участников торгов отличается, т.е. торговые стратегии функционируют по разному, что отражается в изменении серий сделок.

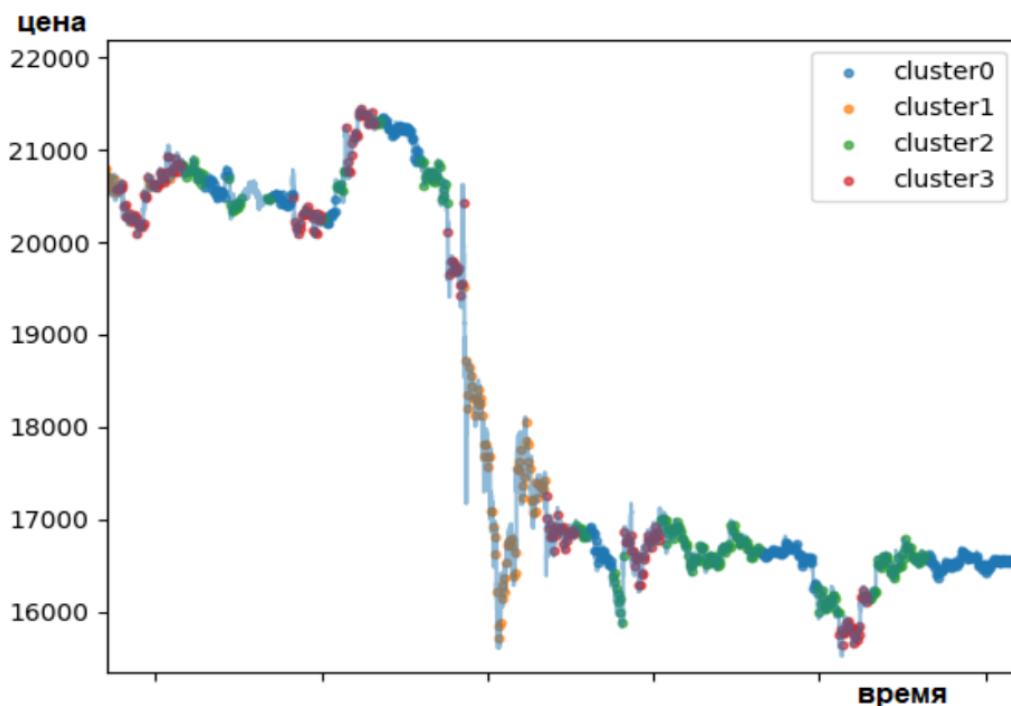


Рисунок 3.3 — Кластеризация серии сделок на 4 кластера методом DBSCAN.

На рисунке 3.7 представлена альтернативная кластеризация на 3 класса. Здесь первый кластер соответствует точкам разворота в зонах высокой волатильности, второй кластер соответствует направленным трендовым движением в зонах высокой волатильности, остальные точки графика в зонах низкой волатильности соответствуют третьему кластеру. Этот подход использовался автором при работе над флетовыми стратегиями, которые не рассматриваются в данной работе. Далее при рассмотрении итоговой модели трендовой стратегии используется только кластеризация на 4 кластера с помощью DBSCAN.

Дополнительно были рассмотрены разовые крупные сделки, совершаемые т.н. китами. Подобные сделки обычно совершаются в разворотных областях рынка, они могут влиять на глобальные тренды, поэтому их учет является важным в задаче прогнозирования точек разворота трендов. Рассматривались

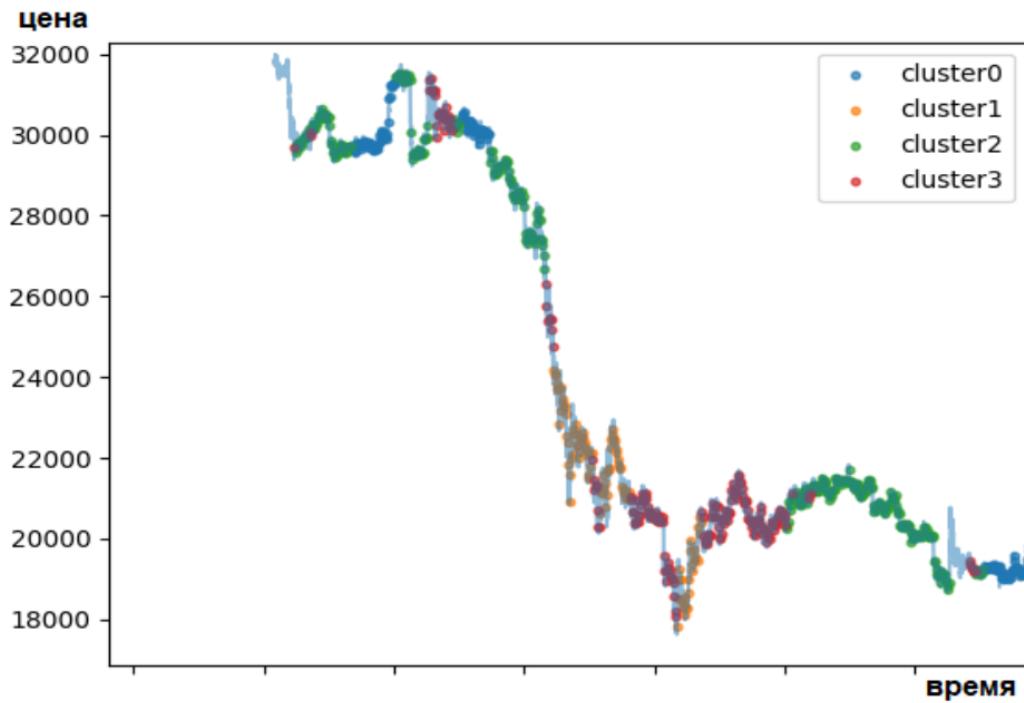


Рисунок 3.4 — Кластеризация серии сделок на 4 кластера методом DBSCAN.

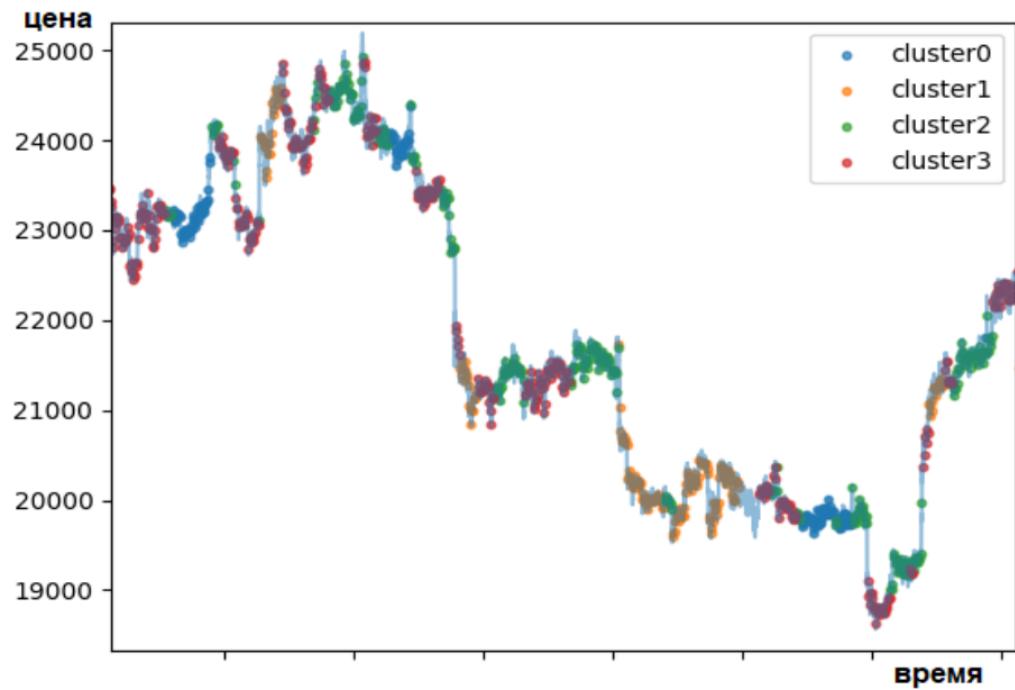


Рисунок 3.5 — Кластеризация серии сделок на 4 кластера методом DBSCAN.

сделки на суммы от 100000 USDT, совершаемые на круглых значениях цены, т.е. кратных 1000 USDT. На рисунке 3.8 приведен результат выявления подобных сделок с наложением на график BTCUSDT. Горизонтальными отрезками обозначены подобные сделки. Легко заметить, что многие из перечисленных

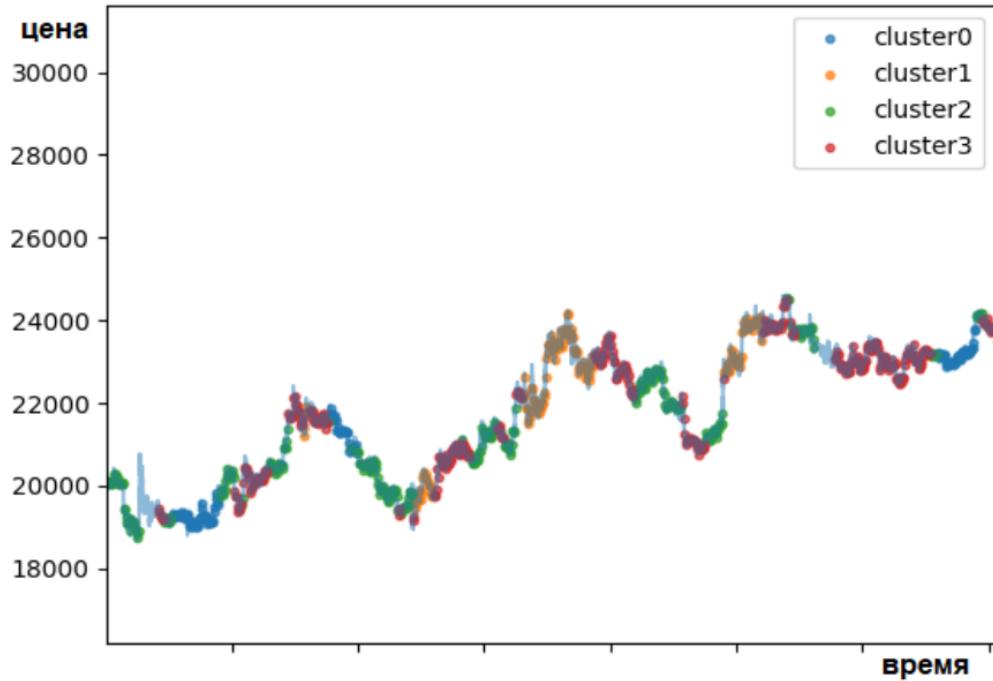


Рисунок 3.6 — Кластеризация серий сделок на 4 кластера методом DBSCAN.



Рисунок 3.7 — Кластеризация серий сделок на 3 кластера методом BIRCH.

сделок приходятся на локальные экстремумы в областях разворота глобальных трендов. Данные сделки также были закодированы во входном векторе модели методом OHE.

Подобное исследование ленты сделок было проведено для 56 активов криптовалютного рынка. Далее в работе будет демонстрироваться итоговая версия стратегии для торговой пары ETHUSDT в часовом таймфрейме.

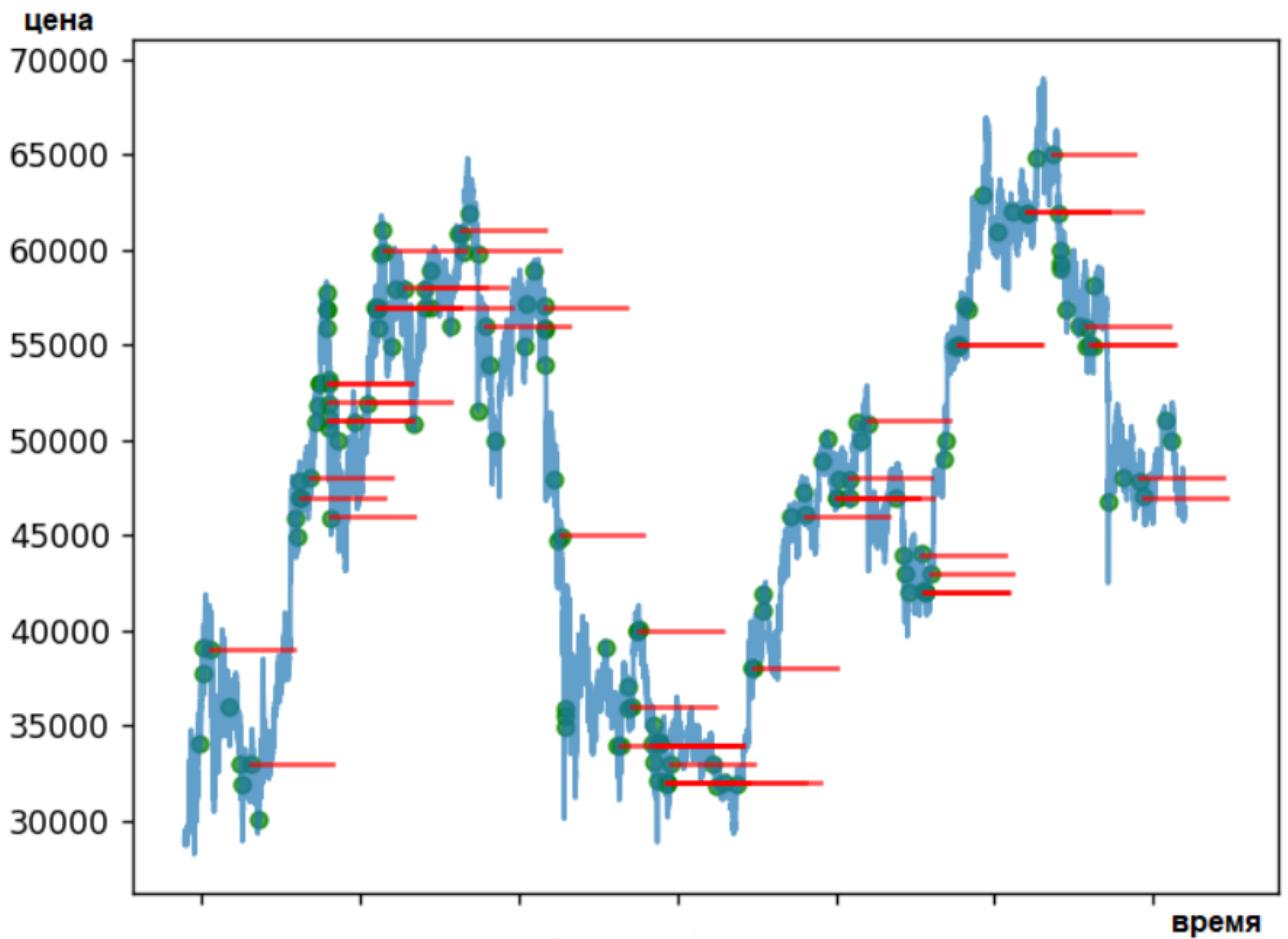


Рисунок 3.8 — Разметка крупных сделок на BTCUSDT со спота Binance.

3.2 Фильтрация сигналов алгоритмической стратегии

В главе 2 были представлены 2 модели машинного обучения. Первая была обучена на размеченной выборке для решения задачи тернарной классификации, вторая была обучена с подкреплением для прогнозирования награды за следующее действие. Использование расширенного MFTS, дополненного вторичными признаками на основе ленты сделок, является не единственным улучшением итоговой модели. Был кардинально пересмотрен подход использования моделей машинного обучения в задачах прогнозирования MFTS [178]. За основу была взята жесткая алгоритмическая трендовая стратегия, сигналы которой в режиме бинарной классификации фильтровались моделью [166; 179; 180]. Ниже представлено математическое описание базовой алгоритмической стратегии:

$$EMA_t(n, m) = \alpha \cdot P_{t-m} + (1 - \alpha) \cdot EMA_{t-m-1}, \alpha = \frac{2}{1+n} \quad (3.1)$$

$$BBW_t(k) = \sqrt{\frac{\sum_{i=t-k+1}^t (P_i - SMA_t(k))^2}{k}}, SMA_t(k) = \frac{\sum_{i=t-k+1}^t P_i}{k} \quad (3.2)$$

$$(P_t - EMA_t(n, m)) * (P_{t-1} - EMA_{t-1}(n, m)) < 0 \Rightarrow N \quad (3.3)$$

$$P_t > EMA_t(n, m), P_{t-1} < EMA_{t-1}(n, m), BBW_t(k) < T \Rightarrow L \quad (3.4)$$

$$P_t < EMA_t(n, m), P_{t-1} > EMA_{t-1}(n, m), BBW_t(k) < T \Rightarrow S \quad (3.5)$$

Здесь обозначено, что основой стратегии служит индикатор ЕМА. Сигнал на покупку поступает при пересечении графиком цены линии ЕМА снизу вверх. Сигнал на продажу поступает при пересечении графиком цены линии ЕМА сверху вниз. При поступлении нового сигнала предыдущая позиция другого типа закрывается. При этом сигналы на первом этапе фильтруются по волатильности, определяемой как ширина между линиями Боллинджера BBW [181]. Если волатильность превышает пороговое значение T сигнал игнорируется. Оптимальные значения $k = 60$ и $T = 0.3$ для часового таймфрейма. Данная стратегия является доходной в базовом варианте при оптимально подобранных параметрах, однако ее можно существенно улучшить при добавлении вторичной фильтрации посредством модели машинного обучения.

Оптимальные значения параметров n и m были определены в результате решения двупараметрической задачи оптимизации на двумерной сетке и составили $n = 3, m = 16$ [182]. На рисунке 3.9 приведена тепловая карта, отражающая решение оптимизационной задачи. Рассматриваемый актив - ETHUSDT на споте Binance. Светлые клетки означают положительную доходность стратегии на тестовом периоде за 2023 год. Темные клетки сигнализируют об отрицательной доходности и неудачных комбинациях параметров. По сути вся тепловая карта дает положительную доходность при любых параметрах. Это говорит о том, что трендовые стратегии применимы для работы с торговой парой ETHUSDT.

ETH является стабильным активом с адекватными трендовыми движениями. Обозначенные выше параметры k и T не перебирались, а использовались фиксированные, т.к. это приводило бы к переобучению модели.

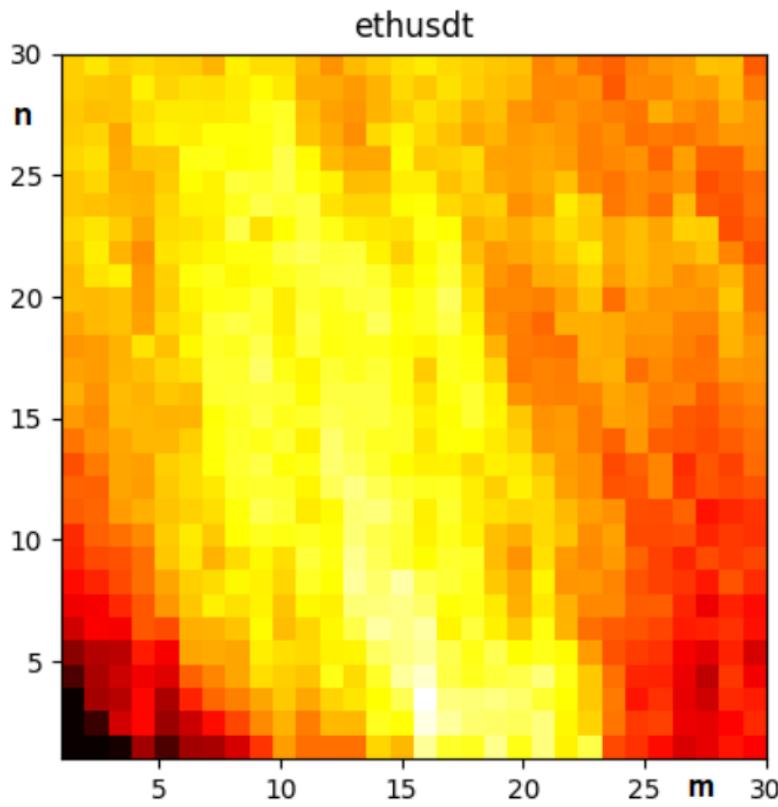


Рисунок 3.9 — Тепловая карта перебора параметров n и m для ETHUSDT.

Для сравнения можно рассмотреть торговую пару DOGEUSDT, на которой трендовые стратегии работают плохо по причине нестабильного поведения. Монета DOGE подвержена частым пампам за счет манипуляций в социальных сетях и обладает гораздо меньшей капитализацией, чем BTC или ETH. Это подтверждается тепловой картой, приведенной на рисунке 3.10.

Далее поверх жесткой алгоритмической стратегии была надстроена модель, обученная методом с подкреплением, описанным в главе 2. За основу была взята та же архитектура, дополненная некоторыми компонентами для обслуживания вторичных признаков, построенных на основе ленты сделок. На рисунке 3.11 представлена архитектура финальной модели. Она содержит примерно 25 млн параметров. Модель была дополнена новыми LSTM слоями в режиме разветвления, предназначенными для обработки информации по сериям сделок и крупным сделкам. Используется модуль автокодировщика для уменьшения размерности вектора, описывающего серии сделок. Модель обучена с подкреплением для решения задачи бинарной классификации, пропускать или

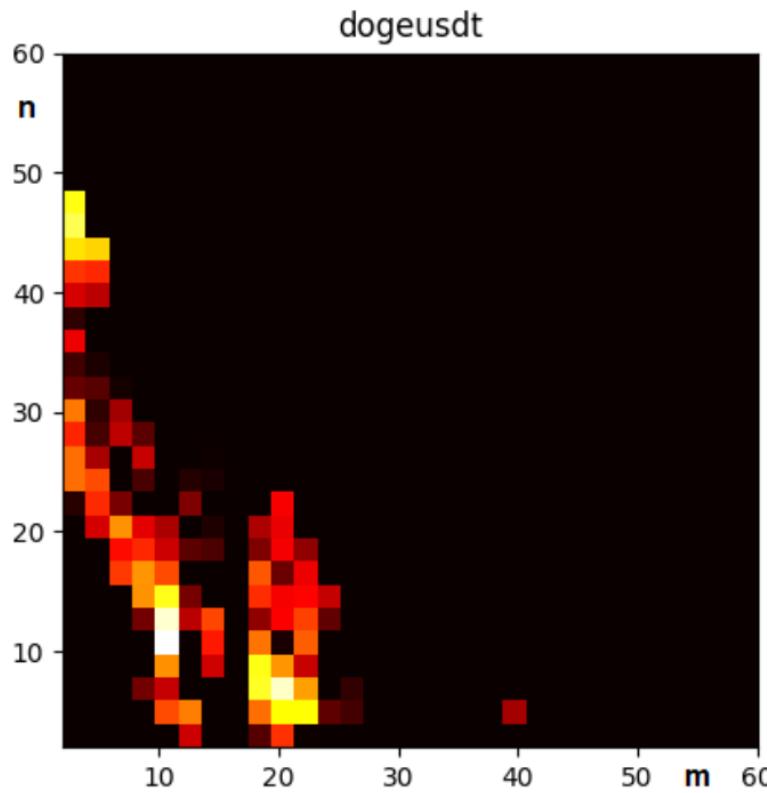


Рисунок 3.10 — Тепловая карта перебора параметров n и m для DOGEUSDT.

нет сигнал от жесткой алгоритмической стратегии. Результаты бэктестирования обученной модели третьей версии приведены в следующем разделе.

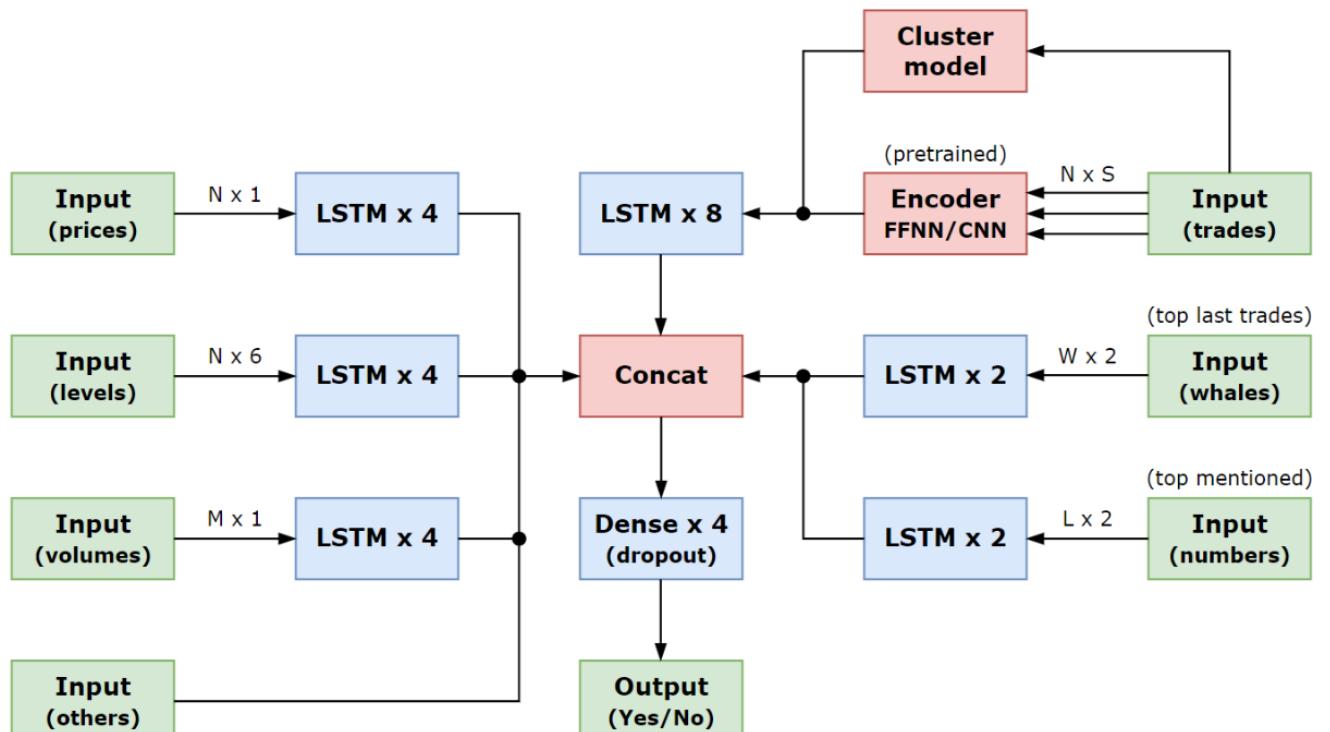


Рисунок 3.11 — Архитектура нейронной сети модели третьей версии.

3.3 Результаты бэктестирования итоговой стратегии

В главе 1 был описан подход бэктестирования стратегий собственным модулем. В данной главе представлены результаты тестирования третьей версии стратегии Intersector. На рисунке 3.12 представлены основные показатели тестирования. Модель обучалась на данных за 2 года - 2020 и 2021 в часовом таймфрейме. 2022 и 2023 года использовались для чистого тестирования. В данном случае результаты приведены для актива ETHUSDT, аналогичные результаты были получены и для 55 других торговых пар, из которых по итогу был составлен портфель, однако эта часть выходит за рамки данной работы. Стратегия тестировалась без реинвестирования прибыли, с фиксированным стоп-лоссом, без тейк-профита, с полными комиссиями биржи и брокера. Обслуживание позиций не приводило к проскальзыванию, т.к. капиталоемкость стратегии ограничена 10 млн USDT. Стратегия показала доходность примерно 289% за 2 тестовых года, коэффициент Шарпа составил 0.97, коэффициент Сортино составил 16.76. Этого достаточно для запуска решения как полноценной активной инвестиционной свинг-стратегии на реальном счете.

Backtesting asset	ETH/USDT	Backtest interval	2019 - 2023	Trading fee rate	0.04 %
Initial investments	1000.00	Strategy version	Intersector 3.1	Trailing stop-loss	4% fixed
Benchmark profit	16705.38	Strategy profit	6083.28	Trailing take-profit	disabled
Has reinvestment	False	Strategy timeframe	1h	Trailing timeframe	5m
Longs quantity	708	Shorts quantity	442	Trades quantity	1150
Longs with profit	229	Shorts with profit	144	Trades with profit	373
Longs with loss	479	Shorts with loss	298	Trades with loss	777
Longs total profit	7694.06	Shorts total profit	4862.17	Trades total profit	12556.23
Longs total loss	3995.47	Shorts total loss	2477.47	Trades total loss	6472.94
Long average profit	33.60	Short average profit	33.77	Trade average profit	33.66
Long average loss	8.34	Short average loss	8.31	Trade average loss	8.33
Long minimum hold	0.33 hours	Short minimum hold	1.00 hours	Trade minimum hold	0.33 hours
Long median hold	6.00 hours	Short median hold	6.00 hours	Trade median hold	6.00 hours
Long maximum hold	76.00 hours	Short maximum hold	110.00 hours	Trade maximum hold	110.00 hours
Sharpe coefficient	0.97	Sortino coefficient	16.76	Kalmar coefficient	undefined

	Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.	Annual
2019													
2020	+7.34	+32.99	+36.22	+19.74	+2.18	-4.21	+13.71	+25.19	+2.95	+3.69	+19.16	+5.33	+164.30
2021	-6.50	+41.10	+1.26	+20.83	+20.12	+20.69	+1.45	+4.89	+27.18	-2.23	+15.25	+9.83	+153.87
2022	+40.11	+31.99	+5.60	+16.71	+11.92	+31.45	+21.22	+18.44	-3.20	+8.49	+29.07	-2.39	+209.41
2023	+9.35	+27.88	+22.72	+19.27	+0.85	-0.44	+0.12	-4.06	-5.35	-2.08	+8.64	+3.86	+80.75

Рисунок 3.12 — Результаты бэктестирования стратегии Intersector 3.1.

На рисунке 3.13 представлено наложение графика доходности стратегии и бенчмарка купи и держи. Видно, что стратегия существенно превосходит бенчмарк, как в плане доходности, так и в плане размера просадок. Стоит отметить, что на второй половине 2023 года заметно снижение доходности стратегии. Это обусловлено изменением расстановки сил на рынке в связи с одобрением спотовых BTC-ETF. Новые крупные игроки привнесли на рынок дополнительные серии сделок, которые необходимо учитывать в моделях. В настоящее время полученная модель работает как один из инвестиционных продуктов в ООО «Интеллектуальные Системы Управления».



Рисунок 3.13 — Наложение результатов стратегии Intersector на бенчмарк.

3.4 Выводы к третьей главе

Дополнительные признаки многомерных временных рядов финансовых рынков получены на основе ленты сделок с криптовалютных бирж. В частности, выявлены серии сделок, совершаемые крупными инвестиционными и хедж фондами, практикующими стратегии межбиржевого арбитража и маркет-мейкинга. Отмечено, что подобная информация позволяет косвенно учитывать осведомленность фондов о ситуации на рынках. Для серий сделок решена задача кластеризации методами DBSCAN и BIRCH, показано, что оптимальным является разбиение всех серий на 4 кластера, соответствующих разным фазам рынка. Также входные вектора дополнены информацией о разовых крупных сделках на круглых значениях цены базового актива. Подобные сделки характерны для разворотных стадий рынка. Показано, что применение моделей машинного обучения позволяет достичь более высоких результатов в терминах доходности и других финансовых показателей, если они используются в качестве фильтра сигналов исходной алгоритмической стратегии, построенной на классических индикаторах или осцилляторах технического анализа, таких как экспоненциально сглаженные скользящие средние, полосы Боллинджера, индексы относительной силы и другие сглаживающие инструменты. Предложен двухэтапный метод оптимизации гибридной стратегии, в рамках которого на первом этапе решается задача многокритериальной оптимизации для поиска наиболее стабильных параметров алгоритмической стратегии, а на втором этапе выполняется обучение с подкреплением DQN модели машинного обучения на данных многомерных временных рядов, дополненных сигналами исходной жесткой алгоритмической стратегии. В соответствии с полученными финансовыми показателями решение может быть применено для реальной работы на финансовых рынках. Перспективным направлением развития предложенного решения является дополнение многомерных временных рядов новыми вторичными признаками, например, признаками, построенными по публикациям из социальных сетей.

Заключение

Основные результаты работы заключаются в следующем.

1. Показано, что применение моделей машинного обучения позволяет достичь более высоких результатов в терминах доходности и других финансовых показателей, если они используются в качестве фильтра сигналов исходной алгоритмической стратегии, построенной на классических индикаторах или осцилляторах технического анализа, таких как экспоненциально сглаженные скользящие средние, полосы Боллинджера или индексы относительной силы.

2. Предложен двухэтапный метод оптимизации гибридной стратегии, в рамках которого на первом этапе решается задача многокритериальной оптимизации для поиска наиболее стабильных параметров алгоритмической стратегии, а на втором этапе выполняется обучение с подкреплением DQN модели на данных MFTS, дополненных сигналами исходной алгоритмической стратегии.

3. Построены дополнительные вторичные признаки MFTS для криптовалютного рынка, а именно апериодические признаки на основе биржевой ленты сделок и публикаций и сообщений социальных сетей. Предложена гибридная модель MFTS, сочетающая в себе данные различных типов из нескольких источников.

Таким образом в рамках данной работы были разработаны методы решения задач прогнозирования точек разворота на многомерных временных рядах финансовых рынков на основе моделей машинного обучения с подкреплением. В качестве результата данной работы предложена обученная и протестированная модель, являющаяся ядром полнофункциональной автоматизированной торговой системы.

Список литературы

1. GitHub: стратегия: сайт. — URL: <https://github.com/i-s-m-mipt/Strategy>.
2. GitHub: результаты: сайт. — URL: <https://github.com/i-s-m-mipt/Research>.
3. Инвестиционный фонд Long Lakes: сайт. — URL: <https://long-lakes.com>.
4. Makarov I., Kovaleva M., Zinkovich V., Kolovertnova V. Research of Financial Time-series Statistical Properties // *International Conference Engineering and Telecommunication*. — 2021. — P. 4.
5. Makarov I., Kovaleva M., Pankovets E., Konstantinov D. A Deep Neural Network Architecture for Solving Classification Problems on Multidimensional Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 6.
6. Konstantinov D., Pankovets E., Makarov I., Gorbachev R. Development and Research of a Deep Neural Network Architecture for Solving Regression Problems on Multidimensional Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 4.
7. Makarov I., Kovaleva M., Fakhrutdinov T., Gorbachev R. Intelligent Module for System Trading of Financial Markets Assets Based on an Ensemble of Deep Neural Networks and the DQN Learning Algorithm // *International Conference Engineering and Telecommunication*. — 2021. — P. 7.
8. Makarov I., Fakhrutdinov T., Kichik, M., Mamontov K., Baskov O., Shumsky S. Forecasting in Financial Markets Using the ADAM Architecture and Reinforcement Learning Methods // *International Conference Engineering and Telecommunication*. — 2021. — P. 7.
9. Makarov I., Kovaleva M., Zakharova E., Gorbachev R. Applicability of the kNN Algorithm in the Problem of Pattern Classification on Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 5.

10. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Zakharova E. Development of and research into a rigid algorithm for analyzing Twitter publications and its influence on the movements of the cryptocurrency market // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 157–170.
11. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Gorbachev R. Development of and research on an algorithm for distinguishing features in Twitter publications for a classification problem with known markup // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 171–183.
12. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Gorbachev R. Development of and research on machine learning algorithms for solving the classification problem in Twitter publications // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 185–195.
13. Esenkov A., Zakharova E., Kovaleva M., Konstantinov D., Makarov I., Pankovets E. Research and application of deep neural network architectures for classification on multidimensional time series // *Journal of Computer and Systems Sciences International*. — 2022. — Vol. 61, no. 4. — Pp. 616–625.
14. Мерфи Д. Технический анализ фьючерсных рынков: Теория и практика: монография. — М.: Альпина Паблишер, 2024. — С. 610.
15. Швагер Д. Технический анализ. Полный курс: монография. — М.: Альпина Паблишер, 2022. — С. 804.
16. Колби Р. Энциклопедия технических индикаторов рынка. — М.: Альпина Паблишер, 2017. — С. 837.
17. Lin Xiaowei, Yang Zehong, Song Yixu. Intelligent stock trading system based on improved technical analysis and Echo State Network // *Expert systems with Applications*. — 2011. — Vol. 38, no. 9. — Pp. 11347–11354.
18. Pramudya Rommy, Ichsan Sakina. Efficiency of technical analysis for the stock trading // *International Journal of Finance & Banking Studies*. — 2020. — Vol. 9, no. 1. — Pp. 58–67.
19. Trading system based on the use of technical analysis: A computational experiment / Thiago Raymon Cruz Cacique da Costa, Rodolfo Toríbio Nazário,

Gabriel Soares Zica Bergo et al. // *Journal of Behavioral and Experimental Finance*. — 2015. — Vol. 6. — Pp. 42–55.

20. *Dash Rajashree, Dash Pradipta Kishore*. A hybrid stock trading framework integrating technical analysis with machine learning techniques // *The Journal of Finance and Data Science*. — 2016. — Vol. 2, no. 1. — Pp. 42–57.
21. *Wang Jar-Long, Chan Shu-Hui*. Stock market trading rule discovery using pattern recognition and technical analysis // *Expert Systems with Applications*. — 2007. — Vol. 33, no. 2. — Pp. 304–315.
22. *Chavarnakul Thira, Enke David*. Intelligent technical analysis based equivolume charting for stock trading using neural networks // *Expert Systems with Applications*. — 2008. — Vol. 34, no. 2. — Pp. 1004–1017.
23. Automated trading systems statistical and machine learning methods and hardware implementation: a survey / Boming Huang, Yuxiang Huan, Li Da Xu et al. // *Enterprise Information Systems*. — 2019. — Vol. 13, no. 1. — Pp. 132–144.
24. *Ritter Gordon*. Machine learning for trading // Available at SSRN 3015609. — 2017.
25. *Lu Ning*. A machine learning approach to automated trading // *Boston, MA, USA: Boston College Computer Science Senior*. — 2016. — Vol. 7. — Pp. 171–180.
26. An empirical study of machine learning algorithms for stock daily trading strategy / Dongdong Lv, Shuhan Yuan, Meizi Li, Yang Xiang // *Mathematical problems in engineering*. — 2019. — Vol. 2019, no. 1. — P. 7816154.
27. Automated bitcoin trading via machine learning algorithms / Isaac Madan, Shaurya Saluja, Aoja Zhao et al. // URL: <http://cs229.stanford.edu/proj2014/Isaac%20Madan>. — 2015. — Vol. 20.
28. *Kearns Michael, Nevmyvaka Yuriy*. Machine learning for market microstructure and high frequency trading // *High Frequency Trading: New Realities for Traders, Markets, and Regulators*. — 2013.

29. *O'hara Maureen*. High frequency market microstructure // *Journal of financial economics*. — 2015. — Vol. 116, no. 2. — Pp. 257–270.
30. High-frequency exchange-rate prediction with an artificial neural network / Taufiq Choudhry, Frank McGroarty, Ke Peng, Shiyun Wang // *Intelligent Systems in Accounting, Finance and Management*. — 2012. — Vol. 19, no. 3. — Pp. 170–178.
31. *Aldridge Irene*. High-frequency trading: a practical guide to algorithmic strategies and trading systems. — John Wiley & Sons, 2013. — Vol. 604.
32. A Q-learning agent for automated trading in equity stock markets / Jagdish Bhagwan Chakole, Mugdha S Kolhe, Grishma D Mahapurush et al. // *Expert Systems with Applications*. — 2021. — Vol. 163. — P. 113761.
33. *Akyildirim Erdinc, Goncu Ahmet, Sensoy Ahmet*. Prediction of cryptocurrency returns using machine learning // *Annals of Operations Research*. — 2021. — Vol. 297. — Pp. 3–36.
34. Forecasting Bitcoin closing price series using linear regression and neural networks models / Nicola Uras, Lodovica Marchesi, Michele Marchesi, Roberto Tonelli // *PeerJ Computer Science*. — 2020. — Vol. 6. — P. e279.
35. *Borges Tome Almeida, Neves Rui Ferreira*. Ensemble of machine learning algorithms for cryptocurrency investment with different data resampling methods // *Applied Soft Computing*. — 2020. — Vol. 90. — P. 106187.
36. *Sun Shaolong, Wang Shouyang, Wei Yunjie*. A new ensemble deep learning approach for exchange rates forecasting and trading // *Advanced Engineering Informatics*. — 2020. — Vol. 46. — P. 101160.
37. *Jothimani Dhanya, Yadav Surendra S*. Stock trading decisions using ensemble-based forecasting models: a study of the Indian stock market // *Journal of Banking and Financial Technology*. — 2019. — Vol. 3, no. 2. — Pp. 113–129.
38. *Moody John, Saffell Matthew*. Reinforcement learning for trading // *Advances in Neural Information Processing Systems*. — 1998. — Vol. 11.

39. *Zhang Zihao, Zohren Stefan, Roberts Stephen.* Deep reinforcement learning for trading // *arXiv preprint arXiv:1911.10107*. — 2019.
40. *Carapuço João, Neves Rui, Horta Nuno.* Reinforcement learning applied to Forex trading // *Applied Soft Computing*. — 2018. — Vol. 73. — Pp. 783–794.
41. *Théate Thibaut, Ernst Damien.* An application of deep reinforcement learning to algorithmic trading // *Expert Systems with Applications*. — 2021. — Vol. 173. — P. 114632.
42. *Jeong Gyeeun, Kim Ha Young.* Improving financial trading decisions using deep Q-learning: Predicting the number of shares, action strategies, and transfer learning // *Expert Systems with Applications*. — 2019. — Vol. 117. — Pp. 125–138.
43. *Pricope Tidor-Vlad.* Deep reinforcement learning in quantitative algorithmic trading: A review // *arXiv preprint arXiv:2106.00123*. — 2021.
44. Decision-making for financial trading: A fusion approach of machine learning and portfolio selection / Felipe Dias Paiva, Rodrigo Tomás Nogueira Cardoso, Gustavo Peixoto Hanaoka, Wendel Moreira Duarte // *Expert Systems with Applications*. — 2019. — Vol. 115. — Pp. 635–655.
45. Machine learning for financial risk management: a survey / Akib Mashrur, Wei Luo, Nayyar A Zaidi, Antonio Robles-Kelly // *Ieee Access*. — 2020. — Vol. 8. — Pp. 203203–203223.
46. Сервис TradingView: сайт. — URL: <https://ru.tradingview.com>.
47. Мерфи Д. Межрыночный анализ: монография. — М.: Альпина Паблишер, 2022. — С. 300.
48. Сорос Д. Алхимия финансов: монография. — М.: Диалектика, 2015. — С. 352.
49. Уильямс Л. Секреты торговли на фьючерсном рынке. Действуйте вместе с инсайдерами: монография. — М.: Альпина PRO, 2022. — С. 232.
50. LeBeau C., Lucas D. W. Computer analysis of the futures market. — McGraw-Hill, 1992.

51. Фишер Ф. Обыкновенные акции и необыкновенные доходы: монография. — М.: Альпина Паблишер, 2003. — С. 384.
52. Грэхем Б., Додд Д. Анализ ценных бумаг: монография. — М.: Диалектика-Вильямс, 2011. — С. 880.
53. Чиркова Е. Как оценить бизнес по аналогии: монография. — М.: Альпина Диджитал, 2017. — С. 326.
54. Smart-Lab: график выплаты дивидендов российских компаний, входящих в индекс Московской биржи: сайт. — URL: <https://smart-lab.ru/dividends>.
55. Московская биржа: расписание торговых сессий для валютной, товарной и фондовой секций биржи: сайт. — URL: <https://www.moex.com/s116>.
56. Рашке Л. Биржевые секреты. — М.: ИК "Аналитика 2002. — С. 275.
57. Грэм Б. Разумный инвестор. Полное руководство по стоимостному инвестированию: монография. — М.: Альпина Паблишер, 2020. — С. 568.
58. Ливермор Д. Торговля акциями. Классическая формула тайминга, управления капиталом и эмоциями: монография. — СПб.: Питер, 2009. — С. 272.
59. TradingView: актуальная справочная информация по биржевому индексу SPX: сайт. — URL: <https://ru.tradingview.com/symbols/SPX>.
60. TradingView: актуальная справочная информация по биржевому индексу NDX: сайт. — URL: <https://ru.tradingview.com/symbols/NASDAQ-NDX>.
61. TradingView: актуальная справочная информация по биржевому индексу DJIA: сайт. — URL: <https://ru.tradingview.com/symbols/DJI>.
62. Нью-Йоркская биржа: сайт. — URL: <https://www.nyse.com>.
63. TradingView: актуальная справочная информация по биржевому индексу US2000: сайт. — URL: <https://www.tradingview.com/symbols/FX-US2000>.
64. Московская биржа: сайт. — URL: <https://www.moex.com>.
65. Санкт-Петербургская биржа: сайт. — URL: <https://spbexchange.ru>.

66. Московская биржа: основная справочная информация по биржевым индексам MOEX: сайт. — URL: <https://www.moex.com/ru/index/RTSI>.
67. TradingView: актуальная справочная информация по биржевому индексу IMOEX: сайт. — URL: <https://ru.tradingview.com/symbols/MOEX-IMOEX>.
68. TradingView: актуальная справочная информация по биржевому индексу RTSI: сайт. — URL: <https://ru.tradingview.com/symbols/MOEX-RTSI>.
69. Smart-Lab: перечень российских компаний, входящих в индекс Московской биржи: сайт. — URL: https://smart-lab.ru/q/index_stocks/IMOEX.
70. Сканер сети Bitcoin: сайт. — URL: <https://bitinfocharts.com/bitcoin>.
71. Сканер сети Etherium: сайт. — URL: <https://etherscan.io>.
72. Сервис CoinMarketCap: сайт. — URL: <https://coinmarketcap.com>.
73. TradingView: актуальная справочная информация по криптовалютному активу BTC: сайт. — URL: <https://coinmarketcap.com/currencies/bitcoin>.
74. TradingView: актуальная справочная информация по криптовалютному активу ETH: сайт. — URL: <https://coinmarketcap.com/currencies/ethereum>.
75. TradingView: актуальная справочная информация по криптовалютному активу LTC: сайт. — URL: <https://coinmarketcap.com/currencies/litecoin>.
76. TradingView: актуальная справочная информация по криптовалютному активу XRP: сайт. — URL: <https://coinmarketcap.com/currencies/ripple>.
77. Комиссия по ценным бумагам США: сайт. — URL: <https://www.sec.gov>.
78. Талеб Н. Одурченные случайностью. О скрытой роли шанса в бизнесе и в жизни: монография. — М.: Махаон, 2024. — С. 400.
79. Льюис М. Покер лжецов: монография. — М.: Олимп-Бизнес, 2022. — С. 368.
80. Блокчейн Bitcoin: сайт. — URL: <https://bitcoin.org/bitcoin.pdf>.
81. Биржа Uniswap: сайт. — URL: <https://app.uniswap.org>.

82. Биржа PancakeSwap: сайт. — URL: <https://pancakeswap.finance>.
83. Биржа dYdX: сайт. — URL: <https://trade.dydx.exchange>.
84. Биржа Binance: сайт. — URL: <https://www.binance.com>.
85. Биржа Bybit: сайт. — URL: <https://www.bybit.com>.
86. Биржа Gate: сайт. — URL: <https://www.gate.io>.
87. GitHub: библиотека CCXT: сайт. — URL: <https://github.com/ccxt/ccxt>.
88. CoinMarketCap: актуальная справочная информация по криптовалютному активу USDT: сайт. — URL: <https://coinmarketcap.com/currencies/tether>.
89. Компания Tether: сайт. — URL: <https://tether.to>.
90. CoinMarketCap: актуальная справочная информация по криптовалютному активу USDC: сайт. — URL: <https://coinmarketcap.com/currencies/usd-coin>.
91. Компания Circle: сайт. — URL: <https://www.circle.com>.
92. Блокчейн Ethereum: сайт. — URL: <https://ethereum.org>.
93. Блокчейн Solana: сайт. — URL: <https://solana.com>.
94. Блокчейн Tron: сайт. — URL: <https://tron.network>.
95. CoinMarketCap: актуальная справочная информация по криптовалютному активу USTC: сайт. — URL: <https://coinmarketcap.com/currencies/terrausd>.
96. Компания Terra: сайт. — URL: <https://www.terra.money>.
97. Чан Э. Алгоритмическая торговля. — 2008. — С. 182.
98. Ghosh S. Building Low Latency Applications with C++. — Packt Publishing, 2023. — Р. 506.
99. Silahian A. C++ High Performance for Financial Systems. — Packt Publishing, 2024. — Р. 314.
100. Donadio S. Developing High-Frequency Trading Systems. — Packt Publishing, 2022. — Р. 320.

101. Малыхин Е. Алгоритмический трейдинг для профессионалов. — сБХВ-Петербург, 2021. — С. 176.
102. Льюис М. Flash Boys. Высокочастотная революция на Уолл-стрит. — М.: Альпина Паблишер, 2021. — С. 348.
103. Цукерман Г. Человек, который разгадал рынок. — М.: Эксмо, 2021. — С. 400.
104. Торп Э. Человек на все рынки: из Лас-Вегаса на Уолл-стрит. Как я обыграл дилера и рынок. — СПб.: КоЛибри, 2019. — С. 560.
105. Паттерсон С. Кванты. — М.: Манн, Иванов и Фербер, 2014. — С. 362.
106. Компания Arqatech: сайт. — URL: <https://arqatech.com>.
107. Пейтэл Э. Internet-трейдинг. Полное руководство. — М.: Вильямс, 2003. — С. 320.
108. GitHub: коннектор: сайт. — URL: <https://github.com/i-s-m-mipt/Terminal>.
109. Библиотека Tensorflow: сайт. — URL: <https://www.tensorflow.org>.
110. Язык программирования LUA: сайт. — URL: <https://www.lua.org>.
111. Библиотека DLL: сайт. — URL: <https://github.com/boostorg/dll>.
112. Машнин Т. Продвинутое использование торговой платформы MetaTrader 5. Создание индикаторов и торговых роботов на MQL5 и Python. — М.: Литрес, 2022. — С. 404.
113. Чиркова Е. АнATOMия финансового пузыря: монография. — М.: Кейс, 2010. — С. 416.
114. Нисон С. Японские свечи. Графический анализ финансовых рынков. — М.: Альпина Паблишер, 2016. — С. 427.
115. Нисон С. За гранью японских свечей. — М.: Альпина Паблишер, 2020. — С. 373.
116. Баффет У. Эссе об инвестициях, корпоративных финансах и управлении компаниями: монография. — М.: Альпина Бизнес Букс, 2006. — С. 268.

117. Хагстром Р. Уоррен Баффет. Как 5 долларов превратить в 50 миллиардов. Простые правила великого инвестора: монография. — М.: Эксмо, 2010. — С. 304.
118. Guilbaud F., Pham H. Optimal high-frequency trading with limit and market orders // *Quantitative Finance*. — 2013. — Vol. 13, no. 1. — Pp. 79–94.
119. T. Herold, Financial Terms Dictionary - Terminology Plain and Simple Explained. — Independently published, 2017.
120. Тарп В. Трейдинг - ваш путь к финансовой свободе. — СПб.: Питер, 2007. — С. 368.
121. Вильямса Л. Долгосрочные секреты краткосрочной торговли. — И.: ITinvest, 2014. — С. 513.
122. Кан М. Технический анализ. Просто и ясно. — СПб.: Питер, 2006. — С. 380.
123. Якимкин В. Финансовый дилинг. Технический анализ. — М.: Омега-Л, 2005. — С. 480.
124. Акелис С. Технический анализ от А до Я. — М.: Диаграмма, 2010. — С. 376.
125. Мэрфи Д. Визуальный инвестор. Как выявлять рыночные тренды. — М.: Альпина Паблишер, 2012. — С. 309.
126. Ковел М. Черепахи-трейдеры. Легендарная история, ее уроки и результаты: монография. — СПб.: Питер, 2011. — С. 304.
127. Бенсигнор Р. Новое мышление в техническом анализе. — М. : [б. и.], 2002. — С. 304.
128. Демарк Т. Технический анализ – новая наука. — М.: Диаграмма, 2008. — С. 288.
129. Дамодаран А. Инвестиционные байки. Разоблачение мифов о беспрогрызных биржевых стратегиях: монография. — СПб.: Питер, 2007. — С. 480.

130. ДиНаполи Д. Торговля с использованием уровней ДиНаполи. — М.: ИК "Аналитика 2001. — С. 312.
131. Фишер Р. Новые методы торговли по Фибоначчи. — М.: ИК "Аналитика 2002. — С. 244.
132. Хъержик Д. Модель, цена, время. Применение Теории Ганна в системах торговли. — М.: ИК "Аналитика 2000. — С. 309.
133. Элдер А. Как играть и выигрывать на бирже. Психология. Технический анализ. Контроль над капиталом: монография. — М.: Альпина Паблишер, 2021. — С. 582.
134. Булковский Т. Полная энциклопедия графических ценовых моделей. — Дивиденд, 810. — С. 2022.
135. Сервис QuantConnect: сайт. — URL: <https://www.quantconnect.com>.
136. Пардо Р. Разработка, тестирование, оптимизация торговых систем для биржевого трейдера. — М.: Минакс, 2002. — С. 224.
137. Шарп У., Александер Г., Бейли Д. Инвестиции: монография. — М.: Инфра-М, 2022. — С. 1028.
138. Бригхэм Ю., Эрхардт М. Финансовый менеджмент: монография. — СПб.: Питер, 2005. — С. 959.
139. Баумоль Б. Секреты экономических показателей: монография. — Киев: Баланс Бизнес Букс, 2007. — С. 352.
140. Фарлей А. Мастерство свинг-трейдинга. — М.: Евро, 2008. — С. 700.
141. Tsay R. Analysis of financial time series. — John wiley & sons, 2005.
142. Eason G., Noble B., Sneddon I. On certain integrals of Lipschitz-Hankel type involving products of Bessel functions // *Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences*. — 1955. — Vol. 247, no. 935. — Pp. 529–551.
143. Финам: экспорт котировок с Московской биржи: сайт. — URL: <https://www.finam.ru/quote/moex/imoex/export/>.

144. Библиотека requests: сайт. — URL: <https://requests.readthedocs.io/en/latest/index.html>.
145. Библиотека urllib: сайт. — URL: <https://docs.python.org/3/library/urllib.html>.
146. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors // *nature*. — 1986. — Vol. 323, no. 6088. — Pp. 533–536.
147. Teamah A. E. M. A., El-Hadidy M. A., El-Ghoul M. M. The truncated distribution of the range for a Wiener process: Application to the stock price // *Delta Journal of Science*. — 2016. — Vol. 37, no. 1. — Pp. 21–40.
148. Senin P. Dynamic time warping algorithm review // *Information and Computer Science Department University of Hawaii at Manoa Honolulu, USA*. — 2008. — Vol. 855, no. 1-23. — P. 40.
149. Cassisi C., Montalto P., Aliotta M., Pulvirenti A. Similarity measures and dimensionality reduction techniques for time series data mining // *Advances in data mining knowledge discovery and applications*. — 2012. — Pp. 71–96.
150. Rodgers J., Nicewander W.A., Thirteen Ways to Look at the Correlation Coefficient // *The American Statistician*. — 1988. — Vol. 42. — Pp. 59–66.
151. Gregoriou G. N. Stock Market Volatility. — CRC Press, 2009. — P. 651.
152. Шиллер Р. Иррациональный оптимизм. Как безрассудное поведение управляет рынками: монография. — М.: Альпина PRO, 2022. — С. 421.
153. Льюис М. Игра на понижение. Тайные пружины финансовой катастрофы: монография. — М.: Альпина Паблишер, 2020. — С. 280.
154. Hiransha M., Gopalakrishnan E.A., Vijay K. M., Soman K.P. NSE Stock Market Prediction Using Deep-Learning Models // *Procedia Computer Science*. — 2018. — Vol. 132. — Pp. 1351–1362.
155. Ganesh P., Rakheja P. Vlstm: Very long short-term memory networks for high-frequency trading // *arXiv preprint arXiv:1809.01506*. — 2018.

156. Huynh H. D., Dang L. M., Duong D. A New Model for Stock Price Movements Prediction Using Deep Neural Network // Proceedings of the 8th International Symposium on Information and Communication Technology. — SoICT '17. — New York, NY, USA: Association for Computing Machinery, 2017. — P. 57–62.
157. Ghosh A. Comparative study of financial time series prediction by artificial neural network with gradient descent learning // *arXiv preprint arXiv:1111.4930*. — 2011.
158. Mokhtari S., Yen K. K., Liu J. Effectiveness of artificial intelligence in stock market prediction based on machine learning // *arXiv preprint arXiv:2107.01031*. — 2021.
159. Mehtab S., Sen J. Stock price prediction using CNN and LSTM-based deep learning models // 2020 International Conference on Decision Aid Sciences and Application (DASA) / IEEE. — 2020. — Pp. 447–453.
160. Heaton J. Applications of deep neural networks with keras // *arXiv preprint arXiv:2009.05673*. — 2020.
161. Parisi L., Ma R., RaviChandran N., Lanzillotta M. hyper-sinh: An accurate and reliable function from shallow to deep learning in TensorFlow and Keras // *Machine Learning with Applications*. — 2021. — Vol. 6. — Pp. 100–112.
162. Kingma D. P., Ba J. Adam: A method for stochastic optimization // *arXiv preprint arXiv:1412.6980*. — 2014.
163. Braun S. LSTM benchmarks for deep learning frameworks // *arXiv preprint arXiv:1806.01818*. — 2018.
164. Kong A., Zhu H., Azencott R. Predicting intraday jumps in stock prices using liquidity measures and technical indicators // *Journal of Forecasting*. — 2021. — Vol. 40, no. 3. — Pp. 416–438.
165. Libman D., Haber S., Schaps M. Volume prediction with neural networks // *Frontiers in Artificial Intelligence*. — 2019. — Vol. 2. — P. 21.
166. Hurwitz E., Marwala T. Suitability of using technical indicators as potential strategies within intelligent trading systems // *arXiv preprint arXiv:1110.3383*. — 2011.

167. Goodfellow I., Bengio Y., Courville A. Deep learning. — MIT press, 2016.
168. Piryonesi S. M., El-Diraby T. E. Role of data analytics in infrastructure asset management: Overcoming data size and quality problems // *Journal of Transportation Engineering, Part B: Pavements*. — 2020. — Vol. 146, no. 2. — P. 04020022.
169. Borovikov V. Borovikov V. STATISTICA. The art of data analysis on a computer: For professionals // *Sanct Peterburg*. — 2003.
170. Schrittwieser J. et al. Mastering atari, go, chess and shogi by planning with a learned model // *Nature*. — 2020. — Vol. 588, no. 7839. — Pp. 604–609.
171. Silver D. et al. A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play // *Science*. — 2018. — Vol. 362, no. 6419. — Pp. 1140–1144.
172. Sadler M., Regan N. Game changer // *AlphaZero's Groundbreaking Chess Strategies and the Promise of AI*. Alkmaar. The Netherlands. New in Chess. — 2019.
173. Briola A. et al. Deep reinforcement learning for active high frequency trading // *arXiv preprint arXiv:2101.07107*. — 2021.
174. Hirsa A. et al. Deep reinforcement learning on a multi-asset environment for trading // *arXiv preprint arXiv:2106.08437*. — 2021.
175. Gao Z. et al. Application of deep q-network in portfolio management // 2020 5th IEEE International Conference on Big Data Analytics (ICBDA) / IEEE. — 2020. — Pp. 268–275.
176. Fang B., Feng Y. Design of high-frequency trading algorithm based on machine learning // *arXiv preprint arXiv:1912.10343*. — 2019.
177. Chen K., Zhou Y., Dai F. A LSTM-based method for stock returns prediction: A case study of China stock market // 2015 IEEE international conference on big data (big data) / IEEE. — 2015. — Pp. 2823–2824.
178. Mehtab S., Sen J., Dutta A. Stock price prediction using machine learning and LSTM-based deep learning models // Machine Learning and Metaheuristics

Algorithms, and Applications: Second Symposium, SoMMA 2020, Chennai, India, October 14–17, 2020, Revised Selected Papers 2 / Springer. — 2021. — Pp. 88–106.

179. Вильямс Б. Новые измерения в биржевой торговле. — М.: ИК "Аналитика" 2000. — С. 288.
180. Silagadze Z. K. Moving Mini-Max-a new indicator for technical analysis // *arXiv preprint arXiv:0802.0984*. — 2008.
181. Боллинджер Д. Боллинджер о лентах Боллинджера. — М.: ИК "Аналитика" 2005. — С. 256.
182. Yu T., Zhu H. Hyper-parameter optimization: A review of algorithms and applications // *arXiv preprint arXiv:2003.05689*. — 2020.

Список рисунков

1.1	Рабочее пространство торгового терминала Quik 8.0.	25
1.2	Архитектура системы автоматической торговли для QUIK.	27
1.3	Свечной график стоимости BTCUSDT с биржи Binance.	30
1.4	Свечной график значений индекса Московской биржи.	30
1.5	Матрица корреляции стоимостей 30 основных криптовалют. . . .	33
1.6	Демонстрация индикаторов EMA и RSI на BTCUSDT.	38
1.7	Демонстрация ложного пробоя поддержки на BTCUSDT.	39
1.8	График зависимости V_{bias} от временного шага на BTCUSDT. . . .	41
1.9	Общие результаты бэктестирования стратегии Intersector.	46
1.10	Таблица месячных возвратов стратегии Intersector.	47
1.11	Сравнение графиков доходности стратегии и бенчмарка.	47
2.1	Наложение графиков цены в дневном и недельном таймфреймах.	54
2.2	Матрица и путь трансформации для графиков цены акций SBER.	55
2.3	Матрица самоподобия для четырех графиков цены акций SBER.	57
2.4	Сопоставление двух временных рядов на предмет непохожести. .	58
2.5	Матрица коэффициентов непохожести для различных активов. .	60
2.6	Матрица коэффициентов корреляции для различных активов. .	62
2.7	Сглаженный график волатильности стоимости акций SBER. . . .	63
2.8	Определение параметров процентных изменений цены.	66
2.9	Нормальное распределение процентных изменений цены.	67
2.10	Экспоненциальное распределение времени жизни уровней.	69
2.11	Архитектура модели для решения задачи классификации.	71
2.12	График зависимости точности от количества эпох обучения. . . .	72
2.13	Определение оптимальной длины предыстории ряда.	74
3.1	Фрагмент ленты сделок для BTCUSDT на споте Binance.	81
3.2	Фрагмент разметки серий сделок на графике BTCUSDT.	82
3.3	Кластеризация серий сделок на 4 кластера методом DBSCAN. . .	83
3.4	Кластеризация серий сделок на 4 кластера методом DBSCAN. . .	84
3.5	Кластеризация серий сделок на 4 кластера методом DBSCAN. . .	84
3.6	Кластеризация серий сделок на 4 кластера методом DBSCAN. . .	85

3.7	Кластеризация серий сделок на 3 кластера методом BIRCH.	85
3.8	Разметка крупных сделок на BTCUSDT со спота Binance.	86
3.9	Тепловая карта перебора параметров n и m для ETHUSDT.	88
3.10	Тепловая карта перебора параметров n и m для DOGEUSDT. . . .	89
3.11	Архитектура нейронной сети модели третьей версии.	89
3.12	Результаты бэктестирования стратегии Intersector 3.1.	90
3.13	Наложение результатов стратегии Intersector на бенчмарк.	91

Список таблиц

1	Особенности рассматриваемых и используемых торговых заявок.	16
2	Результаты анализа поведения цен акций по пятницам.	65
3	Результаты алгоритма разметки для дневного таймфрейма. . . .	70
4	Результативность работы разных ансамблей моделей.	79