

Научная статья
УДК 657
doi: 10.17223/19988648/71/14

Подходы к нейросетевому анализу бухгалтерской отчетности

Инна Викторовна Поправко¹

¹ Воронежский государственный университет, Воронеж, Россия, *ipopravko@mail.ru*

Аннотация. В условиях цифровизации экономики и усложнения финансовой среды возрастаёт потребность в более точных, масштабируемых и интеллектуальных инструментах анализа бухгалтерской отчетности. Традиционные методы, основанные на детерминированных моделях, расчетах финансовых коэффициентов и экспертной интерпретации, утрачивают эффективность при работе с большими объемами неоднородных данных, а также демонстрируют ограниченную способность к выявлению скрытых закономерностей и прогнозированию рисков. В этом контексте применение методов искусственного интеллекта, в частности нейросетевых моделей, становится актуальным направлением как научного, так и прикладного исследования в сфере бухгалтерского учета. Настоящая статья посвящена методологическим аспектам применения нейросетевых моделей в анализе бухгалтерской отчетности. В работе проведён обзор актуальных международных публикаций, посвящённых применению нейронных сетей для прогнозирования финансовых показателей, диагностики финансовой несостоительности, выявления мошенничества и аномалий в учётных данных. Особое внимание уделено методам обработки и стандартизации входных данных, выбору архитектуры модели и процессу обучения. Рассмотрены примеры использования нейросетей в международной и отечественной практике, выявлены преимущества нейросетей, включая повышение точности классификации, снижение ошибок прогнозирования, расширение охвата данных, ускорение анализа и выявление новых паттернов, недоступных традиционным методам.

Ключевые слова: бухгалтерская отчетность, нейронные сети, финансовый анализ, цифровая трансформация, искусственный интеллект, выявление аномалий, прогнозирование показателей

Для цитирования: Поправко И.В. Подходы к нейросетевому анализу бухгалтерской отчетности // Вестник Томского государственного университета. Экономика. 2025. № 71. С. 228–247. doi: 10.17223/19988648/71/14

Original article

Methodological aspects of neural network-based analysis of financial reporting

Inna V. Popravko¹

¹ Voronezh State University,
Voronezh, Russian Federation, ipopravko@mail.ru

Abstract. Amid the accelerating digitalization of the economy and the increasing complexity of the financial environment, there is a growing demand for more accurate, scalable, and intelligent tools for financial statement analysis. Traditional approaches based on deterministic models, financial ratio calculations, and expert interpretation are losing effectiveness in the face of large volumes of heterogeneous data and exhibit limited capacity to detect latent patterns or forecast risks. In this context, the application of artificial intelligence methods (particularly neural network models) has emerged as a promising avenue of both academic inquiry and practical innovation in the field of accounting. This article explores the methodological foundations of employing neural networks for the analysis of financial statements. The primary objective of the study is to systematize contemporary approaches to the construction, training, and interpretation of neural network architectures used for financial data analysis, while also identifying their advantages, limitations, and prospects for practical implementation in accounting and auditing. The object of the research is the financial statements of economic entities, considered as a source of data for analytical processing. The focus of the study is the application of neural network methods to the analysis of this information. The article provides a comprehensive review of recent international studies on the use of neural networks for forecasting financial indicators, diagnosing financial distress, and detecting fraud and anomalies in accounting records. Particular attention is paid to data preprocessing and standardization techniques, model architecture selection, and training procedures. Drawing on both international and Russian experiences, the article highlights the key benefits of neural networks, including enhanced classification accuracy, improved forecasting precision, broader data coverage, accelerated analysis, and the discovery of latent patterns inaccessible to traditional methods. At the same time, it emphasizes several challenges and constraints – from models' sensitivity to data quality and the need for large training datasets, to issues of result interpretability and the lack of unified methodological standards. The scientific novelty of this study lies in its integrated assessment of the potential of neural network technologies within the framework of modern financial analysis methodology. It also offers practical recommendations for integrating neural network tools into accounting, analytical, and audit practice. The article presents a systematized set of conclusions, a classification of neural network architectures, a synthesis of methodological approaches, and directions for further research.

Keywords: financial statements, neural networks, financial analysis, digital transformation, artificial intelligence, anomaly detection, performance forecasting

For citation: Popravko, I.V. (2025) Methodological aspects of neural network-based analysis of financial reporting. *Vestnik Tomskogo gosudarstvennogo universiteta. Ekonomika – Tomsk State University Journal of Economics.* 71. pp. 228–247. (In Russian). doi: 10.17223/19988648/71/14

Введение

Анализ бухгалтерской (финансовой) отчетности традиционно является ключевым инструментом для оценки финансового состояния организаций, выявления рисков и поддержки управленческих решений. Однако в условиях экспоненциального роста объема информации и увеличения сложности данных эффективность классических методов финансового анализа достигает предела. Ежегодные отчеты крупных компаний могут содержать сотни страниц с многочисленными показателями и примечаниями, что затрудняет их полноценную обработку аналитиками вручную.

В таких условиях методы искусственного интеллекта, в частности нейронные сети и глубокое обучение, привлекают все больше внимания как средство автоматизации и повышения эффективности анализа финансовой отчетности. Исследования Kim et al. [1, р. 12–26] показывают, что продвинутые нейросетевые модели способны выявлять скрытые закономерности и тренды в бухгалтерских данных, недоступные при традиционном анализе, и даже превосходить экспертов-людей. Это свидетельствует о революционном потенциале нейросетевых подходов в области финансового анализа. Причины эффективности нейросетевых методов кроются в их способности обрабатывать большие массивы разнородной информации и улавливать сложные нелинейные взаимосвязи между финансовыми показателями. Как отмечают Болотов и Суглобов [2, с. 106–110], если традиционные модели (регрессионный анализ, дискриминантный анализ и пр.) основываются на заранее заданных линейных предположениях, то нейронные сети способны самостоятельно выявлять скрытые зависимости, присущие реальным экономическим процессам.

Таким образом, использование технологий глубокого обучения в анализе финансовой отчетности позволяет получить качественно новые результаты и инсайты. В работе [3, р. 847–853] подчеркивается, что речь идет не просто об очередном инструменте автоматизации расчетов, а о кардинально новом уровне аналитики. Современные нейросетевые модели могут не только расчитать десятки коэффициентов за считанные секунды, но и интерпретировать их совокупность, имитируя рассуждения эксперта-аналитика. Например, продвинутые языковые модели способны прочесть весь годовой отчет компании (включая примечания и пояснения) и сформулировать осмысленные выводы о ее финансовых перспективах.

Подобные возможности ранее находились за пределами автоматизированных систем и требовали участия квалифицированных экспертов. Теперь же нейросетевые алгоритмы становятся интеллектуальными ассистентами финансистов, способными усилить экспертный анализ за счет скорости, масштабируемости и объективности обработки данных.

Цель исследования – выявить, обобщить и систематизировать современные методологические подходы к применению нейронных сетей в анализе бухгалтерской отчетности, а также оценить их потенциал и ограничения в контексте теории и практики бухгалтерского учета.

Задачи исследования:

- Проанализировать современные научные публикации, посвященные применению нейросетей в анализе финансовой отчетности.
- Классифицировать существующие подходы к построению нейросетевых моделей для анализа бухгалтерских данных.
- Рассмотреть методологические аспекты подготовки входных данных, выбора архитектур моделей и оценки качества результатов анализа.
- Выявить ключевые преимущества и ограничения применения нейросетей в задачах бухгалтерского анализа.
- Определить перспективы интеграции нейросетевых инструментов в практику бухгалтерского учета и аудита.

Объектом исследования является бухгалтерская (финансовая) отчетность организаций как источник информации для аналитической обработки и принятия управленческих решений.

Предметом исследования являются методологические подходы и инструменты анализа бухгалтерской отчетности с использованием нейросетевых моделей и технологий глубокого обучения.

Авторская гипотеза заключается в том, что применение нейросетевых моделей в анализе бухгалтерской отчетности позволяет существенно повысить точность прогноза финансовых показателей, выявления аномалий и оценки риска искажения отчетности по сравнению с традиционными аналитическими методами за счёт способности нейронных сетей к обучению на больших массивах данных и выявлению нелинейных зависимостей, что обосновывает необходимость пересмотра методологических основ бухгалтерского анализа в условиях цифровизации.

Обзор литературы

Использование нейронных сетей в финансовом анализе не является абсолютно новой идеей. Первые попытки применения относят еще к периоду 1990-х гг., когда появились работы по прогнозированию банкротства компаний с помощью многослойных перцептронов. Ранние исследования демонстрировали, что даже простые нейронные сети способны соперничать по точности с классическими моделями. Так, в обзоре O'Leary (1998), упомянутом Coakley and Brown [4, р. 119–144], было проанализировано 15 исследований по предсказанию корпоративных дефолтов с помощью нейросетей; отмечалось, что при надлежащей настройке архитектуры и обучении на достаточном объеме данных сети достигали высокой точности.

В конце 1990-х гг. было опубликовано несколько обзорных работ, обобщающих опыт применения нейронных сетей в финансах. В частности, Vellido et al. [4, р. 119–144] рассмотрели 123 статьи периода 1992–1998 гг. Эти обзоры подтвердили растущий интерес к нейросетевым методам в финансовой сфере.

Тем не менее вплоть до середины 2000-х гг. ограниченные вычислительные ресурсы и сравнительно небольшие наборы исходных данных для обучения сдерживали широкое распространение глубоких нейронных сетей в

бухгалтерском учете. В последнее десятилетие, благодаря прогрессу в области глубокого обучения и появлению больших массивов открытых финансовых данных, применение нейросетей в анализе финансовой отчетности вышло на качественно новый уровень.

Современные исследования охватывают широкий спектр задач. Одно из центральных направлений – прогнозирование финансовой несостоятельности и рисков банкротства. Например, исследователи Chen et al. [5, р. 2089–2103] и Bi et al. [6, р. 1–26] разработали нейросетевой инструмент оценки финансовой устойчивости предприятий реального сектора и показали его преимущество перед традиционными моделями при прогнозировании банкротства. Это подтверждает, что нейронные сети эффективно улавливают нелинейные комбинации индикаторов (ликвидности, платежеспособности, оборачиваемости и др.), сигнализирующие о потенциальных проблемах, тогда как традиционные методы зачастую опираются на линейные индексы и теряют информацию о сложных взаимосвязях. В работе [7, р. 1–28] авторы также говорят об улучшении качества прогнозов: в большинстве сравниваемых экспериментов ANN-модели (Artificial Neural Network) превосходят регрессионные в точности классификации дефолтов.

Другое активно развивающееся направление – прогнозирование финансовых результатов и показателей (прибыли, выручки, денежных потоков). Здесь нейросети применяются как для краткосрочных прогнозов (на следующий квартал или год), так и для более общих оценок устойчивости бизнеса [8, с. 1–6]. Важной вехой стала интеграция глубокого обучения с концепциями финансового менеджмента. Например, Artene and Domil [9, р. 993] предложили оригинальный двухуровневый подход к прогнозированию корпоративной прибыли на основе нейронной сети. Сначала на теоретическом уровне они выстраивают семантическую модель связи между бухгалтерскими переменными и прибылью аналогично традиционной финансовой аналитике (т.е. определяют, как изменение определенных показателей должно влиять на чистую прибыль, опираясь на известные зависимости). Затем на эмпирическом уровне эта концептуальная модель реализуется в виде многослойной нейронной сети, куда подаются фактические значения финансовых коэффициентов компаний, на основе которых сеть обучается выявлять сложные нелинейные воздействия этих показателей на итоговый финансовый результат. По сути, это попытка встроить бухгалтерскую логику в архитектуру нейросети. Подобные исследования прокладывают путь к созданию систем поддержки решений нового поколения, встроенных в корпоративные системы планирования и бюджетирования.

Отдельно стоит выделить применение нейросетевых технологий для выявления аномалий и мошенничества в отчетности. Глубокое обучение в таких задачах позволяет анализировать сразу весь комплекс данных (как числовые показатели, так и текстовую составляющую отчетов) для более полного обнаружения случаев искажений. В этой связи следует упомянуть работу Rahayu and Widuri [10, р. 237–248], в которой они представили эмпирическое исследование, посвященное применению методов искусственных нейронных сетей для

выявления мошенничества в финансовой отчетности компаний. Авторы разработали и протестирували модель, направленную на классификацию достоверности отчетных данных на основе набора релевантных финансовых коэффициентов. Особое внимание удалено выбору чувствительных к искажениям показателей и оценке качества модели с использованием метрик точности, полноты и F-меры. Данное исследование демонстрирует высокую прикладную значимость нейросетевых подходов в задаче диагностики мошенничества.

Значительный вклад в вопросы выявления ошибок и мошенничества внесли исследования Müller et al [11, p. 1–26], Bieganowski and Slepaczuk [12, p. 1–29], Li et al. [13, p. 343–355], основанные на применении нейросетевых автоэнкодеров. Например, в работе китайских ученых Li et al. [13, p. 343–355] предложена схема аудиторской проверки данных бухгалтерского учёта с помощью глубокой нейросети. Автоэнкодер обучается на массивах бухгалтерских записей (проводок) таким образом, чтобы реконструировать нормальные данные. При этом любые нестандартные отклонения (например, фиктивные проводки, нетипичные операции) приводят к повышенной ошибке реконструкции и тем самым сигнализируют о потенциальной аномалии. Модель учитывает как глобальные, так и локальные аномальные характеристики счетов, обучаясь отличать обычные закономерности от подозрительных. Время проверки при этом сокращается до долей секунды, что на порядки быстрее человеческого анализа. Это означает, что глубокая нейросеть-детектор способна в режиме реального времени мониторить бухгалтерские проводки компаний и мгновенно сигнализировать о подозрительных транзакциях или неверных учетных записях.

Самое новое поколение нейросетевых технологий в финансовом анализе базируется на больших языковых моделях (Large Language Models, LLM) и трансформерах. Они позволяют по-новому взглянуть на проблему интерпретации и обобщения финансовой информации. Работы Kim et al. [1, p. 12–26], Zhang and Yang [14, p. 349–357] демонстрируют, что LLM (например, GPT-3.5, GPT-4, Claude) можно научить выполнять комплексный анализ финансовой отчетности, сочетая вычисления с рассуждениями в человеческом стиле. Kim et al. [1, p. 12–26] показали, что GPT-4, снабженный стандартизованными финансовыми данными (баланс, отчет о финансовых результатах и т.д.), способен предсказать направление изменения прибыли компании лучше, чем средний финансовый аналитик. Примечательно, что модель не имела доступа к текстовым описаниям или инсайдерской информации – она делала вывод лишь на основе числовых отчетных показателей, фактически имитируя классический фундаментальный анализ, но в автоматическом режиме. Более того, качество прогнозов нейросети сравнимо с лучшими специализированными алгоритмами машинного обучения, настроенными именно на эти задачи. Это говорит о том, что большие языковые модели уже накопили в себе обширные знания по экономике и финансам и могут применять их в аналитических целях. В перспективе интеграция таких моделей с корпоративными базами данных позволит получать целый интеллектуальный анализ «под ключ». Конечно, подобные системы пока требуют тщательной проверки и доработки, однако первые прототипы уже показывают огромный потенциал [15, с. 1–12; 16, с. 1–15].

Международные исследования охватывают и ряд других аспектов применения нейросетей в финансах: от кластеризации компаний по схожести финансовых профилей до прогнозирования рыночных показателей на основе фундаментальных данных (когда финансовая отчетность компаний используется совместно с рыночными данными для прогнозирования цен акций). Так, Elend et al. [17, р. 1–20] продемонстрировали, что глубокие нейросетевые архитектуры, включая LSTM и автоэнкодеры, позволяют эффективно предсказывать прибыль компаний, используя как данные финансовой отчетности, так и рыночные индикаторы. Wang and Wang [18, р. 72] подтвердили высокую прогностическую силу моделей MLP и LSTM при совместной обработке бухгалтерских коэффициентов и рыночных метрик, особенно в задаче предсказания доходности акций. Более широкий прикладной контекст представлен в исследовании Trinh [19, р. 1–29], где глубокие нейронные сети рассматриваются как инструмент поддержки принятия бизнес-решений и инвестиционного анализа. Автор подчеркивает потенциал DNN в условиях обработки сложноструктурированных финансовых данных. Аналогично, Scherrmann and Elsas [20, р. 1–26] сосредоточили внимание на использовании рекуррентных нейронных сетей для прогнозирования прибыли компаний, продемонстрировав превосходство RNN-архитектур над традиционными статистическими моделями в работе с временными рядами бухгалтерской отчетности.

Следует отметить, что методы нейросетевого анализа отчетности не только активно исследуются в научных кругах, но и проникают в практику бухгалтерского учета. Прогрессивные компании и особенно аудиторско-консалтинговые фирмы также активно внедряют AI-инструменты в свои рабочие процессы. Рассмотрим несколько показательных примеров:

- Компания PwC разработала модуль GL.ai платформы Audit.ai, предназначенный для автоматического анализа 100% проводок в главной книге компании. Фактически, это нейросетевой детектор аномалий, включающий алгоритмы, обученные на данных множества аудитов PwC, который проверяет каждую транзакцию на предмет ее нехарактерности. GL.ai выявляет необычные комбинации счетов, суммы, даты, активность пользователей, которые бы ускользнули при традиционном выборочном аудите. За счет этого аудиторы сразу концентрируются на проблемных зонах. По сообщению PwC, инструмент был протестирован в 20 аудиторских проверках в разных странах и получил высокие оценки¹.

- Компания Deloitte разработала AI-платформу Argus, ориентированную на анализ документов и выявление рисков в аудите. Argus использует методы машинного обучения и обработки естественного языка для извлечения информации из неструктурированных документов (например, контрактов, договоров) и их оценки. В частности, Argus автоматически просматривает

¹ Harnessing the power of AI to transform the detection of fraud and error // PwC. URL: <https://www.pwc.com/gx/en/about/stories-from-across-the-world/harnessing-the-power-of-ai-to-transform-the-detection-of-fraud-and-error.html> (дата обращения: 29.05.2025).

содержимое PDF-файлов, извлекает ключевые параметры и формулировки, преобразует их в структурированную форму для дальнейшего анализа аудиторами. Кроме того, Argus применяет алгоритмы детекции аномалий, чтобы из массива данных клиента найти нестандартные паттерны транзакций или условий. В одном из кейсов Argus помог выявить серию необычных транзакций в записях клиента, указывающих на потенциальное мошенничество, что позволило предпринять превентивные действия для недопущения его возникновения¹.

• Компания KPMG интегрирует искусственный интеллект (AI) в свою аудиторскую платформу Clara. Clara включает инструменты для автоматической загрузки и обработки данных клиента, применения аналитических процедур с помощью машинного обучения (ML). Например, она автоматически извлекает данные из ERP-систем клиента, проводит базовый анализ аномалий, вычисляет коэффициенты и сравнивает их с отраслевыми, выделяя отклонения. Благодаря этому, как отмечается, аудиторы больше времени тратят на интерпретацию, чем на сбор данных. Clara также поддерживает возможность непрерывного аудита: в режиме реального времени можно настроить получение потоков данных и их анализ, что позволяет, например, ежемесячно получать обновленную оценку рисков для клиента, а не ожидать окончания года².

• Платформа MindBridge используется сотнями фирм для анализа финансовых данных. Она сочетает статистические правила, классические алгоритмы и глубокое обучение для выявления аномалий в транзакциях, счётах и отчетности. MindBridge специализируется на наглядности: её дашборды показывают рейтинг рисковых операций, типы выявленных аномалий, предоставляют объяснения, почему транзакция кажется подозрительной и требует дополнительного анализа. Алгоритмы MindBridge сертифицированы по ряду аудиторских стандартов, а это говорит об определенном доверии к технологии³.

Обобщая исследования других авторов и практику внедрения алгоритмов машинного обучения в компаниях, можно сделать вывод, что нейросетевые технологии ужеочно входят в арсенал средств финансового анализа. Они демонстрируют превосходство над традиционными методами по ряду критериев – точности прогнозов, полноте выявления аномалий, скорости обработки информации и др. Крупнейшие игроки доверяют нейросетям

¹ Deloitte. Auditing in the AI era. URL: <https://www.deloitte.com/middle-east/en/our-thinking/mepov-magazine/sustainable-strategies/auditing-in-the-ai-era.html> (дата обращения: 29.05.2025).

² Audits.com.au. Technological transformation: Update on AI and data analytics. URL: <https://audits.com.au/technological-transformation-update-on-ai-and-data-analytics/> (дата обращения: 29.05.2025).

³ MindBridge. AI-powered anomaly detection: Going beyond the balance sheet. URL: <https://www.mindbridge.ai/blog/ai-powered-anomaly-detection-going-beyond-the-balance-sheet/> (дата обращения: 29.05.2025).

выполнение ответственных частей финансового контроля. В то же время исследователи отмечают и проблемные зоны: например, необходимость крупных обучающих выборок, сложность интерпретации результатов, риск переобучения на ограниченных данных, вопросы интеграции таких моделей в существующие бизнес-процессы.

Результаты и обсуждение

На основе проведенного анализа литературных источников можно сделать вывод, что применение нейронных сетей в анализе бухгалтерской отчетности требует тщательного методологического подхода, охватывающего сбор и подготовку данных, выбор и настройку архитектуры сети, организацию процесса обучения и оценку результатов. Систематизируем ключевые этапы этого процесса.

1. Источники данных и их подготовка. Для обучения нейросети необходим репрезентативный набор финансовых данных. В зависимости от задачи это могут быть:

- Структурированные числовые данные: например, показатели финансовой отчетности (статьи баланса, показатели отчета о финансовых результатах, денежные потоки, финансовые коэффициенты). Перед использованием данные стандартизируются: выполняются нормализация, заполнение пропусков (либо удалением неполных наблюдений) и при необходимости сглаживание выбросов.
- Текстовые данные: пояснения к отчетности, аудиторские заключения, пресс-релизы, новостные фоны. Тексты проходят лингвистическую обработку (очистка от стоп-слов, лемматизация, возможен перевод финансового жаргона в стандартизированный вид).

• Изображения и сканы документов: в некоторых случаях приходится работать не с готовыми цифровыми данными, а с образами документов (PDF-сканами отчетности, фото счетов-фактур и т.п.). Тогда в методологию включается этап распознавания текста (OCR) с помощью нейросетей. Современные подходы используют сверточные нейронные сети для детектирования областей текста на изображении и рекуррентные сети с механизмом внимания для последовательного распознавания символов (CRNN с LSTM-слоями) [21, с. 13319–13337]. При грамотной настройке такие модели позволяют извлекать финансовые таблицы из изображений отчетов с высокой точностью. Распознанные данные затем проходят проверку консистентности (например, на равенство Актива и Пассива баланса) и могут использоваться как обычные числовые данные.

2. Выбор архитектуры нейросети. Определяющим шагом является выбор типа и структуры нейронной сети, наилучшим образом подходящей под поставленную задачу и доступные данные:

- Для прогнозирования или классификации на основе фиксированного набора показателей (например, оценка вероятности банкротства по финансовым коэффициентам за последний отчетный период) обычно применяются

feed-forward сети. Их архитектура представляет собой несколько полносвязных скрытых слоев между входами (набор показателей) и выходом (вероятность дефолта или класс компании), использующих нелинейную функцию активации. Увеличение числа слоев повышает способность сети приближать сложные зависимости, но усложняет обучение и повышает риск переобучения [22, с. 1–19].

- Для учета временной динамики (например, прогнозирование будущих показателей на основании трендов прошлых лет, анализ последовательности квартальных отчетов) применяются рекуррентные нейронные сети (RNN) и их современные модификации – LSTM или GRU сети с механизмом долгой короткой памяти. Эти архитектуры специально разработаны для последовательных данных, так как содержат циклические связи, позволяющие запоминать состояние [23, с. 1–15].

- Для обработки текстов годовой отчетности применяются либо рекуррентные сети с механизмом внимания, либо трансформеры. Трансформеры (например, модели на основе BERT, GPT) отлично справляются с длинными текстами и контекстуальными зависимостями, что важно при анализе пояснительной записи или примечаний к отчетности [24, с. 1–28; 25, с. 135–154].

- Для обработки изображений (например, графиков) используют сверточные нейронные сети (CNN).

- Для комбинированных данных, включающих табличные показатели, картинки и текст, используют мультимодальные LLM модели класса GPT или сочетание нескольких моделей, описанных выше.

3. Процесс обучения и валидации. Обучение нейросети для финансового анализа обычно производится в режиме *supervised learning* (с учителем), когда имеется обучающая выборка компаний/отчетностей с известными метками или целевыми значениями (например, известен факт банкротства или известна реальная прибыль следующего года для прошлых наблюдений) [26, с. 1–19; 27, с. 1–12]. Процесс включает следующие этапы:

- Разбиение данных на обучающую, валидационную и тестовую выборки. Это позволяет на одной части записей обучать модель, а на другой (которую модель ранее не видела) проверять качество предсказаний, что делает оценку более объективной.

- Настройка гиперпараметров: размер сети, скорость обучения, параметры регуляризации и другие. Это сильно влияет на скорость и качество обучения модели.

- Обучение модели на данных. Используются алгоритмы градиентного спуска, которые итеративно корректируют веса сети, минимизируя функцию ошибки. В результате подбираются оптимальные веса модели, позволяющие делать наиболее точные предсказания.

- Оценка качества модели на тестовых данных (которые не использовались в обучении). Для классификаторов рассчитываются метрики точности (accuracy), полноты (recall), прецизионности (precision), F1-score, строятся ROC-кривые и вычисляется AUC. Для прогнозов количественных величин измеряются ошибки (MAE, MSE, MAPE) и сравниваются с базовыми моделями.

лями (например, сравнение ошибки нейросети с ошибкой линейной регрессии или среднего экспертного прогноза). В результате становится понятно, насколько хорошо работает модель.

Для реализации нейросетевого анализа финансовых данных на практике используют как универсальные фреймворки глубокого обучения, так и специализированные прикладные решения. Научные исследования и прототипы обычно создаются с помощью открытых библиотек Python, таких как TensorFlow, Keras, PyTorch, Scikit-learn. Эти инструменты обеспечивают необходимую гибкость в настройке архитектур и оптимизационных алгоритмов. Для обработки текстов популярны NLP-библиотеки, такие как, например, HuggingFace Transformers. При постановке экспериментов ключевыми вопросами являются воспроизводимость и надежность кода, так как ошибки в реализации могут исказить результаты. В распоряжении аналитиков сегодня имеются и коммерческие платформы, интегрирующие искусственный интеллект (AI) в финансовые рабочие процессы. Например, IBM SPSS Modeler и SAS Enterprise Miner уже давно включают модули нейронных сетей, позволяющие специалистам без глубоких знаний программирования строить простые предиктивные модели на финансовых данных. Современные облачные сервисы (Google AutoML, Amazon SageMaker) предлагают AutoML-функции, автоматизирующие подбор модели под данные, которые можно использовать для быстрого прототипирования моделей.

Таким образом, применение нейросетевых методов в анализе бухгалтерской отчетности представляет собой комплексную многоэтапную процедуру, требующую системного методологического подхода. Эффективность нейросетевого моделирования зависит от качества исходных данных, адекватности архитектурных решений, корректной настройки гиперпараметров и строгости процедур обучения и валидации. Особое значение приобретает учет мультиформатной природы финансовой информации (числовой, текстовой и визуальной), что обуславливает необходимость интеграции специализированных архитектур (CNN, RNN, трансформеров) и мультимодальных решений [28, с. 1–18]. Применение современных программных инструментов и платформ глубокого обучения расширяет возможности исследователей и практиков, однако требует высокой культуры экспериментирования и соблюдения требований к воспроизводимости результатов. В совокупности данная методология обеспечивает не только повышение точности аналитических выводов, но и расширение горизонтов интерпретации финансовой информации в условиях цифровой трансформации учета.

Апробация представленных методик в рамках научных исследований и pilotных внедрений продемонстрировала высокую эффективность нейросетевых моделей при решении различных задач в сфере бухгалтерского учета и финансового анализа. На основании обобщения эмпирических результатов можно выделить ключевые преимущества использования нейронных сетей в обработке и интерпретации данных финансовой отчетности, представленные в табл. 1.

Таблица 1. Преимущества использования нейронных сетей в обработке и интерпретации финансовой отчетности

| Преимущество | Пояснения |
|--|---|
| Повышение точности прогнозов и классификаций | В задачах предсказательного анализа финансового состояния компаний нейросети демонстрируют более высокую точность по сравнению с традиционными подходами |
| Выявление скрытых аномалий и мошенничества | Нейронные сети продемонстрировали способность обнаруживать случаи искажения отчетности, которые ранее не попадали в поле зрения аналитиков. Важно, что наряду с высокими метриками нейросетевые модели дают и качественно новые сведения: например, подсвечивая конкретные аномальные счета или подозрительные фразы, они помогают аудитору адресно проверить проблемные области, тем самым делая аудит более сфокусированным и проактивным. Также платформа на базе AI позволяет проверить 100% транзакций и выявить даже небольшие отклонения, обеспечивая уверенность в том, что ни одна подозрительная активность не останется незамеченной |
| Скорость и масштабируемость анализа | Нейронные сети позволяют обрабатывать финансовую информацию в масштабах и скоростях, недоступных человеку. Так, AI-система способна просканировать миллиарды записей за считанные миллисекунды, выполняя своего рода «рентген» всего бизнеса и вычленяя аномальные корреспонденции счетов в реальном времени. Это меняет парадигму аудита, происходит переход от выборочного тестирования к сплошному контролю. Масштабируемость нейросетевых решений проявляется и в том, что одна и та же модель может быть применена сразу к тысячам компаний. Для этого достаточно предоставить соответствующие данные, и результаты по всему массиву будут получены практически одновременно, без роста времени в линейной пропорции. В условиях, когда регуляторы требуют все большей прозрачности и частоты отчетности (вплоть до непрерывного аудита), подобная масштабируемость является критическим преимуществом |
| Интеграция разнородной информации | Нейросети способны объединять числовые, текстовые, временные и даже графовые данные в рамках единой модели. Мульти-модальные трансформеры могут делать выводы на основании сочетания большого количества разнородной информации. Тем самым реализуется целостный подход к анализу отчетности, приближенный к тому, как рассуждает эксперт, но с охватом намного большего количества факторов |
| Новые знания и партнеры | Интересным итогом внедрения нейросетей стало открытие новых эмпирических закономерностей, ранее не описанных в финансах. Например, кластеризация финансовых отчетов с помощью нейросети выявила, что среди компаний можно выделить устойчивые группы с отличающимися профилями: одна группа – с очень высоким качеством прибыли (высокие коэффициенты денежных потоков к прибыли), вторая – со средними показателями по всем метрикам, третья – с выдающейся рентабельностью, но более низким денежным покрытием [13, с. 343–355]. Таким образом, нейросетевые модели не только решают поставленные задачи, но и дают исследователям новые материалы для экономических интерпретаций, стимулируют развитие теории учета и финансов. |

Источник: разработано автором на основании анализа литературных источников.

Таким образом, можно сделать вывод, что результаты использования нейронных сетей в бухгалтерском учете крайне обнадеживают. Они показывают, что при грамотном применении ИИ-инструменты способны существенно усилить как мониторинг финансовой отчетности на предмет достоверности, так и аналитическую функцию по оценке и прогнозированию показателей.

При этом важно понимать, что сами по себе нейросети не гарантируют успеха. Многое зависит от качества данных, постановки задачи и контроля модели. Поэтому, стоит уделить внимание не только преимуществам, но и ограничениям и условиям эффективного использования нейросетевого анализа в бухгалтерской сфере, представленным в табл. 2.

Таблица 2. Проблемы и ограничения нейросетевых моделей в бухгалтерском анализе

| Проблемы и ограничения | Пояснения |
|---|--|
| Отсутствие методического стандарта | В традиционном анализе финансовой отчетности существуют устоявшиеся методики (например, общий алгоритм расчета и оценки коэффициентов ликвидности, платежеспособности и т.д.). Для нейросетевого анализа подобных стандартов пока нет. Исследователи применяют разные архитектуры, иногда получают противоречивые результаты, что затрудняет формулирование единых рекомендаций. Это означает, что практикующему бухгалтеру или аудитору трудно самостоятельно решить, как именно внедрять нейросети в отсутствие руководств от регуляторов или профессиональных сообществ |
| Необходимость больших выборок и качественных данных | Для обучения нейросетей требуется большой объем правильно размеченных данных. В ряде задач финансового учета это является проблемой. Например, крупных банкротств или случаев доказанного мошенничества происходит не так много. Данные разных компаний могут быть несопоставимы из-за отраслевых различий или разной учетной политики. Поэтому сбор достаточной обучающей выборки становится серьезной проблемой |
| Подбор архитектуры, параметров и времени обучения | Настройка нейросети – итеративный процесс, требующий экспериментов с гиперпараметрами. Перебор всех комбинаций слоев, нейронов, функций активации может занять очень много времени без гарантии результата. Время обучения сложных моделей также велико – даже на мощных видеокартах обучение трансформера на большом корпусе финансовых текстов может занять дни, недели или даже месяцы. Это является серьезным препятствием для небольших организаций или исследователей без доступа к вычислительным ресурсам. Долгий цикл разработки усложняет интеграцию модели в бизнес-процессы, которые требуют быстрых результатов |
| Недостаточная интерпретируемость | При использовании нейросетей сложно понять, почему модель приняла то или иное решение. В бухгалтерском учете и аудите это критично, поскольку аналитики и контролирующие органы не приемлют результатов, не обоснованных расчетами. Требуется объяснить, какие признаки повлияли и в какой степени. |

| Проблемы и ограничения | Пояснения |
|--|---|
| | Безусловно, исследования в области интерпретируемости результатов работы моделей ведутся. Однако полная прозрачность в случае нейросетей пока недостижима, так как такая модель является слишком сложной функцией. Это приводит к возникновению вопроса, готовы ли пользователи доверять важные решения модели, которую они до конца не понимают? Пока ответ скорее негативный, но ситуация меняется по мере развития искусственного интеллекта |
| Неустойчивость и общая применимость | Нейросетевые модели могут быть чувствительны к изменению данных: модель, обученная на одном периоде или стране, не обязательно хорошо будет работать в другом. Финансовые процессы могут меняться (например, кризисы ломают прежние паттерны, вводятся новые стандарты учета). Поэтому модель надо регулярно переобучать и мониторить ее качество на актуальных данных. Это требует организации соответствующего процесса: хранение новых данных, периодический запуск переобучения, сравнение версий модели |
| Необходимость специализированного ПО и компетенций | Внедрение нейросетей требует наличия ИТ-инфраструктуры и высококвалифицированных сотрудников. В исследованиях прямо отмечается необходимость разработки специального программного обеспечения и недостаток методической поддержки пользователей. Поэтому сегодня в крупных компаниях создаются междисциплинарные команды, в которых финансисты работают в паре с специалистами по данным, обеспечивая и постановку задачи и реализацию. Однако небольшие организации пока не обладают ресурсами, чтобы самостоятельно внедрять такие технологии |

Источник: разработано автором на основании анализа литературных источников.

Таким образом, несмотря на высокую эффективность и широкий потенциал применения, нейросетевые модели в бухгалтерском анализе сопряжены с рядом методологических и практических ограничений. Преодоление этих барьеров требует развития специализированных программных решений, совершенствования методической базы, а также формирования нового уровня компетенций у специалистов в области бухгалтерского учета.

Отдельно следует отметить возрастающее влияние развития искусственного интеллекта на компетенции учетных специалистов. Массовое внедрение нейросетевого анализа, безусловно, трансформирует профессию бухгалтера и аудитора. Рутинные операции, такие как сбор данных, расчет показателей, первичная проверка, все больше автоматизируются. Ожидается, что роль бухгалтера сместится в сторону аналитической и консультативной. Вместо сведения отчетов такие специалисты будут заниматься интерпретацией сгенерированных искусственным интеллектом данных, вместо поиска ошибок – оценкой рисков и предложений по их нивелированию. Навыки работы с данными и понимание принципов ИИ станут не менее важны, чем знание бухгалтерских стандартов. Таким образом, профессиональному сообществу нужно адаптироваться к развитию нейросетевого моделирования, включать курсы

по анализу данных и профессиональному интеллекту в подготовку бухгалтеров, разрабатывать этические кодексы использования ИИ, встраивать соответствующие положения в нормативную базу учета и аудита.

Подводя итог, можно сказать, что нейросетевой анализ отчетности – мощный инструмент, который следует применять осмотрительно. Его ценность неоспорима, так как он расширяет границы того, что может сделать финансовый аналитик, повышает качество и глубину анализа. Но чтобы раскрыть эту ценность, надо преодолеть множество трудностей – от качества данных до доверия пользователей.

Заключение

Нейросетевой анализ бухгалтерской отчетности сегодня представляет собой одно из наиболее перспективных направлений развития бухгалтерского учета и финансового анализа. Из проведенного исследования можно сделать ряд выводов.

Во-первых, нейронные сети доказали свою эффективность в решении традиционных задач финансового анализа (от оценки риска банкротства до выявления мошенничества), обеспечивая более высокую точность и полноту, чем классические методы. Это достигается за счет способности нейросетей обнаруживать сложные нелинейные зависимости и обрабатывать большие объемы разнородных данных одновременно.

Во-вторых, применение нейросетей стимулирует развитие научной мысли в области бухгалтерского учета. Оно стимулирует пересмотр классических теоретических догм и интеграцию эмпирических методов в учет. Бухгалтерская профессия эволюционирует – возникает спрос на специалистов, владеющих и финансовыми, и цифровыми компетенциями.

В-третьих, внедрение нейросетевых методов сопряжено с рядом методологических и практических проблем, которые нужно решать сообща усилиями исследователей, разработчиков и профессиональных организаций.

В-четвертых, практика показывает, что интеграция нейросетевых инструментов в реальные бизнес-процессы уже началась и приносит ощущимые результаты, такие как ускорение аудита, повышение качества контроля, экономию ресурсов.

В-пятых, учитывая междисциплинарность вопроса, рекомендуется усилить сотрудничество между учеными в области бухгалтерского учета, специалистами по анализу данных и практикующими аудиторами/финансистами. Совместные проекты, пилотные внедрения и прикладные исследования помогут учесть все аспекты – и математическую корректность моделей, и соответствие предметной области, и удобство применения.

Таким образом, методологические аспекты нейросетевого анализа бухгалтерской отчетности, рассмотренные в статье, показывают, что мы находимся на пороге существенных изменений в способах сбора, проверки и интерпретации финансовой информации. Нейронные сети из сферы теоретических экспериментов переходят в разряд прикладных решений, в ряде случаев уже доказав свою полезность на практике. Для научного сообщества

это означает появление новых исследовательских задач – от оптимизации архитектур для финансовых данных до исследования влияния ИИ на экономические решения. Для практиков – появление новых возможностей повысить эффективность и качество своей работы, а также дополнительных требований к квалификации. Задача научного сообщества и профессионалов – пройти этот путь, сочетая инновации с сохранением лучших принципов финансового контроля, и тогда искусственный интеллект станет надежным союзником в деле обеспечения прозрачности и устойчивости финансовой информации.

Список источников

1. *Kim A., Muhn M., Nikolaev V.* Financial Statement Analysis with Large Language Models // arXiv preprint arXiv. 2024. 2407. 17866. doi: 10.48550/arXiv.2407.17866 (дата обращения: 28.05.2025).
2. *Болотов Р.О., Суглобов А.Е.* О применении нейронных сетей для оценки финансовой устойчивости компаний // Russian Journal of Management. 2020. Т. 8, № 1. С. 106–110. doi: 10.29039/2409-6024-2020-8-1-106-110 (дата обращения: 28.05.2025).
3. *Huang H., Yuan Y.* Automated Financial Statement Analysis Based on Deep Learning Neural Networks // Frontiers in Artificial Intelligence and Applications. 2025. № 391. Р. 847–853. doi: 10.3233/FAIA241179 (дата обращения: 28.05.2025).
4. *Coakley J.R., Brown C.E.* Artificial Neural Networks in Accounting and Finance: Modeling Issues // International Journal of Intelligent Systems in Accounting, Finance & Management. 2000. Vol. 9. Р. 119–144. doi: 10.1002/1099-1174(200009)9:3<119::AID-ISAF165>3.0.CO;2-9. URL: https://download.lib.psu.ac.th/datawebclib/e_resource/trial_database/WileyInterScienceCD/pdf/ISAF/ISAF_1.pdf (дата обращения: 28.05.2025).
5. *Chen Y., Guo J., Huang J., Lin B.* A novel method for financial distress prediction based on sparse neural networks with L1/2 regularization // International Journal of Machine Learning and Cybernetics. 2022. № 13. Р. 2089–2103. doi: 10.1007/s13042-022-01566-y (дата обращения: 28.05.2025).
6. *Bi W., Xu B., Sun X., Wang Z., Shen H., Cheng X.* Company-as-Tribe: Company Financial Risk Assessment on Tribe-Style Graph with Hierarchical Graph Neural Networks // arXiv preprint arXiv: 2023. 2301. 13492. doi: 10.48550/arXiv.2301.13492 (дата обращения: 28.05.2025).
7. *Giantsidi S., Tarantola C.* Deep Learning for Financial Forecasting: A Review of Recent Advancements // SSRN. 2025. doi: 10.2139/ssrn.5263710 (дата обращения: 28.05.2025).
8. *Lipelis M.* Bridging Financial Forecasting and Budget Management: New Approaches for Modern Enterprises // Scientific Journal of Bielsko-Biala School of Finance and Law. 2025. № 29 (1). doi: 10.19192/wsfp.sj1.2025.5 (дата обращения: 28.05.2025).
9. *Artene A.E., Domil A.E.* Neural Networks in Accounting: Bridging Financial Forecasting and Decision Support Systems // Electronics. 2025. № 14 (5). Р. 993. doi: 10.3390/electronics14050993 (дата обращения: 28.05.2025).
10. *Rahayu D.V., Widuri R.* Artificial Neural Network Methodology in Financial Statements Fraud: An Empirical Study in the Property and Real Estate Sector // Risk Governance & Control: Financial Markets & Institutions. 2025. № 15 (1). Р. 237–248. doi: 10.22495/rgcv15i1sip9 (дата обращения: 28.05.2025).
11. *Müller R., Schreyer M., Sattarov T., Borth D.* RESHAPE: Explaining Accounting Anomalies in Financial Statement Audits by enhancing SHapley Additive exPlanations // arXiv preprint arXiv. 2022. 2209. 09157. doi: 10.48550/arXiv.2209.09157 (дата обращения: 28.05.2025).

12. *Bieganowski B., Slepaczuk R.* Supervised Autoencoder MLP for Financial Time Series Forecasting // arXiv preprint arXiv. 2024. 2404. 01866. doi: 10.48550/arXiv.2404.01866 (дата обращения: 28.05.2025).
13. *Li W., Liu X., Zhou S.* Deep Learning Model Based Research on Anomaly Detection and Financial Fraud Identification in Corporate Financial Reporting Statements // Journal of Combinatorial Mathematics and Combinatorial Computing. 2024. Vol. 123. P. 343–355. doi: 10.61091/jcmcc-123-24. – URL: <https://combinatorialpress.com/jcmcc-articles/volume-123/deep-learning-model-based-research-on-anomaly-detection-and-financial-fraud-identification-in-corporate-financial-reporting-statements/> (дата обращения: 28.05.2025).
14. *Zhang Y., Yang X.* Bridging Language Models and Financial Analysis // arXiv preprint arXiv. 2025. 2503. 22693. doi: 10.48550/arXiv.2503.22693
15. *Schreyer M., Hemati H., Borth D., Vasarhelyi M.A.* Federated Continual Learning to Detect Accounting Anomalies in Financial Auditing. arXiv preprint arXiv: 20222210.15051. DOI: 10.48550/arXiv.2210.15051 (дата обращения: 28.05.2025).
16. *Yang L., Li J., Dong R., Zhang Y., Smyth B.* NumHTML: Numeric-Oriented Hierarchical Transformer Model for Multi-task Financial Forecasting // arXiv preprint arXiv. 2022. 2201. 01770. doi: 10.48550/arXiv.2201.01770 (дата обращения: 28.05.2025).
17. *Elend L., Tideman S.A., Lopatta K., Kramer O.* Earnings Prediction with Deep Learning // arXiv preprint arXiv. 2020. 2006. 03132. doi: 10.48550/arXiv.2006.03132 (дата обращения: 28.05.2025).
18. *Wang C., Wang Y.* Stock return prediction with multiple measures using neural network models // Financial Innovation. 2024. № 10. P. 72. doi: 10.1186/s40854-023-00608-w (дата обращения: 28.05.2025).
19. *Trinh V.* Applicability of Deep Neural Networks in Business Decision Making and Market Prediction Investment // arXiv preprint arXiv. 2024. 2502. 00151. doi: 10.48550/arXiv.2502.00151 (дата обращения: 28.05.2025).
20. *Scherrmann M., Elsas R.* Earnings Prediction Using Recurrent Neural Networks // arXiv preprint arXiv. 2023. 2311. 10756. doi: 10.48550/arXiv.2311.10756 (дата обращения: 28.05.2025).
21. *Durairaj M., Mohan B.H.K.* A convolutional neural network based approach to financial time series prediction // Neural Computing and Applications. 2022. № 34. P. 13319–13337. doi: 10.1007/s00521-022-07143-2 (дата обращения: 28.05.2025).
22. *Golbayani P., Wang D., Florescu I.* Application of Deep Neural Networks to Assess Corporate Credit Rating // arXiv preprint arXiv. 2020. 2003. 02334. doi: 10.48550/arXiv.2003.02334 (дата обращения: 28.05.2025).
23. *Shabani M., Tran D.T., Magris M., Kannainen J., Iosifidis A.* Multi-head Temporal Attention-Augmented Bilinear Network for Financial Time Series Prediction // arXiv preprint arXiv. 2022. 2201. 05459. doi: 10.48550/arXiv.2201.05459 (дата обращения: 28.05.2025).
24. *Cuervo R.* Predictive AI for SME and Large Enterprise Financial Performance Management // arXiv preprint arXiv. 2023. 2311. 05840. doi: 10.48550/arXiv.2311.05840 (дата обращения: 28.05.2025).
25. *Piven A.* Analysis of Financial Reports in Companies Using Machine Learning // Financial Markets, Institutions and Risks. 2023. № 7 (4). P. 135–154. doi: 10.61093/fmir.7(4).135-154.2023 (дата обращения: 28.05.2025).
26. *Zim M.N.F.* Harnessing Graph Neural Networks for Enhanced Fraud Detection in Financial Transactions // arXiv preprint arXiv. 2025. 2503. 22681. DOI: 10.48550/arXiv.2503.22681 (дата обращения: 28.05.2025).
27. *Zouaghia Z., Kodia Z., Ben Said L.* SMAPF-HNNA: A novel Stock Market Analysis and Prediction Framework using Hybrid Neural Network Architectures Across Major U.S. Indices // International Journal of Data Science and Analytics. 2025. doi: 10.1007/s41060-025-00811-1 (дата обращения: 28.05.2025).

28. Wang J., Zhang S., Xiao Y., Song R. A Review on Graph Neural Network Methods in Financial Applications // arXiv preprint arXiv. 2021. 2111. 15367. doi: 10.48550/arXiv.2111.15367 (дата обращения: 28.05.2025).

References

1. Kim, A., Muhn, M. & Nikolaev, V. (2024) Financial Statement Analysis with Large Language Models. *arXiv preprint arXiv:2407.17866*. doi: 10.48550/arXiv.2407.17866. [Online] Available from: <https://arxiv.org/abs/2407.17866> (Accessed: 28.05.2025).
2. Bolotov, R.O. & Suglobov, A.E. (2020) O primenenii nevronnykh setey dlya otsenki finansovoy ustoychivosti kompaniy [On the Application of Neural Networks for Assessing the Financial Stability of Companies]. *Russian Journal of Management*. 8 (1). pp. 106–110. doi: 10.29039/2409-6024-2020-8-1-106-110
3. Huang, H. & Yuan, Y. (2025) Automated Financial Statement Analysis Based on Deep Learning Neural Networks. *Frontiers in Artificial Intelligence and Applications*. 391. pp. 847–853. doi: 10.3233/FAIA241179
4. Coakley, J.R. & Brown, C.E. (2000) Artificial Neural Networks in Accounting and Finance: Modeling Issues. *International Journal of Intelligent Systems in Accounting, Finance & Management*. 9 (3). pp. 119–144. doi: 10.1002/1099-1174(200009)9:3<119::AID-ISAF165>3.0.CO;2-9. [Online] Available from: https://download.clib.psu.ac.th/datawebclib/e_resource/trial_database/WileyInterScienceCD/pdf/ISAF/ISAF_1.pdf (Accessed: 28.05.2025).
5. Chen, Y., Guo, J., Huang, J. & Lin, B. (2022) A novel method for financial distress prediction based on sparse neural networks with L1/2 regularization. *International Journal of Machine Learning and Cybernetics*. 13. pp. 2089–2103. doi: 10.1007/s13042-022-01566-y
6. Bi, W., Xu, B., Sun, X., Wang, Z., Shen, H. & Cheng, X. (2023) Company-as-Tribe: Company Financial Risk Assessment on Tribe-Style Graph with Hierarchical Graph Neural Networks. *arXiv preprint arXiv:2301.13492*. doi: 10.48550/arXiv.2301.13492. [Online] Available from: <https://arxiv.org/abs/2301.13492> (Accessed: 28.05.2025).
7. Giatsidi, S. & Tarantola, C. (2025) Deep Learning for Financial Forecasting: A Review of Recent Advancements. *SSRN*. doi: 10.2139/ssrn.5263710. [Online] Available from: <https://ssrn.com/abstract=5263710> (Accessed: 28.05.2025).
8. Lipelis, M. (2025) Bridging Financial Forecasting and Budget Management: New Approaches for Modern Enterprises. *Scientific Journal of Bielsko-Biala School of Finance and Law*. 29 (1). doi: 10.19192/wsfp.sj1.2025.5
9. Artene, A.E. & Domil, A.E. (2025) Neural Networks in Accounting: Bridging Financial Forecasting and Decision Support Systems. *Electronics*. 14 (5). 993. doi: 10.3390/electronics14050993
10. Rahayu, D.V. & Widuri, R. (2025) Artificial Neural Network Methodology in Financial Statements Fraud: An Empirical Study in the Property and Real Estate Sector. *Risk Governance & Control: Financial Markets & Institutions*. 15 (1). pp. 237–248. doi: 10.22495/rgev15i1sp9
11. Müller, R., Schreyer, M., Sattarov, T. & Borth, D. (2022) RESHAPE: Explaining Accounting Anomalies in Financial Statement Audits by enhancing SHapley Additive exPlanations. *arXiv preprint arXiv:2209.09157*. doi: 10.48550/arXiv.2209.09157. [Online] Available from: <https://arxiv.org/abs/2209.09157> (Accessed: 28.05.2025).
12. Bieganowski, B. & Slepaczuk, R. (2024) Supervised Autoencoder MLP for Financial Time Series Forecasting. *arXiv preprint arXiv:2404.01866*. doi: 10.48550/arXiv.2404.01866. [Online] Available from: <https://arxiv.org/abs/2404.01866> (Accessed: 28.05.2025).
13. Li, W., Liu, X. & Zhou, S. (2024) Deep Learning Model Based Research on Anomaly Detection and Financial Fraud Identification in Corporate Financial Reporting Statements. *Journal of Combinatorial Mathematics and Combinatorial Computing*. 123. pp. 343–355. doi: 10.61091/jcmcc123-24. [Online] Available from: <https://combinatorialpress.com/jcmcc-articles/volume-123/deep-learning-model-based-research-on-anomaly-detection-and->

financial-fraud-identification-in-corporate-financial-reporting-statements/ (Accessed: 28.05.2025).

14. Zhang, Y. & Yang, X. (2025) Bridging Language Models and Financial Analysis. *arXiv preprint arXiv:2503.22693*. doi: 10.48550/arXiv.2503.22693. [Online] Available from: <https://arxiv.org/abs/2503.22693> (Accessed: 28.05.2025).

15. Schreyer, M., Hemati, H., Borth, D. & Vasarhelyi, M.A. (2022) Federated Continual Learning to Detect Accounting Anomalies in Financial Auditing. *arXiv preprint arXiv:2210.15051*. doi: 10.48550/arXiv.2210.15051. [Online] Available from: <https://arxiv.org/abs/2210.15051> (Accessed: 28.05.2025).

16. Yang, L., Li, J., Dong, R., Zhang, Y. & Smyth, B. (2022) NumHTML: Numeric-Oriented Hierarchical Transformer Model for Multi-task Financial Forecasting. *arXiv preprint arXiv:2201.01770*. doi: 10.48550/arXiv.2201.01770. [Online] Available from: <https://arxiv.org/abs/2201.01770> (Accessed: 28.05.2025).

17. Elend, L., Tideman, S.A., Lopatta, K. & Kramer, O. (2020) Earnings Prediction with Deep Learning. *arXiv preprint arXiv:2006.03132*. doi: 10.48550/arXiv.2006.03132. [Online] Available from: <https://arxiv.org/abs/2006.03132> (Accessed: 28.05.2025).

18. Wang, C. & Wang, Y. (2024) Stock return prediction with multiple measures using neural network models. *Financial Innovation*. 10. 72. doi: 10.1186/s40854-023-00608-w

19. Trinh, V. (2024) Applicability of Deep Neural Networks in Business Decision Making and Market Prediction Investment. *arXiv preprint arXiv:2502.00151*. doi: 10.48550/arXiv.2502.00151. [Online] Available from: <https://arxiv.org/abs/2502.00151> (Accessed: 28.05.2025).

20. Scherrmann, M. & Elsas, R. (2023) Earnings Prediction Using Recurrent Neural Networks. *arXiv preprint arXiv:2311.10756*. doi: 10.48550/arXiv.2311.10756. [Online] Available from: <https://arxiv.org/abs/2311.10756> (Accessed: 28.05.2025).

21. Durairaj, M. & Mohan, B.H.K. (2022) A convolutional neural network based approach to financial time series prediction. *Neural Computing and Applications*. (34). pp. 13319–13337. doi: 10.1007/s00521-022-07143-2

22. Golbayani, P., Wang, D. & Florescu, I. (2020) Application of Deep Neural Networks to Assess Corporate Credit Rating. *arXiv preprint arXiv:2003.02334*. doi: 10.48550/arXiv.2003.02334. [Online] Available from: <https://arxiv.org/abs/2003.02334> (Accessed: 28.05.2025).

23. Shabani, M., Tran, D.T., Magris, M., Kanniainen, J. & Iosifidis, A. (2022) Multi-head Temporal Attention-Augmented Bilinear Network for Financial Time Series Prediction. *arXiv preprint arXiv:2201.05459*. doi: 10.48550/arXiv.2201.05459. [Online] Available from: <https://arxiv.org/abs/2201.05459> (Accessed: 28.05.2025).

24. Cuervo, R. (2023) Predictive AI for SME and Large Enterprise Financial Performance Management. *arXiv preprint arXiv:2311.05840*. doi: 10.48550/arXiv.2311.05840. [Online] Available from: <https://arxiv.org/abs/2311.05840> (Accessed: 28.05.2025).

25. Piven, A. (2023) Analysis of Financial Reports in Companies Using Machine Learning. *Financial Markets, Institutions and Risks*. 7 (4). pp. 135–154. doi: 10.61093/fmir.7(4).135-154.2023

26. Zim, M.N.F. (2025) Harnessing Graph Neural Networks for Enhanced Fraud Detection in Financial Transactions. *arXiv preprint arXiv:2503.22681*. doi: 10.48550/arXiv.2503.22681. [Online] Available from: <https://arxiv.org/abs/2503.22681> (Accessed: 28.05.2025).

27. Zouaghia, Z., Kodia, Z. & Ben Said, L. (2025) SMAPF-HNNA: A novel Stock Market Analysis and Prediction Framework using Hybrid Neural Network Architectures Across Major U.S. Indices. *International Journal of Data Science and Analytics*. doi: 10.1007/s41060-025-00811-1

28. Wang, J., Zhang, S., Xiao, Y. & Song, R. (2021) A Review on Graph Neural Network Methods in Financial Applications. *arXiv preprint arXiv:2111.15367*. doi: 10.48550/arXiv.2111.15367. [Online] Available from: <https://arxiv.org/abs/2111.15367> (Accessed: 28.05.2025).

Информация об авторе:

Popravko I.V. – доцент кафедры экономической безопасности и бухгалтерского учета, доцент, кандидат экономических наук, Воронежский государственный университет (Воронеж, Россия). E-mail: ipopravko@mail.ru

Автор заявляет об отсутствии конфликта интересов.

Information about the author:

I.V. Popravko, Cand. Sci. (Economics), docent, associate professor at the Department of Economic Security and Accounting, Voronezh State University (Voronezh, Russian Federation). E-mail: ipopravko@mail.ru

The author declares no conflicts of interests.

*Статья поступила в редакцию 09.06.2025;
одобрена после рецензирования 08.09.2025; принята к публикации 12.09.2025.*

*The article was submitted 09.06.2025;
approved after reviewing 08.09.2025; accepted for publication 12.09.2025.*