

ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ВЫЯВЛЕНИЯ ПОДОЗРИТЕЛЬНЫХ БАНКОВСКИХ ОПЕРАЦИЙ

Зиненко А.В., Руйга И.Р., Смирнова О.А.

Зиненко Анна Викторовна, Руйга Ирина Рудольфовна

Сибирский федеральный университет

г. Красноярск, Россия. 660036, Красноярский край, Свободный пр-т, д. 79.

E mail: anna-z@mail.ru, irina_rouiga@bk.ru

Смирнова Ольга Александровна (ORCID.ORG 0000-0003-4740-6051)

Ивановский Государственный Университет

г. Иваново, Россия. 153025, Ивановская область, г. Иваново, ул. Ермака, д. 39.

E-mail: olgakineshma@gmail.com

В работе представлены алгоритмы глубокого обучения на основе искусственных нейронных сетей, позволяющий выявлять подозрительные сделки физических лиц – клиентов коммерческого банка. В качестве критериев подозрительности были взяты два из восьми критериев Банка России. Для обучения и тестирования алгоритма глубокого обучения был сгенерирован датасет из 10000 транзакций. Были разработаны и протестированы две разновидности нейронных сетей: полносвязная нейросеть и рекуррентная нейросеть, предназначенная для анализа последовательностей. Рекуррентная нейронная сеть показала хорошие результаты по метрикам качества модели Precision, Recall и Accuracy.

Ключевые слова: подозрительные транзакции, искусственный интеллект, полносвязная нейронная сеть, рекуррентная нейронная сеть, глубокое обучение

ARTIFICIAL INTELLIGENCE TECHNOLOGIES FOR DETECTING SUSPICIOUS BANKING OPERATIONS

Zinenko A.V., Ruiga I.R., Smirnova O.A.

Zinenko Anna Viktorovna, Ruyga Irina Rudolfovna (ORCID.ORG 0000-0002-4212-0321)

Siberian Federal University

Krasnoyarsk, Russia. 660036, Krasnoyarsk Territory, Svobodny Ave, 79.

E mail: anna-z@mail.ru, irina_rouiga@bk.ru

Smirnova Olga Alexandrovna (ORCID.ORG 0000-0003-4740-6051)

Ivanovo State University

Ivanovo, Russia. 39 Ermaka St., Ivanovo, Ivanovo region, 153025.

E-mail: olgakineshma@gmail.com

The paper presents deep learning algorithms based on artificial neural networks that allow identifying suspicious transactions of individuals - clients of a commercial bank. Two of the eight criteria of the Bank of Russia were taken as criteria of suspicion. A dataset of 10,000 transactions was generated for training and testing the deep learning algorithm. Two types of neural networks were developed and tested: a fully connected neural network and a recurrent neural network designed to analyze sequences. The recurrent neural network showed good results in terms of the Precision, Recall and Accuracy model quality metrics.

Keywords: suspicious transactions, artificial intelligence, fully connected neural network, recurrent neural network, deep learning

ВВЕДЕНИЕ

Под искусственным интеллектом понимается способность программных алгоритмов решать конкретные задачи, обучаться и принимать решения [1]. В банковской сфере искусственный интеллект широко используется в таких областях, как обработка документов, кредитный скоринг, взаимодействие с клиентами, прогнозирование загрузки банкоматов. В сфере противодействия преступному отмыванию доходов, финансированию терроризма искусственный интеллект применяется при анализе связей и при выявлении подозрительных сделок. В настоящей работе мы рассматриваем возможности и ограничения применения искусственного интеллекта к выявлению подозрительных сделок с целью преступного отмывания доходов, финансированию терроризма. Коммерческие банки являются крупнейшими организациями, совершающими операции с денежными средствами. По этой причине они особо подвержены преступному отмыванию доходов. Если в банке возникло подозрение о необычном характере сделки, он вправе приостановить обслуживание клиента, заблокировать его счет, а также обязан сообщить о подозрительной сделке регулятору [2]. Список критериев необычных сделок представлен в приложении к Положению Банка России Положение Банка России от 2 марта 2012 г. N 375-П "О требованиях к правилам внутреннего контроля кредитной организации в целях противодействия легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма".

Он насчитывает десятки критериев. Более широкий список критериев касается основания для блокировки операций физических лиц. В 2024 году Банк России выделил следующие восемь критериев:

- более 10 в день или более 50 в месяц контрагентов-физлиц;
- более 30 операций в день, проведенных физлицами;
- операции по зачислению безналичных средств между физлицами в объеме более 100 000 рублей в день или 1 млн рублей в месяц;
- менее минуты между зачислением средств и их списанием;
- операции по зачислению и списанию средств, проводимые в течение 12 часов одних суток;
- отсутствие платежей в пользу юрлиц, обеспечивающих жизнедеятельность (оплата коммунальных услуг, услуг связи, товаров);
- совпадение идентификационной информации об устройстве, используемом разными физлицами для удаленного доступа к услугам банка;

- в течение недели средний остаток денежных средств на банковском счете не превышает 10% от среднедневного объема операций.

Для конструирования модели глубокого обучения, определяющие подозрительные сделки мы выбрали две наиболее важные на наш взгляд критерия: операции по зачислению и списанию средств, проводимые в течение 12 часов одних суток и операции по зачислению безналичных средств между физлицами в объеме более 100 000 рублей в день или 1 млн. рублей в месяц.

МАТЕРИАЛЫ И МЕТОДЫ

Основным инструментом искусственного интеллекта в настоящее время выступают искусственные нейронные сети. Искусственная нейронная сеть представляет собой систему соединенных между собой и взаимодействующих между собой искусственных нейронов. Нейронная сеть состоит из нескольких слоев: входные нейроны, получающие сигнал; скрытые слои, внутри которых сигнал определенным образом обрабатывается, и выходной слой, который выводит результат [3].

Обучение нейронной сети можно описать следующей последовательностью действий.

1. На первом слое задаются входные сигналы (x_i), веса (w_i) и смещение (b).

2. Взвешенные входные сигналы суммируются и результат $-\sum w_i x_i + b$ обрабатывается некоторой активационной функцией z . Активационной функцией может выступать, например, логистическая функция, гиперболический тангенс и т. д.

3. Результаты активационной функции подаются на следующий скрытый слой, также с определенными весами. Затем шаг 2 повторяется до выходного слоя. На выходе мы получаем некий результат $\sum w_j a_j + b$, где a – результаты функции активации на предпоследнем слое.

4. Полученный результат сравнивается с фактическим значением, которое мы имеем, так как находимся в стадии обучения. Строится функция потерь. Для задач бинарной классификации, к которым относится выявление подозрительных банковских операций, такой функцией выступает кросс-энтропия, рассчитываемая по формуле (1).

$$CE = -\sum_{i=1}^n (p(x) \ln q(x) + (1 - p(x)) \ln(1 - q(x))), \quad (1)$$

где $p(x)$ – фактическая вероятность, $q(x)$ – предсказанная вероятность.

5. Функция потерь устремляется к минимуму, рассчитываются цепочки частных производных, которые в конечном итоге приводят к производным по весам на каждом слое. Веса пересчитываются так, чтобы функция потерь минимизировалась.

6. Процедура повторяется до тех пор, пока ошибка не перестает меняться. Каждый повтор называется эпоха.

Для того, чтобы нейросеть не переобучалась, а также во избежание перегрузки системы веса пересчитываются не по каждой единице входящих данных (например, уровню временного ряда), а по пакетам (батчам) [4].

Особое внимание следует уделить рекуррентному слою, который предназначен для анализа последовательностей. Если для обычного слоя, к примеру плотного слоя Dense, входные данные имеют размерность «образцы» × «признаки», то

для рекуррентного слоя прибавляется еще одно измерение, и входные данные подаются в виде тензора размерностью «образцы» × «временные интервалы» × «признаки». Для такой формы входных данных необходимо несколько преобразовать исходную матрицу «образцы» × «признаки». Пример преобразования исходных данных на случай, если мы прогнозируем на 3 периода вперед на основании 10 прошлых периодов показана на рисунке 1. Первый входной массив X_0 размерностью 10×3 дает первый прогноз Y_0 размерностью 3×3 и так далее.

Date	ID	Sums	Answers
1	134	1,75E+09	1
1	283	1259700	0
1	62	1,37E+08	1
1	43	8,96E+08	1
1	15	1156400	0
1	344	1741300	0
1	79	208100	0
1	201	646400	0
1	317	631100	0
1	277	1508400	0
1	375	555600	0
1	211	534000	0
1	204	1,18E+09	1
1	391	195100	0
1	80	778400	0

Рис. 1. Пример подготовки данных для рекуррентного слоя
Fig. 1. An example of data preparation for a recurrent layer

Наиболее распространенными инструментами для конструирования искусственных нейронных сетей в настоящее время являются библиотеки Tensorflow и Keras [5], которые интегрированы во многие языки программирования, в том числе Python, используемый нами.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для выявления подозрительных операций мы выбрали два критерия: операции по зачислению и списанию средств, проводимые в течение 12 часов одних суток и операции по зачислению безналичных средств между физлицами в объеме более 100 000 рублей в день или 1 млн рублей в месяц. Для обучения нейронной сети мы сгенерировали датасет из 10000 транзакций, состоящий из следующих столбцов: «День» – индекс дня. Всего мы выбрали 31 день. «ID» – ID клиента – физического лица, «Сумма» – сумма транзакции и «Отклик» – бинарная переменная, принимающая значение 0, если операция не является подозритель-

ной и значение 1, если операция является подозрительной. Подозрительными мы кодировали следующие операции: сумма транзакции превышает 100 тысяч рублей; в течение одного дня производится десять или более операций от одного и того же ID. Исходный датасет разделяется на тестовую и тренировочную выборку в соотношении 95×5. Таким, образом, нейросеть обучается на 9500 транзакциях и тестируется на 500 транзакциях. Далее, для распознавания подозрительных операций конструируем искусственную нейронную сеть. Простейшей нейросетью для решения задачи бинарной классификации является полносвязная нейронная сеть с двумя плотными слоями. Ее конструкция в Keras выглядит следующим образом [6].

1. Первый слой Dense – плотный слой. Количество входных нейронов в нем равно количеству признаков (в нашем случае 3). Также задается функция активации (для нашей задачи бинарной классификации это Sigmoid) и количество выходных нейронов.

2. Выходной слой Dense – плотный слой. Количество выходных нейронов равно 1, так как он выдает одно число от нуля до единицы по каждому образцу. Активационная функция также Sigmoid.

3. Функция потерь – функция разниц между фактическими и прогнозными результатами, которая минимизируется в процессе обучения. Для бинарной классификации задается функция бинарной кросс-энтропии.

4. Batch Size – количество образцов в пакете, по достижении которого пересчитываются веса.

5. Оптимизатор – метод минимизации функции потерь.

$$Precision = \frac{TP}{TP+FP}, Recall = \frac{TP}{TP+FN}, Accuracy = \frac{TP+TN}{TP+FP+TN+FN}, \quad (2)$$

где TP – количество откликов, которые алгоритм отнес к положительным, и при этом они действительно положительные, FP – количество откликов, которые алгоритм отнес к положительным, и при этом они отрицательные, TN – количество откликов, которые алгоритм отнес к отрицательным, и при этом они действительно отрицательные, FN – количество откликов, которые алгоритм отнес к отрицательным, и при этом они действительно положительные [7].

6. Количество эпох – количество «прогонов» обратного распространения ошибки.

Последние три пункта задаются эвристически, выбираются такие параметры, при которых функция потерь минимальна. На выходе мы получаем вектор размерностью 500*1 из чисел, принимающих значение от нуля до единицы. Если выход больше либо равен 0,5 мы округляем отклик до 1, иначе – до 0. Для оценки точности предсказаний нейронной сети необходимо сравнить полученные результаты с фактическими откликами. Для этого используем метрики Precision, Recall и Accuracy.

Нам важно не пропустить подозрительные операции, поэтому наиболее важной для нас является метрика Recall. Результаты работы алгоритма представлены в таблице 1.

Таблица 1

Метрики работы полносвязной нейронной сети
Table 1. Fully connected neural network performance metrics

Метрика	Precision	Recall	Accuracy
Значение	100%	16%	83%

Метрики Precision и Accuracy выглядят хорошо, однако наиболее важная (поскольку она определяет долю выявленных подозрительных операций среди их общего количества) метрика Recall показывает неприемлемые результаты. Это связано с тем, что полносвязная нейронная сеть хорошо определяет только транзакции, сумма которых превышает 100000 рублей. По этой причине метрика Precision стопроцентна – все сделки, которые нейросеть распознала как подозрительные, действительно подозрительны, так как превышают 100000 рублей. Что касается второго критерия – повторяющиеся транзакции от одного и того же клиента, то полносвязная нейронная сеть рассматривает образцы по одному, не запоминая последовательности образцов. Таким образом, полносвязная нейронная сеть неприемлема для поставленных задач.

Для выявления последовательных транзакций от одного и того же клиента используем рекуррентную нейронную сеть. Мы сконструировали рекуррентную нейронную сеть по алгоритму, описанному в предыдущем разделе. Параметры, такие как количество эпох и размер пакета, мы

подбирали, исходя из минимальной ошибки, а в качестве функции потерь выбрали Binary Focal Crossentropy – специальную функцию для сложных исходных данных [8]. Рекуррентная нейронная сеть состоит из непосредственно рекуррентного слоя (SimpleRNN), слоя Flatten, который приводит выходные данные из первого слоя к одномерному виду и выходного Dense слоя.

В рекуррентной сети предиктором выступает массив размерностью «образцы» × «временные интервалы» × «признаки». Количество периодов соответствует длине прогнозного периода.

В качестве количества образцов берется изначальное количество образцов – 10000 минус количество периодов. Мы задали в качестве прогнозного периода 500, признаков, включая отклики в нашем датасете 4, соответственно входной массив для рекуррентной нейронной сети имеет размерность 9500*500*4. Выходные данные аналогичны выходным данным полносвязной нейронной сети [9].

Оценка работы рекуррентной нейронной сети по метрикам Precision, Recall и Accuracy показана в таблице 2.

Метрики работы рекуррентной нейронной сети
Table 2. Metrics for the operation of a recurrent neural network

Метрика	Precision	Recall	Accuracy
Значение	67%	73%	84%

Как видно из таблицы 2, результаты работы рекуррентной нейронной сети более равномерны и вполне приемлемы. Однако, ошибка возникает там, где следует распознать подозрительную сделку по первому критерию. Отсюда следует вывод о том, что при задачи выявления подозрительных транзакций по одной следует использовать полносвязную нейросеть, а при анализе последовательности транзакций – рекуррентную [10-14].

ЗАКЛЮЧЕНИЕ

В работе было проанализированы возможности использования искусственных нейронных сетей при определении подозрительных банковских транзакций. Для обучения нейронной сети нами был сгенерирован датасет из 10000 наблюдений и 4 признаков. Подозрительными обозначались

сделки на сумму более 100 тысяч рублей и сделки, производимые одним и тем же лицом последовательно в течение дня. Нами было сконструировано две нейронные сети: основанная на полносвязном слое, типичная для задачи классификации и основанная на рекуррентном слое. Полносвязная нейронная сеть распознала только транзакции, соответствующие первому критерию, а рекуррентная только транзакции, соответствующие второму. При этом результаты работы рекуррентной нейронной сети оказались приемлемыми по всем метрикам оценки.

Авторы заявляют об отсутствии конфликта интересов, требующего раскрытия в данной статье.

The authors declare the absence a conflict of interest warranting disclosure in this article.

ЛИТЕРАТУРА

1. **Просис Д.** Прикладное машинное обучение и искусственный интеллект для инженеров. Москва: TOO «Алист», 2024. 434 с.
2. **Бекетнова Ю.М.** Модели и методы решения аналитических задач финансового мониторинга Ю.М. Бекетнова, Г.О. Крылов С.Л. Ларионова. Монография. Москва: Прометей, 2018. 138 с.
3. Ahmed Sh. et al. Artificial intelligence and machine learning in finance: A bibliometric review. Research in International Business and Finance. 2022. V. 61.
4. **Яроменко Н.Н., Заруба Д.С., Унанов А.Л., Догадина Д.С.** Роль искусственного интеллекта в оценке рисков экономики России. *Вестник академии знаний*. 2024. № 3(62). С. 537-539.
5. **Вьюгин В.В.** Математические основы машинного обучения и прогнозирования. Москва: 2018. 484 с.
6. **Шоле Ф.** Глубокое обучение на Python. Санкт-Петербург: Питер, 2018. 400 с.
7. **Ланских Ю.В.** Интеллектуальный анализ данных: учеб. Пособие. Киров: ВятГУ, 2023. 240 с.
8. **Celic D.** Implementation of Machine Learning and Deep Learning in Finance. Cybersecurity and Artificial Intelligence. 2024. V. 6. P. 59-80.
9. **Миролюбова А.А., Ксенофонтова О.Л., Ворошин Д.А.** Опыт интеллектуального анализа и прогнозирования рынка акций. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством*. 2024. № 4(62). С. 55-63. DOI 10.6060/ivecofin. 2024624.702. EDN CQZLPD.
10. **Миролюбова А.А., Сяотун Я., Ксенофонтова О.Л.** Эконометрический анализ взаимосвязи ВВП Китая с макроэкономическими показателями. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством*. 2024. № 1(59). С. 61-69. DOI 10.6060/ivecofin.2024591.675. EDN TTLWVG.

REFERENCES

1. **Prosia D.** Applied Machine Learning and Artificial Intelligence for Engineers. Moscow: TOO "Alist", 2024. 434 p.
2. **Beketnova Yu. M.** Models and Methods for Solving Analytical Problems of Financial Monitoring. Yu.M. Beketnova, G.O. Krylov, S.L. Larionova. Monograph. Moscow: Prometheus, 2018. 138 p.
3. Ahmed Sh. et al. Artificial intelligence and machine learning in finance: A bibliometric review. Research in International Business and Finance. 2022. V. 61.
4. **Yaromenko N.N., Zaruba D. S., Unanov A.L., Dogadina D.S.** The Role of Artificial Intelligence in Assessing the Risks of the Russian Economy N.N. Yaromenko, D.S. Zaruba, A.L. Unanov, D.S. Dogadina . *Bulletin of the Academy of Knowledge*. 2024. N 3(62). P. 537-539.
5. **Vyugin V.V.** Mathematical Foundations of Machine Learning and Forecasting. Moscow: 2018. 484 p.
6. **Chole F.** Deep Learning in Python F. Chole. St. Petersburg: Piter, 2018. 400 p.
7. **Lanskikh Yu.V.** Intelligent Data Analysis: textbook. Kirov: Vyatka State University, 2023. 240 p.
8. **Celic D.** Implementation of Machine Learning and Deep Learning in Finance D. Celic, S. Jain Cybersecurity and Artificial Intelligence. 2024. V 6. P. 59-80.
9. **Mirolyubova A.A., Ksenofontova O.L., Voroshin D.A.** Experience in intellectual analysis and forecasting of the stock market. *Ivecofin*. 2024. N. 4(62). P. 55-63. DOI 10.6060/ivecofin. 2024 624.702. EDN CQZLPD.
10. **Mirolyubova A.A., Xiaotong Ya., Ksenofontova O.L.** Econometric analysis of the relationship between China's GNP and macroeconomic indicators. *Ivecofin* 2024. N. 1(59). P. 61-69. DOI 10.6060/ ivecofin.2024591.675. EDN TTLWVG.
11. **Shekshueva S.V., Tatyannin G.V.** The introduction of chatbots with artificial intelligence in remote banking as a way to increase the competitiveness of a commercial bank.

11. **Шекшуева С.В., Татьянин Г.В.** Внедрение чат-ботов с искусственным интеллектом в дистанционное банковское обслуживание как способ повышения конкурентоспособности коммерческого банка. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 3 (75). С. 47–51. DOI 10.6060/snt.20237503.0006.
12. **Шекшуева С.В.** Стрессоустойчивость российских коммерческих банков в условиях глобальной неопределенности. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 1 (73). С. 24–30. DOI 10.6060/snt.20237301.0003.
13. **Курникова И.В., Савин В.Э., Адулова Е.А.** Методические проблемы оценки конкурентоспособности коммерческих банков. *Современные наукоемкие технологии. Региональное приложение*. 2024. №2 (78). С.28-34.
14. **Курникова И.В., Савин В.Э., Курникова Е.В.** Роль системного и маркетингового подходов в стратегическом развитии малых городов. *Современные наукоемкие технологии. Региональное приложение*. 2024. №4 (80). С.30-37.
- Modern high technology. Regional application*. N 3 (75). P. 47-51. DOI 10.6060/snt.20237503.0006.
12. **Shekshueva S.V.** Stress tolerance of Russian commercial banks in the context of global uncertainty. *Modern high technology. Regional application*. 2023. N 1 (73). P. 24-30. DOI 10.6060/snt.20237301.0003.
13. **Kournikova I.V., Savin V.E., Adulova E.A.** Methodological problems of assessing the competitiveness of commercial banks. *Modern high technology. Regional application*. 2024. N 2 (78). P.28-34.
14. **Kournikova I.V., Savin V.E., Kournikova E.V.** The role of systemic and marketing approaches in the strategic development of small towns. *Modern high technology. Regional application*. 2024. N 4 (80). P.30-37.

Поступила в редакцию (Received): 23.03.2025
Принята к опубликованию (Accepted): 28.04.2025