

РАЗРАБОТКА МАТЕМАТИЧЕСКИХ МОДЕЛЕЙ ДЛЯ АНАЛИЗА СОСТОЯНИЯ КРЕДИТНЫХ ОРГАНИЗАЦИЙ НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

В. В. Иванов¹, Е. П. Акишина², А. С. Приказчикова³

^{1, 2} Объединенный институт ядерных исследований, Дубна, Московская обл., Россия

³ Федеральная служба по финансовому мониторингу, Москва, Россия

¹ ivanov@jinr.ru, ² eakishina@mail.ru, ³ aska4.92@mail.ru

Аннотация. *Актуальность и цели.* Предметом настоящего исследования являются разработка и оптимизация математических моделей для анализа финансового состояния кредитных организаций на основе искусственных нейронных сетей. Актуальность исследования обусловливается необходимостью внедрения современных вычислительных технологий, с использованием которых Банк России сможет превентивно реагировать на возможные риски в банковской сфере. *Материалы и методы.* В рамках исследования развит новый подход для анализа и оценки деятельности кредитных организаций на основе искусственных нейронных сетей. Проведен анализ состава показателей с использованием матрицы коэффициентов корреляций Пирсона и метода главных компонент. Удалось сократить объем выборки, подаваемой на вход нейронной сети, сохранив при этом качество моделей на высоком уровне. *Результаты.* В результате проведенного исследования разработаны модели нейронных сетей, с помощью которых возможно идентифицировать высокорисковые кредитные организации. *Выводы.* Разработка новых математических моделей, методов и алгоритмов для анализа деятельности кредитных организаций позволит своевременно реагировать на возможные риски экономической безопасности страны и прогнозировать финансовое состояние отдельных ее звеньев.

Ключевые слова: Банк России, кредитные организации, нейросеть, корреляционный анализ, метод главных компонент

Для цитирования: Иванов В. В., Акишина Е. П., Приказчикова А. С. Разработка математических моделей для анализа состояния кредитных организаций на основе искусственных нейронных сетей // Модели, системы, сети в экономике, технике, природе и обществе. 2024. № 4. С. 98–107. doi: 10.21685/2227-8486-2024-4-8

MATHEMATICAL MODELS DEVELOPMENT FOR CREDIT ORGANIZATIONS STATE ANALYSIS BASED ON ARTIFICIAL NEURAL NETWORKS

V.V. Ivanov¹, E.P. Akishina², A.S. Prikazchikova³

^{1, 2} Joint Institute for Nuclear Research, Dubna, Moscow region, Russia

³ Federal Service for Financial Monitoring, Moscow, Russia

¹ ivanov@jinr.ru, ² eakishina@mail.ru, ³ aska4.92@mail.ru

Abstract. *Background.* The subject of this study is the development and optimization of mathematical models for analyzing the financial condition of credit institutions based on artificial neural networks. The relevance of the study is due to the need to introduce modern

computing technologies, with the use of which the Bank of Russia will be able to preventively respond to possible risks in the banking sector. *Materials and methods.* Within the framework of the study, a new approach to analyzing and evaluating the activities of credit institutions based on artificial neural networks was developed. The analysis of the composition of indicators was carried out using the matrix of Pearson correlation coefficients and the principal component method. The authors managed to reduce the sample size fed to the input of the neural network, while maintaining the quality of the models at a high level. *Results.* As a result of the study, neural network models were developed that can be used to identify high-risk credit institutions. *Conclusions.* The development of new mathematical models, methods and algorithms for analyzing the activities of credit institutions will allow a timely response to possible risks to the country's economic security, as well as forecasting the financial condition of its individual links.

Keywords: Bank of Russia, credit institutions, neural network, correlation analysis, principal component analysis

For citation: Ivanov V.V., Akishina E.P., Prikazchikova A.S. Mathematical models development for credit organizations state analysis based on artificial neural networks. *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* = *Models, systems, networks in economics, technology, nature and society*. 2024;(4):98–107. (In Russ.). doi: 10.21685/2227-8486-2024-4-8

Введение

Важнейшим условием обеспечения национальной безопасности любой страны является стабильность ее экономической системы. Одним из основных звеньев такой системы являются кредитные организации. В целях превентивного реагирования на возможные риски в банковской сфере представляется целесообразным провести работы по развитию новых моделей для оценки и прогнозирования финансового состояния той или иной организации.

Ранее авторами рассматривалась практическая задача идентификации высокорисковых кредитных организаций с использованием многомерного статистического анализа [1]. По результатам проведенных исследований была разработана вычислительная схема, позволившая обеспечить прогнозирование попадания кредитных организаций в зону риска. В работе [2] предложен новый подход к оценке финансовой безопасности кредитных организаций. Методом главных компонент найден интегральный показатель, значения которого соответствуют индексу вовлеченности кредитных организаций в отмывание доходов. В статье [3] проведен анализ причин отзывов лицензий у российских банков, а также представлен перечень факторов, сопутствующих повышению или понижению вероятности отзыва лицензий по той или иной причине. Однако все перечисленные решения не позволяют выявлять нелинейные связи, которые присущи реальным экономическим явлениям, в связи с чем возникает необходимость в переходе к более сложным нелинейным методам обработки данных – нейронным сетям.

За последние несколько лет на основе нейронных сетей были разработаны многочисленные модели, позволяющие оценить и спрогнозировать микро- и макроэкономические показатели. Так, авторами работы [4] была разработана нейронная сеть для оценки финансового состояния компаний реального сектора экономики. Исследования [5] посвящены вопросам проектирования архитектур нейронных сетей, решающих задачу кредитного скоринга. В работе [6] представлены результаты прогнозирования российской инфляции при помощи нейронных сетей и метода опорных векторов.

Целью настоящей работы является развитие новых математических моделей для анализа финансового состояния кредитных организаций. Для достижения указанной цели авторами была поставлена задача проведения классификации организаций с помощью современных технологий математического моделирования – искусственных нейронных сетей (ИНС). В качестве объекта исследования выбрано финансовое состояние кредитных организаций, а также показатели их деятельности из стандартной формы банковской отчетности № 101. Выборка данных информационной системы СПАРК [7] содержала 23 показателя о 536 организациях, из которых 202 – неблагонадежные – организации с отозванной лицензией. Для неблагонадежных организаций показатели брались за три месяца до даты отзыва у них лицензии, для благонадежных организаций (действующих на сегодняшний день) использовались данные на 31 января 2019 г. Используемые показатели:

1. Население региона регистрации банка.
2. Уставный капитал.
3. Чистые активы.
4. Счета в Банке России.
5. Коррсчета (НОСТРО).
6. Ценные бумаги.
7. Кредиты (общий показатель).
8. Кредиты организациям.
9. Средства организаций на расчетных счетах.
10. Вклады физических лиц.
11. Векселя.
12. Капитал.
13. Кредиты физическим лицам.
14. Кредиты другим банкам (МБК).
15. Основные средства.
16. Учтенные векселя.
17. Прибыль (убыток) до налогообложения.
18. Коррсчета (ЛОРО).
19. Кредиты других банков.
20. Средства клиентов (физлица).
21. Депозиты юридических лиц.
22. Облигации.
23. Резервы на возможные потери.

Применение нейронной сети к исходным данным

Искусственные нейронные сети широко и успешно применяются во многих задачах науки, техники, экономики и бизнеса, связанных с анализом и обработкой данных. Первым шагом построения модели нейронной сети является определение ее архитектуры. В текущей задаче в качестве модели ИНС использовался многослойный перцептрон (МСП). В теории одного скрытого слоя в МСП достаточно для аппроксимации любой непрерывной функции. Однако на практике для аппроксимации таких сложных данных, как в нашем случае, лучший результат дает МСП с двумя скрытыми слоями. Анализируемые данные подаются на входные нейроны, число этих нейронов определяется объемом исходной выборки. На вход сети подавалась выборка, включающая

23 показателя финансовой деятельности кредитных организаций. Число нейронов скрытых слоев подбиралось исходя из результатов обучения сети с помощью алгоритма обратного распространения ошибок.

В ходе вычислительного эксперимента в Python [8], который проводился с использованием популярных библиотек машинного обучения TensorFlow [9] и Keras [10], рассматривались модели нейронных сетей типа Sequential – линейный стек слоев, где каждый слой следует за предыдущим. Предварительно для улучшения результатов работы нейронной сети исходные данные были стандартизированы. Анализировались модели с разным количеством скрытых слоев, количеством нейронов на них. На всех слоях, кроме последнего, использовалась активационная функция – ReLU, которая работает по принципу: если входное значение x положительное, функция возвращает это значение, а если x отрицательное, то функция возвращает 0. На последнем слое нейронной сети использовалась активационная функция – сигмоида, которая применяется для решения задач бинарной классификации, где требуется получить вероятности принадлежности к одному из классов. Кроме того, авторами были протестированы нейронные сети с использованием разных методов оптимизации, представленных в библиотеке Keras. В качестве функции потерь выбрана функция бинарной кросс-энтропии, широко используемая для задач бинарной классификации.

Для решения проблемы переобучения в нейронных сетях применялся метод dropout («метод прореживания», «метод исключения») [11]. Метод позволяет создавать модели ИНС посредством исключения из сети нейронов с вероятностью p . Исключенные нейроны не вносят свой вклад в процесс обучения ни на одном из этапов алгоритма обратного распространения ошибки и возвращают на выходе 0.

Анализ результатов исследования показал, что архитектура ИНС вида 23-20-10-1 (23 входных нейрона, 20 и 10 нейронов в скрытых слоях и 1 выходной нейрон) при выборе метода оптимизации Adam и скорости обучения, равной 0,001, дает максимальную точность модели – 79 %. Указанная точность классификации Ассигасу рассчитывалась по формуле

$$\text{Assurasy} = \frac{K}{G}, \quad (1)$$

где K – количество правильно классифицированных объектов; G – общее количество объектов в выборке [12].

Применение нейронной сети к некоррелированным данным

Известно, что явление мультиколлинеарности негативно влияет на значения параметров моделей машинного обучения. Для исследования исходных данных была сформирована матрица коэффициентов корреляций Пирсона [13], которая позволяет установить наличие линейной зависимости переменных. Анализ матрицы выявил сильную связь отдельных показателей (коэффициент корреляции более 0,8); такие показатели были исключены из дальнейшего рассмотрения. На основе отобранных показателей («Население региона», «Уставный капитал», «Коррсчета (НОСТРО)», «Кредиты», «Учтенные векселя», «Прибыль до налогообложения», «Коррсчета (ЛОРО)», «Кредиты других банков», «Средства клиентов», «Капитал», «Счета в Банке России», «Ценные бумаги») была построена модель ИНС с точностью 77 % при выборе архитектуры 12-10-5-1 и метода оптимизации Adam.

Применение нейронных сетей к главным компонентам

Следующим этапом настоящего исследования стало применение метода главных компонент (МГК) к данным о кредитных организациях для последующего использования результатов МГК в моделях ИНС. МГК – это метод уменьшения размерности, что достигается путем линейного преобразования исходных данных в новую систему координат, которую образуют главные компоненты, таким образом, чтобы можно было установить направления, отражающие наибольшее изменение данных [14].

В результате применения МГК к 23 исходным показателям сгенерированы 23 главные компоненты. Анализ вклада компонент в общую дисперсию показал, что наибольший вклад дает первая главная компонента, а начиная с 12 компоненты вклад остальных незначителен, исходя из чего использовались первые 12 главных компонент, совокупная дисперсия которых составила 95 %. Анализ нейронной сети, построенной на первых 12 главных компонентах, показал наивысшую точность модели ИНС 76 % при выборе архитектуры 12-10-5-1 и метода оптимизации RMSprop.

Показатели качества модели нейронной сети

Для оценки качества классификации рассмотрим метрики Precision, Recall, F1, AUC (2-5) [12]. Для этих целей используем матрицу ошибок (табл. 1) [15], где TP – количество верноположительных результатов, TN – количество верноотрицательных результатов, FP – количество ложноположительных результатов, FN – количество ложноотрицательных результатов.

Таблица 1

Матрица ошибок классификации кредитных организаций

		Фактические данные	
		Надежный банк	Неблагонадежный банк
Прогнозные данные	Надежный банк	TP	FP
	Неблагонадежный банк	FN	TN

Имеем

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (3)$$

$$F1 = \frac{2}{\frac{1}{\text{Recall}} + \frac{1}{\text{Precision}}} = 2 \frac{\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} = \frac{TP}{TP + \frac{FP + FN}{2}}, \quad (4)$$

$$\text{AUC} = \frac{1 + \text{Recall} - \frac{FP}{TN + FP}}{2}, \quad (5)$$

где Precision – точность или доля правильно классифицированных объектов класса А/Б среди всех наблюдений, отнесенных алгоритмом к классу А/Б; Recall – полнота или оценка способности алгоритма распознать объекты класса А/Б, где класс А – класс благонадежных организаций, класс Б – класс неблагонадежных организаций; $F1$ – среднее гармоническое пары Precision-Recall; AUC – метрика, которая позволяет оценить эффективность модели бинарной классификации одной величиной – площадью под ROC-кривой [2].

Результаты

Рассмотрим полученные результаты классификации кредитных организаций с использованием моделей ИНС. В табл. 2–4 представлены матрицы ошибок для моделей ИНС на исходных данных, на некоррелированных показателях и на главных компонентах соответственно.

Таблица 2

Матрица ошибок модели ИНС на исходных данных

	Надежный	Неблагонадежный
Надежный	293	41
Неблагонадежный	74	128

Таблица 3

Матрица ошибок модели ИНС на некоррелированных данных

	Надежный	Неблагонадежный
Надежный	288	45
Неблагонадежный	77	126

Таблица 4

Матрица ошибок модели ИНС на главных компонентах

	Надежный	Неблагонадежный
Надежный	287	46
Неблагонадежный	80	123

В табл. 5 представлены значения метрик качества моделей нейронной сети для разных типов данных, где «0» – класс благонадежных объектов, «1» – класс неблагонадежных объектов.

Таблица 5

Метрики качества моделей ИНС

Метрика качества	Модель нейронной сети					
	на исходных данных		на некоррелированных показателях		на главных компонентах	
	0	1	0	1	0	1
Precision	80 %	77 %	72 %	68 %	75 %	72 %
Recall	89 %	62 %	82 %	68 %	79 %	61 %
F1-мера	84 %	69 %	77 %	69 %	78 %	69 %
AUC	86 %		77 %		74 %	
Accuracy	79 %		77 %		76 %	

Из табл. 5 видно, что полученные модели имеют высокие значения метрик качества, а значит, могут быть применены для решения практических задач и использоваться для финансового мониторинга кредитных организаций.

На рис. 2–4 представлены графики динамики показателя точности построенных моделей нейронной сети на каждой эпохе (всего 100 эпох) для обучающей и тестовой выборок.




Рис. 2. Динамика показателя точности модели ИНС на исходных данных




Рис. 3. Динамика показателя точности модели ИНС на некоррелированных показателях




Рис. 4. Динамика показателя точности модели ИНС на главных компонентах

Обсуждение

В работе [2] автор использовал модель двухклассовой нейронной сети для решения задачи обнаружения банков, вовлеченных в отмывание денежных средств. При этом метрики качества полученной модели анализа данных оказались следующими: Accuracy = 78 %, AUC = 89 %.

Для разработанной нами модели ИНС, построенной на исходных данных, Accuracy = 79 %, AUC = 86 %. Однако важно, что автор работы [2] на этапе формирования обучающей выборки рассматривал только одну причину отзыва банковской лицензии, в отличие от текущей работы, где авторы задействовали весь спектр причин. Таким образом, результаты, полученные в настоящей статье, обладают более весомой практической значимостью и полнотой исследования по сравнению с результатами, приведенными в работе [2].

Заключение

Авторами развит новый подход для анализа финансового состояния кредитных организаций на основе искусственных нейронных сетей, а также произведена оценка качества моделей ИНС, реализованных на различных типах данных (исходные данные, данные после применения к ним корреляционного анализа, данные после применения к ним метода главных компонент). Точность модели ИНС, построенной на исходных данных, составила 79 %; для некоррелированных показателей – 77 %; для главных компонент – 76 %. Исходя из вышесказанного, можно заключить, что разработанные модели ИНС целесообразно применять для идентификации высокорисковых кредитных организаций.

Отметим также, что с использованием корреляционного анализа и метода главных компонент авторам удалось уменьшить количество анализируемых показателей формы банковской отчетности № 101. В свою очередь, это дает возможность существенно сократить объемы информации для хранения в базах данных Банка России и Росфинмониторинга, задействовать меньше ресурсов и оборудования, повысить работоспособность и оперативность информационных систем контролирующих ведомств России.

Список литературы

1. Акишина Е. П., Иванов В. В., Крянев А. В., Приказчикова А. С. Многомерный анализ данных в задаче прогнозирования попадания кредитных организаций в зону риска // Вестник НИЯУ МИФИ. 2024. № 13 (1). С. 22–29. doi: 10.26583/vestnik.2024.302 EDN: HUDHFW
2. Бекетнова Ю. М. Методология анализа данных в сфере противодействия отмыванию доходов : дис. ... д-ра эконом. наук. М., 2022. 305 с.
3. Зубарев А. В., Шилов К. Д. Дифференциация факторов банковских дефолтов по причинам отзыва лицензий // Экономический журнал ВШЭ. 2022. № 26 (1). С. 69–103.
4. Болотов Р. О., Суглобов А. Е. О применении нейронных сетей для оценки финансовой устойчивости компаний // Russian journal of management. 2020. № 1 (8). С. 106–110.
5. Кадиев А. Д., Чибисова А. В. Нейросетевые методы решения задачи кредитного скоринга // Математическое моделирование и численные методы. 2022. № 4 (36). С. 81–92.
6. Павлов Е. Прогнозирование инфляции в России с помощью нейронных сетей // Деньги и кредит. 2020. № 1. С. 57–73.
7. СПАРК-Интерфакс : официальный сайт. URL: <https://group.interfax.ru> (дата обращения: 31.07.2024).
8. Python. URL: <https://www.python.org> (дата обращения: 19.03.2024).
9. TensorFlow. URL: <https://www.tensorflow.org/?hl=ru> (дата обращения: 21.03.2024).
10. Keras. URL: <https://keras.io> (дата обращения: 21.03.2024).
11. Molchanov D., Ashukha A., Vetrov D. Variational dropout sparsifies deep neural networks // Proceedings of the 34th International Conference on Machine Learning, ICML. 2017.
12. Tharwat A. Classification assessment methods // Applied Computing and Informatics. 2020. Vol. 17, iss. 1. P. 30.
13. Coscia M. Pearson correlations on complex networks // Journal of Complex Networks. 2021. Vol. 9 (6).
14. Андрукович П. Ф. Некоторые свойства метода главных компонент. Многомерный статистический анализ в социально-экономических исследованиях. М. : Наука, 1974. 228 с.

15. Паклин Н. Б., Орешков В. И. Бизнес-аналитика: от данных к знаниям : учеб. пособие. 2-е изд., испр. СПб. : Питер, 2013. 704 с.

References

1. Akishina E.P., Ivanov V.V., Kryanev A.V., Prikazchikova A.S. Multidimensional data analysis in predicting credit institutions' exposure to risk. *Vestnik NIYaU MIFI = Bulletin of the National Research Nuclear University MEPhI*. 2024;(13):22–29. (In Russ.). doi: 10.26583/vestnik.2024.302 EDN: HUDHFW
2. Beketnova Yu.M. *Methodology of data analysis in the field of combating money laundering*. DSc dissertation. Moscow, 2022:305. (In Russ.)
3. Zubarev A.V., Shilov K.D. Differentiation of bank default factors due to license revocation. *Ekonomicheskiy zhurnal VShE = Economic Journal of the Higher School of Economics*. 2022;(26):69–103. (In Russ.)
4. Bolotov R.O., Suglobov A.E. On the use of neural networks to assess the financial stability of companies. *Russian journal of management = Russian journal of management*. 2020;(1):106–110. (In Russ.)
5. Kadiev A.D., Chibisova A.V. Neural network methods for solving the problem of credit scoring. *Matematicheskoe modelirovanie i chislennyye metody = Mathematical modeling and numerical methods*. 2022;(4):81–92. (In Russ.)
6. Pavlov E. Forecasting inflation in Russia using neural networks. *Den'gi i kredit = Money and Credit*. 2020;(1):57–73. (In Russ.)
7. *SPARK-Interfaks: ofitsial'nyy sayt = SPARK-Interfax : official website*. (In Russ.). Available at: <https://group.interfax.ru> (accessed 31.07.2024).
8. *Python*. Available at: <https://www.python.org> (accessed 19.03.2024).
9. *TensorFlow*. Available at: <https://www.tensorflow.org/?hl=ru> (accessed 21.03.2024).
10. *Keras*. Available at: <https://keras.io> (accessed 21.03.2024).
11. Molchanov D., Ashukha A., Vetrov D. Variational dropout sparsifies deep neural networks. *Proceedings of the 34th International Conference on Machine Learning, ICML*. 2017.
12. Tharwat A. Classification assessment methods. *Applied Computing and Informatics*. 2020;17(1):30.
13. Coscia M. Pearson correlations on complex networks. *Journal of Complex Networks*. 2021;9(6).
14. Andrukovich P.F. *Nekotorye svoystva metoda glavnykh komponent. Mnogomernyy statisticheskiy analiz v sotsial'no-ekonomicheskikh issledovaniyakh = Some properties of the principal component method. Multidimensional statistical analysis in socio-economic research*. Moscow: Nauka, 1974:228. (In Russ.)
15. Paklin N.B., Oreshkov V.I. *Biznes-analitika: ot dannyykh k znaniyam: ucheb. posobie. 2-e izd., ispr. = Business analytics: from data to knowledge : a textbook. 2nd ed., rev.* Saint Petersburg: Piter, 2013:704. (In Russ.)

Информация об авторах / Information about the authors

Виктор Владимирович Иванов
доктор физико-математических наук,
профессор, главный научный сотрудник
лаборатории информационных
технологий имени М. Г. Мещерякова,
Объединенный институт ядерных
исследований
(Россия, Московская обл., г. Дубна,
ул. Жолио-Кюри, 6)
E-mail: ivanov@jinr.ru

Victor V. Ivanov
Doctor of physical and mathematical
sciences, professor, chief researcher
of Laboratory of Information
Technologies named after
M.G. Meshcheryakov,
Joint Institute for Nuclear Research
(6 Joliot-Curie street, Dubna, Moscow
region, Russia)

Елена Павловна Акишина

кандидат физико-математических наук,
старший научный сотрудник
лаборатории информационных
технологий имени М. Г. Мещерякова,
Объединенный институт ядерных
исследований
(Россия, Московская обл., г. Дубна,
ул. Жолио-Кюри, 6)
E-mail: eakishina@mail.ru

Elena P. Akishina

Candidate of physical and mathematical
sciences, senior researcher
of Laboratory of Information
Technologies named after
M.G. Meshcheryakov,
Joint Institute for Nuclear Research
(6 Joliot-Curie street, Dubna, Moscow
region, Russia)

Анастасия Сергеевна Приказчикова

консультант Управления развития
информационных технологий
финансового мониторинга,
Федеральная служба по финансовому
мониторингу
(Россия, г. Москва, ул. Мясницкая, 39, стр. 1)
E-mail: aska4.92@mail.ru

Anastasia S. Prikazchikova

Consultant of Department of Information
Technologies Development of Financial
Monitoring,
Federal Service for Financial Monitoring
(build. 1, 39 Myasnitskaya street,
Moscow, Russia)

**Авторы заявляют об отсутствии конфликта интересов /
The authors declare no conflicts of interests.**

Поступила в редакцию/Received 06.09.2024

Поступила после рецензирования/Revised 14.11.2024

Принята к публикации/Accepted 17.12.2024