УДК 004.8:368
DOI: 10.26102/2310-6018/2026.62.11.010

Поддержка принятия решений в прогнозно-аналитической страховой системе

А.В. Калач[1], И.А. Матыцина[1]✉, Ю.Н. Золотарев[1], В.В. Здольник[2]

[1]Воронежский институт ФСИН России, Воронеж, Российская Федерация
[2]МИРЭА – Российский технологический университет, Москва, Российская Федерация

Резюме. В статье рассматриваются особенности разработки прогнозно-аналитической системы для оценки страховых рисков. Традиционные методы систем оценки рисков и надежности потенциальных клиентов часто не справляются с точностью расчетов. Существующие исследования опираются на небольшие или синтетические наборы данных, что приводит к получению существенно завышенных результатов. В статье представлено описание особенностей использования больших анонимизированных массивов данных в прогнозно-аналитической страховой системе для повышения точности предсказания убытков без увеличения операционных расходов. Цель исследования – повышение эффективности оценки страховых случаев за счет внедрения системы прогнозирования убытков без увеличения операционных расходов. Для достижения поставленной цели была предложена архитектура системы поддержки принятия решений на основе прогнозной аналитики в страховании, включающая семь слоев: от безопасной загрузки сырых данных до финального модуля интерпретации результатов. Безопасность данных обеспечивали путем шифрования по протоколу SHA-256 и использования необратимых хеш-функций, что исключает восстановление исходной персональной информации при утечке. В основе математического аппарата больших анонимизированных массивов данных в прогнозно-аналитической страховой системе находились ансамблевые методы машинного обучения. Для сглаживания весов признаков использовали Ridge-регрессию и для решения задач классификации, регрессии и ранжирования данных применяли XGBoost.

Ключевые слова: прогнозная аналитика, ансамблевые методы машинного обучения, принятие решений, оценка страховых рисков, прогнозирование убытков.

Для цитирования: Калач А.В., Матыцина И.А., Золотарев Ю.Н., Здольник В.В. Поддержка принятия решений в прогнозно-аналитической страховой системе. *Моделирование, оптимизация и информационные технологии.* 2026;14(11). URL: https://moitvivt.ru/ru/journal/article?id=2665
DOI: 10.26102/2310-6018/2026.62.11.010

Decision support in a predictive-analytic insurance system

A.V. Kalach[1], I.A. Matytsina[1]✉, Yu.N. Zolotaryov[1], V.V. Zdolnik[2]

[1]Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, the Russian Federation
[2]MIREA – Russian Technological University, Moscow, the Russian Federation

Abstract. This article examines the development of a predictive-analytical system for assessing insurance risks. Traditional methods for assessing risk and the reliability of potential clients often fail to ensure calculation accuracy. Existing studies rely on small or synthetic datasets, leading to significantly inflated results. The article describes the use of large anonymized datasets within an insurance predictive-analytical system to improve loss prediction accuracy without increasing operational costs. The study aims to enhance the efficiency of insurance claim assessment by implementing a loss forecasting system that does not raise operational expenses. To achieve this, the authors proposed a decision-support system architecture based on predictive analytics for insurance,

© Калач А.В., Матыцина И.А., Золотарев Ю.Н., Здольник В.В., 2026

comprising seven layers – ranging from the secure ingestion of raw data to the final results interpretation module. Data security was ensured through SHA-256 encryption and the use of irreversible hash functions, which preclude the recovery of original personal information in the event of a data breach. Ensemble machine learning methods formed the mathematical foundation for processing large anonymized datasets within the system. Ridge regression was employed to smooth feature weights, while XGBoost was used to address data classification, regression, and ranking tasks.

Keywords: predictive analytics, ensemble machine learning methods, decision making, insurance risk assessment, loss forecasting.

For citation: Kalach A.V., Matytsina I.A., Zolotarev Yu.N., Zdolnik V.V. Decision support in a predictive-analytic insurance system. *Modeling, Optimization and Information Technology.* 2026;14(11). (In Russ.). URL: https://moitvivt.ru/ru/journal/article?id=2665 DOI: 10.26102/2310-6018/2026.62.11.010

Введение

В условиях неуклонного роста мировой экономики страховая отрасль стремительно движется к повышению конкурентоспособности и прибыльности. Поддержка принятия решений (СППР) в прогнозно-аналитической страховой системе включает комплекс технологий и алгоритмов, который помогает страховым компаниям минимизировать риски, автоматизировать рутинные процессы и повышать точность прогнозов за счет анализа больших данных (Big Data) и машинного обучения (ML) [1].

Необходимо отметить, что страховые компании сталкиваются с проблемой предоставления передовых решений с использованием методов искусственного интеллекта и машинного обучения для эффективного установления цен и обработки страховых случаев [2].

Кроме того, в современную эпоху, когда данные считаются новой нефтью, обширные хранилища данных страхового сектора предоставляют подходящую среду для применения решений на основе больших данных [3].

Традиционно страховые компании использовали актуарные таблицы и сложные процедуры, основанные на правилах, для оценки страховых заявок, полагаясь на экспертизу актуариев. Хотя эти методы часто были точными, они требовали значительных трудозатрат и субъективных оценок, что приводило к задержкам в оформлении полисов автострахования.

Для решения этой задачи традиционно применяют методы машинного обучения, предиктивную аналитику для точной оценки страховых заявок. Прогностические модели могут выявлять лиц, наиболее склонных к подаче страховых претензий, что обеспечивает справедливое ценообразование, гибкость, точность и предотвращение дискриминации. Однако до сих пор существует неопределенность относительно наилучших прогностических моделей для таких целей. Существующая литература преимущественно фокусируется на использовании небольших наборов данных с ограниченным набором признаков и неанонимных наборов данных, что может привести к потенциальным искажениям. Немногие исследования рассматривали большие анонимные наборы данных, которые часто страдают от методологических ограничений, таких как неоптимальный выбор признаков, настройка гиперпараметров и неадекватные прогностические модели.

Используя большие анонимные массивы данных и оптимизируя прогностические модели, исследование направлено на разработку более точного и эффективного метода оценки рисков и установления страховых премий. Такой подход не только повышает конкурентоспособность и прибыльность страховых компаний и эффективность страхования.

Цель работы – повышение эффективности оценки страховых случаев за счет внедрения системы прогнозирования с применением методов машинного обучения.

Для достижения поставленной цели сформулированы следующие задачи:

1. Составить математическую модель применимую для страховой системы, основываясь на формулах, используемых в области урегулирования убытков и оценки наступления страховых событий.

2. Разработать модель страховой системы, определив у нее методы сбора и предобработки данных, модели для прогнозирования вероятностей, визуализация аналитических результатов.

3. Реализовать страховую систему с применением актуальных технологий.

Новизна исследования заключается в разработке комплексной архитектуры прогнозно-аналитической системы, адаптированной под специфику анонимизированных страховых данных.

Для анонимизации данных этого потребуется создание кода шифрования, который будет генерироваться из комбинации хеш-значений и потокового шифра. Хэш-функция будет преобразовывать длинную строку символов в данные определенной длины. Такое значение является результатом необратимых функций, поэтому исходные данные не могут быть восстановлены. Необходимо минимизировать риск, создав для начала первичный ряд, чтобы ограничить длину под определенный диапазон. После чего применять хеш-функцию для генерации вторичного ряда [4].

Прогнозно-аналитические модели могут выявлять страхователей, которые будут более склонны к подаче страховых претензий, что позитивно скажется на управлении капиталом. Многие исследования, проведенные в области страхования, оперируют небольшими и не анонимными наборами данных. Такие наборы в основном составлены из синтетических данных, что не позволяет корректно обучать модели, и приводит к заведомо завышенным результатам. Очень мало кто рассматривал большие анонимные наборы данных, которые часто страдают от методологических ограничений, таких как неоптимальный выбор признаков, настройка гиперпараметров и неадекватные прогностические модели. Построение прогнозно-аналитической системы с более точным методом оценки страховых рисков, является главной задачей, поставленной в работе.

Материалы и методы

Рассмотрим возможности двух традиционных методов – Cross-Industry Standard Process for Data Mining (CRISP-DM), Team Data Science Process (TDSP). Важная особенность CRISP-DM заключается в фокусировке внимания к бизнес-целям компании. Такой подход позволяет руководству воспринимать проекты по анализу данных как полноценную часть бизнес-процессов компании. Необходимо отметить, что метод позволяет подробное документирование каждого шага. Согласно CRISP-DM аналитический проект состоит из шести основных этапов [5, 6].

Задачу с прогнозированием объема выплат лучше выполняет XGBoost и Ridge регрессия. Распишем оба этих метода подробнее.

Метод Ridge позволяет добавлять штраф, пропорциональный квадрату значений весов. Он не обнуляет веса, а уменьшает их, чтобы сгладить большие значения. Данный метод будет полезен, потому что в страховых данных, которые используем в работе, нет необходимости в отбрасывании признаков. Почти все признаки вносят свою пользу в результат. Рассмотрим формулу функции потерь:

$$L(\beta) = \sum_{i=1}^{n}(y_i - x_i^T \beta)^2 + \lambda \sum_{j=1}^{p} \beta_j^2, \quad (1)$$

где $\sum_{i=1}^{n}(y_i - x_i^T \beta)^2$ – стандартная сумма квадратов ошибок; λ – параметр регуляризации, определяющий силу штрафа; $\sum_{j=1}^{p} \beta_j^2$ – L2 норма весов коэффициентов.

Обучение с помощью ансамблей дает более корректный результат, потому что он объединяет в себе преимущества нескольких моделей сразу, максимизируя эффект от их использования[1].

Суть ансамблевого метода в том, что сначала запускается модель и получается некий результат. Затем определенные точки классифицируются как верные, а остальные неправильные. После чего, добавляем больший вес тем точкам, которые классифицированы неправильными, и запускаем модель заново [7, 8]. Процесс продолжается и создается несколько моделей, где каждая корректирует ошибки предыдущей. При построении моделей с использованием градиентного ансамблевого метода, необходимо рассмотреть процесс данного обучения:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i), \tag{2}$$

где $\hat{y}_i^{(t)}$ – итоговое предсказание системы для объекта i после построения t деревьев; $\hat{y}_i^{(t-1)}$ – предсказание, которое мы получаем на предыдущей итерации; $f_t(x_i)$ – новая функция, которая добавляется на текущем шаге для исправления ошибок предыдущих моделей.

Случайный лес использует ансамбль деревьев решений, которые создаются на случайно разделенном наборе данных. Совокупность деревьев-классификаторов образует лес. Причем каждое дерево решений образуется с использованием метрик отбора показателей. В случае с регрессией конечным результатом считается среднее значение всех выходных данных ансамбля[2] [9]. Метод включает следующие четыре этапа:

– создание случайное выборки из заданного набора данных;
– у каждой выборки строиться дерево решений и, используя данное дерево, получаем результат предсказания;
– далее происходит голосование за каждый полученный прогноз;
– выбираются предсказания с наибольшим количеством голосов в качестве конечного результата.

При классификации формула случайного леса принимает следующий вид:

$$P(c|x) = \frac{1}{n}\sum_{i=1}^{n} P_i(c|x), \tag{3}$$

где $P(c|x)$ – итоговая вероятность того, что x принадлежит к классу c; $P_i(c|x)$ – вероятность класса c, которая была предсказана i деревом; n – количество деревьев.

Основная идея SVM заключается в поиске гиперплоскости, разделяющей классы благоприятным исходом, а расположенные ближе всего к разделяющей гиперплоскости варианты называются опорными векторами. Лучшим разделением классов будет то, при котором максимизируется расстояние между опорными векторами и разделяющей гиперплоскостью. Такое расстояние называется зазором [10].

Важно для SVM рассмотреть принцип максимизации разделяющей полосы. Уравнение разделяющей гиперплоскости:

$$\omega x + b = 0, \tag{4}$$

[1] *Системы поддержки принятия решений: что решает СППР?* Единая экосистема банковских приложений FIS (Финансовые информационные системы). URL: https://fisgroup.ru/blog/fis-dss/ (дата обращения: 05.09.2026).

[2] *Обзор ключевых показателей деятельности страховщиков за 2021–2024 годы.* Банк России. URL: https://cbr.ru/analytics/insurance/overview_insurers/ (дата обращения: 05.09.2026).

где x – входной вектор; ω – весовой вектор; b – смещение.

Метод опорных векторов в системе страхования жизни будет работать по следующему алгоритму:

1. Алгоритм видит каждого клиента как точку в многомерном пространстве, где каждый признак клиента – это свое измерение. Он делает поиск наиболее сложных кандидатов.

2. Метод проводит границы таким образом, чтобы расстояние от нее до ближайших точек обоих классов было максимальным, потому что в страховании, чем шире расстояние между классами, тем меньше вероятность, что компания ошибется и присвоит низкий тариф человеку [11].

После детального анализа методов необходимо обосновать метрики, которые отражены в Таблице 1.

Таблица 1 – Целевые значения метрик
Table 1 – Target metric values

Тип метрик	Метрика	Целевое значение	Обоснование выбора для страховой системы
Точность при классификации	F1	≥ 0,85	Равновесие между полнотой и точностью, чтобы уменьшить пропуск страховых случаев
Точность при прогнозе убыточности	R^2	≥ 0,80	Система должна построить прогноз близкий к предполагаемому значению, с учетом колебаний в сумме страховых убытках
Ошибка оценки	MAE	< 15 % от суммы	Отклонение прогноза от выплаты, которую осуществит убытчик, не должно превышать финансовый риск.
Надежность	AUC-ROC	≥ 0,90	Разработанная страховая система должна корректно разделять клиентов на высоко убыточных и низко убыточных, чтобы дальнейшее решение по страхователю было на уровне руководства

Целевое значение выбрано исходя из заданной погрешности страховых данных.

Результаты

Этапы разработки прогнозно-аналитической системы. Система строится на многоуровневом принципе и охватывает большинство этапов работы с данными. Каждый из них должен проходить процесс в полной мере, чтобы минимизировать риски утечки данных, а также потенциальные проблемы с прогнозированием. Они могут возникать из-за неправильной работы любого из предыдущих этапов системы, поэтому требуется сопровождать каждый процесс визуальной составляющей.

1. Бизнес-анализ (выполняется предсказание наступления страховых случаев, а также потенциальных убытков с использованием данных о страхователях; оценка качества результатов будет выполнена при помощи технических метрик).

2. Анализ данных (данные извлекаются из отчетов, которые, в свою очередь, выгружаются из БД статистических систем отдела, занимающегося работой с несчастными случаями).

3. Подготовка данных (после первичного анализа целостности данных производится их отсеивание, чтобы в дальнейшем получить высокую точность предсказаний).

4. Моделирование (выбрана стратегия разделения задачи на две параллельные ветки – проектирование логики предсказания факта наступления случая через классификацию и проектирование логики оценки размера потенциального убытка в рублях через регрессию). Данные будут разбиты на тренировочную выборку, которая будет учить модель и на тестовую выборку для проверки итоговых результатов.

5. Оценка решений (интерпретируемость данных). Помимо предсказания системой выполняется построение модуля, отвечающего за причинно-следственную связь этого результата.

6. Мониторинг (отслеживание полученного результата, чтобы вовремя переобучать систему при изменениях внешних условий; проверяется стабильность инфраструктуры, где учитывается скорость выполнения прогноза, и насколько система технически соответствует требуемым мощностям).

Пошаговый план в рамках выбранной методологии продемонстрирован на Рисунке 1.

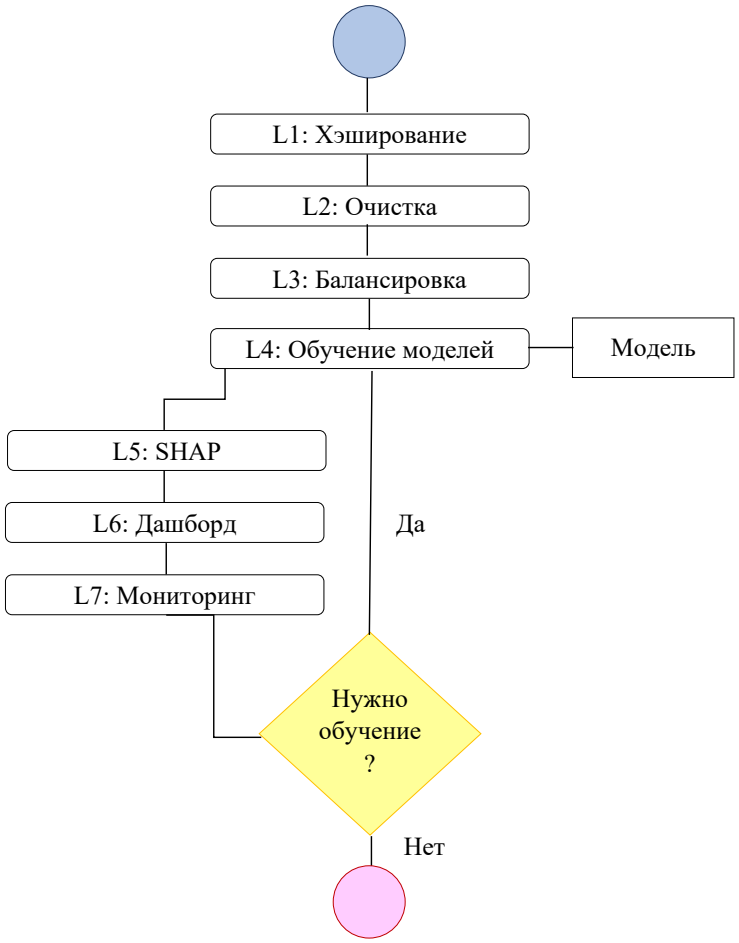


Рисунок 1 – Методология CRISP-DM в рамках страхования от несчастных случаев
Figure 1 – CRISP-DM methodology in accident insurance

После разбора структуры организма системы рассмотрим, как она будет функционировать через диаграмму последовательности на Рисунке 2.

Все начинается с взаимодействия пользователя и интерфейса. Андеррайтер загружает сырые данные из системы. Система не начнет анализ, пока данные не будут детерминированы и зашифрованы по протоколу SHA-256. Такой подход является гарантом безопасности при утечке данных.

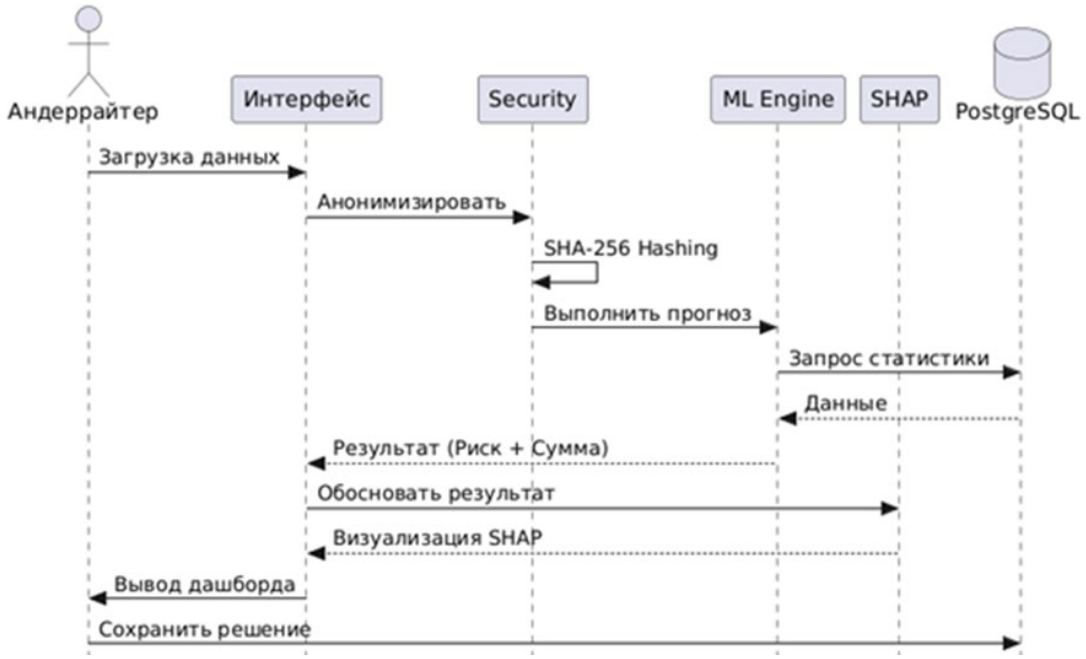


Рисунок 2 – Диаграмма последовательности
Figure 2 – Sequence diagram

Далее модуль делает запрос для получения актуальных весов моделей и коэффициентов, которые были рассчитаны на этапе моделирования. На данном этапе происходит последовательное решение двух задач, связанных с классификацией риска и оценкой убыточности.

В результате построена система, которая ускорила процесс принятия решения для сотрудников андеррайтинга. Система состоит из 7 слоев, каждый из которых играет важную роль при анализе данных.

На первом слое был выполнен процесс анонимизации данных. Происходит проверка на пустые данные, чтобы не хешировать данные, которые отсутствуют. После того, как все необходимые поля были успешно анонимизированы, выполняется следующий слой, где данные подготавливаются и отбираются целевые компоненты. В блоке очистки колонки переименовываются по словарю из конфигурации, чтобы можно было принимать файлы с разными заголовками и приводить их к единой норме.

После удаляются колонки с одним уникальным значением и дубликаты при импорте таблицы. Далее выполняется нормализация полей, которые могу содержать лишние слова и другие элементы, а также разбор числовых строк из строковых форматов в числовые. Это является важным этапом, потому что напрямую влияет на дальнейший процесс обучения.

Следующий блок выполняет отбор признаков, которые известны на момент подачи заявки. После обработки сырых данных, наблюдаем проблему, которая связана с балансом классов. Система распознает помимо выплат и отказов другие статусы заявки, но для прогнозов они не будут нужны из-за своей неопределенности. Из-за статистически низкого процента страховых случаев модель может обучиться только на мажоритарном наборе данных, что сделает прогноз заведомо ложным.

Слой использует несколько вариантов балансировки, чтобы определить, какой из методов справится с задачей более успешно. Выбор метода также может происходить автоматически, чтобы пользователь, который будет пользоваться системой, мог быстро построить прогноз.

Автоматический вариант проверяет, в норме дисбаланс или нет. Если в норме, то данные возвращаются без изменений, а если нет, то применяется стратегия smote, как автоматически выбранная для данного варианта прогноза.

Пользователь также может сам выбрать метод и посмотреть, на каком из них результат его больше удовлетворит. Пример того, как выглядят данные после балансировки, находятся на Рисунке 3.

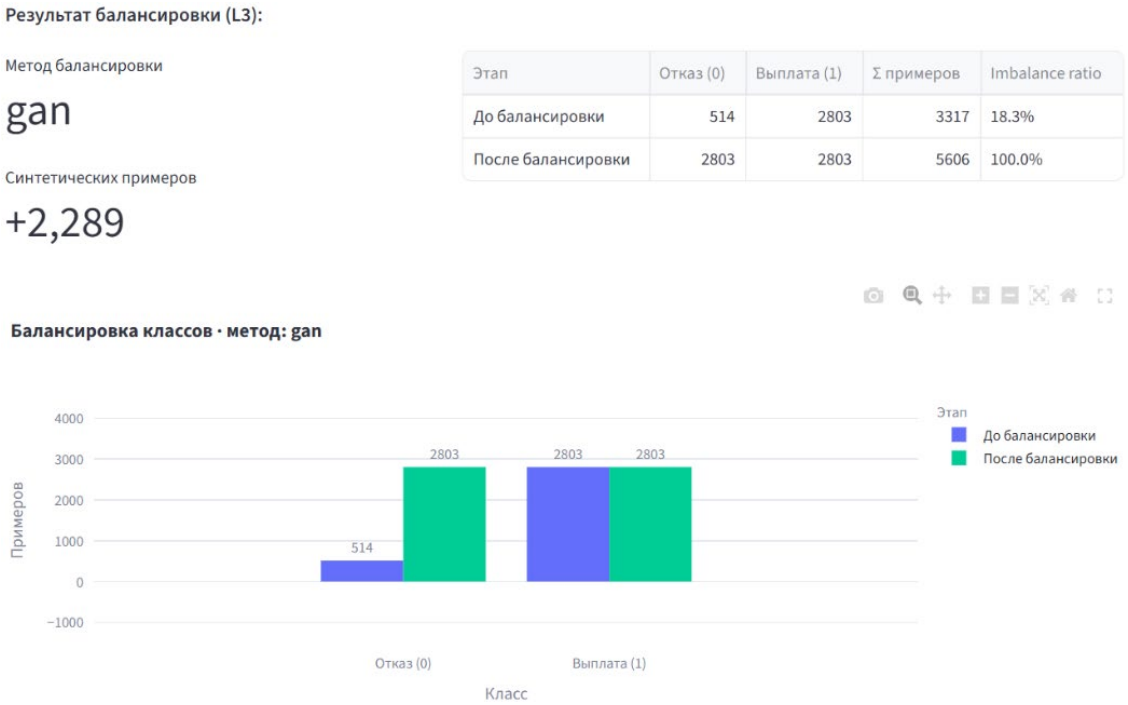


Рисунок 3 – Данные до и после балансировки
Figure 3 – Data before and after balancing

Для более точного сравнения с фактическими данными добавлена возможность ограничения списка договоров по годам на Рисунке 4.

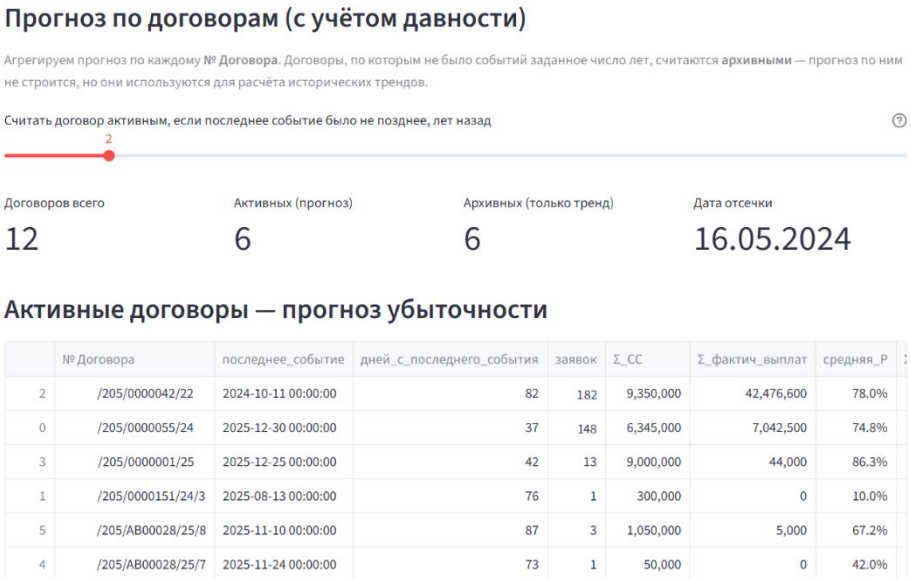


Рисунок 4 – Ограничение выборки договоров
Figure 4 – Limiting the sample of contracts

Блок системы подразумевает обучения модели на тех данных, которые будут актуальнее для андеррайтера, поэтому он может ограничить спектр годов, по которым модель обучается. По умолчанию это значение имеет промежуток в 2 года.

Обсуждение

После нескольких итераций и перебора моделей и гиперпараметров получилось найти оптимальное решение, которое имеет ошибку в пределах допустимого значения. В случае со страхованием от несчастных случаев погрешность, которая не превышает 10 %, является допустимой.

Модель оценивает каждую заявку в 77 % вероятности выплаты и это имеет логическое объяснение, потому что при балансировке мы заметили, что доминирующее число заявок имело статус выплаты [11]. Необходимо подкрепить весь этот процесс жизненным циклом страховой заявки, который продемонстрирован на Рисунке 5.

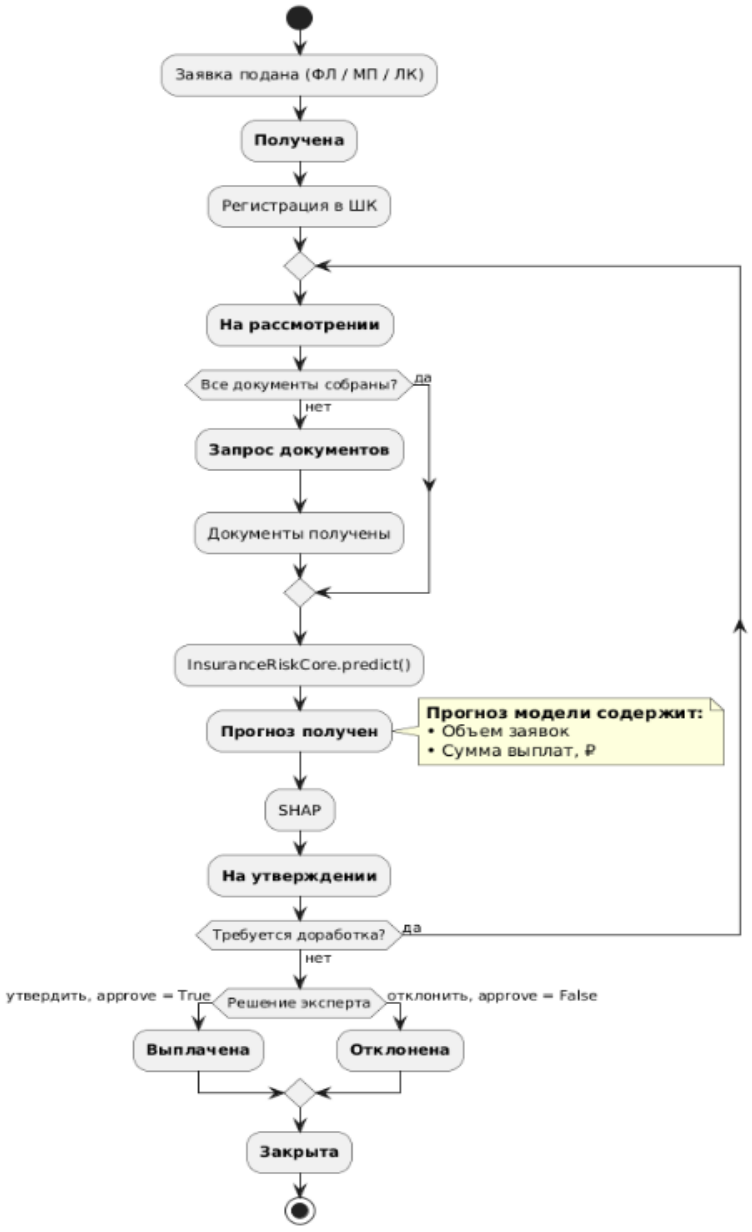


Рисунок 5 – Диаграмма состояний
Figure 5 – State diagram

Диаграмма показывает весь жизненный цикл страховой заявки. Бизнес-процесс включает момент подачи заявки до ее закрытия. Корректно размечен момент, при котором начинает работать модель и как замыкается обратная связь. Также мы видим запрос недостающих документов, который в реальной практике очень часто происходит [11]. При получении прогноза эксперт, который занимается убытками, решает, насколько потенциально выгодно сохранять данного клиента и стоит ли делать операционные расходы времени на взаимодействие с ним.

Сравним полученную систему с существующими аналогами на рынке страхования. На отечественном рынке почти все решения в области страхования и систем, которые выполняют задачи страхового прогнозирования, имеют закрытый характер. Пример существующих систем продемонстрирован в Таблице 2.

Таблица 2 – Сравнение разработанной системы с аналогами
Table 2 – Comparison of the developed system with analogues

Аналог	Тип	Решаемые задачи	Набор моделей	Визуализация
Akur8	Коммерческая	Тарификация, GLM-автоматизация	Transparent ML на базе обобщённых аддитивных моделей	Облачный дашборд
Guidewire Predictive Analytics	Коммерческая	Андеррайтинг, обработка убытков	Random Forest, GBM, нейросети; SHAP в новых версиях	Веб-консоль для андеррайтеров
Скоринг страховых рисков	Коммерческая	Классификация выплат/отказов и регрессия суммы убытка	SVM, RF, XGBoost, Logistic Regression, Ridge SHAP	Streamlit-дашборд с интерактивным прогнозом и сравнением с актуарной формулой

Коммерческие платформы, которые указаны в первых двух строках, охватывают почти весь процесс страхования. Здесь также сложно определить, какие методы и слои имеет система. Такие системы эффективно работают, когда объем застрахованных людей близиться к сотням тысяч лиц.

Разработанная система по своей структуре также более склонна иметь коммерческий характер. Система отличается прозрачностью кода и проверкой каждого слоя работы. Целевым клиентом для такой системы является страховщик со средним числом полисов в пределах нескольких десятков тысяч.

Заключение

По результатам проведенного исследования при построении прогноза о количестве выплат конкретного страхователя, получили объем заявок, близкий к фактическому результату. Ошибка моделирования не превысила 5 %. Необходимо отметить, что модель выполнила небольшую переоценку страхового портфеля клиента. Страховщик сможет эффективнее диверсифицировать портфель, чтобы оставлять прибыльных страхователей и тех, кто напрямую влияет на убыточность компании.

При построении прогноза о потенциальной величине убытка, который принесет определенный страхователь, модель недооценивает суммарную выплату. Получается, что в распределении убытков есть слой крупных страховых случаев, которые регрессор не до конца способен уловить. Установлено, что модели на средних значениях данных

склонны занижать результат. При классификации наблюдалась переоценка, а в регрессии – недооценка, поэтому можно сказать, что это не системное смещение в одну сторону, а две независимые погрешности. Практическим результатом стала система, оценивающая вероятность выплаты с точностью до 77 %. Предложенное численное решение выгодно отличается прозрачностью кода и доступностью визуализации через интерактивные дашборды. Предложенный подход делает продвинутую аналитику доступной для средних компаний. Необходимо отметить, что внедрение такой системы позволит снять с экспертов рутинную работу по мелким договорам и эффективнее распределять ресурсы, отсекая клиентов, напрямую влияющих на убыточность бизнеса.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Acciarini Ch., Cappa F., Boccardelli P., Oriani R. How can organizations leverage big data to innovate their business models? A systematic literature review. *Technovation*. 2023;123:102713. https://doi.org/10.1016/j.technovation.2023.102713
2. Dwivedi Y.K., Sharma A., Rana N.P., Giannakis M., Goel P., Dutot V. Evolution of artificial intelligence research in Technological Forecasting and Social Change: Research topics, trends, and future directions. *Technological Forecasting and Social Change*. 2023;192:122579. https://doi.org/10.1016/j.techfore.2023.122579
3. Jaiswal R., Gupta Sh., Tiwari A.K. Big data and machine learning-based decision support system to reshape the vaticination of insurance claims. *Technological Forecasting and Social Change.* 2024;209:123829. https://doi.org/10.1016/j.techfore.2024.123829
4. Каширская Л.В., Тургаева А.А. *Внутренний контроль в страховых компаниях. Легко и надежно*. Москва: Русайнс; 2021. 355 с.
5. Chen T., Guestrin C. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2016), 13–17 August 2016, San Francisco, CA, USA*. New York: ACM; 2016. P. 785–794. https://doi.org/10.1145/2939672.2939785
6. Овсянников А.В., Барашко О.Г. Оценка эффективности программных математических средств технической поддержки принятия решений. В сборнике: *Организационно-техническое управление в межотраслевых комплексах: Материалы Международной научно-технической конференции, 28–29 октября 2004 года, Минск, Беларусь*. Минск: Белорусский государственный технологический университет; 2004. С. 244–245.
7. Зиатдинова З.Л. Математика страхования: расчет страховых взносов. В сборнике: *Проблемы развития малого и среднего бизнеса в сельском хозяйстве в условиях цифровой экономики: Материалы III Международной научно-практической конференции: Том 2, 20–21 мая 2025 года, Казань, Россия*. Казань: Казанский государственный аграрный университет; 2025. С. 98–103.
   Ziatdinova Z.L. Mathematics of insurance: calculation of insurance premiums. In: *Problems of Small and Medium-Sized Business Development in Agriculture in the Context of the Digital Economy: Proceedings of the III International Scientific and Practical Conference: Volume 2, 20–21 May 2025, Kazan, Russia.* Kazan: Kazan State Agrarian University; 2025. P. 98–103. (In Russ.).
8. Кондрашов А.А., Курашов М.М., Лоскутова Е.Е. Использование данных медицинских информационных систем для разработки персонализированных продуктов лекарственного страхования: моделирование архитектурной концепции. *Вестник Смоленской государственной медицинской академии*. 2025;24(1):253–261. https://doi.org/10.37903/vsgma.2025.1.36
   Kondrashov A.A., Kurashov M.M., Loskutova E.E. Use of medical information systems data for developing personalized pharmaceutical insurance products: architectural

modeling. *Vestnik of the Smolensk State Medical Academy*. 2025;24(1):253–261. (In Russ.). https://doi.org/10.37903/vsgma.2025.1.36

9. Степанова М.Н., Гавриленко Ж.А. Оценка средств поддержки принятия решений, связанных с формированием обоснованного страхового портфеля домохозяйств. *Журнал прикладных исследований*. 2023;(11):49–54.
Stepanova M.N., Gavrilenko Zh.A. Assessment of decision support tools related to the formation of a sound household insurance portfolio. *Journal of Applied Research*. 2023;(11):49–54. (In Russ.).
10. Кувайскова Ю.Е. Применение ансамблевых методов машинного обучения для прогнозирования технического состояния объекта. *Известия Самарского научного центра РАН*. 2021;23(1):111–114. https://doi.org/10.37313/1990-5378-2021-23-1-111-114
Kuvayskova Yu.E. Application of ensemble machine learning methods for predicting the technical state of an object. *Izvestia of Samara Scientific Center of the RAS*. 2021;23(1):111–114. (In Russ.). https://doi.org/10.37313/1990-5378-2021-23-1-111-114
11. Марнадзе Е.И. Цифровизация андеррайтинга: обзор скоринговых систем и методов машинного обучения в личном страховании. *Индустриальная экономика*. 2025;(S2):125–132. https://doi.org/10.47576/2949-1886.2025.9.9.019
Marnadze E.I. Digitalization of underwriting: a review of scoring systems and machine learning methods in personal insurance. *Industrial Economics*. 2025;(S2):125–132. (In Russ.). https://doi.org/10.47576/2949-1886.2025.9.9.019

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Калач Андрей Владимирович, заслуженный работник высшей школы Российской Федерации, доктор химических наук, профессор, профессор кафедры безопасности информации и защиты сведений, составляющих государственную тайну, Воронежский институт ФСИН России, Воронеж, Российская Федерация.
e-mail: a_kalach@mail.ru
ORCID: 0000-0002-8926-3151

Andrey V. Kalach, Honored Worker of Higher Education of the Russian Federation, Doctor of Chemical Sciences, Professor, Professor at the Department of Information Security and Protection of Information Constituting a State Secret, Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, the Russian Federation.

Матыцина Ирина Александровна, кандидат технических наук, доцент кафедры безопасности информации и защиты сведений, составляющих государственную тайну, Воронежский институт ФСИН России, Воронеж, Российская Федерация.
e-mail: irina210390@mail.ru
ORCID: 0000-0001-9236-9654

Irina A. Matytsina, Candidate of Engineering Sciences, Associate Professor at the Department of Information Security and Protection of Information Constituting a State Secret, Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, the Russian Federation.

Золотарев Юрий Николаевич, доктор технических наук, доцент, профессор кафедры безопасности информации и защиты сведений, составляющих государственную тайну Воронежский институт ФСИН России, Воронеж, Российская Федерация.
e-mail: vifsin@36.fsin.gov.ru
ORCID: 0000-0003-0582-3009

Yuri N. Zolotaryov, Doctor of Engineering Sciences, Docent, Professor at the Department of Information Security and Protection of Information Constituting a State Secret, Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, the Russian Federation.

Здольник Владимир Вячеславович, кандидат технических наук, доцент, доцент кафедры КБ-4 «Интеллектуальные системы информационной безопасности» института кибербезопасности и цифровых технологий, МИРЭА – Российский технологический университет.
e-mail: mano1000@yandex.ru
ORCID: 0000-0002-5023-0993

Vladimir V. Zdolnik, Candidate of Engineering Sciences, Docent, Associate Professor at the KB-4 Department of Intelligent Information Security Systems, Institute of Cybersecurity and Digital Technologies, MIREA – Russian Technological University, Moscow, the Russian Federation.

Статья поступила в редакцию 10.09.2026; одобрена после рецензирования 09.11.2026; принята к публикации 18.11.2026.

The article was submitted 10.09.2026; approved after reviewing 09.11.2026; accepted for publication 18.11.2026.