

РЕЧЕВАЯ КОММУНИКАЦИЯ: ВЗАИМОДЕЙСТВИЕ И ВОЗДЕЙСТВИЕ

Анализ тональности русскоязычных текстов с помощью нейросетевых моделей

Sentiment Analysis of Russian-Language Texts Using Neural Network Models

DOI: 10.12737/2587-9103-2025-14-3-7-14

Получено: 05 мая 2025 г. / Одобрено: 26 мая 2025 г. / Опубликовано: 26 июня 2025 г.

**И.И. Просвиркина**

Д-р пед. наук, доцент,
доцент кафедры русского языка № 5
Института русского языка
ФГАОУ ВО «Российский университет дружбы
народов имени Патриса Лумумбы»,
Россия, 117198, г. Москва, ул. Миклухо-Маклая,
д. 6,
ORCID iD: 0000-0002-4052-2853

I.I. Prosvirkina

Doctor of Pedagogical Sciences, Associate Professor,
Department of Russian Language No. 5, Institute of
Russian Language,
RUDN University,
6, Miklukho-Maklaya St., Moscow, 117198, Russia,
ORCID: 0000-0002-4052-2853

**М.А. Голубева**

Магистр лингвистики. Институт русского языка
ФГАОУ ВО «Российский университет дружбы
народов имени Патриса Лумумбы»,
Россия, 117198, г. Москва, ул. Миклухо-Маклая,
д. 6,
ORCID iD: 0000-0003-3764-7601

M.A. Golubeva

Master of Linguistics. Institute of Russian Language,
RUDN University,
6, Miklukho-Maklaya St., Moscow, 117198, Russia,
ORCID: 0000-0003-3764-7601

Аннотация

Статья посвящена определению эмоциональной тональности русскоязычных текстов с помощью нейросетевых моделей, в частности *DeepSeek*. В условиях цифровизации выявление маркеров, репрезентирующих тональность высказывания (отрицательную или положительную), становится актуальным, потому что, во-первых, экономит время исследователя, а во-вторых, делает его беспристрастным, так как исключает авторскую интерпретацию. Однако существующие языковые модели, преимущественно «обученные» на англоязычных корпусах, демонстрируют ограниченную точность при работе с русскоязычными текстами, особенно при определении положительной тональности высказываний. Проблема выявления маркеров тональности текста осложняется стилистическим разнообразием языковых средств, демонстрирующих положительную или отрицательную эмоциональность пользовательского (виртуального) дискурса. Таким образом, проверка работы *DeepSeek* с текстами в условиях русскоязычной цифровой среды позволяет выявить типичные искажения в интерпретации ею оценочного контекста высказывания и наметить пути совершенствования имеющихся нейросетевых моделей для анализа русскоязычного дискурса.

Ключевые слова: sentiment-анализ, тональность текста, эмоциональная окраска текста, нейросетевые модели, *DeepSeek*, *RuSentiment*.

Abstract

This article focuses on determining the emotional sentiment of Russian-language texts using neural network models, particularly *DeepSeek*. In the context of digitalization, identifying markers that represent the tone of a statement (negative or positive) has become increasingly relevant for two main reasons: first, it saves researchers' time, and second, it ensures impartiality by eliminating authorial interpretation. However, existing language models, primarily trained on English-language corpora, show limited accuracy when applied to Russian texts—especially in detecting positive sentiment. The challenge of identifying tonal markers is further complicated by the stylistic diversity of linguistic expressions conveying positive or negative emotionality in user discourse. Thus, testing *DeepSeek*'s performance in a Russian-language digital environment helps reveal typical distortions in its interpretation of evaluative context and outlines potential improvements for existing neural network models in analyzing Russian discourse.

Keywords: sentiment analysis, text tonality, emotional coloring of text, neural network models, *DeepSeek*, *RuSentiment*.

Введение

Современные технологии обработки естественного языка (*NLP*) становятся неотъемлемым инструментом анализа пользовательского контента в интернете, поэтому важно оценить роль данных нейросетевых моделей в анализе высказываний, в частности при выявлении их оценочной окраски. Sentiment-анализ применяется в маркетинге, медиа, социологии, политике, в службах мониторинга общественного мнения и модерации цифровых платформ. Однако,

несмотря на успехи в разработке алгоритмов для английского языка, остаются нерешёнными ключевые проблемы, связанные с точной интерпретацией оценочной составляющей текстов на других языках, особенно таких лингвистически сложных, как русский. Это делает необходимой локальную адаптацию и эмпирическую проверку нейросетевых моделей на национальных корпусах, в частности, на русскоязычном корпусе интернет-дискурса.

Научная литература последних лет демонстрирует устойчивую тенденцию к переходу от лексиконных и статистических методов sentiment-анализа к нейросетевым архитектурам, включая *LSTM*, *GRU*, *BERT* и *GPT*-подобные модели. Современные исследования показали важность предобученных эмбедингов, контекстной обработки и многоступенчатого обучения нейросетевых моделей. Тем не менее все учёные подчеркивают ограниченность универсальных нейросетевых моделей в условиях высокой экспрессивной вариативности и культурной специфики языков, не входящих в ядро глобального англоязычного пространства. Одним из вызовов в области анализа тональности, эмоциональности высказывания являются культурные различия в их восприятии и оценке, которые проявляются в семантике сленга, в прецедентных высказываниях, метафорах и т.п. Вышеназванные лексические особенности интернет-контента могут затруднять автоматическое определение эмоциональной тональности текста. Как отмечает Ю.А. Соснина, работа над созданием адаптивных нейросетевых моделей, способных учитывать культурные нюансы и специфическую лексику, является актуальной [1]. На фоне выводов исследователей [1–15] и необходимости определения именно тональной оценочности русскоязычных текстов особенно актуальной становится необходимость проверки качества работы крупных нейросетевых моделей, таких как *DeepSeek*, с русскоязычными текстами, в частности, в условиях интернет-коммуникации. Несмотря на высокую «обученность» данной нейросетевой модели, остаётся открытым вопрос: насколько точно она способна улавливать и интерпретировать эмоциональные нюансы текстов, отражающих эмоциональность, оценочность, экспрессивность и другие прагматические особенности повседневного речевого общения.

Теоретическая значимость данного исследования заключается в попытке эмпирически оценить способность современной нейросетевой модели интерпретировать эмоциональную составляющую русскоязычных текстов, сопоставляя их классификации с разметкой корпуса *RuSentiment*. Практическая важность работы связана с возможностью использовать выводы для дальнейшей адаптации нейросетевых моделей в системах автоматического мониторинга, фильтрации и анализа больших массивов русскоязычного пользовательского контента.

Новизна исследования состоит в конкретной постановке задачи: провести сопоставление результатов классификации *DeepSeek* с эталонной разметкой корпуса и выявить типичные ошибки и семантические сдвиги в восприятии нейросетевой моделью разных типов тональности высказываний. В отличие от боль-

шинства работ, сосредоточенных на обучении или улучшении нейросетевых архитектур, данная работа акцентирует внимание на прикладной проверке уже готового инструмента, что делает её актуальной с точки зрения оценки его применимости на практике. Отдельно стоит отметить, что данная нейросетевая модель является одной из новых и малоизученных — первые случаи её использования в России датируются 2025 г.

Постановка проблемы. Теоретическая часть

Целью настоящей статьи является эмпирическая проверка точности классификации тональности русскоязычных текстов нейросетевой моделью *DeepSeek* на основе корпуса *RuSentiment* и выявление специфических трудностей, связанных с интерпретацией положительной, нейтральной и отрицательной окраски в условиях реального пользовательского интернет-дискурса.

Современные исследования в области обработки естественного языка демонстрируют разнообразие подходов к анализу эмоциональной тональности текстов. В работе Д.О. Жаксыбаева и Г.Н. Мизамовой [2] подробно рассматриваются методы векторного представления слов, включая латентно-семантический анализ нейросетевых моделей (*LSA*), *Word2Vec* и *GloVe*. Авторы отмечают, что *LSA*, несмотря на свою надежность, уступает другим нейросетевым моделям по скорости обработки, тогда как *Word2Vec* показывает высокую точность классификации (81,2% для русского и 82,9% для английского корпусов). *GloVe*, хотя и менее стабилен, обладает потенциалом благодаря учету глобальной статистики корпуса. Для задач классификации оценочной тональности авторы использовали архитектуру на основе *LSTM*, подчеркивая её эффективность при обработке последовательных данных.

П.А. Савенков и его соавторы в работе «Формирование вектора поведенческих признаков на основе *LSTM* и *GRU* сетей» [3] акцентируют внимание на анализе эмоциональной тональности текстов, создаваемых на мобильных устройствах. Они выделяют сложности, возникающие с использованием в высказываниях неформальных элементов, таких как сленг, ненормированная лексика и эмодзи, и предлагают использовать метод *Embedding* для учета семантической близости слов. Дополнение корпуса *RuTweetCorp* самостоятельно собранными данными (более 50 000 текстов) позволило авторам повысить точность классификации на 5%. Среди нейросетевых архитектур наилучшие результаты показала *GRU*-сеть (92% точности), превзошедшая *LSTM* (84%) и другие полносвязные нейросетевые модели (86%).

В статье А.Л. Богданова и И.С. Дули [4], посвященной анализу языковых средств выражения эмо-

ций, обсуждаются методологические аспекты сентимент-анализа, включая оценку тональности и контекстуальной зависимости текстов. Авторы подчеркивают необходимость разработки специализированных алгоритмов для русскоязычных текстов, учитывающих богатство русского языка. Инструменты, такие как *VADER*, эффективны для англоязычных текстов, но требуют адаптации для других языков, в частности русского.

Одним из исследований, сфокусированном на изучении особенностей использования генеративных моделей для сентимент-анализа является работа С.Ю. Имбер и М.В. Томской [5]. В статье авторы демонстрируют потенциал *GPT-4* как инструмента для анализа эмотивных текстов, особенно при работе с большими массивами данных. Нейросетевая модель *GPT-4* успешно выявляет эмоциональные маркеры (лексические, синтаксические, пунктуационные) и обобщает информацию, что подтверждается анализом немецкоязычных постов. Однако *GPT-4* не различает ключевые для лингвистики понятия эмоциональности (спонтанное проявление эмоций) и эмотивности (целенаправленное воздействие на читателя), что ограничивает её применение. К преимуществам работы с *GPT-4* можно отнести скорость обработки и понимание контекста, к недостаткам — склонность к обобщениям без опоры на конкретные примеры и терминологические неточности. Полученные результаты показывают, что нейросетевую модель *GPT-4* можно использовать как вспомогательный инструмент для первичного анализа, но её выводы требуют обязательной проверки традиционными лингвистическими методами. Особое внимание при интерпретации полученных результатов следует уделять лингвокультурным, грамматическим и лексическим особенностям русскоязычных текстов, которые модель может недооценивать. Таким образом, интеграция нейросетевой модели *GPT-4* в исследования возможна, но требует критического подхода и дальнейшей разработки методик совмещения *AI* с классическим анализом.

Говоря об анализе эмотивности текстов, стоит выделить работу О.Ю. Гукосьянц и О.А. Алимурادова [6], в которой исследуется конфликтное речевое поведение в интернет-коммуникации, выделяются эксплицитные (бранная лексика, зоометафоры) и имплицитные (дихотомия «свой — чужой», графические средства) маркеры агрессии. В работе авторы предлагают ряд практических решений для мониторинга и регулирования агрессивного поведения в цифровой среде.

Также активно развиваются методы векторного представления слов, в частности, нейросетевая модель *FastText*, которая эффективно работает с редкими и

новыми словами, особенно в языках с богатой морфологией, таких как русский, благодаря учёту субсловных единиц, включая суффиксы и приставки. В отличие от классических нейросетевых моделей (вроде *Word2Vec*), в которых каждое слово имеет свой вектор, *FastText* разбивает слова на части — символьные n -граммы (например, «котёнок» на «кот», «отё», «тён»). Вектор слова получается суммированием векторов этих n -грамм, что позволяет обрабатывать даже слова, не встречающиеся в корпусах текстов, собранных для нейросети (обучающих данных). Хотя стандартная нейросетевая модель *FastText* хранит вектора и для целых слов (что требует большого объёма памяти), современные модификации используют только n -граммы, уменьшая размер модели без потери качества. Это делает *FastText* универсальным инструментом для работы с текстами, особенно в случаях, когда важно учитывать редкие словоформы или неизвестные слова [7].

Активно изучается проблема использования метода сентимент-анализа и в зарубежных исследованиях. Так, в статье *State of Art for Semantic Analysis of Natural Language Processing* [8] подробно анализируются существующие подходы к семантическому анализу текста с помощью нейросетевых моделей. Авторы подчеркивают, что способность системы правильно интерпретировать значение слов и предложений в контексте является фундаментальной задачей *NLP*, особенно в таких областях, как анализ эмоциональной окраски текстов и выявление мнения говорящего (пишущего), т.е. понимания скрытых смыслов, заложенных в высказываниях. В числе основных сетевых моделей, способствующих решению проблемы определения оценочности, выделяют:

- анализ тональности (*Sentiment Analysis*) — нейросетевая модель, которая классифицирует тексты в соответствии с их эмоциональной направленностью (позитивной, негативной, нейтральной). Данная модель широко используется в бизнесе, политике, социальных сетях и других сферах;
- применение нейросетевой модели, определяющей онтологии, позволяет структурировать знания и устранять лексическую неоднозначность, что особенно важно при переводах и в многоязычных приложениях. Онтологические модели служат эффективным инструментом для уточнения семантических связей между объектами и событиями;
- нейросетевые модели «глубокого обучения», включая архитектуры *LSTM* (*Long Short-Term Memory*) и их модификации, показывают высокую эффективность в задачах эмоционального анализа и классификации сложных текстов, где требуется учет далекодействующих зависимостей в данных.

Кроме того, в статье [8] затрагиваются существующие проблемы в области семантического анализа с использованием нейросетевых моделей: ограниченная поддержка языков за пределами английского и западноевропейских, трудности в обработке нестандартного языка (сленг, эмодзи, неформальные выражения), а также влияние культурных различий на интерпретацию оценочной, эмоциональной тональности текста. Авторы считают, что современные методы анализа с привлечением нейросетевых моделей *Word2Vec* и *LDA* демонстрируют лучшие результаты по сравнению с традиционными моделями типа *WordNet*, особенно при анализе больших объемов текстов.

Отдельно стоит остановиться на нейросетевых архитектурах *LSTM* (*Long Short-Term Memory*), описанных в статье Клауса Греффа и его соавторов [9]. Исследователи считают, что именно эти нейросетевые модели особенно эффективны для анализа текстов, содержащих оценку, эмоции, благодаря способности обрабатывать длинные текстовые зависимости и сохранять релевантную информацию на протяжении всей последовательности. Данные нейросетевые модели успешно решают проблему исчезающего градиента, характерную для обычных рекуррентных нейросетей, а также являются невосприимчивыми к длительности временных разрывов, что даёт им явное преимущество по сравнению с предыдущими моделями при исследовании эмоциональной окраски текста [9].

Значительный вклад в развитие методов анализа с использованием нейросетевых моделей для определения эмоциональной тональности текстов вносит исследование М. Клиша [10], представленное в рамках конкурса *SemEval-2017*. В статье автор предлагает систему для классификации тональности твитов, объединив возможности сверточных нейронных сетей (*CNN*) и рекуррентных нейросетей с долгой краткосрочной памятью (*LSTM*). Подход строится на трехэтапной схеме обучения нейросетевой модели. На первом этапе осуществляется предобучение на неразмеченных данных с использованием алгоритмов *Word2vec*, *FastText* и *GloVe*, что позволяет создать плотные векторные представления слов. Вторым этапом является дистанционное обучение на основе автоматической разметки с помощью эмодзи, что позволяет учесть эмоциональные оттенки текстов без необходимости трудоемкой ручной аннотации. Наконец, третий этап представляет контролируемое обучение на размеченных выборках *SemEval*, с применением ансамблей *CNN* и *LSTM* для достижения максимальной точности.

Особенностью предложенной методики анализа становится активное использование ансамблирова-

ния: обучение и объединение 20 моделей с разными архитектурами и гиперпараметрами позволяет значительно повысить стабильность предсказаний и комплексно решить задачи анализа высказываний. Данная работа демонстрирует важность использования предобученных эмбеддингов, многоступенчатого обучения и ансамблирования нейронных сетей для повышения точности анализа тональности коротких текстов в социальных сетях.

В обзорной статье Т. Хана и его соавторов [11] рассматриваются различные методы анализа тональности с использованием нейросетевых моделей и описываются сложности, возникающие при их применении. Авторы обсуждают три ключевых подхода к анализу тональности текстов с помощью нейросетевых моделей.

Первый — использование методов машинного обучения. Например, наивный Байесовский классификатор прост в реализации, но его точность ограничена из-за предположения о независимости признаков. Метод опорных векторов (*SVM*) показывает высокую точность на текстовых данных, однако требует значительных вычислительных затрат. Алгоритмы на основе *k*-ближайших соседей (*k-NN*) работают хорошо при правильном выборе метрики расстояния, но их результаты ухудшаются при наличии шума в данных.

Второй — применение лексиконных методов, основанных на заранее подготовленных словарях слов, с помощью которых репрезентируются оценка, эмоциональность, экспрессивность. Они не требуют обучения, что делает их удобными для быстрого применения, но их главный недостаток — неспособность учитывать контекст высказывания, его лингвокультурные маркеры.

Третий — задействовать в процессе анализа статистические методы, такие как латентный семантический анализ (*LSA*) и *PMI*, которые анализируют связи между словами на основе их совместной «встречаемости». Эти методы эффективны при обработке больших объемов данных, но могут уступать более сложным алгоритмам в точности.

Теоретическую базу анализа выражения мнений носителей языка закладывает работа Т. Луо и его соавторов [12], в которой предложена модель представления мнений в виде пяти элементов: объект, атрибут, направленность, субъект, время. Это формализованное представление позволяет четче структурировать информацию о мнениях и проводить более точный аспектный анализ. Также авторы подчеркивают важность различения между явными и скрытыми (имплицитными) мнениями, что требует тонкого анализа контекста и сложных моделей интерпретации.

Авторы проанализированных нами исследований также выделяют ряд проблем, характерных для анализа тональности высказывания. На уровне текстов возникают сложности, которые связаны с неформальным стилем, орфографическими ошибками, спамом и т.д. На уровне предложений некорректно обрабатываются отрицания и сравнительные конструкции. При аспектном анализе необходимо учитывать мнения о конкретных характеристиках объектов, таких как «качество камеры» или «автономность смартфона». На лексическом уровне возникают трудности из-за синонимии, многозначности слов и отсутствия специализированных словарей для узких предметных областей.

Таким образом, современные тенденции в развитии sentiment-анализа показывают устойчивое движение в сторону применения нейросетевых архитектур и методов глубокого обучения. Модели *LSTM*, *GRU*, *CNN* и их комбинации становятся основным инструментом анализа благодаря своей способности учитывать сложные контекстуальные зависимости в тексте, что особенно важно при обработке длинных или структурно неоднозначных высказываний. Большую роль играют предобученные векторные представления слов, такие как *Word2Vec*, *GloVe* и *FastText*, которые позволяют учитывать семантические связи между словами и адаптироваться к тематике корпуса. Широко применяется многоэтапное обучение, включая предобучение на неразмеченных данных, дистанционную разметку с помощью эмодзи и последующую донастройку на размеченных выборках.

Особое внимание уделяется анализу пользовательского и неформального контента, характерного для социальных сетей и мобильных коммуникаций. Сленг, эмодзи, графические и орфографические отклонения требуют более гибких моделей и контекстно-чувствительной обработки. На этом фоне возрастает значимость адаптации нейросетевых моделей к конкретным языкам и их культурным маркерам. Универсальные англоязычные инструменты демонстрируют ограниченную применимость за пределами западноевропейских языков, что стимулирует разработку специализированных решений для русского и других языков с богатой лексикой, морфологией, грамматикой.

Генеративные модели, являющиеся разновидностью нейросетевых моделей, такие как *GPT-4*, начинают активно использоваться для первичного анализа, особенно при работе с большими массивами данных. Они хорошо справляются с выявлением лексических, синтаксических и пунктуационных маркеров оценочности, однако склонны к чрезмерным обобщениям, терминологическим неточностям и не различают скрытые смыслы текста и оттенки эмоций.

Данная проблема требует критического подхода к применению генеративных моделей и последующей валидации результатов с использованием традиционных методов.

Одним из перспективных направлений становится формализованное представление мнений в виде параметризованных нейросетевых моделей, учитывающих объект, его характеристику, направленность оценки, субъект и временной контекст. Такая структура позволяет проводить более точный аспектный анализ, а также различать явные и скрытые мнения. Кроме того, при анализе текстов становятся популярными гибридные и ансамблевые подходы, сочетающие различные нейросетевые архитектуры и методики, что повышает устойчивость при использовании сетевых моделей и точность их предсказаний. Эти методы особенно успешно применяются в конкурсах и задачах с ограниченными или зашумленными данными.

Метод sentiment-анализа расширяет области применения — от маркетинга и социальных сетей до мониторинга агрессии, анализа политических и кризисных коммуникаций. Общее направление развития сфокусировано на повышении точности, адаптивности и интерпретируемости используемых при анализе нейросетевых моделей, а также на создании архитектур, способных работать в многоязычной и мультикультурной среде.

Для дальнейшего развития в данной сфере требуется усиление междисциплинарных исследований на стыке лингвистики, психологии и машинного обучения, а также активное развитие ресурсов для сложных и малораспространенных языков.

Материалы и методы исследования

Для проведения исследования был использован открытый корпус *RuSentiment*, содержащий размеченные тексты из социальной сети «ВКонтакте». После подготовки выборки каждый текст был обработан с использованием языковой модели *DeepSeek*. Взаимодействие с моделью осуществлялось через *API*: каждый текст отправлялся поочередно, после чего фиксировалась его эмоциональная классификация, присвоенная моделью. Реализация процедуры была выполнена на языке *Python*: скрипт читал тексты из *CSV*-файла корпуса, фильтровал по меткам, автоматически формировал запросы к *API* и собирал предсказанные результаты.

Исследование основывалось на методе сопоставительного анализа, в рамках которого классификация нейросетевой модели сравнивалась с референсной разметкой корпуса. Были построены количественные матрицы соответствий и проведена первичная интерпретация отклонений. Методологически

работа опирается на практики эмпирической верификации нейросетевых систем в задачах обработки естественного языка и анализа тональности текстов. Анализ проводился без вмешательства в работу модели, чтобы сохранить чистоту эксперимента и объективность оценки.

Дискуссия

В ходе проведённого исследования удалось получить данные, позволяющие оценить точность и специфику работы модели *DeepSeek* при классификации эмоциональной тональности русскоязычных текстов на основе корпуса *RuSentiment*. Всего было проанализировано 300 сообщений, равномерно распределённых по трём категориям: положительные, нейтральные и отрицательные. Каждое сообщение было классифицировано моделью, а затем результаты были сопоставлены с корпусной разметкой.

Полученные данные показали высокую согласованность нейросетевой модели с корпусом в отношении нейтральных и отрицательных высказываний. Так, из 100 отрицательных сообщений модель правильно классифицировала 77 как отрицательные, 20 — как нейтральные и лишь 3 — как положительные. Аналогично, для нейтральных текстов было получено 83 совпадения, 13 отклонений в сторону «отрицательных» и 4 — «положительных». Самые значительные расхождения наблюдаются в категории положительных сообщений: нейросетевая модель классифицировала 74 из них как нейтральные, и лишь 24 — как действительно положительные. Это указывает на то, что *DeepSeek* имеет тенденцию занижать тональность текста сообщений с положительной оценкой, вероятно, из-за особенностей его обучающего корпуса или ограничения в интерпретации эксплицитной положительной эмоциональности в русском языке.

Такая асимметрия в результатах может быть связана с несколькими факторами. Во-первых, в положительную категорию корпуса включены тексты, в которых выражение эмоций имеет скрытый, контекстуальный характер, что затрудняет их автоматическое распознавание [13; 14]. Например, фразы типа «Эх, как же хочется в Неверляндию...» или «Дико хочется жрать!» имеют экспрессивную окраску, которую человек воспринимает как положительную, но для модели такие формулировки остаются нейтральными из-за отсутствия явных лексем с положительным маркером. Во-вторых, часть расхождений может быть вызвана субъективностью при первоначальной ручной разметке корпуса, что также поднимает вопрос о качестве и интерпретативной стабильности эталонных данных.

Сравнение с опытом других исследователей подтверждает, что подобные сложности в интерпретации эмоционального фона характерны и для других нейросетевых моделей. Например, в работах, рассматривающих использование *LSTM* и *GRU*, также подчёркивается трудность точного выявления положительных эмоций в неформальных или косвенных высказываниях [15]. В частности, в конкурсной работе М. Клиш на *SemEval-2017* была предпринята попытка компенсировать этот эффект за счёт многоэтапного обучения и эמודзи-разметки, что подтверждает необходимость дополнительной подготовки данных для усиления эксплицитности положительных эмоций в обучающих выборках.

Результаты данного исследования демонстрируют, что *DeepSeek* может успешно использоваться в прикладных задачах первичной фильтрации и категоризации текстов по эмоциональной направленности. Особенно эффективна модель при работе с негативным и нейтральным контентом, где её классификации совпадают с корпусной аннотацией в 77% и 83% случаев соответственно. Однако при работе с положительными текстами необходима дополнительная калибровка модели, либо повторное обучение на более репрезентативных для этой категории данных.

В научном плане исследование подчёркивает значимость критического подхода как к нейросетевым моделям, так и к корпусам, которые используются в качестве эталона. Проведённая нами исследовательская процедура также показывает, что даже современные мощные нейросетевые архитектуры допускают ошибки, особенно в условиях культурной, лексической, стилистической неоднозначности. Показанные результаты представляют практический интерес для специалистов по прикладной лингвистике, разработчиков систем анализа социальных сетей, а также исследователей, работающих на стыке искусственного интеллекта и гуманитарных наук.

Выводы

Целью настоящего исследования является эмпирическая проверка точности и устойчивости модели *DeepSeek* при определении положительной или отрицательной эмоциональной тональности русскоязычных текстов с опорой на эталонную разметку корпуса *RuSentiment*. В ходе проведённого исследования была протестирована способность нейросетевой модели *DeepSeek* классифицировать эмоциональную тональность русскоязычных пользовательских текстов с опорой на корпус *RuSentiment*.

Экспериментальная проверка показала высокую точность нейросетевой модели в определении нейтральных и особенно отрицательных сообщений, при этом трудности возникли при распознавании поло-

жительной тональности. Анализ выявил систематическое смещение результатов, предлагаемых нейросетевой моделью, в сторону нейтральной оценки, что частично объясняется спецификой выражения положительных эмоций в русском языке, а также вероятной недоадаптацией данной модели к культурному и лингвистическому русскоязычному контексту. Проведённая проверка работы нейросетевой модели *DeepSeek* в условиях русскоязычной цифровой среды выявила типичные искажения в интерпретации ею оценочного контекста высказывания.

Исследование подтверждает актуальность задачи тонкой настройки и локализации нейросетевых моделей для русского языка. Практический вклад работы заключается в эмпирической оценке эффективности *DeepSeek* на сбалансированном и размеченном датасете, что позволяет объективно судить о её применимости в реальных условиях — для мониторинга общественного мнения, фильтрации токсичных высказываний и анализа пользовательского контента.

Литература

1. Соснина Ю.А. Эмотивность внутренней формы слова: по данным метаязыковой деятельности носителей русского языка: дис. ... канд. филол. наук: 10.02.01 [Текст] / Ю.А. Соснина. — Кемерово, 2009. — 184 с.
2. Жаксыбаев Д.О. Алгоритмы обработки естественного языка для понимания семантики текста [Текст] / Д.О. Жаксыбаев, Г.Н. Мизамова // Труды ИСП РАН. — 2022. — № 1. — URL: <https://cyberleninka.ru/article/n/algoritmy-obrabotki-estestvennogo-yazyka-dlya-ponimaniya-semantiki-teksta> (дата обращения: 25.04.2025).
3. Савенков П.А. Формирование вектора поведенческих признаков на основе LSTM и GRU сетей [Текст] / П.А. Савенков, А.Г. Волошко, А.Н. Ивутин, О.С. Крюков // Известия ТулГУ. Технические науки. — 2024. — № 12. — URL: <https://cyberleninka.ru/article/n/formirovanie-vektora-povedencheskih-priznakov-na-osnove-istm-i-gru-setey> (дата обращения: 18.04.2025).
4. Богданов А.Л. Сентимент-анализ коротких русскоязычных текстов в социальных медиа [Текст] / А.Л. Богданов, И.С. Дуля // Вестник Томского государственного университета. Экономика. — 2019. — № 47. — URL: <https://cyberleninka.ru/article/n/sentiment-analiz-korotkih-russkoyazychnyh-tekstov-v-sotsialnyh-media> (дата обращения: 23.04.2025).
5. Имбер С.Ю. Возможность применения нейросети GPT-4 в лингвистическом исследовании: на примере анализа эмотивных текстов [Текст] / С.Ю. Имбер, М.В. Томская // Социальные и гуманитарные науки. Отечественная и зарубежная литература. Серия 6. Языкознание. — 2024. — № 4. — С. 126–138. — DOI: [10.31249/ling/2024.04.07](https://doi.org/10.31249/ling/2024.04.07)
6. Гукосьянц О.Ю. Эксплицитные и имплицитные маркеры конфликтного речевого поведения в интернет-опосредованной коммуникации периода пандемии COVID-19 [Текст] / О.Ю. Гукосьянц, О.А. Алимуратов // Научные исследования и разработки. Современная коммуникативистика. — 2023. — № 6. — С. 94–104. — DOI: <https://doi.org/10.12737/2587-9103-2023-12-6-94-104> (дата обращения: 18.04.2025).
7. Гукасян Ц.Г. Векторные модели на основе символьных n-грамм для морфологического анализа текстов [Текст] / Ц.Г. Гукасян // Труды ИСП РАН. — 2020. — № 2. — URL: <https://cyberleninka.ru/article/n/vektornye-modeli-na-osnove-simvolnyh-n-gramm-dlya-morfologicheskogo-analiza-tekstov>

В качестве перспектив дальнейших исследований можно отметить расширение выборки, включение многоаспектной аннотации (например, с учётом иронии или эмотивности), тестирование других языковых моделей и проведение дообучения на специально подобранных подкорпусах, отражающих живую речевую практику интернет-пространства. Кроме того, важно продолжать работу над улучшением репрезентативности исходных датасетов и уточнением критериев разметки, особенно в пограничных или субъективных случаях.

Результаты исследования вносят вклад в развитие прикладной лингвистики, в частности в области анализа различных текстов (в области журналистики, лингвокриминалистики, персоналогии и т.п.), а также в практике обработки высказываний в интернет-коммуникации. Результаты данного исследования могут быть учтены при использовании различных систем мониторинга оценочной тональности текстов, свидетельствующие о коммуникационных рисках их применения.

- simvolnyh-n-gramm-dlya-morfologicheskogo-analiza-tekstov (дата обращения: 16.04.2025).
8. Maulud Dastan & Zeebaree Subhi & Jacksi, Karwan & M.Sadeeq, Mohammed & Hussein, Karzan. (2021). State of Art for Semantic Analysis of Natural Language Processing. Qubahan Academic Journal. 1. 21–28. 10.48161/qaj.v1n2a40
9. Klaus Greff, Rupesh Kumar Srivastava, Jan Koutník, Bas R. Steunebrink, Jürgen Schmidhuber. LSTM: A Search Space Odyssey // IEEE Transactions on Neural Networks and Learning Systems 2017 [Электронный ресурс]. URL: <https://arxiv.org/pdf/1503.04069.pdf>
10. Cliche Mathieu. (2017). BB_twtr at SemEval-2017 Task 4: Twitter Sentiment Analysis with CNNs and LSTMs. 573–580. 10.18653/v1/S17-2094
11. Khan Taimoor & Durrani Mehr & Ali Armughan & Inayat, Irum & Khalid, Shehzad & Khan Kamran. (2016). Sentiment analysis and the complex natural language. Complex Adaptive Systems Modeling. 4. 10.1186/s40294-016-0016-9
12. Luo, Tiejian & Chen, Su & Xu, Guandong & Zhou, Jia. (2013). Sentiment Analysis. 10.1007/978-1-4614-7202-5_4
13. Smetanin Sergey. (2020). The Applications of Sentiment Analysis for Russian Language Texts: Current Challenges and Future Perspectives. IEEE Access. Pp. 1-1. 10.1109/ACCESS.2020.3002215
14. Семина Т.А. Анализ тональности текста: современные подходы и существующие проблемы [Текст] / Т.А. Семина // Социальные и гуманитарные науки. Отечественная и зарубежная литература. Сер. 6, Языкознание: Реферативный журнал. — 2020. — № 4. — URL: <https://cyberleninka.ru/article/n/analiz-tonalnosti-teksta-sovremennye-podhody-i-suschestvuyushchie-problemy> (дата обращения: 23.04.2025).
15. Yuxiao Chen, Jianbo Yuan, Quanzeng You, and Jiebo Luo. 2018. Twitter Sentiment Analysis via Bi-sense Emoji Embedding and Attention-based LSTM. In Proceedings of the 26th ACM international conference on Multimedia (MM '18). Association for Computing Machinery, New York, NY, USA, 117–125. <https://doi.org/10.1145/3240508.3240533>.

References

1. Sosnina Yu.A. Emotivnost' vnutrenney formy slova: po dannym metayazykovoy deyatel'nosti nositeley russkogo yazyka [Emo-

- tivity of the internal form of a word: based on the metalinguistic activity of native Russian speakers]. Kemerovo, 2009. 184 p. (in Russian)
2. Zhaksybaev D.O., Mizamova G.N. Algoritmy obrabotki estestvennogo yazyka dlya ponimaniya semantiki teksta [Natural language processing algorithms for understanding text semantics]. Trudy ISP RAN [Proceedings of the ISP RAS]. 2022, no. 1. URL: <https://cyberleninka.ru/article/n/algoritmy-obrabotki-estestvennogo-yazyka-dlya-ponimaniya-semantiki-teksta> (accessed: 25.04.2025). (in Russian)
 3. Savenkov P.A., Voloshko A.G., Ivutin A.N., Kryukov O.S. Formirovanie vektora povedencheskikh priznakov na osnove LSTM i GRU setey [Formation of a behavioral feature vector based on LSTM and GRU networks]. Izvestiya TulGU. Tekhnicheskie nauki [News of Tula State University. Technical Sciences]. 2024, no. 12. URL: <https://cyberleninka.ru/article/n/formirovanie-vektora-povedencheskikh-priznakov-na-osnove-lstm-i-gru-setey> (accessed: 18.04.2025). (in Russian)
 4. Bogdanov A.L., Dulya I.S. Sentiment-analiz korotkikh russkoyazychnykh tekstov v sotsial'nykh media [Sentiment analysis of short Russian-language texts in social media]. Vestnik Tomskogo gosudarstvennogo universiteta. Ekonomika [Bulletin of Tomsk State University. Economics]. 2019, no. 47. URL: <https://cyberleninka.ru/article/n/sentiment-analiz-korotkih-russkoyazychnykh-tekstov-v-sotsialnykh-media> (accessed: 23.04.2025). (in Russian)
 5. Imber S.Yu., Tomskaya M.V. Vozmozhnost' primeneniya neyroseti GPT-4 v lingvisticheskom issledovanii: na primere analiza emotivnykh tekstov [The possibility of using GPT-4 neural network in linguistic research: on the example of emotive text analysis]. Sotsial'nye i gumanitarnye nauki. Otechestvennaya i zarubezhnaya literatura. Seriya 6. Yazykoznanie [Social and Human Sciences. Domestic and Foreign Literature. Series 6. Linguistics]. 2024, no. 4, pp. 126–138. DOI: 10.31249/ling/2024.04.07 (in Russian)
 6. Gukosyants O.Yu., Alimuradov O.A. Eksplitsitnye i implitsitnye markery konfliktного rechevogo povedeniya v internet-oposredovannoy kommunikatsii perioda pandemii COVID-19 [Explicit and implicit markers of conflict speech behavior in Internet-mediated communication during the COVID-19 pandemic]. Nauchnye issledovaniya i razrabotki. Sovremennaya kommunikativistika [Scientific Research and Development. Modern Communication Studies]. 2023, no. 6, pp. 94–104. DOI: 10.12737/2587-9103-2023-12-6-94-104 (accessed: 18.04.2025). (in Russian)
 7. Gukasyan Ts.G. Vektornye modeli na osnove simvol'nykh n-gramm dlya morfologicheskogo analiza tekstov [Vector models based on character n-grams for morphological text analysis]. Trudy ISP RAN [Proceedings of the ISP RAS]. 2020, no. 2. URL: <https://cyberleninka.ru/article/n/vektornye-modeli-na-osnove-simvolnykh-n-gramm-dlya-morfologicheskogo-analiza-tekstov> (accessed: 16.04.2025) (in Russian)
 8. Maulud D., Zeebaree S., Jacksi K., Sadeeq M., Hussein K. State of Art for Semantic Analysis of Natural Language Processing. Qubahan Academic Journal. 2021, vol. 1, no. 2, pp. 21–28. DOI: 10.48161/qaj.v1n2a40.
 9. Greff K., Srivastava R.K., Koutník J., Steunebrink B.R., Schmidhuber J. LSTM: A Search Space Odyssey. IEEE Transactions on Neural Networks and Learning Systems. 2017. URL: <https://arxiv.org/pdf/1503.04069.pdf>.
 10. Cliche M. BB_twtr at SemEval-2017 Task 4: Twitter Sentiment Analysis with CNNs and LSTMs. *Proceedings of the 11th International Workshop on Semantic Evaluation (SemEval-2017)*. 2017, pp. 573–580. DOI: 10.18653/v1/S17-2094.
 11. Khan T., Durrani M., Ali A., Inayat I., Khalid S., Khan K. Sentiment analysis and the complex natural language. Complex Adaptive Systems Modeling. 2016, vol. 4. DOI: 10.1186/s40294-016-0016-9.
 12. Luo T., Chen S., Xu G., Zhou J. Sentiment Analysis. In: Social Media Retrieval. London, Springer, 2013. DOI: 10.1007/978-1-4614-7202-5_4.
 13. Smetanin S. The Applications of Sentiment Analysis for Russian Language Texts: Current Challenges and Future Perspectives. IEEE Access. 2020. DOI: 10.1109/ACCESS.2020.3002215.
 14. Semina T.A. Analiz tonal'nosti teksta: sovremennye podkhody i sushchestvuyushchie problemy [Sentiment analysis of text: modern approaches and existing problems]. Sotsial'nye i gumanitarnye nauki. Otechestvennaya i zarubezhnaya literatura. Ser. 6, Yazykoznanie [Social and Human Sciences. Domestic and Foreign Literature. Ser. 6, Linguistics]. 2020, no. 4. URL: <https://cyberleninka.ru/article/n/analiz-tonalnosti-teksta-sovremennye-podhody-i-suschestvuyushchie-problemy> (accessed: 23.04.2025). (in Russian)
 15. Chen Y., Yuan J., You Q., Luo J. Twitter Sentiment Analysis via Bi-sense Emoji Embedding and Attention-based LSTM. Proceedings of the 26th ACM International Conference on Multimedia (MM '18). New York, ACM, 2018, pp. 117–125. DOI: 10.1145/3240508.3240533