

УДК: 004.852

Обнаружение точек разворота на финансовых данных с помощью методов глубокого машинного обучения

Н. А. Моисеев^а, Д. И. Назарова, Н. С. Семина, Д. А. Максимов

РЭУ им. Г.В. Плеханова,
Россия, 115054, г. Москва, Стремянный пер., д. 37

E-mail: ^а moiseev.na@rea.ru

Получено 15.09.2023, после доработки — 18.10.2023.

Принято к публикации 17.11.2023.

Цель настоящего исследования заключается в разработке методологии выявления точек разворота на временных рядах, включая в том числе финансовые данные. Теоретической основой исследования послужили работы, посвященные анализу структурных изменений на финансовых рынках, описанию предложенных алгоритмов обнаружения точек разворота и особенностям построения моделей классического и глубокого машинного обучения для решения данного типа задач. Разработка подобного инструментария представляет интерес для инвесторов и других заинтересованных сторон, предоставляя дополнительные подходы к эффективному анализу финансовых рынков и интерпретации доступных данных.

Для решения поставленной задачи была обучена нейронная сеть. В ходе исследования было рассмотрено несколько способов формирования тренировочных выборок, которые различаются характером статистических параметров. Для повышения качества обучения и получения более точных результатов была разработана методология формирования признаков, служащих входными данными для нейронной сети. В свою очередь, эти признаки формируются на основе анализа математического ожидания и стандартного отклонения временных рядов на некоторых интервалах. Также исследуется возможность их комбинации для достижения более стабильных результатов.

Результаты модельных экспериментов анализируются с целью сравнения эффективности предложенной модели с другими существующими алгоритмами обнаружения точек разворота, получившими широкое применение в решении практических задач. В качестве тренировочных и тестовых данных используется специально созданный датасет, генерация которого осуществляется с использованием собственных методов. Кроме того, обученная на различных признаках модель тестируется на дневных данных индекса S&P 500 в целях проверки ее эффективности в реальном финансовом контексте.

По мере описания принципов работы модели рассматриваются возможности для дальнейшего ее усовершенствования: модернизации структуры предложенного механизма, генерации тренировочных данных и формирования признаков. Кроме того, перед авторами стоит задача развития существующих концепций определения точек изменения в режиме реального времени.

Ключевые слова: точки разворота, временные ряды, финансовые рынки, машинное обучение, нейронные сети

Данное исследование выполнено в рамках государственного задания в сфере научной деятельности Министерства науки и высшего образования РФ на тему «Модели, методы и алгоритмы искусственного интеллекта в задачах экономики для анализа и стилизации многомерных данных, прогнозирования временных рядов и проектирования рекомендательных систем», номер проекта FSSW-2023-0004.

UDC: 004.852

Changepoint detection on financial data using deep learning approach

N. A. Moiseev^a, D. I. Nazarova, N. S. Semina, D. A. Maksimov

Plekhanov Russian University of Economics,
37 Stremyanny lane, Moscow, 115054, Russia

E-mail: ^a moiseev.na@rea.ru

*Received 15.09.2023, after completion — 18.10.2023.
Accepted for publication 17.11.2023.*

The purpose of this study is to develop a methodology for change points detection in time series, including financial data. The theoretical basis of the study is based on the pieces of research devoted to the analysis of structural changes in financial markets, description of the proposed algorithms for detecting change points and peculiarities of building classical and deep machine learning models for solving this type of problems. The development of such tools is of interest to investors and other stakeholders, providing them with additional approaches to the effective analysis of financial markets and interpretation of available data.

To address the research objective, a neural network was trained. In the course of the study several ways of training sample formation were considered, differing in the nature of statistical parameters. In order to improve the quality of training and obtain more accurate results, a methodology for feature generation was developed for the formation of features that serve as input data for the neural network. These features, in turn, were derived from an analysis of mathematical expectations and standard deviations of time series data over specific intervals. The potential for combining these features to achieve more stable results is also under investigation.

The results of model experiments were analyzed to compare the effectiveness of the proposed model with other existing changepoint detection algorithms that have gained widespread usage in practical applications. A specially generated dataset, developed using proprietary methods, was utilized as both training and testing data. Furthermore, the model, trained on various features, was tested on daily data from the S&P 500 index to assess its effectiveness in a real financial context.

As the principles of the model's operation are described, possibilities for its further improvement are considered, including the modernization of the proposed model's structure, optimization of training data generation, and feature formation. Additionally, the authors are tasked with advancing existing concepts for real-time changepoint detection.

Keywords: changepoint detection, time series analysis, financial markets, machine learning, neural networks

Citation: *Computer Research and Modeling*, 2024, vol. 16, no. 2, pp. 555–575 (Russian).

This research was performed in the framework of the state task in the field of scientific activity of the Ministry of Science and Higher Education of the Russian Federation, project "Models, methods, and algorithms of artificial intelligence in the problems of economics for the analysis and style transfer of multidimensional datasets, time series forecasting, and recommendation systems design", grant no. FSSW-2023-0004.

1. Введение

С момента возникновения финансовых рынков предпринимались попытки проанализировать их поведение и предсказать будущие движения. Инвесторы всегда стремились разработать эффективный инструментарий, использование которого позволило бы принимать обоснованные торговые решения. Одним из таких методов является обнаружение точек разворота, появление которых свидетельствует об изменениях тренда и сигнализирует о необходимости смены трейдинговой стратегии.

На настоящий момент пласт исследований по теме представлен широким разнообразием методик, основанных на различных аналитических методах, таких как технический анализ, фундаментальный анализ и анализ с использованием некоторых статистических моделей. Однако, несмотря на значительный прогресс в этой области, точное прогнозирование точек разворота остается сложной задачей.

В последние годы нейронные сети стали широко применяться для решения проблем анализа данных благодаря своей способности обрабатывать большие объемы данных. Эффективным должно оказаться приложение данного класса моделей к задачам, актуальным на финансовых рынках.

2. Литературный обзор

Задача трекинга структурных изменений на рынках ценных бумаг уже давно находится в сфере интересов исследователей. Работы [Stock, Watson, 1996; Koop, Potter, 2001; Денежкина и др., 2013] посвящены оценке распространенности нестабильности в экономических рядах. Простейшая модель обнаружения точки изменения тренда может например заключаться в использовании t -статистики, F -статистики, p -значений или изменения распределения вероятностей функции правдоподобия. Такие подходы чаще всего используются для сравнения средних дневной доходности индекса до и после определенной даты, как это реализовано, например, в [Bos, Hoontrakul, 2002; Nikkinen et al., 2008; Liu et al., 2013; Tsay, 1988], где таким образом проводилась оценка степени и факта влияния событий 11 сентября на разные мировые рынки. Авторы исследования [Ромм, Тренкеншу, 2012] определяют точку изменения тренда, оценивая расстояние между точками экстремума, которые на графике представляют начало и конец тренда однородного характера (восходящий или нисходящий).

Дальнейшее развитие темы заключается в применении нейронных сетей для решения подобных задач. Например, в работе [Banerjee, Guhathakurta, 2020] использован метод графов на основе ядра радиального базиса Гаусса, что является развитием работ [Zhou, Lafferty, Wasserman, 2010; Kolar, Xing, 2011], посвященных применению метода графов на временных рядах. Преимуществом этого метода является то, что для дальнейшего анализа не обязательно знать тип распределения данных в выборке. Цель исследования состояла в определении того факта, что определенные события (крупнейшие кризисы на финансовых рынках) оказали влияние на конкретные индексы, задачи предсказывать точки разворота у авторов не стояло.

К выводу о применимости глубинного машинного обучения к проблеме обработки финансовых данных приходят авторы ряда работ, например [Xu et al., 2020; Staffini, 2022; Labiad, Berrado, Benabbou, 2023]. В [He et al., 2023] был проведен сравнительный анализ использования разных архитектур нейронных сетей для предсказания данных финансовых рынков (Шанхайская биржа и биткоин). Для тестирования были выбраны LSTM, CNN и MLP, однозначного преимущества не показала ни одна из представленных моделей.

Одной из первых статей, где задача стояла в обучении нейронной сети, которая могла бы заранее предсказать точку разворота, стала работа [Yoo et al., 2021]. Исследование проводилось

на основе индекса Russell 2000 в секторах здравоохранения, информационных технологий и потребительских товаров. В качестве метода оценки выбран тест Петтитта, предназначенный для обнаружения единой точки изменения на временных рядах с непрерывными данными. Обучение происходит на базе архитектуры DAE-LSTM. Авторы смогли предсказывать точку разворота в среднем за 7 дней до ее фактического появления.

Вне исследований, связанных с изучением финансовых рынков, интерес представляют работы, посвященные методам поиска точек разворота на временных рядах. Одним из первых алгоритмов обнаружения точек изменения, применимых к временным рядам, является бинарная сегментация, представленная в [Scott, Knott, 1974]. Его дальнейшим расширением является алгоритм PELT [Killick, Fearnhead, Eckley, 2012], в котором точки разворота рассчитываются путем минимизации функции затрат с правдоподобием со штрафом, что позволяет свести алгоритм к линейной сложности вычисления и сократить затраты времени, при этом получаемые результаты остаются достаточно точными.

3. Методология

В рассмотренных исследованиях за идеей точки разворота стояла базовая идея о том, что индикатором изменения является резкая смена тренда, определенная с помощью вполне конкретных, заданных изначально правил (статистические тесты, метрики на пространстве вероятностных мер). Зачастую так или иначе сравниваются средние значения временного ряда, их стандартное отклонение или комбинация этих двух признаков. Этот подход будет также использован в текущем исследовании.

Нерешенной, как правило, оказывается проблема потери данных. Она связана с тем, что определенное количество граничных первых и последних значений ряда не используется, поскольку просчет среднего и стандартного отклонения требует некоторого количества точек. Таким образом, при использовании достаточно широкого окна значительно сокращается длина сигнала, который используется в качестве компонента модели. В данной работе была поставлена цель разработать такой алгоритм, при использовании которого вне зависимости от выбранной длины окна скользящих средних и стандартного отклонения длина векторов признаков, подаваемых в модель, была бы равна длине исходного сигнала. Это позволяет конструировать необходимое пользователю число признаков, отражающих сравнение двух произвольных окон.

В отличие от рассмотренных источников, в которых результатом работы моделей является некоторое множество точек, определенных как точки разворота, алгоритм, представленный в текущем исследовании, на выходе возвращает массив дробных чисел. Таким образом, для каждой точки сигнала определяется вероятность нахождения в ней точки разворота — число от нуля до единицы. Это позволяет как настроить параметр чувствительности, который пользователь сможет регулировать сам в зависимости от специфики временного ряда, так и продвинуть идею обнаружения точек изменения в онлайн-задачах.

Основное обоснование использования такого рода выходных данных заключается в последующей возможности настройки порога чувствительности определения точек разворота. Важным в проблеме выявления таких точек является тот факт, что они объективно не определены и их наличие зависит от контекста, то есть от того, что пользователь понимает под точкой разворота. Кроме того, разворот может проявляться как переход между трендами, тогда четкое выделение конкретной точки изменения еще более проблематично. Потому использование именно вероятностных выходных данных отражает присущую финансовым временным рядам двусмысленность и позволяет пользователю регулировать уровень уверенности в результатах работы модели самостоятельно или прибегая к настройке параметров постобработки, отвечающих за уточнение прогнозов алгоритма за счет очистки плотно распределенных точек при заданном

пороге. Таким образом обеспечивается гибкость в установлении компромисса между ложноположительными и ложноотрицательными срабатываниями, удовлетворяя ожиданиям пользователя в размере интервалов в зависимости от его целей.

В рамках проведенного исследования реализовано несколько способов генерации сигнала для тренировки и тестирования модели. Выбор модельных признаков осуществляется в зависимости от характеристик сигнала. Процесс обучения и тестирования модели основан на следующих типах данных: первый — это сигнал, где точки изменения разграничивают интервалы с различными средними значениями; второй отражает разнообразие в стандартных отклонениях; третий — одновременное наличие отличий в обеих указанных характеристиках.

Для каждого из методов задаются следующие переменные:

$$X = \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix},$$

где X — сигнал;

$$Y = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix},$$

где Y — вектор целевой переменной.

Следует отметить, что целевая переменная является бинарной. При этом для обучения модели и дальнейшей оценки результатов точкой изменения (единицей) размечена как первая точка изменившегося тренда, так и последняя точка предыдущего периода. Это позволяет установить более щадящие требования к предсказаниям модели и поощряет повышение вероятности в точках, лежащих в окрестности реальной точки изменения. Более того, при подведении итогов и оценке эффективности работы как заявленной авторами модели, так и общепринятых PELT и BinSeg каждая из них имеет больший шанс улучшить собственный результат.

Перед просчетом признаков модели сигнал расширяется в обе стороны на размер окна m методом паддинга крайними значениями, а затем первые m пустующих значений обрезаются. Для корректной работы модели длина вектора, на основе которого рассчитываются признаки, подающиеся как компоненты в модель, должна превышать длину сигнала ровно на размер рассчитываемого окна, то есть на основе расширенного таким образом сигнала выполняется условие по необходимой длине скользящей средней в $n+m$ точек. В свою очередь, это позволяет избежать потери данных и повышает обучаемость модели на следующих шагах работы алгоритма.

Единицы в векторе Y соответствуют крайним точкам смены тренда, и таким образом делят датасет на некоторые интервалы, границы которых необходимо определить. Соответственно, если между установленными двумя интервалами нет точки разворота, они имеют схожие характеристики, например математическое ожидание. Если же точка разворота имеется, то и характеристики будут различаться. Ввиду того, что установка конкретных характеристик, понятных человеку, может незначительно сказываться на качестве модели, следует позволить алгоритму самостоятельно выявить паттерн для поиска значения целевой переменной.

Так, две базовые идеи, сравнение математического ожидания и статистического разброса переменных, отражаются в представленных авторами признаках модели.

3.1. Признак скользящей средней

Во-первых, опишем формирование признака, основанного на расчете скользящей средней по заданному окну:

$$\mu = \begin{bmatrix} \mu_0 \\ \mu_1 \\ \vdots \\ \mu_{n+m} \end{bmatrix},$$

где μ — вектор скользящей средней, n — длина сигнала, m — длина окна.

Значение вектора μ в точке k принимает вид

$$\mu_k = \frac{\sum_{i=k-m+1}^k x_i}{m} \quad \text{при } 0 \leq k \leq n + m.$$

Таким образом, каждой точке сигнала будет соответствовать элемент в векторе μ , и для любой точки становится возможным генерация признака модели:

$$\varphi = \begin{bmatrix} \varphi_0 \\ \varphi_1 \\ \vdots \\ \varphi_n \end{bmatrix},$$

где φ — признак модели.

Имея дело со средними значениями интервалов, достаточно взять значение их разницы по модулю. Потому определим признак φ как

$$\varphi_k = \left| \mu_k(m_1) - \mu_{k+m_2}(m_2) \right|, \quad (1)$$

где m_1 — длина окна первой скользящей средней, m_2 — длина окна второй скользящей средней.

Таким образом, признак φ представляет из себя абсолютную разницу значений вектора скользящей средней окна m_1 в точке k и вектора скользящей средней окна m_2 в точке $k + m_2$. Проще говоря, сравниваются средние m_1 значений до текущей точки x_i и m_2 значений после. Алгоритм подразумевает попарное итерирование между произвольно задаваемыми длинами окон — по умолчанию [7, 14, 30, 50, 120]. Использование скользящих средних различной чувствительности позволяет как сгладить незначительные, непродолжительные изменения, так и отследить резкую смену тренда.

Все рассчитанные признаки затем объединяются в матрицу (табл. 1).

Таблица 1. Матрица признаков для обучения модели

	7_7_среднее	...	7_120_среднее	14_7_среднее	...	14_120_среднее	...	120_7_среднее	...	120_120_среднее
0	значение	...	значение	значение	...	значение	...	значение	...	значение
1	значение	...	значение	значение	...	значение	...	значение	...	значение
2	значение	...	значение	значение	...	значение	...	значение	...	значение
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$n - 1$	значение	...	значение	значение	...	значение	...	значение	...	значение

Каждый из столбцов матрицы содержит информацию об одном из признаков. Так, например, значения в первой колонке — это абсолютная разница среднего по семи значениям до текущей точки и среднего семи значений после нее. Трактровка остальных признаков осуществляется по аналогии. Именно эта матрица затем подается в модель в качестве входных данных.

3.2. Признак скользящего стандартного отклонения

Во-вторых, для сигнала, сгенерированного методом изменения стандартного отклонения, опишем формирование признака скользящего стандартного отклонения:

$$\theta = \begin{bmatrix} \theta_0 \\ \theta_1 \\ \vdots \\ \theta_{n+m} \end{bmatrix},$$

где θ — вектор скользящего стандартного отклонения.

Базовые условия, определенные для вектора μ , справедливы и для вектора θ . Так, для расчета параметра необходимо изначально расширить сигнал в начале и конце временного ряда на длину окна, чтобы получить длину вектора стандартного отклонения в $n + m$ точек. Тогда элемент вектора θ в точке k определен как

$$\theta_k = \sqrt{\frac{\sum_{i=k-n+1}^k (x_i - \bar{x})^2}{n}} \quad \text{при } 0 \leq k \leq n + m.$$

Аналогично ситуации с вектором скользящей средней каждой точке сигнала X соответствует некоторый элемент вектора θ , что позволяет сконструировать новый признак модели η :

$$\eta = \begin{bmatrix} \eta_0 \\ \eta_1 \\ \vdots \\ \eta_n \end{bmatrix}.$$

Признак, записанный в векторе η , как и в предыдущем случае, построен на основе сравнения некоторой характеристики временного ряда на определенном промежутке до и после заданной точки. С учетом статистического смысла стандартного отклонения более рациональным представляется расчет относительного изменения значения следующего периода к предыдущему:

$$\eta = \frac{\theta_k(m_1)}{\theta_{k+m_2}(m_2)}. \quad (2)$$

Таким образом, точке сигнала x_i соответствует отношение k -го элемента вектора стандартного отклонения θ , являющегося стандартным отклонением m_1 точек до текущей точки x_i , к элементу вектора θ в точке $k + m_2$ — то есть стандартного отклонения m_2 точек, следующих за x_i . Аналогично признаку φ пользователь самостоятельно задает размеры окон, по умолчанию являющиеся такими же, какие были заявлены ранее.

Как и ранее, признаки η собираются в матрицу, аналогичной матрице с признаками φ (табл. 1) для подачи в качестве входного сигнала в модель.

Кроме того, для обучения модели на основе сигнала, сгенерированного по принципу различного от интервала к интервалу стандартного отклонения, осуществляется образование и других признаков. Так, текущая матрица, кроме описанных выше признаков η , содержит и следующие:

$$\eta_k^* = \frac{r_k}{\theta_{k-1}(m)}, \quad (3)$$

$$r_k = \frac{x_i - x_{i-1}}{x_{i-1}} \quad \text{при } k = i,$$

где r_k — относительное изменение сигнала текущей точки к предыдущей.

Признак η^* показывает, насколько текущее изменение значения сигнала отличается от статистического разброса за предыдущие m дней.

В случае генерации сигнала, где от интервала к интервалу варьируются и математическое ожидание, и стандартное отклонение, для подачи в модель просчитываются и стыкуются обе описанные матрицы. Авторами предполагается последующее улучшение качества модели за счет более сложных способов генерации значений сигнала X . Так как предполагается, что модель может быть полезна для определения точек смены тренда индекса фондовой биржи или, например, стоимости акций, сигнал будет включать в себя периоды коррекции, стационарности и прочие характеристики, присущие финансовым данным.

4. Архитектура нейронной сети

За основу модели взята идея многослойного персептрона (полносвязные слои). Так, нейронная сеть состоит из трех элементов: входного слоя, одного или более скрытых слоев и выходного слоя (рис. 1) [Popescu et al., 2009]. На вход модели поступает набор сгенерированных факторов x_0, x_1, \dots, x_n . В данном исследовании входной слой представлен не одномерным временным рядом, а матрицей, сформированной из ранее рассчитанных векторов φ и η . Скрытые слои описываемой модели представляют из себя два слоя со 120 и 100 нейронами соответственно. Задача модели на данном этапе преобразовать данные, поступившие из предыдущего слоя, присваивая им определенные веса w_0, w_1, \dots, w_r таким образом, чтобы минимизировать функцию потерь (в данном исследовании в качестве функции потерь была взята перекрестная энтропия). Выходной результат затем корректируется с помощью нелинейной функции активации ReLU, рассчитываемой по формуле

$$\text{ReLU} = \begin{cases} x, & \text{если } x \geq 0, \\ 0, & \text{если } x < 0 \end{cases} = \max(x, 0).$$

На выходном слое с помощью преобразования softmax модель возвращает вероятность того, что рассматриваемые точки могут быть определены как точки разворота. Далее пользователь либо на свое усмотрение устанавливает правила распределения точек на классы, либо самостоятельно интерпретирует вероятностный результат. Для вычисления значений параметров нейронной сети использовался метод обратного распространения ошибок.

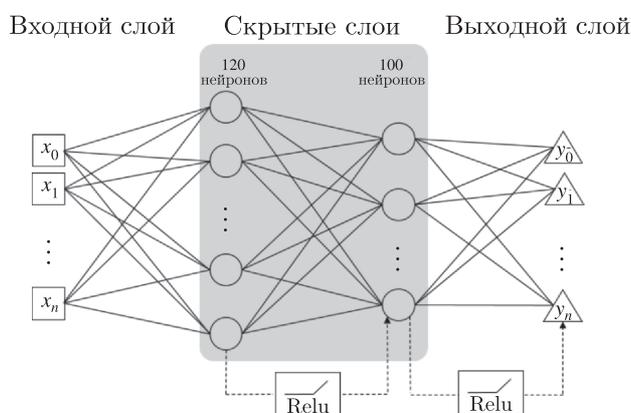


Рис. 1. Архитектура нейронной сети, где x_1, x_2, \dots, x_n — входные данные, y_1, y_2, \dots, y_n — выходные данные

В целях профилактики переобучения модели используется регуляризация L2, которая изменяет изначальную функцию потерь таким образом, что отличные значения весов корректируются за счет определения размера штрафа:

$$\sum_{i=1}^N (y_n - \widehat{y}_n)^2 + \lambda |w|^2,$$

где y_n — значение целевой переменной, \widehat{y}_n — предсказание модели, λ — коэффициент корректировки, w — изначально рассчитанный вес [Cortes, Mohri, Rostamizadeh, 2009].

Здесь первое слагаемое представляет из себя показатель ошибки модели по метрике, а второе — непосредственно начисляемый штраф. В разработанной авторами модели степень влияния данной меры через величину присваиваемого ей веса задается через параметр «альфа» и имеет значение 0,001.

Кроме того, также был настроен параметр темпа обучения, который контролирует переобучение модели в зависимости от размера ошибки на предыдущем шаге [Igir et al., 2015]. Он необходим для того, чтобы избежать проблемы достижения локального минимума: при недостаточном значении параметра процесс обучения перестанет идти, а при слишком высоком — модель будет обучаться слишком быстро, предоставляя нестабильные результаты. Оптимальным было установлено значение 0,0001.

Для обработки вероятностных результатов в целях их перевода в бинарный вид, то есть решения проблемы множественного определения точек разворота на коротком промежутке при заданном пороговом значении вероятности, может быть использовано несколько подходов. Например, можно искать медианную по индексу точку на промежутке с высокой плотностью результатов модели, отвечающих требованию порогового значения. Однако этот подход не является достаточно сбалансированным: так, после изменения тренда финансового инструмента сигнал еще некоторое время может быть нестабильным — подверженным корректировке под влиянием человеческого фактора, и в таком случае фактическая точка изменения окажется сдвинута влево. Потому авторами было принято решение в качестве окончательной точки разворота выбирать ту, для которой модель определила наибольшую вероятность. При этом сравнение происходит для каждой потенциальной точки с теми, которые находятся от нее на j точек до и после на временной шкале, где j — настраиваемый гиперпараметр.

5. Модельные эксперименты

Модельные эксперименты представляют из себя обучение и тестирование нейронной сети и последующее сравнение результатов с базовыми моделями PELT и BinSeg, сущность которых была описана в литературном обзоре. Это подразумевает под собой генерацию данных по трем описанным сценариям, расчет метрик качества моделей и последовательный анализ результатов с поправкой на то, что предварительно выставлены как оптимально настроенные параметры базовых моделей, так и признаки сгенерированы матрицы признаков φ и η . Следует отметить, что все тренировочные временные ряды содержали 100 000 точек, а тестировались модели на сигналах длиной 10 000 точек, 100 из которых являлись точками изменения. Для BinSeg мы устанавливаем значение настраиваемого параметра целевого количества точек на временном ряде на уровне их фактического количества, равного 100.

В качестве метрик для сравнения эффективности исполнения моделями поставленных задач были выбраны ROC AUC, accuracy, precision, recall, F1, а также визуализация ошибок 1-го, 2-го рода и случаев верного срабатывания модели с помощью матрицы ошибок, где True Negative — истинноотрицательные значения, False Positive — ложноположительные значения, False Negative — ложноотрицательные значения, True Positive — истинноположительные значения.

Метрика accuracy (достоверность) соответствует доле корректно классифицированных алгоритмом точек на всей длине сигнала; precision (точность) отражает долю истинно положительных значений среди всех тех, которые были определены моделью как положительные; recall (полнота) показывает процент объектов положительного класса, которые модель выявила среди всех фактических объектов данного класса. F1 рассчитывается как гармоническое среднее между точностью и полнотой, таким образом приводя в баланс количество ложных и истинных срабатываний. ROC AUC (Receiver Operating Characteristic — Area Under the Curve) представляют из себя кривую, для которой по оси абсцисс расположена доля объектов отрицательного класса, ошибочно классифицированных как положительные, по оси ординат — уже ранее упомянутая метрика полноты (recall). Таким образом, происходит оценка способности алгоритма различать два класса, причем метрика не привязана к бинарному виду предсказаний. Ввиду того, что, во-первых, ROC AUC особенно полезна при работе с вероятностными результатами и, во-вторых, для задач определения точек разворота характерен сильный дисбаланс классов, она выбрана в качестве основной метрики качества представленной авторами модели. Однако необъективность сравнения выходных данных нейронной сети с PELT и BinSeg при помощи ROC AUC предопределяет необходимость конвертации вероятностных результатов в бинарные и проведения последующего анализа матрицы ошибок, метрик precision, recall и F1. Для корректной оценки важным является понимание процента ложно и верно определенных значений. Кроме того, следует вспомнить, что целевая переменная представляет из себя набор нулей и единиц, где точка разворота размечена единицами на двух соседних индексах (конец предыдущего трендового периода и начало следующего). Ввиду специфики работы авторского алгоритма не существует таких случаев, когда обе этих точки классифицировались бы как точки разворота, однако такой исход возможен для BinSeg. Так, например, метрика recall будет фактически занижена вдвое (за счет настроенных параметров фильтрации пробабалистических результатов и их перевода в бинарный вид авторский алгоритм не отметит больше 100 точек), однако деление на 0,5 не является целесообразным, так как в таком случае сравнение алгоритмов не будет репрезентативным.

Результаты обработки датасета с переменным от интервала к интервалу математическим ожиданием для всех трех моделей представлены на рис. 2. В разрезе оценки качества по метрике ROC AUC PELT и BinSeg показали практически идентичные результаты — 0,5714 и 0,5847 соответственно. Значение метрики ROC AUC авторской модели, обученной на матрице признаков η соответствующего сигнала, оказалось более чем на 65 % выше и составило 0,9663.

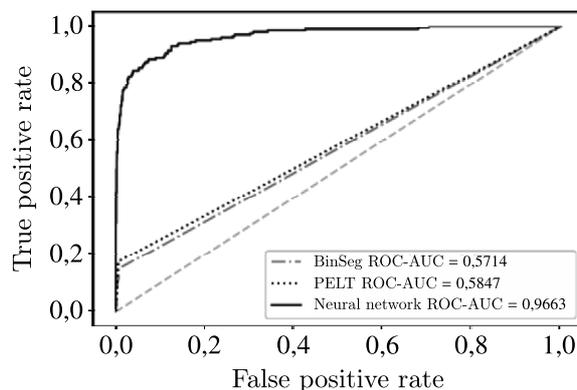


Рис. 2. ROC AUC на наборе данных с изменяющимся математическим ожиданием для моделей BinSeg, PELT, авторской модели. True positive rate — доля истинно положительных значений, false positive rate — доля ложноположительных значений, neural network — разработанная авторами нейронная сеть. Пунктиром обозначена диагональ, при которой значение ROC AUC равно 0,5, что соответствует случайному угадыванию

Тем не менее, если провести предварительную очистку точек по описанному ранее алгоритму, чтобы снизить сконцентрированность более высоких вероятностей в окрестностях реальных точек изменений, ROC AUC нейронной сети снижается до 0,6436 и все еще остается выше, чем у PELT и BinSeg. Как было отмечено ранее, для моделей с бинарными выходными данными более репрезентативной является матрица ошибок (рис. 3), а также метрики precision, recall, F1. Так, модель, описанная в текущей работе, имеет меньше ошибок и первого, и второго рода, то есть реже обозначает единицами точки, которые не являются точками изменения, и нулями те, которые точками изменения являются. Соответственно, precision и recall (табл. 2) улучшаются примерно в полтора раза по сравнению с остальными моделями.

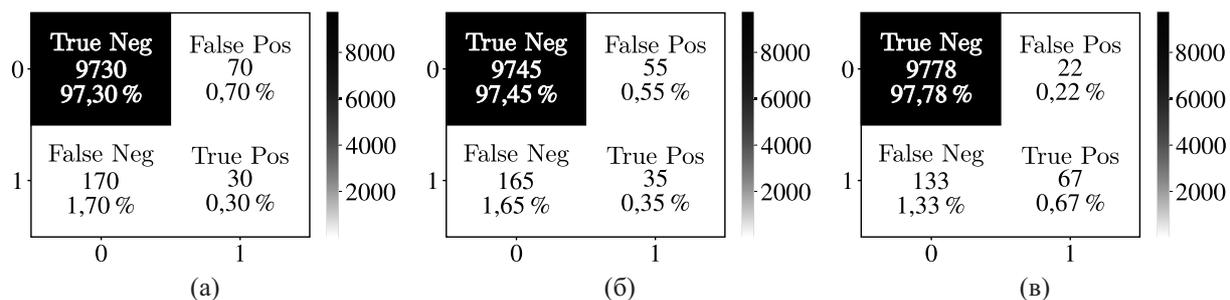


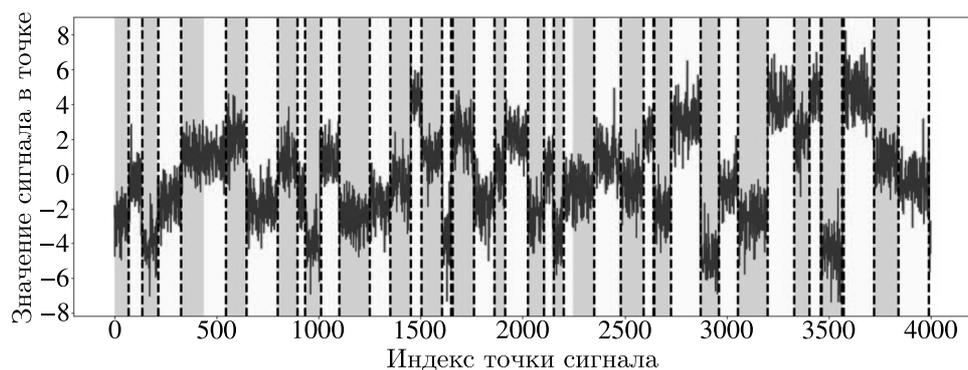
Рис. 3. Матрица ошибок для моделей BinSeg (а), PELT (б), авторской модели (в) при обучении на наборе данных с изменяющимся математическим ожиданием. True Neg — истинноотрицательные значения, False Pos — ложноположительные значения, False Neg — ложноотрицательные значения, True Pos — истинноположительные значения

Таблица 2. Метрики качества на наборе данных с изменяющимся математическим ожиданием для моделей BinSeg, PELT, авторской модели

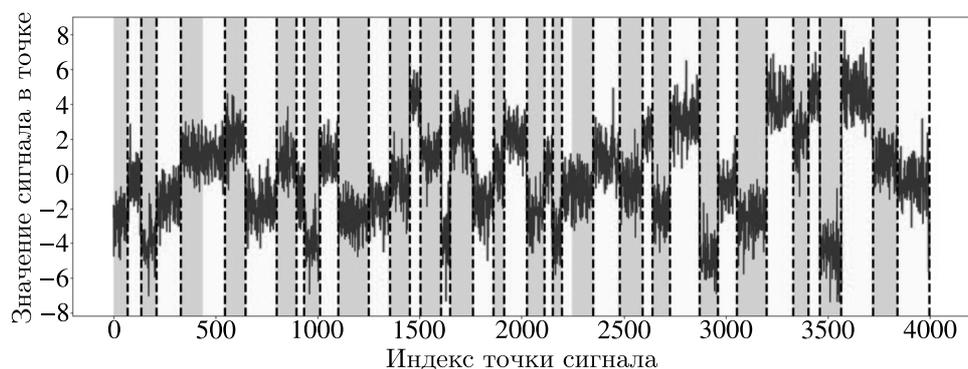
Метрика	Модель		
	BinSeg	PELT	Авторская модель
Accuracy	0,976	0,978	0,985
Precision	0,300	0,389	0,753
Recall	0,150	0,175	0,335
F1 Score	0,200	0,241	0,464

Перейдем к рассмотрению графиков, где на тестовую выборку, границы интервалов которой обозначены сменой яркости заливки, наложены определенные алгоритмом точки разворота — пунктирные линии (рис. 4). Эмпирическая оценка позволяет прийти к выводу, что PELT верно обозначил наибольшее количество точек изменений, что на самом деле противоречит результатам матрицы ошибок. На самом деле модель размечает не фактически верные точки, а расположенные в их некоторой окрестности. В частности, именно по этой причине precision оказывается ниже, чем у нейронной сети, которая рассматривает все потенциальные точки, расположенные в некоторой окрестности, и выбирает среди них имеющую наибольшую вероятность. Оптимизация порога чувствительности позволила снизить число ложных срабатываний представленной в исследовании модели практически в два раза по сравнению с PELT и более чем в два раза по сравнению с BinSeg.

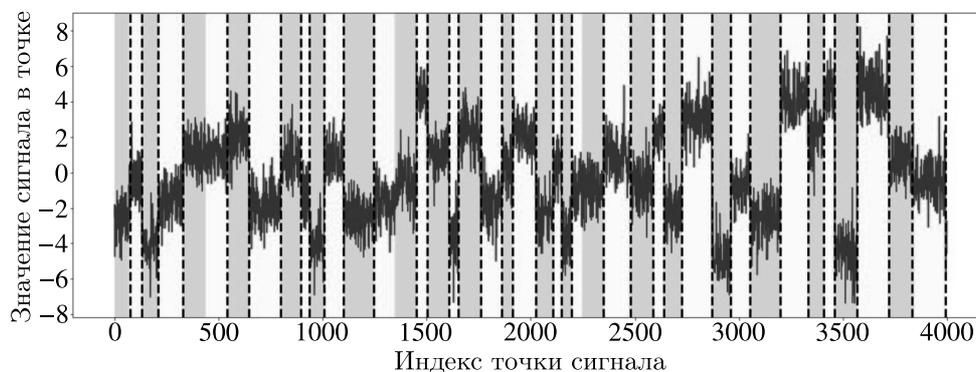
На наборе данных с изменяющимся стандартным отклонением все модели показали результат ниже: ROC AUC составил 0,5459, 0,5380 и 0,8682 соответственно для BinSeg, PELT и вероятностных предсказаний нейронной сети (рис. 5). Даже после приведения результатов предложенной модели в бинарный вид ROC AUC оказался на уровне 0,5728. Так, можно сделать вывод, что разграничение интервалов, в которых варьируется стандартное отклонение, является



(а)



(б)



(в)

Рис. 4. Реализация алгоритмов BinSeg (а), PELT (б), авторской модели (в) на искусственно сгенерированных данных с меняющимся математическим ожиданием. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота, смена заливки обозначает фактическую точку разворота

непростой задачей для алгоритмов машинного обучения и требует доработки. Модели, которые показывают высокие результаты на подобных типах данных, могут быть использованы для анализа финансовых инструментов по их доходностям, например, дневным.

По всем остальным метрикам нейронная сеть тоже оказывалась лучшей среди рассматриваемых моделей, превышая показатели базовых алгоритмов в два и более раз. Анализ матрицы ошибок показывает, что наибольшее количество корректно выявленных точек — 34 — принадлежит нейронной сети, в то время как данный показатель составил 20 и 16 для BinSeg и PELT соответственно (рис. 6). Соответственно, precision, recall и F1 score, полученные для нейронной сети, показали более положительную динамику (табл. 3).

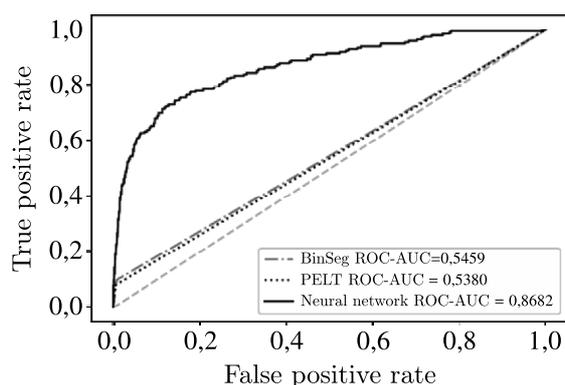


Рис. 5. ROC AUC на наборе данных с изменяющимся стандартным отклонением для моделей BinSeg, PELT, авторской модели. True positive rate — доля истинноположительных значений, false positive rate — доля ложноположительных значений, neural network — разработанная авторами нейронная сеть. Пунктирная обозначена диагональ, при которой значение ROC AUC равно 0,5, что соответствует случайному угадыванию

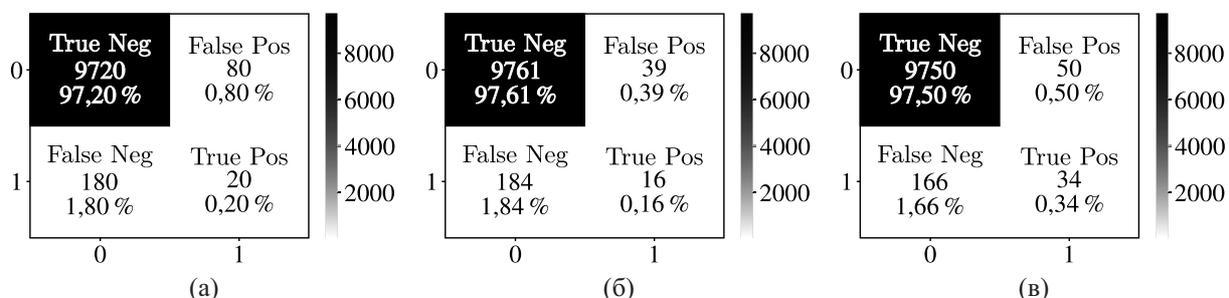


Рис. 6. Матрица ошибок для моделей BinSeg (а), PELT (б), авторской модели (в) при обучении на наборе данных с изменяющимся стандартным отклонением. True Neg — истинноотрицательные значения, False Pos — ложноположительные значения, False Neg — ложноотрицательные значения, True Pos — истинноположительные значения

Таблица 3. Метрики качества на наборе данных с изменяющимся стандартным отклонением для моделей BinSeg, PELT, авторской модели

Метрика	Модель		
	BinSeg	PELT	Авторская модель
Accuracy	0,974	0,978	0,978
Precision	0,200	0,291	0,405
Recall	0,100	0,080	0,170
F1 Score	0,133	0,125	0,239

Анализируя визуализацию результатов (рис. 7), можно заметить, что для PELT сохраняется проблема смещения установленных границ интервалов относительно фактических данных. В дополнение к этому PELT определяет значительно меньше точек при оптимальных настройках, в результате оставляя некоторые интервалы неразмеченными. BinSeg, напротив, выделяет слишком много точек в окрестностях правильной разметки: возможно, таким образом он попадает в две соседние единицы и увеличивает показатели метрик. Нейронная сеть, с другой стороны, корректно размечает большинство интервалов.

Далее рассмотрим работу моделей на наборе данных, генерация которого имитирует изменение одновременно и математического ожидания, и стандартного отклонения в данных (рис. 8).

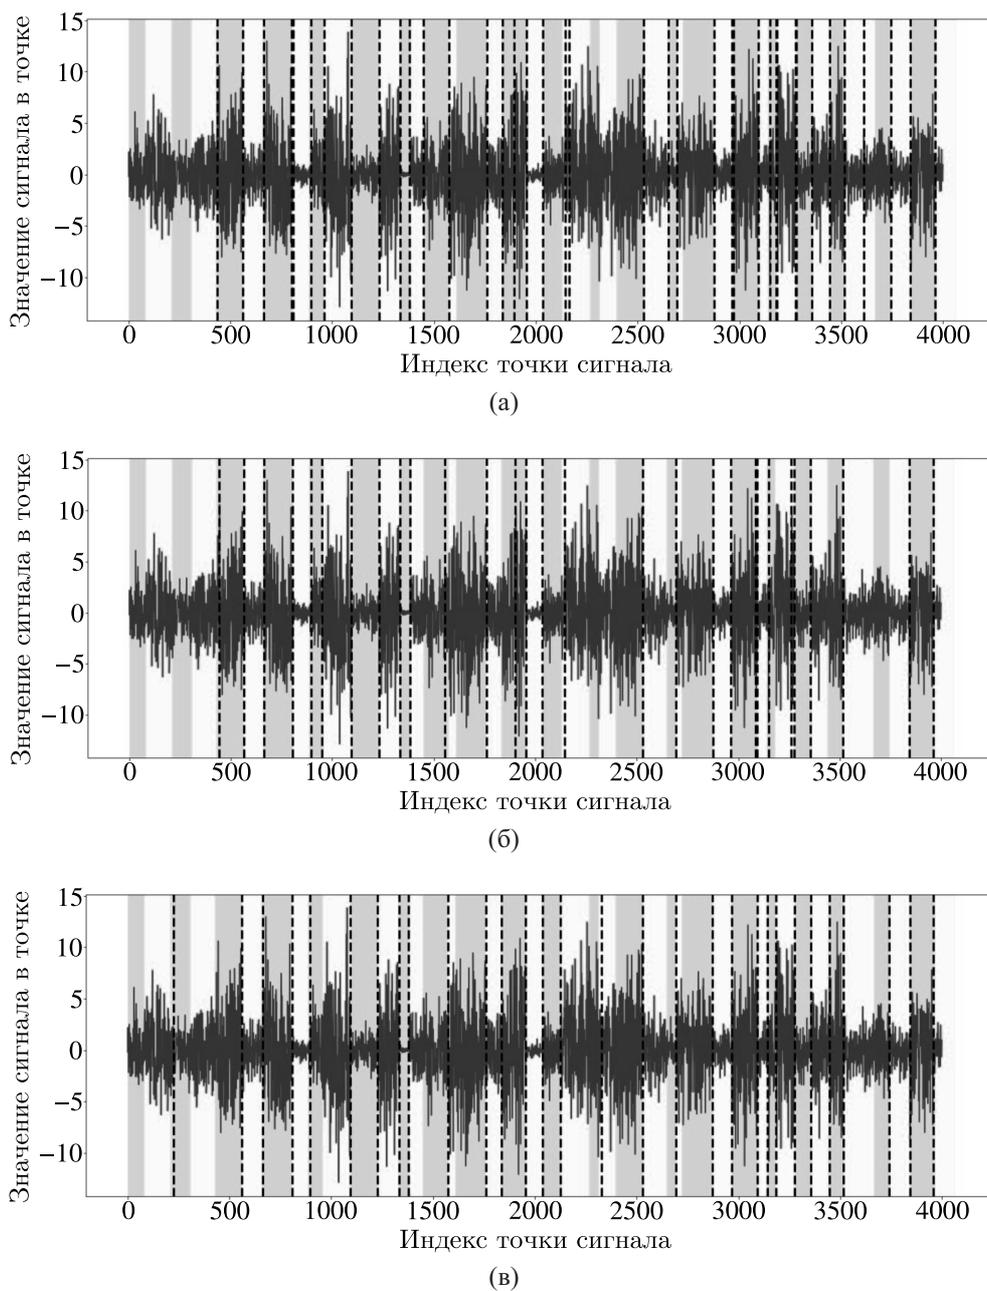


Рис. 7. Реализация алгоритмов BinSeg (а), PELT (б), авторской модели (в) на искусственно сгенерированных данных с меняющимся стандартным отклонением. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота, смена заливки обозначает фактическую точку разворота

В этом случае авторская модель показала свой лучший результат: ROC AUC составил 0,9887. Результаты для других моделей также улучшились по сравнению с предыдущими экспериментами, но прирост показателей метрик оказался менее значительным. После приведения вероятностных результатов в бинарный вид ROC AUC нейронной сети составил 0,6585, что превышает результаты BinSeg и PELT на 12 и 13 %. Это наиболее значительный отрыв среди прочих типов генерации.

Результаты, отраженные в матрице ошибок (рис. 9), оказались в рассматриваемом случае лучше, чем на наборе данных, сгенерированном только с изменением стандартного отклонения,

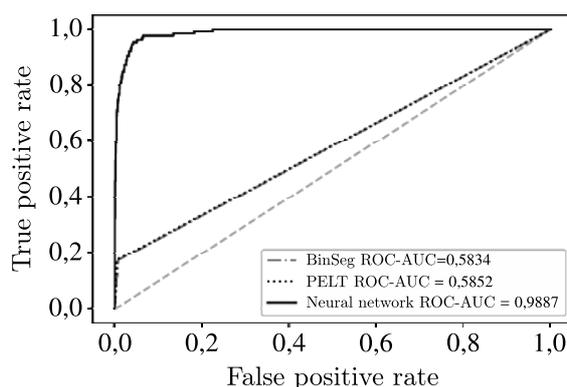


Рис. 8. ROC AUC на наборе данных с изменяющимися математическим ожиданием и стандартным отклонением для моделей BinSeg, PELT, авторской модели. True positive rate — доля истинноположительных значений, false positive rate — доля ложноположительных значений, neural network — разработанная авторами нейронная сеть. Пунктиром обозначена диагональ, при которой значение ROC AUC равно 0,5, что соответствует случайному угадыванию

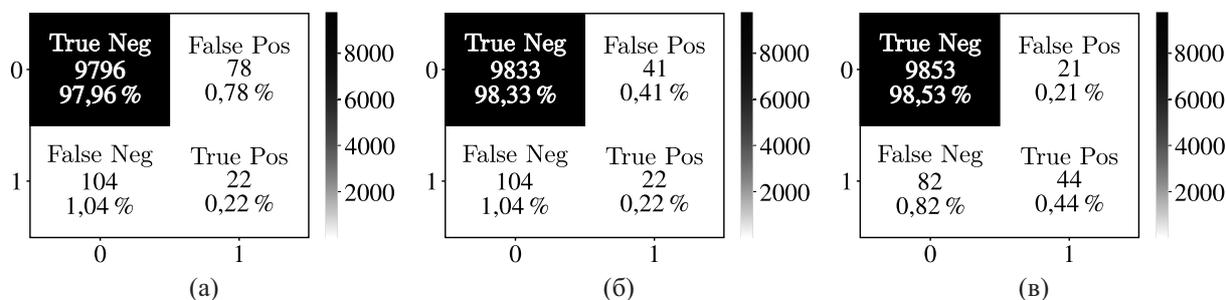


Рис. 9. Матрица ошибок для моделей BinSeg (а), PELT (б), авторской модели (в) при обучении на наборе данных с изменяющимися математическим ожиданием и стандартным отклонением. True Neg — истинноотрицательные значения, False Pos — ложноположительные значения, False Neg — ложноотрицательные значения, True Pos — истинноположительные значения

Таблица 4. Метрики качества на наборе данных с изменяющимися математическим ожиданием и стандартным отклонением для моделей BinSeg, PELT, авторской модели

Метрика	Модель		
	BinSeg	PELT	Авторская модель
Accuracy	0,982	0,986	0,990
Precision	0,220	0,349	0,677
Recall	0,175	0,175	0,349
F1 Score	0,195	0,233	0,461

однако уступили эксперименту, где обучение проводилось на данных с меняющимся математическим ожиданием. Это еще раз подчеркивает, что анализ стандартного отклонения является нетривиальной задачей и может приводить к нестабильным результатам. Тем не менее следует отметить, что предложенная модель проявила себя более адаптивной к такой особенности данных, демонстрируя в два раза больше правильно классифицированных объектов и в два раза меньше ошибочно определенных по сравнению с лучшими результатами, достигнутыми двумя другими моделями. Кроме того, как и ранее, именно эта модель показала самые высокие значения precision, recall и F1 score (табл. 4).

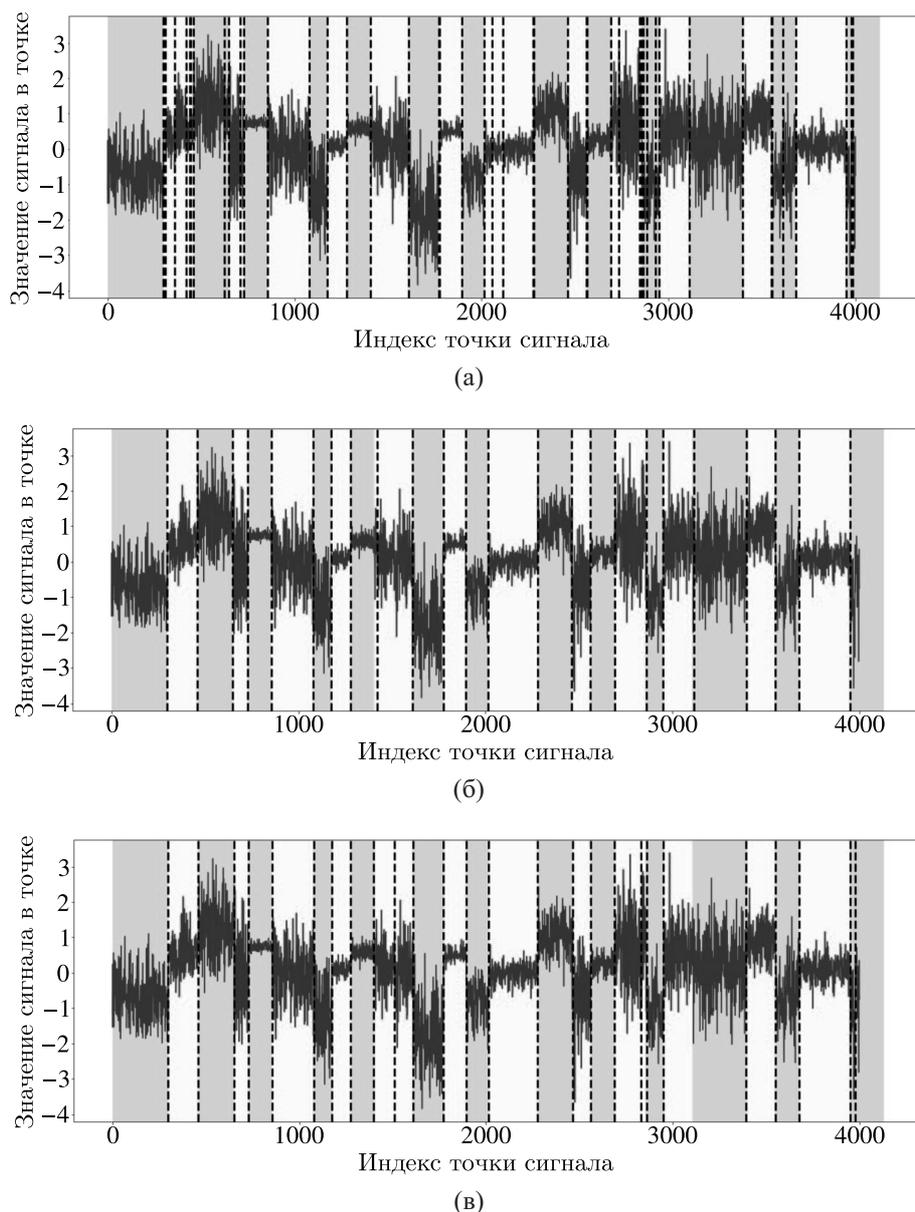


Рис. 10. Реализация алгоритмов BinSeg (а), PELT (б), авторской модели (в) на искусственно сгенерированных данных с меняющимся математическим ожиданием и стандартным отклонением. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота, смена заливки обозначает фактическую точку разворота

Графическое отображение полученных результатов представлено на рис. 10. Для BinSeg возникла ранее не наблюдаемая проблема: модель начала концентрировать несколько точек в окрестности. Точки, определяемые PELT, как и ранее, лежат в близком соседстве с правильной разметкой, но при этом алгоритм не справляется с задачей определения фактических данных более точно.

Суть последнего эксперимента заключается в предсказании точек разворота на индексе S&P 500 с помощью нейронной сети, натренированной на ранее сгенерированных по разным параметрам временных рядах. Другими словами, рассмотрим, как при применении модели к реальным финансовым данным на предсказания влияют параметры, передающиеся в качестве компонентов.

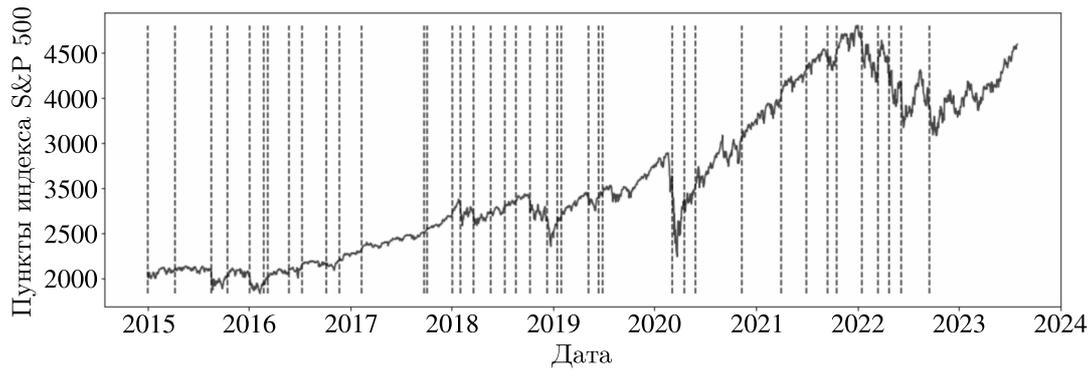


Рис. 11. Реализация авторской модели, обученной на матрице параметров φ (1), на дневных данных индекса S&P 500, 2015–2023 гг. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота

Больше всего периодов выделила модель, натренированная на параметрах скользящих средних (рис. 11). Как тестовые данные на вход подавались значения самого индекса.

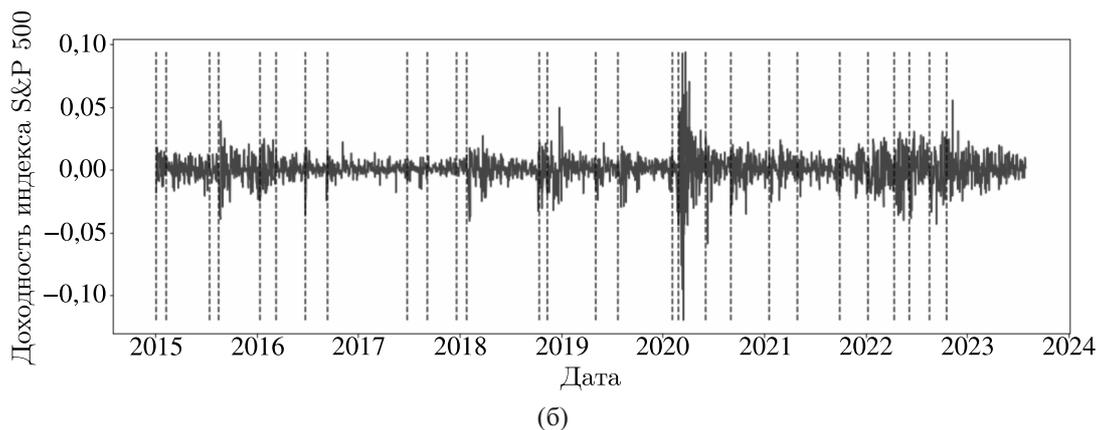
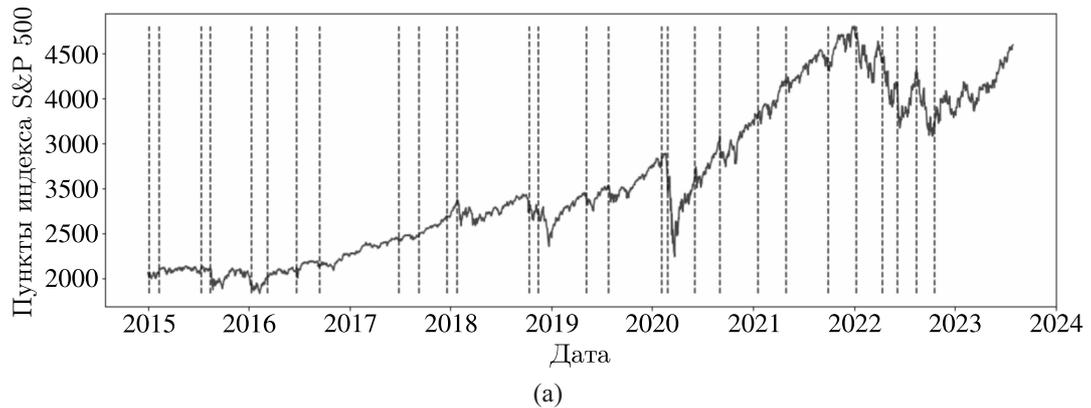


Рис. 12. Реализация авторской модели, обученной на матрице параметров η (2), (3), на дневных доходностях индекса S&P 500, 2015–2023 гг. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота

Модель, обрабатывающая движение индекса параметрами стандартного отклонения, в качестве входных данных использовала дневные доходности. В результате получилось меньше точек изменения при тех же настройках чувствительности. Эмпирически разметка соответству-

ет пикам и впадинам временного ряда (рис. 12, а) и логично разделяет данные доходностей (рис. 12, б).

Модель, обрабатывающая параметры, построенные одновременно на математическом ожидании и стандартном отклонении, оказалась наиболее равновесной среди трех. На вход в данном случае были переданы данные индекса. При эмпирической оценке интервалы выглядят наиболее равномерно распределенными среди всех рассмотренных вариантов (рис. 13).

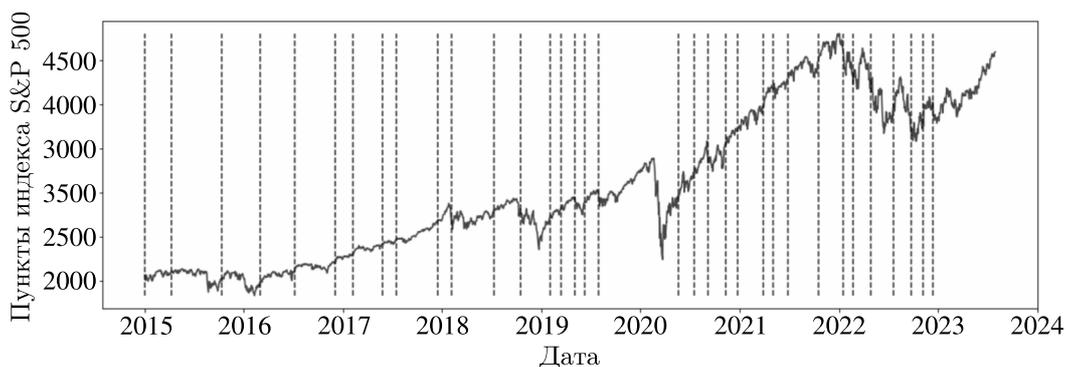


Рис. 13. Реализация авторской модели, обученной на матрице параметров φ и η (1), (2), (3), на дневных доходностях индекса S&P 500, 2015–2023 гг. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота

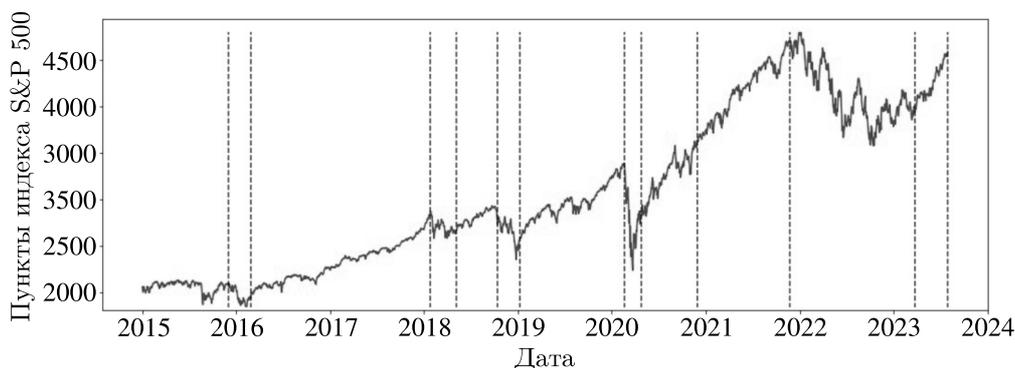


Рис. 14. Реализация алгоритма PELT на дневных доходностях индекса S&P 500, 2015–2023 гг. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота

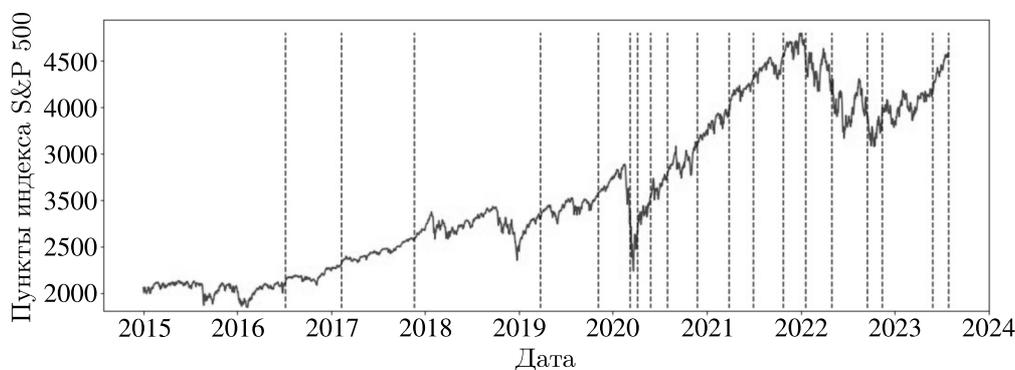


Рис. 15. Реализация алгоритма PELT на дневных данных S&P 500, 2015–2023 гг. Пунктирная линия соответствует точке, классифицированной моделью как точка разворота

Для сравнения: PELT, получавший на вход дневные доходности, разбил индекс на меньшее количество промежутков (рис. 14), а PELT, обрабатывающий значения индекса, чаще размечал интервал с более крутым трендом (рис. 15).

В целом границы интервалов, разменные авторской моделью, соответствуют периодам экономических потрясений, таким как греческий кризис в 2015 г., торговая война США с Китаем и последовавшая за этим рецессия китайской экономики в 2016 г., локдауны в период распространения COVID-19 в 2020 г. и пр. Таким образом, в зависимости от используемых компонентов изменяется характер разметки. Тем не менее предложенная модель требует доработки по упомянутым ранее пунктам в целях ориентации на специфику финансовых данных.

6. Заключение

На настоящий момент проблема определения точек изменения на финансовых рынках не является полностью решенной. В рамках текущего исследования авторами была предложена модель, принцип работы которой построен на обработке нейронной сетью некоторых характеристик временного ряда. В отличие от уже существующих алгоритмов описанная в работе модель предсказывает не конкретные точки изменения, а вероятности их появления в каждой точке сигнала. Такой подход позволяет регулировать параметры чувствительности, если у пользователя возникает необходимость перевода результатов в бинарный вид, и расширяет гибкость в их интерпретируемости.

По результатам проведенных экспериментов предложенная авторами модель, как правило, точнее определяет верные точки изменения по сравнению с базовыми алгоритмами PELT и BinSeg. Следует отметить, что во всех экспериментах при оптимальной настройке параметров каждой модели нейронная сеть предсказывала меньше ложноположительных значений и больше действительных точек изменения классифицировала корректно. В случаях генерации сигнала, где от интервала к интервалу варьируется среднее значение, нейронная сеть показала наиболее точный результат и высокие значения метрик.

Апробация разработанной модели на фактических данных индекса S&P 500 показала, что выбор конкретной компоненты для подачи в нейронную сеть существенно влияет на характер разметки данных. Например, при использовании математического ожидания более крутые участки тренда оказались размеченными чаще, что применимо для инвесторов, стратегия которых ориентирована на высокочастотные сделки. В то же время при использовании стандартного отклонения были выявлены моменты смены наклона, поделившие временной ряд на более равномерные интервалы, что релевантно для реализующих долгосрочные стратегии инвесторов. Так пользователь получает возможность адаптировать модель в зависимости от своих целей, выбирая ту компоненту, которая наилучшим образом соответствует его стратегии.

Таким образом, авторами был предложен инструментарий, который может быть использован инвесторами для определения точек изменения на некотором финансовом ряде. Вероятностные выходные данные модели позволяют регулировать границы определяемых интервалов, что делает алгоритм полезным как для торговли в длинные позиции, так и в интрадей. Кроме того, интерпретировать такие результаты пользователь может и самостоятельно, без перевода их в бинарный вид.

Дальнейшая работа по улучшению модели главным образом заключается в совершенствовании алгоритма генерации сигнала, необходимого для обучения, и модернизации архитектуры самой нейронной сети. Так, генерируемый сигнал должен имитировать движение реального финансового инструмента: содержать периоды стагнации, смены тренда, коррекции и прочие характеристики, присущие временному ряду на финансовом рынке. Перед авторами также стоит задача определения точек изменения онлайн с помощью алгоритмов продления самого временного ряда.

Список литературы (References)

- Денежкина И. Е., Мартиросян Г. Н., Попов В. Ю., Шаповал А. Б.* Количественная оценка динамики волатильности нестабильного рынка // *Финансы: теория и практика*. — 2013. — № 1. — С. 8–14.
- Denezhkina I. E., Martirosyan G. N., Popov V. Yu., Shapoval A. B.* Kolichestvennyye ocenka dinamiki volatil'nosti nestabil'nogo rynka [Quantitative assessment of the volatility dynamics of an unstable market] // *Finance: theory and practice*. — 2013. — No. 1. — P. 8–14 (in Russian).
- Ромм Я. Е., Тренкешу А. И.* Выделение трендов и определение точек разворота тенденций финансовых рынков на основе схем сортировки // *Известия Южного федерального университета. Технические науки*. — 2012. — Т. 136, № 11. — С. 237–244.
- Romm Ya. E., Trenkenshu A. I.* Vydelenie trendov i opredelenie tochek razvorota tendencij finansovyh rynkov na osnove skhem sortirovki [Identification of trends and determination of change points of financial market trends based on sorting schemes] // *News of the Southern Federal University. Technical science*. — 2012. — Vol. 136, No. 11. — P. 237–244 (in Russian).
- Banerjee S., Guhathakurta K.* Change-point analysis in financial networks // *Stat.* — 2020. — Vol. 9, No. 1. — P. e269.
- Bos T., Hoontrakul P.* Estimation of mean and variance episodes in the price return of the stock exchange of Thailand // *Financial Risk Financial Manage.* — 2002. — Vol. 16. — P. 535–554.
- Cortes C., Mohri M., Rostamizadeh A.* L2 regularization for learning kernels // *Conference: UAI 2009, Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence, Montreal, QC, Canada*. — 2009. — P. 109–116.
- He K., Yang Q., Ji L., Pan J., Zou Y.* Financial time series forecasting with the deep learning ensemble model // *Mathematics*. — 2023. — Vol. 11. — P. 1054.
- Igir C., Oscar A., Silas U. A., Silas A.* Effect of learning rate on artificial neural network in machine learning // *International Journal of Engineering Research*. — 2015. — Vol. 4, No. 2. — P. 359–363.
- Jussi N., Mohammad M. O., Petri S., Janne Ä.* Stock returns and volatility following the September 11 attacks: Evidence from 53 equity markets // *International Review of Financial Analysis, Elsevier*. — 2008. — Vol. 17, No. 1. — P. 27–46.
- Killick R., Fearnhead P., Eckley I. A.* Optimal detection of changepoints with a linear computational cost // *Journal of the American Statistical Association*. — 2012. — Vol. 107, No. 500. — P. 1590–1598.
- Kolar M., Xing E.* On time varying undirected graphs // *On Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*. — 2011. — P. 407–415.
- Koop G., Potter S. M.* Are apparent findings of nonlinearity due to structural instability in economic time series? // *The Econometrics Journal*. — 2001. — Vol. 4, No. 1. — P. 37–55.
- Labiad B., Berrado A., Benabbou L.* Predicting extreme events in the stock market using generative adversarial networks // *International Journal of Advances in Intelligent Informatics*. — 2023. — Vol. 9, No. 2. — P. 218–230.
- Liu S., Yamada M., Collier N., Sugiyama M.* Change-point detection in time-series data by relative density-ratio estimation // *Neural Networks*. — 2013. — Vol. 43. — P. 72–83.
- Nikkinen J., Omran M. M., Sahlström P., Äijö J.* Stock returns and volatility following the September 11 attacks: Evidence from 53 equity markets // *International Review of Financial Analysis*. — 2008. — Vol. 17, No. 1. — P. 27–46.
- Popescu M. C., Balas V. E., Perescu-Popescu L., Mastorakis N. E.* Multilayer perceptron and neural networks // *WSEAS Transactions on Circuits and Systems*. — 2009. — Vol. 8, No. 7. — P. 579–588.
- Scott A. J., Knott M. A.* Cluster analysis method for grouping means in the analysis of variance // *Biometrics*. — 1974. — Vol. 30, No. 3. — P. 507–512.
- Staffini A.* Stock price forecasting by a deep convolutional generative adversarial network // *Front. Artif. Intel.* — 2022. — Vol. 5. — 837596.

-
- Stock J. H., Watson M. W.* Evidence on structural instability in macroeconomic time series relations // *Journal of Business & Economic Statistics*. — 1996. — Vol. 14, No. 1. — P. 11–30.
- Tsay R. S.* Outliers, level shifts, and variance changes in time series // *Journal of Forecasting*. — 1988. — Vol. 7. — P. 1–20.
- Xu Z., Zhang J., Wang J., Xu Z.* Prediction research of financial time series based on deep learning // *Soft Computing*. — 2020. — Vol. 24. — P. 8295–8312.
- Yoo S., Jeon S., Jeong S., Lee H., Ryou H., Park T., Choi Y., Oh K.* Prediction of the change points in stock markets using DAE-LSTM // *Sustainability, MDPI*. — 2021. — Vol. 13, No. 21. — P. 1–15.
- Zhou S., Lafferty J., Wasserman L.* Time varying undirected graphs // *Machine Learning*. — 2010. — Vol. 80, No. 2–3. — P. 295–319.