

На правах рукописи



Макаров Иван Сергеевич

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

Специальность 1.2.1 —  
«Искусственный интеллект и машинное обучение»

Автореферат  
диссертации на соискание учёной степени  
кандидата технических наук

Москва — 2024

Работа выполнена в Федеральном исследовательском центре «Информатика и управление» Российской академии наук (ФИЦ ИУ РАН)

Научный руководитель: **Цурков Владимир Иванович**  
д.ф.-м.н., профессор,  
ФИЦ ИУ РАН,  
заведующий отделом №13

Официальные оппоненты: **Гостев Иван Михайлович**  
доктор технических наук,  
ИППИ РАН, центр распределенных вычислений,  
ведущий научный сотрудник

**Андрианова Ольга Геннадьевна**  
кандидат физико-математических наук,  
ИПУ РАН, лаборатория №16 «Нелинейных систем  
управления им. Е.С. Пятницкого»,  
старший научный сотрудник

Ведущая организация: **ФГБОУ ВО «Владимирский государственный  
университет им. А.Г. и Н.Г. Столетовых»**

Защита состоится \_\_\_\_\_ г. в \_\_\_\_ : \_\_\_\_ часов на заседании  
диссертационного совета 24.1.224.03 на базе Федерального исследова-  
тельного центра «Информатика и управление» Российской академии наук (ФИЦ  
ИУ РАН) по адресу: 119333, г. Москва, ул. Вавилова, д. 40.

С диссертацией можно ознакомиться в библиотеке Федерального исследова-  
тельного центра «Информатика и управление» Российской академии наук  
(ФИЦ ИУ РАН) и на сайте <http://www.frccsc.ru>.

Автореферат разослан \_\_\_\_\_ г.

Ученый секретарь  
диссертационного совета  
24.1.224.03, к.т.н.



Рейер И.А.

## Общая характеристика работы

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

**Целью** данной работы является разработка и исследование методов решения задач прогнозирования точек разворота на многомерных временных рядах финансовых рынков на основе моделей машинного обучения с подкреп-

лением. В качестве результата данной работы предлагается обученная и протестированная модель, являющаяся ядром полнофункциональной автоматизированной торговой системы. Для достижения поставленной цели должны быть решены изложенные ниже задачи, в которых детально обозначены требования к модели, методике ее обучения, тестирования и оценки финансовых показателей, а также инфраструктурным компонентам полнофункциональной автоматизированной торговой системы.

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

1. Определены статистические свойства многомерных финансовых временных рядов, а именно, свойства стационарности, самоподобия, корреляции и волатильности. Понимание данных свойств необходимо при формировании выборок данных для обучения и тестирования моделей машинного обучения.
2. Оценена применимость моделей классического машинного обучения с учителем при решении задач прогнозирования на многомерных финансовых временных рядах. Нейронная сеть, обученная решению задачи классификации на размеченных данных используется в качестве базовой модели.
3. Разработана среда для обучения с подкреплением моделей на основе нейронных сетей с рекуррентными слоями типа LSTM; построена архитектура моделей; обучены и оценены модели; выполнено ансамблирование нескольких моделей в единую экспертную систему.
4. Построены дополнительные вторичные признаки для многомерных финансовых временных рядов криптовалютного рынка на основе биржевой ленты сделок. Лента сделок отражает действия других участников рынка, в частности, крупных игроков. Декодирование этой информации и выделение важных сигналов позволяет подстраиваться под тех, кто обладает большей информацией о перспективах актива или рынка.
5. Разработано гибридное решение посредством сочетания алгоритмической стратегии и модели машинного обучения, фильтрующей сиг-

налы алгоритмической стратегии. Таким образом организован процесс решения двух оптимизационных задач: первая задача посвящена определению пары оптимальных параметров алгоритмической стратегии методом поиска на двумерной сетке, вторая задача посвящена обучению с подкреплением модели фильтрации сигналов алгоритмической стратегии. Доказано, что такой подход дает лучшие результаты в терминах финансовых показателей.

### **Основные положения, выносимые на защиту:**

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

**Научная новизна** работы заключается в том, что предложен подход использования комбинированного многомерного временного ряда, сочетающего в себе первичные признаки, и вторичные, вычисленные алгоритмически, такие как уровни поддержки и сопротивления, индикаторы, осцилляторы и другие. Разработана среда для обучения с подкреплением моделей совершению торговых операций, в которой в качестве награды модели используется достигнутая ею доходность на тестовом периоде. Разработана архитектура модели машинного обучения на основе нейронной сети типа DQN (Deep Q-Network), предназначенная для прогнозирования точек разворота. Реализована комбинированная модель из жесткой алгоритмической стратегии и модели машинного обучения с подкреплением, фильтрующей сигналы алгоритмической стратегии. Обученные в разработанной среде модели встроены в систему автоматизированной торговли, в которой являются компонентами активной среднесрочной инвестиционной стратегии и показывают лучшую результативность, чем альтернативные модели и методы, обученные с учителем решению задач классификации и регрессии на размеченных данных или построенные на средствах технического анализа алгоритмические стратегии.

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

**Практическая ценность** обусловлена реализацией активной среднесрочной инвестиционной стратегии на основе прогнозирования точек разворота посредством комбинирования базовой алгоритмической стратегии и модели машинного обучения с подкреплением в составе автоматизированной торговой системы. Данная система внедрена в качестве одного из программных решений в ООО «Интеллектуальные Системы Управления», которое подтвердило практическую ценность указанных разработок в форме акта 0824-1 от 23 августа 2024 года. Техническая документация на разработанные решения предоставляется клиентам ООО «Интеллектуальные Системы Управления» при заключении договора.

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

**Апробация работы** произведена автором на следующих конференциях:

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

Основные результаты по теме диссертации изложены в 10 печатных изданиях [1–10], 4 из которых изданы в журналах, рекомендованных ВАК, 6 опубликованы в качестве тезисов докладов перечисленных выше конференций.

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

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

## Содержание работы

Во введении обосновывается актуальность исследований, проводимых в рамках данной диссертационной работы, приводится обзор научной литературы по изучаемой проблеме, формулируется цель, ставятся задачи работы, сформулированы научная новизна и практическая значимость представляемой работы.

В главе 1 рассмотрены концепции биржевой торговли и особенности функционирования криптовалютных рынков, которые были учтены в процессе разработки системы автоматической торговли и среднесрочной инвестиционной стратегии с переворотом позиций. В частности, рассмотрены способы использования уровней поддержки и сопротивления, а также некоторых других средств технического анализа. Описаны разработанные автором инфраструктурные компоненты, а именно система анализа данных в реальном времени на основе торгового терминала Quik и система бэктестирования среднесрочных стратегий. В разделе 1.1 рассмотрены типы заявок, маржинальная торговля, особенности фьючерсов, биржевые индексы и функционал блокчейнов. Помимо этого, были обозначены скользкие места предметной области, которые избегались в ходе исследований. В разделе 1.2 описана разработанная автором инфраструктура системы автоматической торговли на основе торгового терминала Quik 8.0. Предложена высокопроизводительная архитектура системы обработки финансовых данных различных типов в реальном времени средствами технического и фундаментального анализа. В разделе 1.3 для 30 криптовалютных активов с наибольшей рыночной капитализацией построена матрица корреляции временных рядов, на основе которой можно сделать вывод о сильной коррелированности всего криптовалютного рынка. При включении различных криптовалютных активов в портфель следует выполнять диверсификацию за счет различных торговых или инвестиционных стратегий, а не за счет удержания различных активов. В разделе 1.4 описана разработанная автором примитивная алгоритмическая стратегия на основе индикаторов и осцилляторов технического анализа, которая используется в качестве базовой стратегии в главах 2 и 3. Также показана важность учета уровней поддержки и сопротивления в процессе технического анализа графиков цен активов. Информация об уровнях используется в главе 2 в качестве компонент многомерных временных рядов и входных векторов моделей



машинного обучения. В разделе 1.5 описана разработанная автором система тестирования и валидации среднесрочных торговых стратегий. Данная система используется далее для проверки трех разработанных стратегий, а также в процессе решения двухпараметрической задачи оптимизации алгоритмической стратегии в главе 3. Сформулированы требования к финансовым показателям стратегий на основе коэффициентов Шарпа и Сортино.

В главе 2 рассмотрен полный цикл подготовки и разметки данных, а также архитектура и процессы обучения и тестирования моделей машинного обучения с учителем и с подкреплением. Приведены некоторые статистические свойства многомерных временных рядов финансовых рынков. Сформированы обучающая и тестовая выборки данных для моделей, а также выполнена разметка данных для решения задачи тернарной классификации. Также в главе описаны первые две версии моделей машинного обучения, ориентированных на решение задачи прогнозирования многомерных временных рядов финансовых рынков. Это модель, обученная с учителем, и модель, обученная с подкреплением. Во втором случае используется алгоритм DQN, а обученные по-разному при исследовании среды модели объединены в ансамбль. В разделе 2.1 сформулировано определение торговой стратегии с переворотом позиций, а также сформулирована многокритериальная задача оптимизации с ограничениями, которую необходимо решить в процессе разработки стратегий. В разделе 2.2 приведены результаты исследования некоторых статистических свойств многомерных временных рядов финансовых рынков. В разделах 2.3 и 2.4 описана итоговая структура многомерного временного ряда и входного вектора для моделей машинного обучения с разметкой под тернарную задачу классификации. В итоговую структуру была включена информация об уровнях поддержки и сопротивления, описанных в главе 1. В разделе 2.5 приведено описание первой версии модели прогнозирования многомерных временных рядов финансовых рынков. В разделе 2.6 совмещено обучение отдельных моделей с использованием известного варианта оптимизации алгоритма DQN с двумя сетями и буфером воспроизведения и составлении ансамбля таких моделей. В этой части описывается среда, используемая для обучения с подкреплением, алгоритм DQN, результаты исследования ансамбля обученных глубоких нейронных сетей и использование этого алго-

ритма для применения на финансовых рынках. В качестве входного вектора используются те же вектора, что и для модели обучения с учителем.

Определение торговой стратегии с переворотом позиций следующее:

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

где  $S$  - стратегия с оптимизируемыми параметрами  $\Theta$ . Здесь  $S_{\Theta}$  - разработанный и оптимизированный алгоритм прогнозирования действий,  $\vec{T}_i(x)$  - вектор MFTS для инструмента  $x$  на временном шаге  $i$ ,  $n$  - количество шагов,  $A_{i+1}(x)$  - рекомендуемое для инструмента  $x$  действие на временном шаге  $i + 1$ , при этом  $A_i \in \{B, S, C, H\}$ , где  $B$  - покупка,  $S$  - продажа,  $C$  - закрытие,  $H$  - удержание. Таким образом можно сформировать  $\vec{A}(x) = \{A_n(x), A_{n+1}(x), \dots, A_N(x)\}$  - последовательность действий для инструмента  $x$ , для которой определяется функция  $R(\vec{A}(x), x)$ , вычисляющая награду за последовательность действий для инструмента  $x$ . Далее приводится математическая формулировка многокритериальной задачи оптимизации для обучаемой модели. Численные значения констант, которые указаны в ограничениях, заданы для решения, ориентированного на криптовалютный рынок, аналогично для активов MOEX.

$$R(S_{\Theta}, x) = R(\vec{A}(x), x) \rightarrow \max, s.t. \quad (2)$$

$$R(S_{\Theta}, x) > R(\vec{B}(x), x), \vec{B}(x) = \{B_n, H_{n+1}, \dots, H_N\} \forall x, \quad (3)$$

$$t_N - t_n > 360 \text{ суток при длительности временного шага } \Delta t = 1 \text{ час}, \quad (4)$$

$$R_{sharpe} = \frac{E(R_m)}{\sigma_{R_m}} > 0.5, R_{sortino} = \frac{E(R_m)}{\sigma_{R_m-}} > 5.0, \quad (5)$$

где  $R(S)$  - чистая прибыль стратегии за тестовый период,  $t_n$  - момент времени начала тестового периода,  $t_N$  - момент времени окончания тестового периода, для криптовалютного рынка торговая сессия равняется 24 часам, т.к. биржи работают без выходных,  $I_{max}$  - капиталоемкость стратегии,  $R(B)$  - функция прибыли бенчмарка «купи и держи» за тестовый период. Следует

заметить, что для МОЕХ минимально допустимыми значениями коэффициентов Шарпа и Сортино являются значения 1.0 и 7.0 соответственно.

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

В первую очередь решалась проблема нехватки данных многомерных временных рядов на старших таймфреймах. С учетом выходных дней и праздников за год существует около 200 временных шагов по одному активу на дневном таймфрейме. Этого недостаточно для качественного обучения моделей. В связи с этим рассматривается гипотеза о самоподобии графика цены одного актива в разных таймфреймах, при подтверждении которой можно будет использовать данные разных таймфреймов для обучения одной и той же модели. Пусть два временных ряда  $T = \{t_1, t_2 \dots t_n\}$  и  $S = \{s_1, s_2 \dots s_m\}$  длины  $n$  и  $m$  соответственно. Коэффициент самоподобия определяется как минимальная стоимость преобразования  $T$  в  $S$  на основе евклидова расстояния между соответствующими компонентами. Он используется для оценки подобия паттернов на разных временных шкалах. На следующем шаге составляется матрица расстояний, где на пересечении строки  $i$  и столбца  $j$  стоит расстояние между  $t_i$  и  $s_j$  элементами временных рядов  $T$  и  $S$  соответственно. В расчетах используется расстояние, определяемое следующим образом:

$$d(t_i, s_j) = |t_i - s_j| \quad (6)$$

Таким образом, матрица расстояний примет следующий вид:

$$\begin{pmatrix} d(t_1, s_1) & d(t_1, s_2) & \dots & d(t_1, s_m) \\ d(t_2, s_1) & d(t_2, s_2) & \dots & d(t_2, s_m) \\ \dots & \dots & \dots & \dots \\ d(t_n, s_1) & d(t_n, s_2) & \dots & d(t_n, s_m) \end{pmatrix} \quad (7)$$

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

$$DTW(T,S) = \min \left( \sum_{k=1}^K d(w_k) \right) / K \quad (8)$$

где  $w_k = (i,j)$ ,  $d(w_k) = d(t_i, s_j) = |t_i - s_j|$  граничные условия задаются равенствами  $w_1 = (1, 1)$ ,  $w_K = (n, m)$ . Следующая задача: вычислить минимальную стоимость преобразования T в S. Путь трансформации W находится с помощью методов динамического программирования. Для матрицы трансформации  $\gamma$  значение на пересечении строки  $i$  и столбца  $j$  вычисляется следующим образом:

$$\gamma(i, j) = d(t_i, s_j) + \min(\gamma(i, j - 1), \gamma(i - 1, j), \gamma(i - 1, j - 1)) \quad (9)$$

---

**Algorithm 1** Алгоритм динамической трансформации временной шкалы.

---

```

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

```

---

В результате получена матрица самоподобия, в которой отражено сравнение графиков одного и того же актива в разных таймфреймах. Большие

значения в ячейках матрицы соответствуют большому различию временных рядов. Ноль соответствует полному совпадению графиков. Исследование показывает, что частота сбора данных влияет на их качество: с уменьшением длительности таймфрейма увеличивается уровень шума и снижается схожесть временных рядов. В последующем при обучении моделей, данные с различными таймфреймами, включая дневные, недельные и месячные, будут использоваться одновременно в обучающих выборках для моделей, не являющихся старшими по временной шкале.

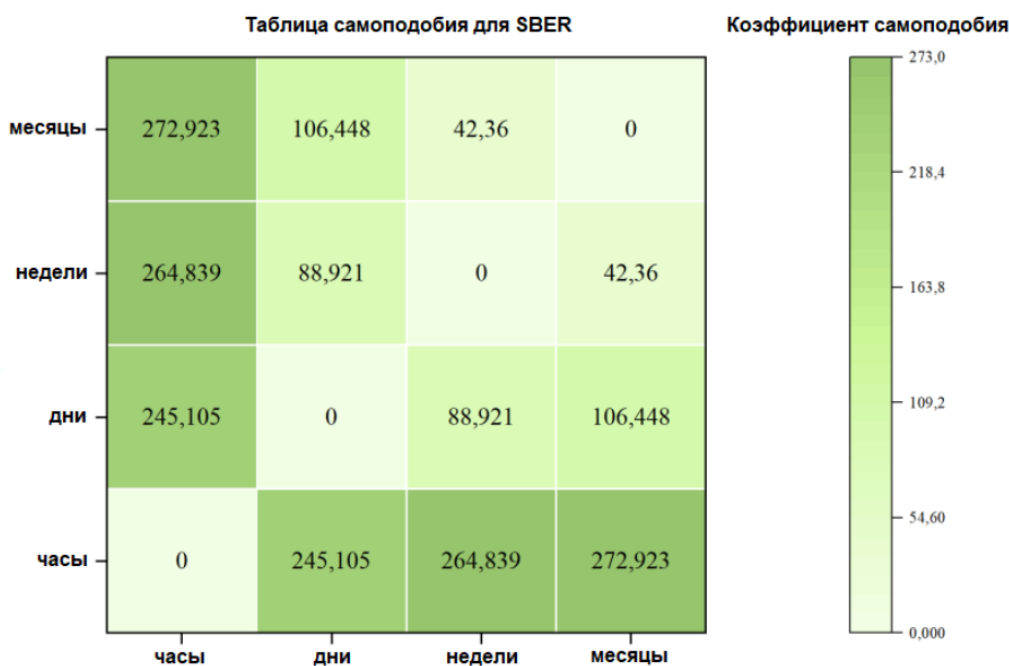


Рис. 1 — Матрица самоподобия для четырех графиков цены акций SBER.

Далее необходимо выделить активы, поведение которых значительно отличается от других. Такие активы будут называться выбросами. Их следует рассматривать отдельно. Для их нахождения будут составлены матрицы непохожести для различных таймфреймов. В ячейках каждой матрицы будут записаны коэффициенты непохожести, соответствующие паре активов.

Пусть  $p_{t_1}, p_{t_2}, \dots, p_{t_n}$  - числовой ряд, где  $p_{t_i}$  - цена закрытия данного актива в момент времени  $t_i$ . Дополнительный временной ряд составляется из процентных отклонений цены с течением времени  $d_1, d_2, \dots, d_{n-1}$ , элементы ряда вычисляются по формуле:

$$d_i = \frac{p_{t_{i+1}} - p_{t_i}}{13^{p_{t_i}}} \quad (10)$$

Далее осуществляется сортировка в порядке возрастания для данной пары активов  $D$  и  $S$  рядов процентных отклонений  $d_1, d_2, \dots, d_n$  и  $s_1, s_2, \dots, s_m$ . Если ряды отличаются по размеру (например,  $m > n$ ), выполняется обрезка одного из них так, что отбрасываются первые  $m - n$  точек. Формула для нахождения коэффициента непохожести:

$$S = \sum_{i=1}^n \frac{|d_i - s_i|}{n} \quad (11)$$

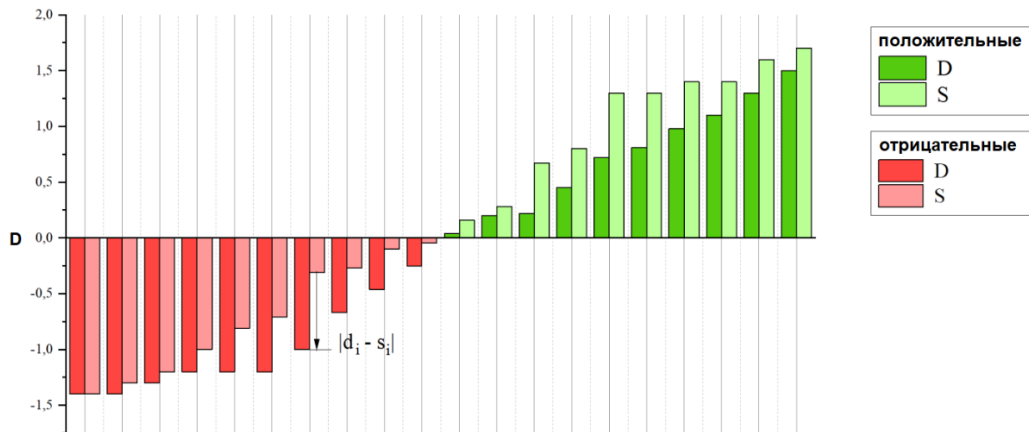


Рис. 2 — Сопоставление двух временных рядов на предмет непохожести.

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

Полученные результаты исследования статистических свойств временных рядов финансовых рынков могут быть применены в процессе подготовки данных для обучения моделей, предназначенных для решения различных задач на подобных временных рядах. Установлено, что, во-первых, свечные графики в малых таймфреймах обладают меньшим самоподобием, чем свечные графики в больших таймфреймах, однако свечные графики в больших таймфреймах также не демонстрируют высокой степени самоподобия, поэтому при составлении выборки данных рекомендуется не смешивать данные свечных графиков различных таймфреймов; во-вторых, графики индексов, акций




Рис. 3 — Матрица коэффициентов непохожести для различных активов.

и товаров в одинаковом таймфрейме различаются по составу свечей, поэтому выборку данных для моделей следует составлять из временных рядов только одного класса; в-третьих, временные ряды акций компаний входящих в индекс МОЕХ и активов товарного рынка не обладают сильной корреляцией друг с другом, поэтому нет необходимости ликвидировать какие-либо компоненты выборки данных по причине корреляции. Дополнительно стоит отметить, что в периоды кризисов на рынке наблюдаются всплески волатильности. В такие моменты поведение стоимости активов плохо описывается математическими моделями.

Для обучения моделей берутся данные на основе свечных графиков на дневном таймфрейме. Длительность используемых временных рядов составляет от 1 до 20 лет. Графики на меньших таймфреймах не рассматриваются из-за сильного шума данных. В данной работе было подготовлено несколько типов разметки для решения задач классификации различного рода. Первый вариант простейшей разметки соответствует задаче прогнозирования движения цены вверх или вниз в ближайшие  $N$  дней от текущего момента,  $N$  лежит в диапазоне  $[1; 5]$ . Вторая версия разметки была получена с использованием алгоритма определения тренда с плавающей правой границей окна фильтра.

В ходе экспериментов выяснилось, что значение точности лучше у разметки, полученной вторым методом. Далее в работе представлены результаты обучения и тестирования моделей на второй разметке, потому что точность на разметке первого типа 54-58%, на разметке второго типа 65-70%. Первоначальный вариант разметки вторым способом подразумевает три класса: L, S, N. Отметка N означает, что на момент закрытия текущей свечи рекомендуется иметь нулевую позицию, L - что рекомендуется иметь длинную позицию, S - что рекомендуется иметь короткая позиция. Метка N соответствует моментам, когда на рынке нет определенного движения.

Первая модель, которая рассматривалась в рамках данной работы — это модель, обученная с учителем на описанной ранее разметке для решения задачи тернарной классификации. Выходной сигнал модели — это наиболее вероятное состояние, которое должно быть реализовано на следующем временном шаге. Модель имеет разветвленную топологию и содержит четыре точки входа, на которые разбивается входной вектор — это предыстория цен, объемов, уровней и данные о временной метке. Далее для работы с предысторией временного ряда используются слои LSTM типа, которые конкатенируются и обрабатываются дополнительными полносвязными слоями с выпадением 0.5. Модель реализована посредством инструментария Keras и Tensorflow и имеет порядка 6 млн параметров.

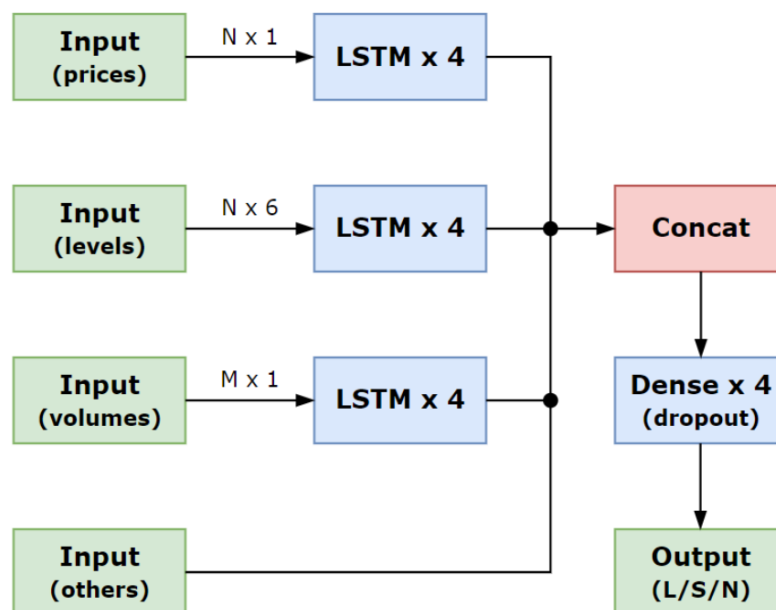


Рис. 4 — Архитектура модели для решения задачи классификации.



В результате обучения модели на протяжении 10 эпох, что являлось оптимальным значением, было достигнуто значение метрики точности в 66.5% и доходность по результатам бэктестирования на тестовой выборке в 15% годовых за 2022 год. Коэффициент Шарпа составил примерно 0.22. Коэффициент Сортино составил примерно 1.38. Это довольно низкие показатели, ниже минимально необходимых, обозначенных ранее. Модель показала обучаемость в терминах машинного обучения, однако непригодна по финансовым показателям в реальных условиях. Низкие показатели модели обусловлены в том числе достаточно примитивной разметкой и частыми переверотами позиций, что будет исправлено далее в подходе обучения с подкреплением.

Новизна данной работы заключается в совмещении обучения отдельных моделей с использованием известного варианта оптимизации алгоритма DQN с двумя сетями и буфером воспроизведения и составлении ансамбля таких моделей. В классическом машинном обучении часто рассматриваются ансамбли слабых моделей. В данной работе рассматривается составление ансамбля сильных моделей, каждая из которых по отдельности способна качественно решить поставленную задачу, но с худшей производительностью (доходностью при совершении операций на финансовых рынках), чем в составе ансамбля. В процессе обучения моделей алгоритмом DQN присутствует фактор случайности, связанный с epsilon-жадным исследованием окружающей среды. В связи с этим обучение моделей осуществляется по-разному, поэтому был разработан критерий отбора обученных моделей для составления ансамбля. Показано, что эффективность ансамбля значительно превышает эффективность каждой отдельной модели.

Как видно из таблицы, с увеличением количества моделей в ансамбле увеличивается и получаемая ими награда. Время, необходимое для функционирования ансамбля на каждом шаге, также увеличивается пропорционально, поэтому было решено сосредоточиться на ансамбле, содержащем 64 модели. Его эффективность приемлема для используемой среднесрочной торговой стратегии. Полученный ансамбль дает прибавку к вознаграждению за тестовый период примерно на 100% по отношению к каждой отдельной модели из ансамбля. Также использование ансамбля дает более плавный график роста вознаграждения без сильных просадок. Доходность одной модели составила от 40 до 56 годовых за 2022 г. Доходность ансамбля из 64 моделей

---

**Algorithm 2** Алгоритм обучения с подкреплением модели типа DQN.

---

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

---

составила примерно 90% годовых за 2022 г. с коэффициентом Шарпа 0.47 и коэффициентом Сортино 4.16, что уже достаточно близко к желаемым целевым показателям и может быть запущено на реальном счете.

<b>М</b>	<b>R(3 года)</b>	<b>R(2022 г.)</b>
22	≈ 206%	≈ 81%
24	≈ 207%	≈ 84%
26	≈ 213%	≈ 84%
32	≈ 240%	≈ 86%
44	≈ 267%	≈ 89%
58	≈ 278%	≈ 90%
<b>64</b>	≈ 280%	≈ 90%

Таблица 1 — Результативность работы разных ансамблей моделей.

В главе 3 представлено оригинальное решение задачи прогнозирования точек разворота на многомерных временных рядах финансовых рынков за счет использования дополнительных апериодических вторичных признаков на основе ленты сделок и предложенном двухэтапном методе оптимизации гибридной стратегии, которая основана на классической алгоритмической стратегии, сигналы которой фильтруются посредством модели машинного обучения на архитектуре DQN. Здесь показано, что подобное использование моделей машинного обучения поверх алгоритмических стратегий позволяет существенно повысить доходность стратегий. В разделе 3.1 описаны дополнительные признаки многомерных временных рядов финансовых рынков. В разделе 3.2 представлена итоговая третья итерации модели и стратегии, предлагаемая автором как основной результат данной работы. В разделе 3.3 продемонстрированы отчеты модуля бэктестирования для итоговой третьей версии стратегии.

В главе 2 были представлены 2 модели машинного обучения. Первая была обучена на размеченной выборке для решения задачи тернарной классификации, вторая была обучена с подкреплением для прогнозирования награды за следующее действие. Использование расширенного MFTS, дополненного вторичными признаками на основе ленты сделок, является не единственным улучшением итоговой модели. Был кардинально пересмотрен подход использования моделей машинного обучения в задачах прогнозирования MFTS. За основу была взята жесткая алгоритмическая трендовая стратегия,

сигналы которой в режиме бинарной классификации фильтровались моделью.

$$EMA_t(n, m) = \alpha \cdot P_{t-m} + (1 - \alpha) \cdot EMA_{t-m-1}, \alpha = \frac{2}{1+n} \quad (12)$$

$$BBW_t(k) = \sqrt{\frac{\sum_{i=t-k+1}^t (P_i - SMA_t(k))^2}{k}}, SMA_t(k) = \frac{\sum_{i=t-k+1}^t P_i}{k} \quad (13)$$

$$(P_t - EMA_t(n, m)) * (P_{t-1} - EMA_{t-1}(n, m)) < 0 \Rightarrow N \quad (14)$$

$$P_t > EMA_t(n, m), P_{t-1} < EMA_{t-1}(n, m), BBW_t(k) < T \Rightarrow L \quad (15)$$

$$P_t < EMA_t(n, m), P_{t-1} > EMA_{t-1}(n, m), BBW_t(k) < T \Rightarrow S \quad (16)$$

Здесь обозначено, что основой стратегии служит индикатор ЕМА. Сигнал на покупку поступает при пересечении графиком цены линии ЕМА снизу вверх. Сигнал на продажу поступает при пересечении графиком цены линии ЕМА сверху вниз. При поступлении нового сигнала предыдущая позиция другого типа закрывается. При этом сигналы на первом этапе фильтруются по волатильности, определяемой как ширина между линиями Боллинджера BBW. Если волатильность превышает пороговое значение T сигнал игнорируется. Оптимальные значения  $k = 60$  и  $T = 0.3$  для часового таймфрейма. Данная стратегия является доходной в базовом варианте при оптимально подобранных параметрах, однако ее можно существенно улучшить при добавлении вторичной фильтрации посредством модели машинного обучения. Оптимальные значения параметров  $n$  и  $m$  были определены в результате решения двухпараметрической задачи оптимизации на двумерной сетке и составили  $n = 3$ ,  $m = 16$ . На рисунке приведена тепловая карта, отражающая решение оптимизационной задачи. Рассматриваемый актив - ETHUSDT на споте

Binance. Светлые клетки означают положительную доходность стратегии на тестовом периоде за 2023 год. Темные клетки сигнализируют об отрицательной доходности и неудачных комбинациях параметров. По сути, вся тепловая карта дает положительную доходность при любых параметрах. Это говорит о том, что трендовые стратегии применимы для работы с торговой парой ETHUSDT. ETH является стабильным активом с адекватными трендовыми движениями. Обозначенные выше параметры  $k$  и  $T$  не перебирались, а использовались фиксированные, т.к. это приводило бы к переобучению модели.




Рис. 5 — Тепловая карта перебора параметров  $n$  и  $m$  для ETHUSDT.

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

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

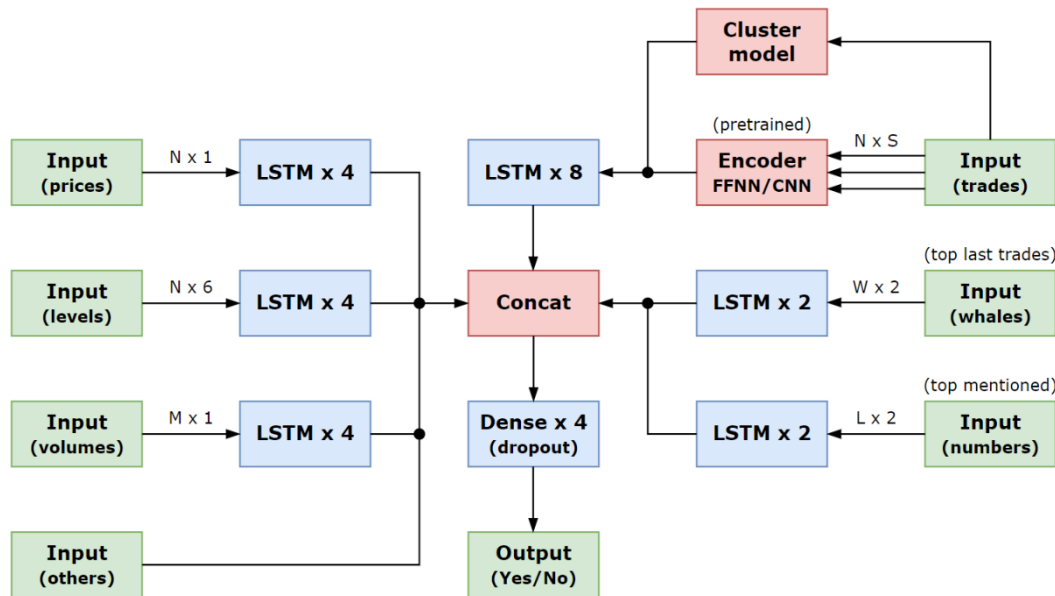


Рис. 6 — Архитектура нейронной сети модели третьей версии.

Модель обучалась на данных за 2 года - 2020 и 2021 в часовом тайм-фрейме. 2022 и 2023 года использовались для чистого тестирования. В данном случае результаты приведены для актива ETHUSDT, аналогичные результаты были получены и для 55 других торговых пар, из которых по итогу был составлен портфель, однако эта часть выходит за рамки данной работы. Стратегия тестировалась без реинвестирования прибыли, с фиксированным стоп-лоссом, без тейк-профита, с полными комиссиями биржи и брокера. Обслуживание позиций не приводило к проскальзыванию, т.к. капиталоемкость стратегии ограничена 10 млн USDT. Стратегия показала доходность примерно 289% за 2 тестовых года, коэффициент Шарпа составил 0.97, коэффициент Сортино составил 16.76.

**В заключении** приведены основные результаты работы:

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

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

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

Рис. 7 — Результаты бэктестирования стратегии Intersector 3.1.

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

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

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

## Публикации автора по теме диссертации

1. Makarov I., Kovaleva M., Zinkovich V., Kolovertnova V. Research of Financial Time-series Statistical Properties // *International Conference Engineering and Telecommunication*. — 2021. — P. 4.
2. Makarov I., Kovaleva M., Pankovets E., Konstantinov D. A Deep Neural Network Architecture for Solving Classification Problems on Multidimensional Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 6.
3. Konstantinov D., Pankovets E., Makarov I., Gorbachev R. Development and Research of a Deep Neural Network Architecture for Solving Regression Problems on Multidimensional Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 4.
4. Makarov I., Kovaleva M., Fakhruddinov T., Gorbachev R. Intelligent Module for System Trading of Financial Markets Assets Based on an Ensemble of Deep Neural Networks and the DQN Learning Algorithm // *International Conference Engineering and Telecommunication*. — 2021. — P. 7.
5. Makarov I., Fakhruddinov T., Kichik, M., Mamontov K., Baskov O., Shumsky S. Forecasting in Financial Markets Using the ADAM Architecture and Reinforcement Learning Methods // *International Conference Engineering and Telecommunication*. — 2021. — P. 7.
6. Makarov I., Kovaleva M., Zakharova E., Gorbachev R. Applicability of the kNN Algorithm in the Problem of Pattern Classification on Time Series of Financial Markets // *International Conference Engineering and Telecommunication*. — 2021. — P. 5.
7. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Zakharova E. Development of and research into a rigid algorithm for analyzing Twitter publications and its influence on the movements of the cryptocurrency market // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 157–170.
8. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Gorbachev R. Development of and research on an algorithm for distinguishing features in Twitter



- publications for a classification problem with known markup // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 171–183.
9. Makarov I., Bagantsova E., Iashin P., Kovaleva M., Gorbachev R. Development of and research on machine learning algorithms for solving the classification problem in Twitter publications // *Journal of Computer Research and Modeling*. — 2023. — Vol. 15, no. 1. — Pp. 185–195.
  10. Esenkov A., Zakharova E., Kovaleva M., Konstantinov D., Makarov I., Pankovets E. Research and application of deep neural network architectures for classification on multidimensional time series // *Journal of Computer and Systems Sciences International*. — 2022. — Vol. 61, no. 4. — Pp. 616–625.