

# СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В ОБЛАСТИ КРЕДИТОВАНИЯ НА ОСНОВЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ

Статья посвящена разработке нейросетевой модели кредитного скоринга физических лиц, направленной на обеспечение достоверности информации о платёжеспособности заёмщиков в условиях неполных или потенциально искажённых данных. Предметом исследования выступают методы построения нейросетевых моделей для кредитного скоринга, ориентированные на обработку и анализ данных заемщиков. Целью работы является разработка и оптимизация нейросетевой архитектуры, способной получить наивероятнейший прогноз исполнения кредитных обязательств и сформировать рекомендации по выдаче кредита. Прогнозирование осуществляется на основе обработки информации о наборе признаков заемщика. В набор входит стандартная информация о заемщике, такая как объем доходов, кредитная история, а также информация о недавней активности заемщика, отраженных в открытых источниках. В качестве объекта исследования использованы данные из реальных кредитных заявок. На основе данных построена и оптимизирована полносвязная нейронная сеть с тремя скрытыми слоями, функцией активации ReLU в промежуточных слоях и сигмоидной функцией на выходе. Обучение осуществлялось с использованием оптимизатора Adam и регуляризации Dropout для предотвращения переобучения и повышения устойчивости модели к шуму и аномалиям во входных данных. Экспериментальная валидация и сравнительный анализ с классическими методами машинного обучения подтвердил превосходство нейросети, демонстрируя лучшую устойчивость к целенаправленным искажениям входных данных. Результаты исследования подтверждают высокую надежность глубокого обучения в условиях несбалансированных данных и сложных нелинейных зависимостей, а также его практическую применимость для внедрения в автоматизированные системы кредитного скоринга финансовых организаций.

**Ключевые слова:** нейронные сети, кредитный скоринг, анализ данных, оценка метода, устойчивость к манипуляциям, принятие решений.

# A DECISION SUPPORT SYSTEM IN THE FIELD OF LENDING BASED ON A NEURAL NETWORK MODEL

*The article is devoted to the development of a neural network model of credit scoring of individuals aimed at improving the accuracy, reliability and stability of forecasting borrowers' solvency in conditions of unreliable, incomplete or potentially distorted data. The subject of the research is the methods of building neural network models for credit scoring, focused on the processing and analysis of borrowers' data. The aim of the work is to develop and optimize a neural network architecture capable of reliably assessing the probability of fulfilling credit obligations based on a comprehensive set of features, including both traditional and behavioral sources of information that are resistant to manipulation. The data from real loan applications was used as the object of the study. Based on the data, a fully connected neural network with three hidden layers, a ReLU activation function in the intermediate layers and a sigmoid function at the output was built and optimized. The training was carried out using the Adam optimizer and Dropout regularization to prevent overfitting and increase the model's resilience to noise and anomalies in the input data. Experimental validation and comparative analysis with classical machine learning methods have confirmed the superiority of the neural network, demonstrating better resistance to targeted distortion of input data. The results of the study confirm the high reliability of deep learning in conditions of unbalanced data and complex nonlinear dependencies, as well as its practical applicability for implementation in automated credit scoring systems of financial organizations.*

**Keywords:** neural networks, credit scoring, data analysis, method evaluation, resistance to manipulation, decision making.

## Введение

Существенным фактором, угрожающим финансовой безопасности как отдельных институтов, так и экономики в целом, является рост за кредитованности населения и корпоративного сектора на фоне увеличения неопределенности в поведении заемщиков. В условиях стремительной цифровизации финансовых потоков и экспоненциального роста объема циркулирующих данных традиционные статистические и экспертные методы оценки кредитных рисков все чаще оказываются неспособными обеспечить надежную защиту от дефолтов, особенно при работе с неполной, зашумленной или намеренно искаженной информацией, что создаёт предпосылки для ошибочных решений и повышает уязвимость финансовых институтов к мошенническим действиям. [1-8]. В этом контексте системы кредитного скоринга, направленные на анализ широкого спектра параметров заемщика и прогнозирующего вероятность

своевременного погашения долга, приобретают особую значимость, выступая ключевым инструментом объективной оценки индекса надежности заемщиков, что в конечном итоге приводит к существенному снижению рисков, связанных с достоверностью кредитоспособности [9-12].

Применение нейронных сетей в кредитном скоринге способно учитывать сложные нелинейные зависимости и выявлять скрытые паттерны в поведении заемщиков, что позволяет решать проблему надежности и устойчивости моделей кредитного скоринга на качественно новом уровне. Среди работ, связанных с этим направлением исследований отметим работу Д. В. Исаева [13] в которой применяются рекуррентные нейронные сети, обученные на данных карточных транзакций. Принципиальной особенностью данного подхода является отказ от традиционных анкетных признаков в пользу поведенческих характеристик, формируемых автоматиче-

чески. Такой подход потенциально снижает уязвимость скоринговой модели к искажению самоотчётных данных и демонстрирует перспективность использования альтернативных источников информации для повышения надёжности оценки кредитоспособности, особенно в сегменте заёмщиков с ограниченной кредитной историей. Другим примером является работа В. С. Чуба, в которой для решения задачи кредитного скоринга применялся оптимизированный многослойный перцептрон на основе традиционных финансово-демографических признаков. Полученные результаты подтверждают высокую эффективность нейросетевых моделей по сравнению с классическими методами машинного обучения. Вместе с тем использование преимущественно анкетных данных повышает чувствительность моделей к их качеству и достоверности, что в реальных условиях может создавать дополнительные риски при намеренном искажении входной информации.

В рассмотренных работах, в которых анализ финансового поведения заемщика осуществляется лишь в одном направлении либо на основе традиционных демографических и кредитных, либо исключительно на поведенческих транзакционных сигналах. В настоящей работе предлагается гибридный подход, объединяющий оба типа признаков, что позволяет не только повысить точность прогнозирования, но и снизить уязвимость скоринговой модели к мошенническим действиям, ошибкам самоотчёта и неполноте данных. Такой гибридный подход позволяет не только повысить точность прогноза, но и повышает надёжность автоматизированных решений в условиях потенциально манипулируемой информации.

### **Структура и предобработка исходных данных**

Исходный датасет, полученный из открытых источников, содержит данные о 1 000 реальных заемщиках с 20 параметрами. В качестве входных признаков использовались 20 характеристик, включая текущий баланс счёта, кредитную историю, сумму кредита, стаж работы, семейное положение, возраст и другие релевантные параметры, а также поведенческие и контекстуальные признаки, устойчивые к манипуляциям, – в частности, своевременная оплата коммунальных услуг или связи за последние 30 дней, наличие регулярных поступлений на счёт, отсутствие

просрочек по обязательствам за 90 дней, а также активность в официальных цифровых сервисах. Эти сигналы повышают достоверность оценки платёжеспособности, снижают уязвимость модели к искажению анкетных данных и позволяют безопасно охватывать клиентов с ограниченной кредитной историей.

Целью этапа предобработки данных является не только обеспечение устойчивости процесса обучения нейронной сети, но и снижение чувствительности модели к зашумлённым, неполным и потенциально искажённым входным данным. Для корректной валидации моделей исходная выборка случайным образом делилась на обучающую и тестовую подвыборки в соотношении 70:30, что позволило оценить обобщающую способность модели в условиях, приближённых к реальной эксплуатации скоринговых систем. Качественная оценка значимости признаков проводилась с помощью алгоритма SHAP. В результате были выделены наиболее информативные и исключены наименее надёжные переменные. С точки зрения устойчивости и безопасности скоринговой системы данный подход позволяет снизить влияние шумовых и наименее надёжных признаков, а также уменьшить «площадь атаки» модели, ограничивая возможности манипулирования результатами за счёт целевых искажений отдельных входных характеристик. После предобработки окончательный набор значимых параметров для нейронной сети составил 15 признаков. Входными данными модели является бинарная функция платёжеспособности заемщика: принимающая значение 1, что соответствует вероятности своевременного погашения кредита — то есть заемщик успешно погасил кредит в срок продемонстрировав свою платёжеспособность (надёжный заемщик), и принимающая значение 0, что соответствует риску дефолта (неплатёжеспособный заемщик).

### **Нейросетевая модель кредитного скоринга**

Предлагаемая нейронная сеть представлена следующим уравнением:

$$z^{(l)} = \sum_{i=1}^{n_l} W_i^{(l)} a_i^{(l-1)} + b_i^{(l)}, \quad a^{(l)} = g^{(l)}(z^{(l)})$$

где:

$W_i^{(l)} \in R^{n_l \times n_{l-1}}$  – веса слоя  $l$ ,

$b_i^{(l)} \in R^{n_l}$  – вектор смещения слоя  $l$ ,

$a^{(l)}$  – выходы слоя  $l$

$a_i^{(l-1)}$  – выходы предыдущего слоя  $l$ ,

$g^{(l)}$  – функция активации, используемая в слое  $l$ ,

$n_l$  – число нейронов в слое  $l$ .

$z^{(l)}$  – выход предыдущего слоя  $l$

$z^{(l-1)}$  – выход предыдущего слоя до функции активации

$l$  – количество слоев

Разработка нейронной сети сопровождалась систематической оптимизацией ее архитектуры с учётом требований информационной безопасности кредитных решений. Оптимизация заключалась в подборе количества скрытых слоев и нейронов, выборе функций активации, настройке гиперпараметров обучения, а также в применении методов регуляризации. Каждая конфигурация обучалась на

одном и том же наборе данных, включающем как традиционные признаки, так и поведенческие данные, которые менее подвержены манипуляциям и повышают достоверность оценки. Цель оптимизации заключается в повышении точности предсказаний нейронной сети на тестовой выборке, а также в обеспечении устойчивости модели к переобучению за счет минимизации значения функции потерь, что особенно важно при работе с несбалансированными данными. Оптимальная модель включает 3 скрытых слоя, такая архитектура показала наилучший баланс между точностью и стабильностью при кросс-валидации. Полученная оптимальная архитектура представлена на рис. 1.




Рис. 1. Архитектура нейронной сети

При построении более глубоких архитектур, включавшей более 3 слоев начиналось переобучение, уменьшение количества слоев приводило к уменьшению способности к извлечению сложных паттернов. Для регуляризации модели и повышения ее устойчивости к шумам в данных был применен метод Dropout. Это достигается за счет случайного отключения части нейронов на каждом шаге обучения, что предотвращает чрезмерную взаимозависимость между ними и снижает риск запоминания шумовых или специфических особенностей обучающей выборки.

#### Динамика обучения

График точности нейронной сети на этапе обучения представлен на рис. 2 и иллюстри-

рует динамику изменения метрики точности как на обучающей, так и на тестовой выборках в зависимости от количества эпох

Из результатов, представленных на рис.2 следует что после 120–130 эпох точность начинает колебаться и перестает следовать за улучшениями на обучающих данных, что указывает на начало переобучения. Наиболее оптимальная производительность на тестовой выборке достигается в диапазоне 80–100 эпох, где разница между обучением и тестированием минимальна. Зависимость значений точности от количества эпох представлена в таблице 1.

На основании результатов, представленных на таблице 1 получаем, что оптимальной




Рис. 2. График точности нейронной сети

Таблица 1

**Результаты работы нейросети на тестовой выборке**

Количество эпох	Точность
97	0.7768
98	0.7589
99	0.7679
100	0.7752
101	0.7768
102	0.7946
103	0.7768
104	0.7935
105	0.7936
106	0.7857
107	0.7768

точке баланса между обучением и обобщением достигается на 102 эпохе. После этого момента рост потерь на тестовых данных при сохранении снижения на обучающей выборке свидетельствует о начале переобучения.

**Результаты экспериментальных исследований**

С целью оценки надёжности и практической применимости разработанной нейросетевой модели в условиях реальной эксплуатации автоматизированных систем кредитного скоринга были проведены экспериментальные исследования, включающие сравнительный анализ с классическими методами машинного обучения. В качестве тестовых методов использовались методы основанные на

алгоритме дерева решений, случайного леса и наивного байесовского классификатора, применяемых для решения задачи кредитного скоринга. Оценка моделей осуществлялась по двум ключевым критериям: точности классификации на тестовой выборке, отражающей предсказательную способность модели, и коэффициенту устойчивости к целевым атакам — доле заявок, сохранивших исходный прогноз при попытке намеренного искажения входных данных, например, за счёт завышения дохода, стажа или добавления «надёжных» признаков, что напрямую характеризует робастность модели к мошенническим сценариям. Результаты работы всех рассмотренных методов предоставлены на таблице 2.

### Результаты работы методов машинного обучения

Модель	Точность классификации	Коэффициент устойчивости к целевым атакам
Дерево решений	0.707	0.832
Случайный лес	0.792	0.879
Наивный байесовский классификатор	0.732	0.715
Нейронная сеть	0.794	0.931

Сравнение точности моделей показало, что случайный лес и разработанная нейронная сеть демонстрируют наилучшие результаты среди всех протестированных подходов, существенно превосходя традиционные методы, такие как наивный байесовский классификатор и дерево решений. Это подтверждает, что предложенная нейросетевая архитектура – с тремя скрытыми слоями и регуляризацией Dropout – обеспечивает оптимальный баланс между предсказательной способностью и защитой от намеренных искажений входных данных, что делает её наиболее надёжным и практичным решением для внедрения в реальные системы кредитного скоринга, где критически важны как точность, так и безопасность принятия решений.

#### Заключение

В работе предложена полносвязная нейронная сеть для поддержки принятия решений в области кредитования, ориентированная на обеспечение безопасности и надёжности при оценке вероятности исполнения кредитных обязательств на основе комплексного набора признаков – включая как традиционные, так и поведенческие данные. Экспериментальная валидация подтвердила приемлемую точность прогнозирования даже в ус-

ловиях сложных нелинейных зависимостей. Сравнительный анализ показал, что предложенная нейросеть превосходит базовые методы машинного обучения по точности и демонстрирует устойчивость к целенаправленным искажениям входных данных. Эти результаты подтверждают практическую пригодность и безопасность разработанной модели для внедрения в автоматизированные системы кредитного скоринга финансовых организаций. В перспективе планируется расширить рамки исследования за счет разработки универсальных архитектур, способных прогнозировать финансовую стабильность не только физических лиц, но и юридических — в частности, малого и среднего бизнеса. Это позволит создать интегрированную систему оценки кредитного риска, применимую в различных сегментах финансового рынка, включая корпоративное кредитование, факторинг и инвестиционный анализ. Особое внимание будет уделено адаптации моделей под специфику бухгалтерской отчетности, макроэкономических индикаторов и отраслевых особенностей компаний, что повысит надёжность и интерпретируемость прогнозов в бизнес-среде.

#### Литература

1. Смирнов А.В., Петров Д.С. Современные подходы к оценке кредитного риска в условиях цифровой трансформации / А. В. Смирнов, Д. С. Петров // Финансы и кредит. 2020. № 24(912). С. 1120–1135.
2. Лебедев Е.А. Исследование достоверности оптимизированной модели скоринга путем прогнозирования кредитных историй заемщиков, данные которых не использовались при синтезе модели / Е. А. Лебедев // Научный журнал Кубанского государственного аграрного университета. 2007. № 34. С. 1–22.
3. Исаев Д.В. Динамическое ансамблевое обучение для оценки кредитоспособности / Д. В. Исаев // Инновации и инвестиции. 2022. № 3. С. 74–79.
4. Кадиев А.Д., Чибисова А.В. Нейросетевые методы решения задачи кредитного скоринга / А. Д. Кадиев, А. В. Чибисова // Математическое моделирование и численные методы. 2022. № 4(36). С. 81–92.
5. Глинкина Е.В. Кредитный скоринг как инструмент эффективной оценки кредитоспособности / Е. В. Глинкина // Финансы и кредит. 2011. № 16(448). С. 43–47.

6. Мельников А.А., Стельмаш Д.С., Ефимов С.Н. Разработка автоматизированной системы кредитного скоринга / А. А. Мельников, Д. С. Стельмаш, С. Н. Ефимов // Актуальные проблемы авиации и космонавтики. 2010. № 6. С. 233–234.
7. Симонов П.М., Збоев Е.В. Скоринговая оценка кредитоспособности физических лиц / П. М. Симонов, Е. В. Збоев // Вестник Дагестанского государственного университета. Серия 1: Естественные науки. 2020. Т. 35. № 2. С. 18–26.
8. Кочеткова В.В., Ефремова К.Д. Обзор методов кредитного скоринга / В. В. Кочеткова, К. Д. Ефремова // *Juvenis scientia*. 2017. № 6. С. 22–25.
9. Митрофанова К.Б. Понятие кредитного риска и факторы, на него влияющие / К. Б. Митрофанова // Молодой ученый. 2015. № 2. С. 284–288.
10. Абдуллаев Н.А. Перспективы внедрения современных технологий искусственного интеллекта в скоринговые системы / Н. А. Абдуллаев // Экономика и финансы (Узбекистан). 2023. № 1(161). С. 39–49.
11. Богданов А.Л., Дуля И.С. Применение нейронных сетей в решении задачи кредитного скоринга / А. Л. Богданов, И. С. Дуля // Вестник Томского государственного университета. Экономика. 2018. № 44. С. 173–183.
12. Костикова А.В., Сайкина Ю.А., Попова А.А. Математические и интеллектуальные методы оценки кредитной платежеспособности физических лиц / А. В. Костикова, Ю. А. Сайкина, А. А. Попова // Вестник Астраханского государственного технического университета. Серия: Экономика. 2024. № 2. С. 127–137.
13. Исаев Д.В. Оценка кредитного скоринга на основе карточных транзакций / Д. В. Исаев // Инновации и инвестиции. 2021. № 5. С. 105–109.
14. Чуб В.С. Сравнительный анализ методов машинного обучения в оценке кредитных рисков / В. С. Чуб // Образовательные ресурсы и технологии. 2023. № 3(44). С. 81–92.

## References

1. Smirnov A.V., Petrov D.S. Modern approaches to credit risk assessment in the context of digital transformation / A.V. Smirnov, D. S. Petrov // *Finance and Credit*. 2020. No. 24(912). pp. 1120-1135.
2. Lebedev E.A. Investigation of the reliability of an optimized scoring model by predicting borrowers' credit histories, the data of which were not used in the synthesis of the model / E. A. Lebedev // *Scientific Journal of the Kuban State Agrarian University*. 2007. No. 34. pp. 1-22.
3. Isaev D.V. Dynamic ensemble training for assessing creditworthiness / D. V. Isaev // *Innovations and investments*. 2022. No. 3. pp. 74-79.
4. Kadiev A.D., Chibisova A.V. Neural network methods for solving the problem of credit scoring / A.D. Kadiev, A.V. Chibisova // *Mathematical modeling and numerical methods*. 2022. No. 4(36). pp. 81-92.
5. Glinkina E.V. Credit scoring as a tool for effective assessment of creditworthiness / E. V. Glinkina // *Finance and Credit*. 2011. No. 16(448). pp. 43-47.
6. Melnikov A.A., Stelmash D.S., Efimov S.N. Development of an automated credit scoring system / A. A. Melnikov, D. S. Stelmash, S. N. Efimov // *Actual problems of aviation and cosmonautics*. 2010. No. 6. pp. 233-234.
7. Simonov P.M., Zboev E.V. Scoring assessment of the creditworthiness of individuals / P.M. Simonov, E. V. Zboev // *Bulletin of Dagestan State University. Series 1: Natural Sciences*. 2020. Vol. 35. No. 2. pp. 18-26.
8. Kochetkova V.V., Efremova K.D. Review of credit scoring methods / V. V. Kochetkova, K. D. Efremova // *Juvenis scientia*. 2017. No. 6. pp. 22-25.
9. Mitrofanova K.B. The concept of credit risk and the factors influencing it / K. B. Mitrofanova // *Young Scientist*. 2015. No. 2. pp. 284-288.
10. Abdullaev N.A. Prospects for the introduction of modern artificial intelligence technologies into scoring systems / N. A. Abdullaev // *Economics and Finance (Uzbekistan)*. 2023. No. 1(161). pp. 39-49.
11. Bogdanov A.L., Dulya I.S. Application of neural networks in solving the problem of credit scoring / A. L. Bogdanov, I. S. Dulya // *Bulletin of Tomsk State University. Economy*. 2018. No. 44. pp. 173-183.
12. Kostikova A.V., Saykina Yu.A., Popova A.A. Mathematical and intellectual methods for assessing the credit solvency of individuals / A.V. Kostikova, Yu.A. Saykina, A. A. Popova // *Bulletin of the Astrakhan State Technical University. Series: Economics*. 2024. No. 2. pp. 127-137.
13. Isaev D.V. Evaluation of credit scoring based on card transactions / D. V. Isaev // *Innovations and investments*. 2021. No. 5. pp. 105-109.
14. Chub V.S. Comparative analysis of machine learning methods in credit risk assessment / V. S. Chub // *Educational Resources and Technologies*. 2023. No. 3(44). pp. 81-92.

---

**ЩЕГОЛЕВ Александр Владимирович**, аспирант кафедры «Информационные Системы и Технологии» ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». 454080, г. Челябинск, проспект Ленина, 76. E-mail: njznew@gmail.com

**ЯПАРОВА Наталья Михайловна**, доктор технических наук, доцент, профессор кафедры «Информационные Системы и Технологии» ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». 454080, г. Челябинск, проспект Ленина, 76. E-mail: iaparovam@susu.ru

**SHCHEGOLEV Alexander Vladimirovich**, Postgraduate Student, Department of Information Systems and Technologies, Federal State Autonomous Educational Institution of Higher Education "South Ural State University (national research university)". 454080, Chelyabinsk, Lenin prospekt, 76. E-mail: njznew@gmail.com

**YAPAROVA Natalia Mikchailovna**, Dr.of Sci, Associate Professor, Department of Information Systems and Technologies, Federal State Autonomous Educational Institution of Higher Education "South Ural State University (national research university)". 454080, Chelyabinsk, Lenin prospekt, 76. E-mail: iaparovam@susu.ru