

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г. ЧЕРНЫШЕВСКОГО»**

Кафедра дифференциальных уравнений и математической экономики

Применение глубоких сверточных нейросетей для обнаружения и
классификации разворотных свечных паттернов на графиках
финансовых инструментов

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студентки 4 курса 451 группы
направления 38.03.05 — Бизнес-информатика

механико-математического факультета

Гребенюков Павел Андреевич

Научный руководитель
зав. кафедрой д.ф.-м.н.,
доцент

В.С. Рыхлов

Заведующий кафедрой
зав. кафедрой д.ф.-м.н., доцент

В.С. Рыхлов

Саратов 2026

Введение. Технический анализ и свечные паттерны остаются важным инструментом прогнозирования на финансовых рынках, однако их субъективная интерпретация и трудоемкость визуального распознавания ограничивают эффективность применения. Развитие методов машинного обучения, в особенности сверточных нейронных сетей (CNN), открывает возможность автоматизации этого процесса за счет преобразования временных рядов в визуальные представления. Несмотря на существующие подходы к распознаванию паттернов, проблема получения устойчивых и интерпретируемых моделей, работающих в условиях рыночного шума и дисбаланса классов, остается не полностью решенной.

Актуальность работы. На финансовых рынках свечные паттерны остаются востребованным инструментом прогнозирования, однако их ручное распознавание трудоёмко и субъективно. Существующие автоматические методы — от жёстких правил до классического машинного обучения — либо плохо обобщаются на зашумлённых данных, либо требуют ручного конструирования признаков, что ограничивает их практическую ценность. Применение свёрточных нейронных сетей к визуальным представлениям временных рядов (например, Gramian Angular Field) позволяет снять эти ограничения, но вопрос устойчивой классификации трёх состояний рынка (разворот вверх/вниз, нейтральный фон) в условиях сильного дисбаланса классов остаётся недостаточно проработанным. Данная работа направлена на восполнение этого пробела.

Целью бакалаврской работы является разработка и экспериментальное исследование модели распознавания разворотных паттернов на основе CNN и GAF. Для достижения цели были поставлены следующие задачи: обзор методов автоматизации распознавания паттернов и архитектур CNN; проектирование конвейера предобработки данных, разметки целевых классов и преобразования временных рядов в многоканальные изображения; разработка архитектуры CNN для классификации трёх состояний (разворот вниз, нейтральное состояние, разворот вверх); обучение модели на исторических данных и оценка её 2

качества с использованием метрик, устойчивых к дисбалансу классов; интерпретация результатов методом Grad-CAM.

Основное содержание работы. Работа состоит из введения, трех разделов, заключения, списка использованных источников, содержащего 20 наименований.

Работа включает следующие 3 раздела:

1. Теоретические основы анализа финансовых паттернов и машинного обучения;
2. Проектирование и разработка модели распознавания паттернов на основе сверточных нейронных сетей;
3. Экспериментальное исследование и анализ результатов

В **первом** разделе приводятся основные понятия, связанные с рынком ценных бумаг и нейронными сетями. Технический анализ — это метод прогнозирования будущих цен на основе истории рыночных данных, прежде всего цены и объёма. Он базируется на трёх принципах: рынок учитывает всё, движение цен подчинено трендам, история повторяется. Основным инструментом визуализации являются японские свечи.

Каждая свеча отображает четыре цены за период: открытие (Open), максимум (High), минимум (Low) и закрытие (Close). Тело свечи показывает разницу между Close и Open, а тени (фитили) — экстремумы (рис. 1.1).



Рисунок 1.1 — Структура бычьей и медвежьей свечи

Разворотные паттерны предупреждают о возможной смене тренда. К наиболее известным относятся: молот и повешенный (рис. 1.2) — одна свеча с длинной нижней тенью и маленьким телом в верхней части диапазона; бычье и медвежье поглощение (рис. 1.3) — пара свечей, где вторая полностью перекрывает тело первой противоположного цвета; утренняя и вечерняя звезда — комбинация из трёх свечей с разрывом; харами и крест харами (рис. 1.5).




Рисунок 1.2 — Молот и повешенный



Рисунок 1.3 — Бычье и медвежье поглощение




Рисунок 1.4 — Утренняя и вечерняя звезда



Рисунок 1.5 — Харами

Классическое машинное обучение (метод опорных векторов, случайный лес, градиентный бустинг) позволило обучать классификатор на размеченных примерах, но требовало ручного конструирования числовых признаков (соотношение тела и тени, относительное положение свечи и т.д.). Качество такого подхода упирается в качество признакового описания. Рекуррентные нейронные сети (LSTM, GRU) работают непосредственно с сырыми временными рядами, однако обрабатывают последовательность шаг за шагом и не воспринимают паттерн как целостную визуальную структуру.

Свёрточная нейронная сеть состоит из нескольких типов слоёв. Свёрточный слой содержит множество ядер (фильтров) малого размера (например, 3×3), которые скользят по входному изображению, вычисляя скалярное произведение с локальным фрагментом. Ранние слои выделяют простые признаки (границы, ориентации), глубокие — целые паттерны. Функция активации

$ReLU(f(x)=\max(0,x))$ вносит нелинейность и предотвращает затухание градиента.

Слой подвыборки (пулинг) уменьшает размерность карт признаков, снижая вычислительную нагрузку и обеспечивая инвариантность к малым искажениям. В конце сети располагаются полносвязные слои, выполняющие классификацию. Обучение происходит методом обратного распространения ошибки с градиентным спуском. Для задачи классификации изображений хорошо зарекомендовал себя оптимизатор Adam. Функция потерь выбирается с учётом дисбаланса классов — в данном случае это взвешенная кросс-энтропия или Focal Loss.

Во **втором** разделе происходит проектирование и разработка модели распознавания паттернов. В рамках исследования использовались исторические данные фондового рынка, полученные с помощью библиотеки `yfinance`. Был выбран тикер SPY (ETF на индекс S&P 500) за период 10 лет с дневным интервалом. Исходный набор данных включает цену открытия (Open), максимальную цену (High), минимальную цену (Low), цену закрытия (Close) и объём торгов (Volume).

На этапе предобработки были сформированы дополнительные производные признаки, отражающие структуру свечей и локальную динамику рынка: тело свечи ($body = Close - Open$), диапазон свечи ($range = High - Low$), верхняя тень ($upper_{wick} = High - \max(Open, Close)$), нижняя тень ($lower_{wick} = \min(Open, Close) - Low$), дневная доходность ($return_1$), скользящая волатильность за 10 дней ($volatility_{10}$) и логарифм объёма торгов (\log_{volume}). После удаления строк с пропущенными значениями итоговый вектор признаков имел размерность 8 на каждый временной шаг. Далее формировались скользящие окна фиксированной длины, представляющие собой последовательности наблюдений, используемые для формирования одного примера и последующего преобразования в изображение GAF. Этот параметр влияет на баланс между учётом долгосрочного контекста и чувствительностью к локальным изменениям цены.

В работе использовался эмпирический подбор параметра. Базовое значение $window\ size = 30$ обеспечивало стабильное обучение и корректное формирование GAF-изображений. При изменении размера окна выполнялось полное пересоздание выборки, так как длина входных последовательностей напрямую определяет размер GAF-матриц, и несоответствие приводит к ошибкам библиотеки `pyts`. Оптимальное значение выбиралось по совокупности метрик качества классификации (balanced accuracy, macro F1 и recall), с учётом устойчивости модели и способности выделять разворотные паттерны.

Задача была сформулирована как многоклассовая классификация с тремя классами: 0 — разворот вниз, 1 — нейтральное состояние, 2 — разворот вверх. Разметка выполнялась на основе анализа будущего ценового движения относительно текущего момента времени. Для каждого временного индекса t рассматривалось окно длины $FUTURE_{HORIZON} = 5$. Определялись максимальное и минимальное значения цены в будущем окне, а также относительные изменения up_{move} и $down_{move}$.

Порог значимости движения рассчитывался как $thr = \max(MIN_{MOVE}, VOL_{MULT} * \sigma_t)$, где $MIN_{MOVE} = 0,012$, $VOL_{MULT} = 1,5$, а σ_t — локальная волатильность. Класс присваивался следующим образом: если наблюдается значимое положительное движение — класс 2; если значимое отрицательное — класс 0; иначе — класс 1 (рис. 2.1).



Рисунок 2.1 — График цены с отмеченными точками разворотов (красный — разворот вниз, зелёный — разворот вверх, серый — нейтрально)

Для предотвращения утечки информации использовалось хронологическое разделение данных: обучающая выборка (80%), валидационная (10%) и тестовая (10%). Между выборками вводился зазор (gap) в 30 дней для исключения пересечения временных окон. Программная реализация выполнена на языке Python с использованием библиотек TensorFlow/Keras, NumPy, pandas, scikit-learn и ruys (для GAF). Все этапы пайплайна — от загрузки данных до оценки модели — организованы в виде последовательных ячеек Jupyter Notebook, что обеспечивает воспроизводимость эксперимента.

В результате второй главы был разработан полный конвейер обработки данных и построения модели, способной обрабатывать финансовые временные ряды в виде изображений и выявлять потенциальные разворотные структуры.

В **третьем** разделе рассматривается экспериментальное исследование и анализ результатов. Оценка качества разработанной модели выполнялась с использованием стандартных метрик многоклассовой классификации. В силу несбалансированности классов (нейтральных состояний значительно больше, чем разворотов) основное внимание уделялось метрикам, устойчивым к дисбалансу. Были использованы: Accuracy (доля правильных ответов) — вспомогательная метрика; Precision — точность положительных предсказаний для каждого класса; Recall — полнота, отражающая способность модели обнаруживать все объекты заданного класса; F1-score — гармоническое среднее Precision и Recall; Macro F1 — среднее F1 по всем классам (главная метрика); Balanced Accuracy — среднее Recall по классам; а также матрица ошибок (confusion matrix) для детального анализа.

Для обеспечения воспроизводимости результатов экспериментов использовалась фиксация генераторов случайных чисел библиотеки NumPy, TensorFlow и стандартного модуля random языка Python. Дополнительно был активирован режим детерминированного выполнения операций TensorFlow.

Обучение модели проводилось на протяжении до 70 эпох с использованием ранней остановки. График функции потерь (рис. 3.1) показал монотонное снижение ошибки на обучающей выборке и более слабую динамику на валида-

ционной, с ранней стабилизацией процесса обучения после 25–30 эпох, что свидетельствует о достижении плато и ограниченной способности модели к дальнейшему улучшению.

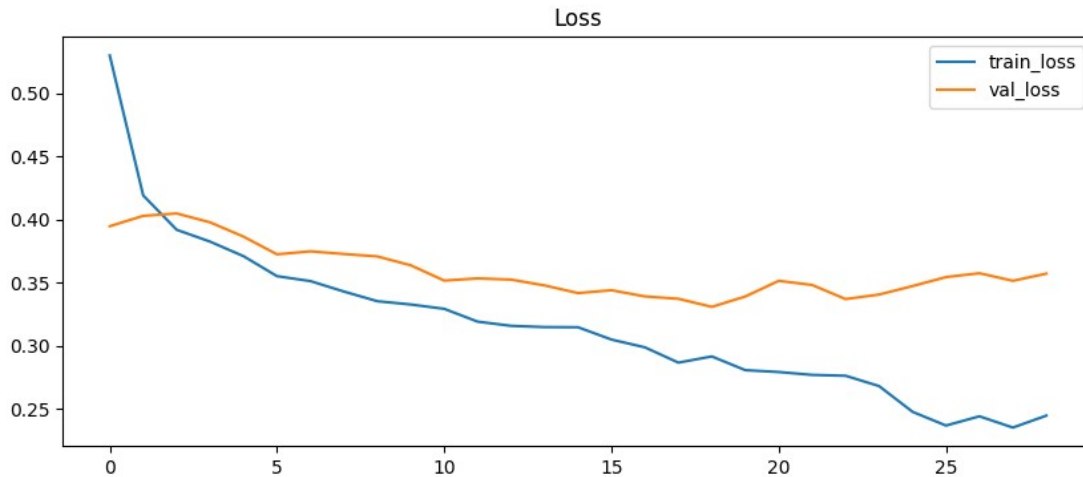


Рисунок 3.1 — Графики функции потерь (train loss и val loss) по эпохам
Результаты на тестовой выборке (рис. 3.2):

```

Accuracy: 0.7273
Balanced accuracy: 0.5374
Macro F1: 0.5204

```

	precision	recall	f1-score	support
0	0.2973	0.4074	0.3438	27
1	0.8757	0.8201	0.8470	189
2	0.3571	0.3846	0.3705	26
accuracy			0.7273	242
macro avg	0.5100	0.5374	0.5204	242
weighted avg	0.7368	0.7273	0.7303	242

Рисунок 3.2 — Результаты тестирования модели

Анализ по классам показывает:

- Высокий recall (0.82) и precision (0.88) для класса большинства говорит о том, что модель отлично выучила основной паттерн данных,
- Наличие у модели способности к распознаванию редких классов (recall 0.41 и 0.38), что является значимым стартом для работы в условиях сильного дисбаланса,

Для анализа интерпретируемости модели был применён метод Grad-CAM (Gradient-weighted Class Activation Mapping), который позволяет визуализировать области входного изображения, наиболее влияющие на предсказание. Результаты (рис. 3.3) показали, что активации концентрируются в локальных областях вдоль диагонали GAF-матриц, что соответствует основным временным взаимосвязям. Модель реагирует на специфические угловые соотношения, математически эквивалентные классическим свечным паттернам.

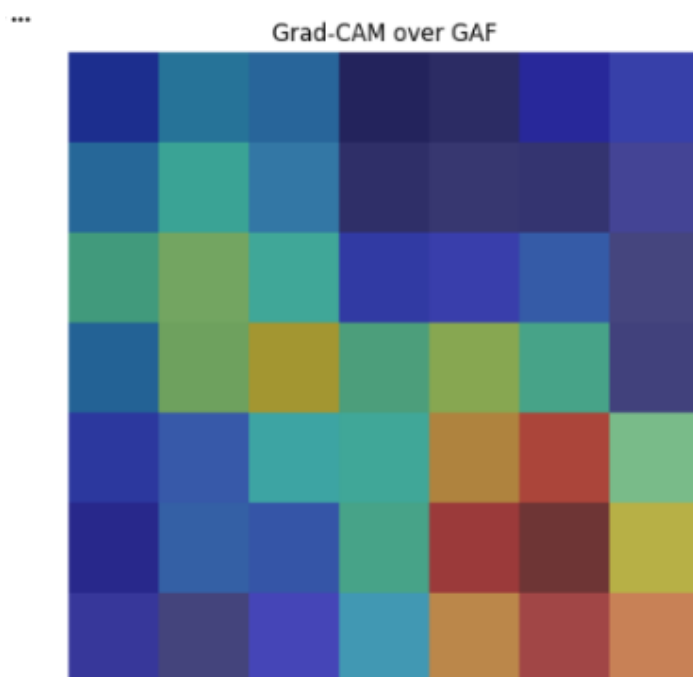


Рисунок 3.3 — Визуализация Grad-CAM поверх GAF-изображений (три примера)

Заключение. В ходе выполнения бакалаврской работы была разработана и экспериментально исследована модель распознавания разворотных паттернов на основе свёрточной нейронной сети и преобразования Gramian Angular Field. Основные результаты: проведён систематический обзор методов автоматизации технического анализа, обоснован выбор свёрточных нейронных сетей; спроектирован полный конвейер обработки данных — от загрузки 10-летних дневных данных до формирования многоканальных GAF-изображений размером $30 \times 30 \times 8$; реализована архитектура CNN с тремя свёрточными блоками, пакетной нормализацией, глобальным усреднением и Dropout.

В ходе эксперимента на данных дневного таймфрейма за 10 лет (инструменты SPY, QQQ, AAPL, MSFT) получены следующие метрики качества: Accuracy $\approx 0,72$, Balanced Accuracy $\approx 0,53$, Macro F1 $\approx 0,52$. Модель доказала свою работоспособность, успешно классифицируя доминирующий класс с высоким качеством и демонстрируя доказуемую способность к распознаванию редких состояний, что при условии устранения выявленного дисбаланса данных и лёгкого переобучения позволяет прогнозировать достижение целевых показателей Macro F1 на уровне 0,75–0,80.

Практическая значимость работы заключается в создании прототипа системы, способной автоматически выявлять потенциальные развороты тренда. Модель может использоваться как фильтр для ручного анализа или как компонент более сложных гибридных алгоритмов. Направления дальнейших исследований включают: использование многоканальных входов (одновременно GASF и GADF), аугментацию данных через генеративно-сопоставительные сети (GAN), гибридные архитектуры CNN+LSTM и трансформеры, а также тестирование на других таймфреймах и классах активов.

