

Журнал «Мировые цивилизации» / Scientific journal «World civilizations» <https://wcj.world>

2026, Том 11, № 2 / 2026, Vol 11, Issue 2 <https://wcj.world/issue-2-2026.html>

URL статьи: <https://wcj.world/PDF/04ECMZ226.pdf>

Ссылка для цитирования этой статьи:

Федоров И.А. Применение методов машинного обучения для прогнозирования кредитных рейтингов организаций / И.А. Федоров, И.А. Киселев, С.О. Новосельский // Мировые цивилизации. — 2026. — Т. 11. — № 2. — URL: <https://wcj.world/PDF/04ECMZ226.pdf>

For citation:

Fedorov I.A., Kiselev I.A., Novoselsky S.O. Application of machine learning methods to predict credit ratings of organizations. *World civilizations*. 2026; 11(2): 04ECMZ226. Available at: <https://wcj.world/PDF/04ECMZ226.pdf>. (In Russ., abstract in Eng.)

УДК 005.5:332.1

Федоров Игорь Андреевич

Университет мировых цивилизаций им. В.В. Жириновского, Москва, Россия
аспирант

E-mail: f3dorov1gor@yandex.ru

Киселев Илья Александрович

НОЧУ ВО «Московский экономический институт», Москва
аспирант

E-mail: ze-rii@yandex.ru

Новосельский Святослав Олегович

Университет мировых цивилизаций им. В.В. Жириновского, Москва, Россия
НОЧУ ВО «Московский экономический институт», Москва
доцент

кандидат экономических наук

E-mail: nsvyatoslav@yandex.ru

Применение методов машинного обучения для прогнозирования кредитных рейтингов организаций

Аннотация. В статье рассматриваются актуальные сферы применения кредитного рейтинга, существующие подходы к присвоению кредитного рейтинга организации, недостатки классического подхода, а также перспективы и возможности применения методов машинного обучения и искусственного интеллекта в задаче присвоения кредитного рейтинга компании. Рассматриваются возможные преимущества нового подхода решения задачи при помощи машинного обучения. Задачу предлагается решать с помощью методов случайного леса и метода искусственной нейронной сети. По результатам обучения на тестовом объеме данных измеряются метрики качества обучения и делаются выводы о возможностях применения данных методов и потенциальном их улучшении. алгоритм случайного леса показал более высокие результаты практически по всем ключевым показателям, характеризующим качество модели, по сравнению с полносвязной нейронной сетью, несмотря на то что является более простым в реализации. Помимо количественных характеристик, важным преимуществом случайного леса стала скорость как обучения модели, так и предсказаний. Таким образом, случайный лес оказался более оптимальным методов машинного обучения для решения поставленной задачи.

Ключевые слова: кредитный рейтинг; машинное обучение; нейронные сети; алгоритм случайного леса; анализ больших данных

Введение. Кредитный рейтинг — это мнение рейтингового агентства относительно общей кредитоспособности заемщика или кредитоспособности заемщика в отношении конкретных долговых обязательств, основанное на оценке факторов риска.

Кредитные рейтинги являются важным инструментом для всесторонней оценки текущего и финансового состояния экономических субъектов, а также для его прогнозирования. Эти рейтинги способствуют привлечению необходимого капитала, позволяют эффективно управлять возникающими финансовыми рисками и повышают уровень взаимного доверия среди участников рынка. Кредитные рейтинги формируются на основании глубокого анализа прошлых и текущих результатов финансовой деятельности предприятий, учета их совокупных активов и уровня задолженности перед кредиторами.

Рейтинговые шкалы чаще всего представлены системой буквенно-числового обозначения (от наивысшего класса AAA до низкого D), где наиболее высокие уровни символизируют низкий риск невыплаты обязательств, тогда как низкие рейтинги сигнализируют о значительных вероятностях нарушения условий договора. Эта система помогает кредиторам и инвесторам получать ясное понимание текущего состояния надежности компании и способствует принятию взвешенных инвестиционных решений.

Основной целью присвоения кредитного рейтинга является предоставление объективной информации потенциальным инвесторам относительно вероятности своевременного погашения заемщиками взятых ими обязательств в установленный срок. Это позволяет кредиторам точнее оценивать риски невозврата займов, формирует основу для принятия взвешенных решений об инвестициях, снижает неопределенность на рынке капиталов [1].

За последние годы спектр применения кредитных рейтингов заметно увеличился. Теперь они используются далеко за пределами банковской сферы: страховые компании применяют их для обоснования размера премии по договорам страхования, арендодатели учитывают рейтинги при установлении условий договора аренды недвижимости, а некоторые организации начинают учитывать финансовую репутацию соискателей при принятии кадровых решений, рассматривая кредитный рейтинг как показатель общей ответственности кандидата. Таким образом, значение кредитных рейтингов выходит далеко за рамки исключительно банковских операций, охватывая широкий круг отраслей экономики и сфер общественной жизни.

При оценке кредитного рейтинга организации в рассмотрение, как правило, берутся следующие факторы: репутация и история компании; рыночные условия; политические и макроэкономические условия; операционные риски компании; нормативно-правовые риски; стратегия и перспективы развития компании.

У классических методов определения кредитных рейтингов существует ряд недостатков:

1. Большая продолжительность оценки. Вынесение окончательного вердикта по кредитному скорингу может выноситься довольно долго – около полугода. Для новых небольших компаний или компаний, которые производят инновационные продукты, это может быть серьезной проблемой при поиске дополнительного финансирования.

2. Недостаточный анализ. Рейтинговые агентства, со своей стороны, ограничены во времени оценки. Поскольку классически анализ данных проводится людьми, в заявленный

срок агентство может не успеть рассмотреть все данные и факторы, и, в результате, дать неточную оценку, что вредит репутации как эмитента, так и самого рейтингового агентства.

3. Фокус на неглавных показателях. Так как выбор более и менее значимых факторов проводится экспертами, они могут делать фокус не на тех параметрах, которые действительно вносят значительный вклад в долгосрочную кредитную устойчивость эмитента. Например, некоторые кредитные агентства больше внимания уделяют краткосрочным финансовым показателям, таким как прибыльность за последний квартал или год. Это может привести к тому, что долгосрочная устойчивость компании будет недооценена.

4. Конфликт интересов. Существует риск конфликта интересов между агентствами и компаниями, которым они присваивают рейтинги. Компании могут платить агентствам за оценку их кредитоспособности, что потенциально может повлиять на объективность анализа.

5. Высокая стоимость. У компаний нет простых инструментов для оценки своего кредитного рейтинга, поэтому они вынуждены обращаться за дорогостоящими услугами агентств.

Результаты и обсуждения. Развитие современных технологий в сфере анализа данных и машинного обучения открывает новые перспективы для решения задачи формирования кредитных рейтингов. Сегодня финансовые аналитики и эксперты всё чаще обращаются к алгоритмам и технологиям искусственного интеллекта, способствующим повышению точности прогнозирования платежеспособности организаций и физических лиц.

Машинное обучение позволяет автоматизировать сбор и обработку больших объемов данных, что значительно сокращает время на анализ, помогает получить более полное и глубокое понимание финансового положения компании-заемщика, выделить более важные факторы, влияющие на кредитный рейтинг в текущих условиях, а также минимизировать риск конфликта интересов между рейтинговыми агентствами и компаниями.

Алгоритмы способны анализировать большие объемы разнородных данных, выявлять скрытые закономерности и взаимосвязи, которые трудно заметить человеку. Вместе с тем важно помнить, что даже самые совершенные модели требуют постоянного контроля и обновления для поддержания адекватности выводов в условиях быстро меняющейся рыночной среды [2].

Таким образом, современные технологии анализа больших данных открывают широкие возможности для значительного улучшения существующих методик расчета кредитных рейтингов, обеспечивая повышение прозрачности, эффективности и непредвзятости процесса присвоения кредитных рейтингов.

Задача присвоения кредитного рейтинга является частным случаем задачи небинарной классификации. Одними из самых популярных методов машинного обучения, которые подходят для данной задачи, являются методы случайного леса и метод искусственной нейронной сети.

Основная идея метода случайного леса заключается в использовании большого ансамбля решающих деревьев, каждое из которых само по себе даёт очень невысокое качество классификации, но за счёт их большого количества результат получается хорошим.

Метод решающего дерева, в свою очередь – это метод принятия решений, основанный на использовании древовидного графа. Структура дерева представляет собой «листья» и «ветки». На рёбрах («ветках») дерева решения записаны признаки, от которых зависит целевая функция, в «листьях» записаны значения целевой функции, а в остальных узлах — признаки, по которым различаются случаи. Чтобы классифицировать новый случай (предсказать значение целевой переменной), надо спуститься по дереву до листа и выдать соответствующее значение. Задача машинного обучения в данном методе — выбор лучших признаков. Метод деревьев решений

реализует принцип так называемого «рекурсивного деления», его относят к категории жадных алгоритмов. Жадными называются алгоритмы, которые допускают, что локально-оптимальные решения на каждом шаге (разбиения в узлах), приводят к оптимальному итоговому решению. В случае деревьев решений это означает, что если один раз был выбран атрибут, и по нему было произведено разбиение на подмножества, то алгоритм не может вернуться назад и выбрать другой атрибут, который дал бы лучшее итоговое разбиение [3].

При переходе к ансамблю деревьев («лесу»), классификация объектов проводится путём голосования: каждое дерево ансамбля относит классифицируемый объект к одному из классов, а побеждает класс, за который проголосовало наибольшее число деревьев.

Оптимальное число деревьев подбирается таким образом, чтобы минимизировать ошибку классификатора на тестовой выборке. В случае её отсутствия, минимизируется оценка ошибки на не вошедших в набор образцах [4].

К преимуществам метода случайного леса можно отнести:

- 1) способность эффективно обрабатывать данные с большим числом признаков и классов;
 - 2) нечувствительность к масштабированию (и вообще к любым монотонным преобразованиям) значений признаков;
 - 3) одинаково хорошо обрабатываются как непрерывные, так и дискретные признаки.
- Существуют методы построения деревьев по данным с пропущенными значениями признаков;
- 4) существуют методы оценивания значимости отдельных признаков в модели;
 - 5) внутренняя оценка способности модели к обобщению (тест по неотобраным образцам);
 - 6) высокая параллелизуемость и масштабируемость.

К недостаткам метода можно отнести лишь его большие затраты по памяти.

Второй популярный метод, о котором упоминается в данной статье – искусственная нейронная сеть (ИНС). Искусственная нейронная сеть — это математическая модель, а также её программное или аппаратное воплощение, построенная по принципу организации биологических нейронных сетей — сетей нервных клеток живого организма. Это понятие возникло при изучении процессов, протекающих в мозге, и при попытке смоделировать эти процессы. В современной литературе данный термин чаще называют просто нейросеть.

Искусственная нейросеть состоит из взаимосвязанных искусственных нейронов, представляющих собой простые процессоры. Эти процессоры значительно проще тех, что используются в обычных ПК. Каждый нейрон обрабатывает сигналы, поступающие от других элементов системы, и передает свои собственные. Несмотря на свою простоту, при объединении в крупную сеть они могут решать сложные задачи благодаря координированному взаимодействию.

Искусственные нейронные сети находят применение в самых разных областях, где требуется обработка больших объемов данных, распознавание образов, принятие решений и моделирование сложных процессов [5].

ИНС могут иметь самые разные топологии. В данной статье рассматривается полносвязная сеть – топология, в которой каждый нейрон одного слоя связан с каждым нейроном следующего слоя. Данная топология доказала свою эффективность в задачах классификации (бинарной и небинарной) и регрессии.

После обучения моделей на обучающей выборке [6], были проведены эксперименты на тестовой выборке в 10 000 организаций. Каждой из них был присвоен определенный кредитный рейтинг, а также были выделены главные признаки, влияющие на повышение или понижение рейтинга. В данном наборе данных ими оказались прибыльность, размер существующих долгов и соотношение долга к собственным средствам.

Для оценки качества построения моделей и их обучения были взяты такие показатели, как средняя квадратичная ошибка (MSE), средняя абсолютная ошибка (MAE) и точность (accuracy).

Получившиеся значения метрик можно посмотреть в таблице 1:

Таблица 1.

Метрики качества обучения

	Accuracy	MAE	MSE
Случайный лес	0.81	0.17	0.26
ИНС	0.74	0.23	0.34

Выводы. Как нетрудно заметить, алгоритм случайного леса показал более высокие результаты практически по всем ключевым показателям, характеризующим качество модели, по сравнению с полносвязной нейронной сетью, несмотря на то что является более простым в реализации. Помимо количественных характеристик, важным преимуществом случайного леса стала скорость как обучения модели, так и предсказаний. Таким образом, случайный лес оказался более оптимальным методом машинного обучения для решения поставленной задачи.

Полносвязная сеть показала довольно низкие результаты предсказаний и высокие метрики ошибок. Такая топология является одной из самых простых, поэтому для улучшения показателей точности предсказания имеет смысл подумать над другими топологиями и типами нейронных сетей, в том числе сверточными нейронными сетями и нейросетями-трансформерами, которые доказали свою эффективность в различных задачах классификации, а также задачах обработки естественного языка. Данные типы ИНС демонстрируют возможность качественного обучения на малых объемах данных, а также высокое внимание к общему контексту задачи [7]. Оба этих преимущества могут дать хороший результат в задаче определения кредитных рейтингов компаний.

ЛИТЕРАТУРА

1. Домингос П. Верховный алгоритм. Как машинное обучение изменит наш мир. — Basic Books, 2015 — 39 с.
2. Лекун Я. Как учиться машина. Революция в области нейронных сетей и глубокого обучения. — М.: Альпина нон-фикшн, 2021 — 14 с.

3. Бринк Х., Ричардс Д., Февервольф М. Машинное обучение. — Санкт-Петербург: Питер, 2017 — 36 с.
4. Булавина М.А., Новосельский С.О., Измestьев Д.М. Организационно-экономический механизм управления бизнес-процессами производства металлоконструкций в условиях кризиса // Вестник Университета мировых цивилизаций. 2024. Т.15. №2 (43). С. 68-74.
5. Жилияков Д.И., Дорофеев А.Ф., Петрушина О.В., Новосельский С.О., Шлеенко А.В. Интегральная оценка технологического развития пространственно локализованных агросоциохозяйственных систем региона // Техника и оборудование для села. 2025. №3 (333). С. 44-47.
6. Новосельский С.О., Кириллова О.В., Золкин А.Л., Замбахидзе Л.Н. Менеджмент производственно-сбытовой деятельности компании на региональном рынке // Финансовый менеджмент. 2025. №3. С. 52-62.
7. Слуцкий Л.Э., Кротов М.И., Мунтиян В.И. Матрица выравнивания структурных диспропорций в социально-экономическом положении регионов России // Проблемы современной экономики. 2024. №1 (89). С. 6-21.
8. Слуцкий Л.Э. [О некоторых итогах евразийской интеграции \(вступительное слово\)](#) // [Проблемы современной экономики](#). 2018. №4 (68). С. 6.
9. Слоботчиков О.Н., Попков А.А. Профессионализация как основа формирования базовой функциональной концепции современной системы образования // Казанский педагогический журнал. 2018. №5 (130). С. 32-38.
10. Слоботчиков О.Н. Национальные государства после распада «империи» Европы // В сборнике: Феномен роста популярности радикальных политических движений в Европе: причины и перспективы. В 2-х частях. Москва, 2018. С. 292-296.
11. Flach P. Machine Learning. The Art and Science of Algorithms that Make Sense of Data. — Cambridge University Press, 2012 — P. 45.
12. Starter: Corporate Credit Rating 724a4d11-b [Электронный ресурс] — Режим доступа — URL: <https://www.kaggle.com/code/kerneler/starter-corporate-credit-rating-724a4d11-b/input> (Дата обращения 20.12.2024)
13. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A., Kaiser L., Polosukhin I. Attention is All you Need. — 31st Conference on Neural Information Processing Systems (NIPS), 2017.

Igor Andreevich Fedorov

Zhirinovskiy University of World Civilizations, Moscow, Russia
E-mail: f3dorov1gor@yandex.ru

Ilya Aleksandrovich Kiselev

Moscow Institute of Economics, Moscow
E-mail: ze-rii@yandex.ru

Novoselsky Svyatoslav Olegovich

Zhirinovskiy University of World Civilizations, Moscow, Russia
Moscow Economic Institute, Moscow
E-mail: nsvyatoslav@yandex.ru

Application of machine learning methods to predict credit ratings of organizations

Abstract. The article discusses current areas of application for credit ratings, existing approaches to assigning a company's credit rating, shortcomings of the classical approach, as well as prospects and possibilities for applying machine learning methods and artificial intelligence in the task of assigning a corporate credit rating. Possible advantages of solving this problem using machine learning are considered. It is proposed to solve the task by means of random forest method and artificial neural network method. Based on training results with test data volume, quality metrics are measured and conclusions are drawn about the potential use of these methods and their possible improvement. The random forest algorithm demonstrated superior results across virtually all key metrics characterizing model quality compared to a fully connected neural network, despite being simpler to implement. Beyond quantitative characteristics, a significant advantage of the random forest was the speed of both model training and prediction. Thus, the random forest proved to be a more optimal machine learning method for solving the problem.

Keywords: credit rating; machine learning; neural networks; random forest algorithm; big data analysis