

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное автономное образовательное учреждение
высшего образования
«ТЮМЕНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»

ИНСТИТУТ МАТЕМАТИКИ И КОМПЬЮТЕРНЫХ НАУК
Кафедра программной и системной инженерии

РЕКОМЕНДОВАНО К ЗАЩИТЕ В
ГЭК

Заведующий кафедрой
д.т.н., профессор

_____ А.Г. Ивашко
_____ 2023 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА
магистра

**СИСТЕМА ПОДДЕРЖКИ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ
НА ФИНАНСОВОМ РЫНКЕ**

09.04.03 Прикладная информатика
Магистерская программа «Информационные системы анализа данных»

Выполнила работу
студентка 2 курса
очной формы обучения



Решетникова
Людмила
Геннадьевна

Научный руководитель
к.т.н, доцент



Цыганова
Мария
Сергеевна

Рецензент
к.ф.-м.н, доцент



Семихин
Дмитрий
Витальевич

г. Тюмень
2023

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
ГЛАВА 1. ПРЕДМЕТНАЯ ОБЛАСТЬ И ПОСТАНОВКА ЗАДАЧИ.....	7
1.1 Описание предметной области и терминологическая база	7
1.2 Постановка задачи	9
1.3 Формализация задачи для цели автоматизации.....	10
ГЛАВА 2. ОБЗОР МОДЕЛЕЙ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ НА ФИНАНСОВОМ РЫНКЕ.....	12
2.1 Обзор методов инвестиционного анализа на финансовом рынке	12
2.2 Обзор методов прогнозирования цен на финансовом рынке.....	22
2.3 Выбор методов машинного обучения для прогнозирования цен и методов инвестиционного анализа на финансовом рынке	34
ГЛАВА 3. ПРОГНОЗИРОВАНИЕ ЦЕН НА ФИНАНСОВОМ РЫНКЕ ПРИ ПОМОЩИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ.....	36
3.1 Описание исходных данных и способ их получения.....	36
3.2 Подготовка данных для модели прогнозирования.....	39
3.3 Описание архитектуры модели прогнозирования.....	44
3.4 Вычислительные эксперименты и их результаты	48
ГЛАВА 4. ПОСТРОЕНИЕ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ.....	57
4.1 Система поддержки принятия инвестиционных решений на основе модели LSTM, оценка ее качества (LSTM-IR)	57
4.2 Система поддержки принятия инвестиционных решений на основе модели DMI, оценка ее качества (DMI-IR)	61

4.3 Система поддержки принятия инвестиционных решений на основе прогноза нейронной сети LSTM и модели DMI, оценка ее качества (LSTM-DMI-IR)	66
ГЛАВА 5. ОЦЕНКА УСТОЙЧИВОСТИ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ	71
5.1 Оценка качества LSTM-DMI-IR на разных инвестиционных горизонтах	71
5.2 Оценка качества LSTM-DMI-IR с разными начальными точками инвестирования при трехлетнем инвестиционном горизонте	73
ЗАКЛЮЧЕНИЕ	77
БИБЛИОГРАФИЧЕСКИЙ СПИСОК	79

ВВЕДЕНИЕ

Финансовый рынок является важным элементом экономической системы. Он представляет собой совокупность отношений, при которых финансовые активы обеспечивают обмен различных ценностей на рыночных принципах.

Ключевой функцией финансовых рынков является перераспределение капитала. Компании получают доступ к капиталу, а инвесторы могут вложить свой капитал в компанию и получить часть результата ее деятельности. Таким образом, порог входа в инвестиционную деятельность существенно снижается и в экономике задействован капитал все большего количества частных лиц.

Также активная деятельность по реализации одного из приоритетных направлений государственной политики – повышение инвестиционной грамотности, приводит к тому, что на финансовом рынке появляется много частных инвесторов. Не только недостаток знаний, т.е. низкая инвестиционная грамотность, а также психологические искажения и отсутствие дисциплины приводят к отрицательным результатам и разочарованию в инвестициях.

Решение указанной проблемы может быть связано с реализацией автоматизированной системы поддержки принятия инвестиционных решений на основе прогнозирования цен финансовых активов (акций) и их интерпретации, результатом работы которой будет инвестиционная рекомендация: включить акцию в инвестиционный портфель (купить) / исключить акцию из инвестиционного портфеля (продать).

Стимулом для частного инвестора выступает прибыль, как положительная разница между ценой продажи и ценой покупки финансовых активов (акций), возникающая из-за изменения рыночной цены при удержании акций определенный период времени. Еще одним источником дохода инвесторов в акции (акционером) могут быть дивиденды – часть прибыли компании, выплачиваемая один или несколько раз в год. Не все компании выплачивают дивиденды, но при реинвестировании прибыли внутри

компании стоимость ее акций возрастает. Поэтому оценка эффективности инвестирования в акции может базироваться на динамике рыночной стоимости акций компании.

Динамика рыночной цены акций разнонаправленная. Поэтому возможности инвестора получить прибыль при повышении курса акций противостоит опасность получить убыток при снижении курса акций. Реальную прибыль инвестор фиксирует своевременными сделками покупки или продажи акций. Таким образом, залогом положительного финансового результата являются правильные инвестиционные решения – решение купить или продать ценную бумагу в определенный момент времени по рыночной цене.

Обладая информацией о возможной будущей стоимости акции, инвестор может принять инвестиционное решение с положительным финансовым результатом (прибылью), которое обеспечивает рост капитала на длительном инвестиционном горизонте.

Таким образом, модели принятия правильных инвестиционных решений, основанных на прогнозе цен акций востребованы частными инвесторами.

Целью данной работы является повышение эффективности портфельного инвестирования на российском фондовом рынке путем разработки системы поддержки принятия инвестиционных решений.

Для достижения поставленной цели сформулирован комплекс задач, подлежащих решению:

- разработка общей архитектуры системы;
- построение и обучение модели прогнозирования цен акций;
- реализация алгоритма интерпретации полученного результата в инвестиционную рекомендацию: включить акцию в инвестиционный портфель (купить) / исключить акцию из инвестиционного портфеля (продать).

В качестве показателей эффективности/качества системы поддержки инвестиционных решений рассматриваются: а) прирост инвестированного капитала в течение анализируемого периода; б) средняя годовая доходность

инвестиционного портфеля; в) риск инвестиционного портфеля; г) значение коэффициента Шарпа.

Указанные показатели сравниваются с такими же показателями эталонного индексного инвестиционного портфеля; в качестве эталона выступает индекс Московской биржи (МОЕХ10).

Для успешной подготовки и защиты выпускной квалификационной работы обучающимся использовались средства и методы физической культуры и спорта с целью поддержания должного уровня физической подготовленности, обеспечивающую высокую умственную и физической работоспособность. В режим рабочего дня включались различные формы организации занятий физической культурой (физкультпаузы, физкультминутки, занятия избранным видом спорта) с целью профилактики утомления, появления хронических заболеваний и нормализации деятельности различных систем организма.

В рамках подготовки к защите выпускной квалификационной работы автором созданы и поддерживались безопасные условия жизнедеятельности, учитывающие возможность возникновения чрезвычайных ситуаций.

ГЛАВА 1. ПРЕДМЕТНАЯ ОБЛАСТЬ И ПОСТАНОВКА ЗАДАЧИ

1.1 Описание предметной области и терминологическая база

Современная экономика характеризуется движением капитала между отраслями и странами, в поисках более высокой прибыли. В результате этого курсы валют, процентные ставки и котировки акций оказывают большое влияние на экономику. Определяющую роль в этом играет фондовый рынок, который является неотъемлемой частью национального финансового рынка, что связано с появлением массового инвестора. В настоящее время все больше частных лиц интересуется инвестированием.

Инвестиции – это вложение денежных средств в целях получения дохода, а также сохранения и приумножения капитала. Инвестиции на финансовом рынке (финансовые инвестиции) реализуются через покупку-продажу ценных бумаг и других финансовых активов.

Реализация Стратегии повышения финансовой грамотности в Российской Федерации на 2017-2023 годы (утв. Распоряжением правительства РФ 25.09.2017 № 2039-р), приводит к тому, что на финансовом рынке появляется много частных инвесторов. В России доля частных инвесторов составляет около 15% взрослого населения. В начале мая 2023 г. Московская биржа объявила о росте количества частных инвесторов. По итогам апреля 2023 г. значение достигло 25,1 млн клиентов. Доля физических лиц в объеме торгов акциями в апреле 2023 г. составила 81,5% - новое рекордное значение, прошлый максимум зафиксирован в феврале 2023 г. – 81,1%. Доля физических лиц в объеме торгов облигациями в апреле 2023 г. составила 36,5% [Московской бирже, 2023].

Большое влияние на популяризацию биржевой торговли оказала цифровизация и развитие финтех, что позволило совершать сделки прямо из дома. В итоге на фондовый рынок ежегодно приходят миллионы новых инвесторов, что усложняет систему, добавляя множество переменных, из-за чего получение прибыли для участников рынка существенно усложняется.

Вследствии этого повышается неопределенность и возрастает риск при осуществлении сделок на фондовом рынке. В таких условиях повысить конкурентоспособность участников биржевых торгов могут передовые методы прогнозирования стоимости ценных бумаг.

Стимулом для частного инвестора выступает прибыль, как положительная разница между ценой продажи и ценой покупки финансовых активов (акций), возникающая из-за изменения рыночной цены при удержании акций определенный период времени. Еще одним источником дохода инвесторов в акции (акционером) могут быть дивиденды – часть прибыли компании, выплачиваемая один или несколько раз в год. Не все компании выплачивают дивиденды, но при реинвестировании прибыли внутри компании стоимость ее акций возрастает. Поэтому оценка эффективности инвестирования в акции может базироваться на динамике рыночной стоимости акций компании.

Динамика рыночной цены акций разнонаправленная. Поэтому возможности инвестора получить прибыль при повышении курса акций противостоит опасность получить убыток при снижении курса акций. Реальную прибыль инвестор фиксирует своевременными сделками покупки или продажи акций. Таким образом, залогом положительного финансового результата являются правильные инвестиционные решения – решение купить или продать ценную бумагу в определенный момент времени по рыночной цене.

Обладая информацией о возможной будущей стоимости акции, инвестор может принять правильное инвестиционное решение – инвестиционное решение с положительным финансовым результатом (прибылью), которое обеспечивает рост капитала на длительном инвестиционном горизонте.

Результаты инвестирования определяются правильными инвестиционными решениями при движении рыночных цен. Точное прогнозирование цен на акции играет важную роль в инвестировании. Поскольку данные о ценах на акции характеризуются высокой частотой, волатильностью, нелинейностью и длительной памятью, точное прогнозирование цен на акции является сложной задачей.

1.2 Постановка задачи

Целью данной работы является повышение эффективности портфельного инвестирования на российском фондовом рынке путем разработки системы поддержки принятия правильных инвестиционных решений. Можно утверждать, что инвестиционное решение правильное, если результатом сделки является получение прибыли, т.е. цена продажи превышает цену покупки.

Объективно, каждая сделка не может быть прибыльной. Поэтому на более длительном инвестиционном горизонте критерием качества системы поддержки принятия инвестиционных решений выступает приумножение капитала, которое проявляется в росте стоимости инвестиционного портфеля.

Для достижения поставленной цели сформулирован комплекс задач, подлежащих решению:

разработка общей архитектуры системы;
построение и обучение модели прогнозирования цен акций;
реализация алгоритма интерпретации полученного результата в инвестиционную рекомендацию: включить акцию в инвестиционный портфель (купить) / исключить акцию из инвестиционного портфеля (продать).

В качестве показателей эффективности/качества системы поддержки инвестиционных решений рассматриваются:

- а) прирост инвестированного капитала в течение анализируемого периода;
- б) средняя годовая доходность инвестиционного портфеля;
- в) риск инвестиционного портфеля;
- г) значение коэффициента Шарпа.

Указанные показатели сравниваются с такими же показателями эталонного индексного инвестиционного портфеля; в качестве эталона выступает индекс Московской биржи (MOEX10), который рассчитывается как средняя арифметическая цен 10 наиболее ликвидных акций.

1.3 Формализация задачи для цели автоматизации

Для разработки программы необходима формализация поставленной задачи в контексте информационной системы.

Системы поддержки принятия решений используют, когда пользователи хотят получить профессиональную рекомендацию выбрать некоторую альтернативу из множества альтернатив. Пользователь системы может не согласиться с рекомендациями системы, а принять другое решение. Для поддержки принятия решений используется комплекс программных и логико-математических средств.

Чтобы получить исходные данные для создания системы поддержки принятия инвестиционных решений используем известный кибернетический метод «черного ящика» [Энциклопедия кибернетики, 1974], который описывает систему через входы, выходы, границы и внешнюю среду. Первым этапом создания системы является модель типа «черный ящик», т.к. отсутствует информация о внутреннем строении и состоянии анализируемой системы. В данном случае достаточным является содержательное описание входов и выходов как показано на рисунке 1.



Рис. 1. Система поддержки принятия инвестиционных решений на финансовом рынке как «черный ящик»

Входы системы (данные о биржевой торговле акцией) представим в виде множества из пяти элементов:

$$X = \{1, 2, 3, 4, 5\}, \quad (1)$$

где x_1 – цена открытия;

x_2 – цена закрытия;

x_3 – минимальная цена;

x_4 – максимальная цена;

x_5 – объем торгов.

Выходом системы (инвестиционной рекомендацией) является один элемент:

$$Y = \{1\}, \quad (2)$$

где y – инвестиционная рекомендация – включить акцию в инвестиционный портфель (купить) или исключить акцию из инвестиционного портфеля (продать).

Таким образом, модель «черного ящика» системы поддержки принятия инвестиционных решений на вход принимает данные о биржевой торговле акциями, а выходом является инвестиционная рекомендация о включении или исключении акции из инвестиционного портфеля.

ГЛАВА 2. ОБЗОР МОДЕЛЕЙ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ НА ФИНАНСОВОМ РЫНКЕ

2.1 Обзор методов инвестиционного анализа на финансовом рынке

Наиболее важным для прогнозирования стоимости ценных бумаг остается вопрос, какие факторы и в какой степени влияют на формирование рыночной стоимости разных финансовых активов.

На финансовом рынке существует много разнообразных методов анализа для принятия инвестиционных решений, которые можно классифицировать следующим образом (Таблица 1):

Таблица 1

Классификация методов принятия инвестиционных решений на финансовом
рынке

Методы инвестиционного анализа	Портфельные инвестиционные стратегии
<ul style="list-style-type: none"> • Технический анализ (графический – «голова и плечи», «двойная вершина/дно» и др., индикаторный - ADX, ROC, MACD, RSI и др.) • Фундаментальный анализ (глобальный - «сверху-вниз», локальный - «снизу-вверх») 	<ul style="list-style-type: none"> • Динамические стратегии (Global Tactical Asset Allocation, Dual Momentum Investing, Risk-Parity Portfolio, Minimum Variance Portfolio и др.) • Статические стратегии (Permanent Portfolio, Ivy Portfolio, Equal Weight Portfolio, All-Weather Portfolio и др.)

Часто прогнозы, получаемые посредством применения фундаментального анализа не реализуются на практике. Это можно увидеть на множестве примеров неожиданного обесценивания активов, например в случаях с падением стоимости акций высокотехнологичных компаний в 2000-2001 годах,

финансовым кризисом в России в 1998 году, банкротстве мировых гигантов, таких как WorldCom и Enron в 2002 году. В каждом из этих случаев, методы фундаментального анализа не только не предсказывали такого катастрофического развития событий, но и предполагали дальнейший рост котировок.

Альтернативой фундаментальному анализу для прогнозирования будущей стоимости ценных бумаг выступает технический анализ. Данный подход не предполагает изучение и анализ текущих финансовых показателей компаний, чьи акции прогнозируются, а придает основополагающее значение факторам, не участвующим в фундаментальном анализе: несовершенное понимание участниками биржевых торгов реальной ситуации, их ограниченное рациональное поведение и отсутствие достоверной информации. Технический анализ является популярной методологией среди инвесторов.

В трудах иностранных авторов по техническому анализу можно выделить две категории работ. К первой относятся разработки базового инструментария и методологии его применения [Джастин, Билл В., 2021; Мэрфи, 1996] и др. В трудах этих авторов уделяется недостаточное внимание психологии массового инвестора и методам управления капиталом. Ко второй категории относятся исследования в области закономерностей поведения участников рынка и методов управления капиталом А. Элдер [Элдер А. Как играть и выигрывать на бирже: Психология. Технический анализ. Контроль над капиталом. — М.: АЛЬПИНА ПАБЛИШЕР, 2013.], Т. Пламмер, В. Тарп, Л. Твид [Твид Л. Психология финансов. — М.: "ИК "Аналитика", 2002. — 376 с.]. Среди российских исследователей, которые занимаются вопросами технического анализа и его применения на фондовом рынке, можно выделить С. Вайн, И. Закирян, В. Рычков. Однако, значительная часть вопросов формирования стоимости акций и возможностей ее прогнозирования с помощью методов технического анализа не получила достаточного освещения в отечественной научной литературе. Это обуславливает выбор цели данной исследовательской работы.

Необходимость изучения факторов, определяющих движение рыночной стоимости акций, исследования возможностей и ограничений технического анализа, особенностей его применения в российских условиях, с одной стороны, и отсутствие комплексных научных разработок в этой области – с другой, объясняют актуальность данного исследования.

Индикаторы технического анализа – это алгоритмы, которые позволяют получать данные о будущих ценах с помощью данных о котировках за определенный промежуток времени. В основе каждого индикатора технического анализа лежит определенная формула. Именно с ее помощью и происходит расчет. В зависимости от типа индикатора или его предназначения, формула может варьироваться.

К классу трендовых индикаторов относятся алгоритмы, следящие за трендом. Одной из основ большинства трендовых индикаторов является скользящая средняя линия, имеющая массу разновидностей. Индикаторы на ее основе позволяют отследить тренд и увидеть его начало или конец. Наиболее часто используемый в техническом анализе индикатор – скользящая средняя. Она показывает среднее значение цены биржевого товара за определенный промежуток времени и сглаживает ценовые колебания. Moving Average можно рассчитывать для любого временного ряда, цены открытия и закрытия, максимальную и минимальную цены, объем торгов или значения других индикаторов.

Существует несколько вариантов скользящей средней, но чаще используют:

- простую скользящую среднюю – Simple Moving Average (SMA), которая рассчитывается по формуле:

$$SMA_t = \frac{1}{n} \sum_{i=t-n}^t P_i, \quad (3)$$

где P_i – цена актива на момент времени i ;

n – период усреднения.

- экспоненциальную скользящую среднюю – Exponential Moving Average (EMA)), которая рассчитывается по формуле:

$$EMA_t = P_t \times K + EMA_{t-1} \times (1 - K), \quad (4)$$

$$K = \frac{2}{n+1}, \quad (5)$$

где P_i – текущая цена актива на момент времени t ;

n – период усреднения.

Они отличаются друг от друга весовыми коэффициентами, которые присваиваются последним данным. SMA – все цены имеют равный вес, EMA – последние цены имеют больший вес. Скользящие средние являются трендследящим индикатором, они не прогнозируют изменения тренда, дают запаздывающий сигнал.

Индикатор ADX (Average Directional Movement Index) – популярный индикатор, с помощью которого определяют силу и перспективы текущего рыночного тренда. Инструмент был разработан знаменитым трейдером Уэллсом Уайлдером на основе двух других его программ – Positive Directional (+DI) и Negative Directional Indicator (-DI).

Индикатор ADX представляет собой график, на котором размещены три кривые: +DI, -DI и ADX. Они колеблются в диапазоне от нуля до ста. Перемещения этих линий дают определенные торговые сигналы.

+DI/-DI отражают силу восходящей/нисходящей тенденции за определенный временной отрезок. Если сверху располагается плюсовая кривая, то рынок «бычий». Если минусовая DI – доминируют «медведи».

Кривая ADX является экспоненциальной средней –DI и +DI. Она сообщает о рыночных настроениях – присутствует ли в данный момент тренд

(если да, то насколько сильный), или цена «застряла» в боковом движении (флете). О наличии стабильной тенденции свидетельствует рост ADX, сопровождаемый расхождением +DI и –DI в разные стороны. Схождение этих линий сигнализирует о постепенном затухании движения.

Помимо фундаментального и технического анализа на финансовом рынке применяются различные стратегии инвестирования, предполагающие принятие решений по управлению инвестиционными портфелями. Инвестиционные стратегии делятся на статические и динамические.

Целью статических инвестиционных стратегий является сохранение рыночной доходности при снижении риска. К статическим стратегиям относятся:

- Permanent Portfolio – распределение портфеля по 25% в акции, долгосрочные облигации, краткосрочные облигации и золото;
- Ivy Portfolio – стратегия копирует портфель эндаументов университетов «Лиги Плюща»;
- Equal Weight Portfolio – выбранные классы активов удерживаются в портфеле с постоянными и равными весами;
- All-Weather Portfolio – в портфеле в разных постоянных весах содержатся акции, долгосрочные облигации, среднесрочные облигации, сырьевые товары и золото. Управление предполагает ежегодную ребалансировку портфеля [Далио Р. Большие долговые кризисы. Принципы преодоления. Изд-во: Манн, Иванов и Фербер, 2020. – 496 с.].

Целью динамических инвестиционных стратегий является повышение доходности без увеличения риска. К динамическим стратегиям относятся:

- GTAA (Global Tactical Asset Allocation) – стратегия инвестирования в классы активов, которые на конец месяца торгуются выше 200-дневных скользящих средних;
- Dual Momentum – стратегия инвестирования в 4 класса наиболее сильных на данный момент активов [Antonacci G. Dual Momentum Investing: An

Innovative Strategy for Higher Returns with Lower Risk 1st Edition. - Publisher : McGraw Hill, 2014. – 240 p.];

- Risk-Parity Portfolio – инвестирование в разные классы активов, которые взвешиваются на основе волатильности;

- Minimum Variance Portfolio – стратегия аналогична Risk-Parity Portfolio, но задачей является минимизировать волатильность.

Более подробно рассмотрим стратегию Dual Momentum Investing (DMI).

DMI заключается в том, что для инвестирования выбираются только активы, которые за определенный период времени превзошли свои аналоги и также приносят положительный финансовый результат (прибыль). Идея этой стратегии заключается в том, что актив с более высоким относительным импульсом и положительным абсолютным импульсом будет продолжать работать до тех пор, пока другой актив не превзойдет его. Таким образом, это своего рода трендовая стратегия.

Двойной импульс – это инвестиционная стратегия, которая использует два вида импульса для определения, какую ценную бумагу покупать и когда это делать. Он сравнивает текущий импульс двух или более ценных бумаг и выбирает ту, у которой наибольший импульс, а затем сравнивает ее с тем, что было в прошлом.

На фьючерсных рынках, где можно открывать короткие позиции так же легко, как и длинные, стратегия двойного импульса также может быть использована для выявления и продажи актива с наихудшими показателями, который имеет отрицательный (нисходящий) импульс при этом импульсе – слабейшего из слабых.

Импульс, используемый в осцилляторе momentum на многих торговых платформах, также известен как скорость изменения (ROC), которая измеряет величину изменения цены ценной бумаги за определенный период. Импульс рассчитывается как процентное изменение текущей цены по сравнению с определенным периодом в прошлом по формуле:

$$Momentum = \frac{P_t}{P_{t-k}} \times 100, \quad (6)$$

где P_t – текущая цена актива на момент времени t ;

P_{t-k} – цена актива на момент времени $(t-k)$.

Таким образом *Momentum* колеблется около 100. Значения меньше 100 указывают на отрицательный или нисходящий импульс (снижение цен), в то время как значения больше 100 указывают на положительный или восходящий импульс (повышение цен).

Формула (3) предназначена для одного типа импульса, известного как абсолютный импульс, но существует также другое понятие импульса, известное как относительный импульс. Абсолютный импульс – импульс актива относительно самого себя. Если актив имеет положительное изменение в течение интересующего периода, абсолютный импульс будет положительным, и чем больше изменение, тем больше импульс, и наоборот. Относительный импульс – тип импульса сравнивает доходность актива за определенный период с доходностью других активов. Он сравнивает абсолютный импульс одного актива с импульсом другого актива или даже со многими активами таким образом, что актив с более высоким импульсом, чем другие, считается имеющим положительный относительный импульс.

Двойной импульс рассчитывается по формуле

$$DM = Momentum_1 - Momentum_2, \quad (7)$$

где $Momentum_1$ – абсолютный импульс 1-го актива;

$Momentum_2$ – абсолютный импульс 2-го актива.

При этом оба абсолютных импульса должны быть положительными или отрицательными.

Интерпретация DM будет следующей:

- открывайте длинные позиции по активу 1, если двойной импульс положительный и оба актива имеют положительный абсолютный импульс, т.к. актив 1 имеет более высокий абсолютный импульс;

- открывайте короткие позиции по активу 2, если двойной импульс отрицательный и оба актива имеют отрицательный двойной импульс, т.к. у актива 1 более высокий абсолютный импульс.

Формула заключается просто в том, чтобы получить положительный относительный импульс на растущем рынке или отрицательный относительный импульс на падающем рынке. С его помощью инвестор может покупать лучшие из активов с положительными показателями и продавать худшие из активов с отрицательными показателями.

На рынке могут быть активы, которые имеют положительный абсолютный импульс, но отрицательный относительный импульс. Когда рынок в целом растет, отстающие активы могут иметь положительный импульс, но показывать плохие результаты по сравнению со своими альтернативами. С другой стороны, могут быть активы с положительным относительным импульсом и отрицательным абсолютным. Когда рынок падает (медвежий рынок), некоторые активы с отрицательным абсолютным импульсом будут иметь положительный относительный импульс, потому что они теряют меньше, чем другие. На падающем рынке имеет смысл открывать короткие позиции с худшими проигравшими.

Первым шагом в применении подхода с двойным импульсом является поиск активов с положительным абсолютным импульсом. Нужно рассчитать абсолютный импульс отдельных активов, представляющих интерес, за определенный период. Если актив торгуется по более высокой цене, чем это было в прошлом, его абсолютный импульс будет положительным, и его можно рассмотреть для открытия длинной позиции после проверки относительного импульса. Однако, если он торгуется ниже, его абсолютный

импульс будет отрицательным, что делает его кандидатом на короткие продажи.

Второй шаг – сравнить активы с положительным абсолютным импульсом друг с другом, чтобы получить относительный импульс. Также можно сравнить активы с отрицательным абсолютным импульсом друг с другом, чтобы получить их относительный импульс. Среди активов с положительным абсолютным импульсом для покупки следует выбирать активы с наибольшим относительным импульсом. Для активов с отрицательным абсолютным импульсом те, у которых наименьший относительный импульс (наибольшее отрицательное значение), могут быть использованы для открытия коротких позиций.

На фондовом рынке, стратегия двойного импульса лучше работает в долгосрочной перспективе, потому что фондовый рынок имеет тенденцию к долгосрочному росту. Воспользоваться преимуществами короткой продажи можно на фьючерсном и валютном рынках. Стратегия DMI, несмотря на использование относительно простого подхода, на протяжении многих лет демонстрировала хорошие результаты.

Существует множество способов реализации концепции двойного импульса при инвестировании или торговле на финансовом рынке. Этот подход можно использовать для торговли отдельными активами, такими как акции. Стратегию DMI можно использовать для выбора акций для инвестирования в различных рыночных условиях. Во время бычьего рынка можно использовать подход к отбору акций таким образом, чтобы выбирать только те, у которых наибольший импульс, и инвестировать в эти акции. Аналогично, на медвежьем рынке можно использовать концепцию выбора ценных бумаг с наибольшим нисходящим импульсом и открывать короткие позиции по ним.

При правильном внедрении этот подход потенциально может дать хорошие результаты. Однако стратегия DMI имеет тенденцию к снижению эффективности во время сильных бычьих рынков или когда рынок сильно

восстанавливается, но благодаря своей способности выдерживать медвежьи рынки стратегия показала лучшие результаты в долгосрочной перспективе.

Стратегия DMI имеет два ключевых преимущества. Во-первых, она обеспечивает лучший результат, чем стратегия «купи и держи». Второе ключевое преимущество заключается в том, что оно сопровождается меньшей волатильностью. Его худшие просадки были не такими серьезными, как у бенчмарка.

Главной рыночной аномалией является импульс. Акции с низкой доходностью за последний год, как правило, имеют низкую доходность в течение следующих нескольких месяцев, а акции с высокой доходностью в прошлом, как правило, имеют высокую доходность в будущем.

Эффективность инвестиционных решений оценивается с помощью нескольких показателей. Средняя годовая доходность инвестиционного портфеля; рассчитывается по формуле:

$$r_p = \sqrt[n]{\frac{W_n}{W_0}} - 1, \quad (8)$$

где r_p – доходность портфеля;

W_n – стоимость портфеля в конце периода;

W_0 – стоимость портфеля в начале периода;

n – число периодов.

Риск инвестиционного портфеля, измеренный волатильностью; рассчитывался по формуле:

$$\sigma_p = \sqrt{\frac{\sum_{i=1}^n (r_i - \bar{r})^2}{n}}, \quad (9)$$

где σ_p – риск портфеля;

r_i – доходность портфеля в i -том периоде;

\bar{r} – средняя доходность портфеля;

n – число периодов.

Коэффициент Шарпа (Sharpe Ratio) – показывает какую доходность получает инвестор на единицу риска [Шарп, 2014]. Рассчитывается по формуле

$$SR = \frac{r_p - r_f}{\sigma_p}, \quad (10)$$

где SR – коэффициент Шарпа;

r_p – доходность портфеля;

r_f – безрисковая доходность (государственных облигаций);

σ_p – риск портфеля.

Таким образом, на финансовом рынке существует большой и разнообразный инструментарий для принятия инвестиционных решений. Общепризнанными показателями для оценки эффективности инвестиционных решений являются доходность, риск и коэффициент, учитывающий доходность инвестора на единицу риска, в качестве которого выбран коэффициент Шарпа.

2.2 Обзор методов прогнозирования цен на финансовом рынке

Особенностями данных фондового рынка является их упорядоченность по времени. Разработано много методов для прогнозирования элементов временного ряда, которые обобщены и систематизированы (Таблица 2).

Классификация методов прогнозирования цен на финансовом рынке

Эконометрические методы	Классические методы машинного обучения	Методы глубокого обучения (ИНС)
ARMA, ARIMA, ARCH, GARCH и др.	случайный лес (RF), регрессия опорных векторов (SVR) и др.	FNN, CNN, RNN (SRN, LSTM, GRU и др.)

Авторегрессионная скользящая средняя (ARMA). Этот метод моделирует следующий шаг в последовательности как линейную функцию наблюдений и случайных ошибок на предыдущих временных шагах. Он объединяет модели авторегрессии (AR) и скользящей средней (MA).

Параметром модели AR является порядок модели, AR(p) [Statsmodels.tsa.ar_model.AutoReg – Statsmodels 0.12.2 documentation. www.statsmodels.org]. Например, AR(1) является моделью авторегрессии первого порядка. Модель AR(p) определяется следующей формулой [Shumway R.H. (2000). Time series analysis and its applications. David S. Stoffer. New York: Springer. pp. 90–91.]:

$$X_t = \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (11)$$

где φ_i – параметры модели;

ε_t – бел шум.

Метод скользящего среднего (MA) моделирует следующий шаг в последовательности как линейную функцию от остаточных ошибок из среднего процесса на предыдущих временных шагах [Box G.E.-P., Jenkins G.M., Reinsel G.C., Ljung G.M. (2016). Time series analysis : forecasting and control (5th

ed.). Hoboken, New Jersey: John Wiley & Sons, Incorporated. p. 53.]. Модель скользящего среднего отличается от вычисления скользящего среднего временного ряда. Параметром функции МА является порядок модели q , $MA(q)$. Например, $MA(1)$ является моделью скользящего среднего первого порядка. Модель скользящего среднего концептуально представляет собой линейную регрессию текущего значения ряда по сравнению с текущими и предыдущими (наблюдаемыми) ошибками белого шума или случайными скачками выражается формулой:

$$X_t = \mu + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (12)$$

где μ – среднее значение ряда;

θ_i – параметры модели;

ε_t – бел шум.

Методы AR и MA подходят для одномерных временных рядов без трендовых и сезонных составляющих. Модель ARMA включает в себя указание порядков для моделей $AR(p)$ и $MA(q)$ в качестве параметров функции ARMA (p, q) .

Авторегрессионное интегрированное скользящее среднее (ARIMA). Этот метод моделирует следующий шаг в последовательности как линейную функцию разностных наблюдений и остаточных ошибок на предыдущих временных шагах. Он объединяет модели авторегрессии (AR) и скользящего среднего (MA), а также этап предварительной обработки разностной последовательности, чтобы сделать последовательность стационарной, называемой интеграцией (I). Обозначения для модели включают указание порядка для моделей AR (p) , I (d) и MA (q) в качестве параметров функции ARIMA (p,d,q) . Модель ARIMA также может быть использована для разработки моделей AR, MA и ARMA. Метод подходит для одномерных временных рядов с трендом и без сезонных компонентов.

Авторегрессионная условная гетероскедастичность (ARCH – AutoRegressive Conditional Heteroscedasticity) – модель, применяемая для анализа временных рядов (в первую очередь финансовых), у которых условная (по прошлым значениям ряда) дисперсия ряда зависит от прошлых значений ряда, прошлых значений этих дисперсий и иных факторов. Данные модели предназначены для «объяснения» кластеризации волатильности на финансовых рынках, когда периоды высокой волатильности длятся некоторое время, сменяясь затем периодами низкой волатильности, причём среднюю (долгосрочную, безусловную) волатильность можно считать относительно стабильной. Модели ARCH впервые были предложены Робертом Энглом в 1982 году. Уже в 1986 году Боллерслев предложил обобщение этих моделей (GARCH). В дальнейшем различные авторы предложили и иные варианты моделей данного типа, учитывающих те или иные особенности.

ARCH-моделью порядка q (обозначают ARCH(q)) называют временной ряд u_t с функцией условной дисперсии следующего вида:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i u_{t-i}^2 \quad (13)$$

где u_t – функция условной гетероскедастичности.

$$u_t = \sigma_t \varepsilon_t \quad (14)$$

Необходимое условие – стационарность временного ряда – сумма коэффициентов модели (без константы) строго меньше единицы. Если сумма коэффициентов равна единице. Оценка параметров ARCH(q)-модели может быть произведена при помощи обычного метода наименьших квадратов.

ARCH-модель предполагает зависимость условной дисперсии только от квадратов прошлых значений временного ряда. Обобщить данную модель можно предположив, что условная дисперсия зависит также от прошлых

значений самой условной дисперсии. Это так называемый обобщённый ARCH (Generalized ARCH – GARCH). В этом случае GARCH(p, q) модель (где p – порядок GARCH-членов σ^2 и q – порядок ARCH-членов u^2) описывается следующим образом:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{j=1}^p \beta_j u_{t-j}^2 \quad (15)$$

Алгоритм случайного леса (Random Forest) – универсальный алгоритм машинного обучения, суть которого состоит в использовании ансамбля решающих деревьев. Само по себе решающее дерево предоставляет крайне невысокое качество классификации, но из-за большого их количества результат значительно улучшается. Также это один из немногих алгоритмов, который можно использовать в абсолютном большинстве задач.

Благодаря своей гибкости Random Forest применяется для решения практически любых проблем в области машинного обучения. Сюда относятся регрессии (RandomForestRegressor), а также более сложные задачи, вроде отбора признаков, поиска выбросов/аномалий и кластеризации.

Теоретическая часть алгоритма Random Forest формализуется следующим образом:

$$a(x) = \frac{1}{N} \sum_{i=1}^N b_i(x) \quad (16)$$

где N – количество деревьев;

i – счетчик для деревьев;

b – решающее дерево;

x – выборка, сгенерированная на основе данных.

Для задачи регрессии решение выбирается средним. В отличие от линейной регрессии, Random Forest не обладает возможностью экстраполяции.

Процесс прогнозирования с использованием случайных лесов очень трудоемкий по сравнению с другими алгоритмами.

В основе метода опорных векторов для задач регрессии – регрессии опорных векторов (SVR) лежит поиск гиперплоскости, при которой риск в многомерном пространстве будет минимальным. По сравнению с традиционной регрессионной моделью SVR оценивает коэффициенты путем минимизации квадратичных потерь. Так, если прогнозное значение попадает в область гиперплоскости, то потери равны нулю. В противном случае разности прогнозного и фактического значений.

Искусственная нейронная сеть (ИНС) представляет собой упрощенную модель биологической, где нейроны также взаимодействуют друг с другом, принимая, обрабатывая и передавая информацию. Любая нейронная сеть состоит из двух основных слоев: принимающий (распределяющий) и обрабатывающий. Если в нейросети только два эти слоя, то ее считают однослойной. Если их количество больше — многослойной. В многослойной ИНС присутствуют все три их типа (входной, скрытый и выходной). Часть информации обрабатывается во втором нейронном слое и передается в третий, который вычисляет и выдает результат. Работа обратных связей в ИНС заключается в следующем: часть сигнала может вернуться назад. Это расширяет возможности нейронных сетей, которые могут иметь краткосрочную память, подобную человеческой.

Нейросети классифицируют еще на такие типы, как сверточные и рекуррентные. Для временных рядов обычно используют рекуррентные нейронные сети (RNN). В отличие от многослойных перцептронов, рекуррентные сети могут использовать свою внутреннюю память для обработки последовательностей произвольной длины (рис. 2).




Рис. 2. Рекуррентная нейронная сеть

Было предложено много различных архитектурных решений для рекуррентных сетей от простых до сложных.

Простая рекуррентная нейронная сеть (SRN). Простыми рекуррентными сетями (SRN) называют сети Элмана [Elman, 1990, с. 179] и Джордана [Jordan, 1997, с. 471]. Смысл обработки последовательности данных SRN заключается в том, чтобы кроме выделения отклика для каждого элемента, учесть и связь элементов. Нейронная сеть Элмана является трёхслойной нейронной сетью. Сеть также содержит набор «контекстных блоков», в которых сохраняются предыдущие значения узлов скрытого слоя. Для этого скрытый слой соединён с контекстными блоками прямыми связями с фиксированным весом, равным единице [Cruse, 2016]. С каждым шагом на вход поступает информация, которая проходит прямой ход к выходному слою в соответствии с правилами обучения. Фиксированные обратные связи из контекстных блоков передают значения предыдущих состояний узлов скрытого слоя (до того, как скрытый слой поменяет значение в процессе обучения). Таким способом сеть сохраняет своё предыдущее состояние, обеспечивая тем самым предсказание последовательностей, что выходит за пределы возможностей многослойного перцептрона. Нейронная сеть Джордана подобна сети Элмана. Однако контекстные блоки связаны не со скрытым слоем, а с выходным слоем. Контекстные блоки таким образом сохраняют предыдущее состояние и обеспечивают рекуррентную связь в сети.

RNN решает задачу запоминания уже обработанных элементов последовательности. Для этого, кроме выходного вектора, RNN имеет вектор, который описывает текущее внутреннее состояние сети, т.е. в нем содержатся воспоминания о всех элементах уже обработанных сетью. Это описывается следующими формулами:

$$h_t = \sigma_h(W_h x_t + U_h h_{t-1} + b_h), \quad (17)$$

$$y_t = \sigma_y(W_y h_t + b_y), \quad (18)$$

где x_t – вектор входного слоя;

h_t – вектор скрытого слоя (текущего состояния);

y_t – вектор выходного слоя;

W, U, b – матрицы весов соединений и вектор параметров;

σ_h, σ_y – функция активации.

Таким образом сеть состоит из ячеек, изображенных на рисунке 3.

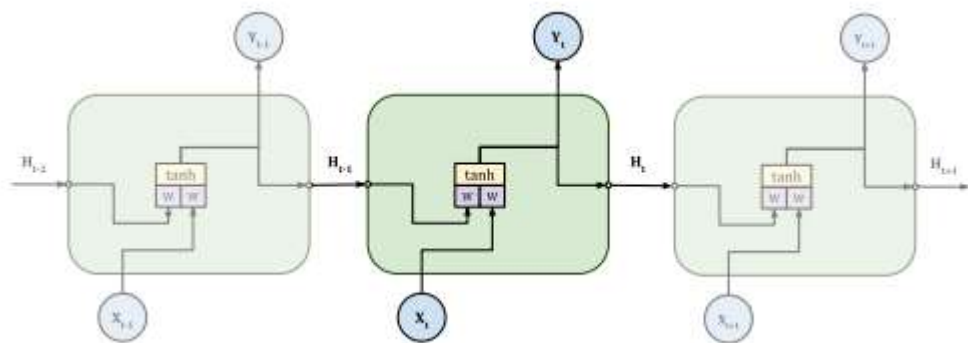


Рис. 3. Ячейка памяти RNN

В последнее время наибольшее распространение получили сеть с долговременной и кратковременной памятью (LSTM) и управляемый рекуррентный блок (GRU).

Нейронные сети с долговременной кратковременной памятью (LSTM). Впервые LSTM-сеть предложена в работе [Hochreiter, Schmidhuber, 1997] в 1997 году в качестве варианта рекуррентной нейронной сети (RNN). По сравнению с SRN, модель LSTM обладает характеристиками, подходящими для обработки и прогнозирования важных событий с большими интервалами и задержками во временных рядах [Wu, Guan, Lv, Huang, 2021]. LSTM улучшает структуру скрытого слоя SRN путем введения системы блоков (вентилей), состоящих из входных элементов, элементов забывания и выходных элементов, что эффективно устраняет проблемы затухания градиента и взрыва градиента при обучении модели. Вентили реализованы в виде логистической функции для вычисления значения в диапазоне $[0; 1]$. Умножение на это значение используется для частичного допуска или запрещения потока информации внутрь и наружу памяти. Элемент забывания используется для решения, какую информацию необходимо удалить из нейрона в модели, элемент ввода используется для обновления состояния единицы, а элемент вывода используется для управления выходом нейрона в следующий момент [Sun, Sun, Zhu, 2022]. Структура нейрона скрытого слоя LSTM показана на рисунке 4.




Рис. 4. Ячейка памяти LSTM

На рисунке, $h_{(t-1)}$ и h_t являются выходными данными предыдущей ячейки и текущей ячейки соответственно. x_t это входные данные текущей единицы измерения, *Sigmoid* и *tanh* являются функциями активации, а кружки на рисунке обозначают арифметические правила между векторами. C_t это состояние нейрона в момент t . f_t это порог забывания, который управляет тем, как ячейка должна отбрасывать информацию с помощью функции активации сигмоидной функции. i_t это пороговое значение ввода, которое определяет информацию, которая должна быть обновлена функцией *Sigmoid*, которая затем генерирует новую память с использованием функции активации *tanh*. C_t и в конечном итоге контролирует, сколько новой информации добавляется к состоянию нейрона. O_t является выходным порогом, который определяет состояние выходного нейрона сигмоидной функции и, наконец, обрабатывает состояние нейрона с использованием функции активации *tanh* для получения конечного результата [Lu, Li, Li, Sun, Wang, 2020].

Традиционная LSTM с модулями забывания $c_0=0$ и $h_0=0$ описывается следующими формулами:

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f), \quad (19)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i), \quad (20)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o), \quad (21)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c), \quad (22)$$

$$h_t = o_t \circ \sigma_h(c_t), \quad (23)$$

где x_t – входной вектор;

h_t – выходной вектор;

c_t – вектор состояний;

W, U, b – матрицы параметров и вектор;

f_t – вектор вентиля забывания, вес запоминания старой информации;

i_t – вектор входного вентиля, вес получения новой информации;

o_t – вектор выходного вентиля, кандидат на выход;

σ_g – функция активации на основе сигмоиды;

σ_c – функция активации на основе гиперболического тангенса;

σ_g – функция активации гиперболического тангенса, но в работе смотровых отверстий предполагается, что $\sigma_h(x) = x$.

LSTM-модуль способен запоминать значения как на короткие, так и на длинные промежутки времени. Ключом к данной возможности является то, что LSTM-модуль не использует функцию активации внутри своих рекуррентных компонентов. Таким образом, хранимое значение не размывается во времени, и градиент или штраф не исчезает при использовании метода обратного распространения ошибки во времени при обучении ИНС. В отличие от SRN, LSTM-сеть хорошо приспособлена для прогнозирования временных рядов, когда важные события разделены временными лагами с неопределённой продолжительностью и границами. Относительная невосприимчивость к длительности временных разрывов даёт LSTM преимущество по отношению к альтернативным рекуррентным нейронным сетям, скрытым марковским моделям и другим методам обучения для последовательностей в различных сферах применения.

LSTM-модули часто группируются в «блоки», содержащие различные LSTM-модули. Подобное устройство характерно для «глубоких» многослойных нейронных сетей и способствует выполнению параллельных вычислений.

Управляемые рекуррентные блоки (GRU) – рекуррентная нейронная сеть, имеющая несколько иной механизм вентиля, чем LSTM. Ее эффективность сопоставима с LSTM при решении задач моделирования музыкальных и речевых сигналов [Chung, Gulcehre, Cho, Yoshua, 2014]. По сравнению с LSTM у данного механизма меньше параметров, т.к. отсутствует выходной вентиль [Recurrent Neural Network Tutorial, Part 4, 2015].

Модель GRU с модулем обновления $h_0 = 0$ описывается следующими формулами:

$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z), \quad (24)$$

$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r), \quad (25)$$

$$h_t = z_t \circ h_{t-1} + (1 - z_t) \circ \sigma_h(W_h x_t + U_h (z_t \circ h_{t-1}) + b_h), \quad (26)$$

где x_t – входной вектор;

h_t – выходной вектор;

z_t – вектор вентиля обновления;

r_t – вектор вентиля сброса;

W, U, b – матрицы параметров и вектор;

σ_g – функция активации на основе сигмоиды;

σ_h – функция активации на основе гиперболического тангенса.

Высокую точность прогнозирования цен на акции и индексов показывает модель, основанная на CNN-BiLSTM-Attention. Эта модель превосходит такие часто используемые модели глубокого обучения, как RNN, LSTM, CNN-LSTM, CNN-BiLSTM и т.д. Однако прогнозирование цен двенадцати индексов фондового рынка (четырёх китайских и восьми международных) показало, что в среднем точность модели CNN-BiLSTM-Attention превосходит точность модели LSTM на 1,2% [Zhang, J.; Ye, L.; Lai, Y. Stock Price Prediction Using CNN-BiLSTM-Attention Model. Mathematics 2023, 11, 1985. <https://doi.org/10.3390/math11091985> (дата обращения: 17.05.2023)]. В среднем точность модели LSTM составляет 96,2% против 97,6% модели CNN-BiLSTM-Attention.

2.3 Выбор методов машинного обучения для прогнозирования цен и методов инвестиционного анализа на финансовом рынке

Обобщение публикаций результатов научных исследований, предметом которых стали различные методы прогнозирования динамики цен фондовых инструментов. В итоге выявлено:

- традиционные эконометрические методы, такие как ARIMA, GARCH и другие, показывают лучшие результаты прогнозирования при менее изменчивых данных [Dwivedi, Attry, Parekh, Singla, 2021; Parmar, Singh, Kumar, 2021; Xiang, 2022];

- традиционные алгоритмы машинного обучения, такие как случайный лес (RF) и метод опорных векторов (SVM), могут быть хорошим выбором для изучения нелинейных взаимосвязей между ценой акций и различными влияющими факторами. Тем не менее, эти методы чрезмерно полагаются на отбор выборок в процессе построения модели, что делает построение и обновление модели негибкими, в результате чего точность прогнозирования не всегда соответствует требованиям [Ince, Trafalis, 2004; Yin, Li, Li, Zhang, 2021];

- модели глубокого обучения обладают более мощными возможностями обучения и самоадаптации, чем традиционные модели машинного обучения, и могут лучше выполнять анализ цен на акции [Sun, Xu, Liu, 2021].

Анализ публикаций об использовании моделей глубокого обучения для прогнозирования цен акций показал, что исследовано много различных видов и архитектур искусственных нейронных сетей (ИНС). Кроме того, исследователи тестируют разные комбинации методов прогнозирования. Каждый метод достигает определенного уровня точности, но также имеет свои ограничения.

В работе [Moghar, Hamiche, 2020] предложена модель рекуррентной нейронной сети (RNN) на основе LSTM для прогнозирования ценового тренда акций GOOGL и NIKE, и результаты тестирования подтвердили ее эффективность. Основываясь на компромиссе эффективности и затрат ресурсов при использовании разных моделей прогнозирования цен акций, для принятия

инвестиционных решений использована модель LSTM. С помощью модели LSTM построен прогноз значений индекса Московской биржи (MOEX10), включающего в себя 10 наиболее ликвидных акций.

DMI представляет собой систематический подход, основанный на правилах, для входа и выхода с рынков на основе конкретных проверенных критериев. Поэтому данная стратегия хорошо поддается автоматизации. Подход с двойным импульсом направлен на инвестирование в актив, только если он показывает лучшие результаты за определенный период, чем аналогичные активы, и в то же время имеет положительный (восходящий) импульс. Следовательно, она не направлена на то, чтобы купить лучшее среди проигравших; она направлена только на то, чтобы купить лучшее среди победителей.

Непрерывные исследования твердо установили импульс как аномалию, которая хорошо работает почти на всех рынках, включая акции, фондовые индексы, валюты, товары, недвижимость и облигации. Исследования вне выборки показали, что импульс был эффективным с начала 1800-х годов до настоящего времени. Существует синергия в сочетании обоих типов импульса. Если инвестор уменьшает потери на медвежьем рынке, используя абсолютный моментум, то больше выигрывает от относительного импульса на бычьем рынке. Если абсолютный моментум существенно снижает потери на медвежьего рынка, то прибыль бычьего рынка становится новой прибылью, а не компенсирует убытки.

Таким образом, в дальнейшем для прогнозирования цен акций используем модель LSTM, для моделирования инвестиционной стратегии используем DMI.

ГЛАВА 3. ПРОГНОЗИРОВАНИЕ ЦЕН НА ФИНАНСОВОМ РЫНКЕ ПРИ ПОМОЩИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

3.1 Описание исходных данных и способ их получения

В качестве исходных данных для задачи прогнозирования использовались данные индекса Московской биржи (MOEX10), который является основным индексом российского фондового рынка. Для вычислительных экспериментов использовались данные индекса Московской биржи 10 наиболее ликвидных акций за период с 6 января 1998 года по 08 мая 2023 года, в общей сложности 6329 торговых дней, и данные 10 акций, на основе которых рассчитывается этот индекс за период с 25 марта 2013 года по 08 мая 2023 года, в общей сложности 2546 торговых дней.

Для получения биржевых данных использована библиотека Pandas, класс `pandas_datareader.moex.MoexReader()` [Pandas documentation, 2021]. В качестве аргумента указан список коротких названий акции и биржевых индексов (тикеров), а также даты начала и окончания периода, за который необходимо получить данные. Структура исходного набора данных показана в таблице 3.

Таблица 3

Структура исходного набора данных

Описание поля	Наименование	Формат	Количество пропусков
Дата торгов	TRADEDATE	Дата	1
Идентификатор режима торгов	BOARDID	Строковый	0
Идентификатор ценной бумаги (тикер)	SECID	Строковый	0
Короткое название ценной бумаги	SHORTNAME	Строковый	0

Название ценной бумаги	NAME	Строковый	0
Цена закрытия	CLOSE	Вещественный	1
Цена открытия	OPEN	Вещественный	1
Максимальная цена	HIGH	Вещественный	1
Минимальная цена	LOW	Вещественный	1
Объем торгов	VOLUME	Вещественный	1
Дюрация	DURATION	Вещественный	4969
Доходность	YIELD	Вещественный	4969
Шаг цены	DECIMALS	Целый	0
Капитализация	CAPITALIZATION	Вещественный	3472
Идентификатор валюты	CURRENCYID	Строковый	0
Число для вычисления индекса	DIVISOR	Вещественный	3964
Торговая сессия	TRADINGSESSION	Целый	0
Стоимость	VALUE	Вещественный	6331

Получаемый фрейм данных содержит 17 столбцов разной информации об акциях, обращающихся на Мосбирже, которые указаны в запросе. Данные содержат строковые и числовые переменные, в некоторых данных присутствуют пропуски. На рисунке 5 показан фрагмент содержимого столбцов биржевых данных.

TRADEDATE	BOARDID	SECDID	SHORTNAME	NAME	CLOSE	OPEN	HIGH	LOW	VALUE	DURATION	YIELD	DECIMALS	CAPITALIZATION	CURRENCYID	DIVISOR	TRAC
1998-01-06	SNDX	MDEX10	Индекс МосБиржи 10	Индекс МосБиржи 10	104.12	100.29	107.50	100.29	4.134117e+07	NaN	NaN	2	NaN	RUB	NaN	
1998-01-08	SNDX	MDEX10	Индекс МосБиржи 10	Индекс МосБиржи 10	98.38	101.92	103.56	98.08	3.004626e+07	NaN	NaN	2	NaN	RUB	NaN	
2023-05-18	SNDX	MDEX10	Индекс МосБиржи 10	Индекс МосБиржи 10	4924.62	4956.94	4968.33	4905.60	2.547142e+10	0.0	0.0	2	1.004510e+13	RUB	4259.29	
2023-05-19	SNDX	MDEX10	Индекс МосБиржи 10	Индекс МосБиржи 10	4874.70	4904.17	4947.83	4859.76	3.801487e+10	0.0	0.0	2	1.001555e+13	RUB	4259.29	

Рис. 5. Фрагмент фрейма биржевых данных

Данные с пропусками исходя из логики анализа не используются, поэтому их обработка не проводилась. Столбцы, содержащие данные для анализа предварительной обработки не требуют. Отбираем параметры, необходимые для обучения модели, они включают ежедневные исторические цены открытия и цены закрытия, максимальную и минимальную цены, объем торгов. Фрагмент фрейма биржевых данных, которые используются для прогнозирования показан на рисунке 6.

TRADEDATE	CLOSE	OPEN	HIGH	LOW	VALUE
1998-01-06	104.12	100.29	107.50	100.29	4.134117e+07
1998-01-08	98.38	101.92	103.56	98.08	3.004626e+07
2023-05-18	4924.62	4956.94	4968.33	4905.60	2.547142e+10
2023-05-19	4874.70	4904.17	4947.83	4859.76	3.801487e+10

Рис. 6. Фрагмент фрейма биржевых данных для прогнозирования

В основном набор данных для прогнозирования содержит числовые переменные, даты торгов следует использовать в качестве индексов.

3.2 Подготовка данных для модели прогнозирования

Набор данных характеризуется большим разбросом значений. Чтобы устранить влияние масштаба, набор данных был нормализован. Нормализация полезна для ускорения сходимости алгоритма оптимизации и предотвращения «взрыва градиента» при обучении сети. Данные были нормализованы на $[0, 1]$ с использованием нормализации Min-Max; расчетная формула имеет вид:

$$x_i^* = \frac{x_i - x_{min}}{x_{max} - x_{min}}, \quad (27)$$

где x_i – исходные данные;

x_{min} – минимальное значение исходных данных;

x_{max} – максимальное значение исходных данных;

x_i^* – нормализованное значение.

Фрагмент масштабированных биржевых данных показан на рисунке 7.

	CLOSE	OPEN	HIGH	LOW	VALUE
TRADEDATE					
1998-01-06	0.013560	0.015884	0.016912	0.015961	0.000122
1998-01-08	0.012651	0.016142	0.016292	0.015610	0.000089
2023-05-18	0.776886	0.785075	0.781607	0.780734	0.075225
2023-05-19	0.768981	0.776717	0.778382	0.773438	0.112269

Рис. 7. Фрагмент масштабированных биржевых данных

Применение модели прогнозирования к масштабированным данным приводит к тому, что и получаемый результат также будет представлять собой масштабированное значение. Поэтому необходимо выполнить приведение

выходных данных модели к первоначальному масштабу с помощью триггерного процесса. Расчетная формула имеет вид:

$$\hat{y}_i = \hat{y}_i^* \cdot (x_{max} - x_{min}) + x_{min}, \quad (28)$$

где \hat{y}_i^* – нормализованный прогноз цен на акции;

\hat{y}_i – прогнозное значение цены акций, после приведения к первоначальному масштабу.

Работа с временным рядом, как последовательностью наблюдений во времени, требует особого подхода к прогнозированию. В случае неупорядоченных по времени (или другому признаку) данных для перекрестной проверки в процессе обучения модели, а также для проверки качества обученной модели выбирается случайное подмножество данных. Во временных рядах в качестве проверочного набора всегда должны использоваться «более поздние» данные по отношению к тем наблюдениям, на которых обучалась модель.

Существует две схемы разделения данных временного ряда на обучающую и тестовую выборки: «скользящее окно» (sliding window) и «прямая цепочка» (forward chaining), как показано на рисунке 8.

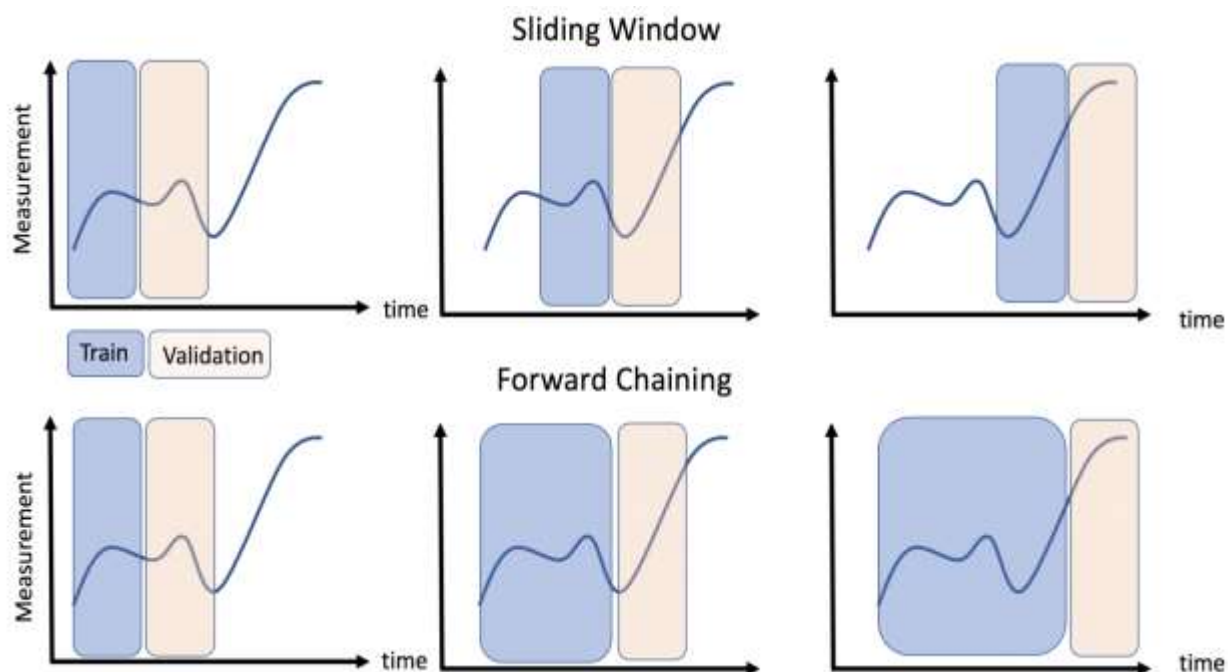


Рис. 8. Схема перекрестной проверки временного ряда

При использовании метода «скользящего окна» обучение происходит на n -точках данных и проверка прогноза на следующих n -точках данных, сдвигая окно на $(2n)$ точек для обучения / проверки во времени для следующего шага. При использовании метода «прямой цепочки» обучение происходит по последним n -точкам данных, а проверка прогноза на следующих m -точках данных, сдвигая окно обучения и проверки на $(n+m)$ точек во времени. В данном исследовании для разделения данных временного ряда на обучающую и тестовую выборки и при обучения модели использована схема «скользящего окна» (sliding window).

Метод скользящего окна – алгоритм трансформации, позволяющий сформировать из членов временного ряда набор данных, который может служить обучающим множеством для построения модели прогнозирования.

Под окном в данном случае понимается временной интервал, содержащий набор значений, которые используются для формирования обучающего примера. В процессе работы алгоритма окно

смещается по временной последовательности на единицу наблюдения, и каждое положение окна образует один пример (рис. 9).




Рис. 9. Метод скользящего окна

Если требуется построить прогноз не на одну единицу наблюдения, а на несколько, то в качестве целевых выбирается соответствующее число значений, которое называется горизонтом прогноза. Количество наблюдений ряда, которые берутся в качестве входных значений называется глубиной прогноза.

Схема предварительной обработки временного ряда биржевых данных в целях подготовки данных для входа в модель показана на рисунке 10.

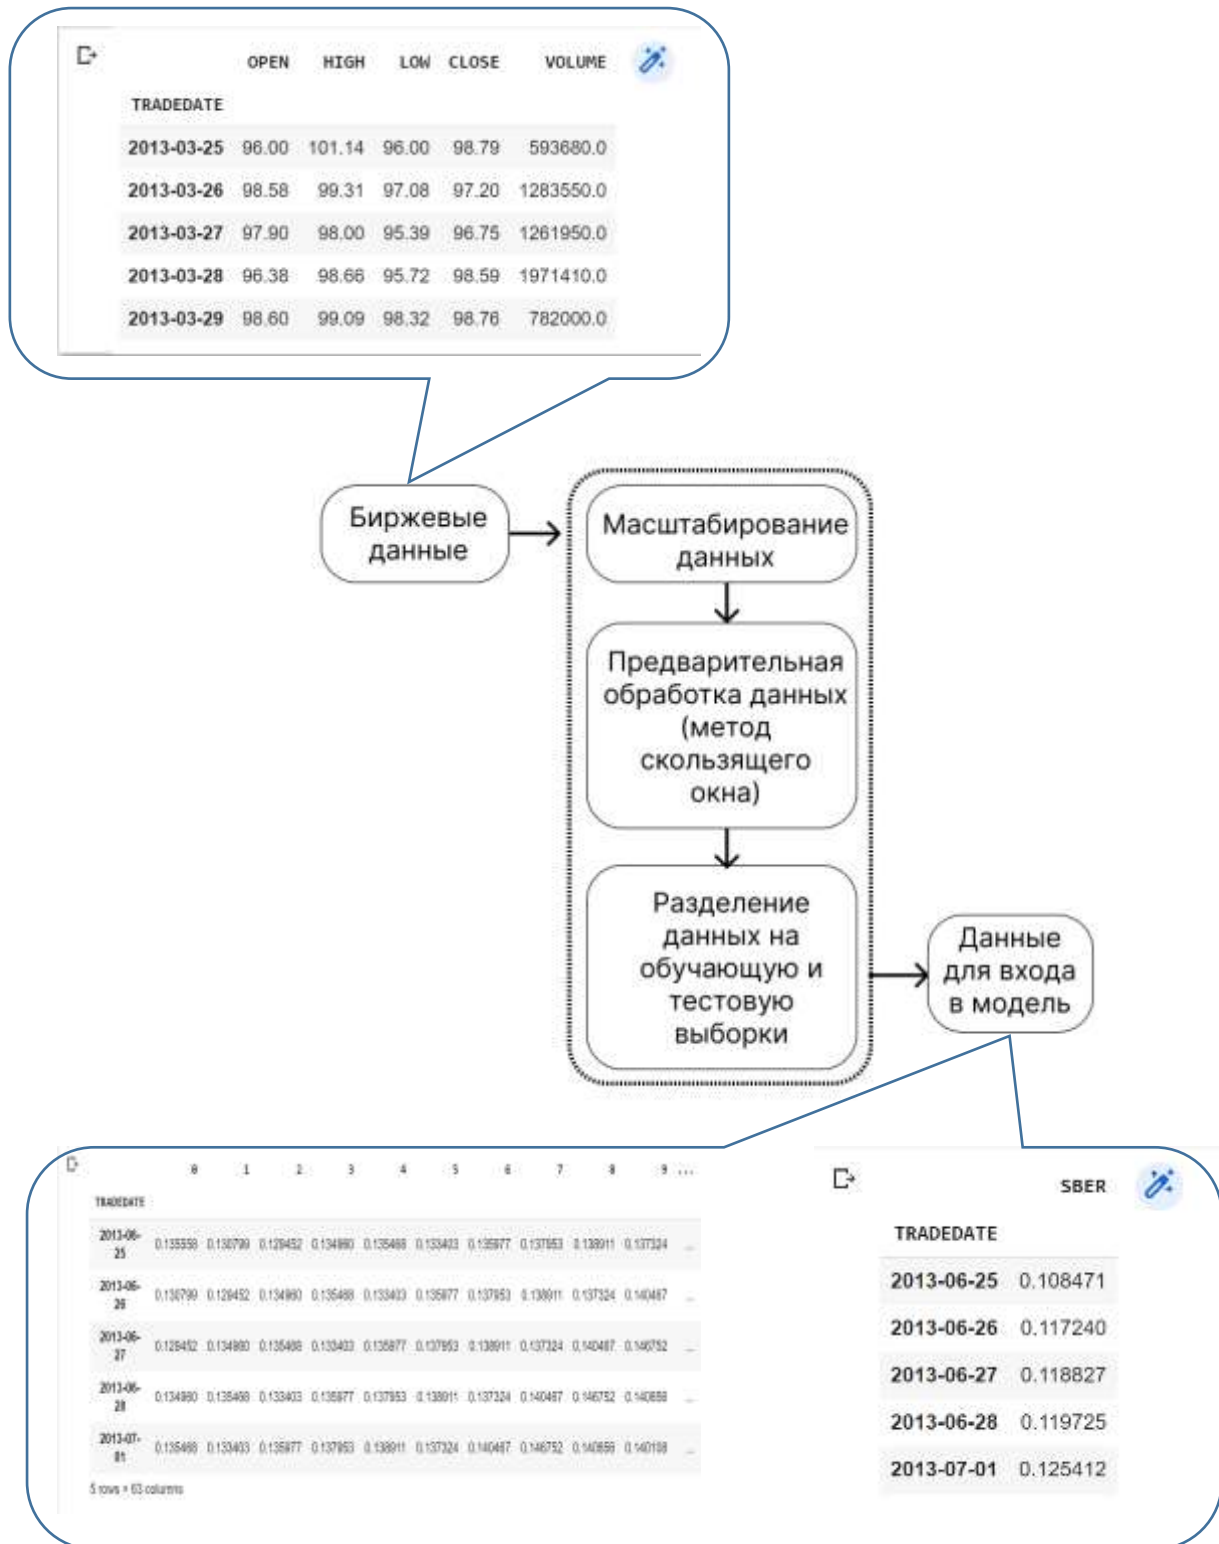


Рис. 10. Схема предварительной обработки временного ряда с примерами
ВХОДНЫХ И ВЫХОДНЫХ ДАННЫХ

Чтобы оценить качество модели используется блок данных в конце временного ряда, который зарезервирован для тестирования обученной модели. Соотношение данных, используемых для обучающего набора и набора тестов составляет 8:2.

3.3 Описание архитектуры модели прогнозирования

Для прогнозирования использована реализация LSTM в Keras [Высокоуровневый API Keras, 2023] Нейронная сеть с долговременной кратковременной памятью (LSTM) – это тип рекуррентной нейронной сети, которая может лучше обрабатывать длинные последовательности ввода, учитывая нелинейный характер временных рядов данных об акциях. Поэтому LSTM широко используется в прогнозировании цен акций из-за исключительного объема памяти и структуры элементов по сравнению с другими рекуррентными нейронными сетями, которые могут запоминать только короткие последовательности.

При построении модели использовалась стратегия прямого одноэтапного прогнозирования. Для изучения внутренней модели динамических изменений слой LSTM обучается на биржевых данных. Затем выходные данные пропускаются через полносвязный слой. Схема обучаемой нейронной сети показана на рисунке 11.




Рис. 11. Схема обучаемой нейронной сети

Начальная архитектура нейронной сети показана на рисунке 12.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
LSTM (LSTM)                  (None, 20)                  1760
Output (Dense)               (None, 1)                   21
-----
Total params: 1,781
Trainable params: 1,781
Non-trainable params: 0
-----

```

Рис. 12. Начальная архитектура обучаемой нейронной сети

На выходном слое использована функция активации `relu`. Решение задачи регрессии обуславливает наличие на выходном слое одного нейрона. Количество обучаемых параметров модели 1781. Несмотря на то, что для прогнозирования используется ИНС глубокого обучения, небольшое количество параметров позволяет обучить модель на имеющемся наборе данных.

Начальные параметры модели прогнозирования цен на финансовом рынке показаны в таблице 4.

Таблица 4

Начальные параметры обучения модели прогнозирования

№ п/п	Название параметра	Значение параметра
1.	Размер «скользящего окна»	63 дня
2.	Количество внутренних слоев LSTM	1
3.	Количество ядер, слой LSTM	20

4.	Функция активации выходного слоя Dense	relu
5.	Оптимизатор	RMSprop
6.	Функция потерь	RMSE
7.	Размер пакета batch_size	50
8.	Количество эпох	500
9.	Количество периодов контрольной точки	5
10.	Количество периодов ранней остановки	25

Изначально слой LSTM содержал 20 ядер, для обучения модели был использован оптимизатор RMSprop. Этот оптимизатор поддерживает скользящее (дисконтированное) среднее значение квадрата градиентов и делит градиент на корень из этого среднего. Алгоритм RMSprop выглядит следующим образом:

$$g_t \leftarrow \nabla \theta_{t-1} f(\theta_{t-1}) \quad (29)$$

$$n_t \leftarrow v n_{t-1} + (1 - v) f g_t^2 \quad (30)$$

$$\theta_t \leftarrow \nabla \theta_{t-1} - \eta \frac{g_t}{\sqrt{n_t + \epsilon}} \quad (31)$$

Оптимизатор использует знак градиента для адаптации размера шага отдельно для каждого веса. Если знаки двух последних градиентов совпадают, то размер шага увеличивается, в противном случае размер шага уменьшается. Реализация RMSprop использует обычный импульс, а не импульс Нестерова.

В качестве функции потерь выбрана среднеквадратичная ошибка (RMSE), подходящая для задачи регрессии. Она рассчитывается с помощью следующей формулы:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}, \quad (32)$$

где y_i – реальная стоимость акций на i момент времени;
 y'_i – прогнозируемая стоимость акций на i момент времени;
 n – общее количество наблюдений в выборке.

Модель прогнозирования цены акций обучалась в течение 500 эпох, размер батча был выбран равным 50. При обучении использовался механизм ранней остановки (контроль качества модели в процессе обучения и прекращение обучения, когда ошибка не уменьшается в течение нескольких эпох). Для нейронной сети задана ранняя остановка обучения с помощью EarlyStopping, который отслеживает уровень потерь на проверочной выборке с задержкой триггера 5 эпох. Веса наилучшей модели сохраняются с помощью ModelCheckpoint через 25 эпох. Это позволяет предотвратить переобучение и сэкономить затраты ресурсов. Графически динамика фактического и прогнозного прироста цены индекса Мосбиржи10 по начальной модели показана на рисунке 13.



Рис. 13. Динамика индекса Мосбиржи10
(факт и прогноз начальной модели)

Таким образом, нейронная сеть LSTM используется для изучения последовательных предварительно обработанных биржевых данных, чтобы использовать долгосрочные зависимости выборочных данных для обучения и выводить результаты прогнозирования цен на акции через полносвязанный слой.

Для оценки качества обучения модели использована средняя абсолютная процентная ошибка (MAPE) рассчитывается с помощью следующей формулы:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{|y_i|} \times 100\%, \quad (33)$$

Точность прогноза обученной модели рассчитывается с помощью следующей формулы:

$$accuracy = 100\% - MAPE \quad (34)$$

Обученная модель с начальными параметрами показала высокую точность 98.92%. Средняя разница между прогнозируемым значением и фактическим значением на тестовой выборке составляет 1.08%.

3.4 Вычислительные эксперименты и их результаты

Для изучения возможности оптимизации модели проводились вычислительные эксперименты по сетке параметров. Поскольку модель при первоначальных параметрах показала хорошие результаты, целью стало сохранение точности прогноза при сокращении затрат вычислительных ресурсов. При этом увеличение количества внутренних слоев не рассматривалось. Параметры, варьируемые в рамках вычислительных экспериментов показаны в Таблице 5.

Варьируемые параметры

№ п/п	Название параметра	Значение параметра
1.	Размер «скользящего окна»	63, 42, 21 дня
2.	Количество ядер, слой LSTM	range(5, 30, 5)
3.	Функция активации выходного слоя Dense	relu, sigmoid, gelu
4.	Оптимизатор	RMSprop, Adam, Nadam
5.	Функция потерь	RMSE, MAE, MAPE
6.	Размер пакета batch_size	range(10, 50, 10)
7.	Количество эпох	range(100, 500, 100)
8.	Количество периодов ранней остановки	range(10, 30, 5)

Размер «скользящего окна» является гиперпараметром модели. Чтобы проверить устойчивость результатов, использованы разные размеры «скользящего окна» (21, 42 и 63 дня) для обучения модели в сочетании с разным количеством ядер на слое LSTM от 5 до 30 с шагом 5. Основные результаты проведенных экспериментов показаны в таблице 6.

Таблица 6

Оценка качества моделей с разным количеством ядер на слое LSTM для разного размера скользящего окна (MAPE, %)

Размер скользящего окна	Количество ядер, слой LSTM	5	10	15	20	25	30
	63 дня		1.04	1.10	1.07	1.08	1.10
42 дня		1.00	1.03	1.11	1.07	1.08	1.05
21 дня		1.11	1.05	1.03	1.01	1.06	1.06

Результаты показали практически неизменное значение функции ошибки, поэтому для экономии вычислительных ресурсов в дальнейшем исследовалась модель с 5 ядрами. Итоговая архитектура модели прогнозирования показана на рисунке 14.

```

↳ Model: "sequential_1"

```

Layer (type)	Output Shape	Param #
LSTM (LSTM)	(None, 5)	140
Output (Dense)	(None, 1)	6

```

=====
Total params: 146
Trainable params: 146
Non-trainable params: 0
=====

```

Рис. 14. Архитектура лучшей модели прогнозирования

Модель отличается высокой устойчивостью точности прогноза. Для экономии вычислительных ресурсов в дальнейших экспериментах используем нейронную сеть с 5 ядрами на слое LSTM для скользящего окна 21 день.

В рамках вычислительных экспериментов, кроме оптимизатора RMSprop использовались также оптимизаторы Adam и Nadam в сочетании с разными функциями активации на выходном слое. Оптимизатор Adam основан на адаптивной оценке моментов первого и второго порядка. Он эффективен в вычислительном отношении, требует мало памяти. Nadam представляет собой Adam с функцией Нестерова. Алгоритм Nadam выглядит следующим образом:

$$g_t \leftarrow \nabla \theta_{t-1} f(\theta_{t-1}) \quad (35)$$

$$\hat{g}_t \leftarrow \frac{g_t}{1 - \prod_{i=1}^t \mu_i} \quad (36)$$

$$m_t \leftarrow \mu m_{t-1} + (1 - \mu) g_t \quad (37)$$

$$\hat{m}_t \leftarrow \frac{m_t}{1 - \prod_{i=1}^{t+1} \mu_i} \quad (38)$$

$$n_t \leftarrow v n_{t-1} + (1 - v) f g_t^2 \quad (39)$$

$$\hat{n}_t \leftarrow \frac{n_t}{1 - v^t} \quad (40)$$

$$\bar{m}_t \leftarrow (1 - \mu_t) \hat{g}_t + \mu_{t+1} \hat{m}_t \quad (41)$$

$$\theta_t \leftarrow \theta_{t-1} - \eta \frac{\bar{m}_t}{\sqrt{\hat{n}_t + \varepsilon}} \quad (42)$$

На качество обученной модели влияет функция активации на выходном слое, в результате работы которой получается результат. Исследование работы разных функций активации также показано в таблице 7.

Таблица 7

Оценка качества моделей с разными оптимизаторами и разными функциями активации на выходном слое (MAPE, %)

Функция активации Оптимизатор	relu	sigmoid	gelu
RMSprop	1.11	3.64	1.12
Adam	1.12	2.89	1.08
Nadam	1.08	3.12	0.98

Вычислительные эксперименты показали, что использовании сигмоидной функции снижает качество модели. Функции relu и gelu показывают практически одинаковый уровень MAPE при использовании разных оптимизаторов, но более высокую скорость обучения показал оптимизатор Nadam (рис. 15).

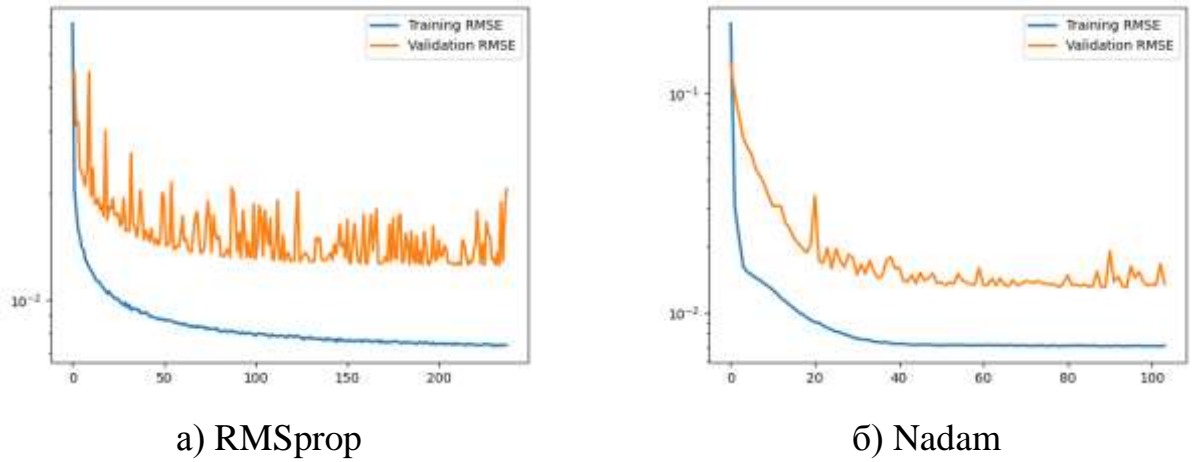


Рис. 15. Графики функции потерь при разных оптимизаторах

Функция *gelu* – гауссова ошибка линейного блока, введена в 2016 г., используется в Google BERT и OpenAI GPT-2. Эта функция активации принимает форму следующего уравнения:

$$GELU(x) = 0.5x \left(1 + \tanh \left(\sqrt{\frac{2}{\pi}} (x + 0.044715x^3) \right) \right) \quad (42)$$

В сочетании с функцией *gelu* оптимизатор Nadam показывает высокую точность до 99.02%. В дальнейших исследованиях для экономии вычислительных ресурсов используем на выходном слое функцию активации *gelu* с оптимизатором Nadam с настройками по умолчанию.

Затем, кроме RMSE (32) исследуем при обучении различные функции потерь также рекомендуемые для регрессии – средняя абсолютная ошибка (MAE) и средняя абсолютная процентная ошибка (MAPE) (33).

Средняя абсолютная ошибка (MAE) рассчитывается с помощью следующей формулы:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i|, \quad (43)$$

где y'_i – прогнозируемая стоимость акций на i момент времени;

y_i – реальная стоимость акций на i момент времени;

n – общее количество наблюдений в выборке.

Итоговая оценка моделей по RMSE, обученных на разных функциях потерь показана в таблице 8.

Таблица 8

Оценка качества моделей с разными функциями потерь при разном размере батча (MAPE, %)

Размер батча Функция потерь	10	20	30	40	50
RMSE	1.16	1.38	1.01	1.04	0.98
MAE	1.09	1.45	1.19	1.32	1.18
MAPE	-	-	-	-	-

Вычислительные эксперименты показали, что использование для обучения других функций потерь не повышает качество модели. Поэтому будем использовать функцию потерь RMSE при размере батча 30.

Мониторинг процесса обучения в рамках вычислительных экспериментов показал, что количество эпох 500 является избыточным. При ранней остановке с помощью EarlyStopping, отслеживающей уровень потерь на проверочной выборке с задержкой триггера 5 эпох процесс обучения не достигал такого числа эпох. В итоговом варианте модели оставлено обучение в течение 200 эпох. Также исследованы разное количество периодов ранней остановки, от 10 до 30 с шагом 5.

Параметры наилучшей модели прогнозирования цен на финансовом рынке показаны в таблице 9.

Параметры наилучшей модели прогнозирования

№ п/п	Название параметра	Значение параметра
1.	Размер «скользящего окна»	21 день
2.	Количество внутренних слоев LSTM	1
3.	Количество ядер, слой LSTM	5
4.	Функция активации выходного слоя Dense	gelu
5.	Оптимизатор	Nadam
6.	Функция потерь	RMSE
7.	Размер пакета batch_size	30
8.	Количество эпох	200
9.	Количество периодов контрольной точки	5
10.	Количество периодов ранней остановки	20

В наилучшей модели слой LSTM содержит 5 нейронов с оптимизатором Nadam, функцией ошибки RMSE. Обучение модели происходит 150 эпох с размером батча, равным 30, с контрольной точкой после 5 эпох и ранней остановкой при отсутствии улучшения контролируемого показателя после 20 эпох. На тестовых данных средняя абсолютная процентная ошибка прогноза модели с указанными параметрами составила 1.01%. Графически фактического и прогнозного динамика индекса Мосбиржи¹⁰ по итоговой модели показана на рисунке 16.



Рис. 16. Динамика индекса Мосбиржи10
(факт и прогноз итоговой модели)

Таким образом, модель с итоговыми параметрами при экономии вычислительных ресурсов и сокращении времени обучения, сохранила небольшую ошибку прогноза на тестовых данных, которая составила 1.01%., точность прогноза 98.99%.

В дальнейшем модель, обученная на данных о индексе MOEX10, использовалась для обучения на данных о ценах отдельных акций, входящих в этот индекс. Модели прогнозирования для акций, обученные с помощью нейронной сети с итоговыми параметрами показали хорошие результаты на тестовых данных, наибольшую ошибку показала модель для прогнозирования цен акций Газпром – 3.62%, наименьшую ошибку дает модель прогнозирования цен акций Магнит – 1.25%. Результаты оценки моделей для отдельных акций на тестовых данных обобщены в таблице 10.

Результаты оценки моделей прогнозирования цен акций в индексе MOEX10

Функция ошибки	Минимум (акции Магнит)	Максимум (акции Газпром)	Среднее значение
MAPE, %	1.25	3.62	2.36

Таким образом, нейронная сеть с итоговыми параметрами позволяет устойчиво обучать модели прогнозирования цен акций с высокой точностью, от 96.38% до 98.75%, в среднем 97.64%. Средняя разница между прогнозируемым значением и фактическим значением на тестовой выборке составляет 2.36%.

ГЛАВА 4. ПОСТРОЕНИЕ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ

4.1 Система поддержки принятия инвестиционных решений на основе модели LSTM, оценка ее качества (LSTM-IR)

Для практического использования важно принятие правильного инвестиционного решения, критерием которого является положительный финансовый результат. Для принятия инвестиционных решений могут быть использованы разные, рассмотренные выше. В дальнейшем с помощью моделирования определим более эффективную модель с точки зрения принятия правильного инвестиционного решения.

С учетом того, что с помощью обученной модели LSTM получен хороший прогноз. Для построения системы принятия инвестиционных решений проверяется гипотеза: принятие инвестиционного решения на основе прогноза цены акции с небольшой ошибкой приводит к положительному финансовому результату.

Фактические значения цены и прогнозные значения после приведения к первоначальному масштабу поступают в логический блок. В результате сравнительного анализа генерируется инвестиционная рекомендация. Схема генерации инвестиционной рекомендации показана на рисунке 17.



Рис. 17. Схема генерации инвестиционных рекомендаций на основе прогноза нейронной сети LSTM

Генерация инвестиционной рекомендации о включении ценных бумаг в портфель (покупке) происходит при выполнении следующего условия:

$$(y'_{i+1} - y_i) > 0, \quad (44)$$

где y'_{i+1} – прогнозируемая стоимость акций на $(i+1)$ момент времени;

y_i – реальная стоимость акций на i момент времени.

При невыполнении этого условия дается рекомендация исключить ценные бумаги из портфеля (продать).

Логический блок работает по алгоритму, который показан на рисунке 18.

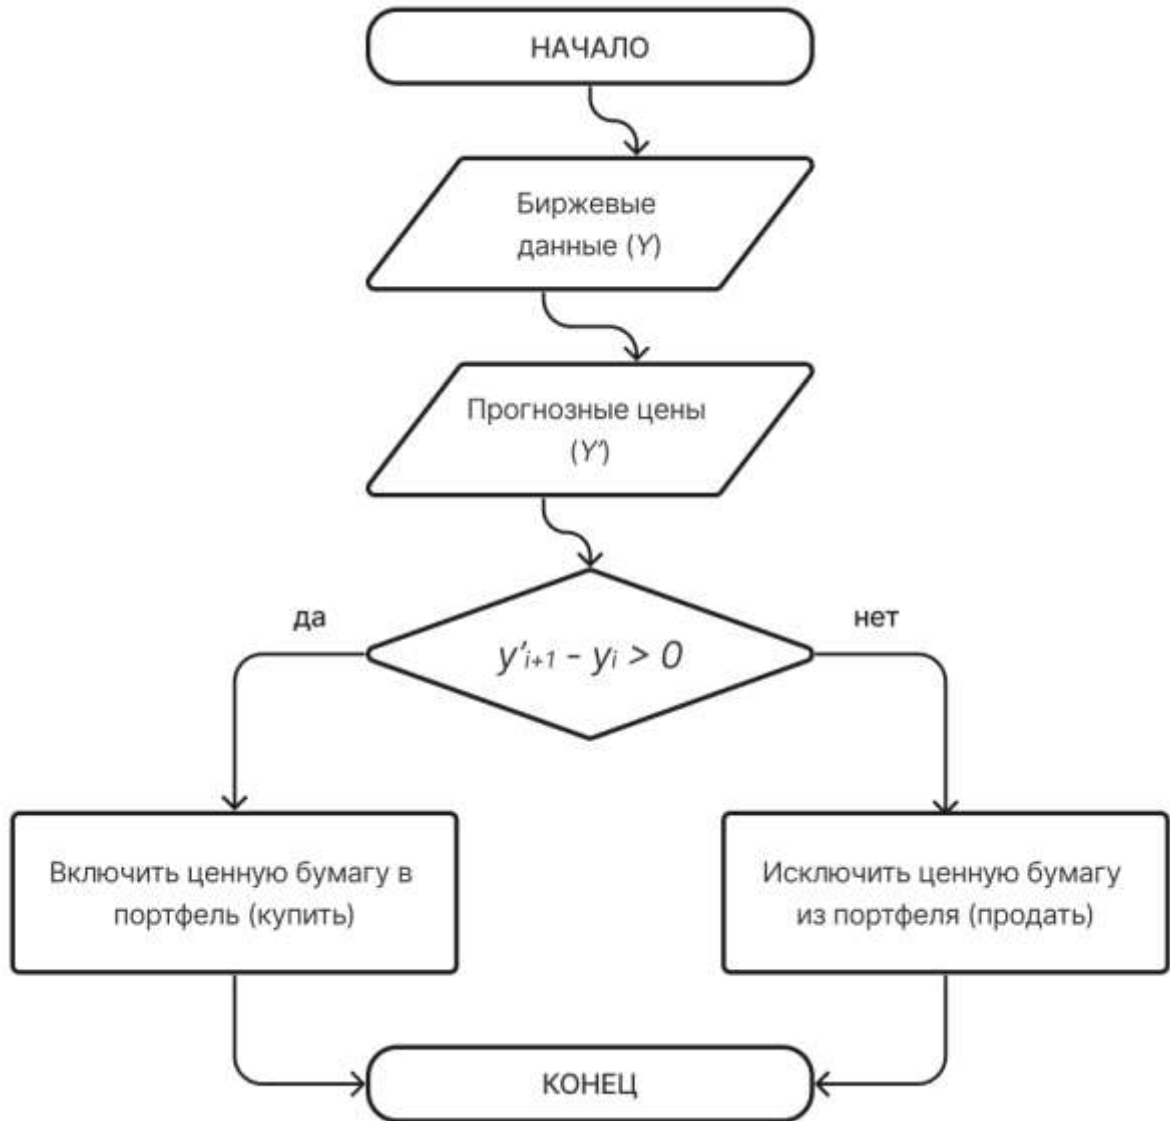


Рис. 18. Алгоритм работы логического блока LSTM-IR

Последовательная реализация прогнозирования с помощью рекуррентной нейронной сети LSTM и генерации инвестиционной рекомендации с помощью логического блока формирует систему поддержки принятия инвестиционных решений (LSTM-IR).

Вычислительные эксперименты показали, что принятие инвестиционных решений по портфелю MOEX10_LSTM, опираясь на прогноз цены, сгенерированной нейронной сетью не приводит к положительному финансовому результату, что показано на рисунке 19.



Рис. 19. Динамика роста индекса MOEX10 и портфеля MOEX10_LSTM

Такая инвестиционная стратегия не повышает эффективность инвестирования в сравнении с эталонной индексной стратегией инвестирования «купи и держи» в MOEX10. Показатели качества инвестиционных портфелей MOEX10 и MOEX10_LSTM представлены в таблице 11.

Таблица 11

Метрики качества инвестиционных портфелей MOEX10 и MOEX10_LSTM

Инвестиционный портфель	Средняя доходность, % годовых	Риск, %	Коэффициент Шарпа
MOEX10_LSTM	3.91	52.40	0.0746
MOEX10	5.37	90.85	0.0591
Отклонение	-1.46	-38.45	0.0155

Портфель MOEX10_LSTM ожидаемо в среднем показал меньшую доходность 3.91% против 5.37% годовых индексного портфеля MOEX10. Одновременно инвестирование в портфель MOEX10_LSTM было связано с

меньшим риском – среднегодовая волатильность 52.40% против 90.85% для индексного портфеля MOEX10. В результате коэффициент Шарпа, учитывающий в комплексе доходность и риск инвестирования, выше у портфеля MOEX10_LSTM на 0.0155.

Однако, принимая во внимание, что для инвестора основной целью является рост инвестированного капитала, систему принятия инвестиционных решений на основе прогнозов нейронной сети нельзя признать хорошей. Прирост капитала MOEX10_LSTM, инвестированного согласно рекомендациям за анализируемый период составил 39.4% против 57.3% прироста индексного портфеля MOEX10.

4.2 Система поддержки принятия инвестиционных решений на основе модели DMI, оценка ее качества (DMI-IR)

В качестве решения вопроса эффективности инвестиционного алгоритма рассмотрим генерацию инвестиционных решений по управлению портфелем акций на основе стратегии Dual Momentum Investing (DMI), которая описана выше.

В таком случае генерация инвестиционной рекомендации о включении ценной бумаги в портфель (покупке) происходит при одновременном выполнении двух условий. Первое условие, выражается следующей формулой:

$$A_i > 0, \quad (23)$$

где A_i – доходность акций за период k на i момент времени.

Доходность акции за период k рассчитывается по следующей формуле:

$$A_i = \frac{y_i}{y_{i-k}} - 1, \quad (24)$$

где y_i – реальная стоимость акций на i момент времени;

y_{i-k} – реальная стоимость акций на $(i-k)$ момент времени.

При невыполнении этого условия дается рекомендация исключить ценную бумагу из портфеля (продать).

Если условие (23) выполняется, то проверяется второе условие:

$$A_i > M_i, \quad (25)$$

где M_i – доходность индекса за период k на i момент времени.

$$M_i = \frac{z_i}{z_{i-k}} - 1, \quad (26)$$

где z_i – реальная стоимость индекса на i момент времени;

z_{i-k} – реальная стоимость индекса на $(i-k)$ момент времени.

При выполнении этого условия дается рекомендация включить ценную бумагу в портфеля (купить), а при его невыполнении дается рекомендация исключить ценную бумагу из портфеля (продать).

Логический блок в таком случае работает по алгоритму, который показан на рисунке 20.

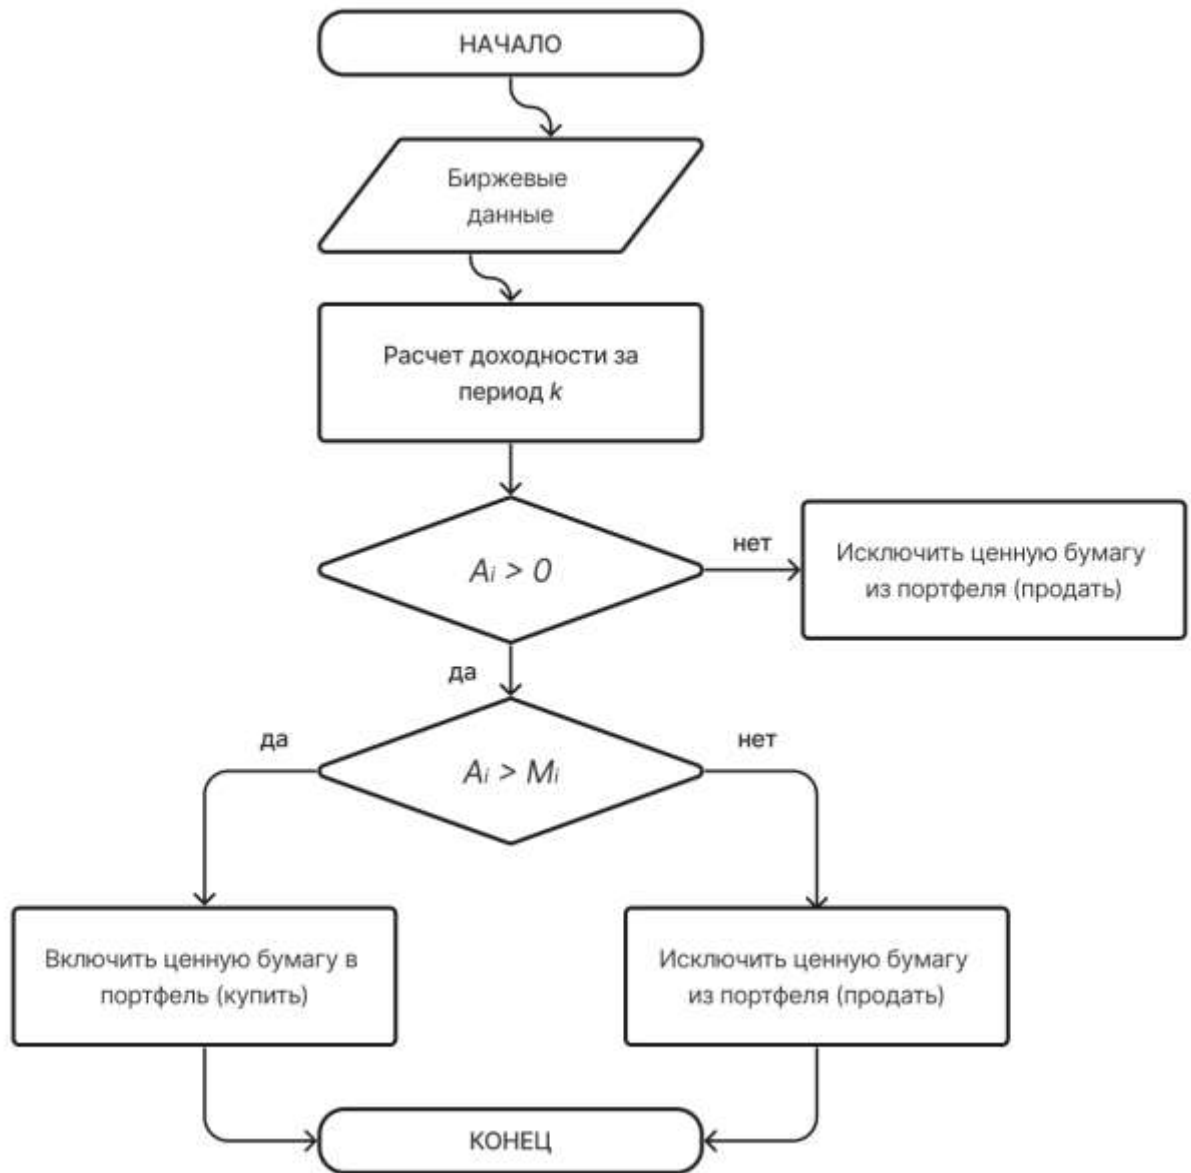


Рис. 20. Алгоритм работы логического блока DMI-IR

В вычислительных экспериментах использованы разные периоды $k = \{1, 5, 11, 16, 21, 42, 63\}$ для расчета доходности при генерации инвестиционных рекомендаций по модели DMI. Основные результаты проведенных экспериментов показаны в таблице 12.

Метрики качества инвестиционных портфелей Portfolio_DMI для разных периодов доходности

Период доходности	Прирост капитала, %	Средняя доходность, % годовых	Риск, %	Коэффициент Шарпа
1 день	241.31	14.91	268.02	0.0556
5 дней	213.99	13.86	285.58	0.0485
11 дней	209.05	13.69	258.47	0.0530
16 дней	259.82	15.71	286.63	0.0548
21 день	231.96	14.69	293.01	0.0501
42 дня	274.34	16.44	342.34	0.0480
63 дня	233.61	15.06	278.19	0.0541

Вычислительные эксперименты показали, что принятие инвестиционных решений, опираясь на модель DMI стабильно приводит к положительному финансовому результату. За анализируемый период, при разных периодах доходности, на основе которой генерировались инвестиционные рекомендации, прирост капитала составлял от 209.05% до 274.34%, что показало среднюю ежегодную доходность от 13.69% до 16.44%. получение более высокой доходности ожидаемо связано с принятием на себя инвестором более высокого риска от 258.47% до 342.19%.

Инвестиционная стратегия Portfolio_DMI на основе абсолютного и относительного импульса за 42 торговых дня повышает эффективность инвестирования в сравнении с эталонной индексной стратегией инвестирования «купи и держи» MOEX10. Прирост капитала, инвестированного согласно рекомендациям за анализируемый период составил 274.34% против 57.30% прироста индексного портфеля MOEX10. Изменение стоимости индексного

портфеля MOEX10 и портфеля из акций, входящих в этот индекс, управляемого в соответствии с инвестиционными рекомендациями системы Portfolio_DMI показано на рисунке 21.



Рис. 21. Динамика роста индекса MOEX10 и Portfolio_DMI

Показатели эффективности разработанной системы поддержки инвестиционных решений в сравнении с индексной инвестиционной стратегией представлены в таблице 13.

Таблица 13

Метрики качества инвестиционных портфелей MOEX10 и Portfolio_DMI

Инвестиционный портфель	Средняя доходность, % годовых	Риск, %	Коэффициент Шарпа
Portfolio_DMI	16.44	342.34	0.0480
MOEX10	5.37	90.85	0.0591
Отклонение	11.07	251.49	-0.0111

Инвестиционный портфель Portfolio_DMI в среднем показал ежегодную доходность, которая более, чем в 3 раза превысила доходность индексного портфеля MOEX10, 13.86% против 5.37%. Одновременно инвестирование в портфель Portfolio_DMI было связано с большим риском – среднегодовая волатильность 342.34% против 90.85% для индексного портфеля MOEX10. В результате инвестиционный портфель Portfolio_DMI показал коэффициент Шарпа 0.0480 против 0.0591 для индексного портфеля MOEX10. Принимая во внимание, что основной целью инвестора является рост инвестированного капитала при приемлемом уровне, систему принятия инвестиционных решений на основе модели DMI можно признать хорошей. В зависимости от индивидуального отношения к риску инвестора может выбрать подходящую ему инвестиционную стратегию.

4.3 Система поддержки принятия инвестиционных решений на основе прогноза нейронной сети LSTM и модели DMI, оценка ее качества (LSTM-DMI-IR)

В работе исследовано совместное применение для генерации инвестиционных рекомендаций прогнозирования цен нейронной сетью LSTM и модели DMI. В таком случае генерация инвестиционной рекомендации о включении ценной бумаги в портфель (покупке) происходит при одновременном выполнении двух условий. Первое условие, выражается следующей формулой:

$$A'_i > 0, \quad (27)$$

где A'_i – прогнозная доходность акций за период k на i момент времени.

Прогнозная доходность акции за период k рассчитывается по следующей формуле:

$$A'_i = \frac{y'_{i+1}}{y'_{i-k+1}} - 1, \quad (28)$$

где y'_{i+1} – прогнозная стоимость акций на $(i+1)$ момент времени;
 y'_{i-k+1} – прогнозная стоимость акций на $(i-k+1)$ момент времени.

При невыполнении этого условия дается рекомендация исключить ценную бумагу из портфеля (продать).

Если условие (27) выполняется, то проверяется второе условие:

$$A'_i > M'_i, \quad (29)$$

где M'_i – прогнозная доходность индекса за период k на i момент времени.

$$M'_i = \frac{z'_{i+1}}{z'_{i-k+1}} - 1, \quad (30)$$

где z'_{i+1} – прогнозная стоимость индекса на $(i+1)$ момент времени;
 z'_{i-k+1} – прогнозная стоимость индекса на $(i-k+1)$ момент времени.

При выполнении этого условия дается рекомендация включить ценную бумагу в портфеля (купить), а при его невыполнении дается рекомендация исключить ценную бумагу из портфеля (продать).

Логический блок в таком случае работает по алгоритму, который показан на рисунке 22.

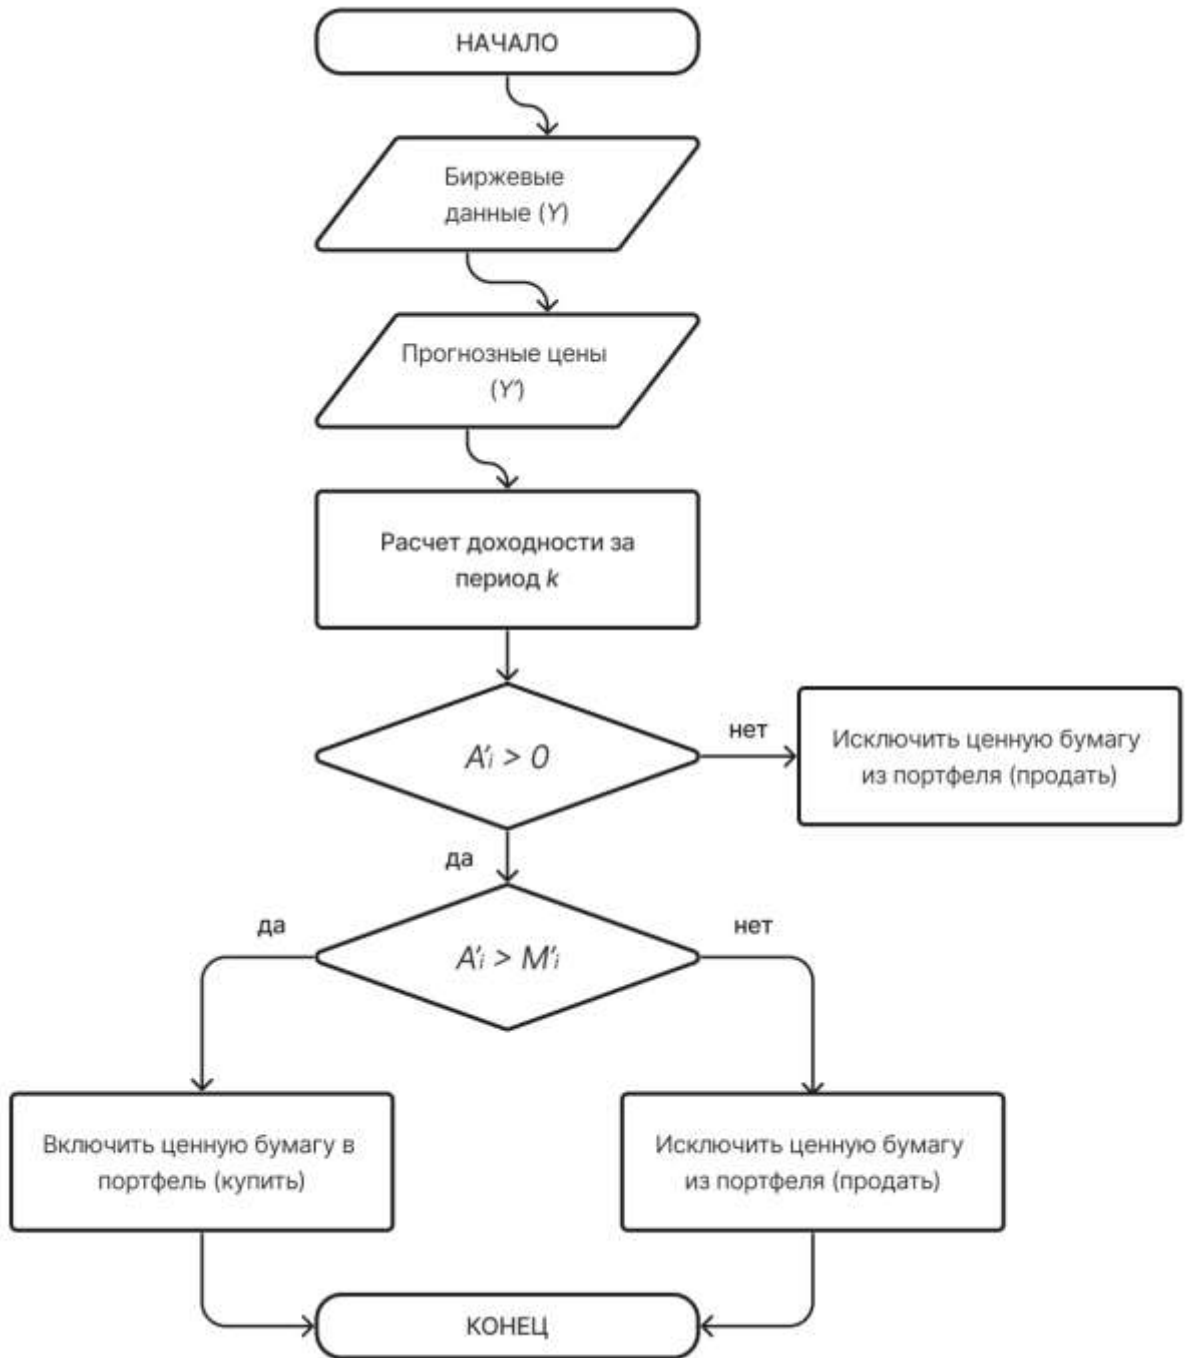


Рис. 22. Алгоритм работы логического блока LSTM-DMI-IR

Вычислительные эксперименты показали, что принятие инвестиционных решений на основе LSTM-DMI-IR стабильно приводит к положительному финансовому результату. Изменение стоимости индексного портфеля MOEX10 и портфеля из акций, входящих в этот индекс, управляемого в соответствии с

инвестиционными рекомендациями системы Portfolio_LSTM_DMI показано на рисунке 23.



Рис. 23. Динамика роста индекса MOEX10, Portfolio_DMI и Portfolio_LSTM_DMI

Инвестиционная стратегия Portfolio_LSTM_DMI на основе двойного импульса за 42 торговых дня повышает эффективность инвестирования в сравнении с эталонной индексной стратегией инвестирования «купи и держи» MOEX10. Прирост капитала, инвестированного согласно рекомендациям за анализируемый период составил 279.38% против 57.30% прироста индексного портфеля MOEX10, что показало среднюю ежегодную доходность 16.80% против 5.37%. Получение более высокой доходности ожидаемо связано с принятием на себя инвестором более высокого риска 343.86% против 90.85% (табл. 14).

Метрики качества инвестиционных портфелей Portfolio_LSTM_DMI,
Portfolio_DMI и MOEX10

Период доходности	Прирост капитала, %	Средняя доходность, % годовых	Риск, %	Коэффициент Шарпа
Portfolio_LSTM_DMI	279.38	16.80	343.86	0.0489
Portfolio_DMI	274.34	16.44	342.34	0.0480
MOEX10	57.30	5.37	90.85	0.0591

Результаты принятия инвестиционных решений на основе LSTM-DMI-IR превосходят результаты инвестиционных решений на основе DMI-IR незначительно, в среднем на 0.36% годовых, что за анализируемый период обеспечило дополнительный прирост капитала на 5.04%. По сравнению с системой принятия инвестиционных решений на индексной основе MOEX10 инвестиционные решения на основе LSTM-DMI-IR за анализируемый период показали дополнительный прирост капитала в размере 222.08%, т.е. дополнительно в среднем по 11.43% ежегодно.

Таким образом, построена система поддержки принятия инвестиционных решений на финансовом рынке, использование которой может повысить эффективность портфельного менеджмента.

ГЛАВА 5. ОЦЕНКА УСТОЙЧИВОСТИ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ

5.1 Оценка качества LSTM-DMI-IR на разных инвестиционных горизонтах

Для инвестора важна устойчивость результатов инвестирования. Чтобы проверить устойчивость работы системы поддержки принятия инвестиционных решений, проверяется гипотеза: принятие инвестиционных решений в соответствии с рекомендациями системы приводит к положительному финансовому результату на разных инвестиционных горизонтах.

В вычислительных экспериментах использованы разные инвестиционные горизонты от 3 до 10 лет для LSTM-DMI-IR в сравнении с DMI-IR и индексным портфелем MOEX10. Изменение средней годовой доходности разных инвестиционных портфелей в зависимости от длины инвестиционного горизонта показано на рисунке 24.




Рис. 24. Изменение средней доходности индекса MOEX10, Portfolio_DMI и Portfolio_LSTM_DMI в зависимости от горизонта инвестирования

Вычислительные эксперименты показали, что принятие инвестиционных решений на основе рекомендаций LSTM-DMI-IR и DMI-IR в среднем повышает годовую доходность инвестирования на 6.52%-6.82% на любом инвестиционном горизонте от 3 до 10 лет.

Изменение инвестиционного риска разных портфелей в зависимости от длины инвестиционного горизонта показано на рисунке 25.




Рис. 25. Изменение инвестиционного риска индекса MOEX10, Portfolio_DMI и Portfolio_LSTM_DMI в зависимости от горизонта инвестирования

Вычислительные эксперименты показали, что инвестиционные решения по рекомендациям LSTM-DMI-IR и DMI-IR требуют принятия более высокого риска, чем индексное инвестирование после 6-летнего периода. Однако повышение риска компенсируется более высокой доходностью, что показывает коэффициент Шарпа (рис. 26).

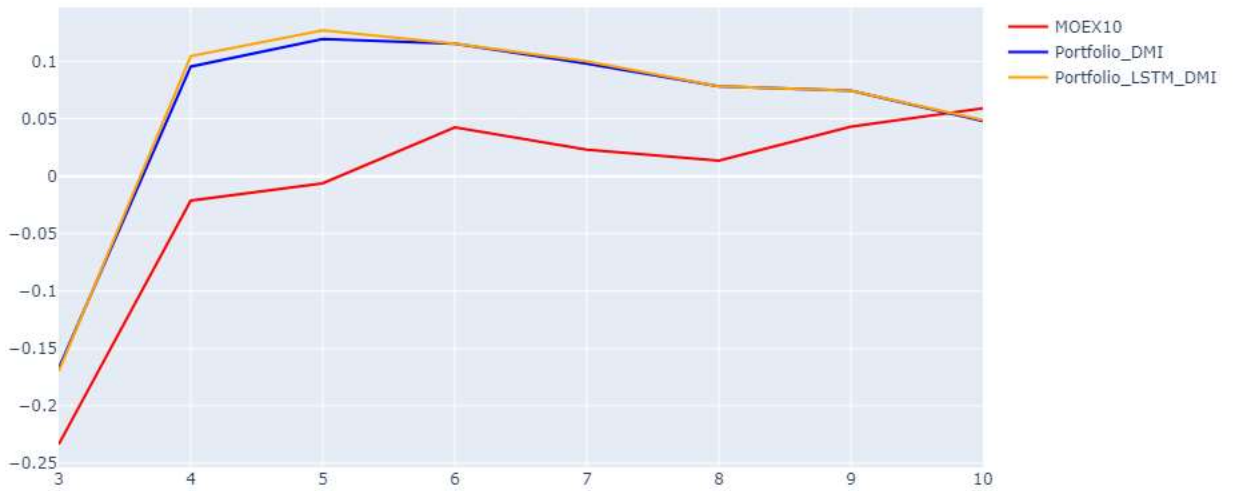


Рис. 26. Изменение коэффициента Шарпа индекса MOEX10, Portfolio_DMI и Portfolio_LSTM_DMI в зависимости от горизонта инвестирования

Практически на любом горизонте инвестирования от 3 до 10 лет, принимая решения на основе рекомендаций систем LSTM-DMI-IR и DMI-IR, инвестор за дополнительный риск получает более высокую доходность.

Таким образом, разработанная система принятия инвестиционных решений дает положительные финансовые результаты на разных горизонтах инвестирования.

5.2 Оценка качества LSTM-DMI-IR с разными начальными точками инвестирования при трехлетнем инвестиционном горизонте

Проверим устойчивость работы системы поддержки принятия инвестиционных решений при изменении начала процесса инвестирования. Для этого проверяется гипотеза: принятие инвестиционных решений в соответствии с рекомендациями системы приводит к положительному финансовому результату независимо от начала инвестирования при трехлетнем инвестиционном горизонте.

В вычислительных экспериментах использованы разные точки начала трехлетних инвестиций с интервалом в один год для LSTM-DMI-IR в сравнении с DMI-IR и индексным портфелем MOEX10. Основные результаты проведенных экспериментов по средней годовой доходности портфелей показаны в таблице 15.

Таблица 15

Основные статистики средней доходности портфелей с 3-летним горизонтом инвестирования, % годовых

Показатель	Portfolio_LSTM_DMI	Portfolio_DMI	MOEX10
Среднее значение	9.43	9.26	2.94
Минимум	-5.16	-4.94	-13.87
Максимум	21.85	21.88	12.23
Стандартное отклонение	8.47	8.44	8.84

Вычислительные эксперименты показали, что принятие инвестиционных решений на основе рекомендаций LSTM-DMI-IR и DMI-IR в среднем повышает годовую доходность в 3.2 раза независимо от начальной точки 3-летнего инвестирования. При этом минимальная доходность (максимальная просадка) портфелей за год в 2.7 раза меньше, чем потери инвестора при индексном инвестировании в MOEX10.

Основные результаты проведенных экспериментов по риску портфелей показаны в таблице 16.

Основные статистики риска портфелей с 3-летним горизонтом инвестирования,
%

Показатель	Portfolio_LSTM_DMI	Portfolio_DMI	MOEX10
Среднее значение	52.61	51.65	44.08
Минимум	30.4	29.55	18.06
Максимум	123.49	120.33	72.02
Стандартное отклонение	32.75	31.93	19.75

Вычислительные эксперименты показали, что принятие инвестиционных решений на основе рекомендаций LSTM-DMI-IR и DMI-IR повышая годовую доходность в среднем в 3.2 раза, также требует в среднем более высокого риска, в 1.2 раза, по сравнению с индексом MOEX10, независимо от начальной точки 3-летнего инвестирования. При этом портфели Portfolio_LSTM_DMI и Portfolio_DMI по риску и доходности отличаются незначительно.

Основные результаты проведенных экспериментов по значению коэффициента Шарпа портфелей показаны в таблице 17.

Основные статистики коэффициента Шарпа портфелей с 3-летним горизонтом инвестирования

Показатель	Portfolio_LSTM_DMI	Portfolio_DMI	MOEX10
Среднее значение	0.1636	0.1616	0.1017
Минимум	-0.1698	-0.1672	-0.2335
Максимум	0.2939	0.3047	0.2666
Стандартное отклонение	0.1595	0.1589	0.1753

Вычислительные эксперименты показали, что управление портфелями Portfolio_LSTM_DMI и Portfolio_DMI на основе инвестиционных рекомендаций разработанной системы более эффективно, инвестор получает более высокую доходность, в среднем 0.1616 и 0.1636, на единицу риска, тогда как за каждую единицу риска при вложении в индекс MOEX10 по стратегии «купи и держи» инвестор в среднем получал доходности 0.1017.

Также, руководствуясь инвестиционными рекомендациями, инвестор действовал более эффективно не только в самый лучший, но и в самый худший 3-летний период.

Таким образом, принятие инвестиционных решений в соответствии с рекомендациями системы приводит к положительному финансовому результату независимо от начала инвестирования при трехлетнем инвестиционном горизонте.

В целом созданная система поддержки принятия инвестиционных решений на финансовом рынке позволяет устойчиво иметь более высокую эффективность управления портфелем ценных бумаг.

ЗАКЛЮЧЕНИЕ

В данной исследовательской работе были детально разобраны предметная область, инвестиционные решения, критерии их оценки, методы анализа, используемые на финансовом рынке для принятия инвестиционных решений, рассмотрены методы прогнозирования цен как временных рядов, проанализированы классические методы машинного обучения, а также методы глубокого обучения, доступные для решения задачи прогнозирования стоимости ценных бумаг.

Проведены вычислительные эксперименты для определения лучших параметров рекуррентной нейронной сети с архитектурой LSTM для прогнозирования цен акций (оптимизатор, функция ошибки, размер скользящего окна, функция активации, размер batch-size). В результате получена модель с устойчивой высокой точностью прогнозирования 98.99%.

Реализация алгоритма генерации инвестиционных рекомендаций на основе прогноза цен акций показала, что этот алгоритм не позволяет решить поставленную задачу. Эффективность системы поддержки принятия инвестиционных решений оказалась ниже эффективности стратегией «купи и держи» при вложении в эталонный индексный портфель.

После получения неудачных результатов был изменен алгоритм принятия инвестиционных решений на управление портфелем акций в рамках стратегии Dual Momentum Investing. Реализация данного алгоритма на фактических исторических данных показала положительный результат, увеличение инвестированного капитала в 3 раза, по сравнению с эталонным ростом инвестиционного капитала в 1,5 раза.

Использование алгоритма Dual Momentum Investing на прогнозных ценах, полученных с помощью обученной модели с архитектурой LSTM показало хороший результат поддержки инвестиционных решений, позволил улучшить инвестиционный результата, обеспечив рост инвестированного капитала в 3,5 раза.

Подводя итог, можно сделать вывод, что поставленная задача успешно решена. Разработанная система может применяться для поддержки принятия инвестиционных решений на финансовом рынке.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Antonacci G. Dual Momentum Investing: An Innovative Strategy for Higher Returns with Lower Risk 1st Edition. - Publisher : McGraw Hill, 2014. – 240 p.
2. Baccouche M., F. Mamalet, C Wolf, C. Garcia, A. Baskurt. Sequential Deep Learning for Human Action Recognition. 2nd International Workshop on Human Behavior Understanding (HBU), A.A. Salah, B. Lepri ed. Amsterdam, Netherlands. pp. 29-39. Lecture Notes in Computer Science 7065. Springer. 2011
3. Box G.E.-P., Jenkins G.M., Reinsel G.C., Ljung G.M. (2016). Time series analysis : forecasting and control (5th ed.). Hoboken, New Jersey: John Wiley & Sons, Incorporated. p. 53.
4. Chung, Junyoung; Gulcehre, Caglar; Cho, KyungHyun & Bengio, Yoshua (2014), Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, arXiv:1412.3555 (дата обращения: 17.05.2023)
5. Cruse, Holk; Neural Networks as Cybernetic Systems Архивная копия от 20 октября 2016 на Wayback Machine, 2nd and revised edition.
6. Dwivedi, S.A.; Attry, A.; Parekh, D.; Singla, K. Analysis and forecasting of Time-Series data using S-ARIMA, CNN and LSTM. In Proceedings of the 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS), Greater Noida, India, 19–20 February 2021; pp. 131–136;
7. Eck D.and J. Schmidhuber. Learning The Long-Term Structure of the Blues. In J. Dorransoro, ed., Proceedings of Int. Conf. on Artificial Neural Networks ICANN'02, Madrid, pages 284—289, Springer, Berlin, 2002.

8. Elman, Jeffrey L. Finding Structure in Time (неопр.) // Cognitive Science. — 1990. — Т. 14, № 2. — С. 179—211. — doi:10.1016/0364-0213(90)90002-E (дата обращения: 17.05.2023)
9. Felix A. Gers; Jürgen Schmidhuber; Fred Cummins. Learning to Forget: Continual Prediction with LSTM // Neural Computation : journal. — 2000. — Vol. 12, no. 10. — P. 2451—2471. — doi:10.1162/089976600300015015.
10. Fernandez S., A. Graves, J. Schmidhuber. An application of recurrent neural networks to discriminative keyword spotting. Intl. Conf. on Artificial Neural Networks ICANN'07, 2007.
11. Gers, F. A.; Schmidhuber, J. LSTM Recurrent Networks Learn Simple Context Free and Context Sensitive Languages (англ.) // IEEE Transactions on Neural Networks : journal. — 2001. — Vol. 12, no. 6. — P. 1333—1340. — doi:10.1109/72.963769.
12. Gers, F.; Schraudolph, N.; Schmidhuber, J. Learning precise timing with LSTM recurrent networks (англ.) // Journal of Machine Learning Research : journal. — 2002. — Vol. 3. — P. 115—143.
13. Graves A., J. Schmidhuber. Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks. Advances in Neural Information Processing Systems 22, NIPS'22, pp 545—552, Vancouver, MIT Press, 2009.
14. Graves A., M. Liwicki, S. Fernandez, R. Bertolami, H. Bunke, J. Schmidhuber. A Novel Connectionist System for Improved Unconstrained Handwriting Recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 31, no. 5, 2009.
15. Graves A., S. Fernandez, M. Liwicki, H. Bunke, J. Schmidhuber. Unconstrained online handwriting recognition with recurrent neural networks. Advances in Neural Information Processing Systems 21, NIPS'21, pp 577—584, 2008, MIT Press, Cambridge, MA, 2008

16. Graves, A.; Schmidhuber, J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures // *Neural Networks : journal.* — 2005. — Vol. 18, no. 5—6. — P. 602—610. — doi:10.1016/j.neunet.2005.06.042.
17. Graves, Alex; Mohamed, Abdel-rahman; Hinton, Geoffrey. Speech Recognition with Deep Recurrent Neural Networks (англ.) // *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on : journal.* — 2013. — P. 6645—6649.
18. Hochreiter S. Untersuchungen zu dynamischen neuronalen Netzen. Diploma thesis, Institut f. Informatik, Technische Univ. Munich, 1991.
19. Hochreiter S., Y. Bengio, P. Frasconi, and J. Schmidhuber. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. In S. C. Kremer and J. F. Kolen, editors, *A Field Guide to Dynamical Recurrent Neural Networks*. IEEE Press, 2001.
20. Hochreiter, S.; Heusel, M.; Obermayer, K. Fast model-based protein homology detection without alignment // *Bioinformatics : journal.* - 2007. - Vol. 23, no. 14. - P. 1728-1736. doi:10.1093/bioinformatics/btm247. — PMID 17488755.
21. Hochreiter, S.; Schmidhuber, J. Long Short-Term Memory. *Neural Comput.* 1997, 9, 1735–1780.
22. Ince, H.; Trafalis, T.B. Kernel principal component analysis and support vector machines for stock price prediction. In *Proceedings of the 2004 IEEE International Joint Conference on Neural Networks, Budapest, Hungary, 25–29 July 2004*; IEEE Cat. No. 04CH37541; Volume 3, pp. 2053–2058.
23. Jordan, Michael I. Serial Order: A Parallel Distributed Processing Approach (англ.) // *Advances in Psychology : journal.* — 1997. — 1 January (vol. 121). — P. 471—495. — doi:10.1016/s0166-4115(97)80111-2 (дата обращения: 17.05.2023)

24. Klaus Greff; Rupesh Kumar Srivastava; Jan Koutník; Bas R. Steunebrink & Jürgen Schmidhuber (2015), LSTM: A Search Space Odyssey, arXiv:1503.04069.
25. Lu, W.; Li, J.; Li, Y.; Sun, A.; Wang, J. A cnn-lstm-based model to forecast stock prices. *Complexity* 2020, 2020, 1–10
26. Mayer H., F. Gomez, D. Wierstra, I. Nagy, A. Knoll, and J. Schmidhuber. A System for Robotic Heart Surgery that Learns to Tie Knots Using Recurrent Neural Networks. *Advanced Robotics*, 22/13-14, pp. 1521—1537, 2008.
27. Moghar, A.; Hamiche, M. Stock market prediction using LSTM recurrent neural network. *Procedia Comput. Sci.* 2020, 170, 1168–1173.
28. Moghar, A.; Hamiche, M. Stock market prediction using LSTM recurrent neural network. *Procedia Comput. Sci.* 2020, 170, 1168–1173]
29. Parmar, K.; Singh, S.; Kumar, J. Soft computing models coupled with statistical models estimate the future of the stock market. *Neural Comput. Appl.* 2021, 33, 7629–7647;
30. Perez-Ortiz, J. A.; Gers, F. A.; Eck, D.; Schmidhuber, J. Kalman filters improve LSTM network performance in problems unsolvable by traditional recurrent nets // *Neural Networks : journal.* — 2003. — Vol. 16, no. 2. — P. 241—250. — doi:10.1016/s0893-6080(02)00219-8.
31. Recurrent Neural Network Tutorial, Part 4 – Implementing a GRU/LSTM RNN with Python and Theano – WildML. Дата обращения: 18 мая 2016. Архивировано 27 октября 2015 года.
32. Schmidhuber J. and D. Wierstra and F. J. Gomez. Evolino: Hybrid Neuroevolution / Optimal Linear Search for Sequence Learning. *Proceedings of the 19th International Joint Conference on Artificial Intelligence (IJCAI)*, Edinburgh, pp. 853—858, 2005.
33. Schmidhuber, J.; Gers, F.; Eck, D.; Schmidhuber, J.; Gers, F. Learning nonregular languages: A comparison of simple recurrent networks and

- LSTM (АНГЛ.) // *Neural Computation : journal.* — 2002. — Vol. 14, no. 9. — P. 2039—2041. — doi:10.1162/089976602320263980.
34. Schmidhuber, J.; Wierstra, D.; Gagliolo, M.; Gomez, F. Training Recurrent Networks by Evolino // *Neural Computation* — 2007. — Vol. 19, no. 3. — P. 757—779. — doi:10.1162/neco.2007.19.3.757.
 35. Sepp Hochreiter; Jürgen Schmidhuber. Long short-term memory (АНГЛ.) // *Neural Computation : journal.* — 1997. — Vol. 9, no. 8. — P. 1735—1780. — doi:10.1162/neco.1997.9.8.1735.
 36. Shumway R.H. (2000). Time series analysis and its applications. David S. Stoffer. New York: Springer. pp. 90–91.
 37. Statsmodels.tsa.ar_model.AutoReg – Statsmodels 0.12.2 documentation. www.statsmodels.org.
 38. Sun, L.; Xu, W.; Liu, J. Two-channel attention mechanism fusion model of stock price prediction based on cnn-lstm. *ACM Trans. Asian -Low-Resour. Lang. Inf. Process.* 2021, 20, 1–12.
 39. Sun, Y.; Sun, Q.; Zhu, S. Prediction of Shanghai stock index based on investor sentiment and cnn-lstm model. *J. Syst. Sci. Inf. Technol. Engl. Ed.* 2022, 10, 620–632
 40. Wu, Q.; Guan, F.; Lv, C.; Huang, Y. Ultra-short-term multi-step wind power forecasting based on cnn-lstm. *IET Renew. Power Gener.* 2021, 15, 1019–1029
 41. Xiang, Y. Using the ARIMA-GARCH model to analyze the fluctuation law of international oil prices. *Math. Probl. Eng.* 2022, 2022, 3936414. <https://doi.org/10.1155/2022/3936414> (дата обращения: 17.05.2023)
 42. Xingjian Shi; Zhouong Chen; Hao Wang; Dit-Yan Yeung; Wai-kin Wong; Wang-chun Woo. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting // *Proceedings of the 28th International Conference on Neural Information Processing Systems : journal.* — 2015. — P. 802—810.

43. Yin, L.; Li, B.; Li, P.; Zhang, R. Research on stock trend prediction method based on optimized random forest. CAAI Trans. Intell. Technol. 2021, 8, 274–284. <https://doi.org/10.1049/cit2.12067> (дата обращения: 17.05.2023)
44. Zhang, J.; Ye, L.; Lai, Y. Stock Price Prediction Using CNN-BiLSTM-Attention Model. Mathematics 2023, 11, 1985. <https://doi.org/10.3390/math11091985> (дата обращения: 17.05.2023)
45. Библиотека Pandas – <https://pandas-datareader.readthedocs.io/en/latest/readers/moex.html> / pandas-datareader Documentation Release 0.10.0 Jul 13, 2021 - <https://readthedocs.org/projects/pandas-datareader/downloads/pdf/latest/> (дата обращения: 17.05.2023)
46. Грегори-Вильямс Джастин, Вильямс Билл Торговый хаос. Увеличение прибыли методами технического анализа. М.: Альпина PRO, 2021. – 310 с.
47. Далио Р. Большие долговые кризисы. Принципы преодоления. Изд-во: Манн, Иванов и Фербер, 2020. – 496 с.
48. Джон Дж. Мэрфи Технический анализ фьючерсных рынков: теория и практика. М.: Сокол, 1996.- 592 с.
49. Линч П. Метод Питера Линча: Стратегия и тактика индивидуального инвестора. – М.: АЛЬПИНА ПАБЛИШЕР, 2011.
50. Мерфи Дж. Технический анализ финансовых рынков. — М.: Вильямс, 2012.
51. Платоформа с открытым исходным кодом Keras https://www.tensorflow.org/api_docs/python/tf/keras/layers/LSTM (дата обращения: 17.05.2023)
52. Твид Л. Психология финансов. – М.: "ИК "Аналитика", 2002. – 376 с.

53. Число частных инвесторов на Московской бирже достигло 24 млн человек - <https://www.moex.com/n54937/?nt=0> (дата обращения: 17.05.2023)
54. Шарп У. Инвестиции : Учебник / У.Ф. Шарп, Г.Дж. Александер, Дж.В. Бэйли. - М.: Инфра-М, 2014. - 1028 с. - Текст : непосредственный.
55. Элдер А. Как играть и выигрывать на бирже: Психология. Технический анализ. Контроль над капиталом. — М.: АЛЬПИНА ПАБЛИШЕР, 2013.
56. Элдер А. Трейдинг. Первые шаги. — М.: АЛЬПИНА ПАБЛИШЕР, 2013.
57. Энциклопедия кибернетики / Ред. коллегия: В.М. Глушков (отв. ред.) [и др.] ; АН УССР. - Киев : Укр. сов. энциклопедия, 1974.