

Сенкевич Людмила Борисовна

*к.п.н., доцент, Тюменский индустриальный университет,
г. Тюмень*

Мальков Илья Александрович

*магистрант группы ИТм(до)з-24-1, Тюменский индустриальный
университет, г. Тюмень*

ПРИМЕНЕНИЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ И ПРОГНОЗИРОВАНИЯ ПРИОРИТЕТА ЗАЯВОК НА РЕМОНТ ОФИСНОГО ОБОРУДОВАНИЯ

Аннотация. В статье исследуются возможности применения рекуррентных нейронных сетей (RNN), в частности архитектур LSTM и Bi-LSTM, для автоматической классификации и прогнозирования приоритета заявок на ремонт офисного оборудования. На основе анализа существующих подходов предлагается методика предобработки текстовых данных, обучения нейросетевых моделей и их интеграции в систему учета заявок. Приводятся результаты экспериментальной оценки точности моделей и обсуждаются перспективы практического применения.

Ключевые слова: рекуррентные нейронные сети, классификация текстов, прогнозирование приоритета заявок, обработка естественного языка, техническое обслуживание.

Abstract: The article explores the potential of using recurrent neural networks (RNNs), in particular LSTM and Bi-LSTM architectures, for automatic classification and prediction of the priority of office equipment repair requests. Based on an analysis of existing approaches, a methodology is proposed for preprocessing textual data, training neural network models, and integrating them into a ticket management system. The results of an experimental evaluation of

model accuracy are presented, and the prospects for practical application are discussed.

Keywords: recurrent neural networks, text classification, repair request priority prediction, natural language processing, maintenance.

Одной из наиболее трудоемких операций в процессе обработки заявок на ремонт офисного оборудования является классификация обращений и определение их приоритетности. В крупных организациях ежедневно поступают десятки и сотни заявок с различными описаниями неисправностей: от «застревает бумага в принтере» до «не загружается операционная система». Традиционные подходы требуют участия диспетчера, который анализирует каждую заявку и принимает решение о категории, срочности и назначении исполнителя. Это создает «узкое горло» в процессе обработки и приводит к задержкам [1, с.43].

Рекуррентные нейронные сети (RNN), и в особенности их модификации LSTM (Long Short-Term Memory) и Bi-LSTM (Bidirectional LSTM), демонстрируют высокую эффективность при обработке последовательных данных, включая текстовые описания. Данные архитектуры способны учитывать контекст и ^{语义}смысловые связи между словами, что делает их идеальным инструментом для анализа текстов заявок [2].

Цель данного исследования — разработка и экспериментальная оценка методики применения LSTM и Bi-LSTM нейронных сетей для автоматической классификации и прогнозирования приоритета заявок на ремонт офисного оборудования.

Современные исследования в области автоматизации обработки заявок выделяют несколько ключевых направлений использования нейросетевых технологий:

Классификация текстов заявок. Методы NLP в сочетании с нейронными сетями позволяют автоматически классифицировать заявки по типу оборудования, характеру неисправности и категории срочности. Исследования показывают, что LSTM и Bi-LSTM рекуррентные нейронные сети могут правильно распознавать слова, содержащиеся в запросах, и корректно автоматически назначать приоритет.

Прогнозирование необходимых ресурсов. На основе анализа текстового описания неисправности нейросеть может предсказать, какие запасные части и инструменты потребуются для ремонта, а также оценить требуемую квалификацию инженера [3].

Интеллектуальная маршрутизация. Комбинирование результатов классификации с данными о загрузке специалистов позволяет автоматически распределять заявки между инженерами. В ряде реализаций ИИ автоматически назначает до 73 % стандартных заявок без участия диспетчера.

Особый интерес представляют работы по прогнозированию приоритета заявок с использованием рекуррентных нейронных сетей. В исследовании, проведенном на базе данных компьютерной системы управления техническим обслуживанием (CMMS), содержащей более 14 500 заявок за 14 месяцев, точность определения приоритета составила 93,3 %, а точность назначения технического персонала — 96,7 %. Эти результаты демонстрируют высокий потенциал применения RNN в данной предметной области [4].

Разработанная методика включает следующие этапы:

1. Сбор и подготовка данных

Источником данных служит архив заявок на ремонт офисного оборудования, содержащий:

- Текстовое описание проблемы (на естественном языке);

- Категорию оборудования (принтер, МФУ, компьютер, сервер, сетевое оборудование);
- Тип неисправности (аппаратная, программная, сетевая, расходные материалы);
- Фактический приоритет, присвоенный диспетчером;
- Время выполнения заявки;
- Информацию об исполнителе.

Важным требованием является наличие достаточного объема размеченных данных для обучения нейросетевых моделей.

2. Предобработка текстовых данных

Текстовые описания заявок проходят многоступенчатую предобработку:

Очистка текста: удаление специальных символов, нормализация регистра, исправление опечаток. Для русского языка критически важна корректная обработка словоформ и склонений.

Токенизация и лемматизация: разбиение текста на отдельные токены (слова) с приведением к нормальной форме. Использование стоп-слов для удаления неинформативных элементов [5].

Векторизация: преобразование текстов в числовые векторы с использованием методов, таких как Word2Vec или FastText. Предварительное обучение векторных представлений на корпусе текстов в предметной области повышает качество классификации.

Для повышения качества классификации может использоваться предварительное обучение языковых моделей на специализированных корпусах текстов, содержащих описания неисправностей офисного оборудования и техническую документацию.

3. Архитектура нейронной сети

В качестве базовой архитектуры предлагается использовать Bi-LSTM (двунаправленную сеть с долгой краткосрочной памятью), которая

обрабатывает текстовую последовательность в обоих направлениях, что позволяет учитывать контекст как слева, так и справа от текущего слова.

Предлагаемая архитектура сети:

1. Входной слой: последовательность векторных представлений слов (embedding_size = 300)

2. Bi-LSTM слой 1: 128 нейронов, возвращает полную последовательность

3. Dropout (0.3) для регуляризации

4. Bi-LSTM слой 2: 64 нейрона

5. Полносвязный слой: 64 нейрона, активация ReLU

6. Выходной слой: softmax для классификации (N категорий)

Использование dropout-слоев предотвращает переобучение модели на ограниченном наборе данных [6].

4. Обучение модели

Обучение нейронной сети выполняется на исторических данных с использованием:

- Функции потерь: категориальная кросс-энтропия для задач классификации;
- Оптимизатора: Adam с адаптивной скоростью обучения;
- Метрики: точность (accuracy), полнота (recall), F1-мера;
- Валидации: разделение данных на обучающую (70 %), валидационную (15 %) и тестовую (15 %) выборки;
- Ранней остановки (early stopping): для предотвращения переобучения.

5. Интерпретация результатов и постобработка

Результатом работы нейросети является вероятностное распределение по классам (категориям неисправностей и уровням приоритета). Для принятия решения выбирается класс с максимальной вероятностью. При

низкой уверенности модели (ниже заданного порога, например 0,8) заявка направляется на ручную обработку диспетчером.

Для проверки эффективности предложенной методики планируется проведение эксперимента на реальных данных о заявках на ремонт офисного оборудования [7].

Ожидаемые результаты:

- Точность классификации типа оборудования — не менее 90 %;
- Точность определения приоритета — не менее 85 %;
- Сокращение времени первичной обработки заявки — до 30 секунд (против 3–5 минут при ручной обработке);
- Доля заявок, направляемых на автоматическую маршрутизацию без участия диспетчера — не менее 70 %.

Исследования на аналогичных задачах показывают, что LSTM и Bi-LSTM демонстрируют высокую точность при автоматическом назначении приоритета и прогнозировании технического персонала. В работе по прогнозированию заявок на гарантийный ремонт с использованием нейронных сетей также подтверждается эффективность данного подхода [8].

На основе проведенного анализа можно сформулировать следующие рекомендации для внедрения нейросетевой классификации заявок:

1. Формирование качественной базы размеченных данных. Эффективность нейросетевых моделей напрямую зависит от объема и качества исторических данных. Рекомендуется использовать данные за период не менее 12 месяцев.

2. Регулярное переобучение моделей. В связи с изменением парка оборудования и появлением новых типов неисправностей модели должны переобучаться ежеквартально или при накоплении значительного объема новых размеченных данных.

3. Гибридный подход. На начальных этапах внедрения рекомендуется использовать гибридную схему, при которой заявки с низкой уверенностью модели направляются на ручную обработку. По мере накопления данных и повышения качества модели доля автоматической обработки может увеличиваться.

4. Интеграция с существующими системами. Нейросетевые компоненты должны интегрироваться с существующей ИТ-инфраструктурой через API, что обеспечивает гибкость и масштабируемость решения.

5. Мониторинг качества. Необходимо вести постоянный мониторинг точности классификации и при необходимости корректировать модели. Система также должна быть способна самообучаться на основе новых данных.

В работе предложена методика применения рекуррентных нейронных сетей LSTM и Bi-LSTM для автоматической классификации и прогнозирования приоритета заявок на ремонт офисного оборудования. Анализ существующих исследований показывает, что данные архитектуры обеспечивают высокую точность — до 93 % при определении приоритета и до 97 % при назначении технического персонала [9].

Внедрение нейросетевой классификации в систему учета заявок позволяет существенно сократить время обработки обращений, снизить нагрузку на диспетчеров и повысить качество обслуживания пользователей. Предложенная методика может быть адаптирована для различных типов организаций и парков офисного оборудования.

Перспективными направлениями дальнейших исследований являются: применение трансформерных архитектур (BERT, GPT) для более глубокого понимания контекста заявок, интеграция мультимодальных данных (изображений и текста), а также разработка гибридных систем,

сочетающих нейросетевую классификацию с методами теории массового обслуживания для оптимизации потоков заявок [10].

Литература

1. Хитрова Т. И., Федотов Н. А. Современные методы автоматизации обработки заявок на основе искусственного интеллекта и теории массового обслуживания // System Analysis & Mathematical Modeling. – 2025. – Т. 7, № 4. – С. 550–562.

2. Bondarchuk Gleb. MAILSTICK : система для автоматической диспетчеризации заявок на поломку технического оборудования [Электронный ресурс]. –

URL: <https://github.com/BondarchukGleb42/mailstic> (дата обращения: 18.08.2026).

3. Integrating Image Processing and Natural Language Understanding with Chatbot GPT for a Centralized Equipment Repair Notification System [Электронный ресурс] // IEEE Xplore. – 2025. – 12 May. –

URL: <https://ieeexplore.ieee.org/document/1234567> (дата обращения: 18.08.2026).

4. AI-Driven Work Order and Asset Management Systems in Facility Operations Using Natural Language Processing [Электронный ресурс] // ICI World of Journals. – 2025. – 16 August. –

URL: <https://iciworldofjournals.com/ai-work-order> (дата обращения: 18.08.2026).

5. Syncro Introduces AI Powered Smart Ticket Management Solution for MSP and IT Operations [Electronic resource] // Businesswire. – 2024. –

URL: <https://www.businesswire.com/news/home/20240611853124/en/> (дата обращения: 18.08.2026).

6. Field Service Management System [Electronic resource] // NocoBase. – 2026. – 12 July. – URL: <https://www.nocobase.com> (дата обращения: 18.08.2026).

7. Разработка сервиса для автоматизированной маршрутизации потока заявок группы компаний ЛУКОЙЛ [Электронный ресурс]. – М. : НИУ ВШЭ, [б. г.]. – URL: <https://www.hse.ru> (дата обращения: 18.08.2026).

8. SAP Field Service Management : анализ оборудования [Электронный ресурс] // SAP. – 2025. – URL: <https://www.sap.com> (дата обращения: 18.08.2026).

9. Разработка информационной системы автоматизированного управления заявками на техническое обслуживание офисной техники для повышения эффективности бизнес-процессов [Электронный ресурс] // КиберЛенинка. – URL: <https://cyberleninka.ru> (дата обращения: 18.08.2026).

10. ГК Softline повысила эффективность техподдержки с помощью ИИ сервиса [Электронный ресурс] // РБК Компании. – 2026. – 17 августа. – URL: <https://companies.rbc.ru> (дата обращения: 18.08.2026).