

# ИНТЕГРАЦИЯ МЕТОДОВ РОБОТИЗАЦИИ И МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ЛОГИСТИЧЕСКИХ ПРОЦЕССОВ

Пятецкий В.Е., Радаева А.В., Куликовский М.А., Белых П.В.

Национальный исследовательский технологический университет "МИСИС", Москва, Россия  
7621496@gmail.com, av.radaeva@misis.ru, kulikovskij.m@yandex.ru, belykh.pv@misis.ru

*Аннотация.* В работе представлен двухэтапный подход к оптимизации процесса выбора поставщика ТМЦ на промышленном предприятии. Реализована роботизация проверки поставщиков и разработана модель машинного обучения для оценки их надёжности с помощью языка Python, заложенная в основу приложения на Streamlit.

*Ключевые слова:* оптимизация бизнес-процессов, выбор поставщика, роботизация (RPA), машинное обучение, надёжность контрагентов, имитационное моделирование, цифровая трансформация, закупки, классификация, Streamlit, Docker, металлургическое предприятие.

## Введение

Процессы управления поставками, включая выбор поставщиков товарно-материальных ценностей (ТМЦ), играют ключевую роль в обеспечении бесперебойного производства, снижении издержек и повышении конкурентоспособности металлургических предприятий. Качество принимаемых решений напрямую влияет на надёжность логистики и общую эффективность деятельности.

На практике данный процесс часто реализуется вручную, с опорой на экспертные оценки и проверку данных через внешние ресурсы, что приводит к высокой трудоёмкости, субъективности и рискам ошибок. В условиях увеличения объёмов информации и скорости проведения закупок традиционный подход становится экономически неэффективным. Современные исследования подчёркивают необходимость внедрения автоматизации и интеллектуального анализа данных как инструмента повышения устойчивости бизнес-процессов [1].

Оптимизация бизнес-процессов представляет собой систематическое улучшение процедур для достижения наилучших показателей по критериям времени, стоимости, надёжности и производительности. Особое значение приобретает имитационное моделирование как инструмент численного анализа поведения бизнес-системы во времени. Оно позволяет воспроизводить сценарии функционирования процесса, выявлять узкие места и оценивать последствия управленческих решений без вмешательства в реальную среду, что особенно актуально при высокой стоимости возможных ошибок [2].

Роботизация бизнес-процессов (Robotic Process Automation, RPA) направлена на автоматизацию рутинных, формализованных операций с помощью программных роботов, способных взаимодействовать с офисными приложениями, сайтами и файлами. Такие решения позволяют сократить трудозатраты, устранить ошибки и повысить скорость выполнения операций без необходимости доработки IT-инфраструктуры [3].

Следующий логический шаг в повышении интеллектуального уровня процессов — внедрение методов машинного обучения. Машинное обучение (ML), как одно из ключевых направлений искусственного интеллекта, предоставляет инструменты для построения моделей, способных выявлять закономерности в данных и принимать решения без явного программирования. Особенно эффективно ML зарекомендовало себя в задачах классификации и ранжирования поставщиков, анализа рисков и прогнозирования поведения контрагентов в цепях поставок [4].

Целью настоящей работы является разработка и апробация поэтапного подхода к оптимизации бизнес-процесса выбора поставщика ТМЦ на металлургическом предприятии, включающего роботизацию этапа проверки поставщиков через сайт ЕИС с использованием RPA-платформы Primo и построение модели машинного обучения для автоматизированной оценки их надёжности.

## 1. Имитационное моделирование и количественная оценка эффекта оптимизации

В рамках исследования бизнес-процесса «Выбор поставщика товарно-материальных ценностей» был проведен анализ и построена модель процесса в состоянии «как есть» (AS-IS), включающая следующие этапы: анализ заявки на закупку, подбор потенциальных поставщиков, согласование допустимых расходов на закупки, составление ранжированного списка поставщиков, выбор поставщика, заключение договора и формирование отчетности.

Для обоснования целесообразности оптимизации данного этапа был применён метод имитационного моделирования с использованием среды Business Studio. Это позволило смоделировать и сопоставить эффективность бизнес-процесса в текущем состоянии (AS-IS) и в предполагаемом будущем состоянии (TO-BE) после внедрения роботизации и других цифровых решений.

В текущем состоянии бизнес-процесс проверки благонадежности поставщиков на предприятии осуществляется вручную. Специалист отдела материально-технического снабжения открывает портал Единой информационной системы (ЕИС), вводит ИНН каждого контрагента и анализирует информацию о его присутствии в реестре недобросовестных поставщиков. Процедура повторяется для всех участников тендера, что требует значительных трудозатрат и подвержено рискам ошибок, связанных с человеческим фактором. Процесс занимает в среднем 20 минут на 1 контрагента, и повторяется до 5000 раз в год, вовлекая до трёх сотрудников.

Имитационное моделирование, выполненное в среде Business Studio, позволило количественно оценить эффективность бизнес-процесса. В рамках настройки модели были заданы ключевые параметры, включая частоту выполнения процесса, рыночные значения часовых ставок сотрудников, а также длительность операций, распределённая по нормальному закону, что обеспечило приближение к реалистичным условиям исполнения. В таблице 1 представлены результаты:

Таблица 1. Основные показатели бизнес-процесса до оптимизации (модель AS-IS)

Показатель	Значение
Среднее время на проверку одного поставщика	10 минут
Совокупное время на проверку группы из 5 поставщиков	50 минут
Средняя длительность всего бизнес-процесса выбора поставщика	12 суток 14 часов
Суммарная стоимость выполнения одного экземпляра бизнес-процесса	17 062,88 рублей
Временные затраты на этап проверки благонадежности	около 20 часов
Стоимость подпроцесса проверки благонадежности на один цикл	1 016,67 рублей
Доля ошибочных записей поставщиков из-за ручного ввода и неполных данных	до 20%

## 2. Роботизация проверки поставщиков на благонадежность

Для устранения, выявленного «узкого места» – ручной проверки благонадежности поставщиков по ИНН через портал ЕИС – было разработано и реализовано роботизированное решение с использованием отечественной платформы Primo RPA. Платформа обеспечивает выполнение RPA-сценариев в защищённом контуре и поддерживает автоматизированную работу с Microsoft Office, Outlook и веб-интерфейсами. Программный робот выполняет последовательную проверку поставщиков, исключает недобросовестных контрагентов и формирует финальный перечень допущенных к участию в закупке.

### 2.1. Построение модели процесса «как будет»

После анализа требований и оценки потенциала автоматизации был разработан программный робот, реализующий следующий сценарий:

- считывание конфигурационного файла с параметрами доступа и путями сохранения данных;
- автоматическое подключение к Outlook и извлечение входящих писем со списками поставщиков;
- открытие вложенного Excel-файла, извлечение ИНН поставщиков;
- пошаговая проверка каждого ИНН на сайте ЕИС с использованием браузера Google Chrome;
- удаление из списка недобросовестных контрагентов на основе результатов поиска;
- сохранение обновлённого списка и автоматическая отправка его обратно сотруднику на электронную почту;
- архивирование исходного файла и логирование операций.

По завершении обработки робот автоматически отправляет результат проверки на электронную почту сотрудника и фиксирует все действия в журнале логирования. Это обеспечивает контроль выполнения и уведомление пользователя о завершении сценария.

Схема процесса «TO-BE», выполняемого роботом, представлена на рисунке 1.

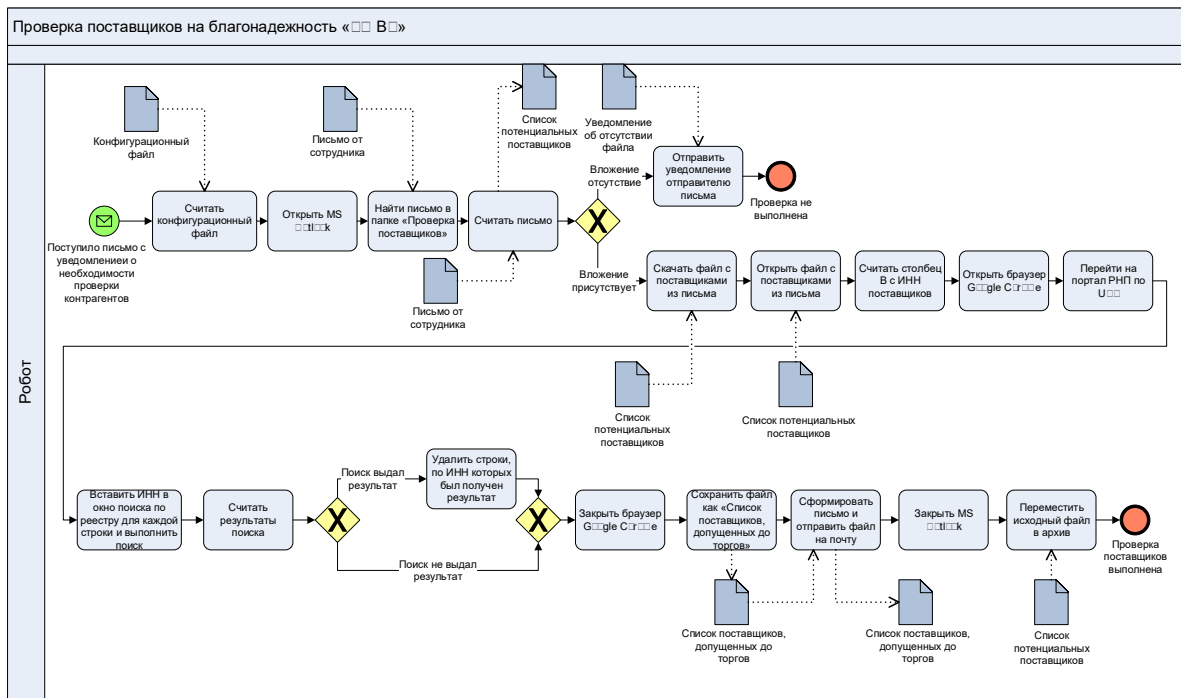


Рис. 1. Модель процесса проверки поставщиков на надежность «как будет»

Процесс реализован на базе платформы Primo RPA Studio с использованием встроенных компонентов: цикла ForEach, условий If-Else, активности Try-Catch для обработки исключений, а также модулей взаимодействия с Excel, Outlook и веб-браузером. На рисунке 2 представлен фрагмент алгоритма работы робота, реализующий цикл перебора списка поставщиков с целью последовательной проверки их ИНН в реестре.

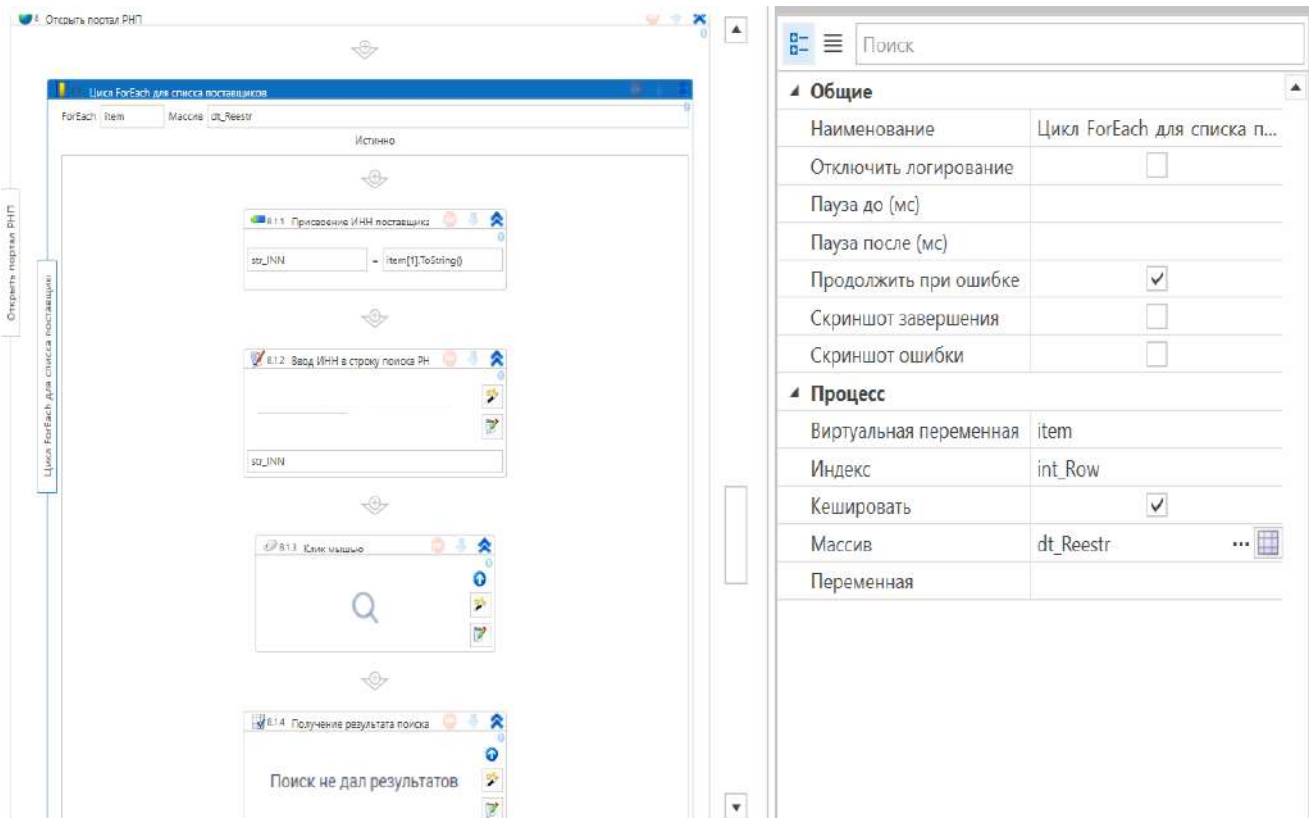


Рис. 2. Цикл проверки ИНН поставщиков в среде Primo RPA

## 2.2. Количественная оценка эффекта от роботизации

Проведён расчёт экономического эффекта на основе методики оценки FTE (full-time equivalent):

- Среднегодовое количество операций – 4940;
- Время на одну операцию – 10 мин;
- Занятость – 3 специалиста среднего звена;
- Потенциальная экономия трудозатрат – 823,3 чел.-часа/год;
- Дополнительно рассчитан показатель Ratio (интегральный потенциал роботизации), равный 0,38, что превышает порог внедрения (0,33) и подтверждает целесообразность реализации RPA-решения. Рассчитан экономический эффект  $S$  от внедрения роботизированного решения по формуле 1:

$$S = t\Sigma \cdot n \cdot S_{СТ} \cdot N + R, \quad (1)$$

где  $S_{СТ}$  – часовая ставка сотрудника, выполняющего процесс, руб., составляющая 625 руб. в час.  
 $t\Sigma = 10$  мин.

$R$  – прочие расходы на процесс, руб. (не предусмотрены).

Так, экономический эффект от внедрения роботизации при средней ставке 625 руб./час составляет 1 543 750 руб./год.

Разработанное роботизированное решение позволило полностью автоматизировать повторяющийся этап проверки поставщиков на благонадёжность, устранив ошибки, ускорив процесс и освободив сотрудников от выполнения рутинных задач, также доказана экономическая эффективность [5]. Это создало предпосылки для перехода ко второму этапу оптимизации – автоматизации аналитического выбора поставщика с использованием методов машинного обучения.

## 3. Применение модели машинного обучения для оценки надёжности поставщиков

После автоматизации рутинного этапа проверки контрагентов с использованием RPA, осуществлен переход к интеллектуальной оценке надёжности поставщиков. Применение методов машинного обучения (ML) позволяет автоматизировать процесс принятия решений на основе множества критериев, снизить влияние субъективного фактора и повысить точность отбора.

Цель построения модели – присвоение бинарного признака «надёжность» (да/нет) поставщикам на основе исторических данных.

Для автоматизации выбранной части бизнес-процесса требуется обучить модель, которой в дальнейшем ведущий специалист по закупкам будет подавать на вход данные о поставщиках. Алгоритм осуществляет прогноз и возвращает результат сотруднику, на основе которого он может принимать решение и делать выбор контрагента (рисунок 3).

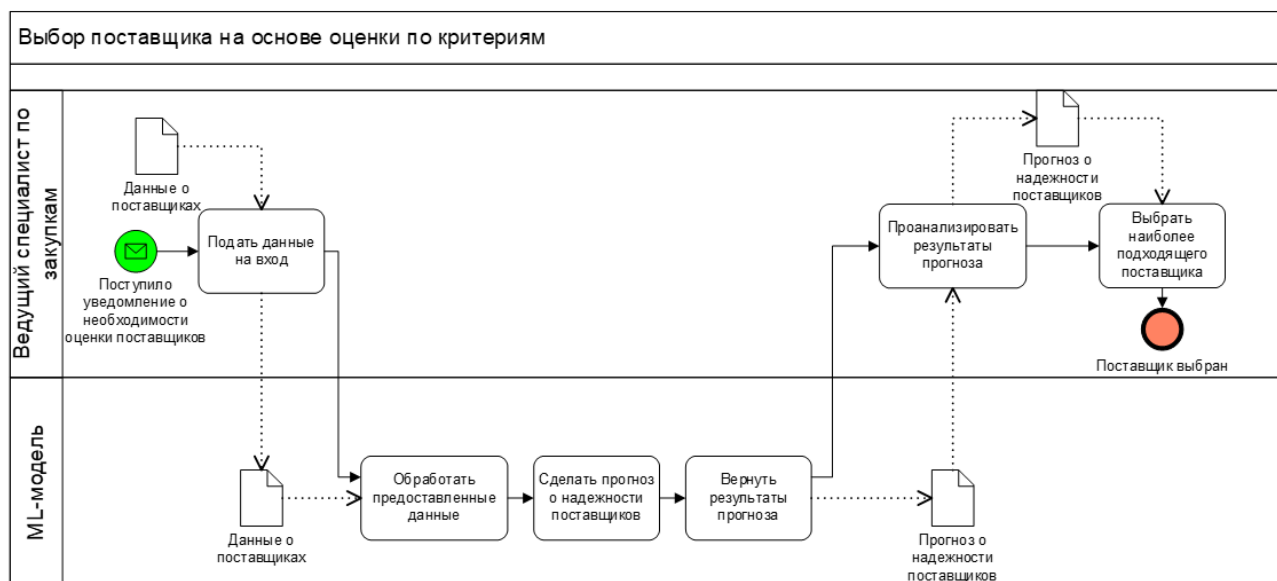


Рис. 3. Процесс оценки поставщиков по критериям с помощью алгоритма

Исходные данные для модели представлены в виде таблицы, содержащей как общую информацию о контрагенте (ИНН, адрес, участие в торгах и др.), так и экспертные оценки по критериям, перечисленным в таблице 2.

Таблица 2. Описание входных данных

Атрибут	Тип данных	Пример записи
Название поставщика	VARCHAR(255)	ООО "Поставщик"
ИНН	INT(8)	1111111111
Адрес	VARCHAR(255)	000000, Г. ЕКАТЕРИНБУРГ, УЛ. МИРА, Д.1
Участие	INT(8)	111
Допуски	INT(8)	111
Победы	INT(8)	111
Контракты	INT(8)	111
Сумма побед	DECIMAL	11 111 111
Среднее снижение цены	DATE	1%
Контактное лицо	VARCHAR(255)	Иванов Иван Иванович
Телефон	VARCHAR(20)	+7 (111) 111-11-11
Электронная почта	VARCHAR(255)	pochta@mail.ru
Качество продукции	VARCHAR(255)	Продукция соответствует требованиям НД
Своевременность поставки	INT(8)	Да
Надежность	VARCHAR(255)	Да
Соответствие маркировки	INT(8)	3(оценка по шкале от 1 до 3)
Результаты текущего (входного, производственного) контроля	INT(8)	3(оценка по шкале от 1 до 3)

Перед построением модели был выполнен предварительный анализ исходного набора данных с целью выявления трендов, закономерностей и аномалий. На основании результатов анализа проведена подготовка данных, включающая очистку от выбросов, заполнение пропущенных значений, кодирование категориальных признаков и масштабирование числовых. Такие шаги позволяют минимизировать искажения при обучении и повысить обобщающую способность модели. В качестве целевой переменной выступал бинарный признак «Надёжность», отражающий принадлежность поставщика к категории надёжных или ненадёжных контрагентов.

### 3.1. Алгоритм обучения модели

Алгоритм работы модели машинного обучения реализован с использованием языка Python и включает в себя полный цикл обработки данных: от подготовки и обучения до прогнозирования и визуализации. Все этапы выполнены с применением библиотек pandas, scikit-learn, Streamlit и plotly, что обеспечивает воспроизводимость решения и удобство его практического внедрения.

На вход модель получает структурированный набор данных, содержащий сведения о поставщике, такие как количество побед в тендерах, сумма контрактов, своевременность поставки, качество продукции и другие критерии, значимые для оценки его надёжности. Всего для обучения и тестирования модели было использовано 462 записи, каждая из которых представляет отдельного поставщика с соответствующими характеристиками и целевым признаком надёжности.

Алгоритм реализован в следующей последовательности:

1) Импорт и подготовка данных.

Загрузка исходных данных с характеристиками поставщиков. Выполняется удаление выбросов, заполнение пропусков, кодирование категориальных признаков (например, "Да"/"Нет"), масштабирование числовых переменных для обеспечения корректной работы моделей.

2) Разделение выборки.

С помощью функции train\_test\_split() данные делятся на обучающую (70%) и тестовую (30%) выборки. Это позволяет объективно оценить обобщающую способность модели.

3) Обучение моделей.

Проводится обучение нескольких алгоритмов классификации, включая Logistic Regression, Decision Tree и Random Forest. Каждый алгоритм настраивается и обучается на обучающей выборке с целью выявления наиболее точного предсказателя.

4) Оценка качества моделей.

По итогам обучения проводится сравнение моделей на тестовой выборке с использованием метрик: accuracy, precision, recall, F1-score.

### 5) Предсказание и вывод результата.

После выбора наилучшей модели она применяется к новым данным для определения признака "надёжность" (1 – надёжный, 0 – ненадёжный). Результат возвращается пользователю в виде понятного вывода с визуализацией. Схема алгоритма представлена на рисунке 4.

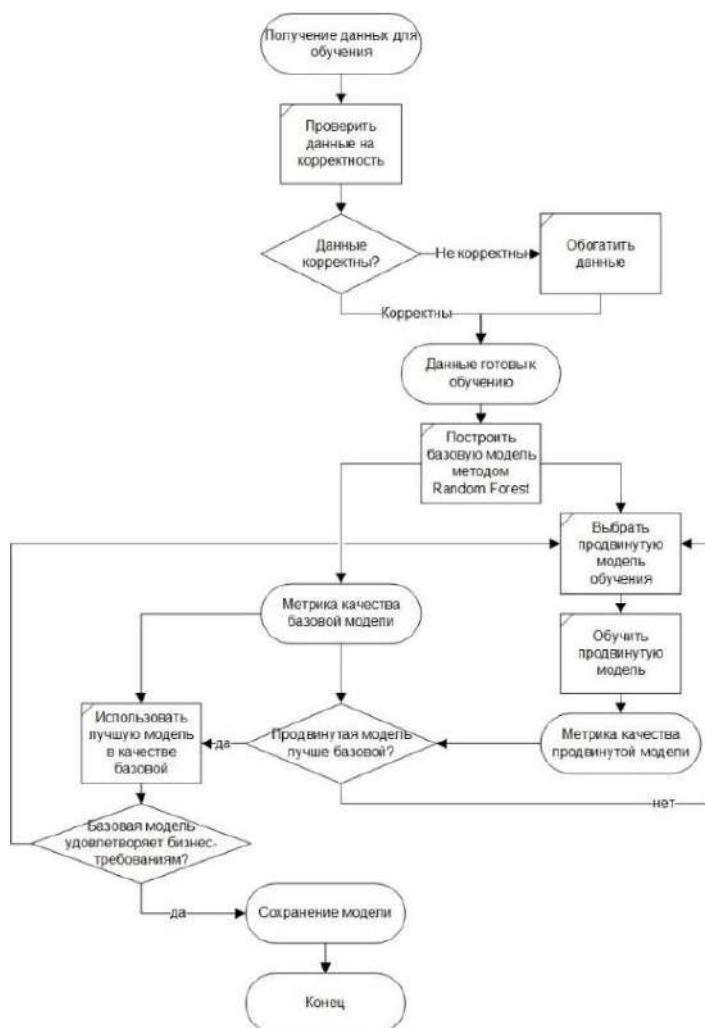


Рис. 4. Алгоритм обучения модели

## 3.2. Метрики оценки качества модели

Для оценки качества работы построенной модели машинного обучения были использованы стандартные метрики классификации: точность (precision), полнота (recall), F1-мера (f1-score), а также общая точность (accuracy). Эти показатели позволяют комплексно оценить способность модели корректно классифицировать поставщиков по признаку надёжности.

На рисунке 5 представлены результаты точности моделей. Наилучший результат показал метод Random Forest, обеспечившая точность предсказания на уровне 97,8%.




Рис. 5. Оценка точности моделей

Результаты тестирования модели Random Forest на валидационной выборке представлены в таблице 3.

Таблица 3. Отчет о точности модели Random Forest

Метрика	precision	recall	f1-score	support
0	0,99	0,94	0,97	159
1	0,97	1,00	0,98	303
accuracy			0,98	462
macro avg	0,98	0,97	0,97	462
weighted avg	0,98	0,98	0,98	462

Высокие значения precision и recall по обоим классам свидетельствуют о сбалансированной работе модели: она эффективно выявляет как надёжных, так и ненадёжных поставщиков. F1-мера в диапазоне 0,97–0,98 указывает на высокий уровень гармонии между точностью и полнотой. Общая точность классификации составила 98%, что подтверждает устойчивость и высокое качество прогнозирования.

Дополнительно для оценки дискриминационной способности модели была построена ROC-кривая (Receiver Operating Characteristic), отражающая соотношение между уровнем истинно положительных и ложно положительных классификаций при различных порогах принятия решения. (рисунок 6).

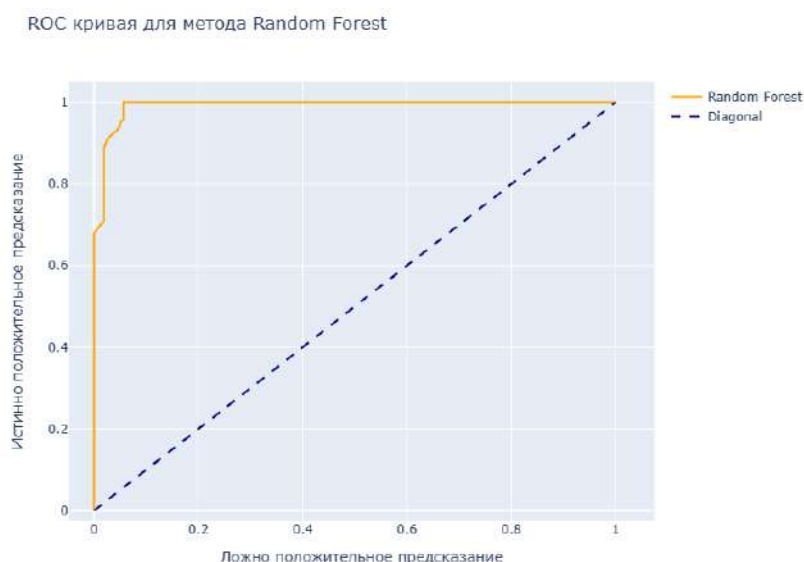


Рис. 6. ROC-кривая модели Random Forest

Как видно из графика, ROC-кривая модели Random Forest проходит близко к верхнему левому углу, что свидетельствует о высокой чувствительности и специфичности модели. Линия сравнения (диагональ) обозначает поведение случайного классификатора. Значительное превышение ROC-кривой над этой диагональю указывает на устойчивую способность модели различать два класса — надёжных и ненадёжных поставщиков. Более того, площадь под кривой (AUC, Area Under Curve) приближается к 1, что подтверждает высокое качество модели независимо от выбранного порога вероятности. Таким образом, модель Random Forest демонстрирует надёжность не только по точечным метрикам, но и в диапазоне вероятностных решений.

Для дополнительной оценки работы классификатора построена матрица ошибок, позволяющая визуально отразить количество верных и ошибочных предсказаний по каждому из классов (рисунок 7).



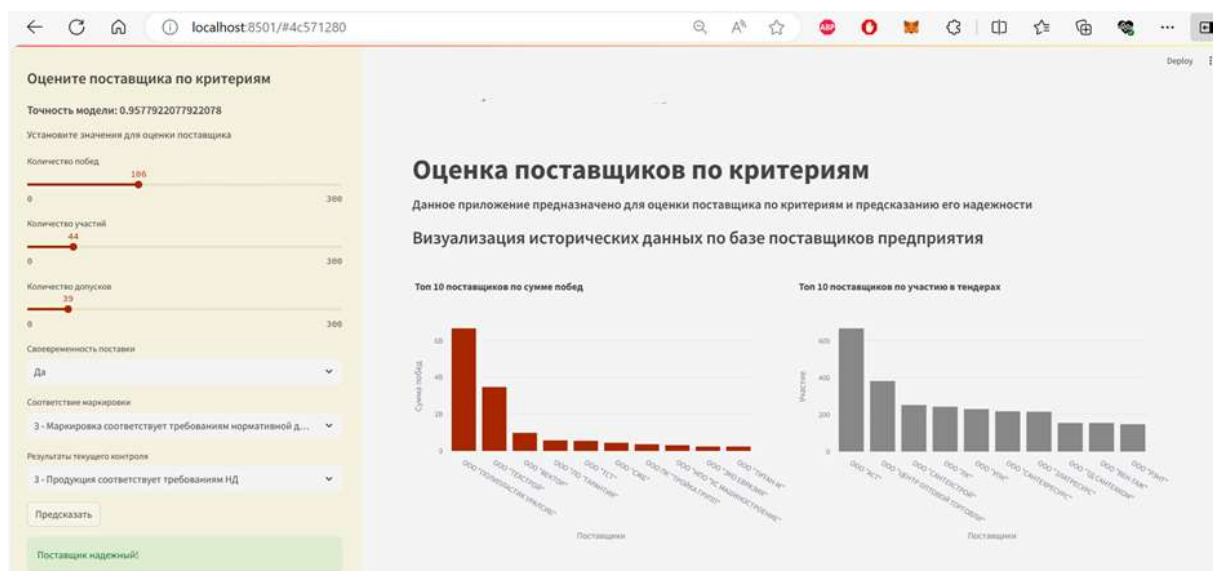
*Рис. 7. Матрица ошибок модели Random Forest*

Как видно из матрицы, модель предсказала положительный класс (надёжных поставщиков) в 301 случае при фактически положительном классе, допустив лишь 2 ошибки пропуска. Однако при этом наблюдаются 150 ложноположительных срабатываний, когда ненадёжный поставщик был ошибочно классифицирован как надёжный. Такие ошибки относятся к наиболее значимым в контексте задачи, поскольку они могут привести к принятию рискованных решений в закупке.

Тем не менее, соотношение между ошибками I и II рода указывает на относительно сбалансированное поведение модели и её способность обоснованно идентифицировать основную долю надёжных контрагентов. Полученные результаты согласуются с высокими значениями recall и f1-score, что подтверждает стабильность модели при работе с реальными данными.

### 3.3. Внедрение и визуализация решения

Для внедрения модели в практическую деятельность отдела закупок было разработано веб-приложение на базе Streamlit. В его основе лежит обученная модель машинного обучения (Random Forest), реализованная с использованием библиотеки scikit-learn. Приложение позволяет пользователю вводить значения критериев по поставщику и мгновенно получать прогноз с вероятностью принадлежности к надёжному или ненадёжному классу (рисунок 8).



*Рис. 8. Пользовательское приложение для прогноза надёжности*

Приложение также содержит визуальные аналитические панели, отражающие распределение поставщиков по ключевым метрикам.

Разработанное приложение для оценки надёжности поставщиков было развёрнуто с использованием технологии контейнеризации Docker, что обеспечило его платформенную независимость, воспроизводимость и устойчивость к изменениям внешней среды.

Архитектура решения включает следующие компоненты:

- Dockerfile, содержащий описание среды выполнения и зависимостей;
- Python-скрипт, реализующий алгоритм обработки входных данных и предсказания на основе предварительно обученной модели машинного обучения;
- Пользовательский интерфейс на базе Streamlit, обеспечивающий доступ к функционалу модели через веб-приложение.

Процесс развертывания предусматривает сборку Docker-образа, включающего весь необходимый программный стек, и запуск контейнера в среде приложений. Внутри контейнера реализован механизм кеширования, что позволяет ускорить повторные обращения к модели и повысить общую производительность системы.

Разработанная модель машинного обучения позволила формализовать и автоматизировать процесс оценки поставщиков по множеству критериев, повысив точность и объективность принимаемых решений. Внедрение модели в виде веб-интерфейса обеспечило её доступность для сотрудников, не обладающих навыками программирования, и создало предпосылки для масштабирования решения на другие процессы управления цепями поставок.

#### 4. Заключение

В настоящей работе представлен поэтапный подход к оптимизации бизнес-процесса выбора поставщика товарно-материальных ценностей на металлургическом предприятии, основанный на последовательном внедрении цифровых технологий: роботизации и машинного обучения. В качестве исследуемого предмета выделен подпроцесс проверки благонадежности поставщиков — наиболее ресурсоёмкий и подверженный ошибкам этап, напрямую влияющий на общее качество принятия решений в сфере закупок.

На первом этапе была реализована роботизация рутинных операций с применением платформы Primo RPA, позволившая автоматизировать проверку поставщиков по ИНН через портал ЕИС. Это привело к резкому сокращению временных и трудовых затрат, устранению человеческого фактора и подготовило процесс к дальнейшей интеллектуализации.

На втором этапе разработана и внедрена модель машинного обучения, способная классифицировать поставщиков по признаку надёжности на основе множества критериев, включая исторические и качественные показатели. Развёртывание модели в виде веб-приложения на базе Streamlit с контейнеризацией в Docker обеспечило её практическую применимость, доступность для непрофильных пользователей и лёгкость масштабирования.

Для количественной оценки результатов внедрения были построены имитационные модели AS-IS и TO-BE в среде Business Studio. Ниже в таблице 4 представлены ключевые сравнительные показатели:

Таблица 4. Результаты оптимизации бизнес-процесса

Показатель	Модель (AS-IS)	Модель (TO-BE)	Эффект
Средняя длительность всего процесса	12 суток 14 часов	7 суток 12 часов	–5 суток 2 часа
Стоимость одного экземпляра процесса	17 062,88 руб.	7 357,64 руб.	–56,9%
Время на проверку одного поставщика	20 минут	5 минут	–75%
Стоимость подпроцесса проверки поставщиков	1 016,67 руб.	266,67 руб.	–750 руб.
Частота ошибок в списке поставщиков	до 20%	менее 1%	устранение ошибок ввода

Проведённое исследование показало, что даже локальная оптимизация одного критически важного этапа — проверки благонадежности поставщиков — способна оказать системное влияние на весь бизнес-процесс. Интеграция роботизации и методов машинного обучения не только сокращает ресурсоёмкость операций, но и формирует основу для внедрения комплексных интеллектуальных систем поддержки принятия решений в сфере снабжения. Модель TO-BE может служить основой для масштабирования цифровых инициатив на других уровнях производственно-логистической цепи.

## Литература

1. *Золотухина М.М., Половникова Н.А.* К вопросу об оценке надежности поставщика // *Экономические науки.* – 2022. – № 3. – С. 73–76. – DOI: 10.24412/2500-1000-2022-12-3-73-76.
2. *Куликовский М.А., Макаров В.В.* Имитационное моделирование как инструмент оптимизации технологического процесса // *XIV всероссийское совещание по проблемам управления ВСПУ-2024.* – 2024. – 1856 с.
3. *Пятецкий В.Е., Белых П.В., Елесина К.Е.* Роботизация бизнес-процессов (RPA): методические указания. – М.: Издательский дом НИТУ «МИСиС», 2023. — 28 с.
4. *Роголин Р.С.* Использование методов анализа данных и машинного обучения для прогнозирования и планирования спроса при управлении цепочками поставок // *Теоретическая экономика.* – 2023. – № 8. – С. 35–53. – URL: <https://theoreticaleconomy.ru/ru/nauka/article/81582/view> (дата обращения: 30.05.2025).
5. *Исаева Н.А., Калинин О.И.* Перспективные экономические возможности предприятия: сущность и управление – Москва: Национальный исследовательский технологический университет "МИСИС", 2024. – 192 с. – ISBN 978-5-907833-05-0.