

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОВЕРКИ БУХГАЛТЕРСКИХ ПРОВОДОК

И.В. Матюш, канд. экон. наук

В.Н. Казак, студентка

*Полоцкий государственный университет имени Евфросинии Полоцкой,
Республика Беларусь*

Нейронные сети можно эффективно использовать в разных сферах, в частности для использования в бухгалтерском учёте. В статье рассматривается применение нейронных сетей для автоматической проверки бухгалтерских проводок, ключевые концепции бухгалтерских проводок, а также методы их представления, специфика обучения нейронных сетей на бухгалтерских данных и выбор подходящих архитектур.

Ключевые слова: *искусственный интеллект, бухгалтерский учёт, машинное обучение, нейронные сети, бухгалтерские проводки.*

Искусственный интеллект уже несколько лет является неотъемлемой частью нашей жизни. Каждый день мы сталкиваемся с различными сервисами рекомендаций, умными гаджетами, которые в своей основе имеют нейронные сети. Глупо отрицать, что технологии искусственного интеллекта значительным образом повышают комфорт и эффективность, позволяя автоматизировать рутинные задачи и улучшать качество принимаемых решений. В результате, они открывают новые возможности в самых разных сферах, включая медицину, образование и финансы, делая наши повседневные процессы более продуктивными и удобными.

С течением времени и развитием информационных технологий бухгалтерский учёт претерпел значительные изменения, преобразовавшись из простого набора бумажных журналов и книг в комплексные цифровые системы. Ранее компьютерные технологии использовались преимущественно для регистрации бухгалтерских операций и выполнения вычислений, что привело к созданию баз данных с ограниченным объёмом информации, связанной исключительно с конкретной организацией. Однако эти изменения стали лишь началом трансформации бухгалтерии. Современные информационные технологии не только автоматизировали рутинные процессы, но и позволили создать интегрированные системы, охватывающие не только внутренние операции компании, но и взаимодействующие с внешними источниками данных. Это открыло новые горизонты для анализа, прогнозирования и управления финансовыми потоками на более высоком уровне.

С появлением искусственного интеллекта в бухгалтерском учёте ситуация изменилась кардинально. Интеграция ИИ не только повысила скорость и качество обработки информации, но и создала новые возможности для финансового анализа и управления, позволяя компаниям более эффективно принимать решения на основе анализа больших объёмов данных.

Переходя от искусственного интеллекта, следует отметить, что одной из наиболее ярких и мощных технологий в этой области являются нейронные сети.

Нейронная сеть представляет один из видов машинного обучения, в основу которой положена математическая модель и ее программно-аппаратное воплощение, смоделированная по принципу функционирования человеческого мозга. Обучение нейронной системы

может осуществляться как с помощью алгоритмов распознавания или команд, заданных человеком, так и самостоятельно, основываясь на ранее полученной информации. Структура нейронной сети формируется из нескольких слоев простейших процессоров (нейронов). Каждый такой нейрон производит математические вычисления над входящей информацией. Передача сигналов и взаимосвязь между нейронами осуществляется через синапсы, которые представляют собой место контакта, где конечные отростки одного нейрона встречаются с телом другого нейрона. Полученный таким образом результат математической функции нейрона передаётся в следующий слой или на выход нейронной сети.

Основное предназначение нейронных сетей — решение задач, связанных с анализом больших объёмов данных, распознаванием образов и прогнозированием. Они используются в самых разных сферах: от обработки изображений и речи до финансов и медицины. Например, нейронные сети могут распознавать изображения, обрабатывать естественный язык, управлять автономными транспортными средствами или выполнять прогнозы на фондовом рынке.

Нейронные сети эффективны, когда задача требует анализа сложных и многомерных данных, таких как изображения, звуки или текст. Они способны «обучаться» на примерах, улучшая свои результаты по мере увеличения объёма тренировочных данных.

В анализе бухгалтерских проводок, нейронные сети позволяют решить следующие задачи:

- выявление мошенничества в бухгалтерских проводках: Нейронные сети способны обнаруживать подозрительные транзакции и отклонения от нормальных паттернов, что помогает предотвратить мошенничество и ошибки в учёте;
- автоматизация проверки проводок: Возможность автоматизировать процесс проверки проводок, сокращая время, затрачиваемое на ручной анализ, и повышая точность финансовых отчётов;
- прогнозирование финансовых потоков: Нейронные сети могут анализировать исторические данные для предсказания будущих финансовых потоков, что способствует более эффективному планированию и управлению ресурсами;
- классификация проводок: Способность классифицировать проводки по категориям (например, доходы, расходы, активы) на основе их характеристик, что упрощает последующий анализ и отчетность.

Немаловажным моментом в интеграции нейронных сетей в область применения является правильное описание и представление данных для обучения. В данном случае, данных бухгалтерских проводок.

Бухгалтерские проводки — это системные записи в учётных регистрах, которые фиксируют каждое движение финансовых или иных активов компании. Каждая проводка представляет собой отражение хозяйственной операции, состоящей из двух частей: дебета и кредита. Эти записи позволяют отслеживать, откуда поступили средства и куда они были направлены. Основная задача бухгалтерской проводки — обеспечить прозрачность и точность финансовой отчётности.

Проводки необходимы для составления бухгалтерского баланса, формирования отчётов о прибылях и убытках, а также для проведения различных аудиторских проверок. Они используются для контроля финансового положения компании, позволяют оценивать её активы и обязательства, а также управлять расходами и доходами. Кроме того, проводки являются основой для последующего анализа финансовых результатов и принятия управленческих решений.

С помощью проводок можно обеспечить соответствие деятельности компании законодательным нормам и стандартам бухгалтерского учёта. В конечном итоге они помогают компаниям избегать финансовых рисков и своевременно выявлять отклонения в движении средств.

Таблица бухгалтерских проводок обычно содержит значительный объём данных, особенно для крупных организаций, где ежедневно совершаются сотни или тысячи операций. Размер данных может варьироваться от нескольких тысяч записей до миллионов, в зависимости от активности компании и временного диапазона, который охватывается таблицей.

Обычно такая таблица включает следующие ключевые поля:

Номер проводки — уникальный идентификатор каждой операции. Это числовое значение или строка, которое используется для быстрого поиска и отслеживания конкретных проводок.

Дата операции — точная дата и время совершения проводки. Этот столбец необходим для анализа проводок по периодам, чтобы выявлять финансовую активность за отчётные периоды, кварталы или годы.

Счёт дебета — номер бухгалтерского счёта, на который поступают активы или обязательства в результате операции. Этот счёт отражает, какие ресурсы увеличиваются.

Счёт кредита — номер бухгалтерского счёта, с которого списываются средства. В отличие от дебета, кредит показывает, откуда средства были переведены или какие обязательства уменьшились.

Сумма операции — числовое значение, представляющее денежный эквивалент проведённой операции. Это ключевая метрика для финансового анализа и контроля.

Описание операции — текстовое поле, содержащее краткое описание цели проводки. Например, это может быть оплата услуг, закупка материалов, перечисление налогов или зарплат.

Документ-основание — ссылка на первичный документ, который подтверждает факт совершения проводки (например, счёт-фактура, накладная, чек). Это обязательный элемент для аудита и подтверждения легитимности каждой финансовой операции.

Статус операции — показывает, была ли операция завершена, аннулирована или ожидает подтверждения. Этот столбец позволяет отслеживать состояние проводок в реальном времени.

Объём данных может варьироваться в зависимости от времени хранения информации и частоты проводок. В типичной базе данных за год могут накопиться миллионы записей, особенно в компаниях с высокой транзакционной активностью.

Также немаловажным аспектом для эффективной интеграции нейронных сетей является выбор конструкции нейронной сети. Так как в зависимости от задачи наиболее эффективными являются нейронные сети определенного типа.

Для задачи проверки бухгалтерских проводок наиболее актуальными являются следующие типы нейронных сетей:

Полносвязные нейронные сети (Fully Connected Networks, FCN) представляют собой модели, состоящие из нескольких слоёв нейронов, каждый из которых соединён со всеми нейронами следующего слоя. Эти сети особенно эффективны при работе с задачами классификации и регрессии на структурированных данных, таких как бухгалтерские проводки. Благодаря своей архитектуре, они могут находить сложные нелинейные зависимости между

различными признаками, такими как сумма операции, дата, счета дебета и кредита. FCN позволяют анализировать большие массивы данных, помогая обнаружить аномалии или ошибки, которые могут ускользнуть при ручной проверке. Они хорошо подходят для классификации проводок как корректных или подозрительных, а также для предсказания вероятности ошибок на основе исторических данных.

Рекуррентные нейронные сети (RNN), и, в частности, их модификация LSTM (Long Short-Term Memory), предназначены для анализа последовательных данных, что делает их эффективными для работы с временными рядами бухгалтерских проводок. LSTM-сети способны запоминать долгосрочные зависимости, что особенно важно при анализе транзакций, которые могут быть связаны через определённые временные интервалы. Это позволяет выявлять паттерны или аномалии в поведении финансовых операций, например, внезапное увеличение активности на определённых счетах или повторяющиеся подозрительные транзакции. Рекуррентные сети полезны для анализа временных корреляций, что делает их отличным инструментом для предотвращения и обнаружения мошенничества.

Сверточные нейронные сети (CNN), которые обычно используются для обработки изображений, также могут применяться для анализа временных рядов или табличных данных. Они выделяют локальные закономерности в данных, что позволяет находить аномальные сегменты или шаблоны в последовательностях проводок. Например, транзакции могут быть представлены в виде временной матрицы с ключевыми признаками, и CNN помогут выявить в этих данных локальные отклонения. Это делает сверточные сети полезными для анализа больших массивов транзакций, где важно находить небольшие аномальные участки, которые могут оставаться незамеченными.

Автокодировщики (Autoencoders) — это нейронные сети, которые обучаются восстанавливать исходные данные через сжатое скрытое представление. Они полезны для обнаружения аномалий, поскольку способны плохо восстанавливать нетипичные или редкие данные, что позволяет эффективно выявлять подозрительные операции, отклоняющиеся от нормальных шаблонов. В бухгалтерском учёте автокодировщики могут использоваться для нахождения транзакций, которые отличаются от общей массы, например, неверные суммы или некорректные сочетания счетов дебета и кредита. Этот подход позволяет быстро выявлять ошибки или подозрительные проводки в больших объёмах данных.

Таким образом, каждая из этих нейронных сетей имеет свои преимущества для автоматизированной проверки бухгалтерских проводок. Полносвязные сети позволяют выявлять сложные зависимости в данных, рекуррентные сети эффективны для анализа временных последовательностей, сверточные сети помогают находить локальные отклонения, а автокодировщики полезны для поиска редких аномалий.

Обучение нейронной сети на данных бухгалтерского учёта требует особого внимания к представлению данных и их подготовке. Классовый дисбаланс является важной проблемой, так как аномальные проводки встречаются реже, что может снизить качество предсказаний. Для борьбы с этим можно использовать методы взвешивания классов или генерировать синтетические данные с помощью SMOTE или GAN. Важно также провести тщательный отбор признаков, чтобы удалить незначимые и избыточные, что ускорит обучение и повысит интерпретируемость модели. Аугментация данных может быть полезна при нехватке информации, позволяя создавать новые примеры проводок через небольшие варьирования значений. Что касается обработки данных, ключевыми этапами являются кодирование кате-

гориальных признаков, нормализация числовых значений и создание новых признаков, отражающих временные зависимости. Например, из даты операции можно извлечь год, месяц и день недели. При этом необходимо также учитывать пропуски и выбросы: пропуски можно заполнять средними значениями, а выбросы — либо удалять, либо заменять. Данные следует разделить на обучающую, валидационную и тестовую выборки, что обеспечит корректную оценку производительности модели. В результате, при правильно настроенной модели и качественной подготовке данных, можно ожидать, что рекуррентные нейронные сети, особенно LSTM, продемонстрируют высокую точность предсказаний.

Интеграция нейронных сетей в процесс проверки бухгалтерских проводок существенно повышает точность и эффективность финансового контроля, позволяя выявлять аномалии, автоматизировать рутинные операции и оптимизировать процесс принятия решений. Таким образом, использование нейронных сетей не только улучшает качество аудиторских проверок, но и открывает новые перспективы для анализа и прогнозирования финансовых потоков, что в свою очередь способствует более устойчивому и прозрачному управлению финансовыми ресурсами в организациях.

Список использованных источников

1. Васильев, С. И. Влияние искусственного интеллекта на бухгалтерский учёт // Вестник экономики и управления. 2020. Т. 18, № 3. С. 45-59.
2. МАТЮШ, И. В. (2024). ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ПРИ МОНИТОРИНГЕ И ПРОГНОЗИРОВАНИИ ФИНАНСОВЫХ ПОТОКОВ. Вестник Полоцкого государственного университета. Серия D. Экономические и юридические науки, (2), 16-20. <https://doi.org/10.52928/2070-1632-2024-67-2-16-20>
3. Захаров, М. П. Рекуррентные нейронные сети и их применение в прогнозировании финансовых потоков // Экономика и управление: теория и практика. 2022. № 15. С. 65-78.
4. Сергеев, О. Н. Классификация бухгалтерских проводок с использованием полносвязных нейронных сетей // Бухгалтерский учёт в XXI веке. 2021. № 11. С. 22-35.
5. Фёдоров, А.С. Прогнозирование финансовых рисков с использованием LSTM-нейронных сетей // Бухгалтерский учёт и анализ. 2023. Т.5, №1. С. 78-93.
6. Беляев, Н. И. Проблемы и перспективы применения ИИ в области финансового учёта // Информационные системы и технологии в экономике. 2023. №6. С. 50-63.