

АВТОМАТИЗАЦИЯ ПРОЦЕССА ОБРАБОТКИ КЛИЕНТСКИХ ОБРАЩЕНИЙ

**Чернявская А. В. ORCID ID 0009-0003-3560-4998,
Горшков К. А. ORCID ID 0000-0003-4872-2195**

*Федеральное государственное образовательное бюджетное учреждение высшего образования
«Финансовый университет при Правительстве Российской Федерации», Москва,
Российская Федерация, e-mail: godograf@list.ru*

В работе рассматривается процесс автоматизации взаимодействия с клиентами. Целью работы является моделирование процессов для автоматизированной системы обработки клиентских обращений и подбор наиболее эффективных моделей машинного обучения для определения тональности обратной связи. В рамках исследования выполнено моделирование автоматизации процесса обработки клиентских обращений с использованием системных инструментов BPMN и UML-диаграмм последовательности, что позволило структурировать и сделать более понятными ключевые этапы построения обратной связи с клиентами. В предложенных схемах отдельно рассмотрен ML-анализатор, предназначенный для определения тональности сообщений и автоматической генерации задач для сотрудников. В работе проведено экспериментальное сравнение характеристик трех алгоритмов для задачи определения тональности (sentiment analysis): BERT, DistilBERT и TextBlob. Оценка их эффективности осуществлялась с использованием метрики F1-score на трех различных наборах данных: Yelp Review Polarity Dataset, Amazon Product Reviews Dataset и Rotten Tomatoes Reviews Dataset. Наилучшие результаты по метрике F1-score демонстрирует модель BERT, хотя по времени на обучение и обработку данных она немного уступает другим моделям и фреймворкам, с которыми проводилось сравнение в данной работе.

Ключевые слова: автоматизация взаимодействия, BPMN-диаграммы, диаграммы последовательности UML, анализ тональности, BERT, ML-анализатор

AUTOMATIZATION OF CUSTOMER INQUIRY PROCESSING

**Chernyavskaya A. V. ORCID ID 0009-0003-3560-4998,
Gorshkov K. A. ORCID ID 0000-0003-4872-2195**

*Federal State Educational Budgetary Institution of Higher Education
“Financial University under the Government of the Russian Federation”,
Moscow, Russian Federation, e-mail: godograf@list.ru*

The article deals with the process of automatization of customer interaction. The aim of this article is modeling of processes for an automated customer request processing system and select the most effective machine learning models to determine the tone of feedback. As part of the research, the automatization of the customer request processing process was modeled using BPMN system tools and UML sequence diagrams, which made it possible to structure and make clearer the key stages of building customer feedback. In the proposed schemes, an ML analyzer is considered separately, designed to determine the tone of messages and automatically generate tasks for employees. The paper presents an experimental comparison of the characteristics of three algorithms for the problem of determining tonality (sentiment analysis): BERT, DistilBERT and TextBlob. Their effectiveness was assessed using the F1-score metric on three different datasets: the Yelp Review Polarity Dataset, the Amazon Product Reviews Dataset, and the Rotten Tomatoes Reviews Dataset. The BERT model demonstrates the best results for the F1-score metric, although it is slightly inferior in terms of training and data processing time to other models and frameworks compared in this paper.

Keywords: automatization of interaction, BPMN diagrams, UML sequence diagrams, sentiment analysis, BERT, ML analyzer

Введение

Качество обслуживания клиентов для современного бизнеса, независимо от того, какая категория товаров или услуг предлагается, выступает одним из наиболее значимых факторов, определяющих успех и позиции на конкурентном рынке [1, 2]. Ведущим инструментом, позволяющим грамотно выстраивать взаимоотношения с клиентами, зачастую является система обратной связи. С одной стороны, она позволяет своевре-

менно реагировать на рекламации и решать задачи тактического назначения, не давая конфликтным ситуациям усугубляться. А с другой, формировать стратегические управленческие решения на основе собранной статистики [3]. Если положительные отзывы в основном влияют на формирование репутационного поля, то отзывы негативного плана, помимо этого, могут приводить к реальным потерям и оттоку важных клиентов [4, 5]. К сожалению, су-

существующие у большинства компаний традиционные методы обработки обращений часто связаны с ручной работой, высокой нагрузкой на сотрудников и риском ошибок, что приводит к затягиванию решения проблем. Помимо этого, без специализированных инструментов часто не удается сразу определить приоритетность и категорию каждого обращения. Нередко система обратной связи имеет недостаточную интеграцию с внутренними процессами компании, что может приводить к ненамеренному игнорированию негативных отзывов [6]. Многие организации не имеют инструментов для комплексного анализа обратной связи, а без него невозможно выявить системные проблемы и своевременно принимать управленческие решения. В связи с этим возникает необходимость разработки и внедрения автоматизированных систем, способных анализировать отзывы с использованием современных методов анализа текста (например, машинного обучения), классифицировать обращения и автоматизировать маршрутизацию процессов решения проблем. На актуальность такой разработки также указывает использование инструментов автоматизации обратной связи как крупными частными корпорациями (например, чат-боты и виртуальные ассистенты Tele2 и Sberbank) [7], так и учреждениями государственного сектора [8]. Нередко подобного рода системы встречаются в автоматизированных системах обучения [9–11].

Цель исследования – моделирование процессов для автоматизированной системы обработки клиентских обращений и подбор наиболее эффективных моделей машинного обучения для определения тональности обратной связи.

Материалы и методы исследования

В рамках данного исследования проведено экспериментальное сравнение характеристик трех алгоритмов для задачи определения тональности (sentiment analysis): BERT, DistilBERT и TextBlob. Оценка их эффективности осуществлялась с использованием метрики F1-score на трех различных наборах данных. В качестве исходных материалов использовался Yelp Review Polarity Dataset¹ – сбалансированный набор данных, содержащий 598 000 текстовых отзывов, которые оставляли пользователи о различных предприятиях сферы услуг: отрицательные (1 и 2 звезды) и положительные (3 и 4 звезды). Вторым источником данных выступал

Amazon Product Reviews Dataset² – набор отзывов на товары с платформы Amazon, включающий 142 млн объектов и характеризующийся большим разнообразием тем и форматов отзывов. Третьим датасетом был выбран Rotten Tomatoes Reviews Dataset (Movie Review Sentence Polarity Dataset)³, который содержит короткие текстовые фрагменты из кинокритик, численностью 10 662 примеров, и из-за небольшой средней длины предложений (около 21 слова) удобен для оценки эффективности моделей в условиях дефицита контекста. Моделирование бизнес-процессов автоматизированной обработки отзывов проводилось с помощью BPMN-диаграмм и диаграмм последовательности (Sequence Diagram) в нотации UML, что позволило более структурированно описать все этапы обработки и взаимодействие системных компонентов.

Результаты исследования и их обсуждение

Процесс обработки клиентского отзыва в информационной системе компании реализуется поэтапно, что важно учитывать на всем жизненном цикле разработки. Принимая во внимание обзор существующих решений для автоматизации управления клиентскими запросами в различных областях [9, 12] и видоизменив стандартные схемы реализации таких решений, можно предложить следующий сценарий работы. После того как отзыв поступает в систему, производится его автоматизированный анализ, который осуществляется за счет встроенного модуля машинного обучения. Сам ML-анализатор выполняет задачу по определению тональности отзыва (позитивная, нейтральная, негативная). В зависимости от алгоритма машинного обучения такой модуль может также соотнести отзыв с конкретной категорией и присвоить обращению степень срочности или приоритетности реагирования, указывая это затем в диспетчере задач. В системе также необходимо предусмотреть отдельный модуль для сбора и хранения поступивших обращений, реализованный в виде единой базы данных. Лицам, принимающим решения, доступ к таким данным позволяет отслеживать истории взаимодействия с конкретным клиентом для персонализации предложений, а также проводить комплексный анализ динамики настроений и предпочтений всех клиентов.

² Amazon Product Reviews Dataset [Электронный ресурс]. URL: <https://registry.opendata.aws/amazon-reviews/> (дата обращения: 14.03.2026).

³ Rotten Tomatoes Reviews Dataset [Электронный ресурс]. URL: https://huggingface.co/datasets/cornell-movie-review-data/rotten_tomatoes (дата обращения: 14.03.2026).

¹ Yelp Review Polarity Dataset [Электронный ресурс]. URL: https://www.tensorflow.org/datasets/catalog/yelp_polarity_reviews?hl=ru (дата обращения: 14.03.2026).

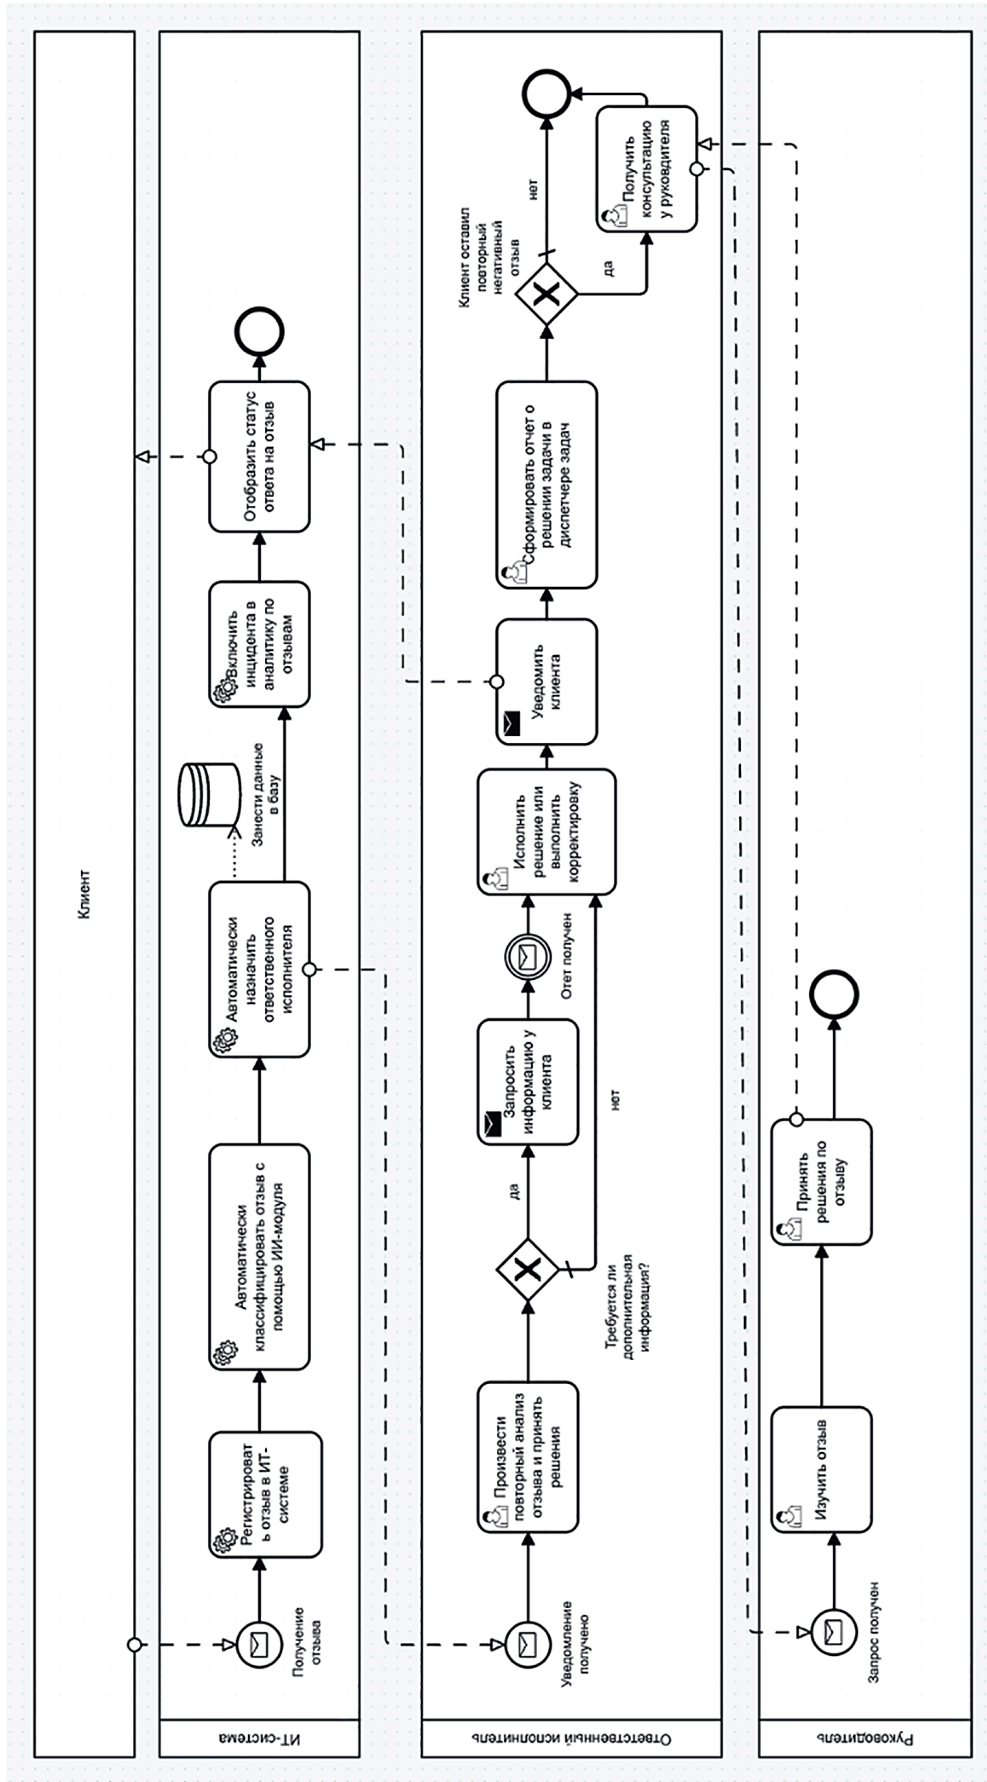


Рис. 1. VRMN диаграмма возможных процессов в автоматизированной системе для обработки отзывов
 Примечание: составлен авторами по результатам данного исследования



Рис. 2. Модель последовательностей действий компонентов автоматизированной системы обработки отзывов
Примечание: составлен авторами по результатам данного исследования

Таблица 1

Сравнение моделей и фреймворков для определения тональности

Модель / Фреймворк	Тип модели	Преимущества	Недостатки	Области использования
BERT	Трансформер	Высокая точность, хорошо понимает контекст	Требует больших вычислительных ресурсов	Исследовательские проекты
RoBERTa	Модификация BERT	Оптимизированная версия BERT с улучшенной точностью	Сложность настройки и обучения	Коммерческие сервисы NLP
DistilBERT	Упрощенный BERT	Быстрее и легче при сохранении качества	Немного уступает в точности большим моделям	Бизнес-приложения с ограниченными ресурсами
TextBlob	Библиотека Python	Простота использования, наличие базовых возможностей	Ограниченная точность на сложных отзывах	Малые и средние проекты, обучение новичков
VADER	Лексический анализ	Подходит для соцсетей и коротких сообщений	Не справляется с иронией и сложным контекстом	Анализ социальных медиа и маркетинг
FastText	Встраивание слов	Быстрая работа, поддержка многих языков	Меньше внимания к контексту	Проекты с многими языками
RuBERT	Русскоязычный BERT	Высокая точность для русского языка	Требует настройки под конкретные задачи	Анализ отзывов в России, локализованные решения

Примечание: составлена авторами на основе источников [13–15].

В автоматизированной системе по итогам работы ML-модуля должны формироваться задачи для сотрудников (например, обработка жалоб, подготовка ответов, проведение разъяснительной работы или инициирование улучшений). Использование правильного диспетчера задач позволяет также осуществлять мониторинг исполне-

ния автоматически выставленных поручений, а в случае затруднения в принятии решения давать возможность связаться с клиентом, если это CRM-система (Customer Relationship Management), или получить разъяснения у руководителя. Примерный вариант описания бизнес-процессов для такой системы представлен на рис. 1.

Учет всех участников взаимодействия при проектировании автоматизированной системы обработки отзывов, а также последовательность их действий могут быть отражены с помощью диаграммы последовательности в нотации UML (рис. 2). Это дает разработчику более полное представление о хронологии действий и ключевых модулях системы. На диаграмме в отдельные Lifelines выделены клиент, ИТ-система, ML-анализатор, база данных, ответственный исполнитель и руководитель.

Отдельного внимания заслуживает процесс отбора алгоритма машинного обучения для ML-анализатора. Как показывает ряд авторов [13–15], в задачах определения тональности, в том числе для отзывов, оставленных на различных платформах клиентами, высокую эффективность демонстрируют DistilBERT, TextBlob, VADER, FastText, RuBERT. Для дальнейшего отбора с целью рекомендации к использованию в автоматизированной системе обработки отзывов было проведено сопоставление этих моделей и фреймворков по ряду параметров. Результаты приводятся в табл. 1.

Исходя из проведенного сравнительного анализа различных моделей и фреймворков, для дальнейшей экспериментальной проверки на данных целесообразнее выбрать BERT, DistilBERT, TextBlob и RuBERT. Однако область применения последней модели ограничивается русскоязычными текстами, и, несмотря на то, что проверка этой модели была бы полезна для отечественных систем, предназначенных для взаимодействия с клиентами, отсутствие реальных (не синтетических) данных в открытом доступе затрудняет ее объективное сравнение с другими моделями. Возможно, сбор данных об отзывах в русскоязычном сегменте с их последующей разметкой мог

бы стать отдельной исследовательской задачей и оказать ценную помощь для разработки более точных и релевантных моделей по анализу клиентских настроек.

Как было описано в разделе «Материалы и методы исследования», сравнение моделей производилось на трех различных датасетах (Yelp Review Polarity Dataset, Amazon Product Reviews Dataset и Rotten Tomatoes Reviews Dataset), хорошо зарекомендовавших себя в задачах определения тональности. Значение основных метрик, а также время работы моделей при экспериментальном сравнении приведены в табл. 2.

Результаты работы моделей сопоставлялись по значениям стандартных метрик задачи классификации: Accuracy, Precision, Recall, F1-score (учитывающей баланс точности и полноты предсказаний), а также по времени, затраченному на предсказание и обучение модели. Последний столбец табл. 2 показывает, что TextBlob, основанный на простых правилах и словарях, обладает преимуществом довольно быстрого развертывания и низкой вычислительной сложности, что может быть полезно для ряда прикладных сценариев, где время играет решающую роль. Однако по всем трем метрикам TextBlob демонстрирует самые низкие оценки.

В задачах анализа настроек или определения характера отзыва важна способность модели находить все позитивные примеры без чрезмерных ложных срабатываний, что делает F1-score более информативной, чем остальные метрики по отдельности. Также эта метрика особенно полезна для данных с несбалансированными классами, поскольку обеспечивает более объективную оценку при определении миноритарного класса. Сравнение BERT, DistilBERT и TextBlob по значениям F1-score приведено на рис. 3.

Таблица 2

Оценка качества определения тональности BERT, DistilBERT, TextBlob и время их работы

Модель/фреймворк	Датасет	Accuracy	Precision	Recall	F1-Score	Время на итерацию/предсказание
DistilBERT	Yelp Review Polarity	86,0 %	87,0 %	85,0 %	86,0 %	0,5 мин / 1,2 мин
	Amazon Product Reviews	87,8 %	86,2 %	88,4 %	87,3 %	0,6 мин / 1,3 мин
	Rotten Tomatoes Reviews	82,5 %	83,5 %	80,5 %	82,0 %	0,5 мин / 1,2 мин
TextBlob	Yelp Review Polarity	65,0 %	60,0 %	55,0 %	57,0 %	4 с / 13 с
	Amazon Product Reviews	73,2 %	72,5 %	73,8 %	73,1 %	5 с / 15 с
	Rotten Tomatoes Reviews	51,0 %	60,0 %	48,5 %	52,5 %	4 с / 12 с
BERT	Yelp Review Polarity	88,0 %	89,0 %	87,0 %	88,0 %	1 мин / 2,5 мин
	Amazon Product Reviews	89,2 %	88,7 %	89,8 %	89,2 %	1,5 мин / 2,8 мин
	Rotten Tomatoes Reviews	87,0 %	88,0 %	85,0 %	86,0 %	1 мин / 2,4 мин

Примечание: составлена авторами на основе полученных данных в ходе исследования.




Рис. 3. Сравнение моделей по метрике F1-score на различных датасетах
Примечание: составлен авторами по результатам данного исследования

На всех трех наборах данных, несмотря на самые большие временные затраты на обучение и работу, модель BERT оказалась наиболее успешной. Она проявила себя эффективнее облегченной модели DistilBERT и значительно превзошла по ключевой метрике F1-score результаты TextBlob. В автоматизированных системах обработки клиентских обращений, бесспорно, ее можно рекомендовать в качестве ведущей модели ML-анализатора не только из общих соображений и обзора опубликованных сведений, но и по итогам экспериментальной проверки.

Для автоматизированных систем с большим объемом отзывов и активной обратной связью от клиентов модуль машинного обучения может включать суммаризатор отзывов. Суть его работы состоит в том, что он создает короткие и сжатые варианты по большому числу отзывов с сохранением смысла. Это позволяет не только аналитическому отделу отслеживать какие-то глобальные тенденции, но и самим пользователям быстрее ориентироваться при выборе товара или сервиса, которые предоставляет компания. Однако разработка такого суммаризатора требует отдельного исследования и экспериментального сравнения различных моделей машинного обучения по преобразованию длинных текстов в короткие и не входит в задачи данной работы.

Заключение

В рамках данной работы было проведено моделирование автоматизации процесса обработки клиентских обращений с исполь-

зованием системных инструментов BPMN и UML-диаграмм последовательности. Это позволило выделить и сделать более понятными основные этапы обработки обратной связи от клиентов.

В рассмотренные схемы предложено включить ML-анализатор, который предназначен для определения тональности клиентских сообщений (sentiment analysis) и автоматической генерации задач для сотрудников с указанием их приоритета. В работе был осуществлен экспериментальный отбор модели для такого анализатора, для этого DistilBERT, TextBlob и RuBERT были протестированы на трех различных наборах данных. Лучшие результаты по метрике F1-score продемонстрировала модель BERT, что подтверждает ее высокую точность и возможность использования для задач анализа пользовательских обращений.

Полученные результаты могут быть полезны разработчикам в области интеграции искусственного интеллекта в автоматизированные системы, что позволит компаниям, использующим такие системы, более эффективно осуществлять как тактические решения, требующие незамедлительных мер, так и стратегическое планирование на основе исторических данных.

Список литературы

1. Гиздуллина Э. А., Казанцева К. А. Лояльность через качество: роль обслуживания клиентов в электронной коммерции // Цифровая экономика глазами студентов: материалы V Международной научной конференции (Казань, 16 мая 2025 г.). Казань: ИП Сагиев А. Р., 2025. С. 53–57. EDN: SPIENX.

2. Стремюсова Е. Н. Эффективность обратной связи и ее специфика в организации // Прикладная юридическая психология. 2008. № 2. С. 75–86. URL: https://elibrary.ru/download/elibrary_15270227_28611886.pdf (дата обращения: 23.03.2026).
3. Арбатская Е. А. Стратегия как инструмент управления конкурентоспособностью предприятия // Бизнес. Образование. Право. 2018. № 4 (45). С. 93–96. URL: https://elibrary.ru/download/elibrary_36368581_20797860.pdf (дата обращения: 23.03.2026). DOI: 10.25683/VOLBI.2018.45.402.
4. Голикова А. С. Негативные отзывы розничных клиентов банков в сети Интернет // Банковская система: устойчивость и перспективы развития: сборник научных статей шестнадцатой международной научно-практической конференции по вопросам финансовой и банковской экономики (Пинск, 24 октября 2025 г.). Пинск: Учреждение образования «Полесский государственный университет», 2025. С. 25–28. URL: <https://rep.polessu.by/handle/123456789/35030> (дата обращения: 23.03.2026).
5. Natorina A. O. Simulation Model of the Retailer's Response to Negative Online Buyer's Reviews and Comments // Бизнес информ. 2020. № 2 (505). Р. 451–457. URL: https://www.elibrary.ru/download/elibrary_42896917_76491677.pdf (дата обращения: 23.03.2026). DOI: 10.32983/2222-4459-2020-2-451-457.
6. Емельянов А. М. Автоматизация обратной связи в обучении с помощью нейросетей: возможности и ограничения // Воспитательная работа в школе. 2025. № 1. С. 15–30. URL: <https://narodnoe.org/journals/vospitatelnaya-rabota-v-shkole/2025-1/avtomatizaciya-obratnoy-svyazi-v-obuchenii-s-pomoshyu-neirosetey-vozmozhnosti-i-ogranicheniya> (дата обращения: 23.03.2026).
7. Иванченко О. В. Развитие чат-ботов на основе технологии NLP в маркетинговой деятельности компаний // Инфраструктура рынка: проблемы и перспективы: ученые записки. Вып. 28. Ростов-на-Дону: Ростовский государственный экономический университет «РИНХ», 2023. С. 69–73. URL: https://www.elibrary.ru/download/elibrary_54735601_90971658.pdf (дата обращения: 23.03.2026).
8. Абрамян Н. С. Автоматизация системы обратной связи при помощи Telegram-бота Центра управления регионом // Государство и граждане в электронной среде. 2024. № 7. С. 59–68. URL: <https://ojs.itmo.ru/index.php/SCEE/article/view/1348/1159> (дата обращения: 23.03.2026). DOI: 10.17586/2541-979X-2024-7-59-68.
9. Есин Т. Е., Глухих И. Н. Автоматизация предоставления персонализированной обратной связи на курсах изучения программирования // Моделирование, оптимизация и информационные технологии. 2019. Т. 7. № 1 (24). С. 482–493. URL: https://www.elibrary.ru/download/elibrary_37419033_17985360.pdf (дата обращения: 23.03.2026). DOI: 10.26102/2310-6018/2019.24.1.043.
10. Хусаинов Ш. Г., Горшков К. А. Подведение итогов деятельности обучаемого в автоматизированном лабораторном практикуме // Наукосфера. 2023. № 8–2. С. 25–29. EDN: LMHKWL.
11. Хусаинов Ш. Г., Горшков К. А. Варианты систем автоматизированного обучения и их дидактический потенциал // Современные наукоемкие технологии. 2024. № 5–1. С. 221–225. URL: https://www.elibrary.ru/download/elibrary_67351449_63886239.pdf (дата обращения: 23.03.2026). DOI: 10.17513/snt.40032.
12. Волковский К. М. Анализ существующих технологий искусственного интеллекта для использования в оптимизации бизнес-процессов // Наука и технологии – 2025: сборник статей II Международной научно-практической конференции. Петрозаводск: Международный центр научного партнерства «Новая Наука» (ИП Ивановская И. И.), 2025. С. 114–119. URL: https://elibrary.ru/download/elibrary_82133188_71076791.pdf (дата обращения: 23.03.2026).
13. Сбоев А. Г., Воронина И. Е., Гудовских Д. В., Селиванов А. А. Продвинутое нейросетевые модели для решения задачи определения тональности // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. 2016. № 4. С. 178–183. URL: https://www.elibrary.ru/download/elibrary_28320141_39085976.pdf (дата обращения: 23.03.2026).
14. Мартынова И. Р., Платонов Е. Н. Семантический анализ отзывов об организациях методами машинного обучения // Моделирование и анализ данных. 2024. Т. 14. № 1. С. 7–26. URL: https://www.elibrary.ru/download/elibrary_65582559_17533547.pdf (дата обращения: 23.03.2026).
15. In S., Chanchamnan S. Comparison of VADER and TextBlob labeling for sentiment analysis using machine learning and deep learning models: A study on generative AI user experience // Acta Psychologica. 2026. Vol. 263. (106268). P. 1–17. URL: <https://www.sciencedirect.com/science/article/pii/S0001691826000673> (дата обращения: 23.03.2026).

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.

Финансирование: Авторы заявляют об отсутствии внешнего финансирования.

Financing: The research was performed without external funding.