

УДК 631.1,62-5

5.2.2. Математические, статистические и инструментальные методы экономики (физико-математические науки, экономические науки)

ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СФЕРЕ АНАЛИЗА ФИНАНСОВЫХ РИСКОВ

Мурлин Алексей Георгиевич
Кандидат технических наук, доцент кафедры информационных систем и программирования
РИНЦ-SCIENCE INDEX SPIN-код: 4991-8507
murlinag@mail.ru
ФГБОУ ВО "Кубанский государственный технологический университет", Краснодар, Россия

Павлюченко Антон Тарасович
студент кафедры информационных систем и программирования
pavlyuchenkoantosha@yandex.ru

Марзан Иван Сергеевич
студент кафедры информационных систем и программирования
ioann@imarzan.ru
ФГБОУ ВО "Кубанский государственный технологический университет", 350072, улица Московская, 2, Краснодар, Россия

Цель исследования заключается в разработке интеллектуальной системы для анализа и управления финансовыми рисками с применением методов искусственного интеллекта. Разрабатываемое приложение охватывает три ключевых направления риск-менеджмента: кредитный риск, инвестиционный риск и страховой риск. В рамках проекта реализуется оценка платежеспособности заемщиков, прогнозирование дефолтов, расчет показателей VaR и CVaR, а также построение актуарных моделей для страховой отрасли. Система использует алгоритмы машинного обучения и нейросетевые архитектуры для построения прогнозных моделей, а также включает веб-интерфейс для интерактивной работы пользователей с данными и визуализации аналитики. Решение обеспечивает адаптацию к изменяющимся финансовым условиям, способствует повышению точности оценки рисков и автоматизации процессов принятия управленческих решений в финансовых организациях

Ключевые слова: РИСК-МЕНЕДЖМЕНТ, КРЕДИТНЫЙ РИСК, ИНВЕСТИЦИИ, СТРАХОВАНИЕ, ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ, МАШИННОЕ ОБУЧЕНИЕ,

UDC 631.1,62-5

5.2.2. Mathematical, statistical and instrumental methods of economics (physical and mathematical sciences, economic sciences)

EXPLORING THE CAPABILITIES OF ARTIFICIAL INTELLIGENCE IN THE FIELD OF FINANCIAL RISK ANALYSIS

Murlin Alexey Georgievich
Candidate of Technical Sciences, Associate Professor of the Department of Information Systems and Programming
RSCI-SCIENCE INDEX SPIN-code: 4991-8507
murlinag@mail.ru
Kuban State Technological University, Krasnodar, Russia

Pavlyuchenko Anton Tarasovich
student of the Department of Information Systems and Programming
pavlyuchenkoantosha@yandex.ru

Marzan Ivan Sergeevich
student of the Department of Information Systems and Programming
ioann@imarzan.ru
Kuban State Technological University, 350072, Moskovskaya, 2, Krasnodar, Russia

The aim of the research is to develop an intelligent system for analysing and managing financial risks using artificial intelligence methods. The application under development covers three key areas of risk management: credit risk, investment risk and insurance risk. The project involves assessing borrowers' solvency, forecasting defaults, calculating VaR and CVaR indicators, and building actuarial models for the insurance industry. The system uses machine learning algorithms and neural network architectures to build predictive models, and also includes a web interface for users to interactively work with data and visualise analytics. The solution provides adaptation to changing financial conditions, improves the accuracy of risk assessment and automation of management decision-making processes in financial organisations

Keywords: RISK MANAGEMENT, CREDIT RISK, INVESTMENTS, INSURANCE, ARTIFICIAL INTELLIGENCE, MACHINE LEARNING, NEURAL NETWORKS, PYTHON, PYTORCH,

НЕЙРОННЫЕ СЕТИ, PYTHON, PYTORCH,
REACT, PANDAS, КЛИЕНТ-СЕРВЕРНОЕ
ПРИЛОЖЕНИЕ

REACT, PANDAS, CLIENT-SERVER
APPLICATION

<http://dx.doi.org/10.21515/1990-4665-211-013>

Введение

Современная финансовая система характеризуется высокой степенью нестабильности и подвержена множеству рисков, что обусловлено глобализацией рынков, ускорением цифровизации, а также увеличением объемов и скорости финансовых операций. В этих условиях особую значимость приобретает эффективный риск-менеджмент — совокупность методов и стратегий, направленных на выявление, оценку и снижение финансовых рисков. Одним из ключевых факторов повышения эффективности риск-менеджмента становится внедрение методов искусственного интеллекта (ИИ), в частности алгоритмов машинного обучения и глубинного обучения.

Для реализации поставленных задач используется стек технологий, включающий Python в качестве основного языка программирования для серверной логики и анализа данных. На стороне бэкенда применяются такие библиотеки, как PyTorch (для построения нейронных сетей), Pandas (для обработки и трансформации данных), а также ReportLab (для генерации отчетов). Клиентская часть реализуется с использованием React и jQuery, что обеспечивает интерактивность пользовательского интерфейса и возможность динамического взаимодействия с аналитической системой.

Методы исследования

Методологическая основа исследования базируется на междисциплинарном подходе, объединяющем принципы финансовой аналитики, прикладной математики, теории вероятностей и методов машинного обучения. При исследовании применяются как классические статистические модели, так и современные архитектуры нейронных сетей,

<http://ej.kubagro.ru/2025/07/pdf/13.pdf>

ориентированных на обработку структурированных и временных данных. Рассматриваются три основных направления: кредитные риски, инвестиционные риски и страховые риски, в каждом из которых предлагается использование аналитических и предиктивных моделей, построенных с применением современных технологий анализа данных.

Алгоритмы и модели машинного обучения

Для каждой категории рисков используются специализированные модели. Для анализа кредитных рисков в приложении применяются следующие модели и методики обучения нейронных сетей. Логистическая регрессия — базовая модель для бинарной классификации платежеспособности. Случайный лес и градиентный бустинг — для повышения точности скоринга. Нейронная сеть (MLP - multilayered perceptron) — для обработки сложных многомерных данных о заемщике. Предсказание PD (probability of default) и LGD (loss given default) осуществляется через регрессионные и классификационные модели, обученные на исторических данных о дефолтах.

Для анализа инвестиционных рисков в приложении применяются следующие модели и методики обучения нейронных сетей. Оценка VaR (Value at Risk) и CVaR (Conditional Value at Risk) — через методы исторического моделирования и Монте-Карло. Рекуррентные нейронные сети (RNN - Recurrent Neural Network, LSTM - Long Short-Term Memory) — для прогнозирования рыночных цен и анализа временных рядов. Метод главных компонент (PCA - Principal Component Analysis) — для анализа корреляций между активами в портфеле.

Для анализа страховых рисков в приложении применяются следующие модели и методики обучения нейронных сетей. Актуарные модели с распределениями Пуассона и Гамма для оценки страховых премий и вероятности наступления страхового случая. Деревья решений и методы аномалий — для выявления мошеннических схем в андеррайтинге.

Архитектура приложения

Разрабатываемое приложение представляет собой модульную информационно-аналитическую систему, включающую несколько компонентов. Сервис обработки данных — отвечает за предобработку, очистку и агрегацию финансовых данных, поступающих из внешних источников (например, базы данных заемщиков, котировки активов, страховые реестры). Сервис машинного обучения — реализует модели оценки различных видов риска с использованием машинного обучения. Основной сервер приложения — обеспечивает генерацию аналитических отчетов, графиков и таблиц, а также экспорт результатов в форматы PDF/Excel. Интерфейс взаимодействия с пользователем — реализован на React и предоставляет доступ к функционалу анализа через веб-интерфейс. Между модулями осуществляется обмен данными с помощью REST API. Серверная часть реализована с применением фреймворка Flask.

Методы тестирования

Для оценки корректности работы приложения и точности прогнозных моделей используются нижеперечисленные методы. Кросс-валидация — для оценки обобщающей способности моделей. Метрики классификации и регрессии — точность, полнота, F1-меры, ROC-AUC (Receiver Operating Characteristic – Area Under Curve) для задач бинарной классификации; MAE (Mean Absolute Error) и RMSE (Root Mean Square Error) — для регрессии. Стресс-тестирование — моделирование сценариев экономических шоков и проверка устойчивости моделей в нестабильной среде. Юзабилити-тестирование — анализ удобства и интуитивности пользовательского интерфейса конечного приложения.

Архитектура и техническая реализация программного продукта

Разрабатываемая информационно-аналитическая система управления финансовыми рисками представляет собой многоуровневое клиент-серверное приложение, обеспечивающее автоматизированный сбор,

обработку, анализ и визуализацию данных, необходимых для прогнозирования и минимизации рисков в трех ключевых направлениях: кредитных, инвестиционных и страховых. Архитектура системы построена по принципу модульности, что способствует масштабируемости и удобству внедрения новых функций.

Используемые технологии и программные компоненты

При проектировании системы был выбран стек технологий, обеспечивающий высокую гибкость, производительность и кроссплатформенность. Для бэкенд-стороны приложения (его серверной части) используются следующие компоненты. Python — основной язык программирования, отвечающий за реализацию логики обработки данных и построения моделей. PyTorch — фреймворк глубокого обучения, применяемый для создания и обучения нейронных сетей. Pandas и NumPy — библиотеки для манипуляции табличными данными и массивами. Scikit-learn — библиотека классических ML-алгоритмов (логистическая регрессия, SVM - Support Vector Machine, Random Forest и др.). Flask — микрофреймворк для разработки REST API и серверной логики. ReportLab — библиотека для генерации отчетов в формате PDF.

Для клиентской части приложения используются следующие технологии. React — библиотека JavaScript для построения пользовательского интерфейса. jQuery — применяется для работы с DOM и AJAX-запросами в рамках взаимодействия с API.

Организация клиент-серверного взаимодействия осуществляется по протоколу HTTP с использованием формата JSON. Серверный REST API предоставляет следующие функциональные конечные точки (эндпоинты).

/upload-data — загрузка и предобработка пользовательских данных;

/train-model — запуск процедуры обучения модели на сервере;

/get-predictions — получение прогнозов и аналитических метрик;

/generate-report — формирование и загрузка PDF-отчета;

Анализ данных

В контексте кредитного риска анализ данных направлен на построение надежных моделей оценки платежеспособности заемщиков, прогнозирование вероятности дефолта и управление просроченной задолженностью. Для этих целей применяется как классическая логистическая регрессия, так и более гибкие методы машинного обучения, включая ансамблевые алгоритмы и нейронные сети. Особое внимание уделяется формированию качественных выборок. Это позволяет создать адаптивные скоринговые системы, способные учитывать макроэкономические условия, сезонность и изменения клиентского поведения. Кроме того, интеллектуальные методы применяются для построения моделей оценки вероятности дефолта (PD) и потерь в случае дефолта (LGD), что важно для внутреннего рейтингового подхода к оценке капитала, соответствующего требованиям Базеля II и III.

Что касается инвестиционных рисков, анализ строится на обработке временных рядов и прогнозировании рыночных цен с учетом множества факторов. Здесь ключевую роль играют методы оценки стоимости под риском (VaR) и условной стоимости под риском (CVaR), а также стресс-тестирование, моделирующее поведение активов в условиях экстремальных экономических сценариев. Интеллектуальные системы позволяют выявлять сложные нелинейные зависимости между рыночными индикаторами, использовать методы машинного обучения для выявления кластеров активов и автоматизировать принятие решений по хеджированию рисков. Применение рекуррентных нейронных сетей (RNN, LSTM) дает возможность точно моделировать поведение активов во времени, что особенно важно при высокой чувствительности портфеля к краткосрочным изменениям рыночной конъюнктуры.

В области страховых рисков интеллектуальный анализ сосредоточен на актуарных расчетах и выявлении аномалий в заявках на страхование. Алгоритмы позволяют предсказывать вероятность наступления страхового события, определять размер предполагаемых выплат и оценивать финансовую устойчивость страховой организации. Особое внимание уделяется построению моделей на основе распределений вероятностей (Пуассон, Гамма, логнормальное распределение), а также применению методов классификации для выявления случаев мошенничества и ошибок в процессе андеррайтинга. Интеграция этих моделей в единую систему позволяет отслеживать динамику страховых резервов и оптимизировать политику переоценки тарифов и премий.

ИИ-подход к решению задачи управления рисками

Основу вычислительного ядра предлагаемого программного решения составляют алгоритмы предсказательного анализа, адаптированные под специфику кредитного, инвестиционного и страхового рисков. Применение алгоритмов машинного обучения обусловлено необходимостью анализа сложных, зачастую нелинейных взаимосвязей, которые слабо поддаются интерпретации классическими статистическими подходами.

На начальном этапе обработки данных выполняется предобработка и нормализация исходных массивов. Финансовые данные характеризуются высокой степенью зашумленности, наличием выбросов, пропущенных значений и мультиколлинеарных признаков. Для повышения качества моделей применяется процедура отбора признаков (feature selection), в том числе с использованием методов взаимной информации, важности признаков в ансамблях деревьев (например, в Random Forest) и регуляризаций (L1, L2).




Рисунок 1 – Алгоритм случайного леса

В целях устранения дисбаланса классов, особенно актуального при моделировании дефолтов или страховых случаев, используются методы балансировки, такие как SMOTE (Synthetic Minority Oversampling Technique) или модифицированные версии ресемплинга.

Ключевыми алгоритмами, реализуемыми в программной системе, являются логистическая регрессия, решающие деревья, случайный лес, градиентный бустинг (XGBoost - Extreme Gradient Boost), а также методы опорных векторов (SVM) и наивные байесовские классификаторы.

Логистическая регрессия, как один из базовых инструментов, применяется преимущественно в скоринговых моделях благодаря своей интерпретируемости и устойчивости. Более сложные ансамблевые методы, такие как бустинг, позволяют достигать более высокой точности предсказания за счёт интеграции слабых моделей в единую сильную композицию.

При анализе инвестиционных рисков значительное внимание уделяется работе с временными рядами. Для построения прогностических моделей цен и индексов используются методы ARIMA и Prophet, а также рекуррентные нейронные сети (LSTM), способные учитывать долгосрочные зависимости. При этом особая роль отводится формированию обучающих выборок с учетом скользящих окон (rolling windows) и перекрестной валидации во времени (time series cross-

validation), что критично для обеспечения реалистичной оценки качества модели на исторических данных.



Рисунок 2 – Алгоритм XGBoost

В страховой аналитике применяются как регрессионные модели (например, гамма-регрессия и GLM — Generalized Linear Models), так и классификационные подходы для выявления мошенничества. Здесь важна возможность работы с категориальными признаками (например, тип транспортного средства, регион, возраст страхователя), что реализуется либо через one-hot encoding.

Особого внимания заслуживает интерпретируемость моделей, особенно в области финансов, где модели подвергаются контролю со стороны регуляторов. В преект интегрированы методы интерпретации, такие как SHAP (SHapley Additive exPlanations) и LIME (Local Interpretable Model-agnostic Explanations), позволяющие объяснить вклад отдельных признаков в принятие решения. Это особенно важно при оценке кредитного рейтинга клиента или принятии решения по страховой выплате.

Архитектура MLP

Одной из базовых архитектур глубокого обучения, применяемых в разрабатываемом программном продукте, является многослойный персептрон (MLP). MLP демонстрирует высокую эффективность при решении задач классификации и регрессии, в которых входные данные представлены в виде фиксированных векторов признаков. Такой подход оказывается особенно полезным при анализе кредитных, страховых и

инвестиционных рисков, где данные структурированы и имеют табличную природу.

Модель MLP в контексте проекта реализуется как последовательность полносвязных слоев, между которыми используются нелинейные функции активации, что позволяет аппроксимировать сложные зависимости между входными и выходными переменными. Типичная архитектура включает входной слой, принимающий вектор признаков (например, сведения о заемщике, параметры облигации, страхового полиса и др.), несколько скрытых слоев с функциями активации ReLU (Rectified Linear Unit), и выходной слой, специфичный для решаемой задачи: сигмоидальный выход при бинарной классификации (предсказание дефолта) и линейный — для задач регрессии (прогноз LGD или ожидаемой выплаты по страховому событию).

Пример конфигурации MLP для задачи оценки кредитного риска может включать входной вектор размерности 30–100 признаков, два или три скрытых слоя размерностью 128–64–32 нейрона соответственно, с последующей дропаут-регуляризацией (Dropout 0.3–0.5) для борьбы с переобучением. Для ускорения сходимости и повышения стабильности обучения применяется пакетная нормализация (Batch Normalization) после каждого скрытого слоя.




Рисунок 3 – Модель MLP

Перед подачей данных в MLP осуществляется их масштабирование (MinMax или StandardScaler), а категориальные признаки кодируются с использованием техники one-hot. Такое представление позволяет эффективно сократить размер входного пространства и повысить качество обобщения модели. Обучение модели происходит на тренировочной выборке с валидацией по метрикам, соответствующим типу задачи: F1-score, AUC-ROC и LogLoss для классификации; MAE и RMSE — для регрессии. Кроме того, используются техники ранней остановки (early stopping) для предотвращения переобучения, а также механизмы сохранения наилучшего состояния модели по результатам валидационного прогона.

Преимущество MLP в рамках данной системы заключается в его универсальности и способности обрабатывать гетерогенные по типу и масштабу признаки, что особенно актуально для кредитных и страховых данных. Архитектура показывает высокую эффективность при анализе "снимков" состояния объектов — клиентов, активов или страховых случаев — на фиксированные моменты времени.

Заключение

Развитие интеллектуальных технологий и методов анализа данных оказывает значительное влияние на трансформацию подходов к управлению финансовыми рисками. В представленной работе была рассмотрена концепция построения модульной информационной системы, объединяющей три ключевых направления: управление кредитными, инвестиционными и страховыми рисками. Предложенное решение базируется на использовании современных методов машинного обучения, включая логистическую регрессию, градиентный бустинг, методы обработки временных рядов и архитектуры глубоких нейронных сетей, в частности многослойных персептронов.

Используемая архитектура приложения адаптивность и возможность масштабирования системы, применения различных аналитических моделей, а также интеграции новых источников данных. В результате удаётся обеспечить как высокую точность прогнозирования, так и соответствие регуляторным требованиям, включая интерпретируемость решений и устойчивость к переобучению. Разработанная система, интегрированная в инфраструктуру банковских, инвестиционных и страховых организаций для автоматизации анализа рисков, повысит надёжность финансовых операций и устойчивость бизнес-процессов.

ЛИТЕРАТУРА

1. Остроух А.В., Суркова Н.Е. Проектирование информационных систем. СПб.: Лань, 2019. 364 с.
2. Гарькавый К. А., Бегдай С. Н. Анализ эффективности микроклимата помещения // Энергосбережение и водоподготовка. 2006. № 6(44). С. 76-77.
3. Оцоков Ш. А., Чельшев Э. А., Шибитов Д. В., Раскатова М. В. Разработка программно-аппаратного комплекса сбора и хранения данных термометрии // Инженерный вестник Дона, 2022, No 2. URL: ivdon.ru/ru/magazine/archive/n2y2022/7436.
4. Добробаба, Ю. П. Анализ переходных характеристик системы шестого порядка с кратными корнями характеристического уравнения / Ю. П. Добробаба, А. Г. Мурлин, А. Д. Серкин // Наука. Техника. Технологии (политехнический вестник). – 2019. – № 1. – С. 430-437. – EDN WAMJVI.
5. Добробаба, Ю. П. Анализ переходных характеристик системы второго порядка с кратными корнями характеристического уравнения / Ю. П. Добробаба, А. Г. Мурлин, А. Д. Серкин // Наука. Техника. Технологии (политехнический вестник). – 2019. – № 1. – С. 405-410. – EDN QFPFBX.

REFERENCES

1. Ostrouh A.V., Surkova N.E. Proektirovanie informacionnyh sistem. SPb.: Lan', 2019. 364 s.
2. Gar'kavyj K. A., Begdaj S. N. Analiz jeffektivnosti mikroklimata pomeshhenija // Jenergosberezhenie i vodopodgotovka. 2006. No 6(44). S. 76-77.
3. Ocokov Sh. A., Chelyshev Je. A., Shibitov D. V., Raskatova M. V. Razrabotka programmno-apparatnogo kompleksa sbora i hranenija dannyh termometrii // Inzhenernyj vestnik Dona, 2022, No 2. URL: ivdon.ru/ru/magazine/archive/n2y2022/7436.
4. Dobrobaba, Ju. P. Analiz perehodnyh harakteristik sistemy shestogo porjadka s kratnymi kornjami harakteristicheskogo uravnenija / Ju. P. Dobrobaba, A. G. Murlin, A. D. Serkin // Nauka. Tehnika. Tehnologii (politehnicheskij vestnik). – 2019. – № 1. – S. 430-437. – EDN WAMJVI.
5. Dobrobaba, Ju. P. Analiz perehodnyh harakteristik sistemy vtorogo porjadka s kratnymi kornjami harakteristicheskogo uravnenija / Ju. P. Dobrobaba, A. G. Murlin, A. D. Serkin // Nauka. Tehnika. Tehnologii (politehnicheskij vestnik). – 2019. – № 1. – S. 405-410. – EDN QFPFBX.