

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ В БАНКОВСКОЙ СФЕРЕ

Ксенофонтова О.Л., Миролюбова А.А., Фокин С.А.

Ксенофонтова Ольга Леонидовна (ORCID 0000-0002-4122-6220), Миролюбова Анастасия Александровна (ORCID 0000-0003-3785-0538), Фокин Станислав Антонович (ORCID 0009-0002-9596-6918)
Ивановский государственный химико-технологический университет
г. Иваново, Россия. 153000, Ивановская область, г. Иваново, пр. Шереметевский, д. 7.
E-mail: olga_izvolova@mail.ru, mirolubowa@mail.ru, stasfokin86@gmail.com

Интеллектуальный анализ данных с каждым годом становится все более актуальным направлением исследования во всех сферах жизни людей: банковский, страховой, государственный сектора и др. Кредитные институты столкнулись с необходимостью обрабатывать большие объемы данных с возрастающей скоростью. Используемые в кредитовании модели, такие как скоринг, стали комбинироваться с методами машинного обучения или интеллектуального анализа данных. В статье рассмотрено понятие кредитного скоринга. Кредитный скоринг позволяет упростить работу кредитных специалистов в банковской сфере и сделать оценку кредитных рисков менее затратной. Кредитный скоринг подразумевает применение алгоритмов, полученных с использованием математических и статистических методов, для деления потенциальных кредитных операций на непересекающиеся группы риска. В статье описаны преимущества и ограничения различных моделей и алгоритмов, используемых в кредитном скоринге, а также перспективы дальнейшего развития данного способа оценки кредитных рисков. Выбор и построение модели, внедрение кредитного скоринга и его применение - сложная и трудоемкая задача. В кредитном скоринге алгоритмы машинного обучения являются неотъемлемой частью и помогают избежать лишних рисков и издержек, за счёт работы алгоритмов, которые помогают сотрудникам банка принимать правильные решения касательно вопросов предоставления кредитов.

Ключевые слова: интеллектуальный анализ данных, банковская сфера, большие данные, машинное обучение, моделирование, кредитный скоринг

USING DATA MINING METHODS IN THE BANKING SECTOR

Ksenofontova O.L., Mirolubova A.A., Fokin S.A.

Ksenofontova Olga Leonidovna (ORCID 0000-0002-4122-6220), Mirolubova Anastasia Alexandrovna (ORCID 0000-0003-3785-0538), Fokin Stanislav Antonovich (ORCID 0009-0002-9596-6918)
Ivanovo state university of chemistry and technology
Ivanovo, Russia. 153000, Ivanovo region, Ivanovo, Sheremetevsky ave., 7.
E-mail: olga_izvolova@mail.ru, mirolubowa@mail.ru, stasfokin86@gmail.com

Intelligent data analysis is becoming more and more relevant research area every year in all spheres of people's life: banking, insurance, public sector and others. Credit institutions are faced with the need to process large amounts of data with increasing speed. The models used in credit scoring, such as scoring, began to be combined with methods of machine learning or data mining. This article discusses the concept of credit scoring. Credit scoring allows to simplify the work of credit specialists in the banking sphere and make the assessment of credit risks less costly. Credit scoring implies the application of algorithms obtained using mathematical and statistical methods to divide potential credit operations into non-overlapping risk groups. The article describes the advantages and limitations of various models and algorithms used in credit scoring, as well as the prospects for further development of this method of credit risk assessment. Selection and construction of a model, implementation of credit scoring and its application is a complex and labor-intensive task. In credit scoring machine

learning algorithms are an indispensable part of credit scoring and help to avoid unnecessary risks and costs, due to the work of algorithms that help bank employees to make the right decisions regarding the issues of granting loans.

Keywords: data mining, banking, big data, machine learning, modeling, credit scoring

ВВЕДЕНИЕ

В настоящее время все большей популярностью пользуются технологии интеллектуального анализа данных. Растет объем данных, а вместе с ним и потребность в его анализе, сборе и обработке. Классические методы хороши только на кратковременный прогноз и небольшое количество данных. Методы машинного обучения и анализа данных, напротив, могут иметь применение в самых разных сферах деятельности человека: банковская, страховая, медицина, государственная и муниципальная деятельность, энергетика, и т.д. [1-4].

Внедрение интеллектуального анализа данных осуществляется благодаря наличию разных инструментов, помогающих реализации разнообразных методов технологии. Эксперты считают, что в ближайшее десятилетие технология Data Mining и интеллектуальный анализ данных станут одними из самых перспективных направлений разработки программных компонентов. Издание MIT Technology Review считает, что при должном развитии эта технология изменит мир.

Современные технологии BigData способны обрабатывать поступающую информацию и автоматически находить паттерны, характерные для фрагментов неоднородных многомерных данных. При этом, главное отличие заключается в автоматизации процесса формулировки гипотез и выявления необычных шаблонов. Данный процесс переложено с человека на компьютер [5, 6].

Интеллектуальный анализ данных – это метод поддержки и принятия решений, который основан на анализе зависимостей конкретных параметров внутри набора данных.

АВТОРСКОЕ ИССЛЕДОВАНИЕ

Актуальность темы исследования связана с текущими тенденциями развития банковской сферы. Гонка технологий между банковскими организациями, внедрение инновационных методов в деятельность позволяет банкам расти и развиваться, находить новые сферы влияния, обеспечивать постоянный клиентопоток, а также грамотно регулировать финансовую деятельность организации. Банки испытывают потребность во внедрении в деятельность своих структур интеллектуального анализа данных. Это эффективный инструмент, который помогает предсказать развитие событий, а на этой основе распределить ресурсы [1,7,8,20].

Теоретическую и методологическую основу исследования составили труды российских и зарубежных ученых по вопросам экономики, применения математического моделирования в банковской сфере, экономического прогнозирования Афанасьев Э.В., Ярошенко В.Н., А.М. Тавасиев, Биктимиров, М. Р., Бодров, А. А., Бююль А., Дуброва Т.А., Ендовицкий Д.А., Бочарова И.В., Мэйз Э.

Кредитные отношения – это неотъемлемая часть современной экономики любой страны. Этот инструмент позволяет физическим и юридическим лицам иметь большие возможности для поддержания и улучшения условий развития бизнеса, жилищных и хозяйственно-бытовых нужд. Данный продукт позволяет рассчитывать дополнительные возможности вложения.

Среди банковских рисков кредитный риск является наиболее трудным в управлении риском. Неверная оценка платежеспособности заемщика или неточно установленный банком допустимый уровень толерантности к риску кредитного портфеля может привести к значительным потерям. Формирование систем оценки рисков кредиторами позволит им значительно повысить качество кредитного портфеля. При помощи механизмов оценки и регулирования риска кредитного портфеля можно вовремя переформировать его структуру. Банк может накапливать статистические данные показателей заемщиков за длительный период времени. На основе этих данных можно выделять группы клиентов, строить математические модели для определения вероятности кредитоспособности потенциальных заемщиков. Применение кредитно-скоринговых систем значительно ускоряет процесс удовлетворения либо отклонения кредитных заявок клиентов [4, 9,10].

Впервые скоринг как метод оценки заемщика был предложен американским экономистом Д. Дюраном в 40-е гг. XX в. Кредитный скоринг – это процесс оценки кредитного риска заемщика, на основе математических моделей и статистического анализа ряда факторов, таких как история кредитных платежей, уровень дохода, занятость, наличие долгов, погашаемых кредитов, возраст, семейное положение и другие. Это позволяет банкам и кредиторам быстро и эффективно определить способность заемщика выплатить кредит вовремя и принять решение по выдаче кредита и на каких условиях. Кредитный скоринг также может быть ис-

пользован для управления риском портфолио кредитов, а также для принятия решений по автоматизированным системам кредитования [9, 11, 12].

Самый главный риск банка в случае выдачи кредита – дефолт заемщика, то есть невозврат суммы кредита (полностью или частично), несоблюдение сроков платежей, в общем, нарушение условий договора.

Для обработки и недопуска таких ситуаций, банки активно развивают IT-направление в своих компаниях, а также разрабатывают собственные или используют готовые системы кредитного скоринга для поддержания уровня конкурентоспособности и привлечения потенциальных клиентов.

Говоря о кредитном скоринге, зачастую имеют в виду именно анализ кредитоспособности физических лиц, но существуют системы для проверки юридических лиц.

Процесс оценивания кредитных рисков может быть разделен на 4 основные категории:

1) Оценка кредитоспособности заемщиков для выдачи кредитов.

2) Оценка динамики состояния кредитного счета заемщика и кредитного портфеля в целом.

3) Определение приоритетных дел и направлений работы с проблемными заемщиками, мониторинг задолженности и выбор оптимального коллекторского воздействия.

4) Выявление мошеннических схем заемщика.

Сущность кредитного скоринга заключается в определении совокупного кредитного балла заемщика в результате его оценки по ряду критериев, а в его основе лежит математический аппарат. Процесс скоринга состоит в применении математических и статистических алгоритмов, с тем, чтобы разделить потенциальные операции кредитования на дефолтную и недефолтную группы. Дефолтная группа представляет собой большой риск возникновения нарушения обязательств заемщиком. Для их предотвращения необходимо выявлять факторы риска, их значимость и взаимозависимость. Созданные модели выявляют данные зависимости и обучаются на схожих примерах.

Основным преимуществом кредитного скоринга является способность установить количественно измеримую степень риска. Это способствует: снижению издержек за счет автоматизации принятия решения о выдаче кредита; сокращению времени обработки заявлений и принятия решения о выдаче или отказе в кредите; снижению влияния человеческого фактора при принятии кредитного решения [9].

При расчете кредитного сора учитываются следующие факторы: демографические данные

(возраст, семейное положение, и т.д.), наличие работы (тип занятости, престиж), информация из Бюро кредитных историй, данные о финансовом благополучии клиента. Впрочем, не всегда использование этих данных разрешено на законодательном уровне. Например, в США существует Федеральный Закон «Об отчете по кредитным операциям» и Закон «О равных кредитных возможностях», согласно которым запрещено учитывать семейное положение, расу, религиозные убеждения и пол в качестве признаков при создании модели кредитного скоринга и принятии решения о выдаче кредитов в целом. Но для грамотной оценки необходимо также учитывать валютные риски выдачи кредита (валютные ссуды считаются более рискованными) [9]. Кредитные бюро также являются одним из самых важных звеньев в расчете кредитного потенциала клиента. Они предоставляют информацию относительно существующих и потенциальных заемщиках, обеспечивая эффективный скоринг и улучшая уровень безопасности финансовых отношений. Существование данных организаций помогает не только банкам, но и клиентам, ведь при наличии хорошей кредитной истории банк в состоянии предложить более низкий процент кредита, а также в меньшей мере компенсировать риски невозврата кредита за счет добропорядочных клиентов.

Основные методы, которые применяются при построении модели кредитного скоринга: традиционные (линейный дискриминантный анализ и линейная регрессия) и современные (применение методов машинного обучения в логистической и пробит-регрессии, нейронные сети) [6, 10, 13, 14].

Современная экономика требует от банковской системы быстрого и эффективного анализа данных, в том числе и в процессе выдачи кредитов. Цифровизация основных направлений работы банковского сектора активно обсуждаются в работах ученых [15;16]. В связи с этим, использование методов машинного обучения в кредитном скоринге является одним из наиболее актуальных направлений в банковской сфере. Актуальность выбранной темы обусловлена перебором большой базы данных и параметров, на основании которых производится оценка заемщика. Мы проанализировали набор данных о заемщиках, на основании которых будет определено, стоит ли оформлять кредит в конкретном случае [5].

Машинное обучение - это подход к анализу данных, основанный на использовании алгоритмов и статистических моделей. Основные методы машинного обучения включают в себя: а) обучение с учителем - это метод, в котором система обучается

на основе имеющихся данных и меток, которые указывают на правильный ответ; б) обучение без учителя - это метод, в котором система обучается на основе имеющихся данных, но без меток, и самостоятельно ищет закономерности в данных; в) обучение с подкреплением - это метод, в котором система обучается, играя в игру, и получая подкрепление за правильные действия. Машинное обучение нашло широкое применение в банковской сфере, в том числе и кредитном скоринге. Методы машинного обучения широко применяются в банковской сфере для решения различных задач, они включают:

- кредитный скоринг - используется для оценки кредитоспособности заемщиков на основе анализа их данных.

- беттинг-рейтинг - используется для прогнозирования вероятности дефолта заемщика на основе исторических данных и анализа кредитного портфеля.

- анти-мошеннический мониторинг – используется для выявления и предотвращения финансовых мошенничеств с помощью анализа транзакций и автоматического обнаружения аномалий.

- персонализация услуг - используется для анализа данных клиентов (например, их истории покупок) с целью предоставления персонализированных продуктов и услуг.

- прогнозирование и управление рисками - используется для прогнозирования рисков и управления портфелем инвестиций на основе анализа финансовых данных и рыночных тенденций.

- оптимизация процессов - используется для автоматизации и оптимизации бизнес-процессов, таких как управление запасами или принятие решений по кредитованию.

Использование методов машинного обучения позволяет банкам повысить эффективность своих бизнес-процессов, повысить точность и скорость принятия решений, а также улучшить взаимодействие с клиентами. Основной принцип технологии кредитного скоринга с машинным обучением заключается в использовании алгоритмов машинного обучения для анализа большого объема данных, связанных с заемщиками. Оценка кредитоспособности заемщика происходит на основе анализа исторических данных, таких как данные о доходах, кредитной истории, возрасте и других факторах. Системы машинного обучения используют эти данные для создания математической модели, которая позволяет оценить кредитоспособность заемщика и прогнозировать вероятность возврата кредита.

Основные этапы технологии кредитного скоринга [11]:

1 этап - сбор и анализ информации о заемщике: общая информация о заемщике, данные о его доходах и расходах, кредитная история, наличие задолженности и т.д.;

2 этап - выделение основных факторов риска: на основании анализа информации о заемщике, определяются главные факторы, которые могут повлиять на его способность вернуть кредит, например, существующие задолженности, уровень доходов и т.д.;

3 этап - разработка системы оценки кредитного риска: на основании данных анализа и выделенных факторов риска разрабатывается система оценки кредитного риска;

4 этап - определение кредитного скорора: на основании полученной системы оценки риска, заемщик получает кредитный скор, который определяет его способность вернуть кредит;

5 этап - принятие решения о выдаче кредита: на основании данных о кредитном скороре и других факторов риска, кредиторы принимают решение о выдаче кредита и установлении процентной ставки.

В исследовании в качестве объекта исследования выступает АО «Альфа Банк». Построим модель кредитного скоринга для АО «Альфа Банк» с использованием открытого набора данных [SF-DST] Credit Scoring на платформе Kaggle.

Платформа Kaggle - это система организации конкурсов по исследованию данных, а также социальная сеть специалистов по обработке данных и машинному обучению. Среда организована как публичная веб-платформа, на которой пользователи и организации могут публиковать наборы данных, исследовать и создавать модели, взаимодействовать с другими специалистами по данным и инженерами по машинному обучению, организовывать конкурсы по исследованию данных и участвовать в них. В системе размещены наборы открытых данных, предоставляются облачные инструменты для обработки данных и машинного обучения. Также реализованы обучающие ресурсы, имеется раздел для размещения вакансий работодателями, где тоже возможна организация конкурсов для отбора наилучших кандидатов.

При получении набора данных необходимо его изучить, а также подключить необходимые библиотеки для последующей обработки. Далее необходимо загрузить и изучить датасет и его представление в рабочей области. Набор данных для модели выбран совместно с менеджерами банка, он включает следующие **показатели**: client_id - идентификатор клиента, education - уровень образования, sex - пол заемщика, age - возраст заемщика, car - флаг наличия автомобиля, car_type - флаг

автомобиля иномарки, `decline_app_cnt` - количество отказанных прошлых заявок, `good_work` - флаг наличия “хорошей” работы, `bki_request_cnt` - количество запросов в БКИ, `home_address` - категоризатор домашнего адреса, `work_address` - категоризатор рабочего адреса, `income` - доход заемщика, `foreign_passport` - наличие загранпаспорта, `sna` - связь заемщика с клиентами банка, `first_time` - давность наличия информации о заемщике, `score_bki` - скоринговый балл по данным из БКИ, `region_rating` - рейтинг региона, `app_date` - дата подачи заявки, `default` - флаг дефолта по кредиту (рис. 1).

Для корректной обработки нам необходимо объединить обучающую и тестовую выборку, а также создать поле `sample`, где пометим значением 1 обучающую выборку и значением 0 – тестовую. Создадим простой входной отчет фрейма данных. Для этого используем метод `Profile Report`, которая отобразит статистические данные для каждого столбца, выделит гистограммы, описательную статистику, корреляции, анализ текста для нахождения типов данных.

Проведем первичный анализ данных, он показал следующее: 110148 строк, из них 73799

строк для обучения и 36349 строк тестового набора; отсутствуют дублирующиеся строки; поле `Education` имеет пропуски; 3 поля Boolean, 10 категориальных и 7 числовых переменных; отсутствие корреляции с целевой переменной; найдена значимая корреляция между доходом заемщика и рейтингом региона.

Далее была проведена предобработка данных. Обработаны пустые значения ординарного признака `Education`. Пустых значений 478. Это 0,43% от общего количества строк. Заполним пропуски самым часто встречающимся значением ‘SCH’. Разделим признаки по категориям – бинарные (пол, машина, тип машины, наличие загранпаспорта, отметка о хорошей работе), категориальные (образование, рейтинг региона, домашний адрес, рабочий адрес, дата подачи заявки, связь заемщика с клиентами банка, давность наличия информации о заемщике), числовые (возраст, доход, скор БКИ, количество запросов БКИ) [4]. Далее проведем оценку корреляции, значимость непрерывных признаков, а также проведем оценку категориальных признаков (рис. 2).




Рис. 1. Количественные показатели набора данных
Fig. 1. Quantitative indicators of the data set




Рис. 2. Корреляция параметров набора
Fig. 2. Correlation of set parameters

После проведения первичного анализа необходимо подготовить данные к машинному обучению. Для этого необходимо преобразовать категориальные признаки, выполнить стандартизацию численных переменных, разделить на тестовую и обучающую выборку и произвести поиск оптимальной модели. Построим модель логистической регрессии на исходных данных без дополнительных обработок. Ассигнату score данной модели составляет 0,8736. Но при последующей визуализации confusion matrix стало известно, что наша мо-

дель хоть и имеет достаточно высокую точность, но выдает кредиты практически во всех случаях, когда клиент не способен его вернуть.

Для нормализации модели проведем процедуру undersampling чтобы нормализовать классы в наборе train. Теперь, когда настроены параметры модели логистической регрессии, для увеличения точности обработки данных попробуем более сложную модель. Применим модель градиентного бустинга и посмотрим на реакцию датасета (рис. 3).

```
cat = CatBoostClassifier(n_estimators=1000,
                        depth=2,
                        logging_level='Silent')

cat.fit(X_train, Y_train)
probs = cat.predict_proba(X_test)
y_pred = cat.predict(X_test)
probs = probs[:,1]

fpr, tpr, threshold = roc_curve(Y_test, probs)
roc_auc = roc_auc_score(Y_test, probs)

fig, ax = plt.subplots(figsize=(10,5))
plt.plot([0, 1], label='Baseline', linestyle='--')
plt.plot(fpr, tpr, label='Regression')
ax.set_title('Logistic Regression ROC AUC = %0.5f'%roc_auc)
plt.ylabel('True Positive Rate')
plt.xlabel('False Positive Rate')
plt.legend(loc='lower right')

<matplotlib.legend.Legend at 0x7efeae9bd3650>
```

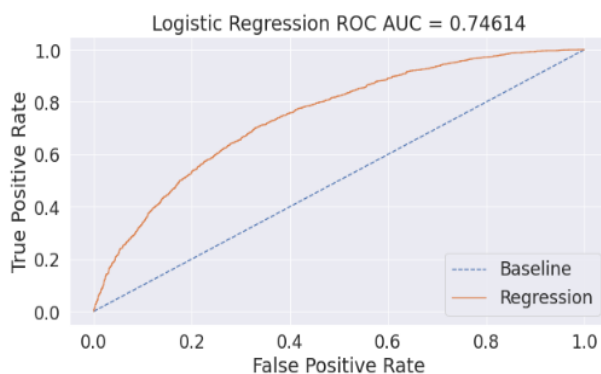


Рис.3. Модель градиентного бустинга
Fig.3. Gradient boosting model

Данная модель показала оптимальное соотношение верно вычисленных ответов. Показатель гос-аус данной модели равен 0.74614, это значит, что наша модель достаточно точна для поддержки принятия решений менеджера банка. Именно она будет использоваться в качестве итоговой модели для работы с данными кредитного скоринга.

ЗАКЛЮЧЕНИЕ

С учетом быстрого развития технологий машинного обучения и анализа данных, можно ожидать, что кредитный скоринг с использованием машинного обучения будет продолжать развиваться и совершенствоваться в будущем. В ближайшее время можно ожидать появления новых методов машинного обучения, которые позволят банкам создавать более точные и эффективные модели кредитного скоринга [17-19].

Кроме того, можно предположить, что использование машинного обучения в кредитном скоринге будет распространяться не только на банковскую сферу, но и на другие отрасли. Например, модели машинного обучения могут быть применены для оценки рисков страхования или для анализа кредитоспособности клиентов в дру-

гих сферах экономики. Использование методов машинного обучения в кредитном скоринге позволяет банкам значительно повысить эффективность процесса выдачи кредитов и уменьшить риски, связанные с невозвратом кредитов. Однако, внедрение систем машинного обучения требует серьезных усилий и инвестиций в обучение моделей и разработку инфраструктуры. Поэтому, банки должны внимательно оценивать все преимущества и недостатки использования машинного обучения в кредитном скоринге, прежде чем принимать решение о внедрении таких систем. В свете последних технологических достижений в области машинного обучения, все больше банков становятся заинтересованы в применении этой технологии в кредитном скоринге. Одним из наиболее перспективных направлений является использование алгоритмов глубокого обучения, которые позволяют обрабатывать и анализировать сложные данные, такие как изображения и звук.

Кроме того, использование методов машинного обучения в кредитном скоринге может быть полезно для выявления мошеннических схем. Модели машинного обучения могут анализировать данные о поведении заемщиков и выяв-

лять аномалии, которые могут свидетельствовать о мошенничестве.

Недавно были разработаны новые методы машинного обучения, которые позволяют создавать персонализированные модели кредитного скоринга. Это означает, что модели машинного обучения могут быть настроены на конкретного заемщика, учитывая его индивидуальные характеристики и поведение.

Несмотря на все преимущества, связанные с использованием машинного обучения в кредитном скоринге, существуют также и риски. Одним

из главных рисков является возможность ошибок модели, которые могут привести к неверным решениям в процессе выдачи кредитов. Поэтому, банки должны тщательно анализировать данные и проводить регулярную проверку моделей машинного обучения, чтобы убедиться в их точности и надежности.

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. **Фокин С.А., Ксенофонтова О.Л.** Анализ и перспективы внедрения технологий больших данных в банковской сфере. *Сборник научных трудов вузов России "Проблемы экономики, финансов и управления производством"*. 2022. № 51. С. 21-26. EDN KGCQEW.
2. **Смирнова Е.М., Валинурова А.А., Данилова С.В., Валинуров Т.Р.** Разработка подхода к кластеризации районов на базе инструментального средства машинного обучения KNIME. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством*. 2021. № 4 (50). С. 165-175.
3. **Миролюбова А.А., Ксенофонтова О.Л.** Архитектуры нейронных сетей для прогнозирования развития коронавирусной инфекции. В сборнике: *Последствия и вызовы пандемии коронавируса для технологического и социально-экономического развития общества*. Сборник трудов III Международной научно-практической конференции. Под общей редакцией к.э.н. С.В. Шкиотова, д.э.н. В.А. Гордеева. Ярославль, 2020. С. 375-380.
4. **Гонова О.В.** Моделирование социально-экономического развития экономики региона (на материалах Ивановской области). *Современные наукоемкие технологии. Региональное приложение*. 2015. № 3(43). С. 57-63.
5. **Пленкин В., Тартенас М.** Скоринговая модель кредитных историй. *Банковский вестник*. 2015. № 6(623). С. 48-52. – EDN GQZBRZ.
6. **Ильченко А.Н., Ксенофонтова О.Л., Канакина Г.В.** Практикум по экономико-математическим методам. Учебное пособие. Москва: Финансы и статистика. 2014. 288 с.
7. **Волкова Е.С., Гисин В.Б., Соловьев В.И.** Современные подходы к применению методов интеллектуального анализа данных в задаче кредитного скоринга. *Финансы и кредит*. 2017. Т. 23, № 34. С. 2044-2060. <https://doi.org/10.24891/fc.23.34.2044>.
8. **Гонова О.В.** Формирование финансовых результатов сельскохозяйственного предприятия в условиях экономической неопределённости. *Современные наукоемкие технологии. Региональное приложение*. 2021. № 3(67). С. 23-30. DOI 10.6060/snt.20216703.0003.
9. **Ткачев А., Шипунов А.** Системы кредитного скоринга. Матричный подход. *Банковский вестник*. 2019. № 10(675). С. 37-46. – EDN KFBQQZ.
10. **Кочеткова В.В., Ефремова К.Д.** Обзор методов кредитного скоринга. *Juvenis Scientia*. 2017. № 6. С. 22-25. DOI 10.15643/jscientia.2017.6.006. – EDN YUONYJ.
11. **Воронин С.М., Совертека З.К., Березин А.Д., Ларин А.И.** Кредитный скоринг, реализованный с помощью машинного обучения. *Столыпинский вестник*. 2022. Т. 4, № 10.

REFERENECES

1. **Fokin S.A., Ksenofontova O.L.** Analysis and prospects for the introduction of big data technologies in the banking sector. *Collection of scientific papers of Russian universities "Problems of economics, finance and production management"*. 2022. N 51. P. 21-26. – EDN KGCQEW.
2. **Smirnova E.M., Valinurova A.A., Danilova S.V., Valinurov T.R.** Development of an approach to clustering of districts based on the KNIME machine learning tool. *News of higher educational institutions. Series: Economics, Finance and Production Management*. 2021. N 4 (50). P. 165-175.
3. **Mirolubova A.A., Ksenofontova O.L.** Neural network architectures for predicting the development of coronavirus infection. In the collection: *Consequences and challenges of the coronavirus pandemic for the technological and socio-economic development of society*. Proceedings of the III International Scientific and Practical Conference. Under the general editorship of Candidate of Economics S.V. Shkiotov, Doctor of Economics V.A. Gordeev. Yaroslavl, 2020. P. 375-380.
4. **Gonova O.V.** Modeling of socio-economic development of the economy of the region (based on the materials of the Ivanovo region). *Modern high-tech technologies. A regional application*. 2015. N 3(43). P 57-63.
5. **Plenkin V. Tartenas M.** Scoring model of credit histories. *Banking Bulletin*. 2015. N 6(623). P. 48-52. – EDN GQZBRZ.
6. **Ilchenko A.N., Ksenofontova O.L., Kanakina G.V.** Workshop on economic and mathematical methods. Study guide. Moscow: Finance and Statistics. 2014. 288 p.
7. **Volkova E.S., Gisin V.B., Soloviev V.I.** Modern approaches to the application of data mining methods in the problem of credit scoring. *Finance and credit*. 2017. Vol. 23, N 34. P. 2044-2060. <https://doi.org/10.24891/fc.23.34.2044>
8. **Gonova O.V.** Formation of financial results of agricultural enterprise in conditions of economic uncertainty. *Modern high-tech technologies. Regional application*. 2021. N 3(67). P. 23-30. DOI 10.6060/snt.20216703.0003.
9. **Tkachev A., Shipunov A.** Credit scoring systems. Matrix approach. *Banking Bulletin*. 2019. N 10(675). P 37-46. – EDN KFBQQZ.
10. **Kochetkova V.V., Efreмова K.D.** Review of credit scoring methods. *Juvenis Scientia*. 2017. N 6. P. 22-25. DOI 10.15643/jscientia.2017.6.006. – EDN YUONYJ.

12. **Гонова О.В.** Разработка автоматизированной информационной системы (АИС) для планирования производственно-финансовой деятельности сельскохозяйственного предприятия. Наука о данных: Материалы международной научно-практической конференции, Санкт-Петербург, 05–07 февраля 2020 года. Санкт-Петербург: Санкт-Петербургский государственный экономический университет, 2020. С. 91–93.
13. **Гонова О.В.** Построение игровых динамических моделей макроэкономических процессов в регионе. *Современные наукоемкие технологии. Региональное приложение.* 2011. № 4(28). С. 26–34.
14. **Миролюбова А.А., Ермолаев А.Д., Прокофьев М.Б.** ARIMA - прогнозирование спроса производственного предприятия. *Современные наукоемкие технологии. Региональное приложение.* 2021. № 2(66). С. 50–55. DOI 10.6060/snt.20216602.0007.
15. **Рычихина Н.С.** Большие данные и искусственный интеллект как основа реализации региональных цифровых проектов. В сборнике: Наука о данных. Материалы международной научно-практической конференции. 2020. С. 264
16. **Шекшуйева С.В., Зенов С.В.** Российские и международные рейтинговые агентства: сравнение методологий определения кредитного рейтинга коммерческого банка. *Современные наукоемкие технологии. Региональное приложение.* 2020. № 2 (62). С. 80–89.
17. **Валинурова А.А., Смирнова Е.М., Ксенофонтова О.Л.** Интеллектуальное дистанционное банковское обслуживание и его особенности. *Современные наукоемкие технологии. Региональное приложение.* 2021. № 2(66). С. 16–21. DOI:10.6060/snt.20216602.0002
18. **Бушуева М.А., Видулова Е.Н., Масюк Н.Н.** Повышение качества кредитного портфеля регионального коммерческого банка как фактор совершенствования его кредитной политики. *Современные наукоемкие технологии. Региональное приложение.* 2021. № 3(67). С. 8–17. DOI:10.6060/snt.20216703.0001
19. **Широкова Н.П., Степанова С.М.** Сравнительный анализ депозитных услуг юридических лиц, облигаций и счетов в банках Ивановской области. *Современные наукоемкие технологии. Региональное приложение.* 2021. № 3(67). С. 46–52. DOI:10.6060/snt.20216703.0006
20. **Бобков, С. П.** Имитационное моделирование для интеллектуальной поддержки принятия управленческих решений / С. П. Бобков, И. А. Астраханцева, Е. А. Павлова // *Современные наукоемкие технологии. Региональное приложение.* – 2022. – № 1(69). – С. 61–69. – DOI 10.6060/snt.20226901.0008. – EDN VIOOGK
11. **Voronin S.M., Sovertek Z.K., Berezin A.D., Larin A.I.** Credit scoring implemented using machine learning. *Stolypin Bulletin.* 2022. Vol. 4, N 10.
12. **Gonova O.V.** Development of an automated information system (AIS) for planning the production and financial activities of an agricultural enterprise. Data science: Materials of the International scientific and practical conference, St. Petersburg, 05-07 February 2020. St. Petersburg: St. Petersburg State University of Economics, 2020. P. 91-93.
13. **Gonova O.V.** Construction of game dynamic models of macroeconomic processes in the region. *Modern high-tech technologies. Regional application.* 2011. N 4(28). P. 26-34.
14. **Mirolubova A.A., Ermolaev A.D., Prokofiev M.B.** ARIMA - forecasting the demand of a manufacturing enterprise. *Modern high-tech technologies. Regional application.* 2021. № 2(66). P. 50-55. DOI 10.6060/snt.20216602.0007.
15. **Rychikhina N.S.** Big data and artificial intelligence as the basis for the implementation of regional digital projects. In the collection: Data Science. Materials of the international scientific and practical conference. 2020. P. 264-265.
16. **Shekshuyeva S.V., Zenov S.V.** Russian and international rating agencies: comparison of methodologies for determining the credit rating of a commercial bank. *Modern high technologies. Regional application.* 2020. N 2 (62). P. 80–89.
17. **Valinurova A.A., Smirnova E.M., Ksenofontova O.L.** Intelligent remote banking services and its features. *Modern High Technologies. Regional Application.* 2021. N 2(66). P. 16-21. DOI:10.6060/snt.20216602.0002
18. **Bushueva M.A., Vikulova E.N., Masyuk N.N.** Improving the quality of the loan portfolio of a regional commercial bank as a factor in improving its credit policy. *Modern High Technologies. Regional Application.* 2021. N 3(67). P. 8-17. DOI:10.6060/snt.20216703.0001
19. **Shirokova N.P., Stepanova S.M.** Comparative analysis of deposit services of legal entities, bonds and accounts in banks of the Ivanovo region. *Modern High Technologies. Regional Application.* 2021. N 3(67). P. 46-52. DOI:10.6060/snt.20216703.0006
20. **Bobkov, S. P.** Simulation modeling for intellectual support of managerial decision-making / S. P. Bobkov, I. A. Astrakhanseva, E. A. Pavlova // *Modern high-tech technologies. Regional application.* – 2022. – № 1(69). – Pp. 61-69. – DOI 10.6060/snt.20226901.0008. – EDN VIOOGK.

Поступила в редакцию 08.09.2023
Принята к опубликованию 11.10.2023

Received 08.09.2023
Accepted 11.10.2023