

Санкт-Петербургский государственный университет

**Быкова Анна Павловна**

**Выпускная квалификационная работа**

**ОЦЕНКА ЭМОЦИОНАЛЬНОЙ ОКРАСКИ СЛОВСОЧЕТАНИЙ В  
ПОСТАХ СОЦИАЛЬНОЙ СЕТИ «ВКОНТАКТЕ»  
МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ**

Уровень образования: магистратура

Направление 45.04.02 «Лингвистика»

Основная образовательная программа ВМ.5805. «Компьютерная и  
прикладная лингвистика»

Научный руководитель:  
доцент, Кафедра математической  
лингвистики,

Хохлова Мария Владимировна

Рецензент:

доцент, Национальный исследовательский  
университет «Высшая школа экономики»,

Факультет гуманитарных наук, Школа  
лингвистики,

Клышинский Эдуард Станиславович

Санкт-Петербург

2023

## ОГЛАВЛЕНИЕ

ОГЛАВЛЕНИЕ.....	2
ВВЕДЕНИЕ.....	3
ГЛАВА 1. ЛИНГВИСТИЧЕСКИЕ ИССЛЕДОВАНИЯ КАТЕГОРИИ ЭМОЦИОНАЛЬНОСТИ.....	7
1.1 Теоретические подходы к исследованию эмоциональности.....	7
1.2 Модели эмоций и тональности.....	10
1.3 Методы определения эмоций в тексте.....	14
1.4 Метрики оценки качества моделей классификации.....	23
ГЛАВА 2. ИССЛЕДОВАНИЯ КОРПУСОВ СОЦИАЛЬНЫХ СЕТЕЙ В ОБЛАСТИ ТОНАЛЬНОЙ И ЭМОЦИОНАЛЬНОЙ ОЦЕНКИ.....	27
ГЛАВА 3. ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ ЭМОЦИОНАЛЬНОЙ ОКРАСКИ ПОСТОВ И СЛОВСОЧЕТАНИЙ.....	33
3.1 Сбор и разметка экспериментального корпуса эмоционально окрашенных текстов.....	33
3.2 Эксперименты по автоматической классификации постов методами машинного обучения.....	43
3.3 Результаты оценки эмоциональной окраски текста постов.....	45
3.4 Модель на основе gubert-tiny2.....	51
3.5 Оценка эмоциональной окраски словосочетаний.....	52
ЗАКЛЮЧЕНИЕ.....	60
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ.....	62
ПРИЛОЖЕНИЕ А. СПИСОК ПОПУЛЯРНЫХ ГРУПП «ВКОНТАКТЕ» НА 5 ФЕВРАЛЯ 2023 ГОДА.....	68
ПРИЛОЖЕНИЕ Б. ВИЗУАЛИЗАЦИЯ СЛОВСОЧЕТАНИЙ ДЛЯ КЛАССОВ ЭМОЦИЙ И ТОНАЛЬНОСТИ.....	74
ПРИЛОЖЕНИЕ В. МЕТРИКИ ОЦЕНКИ КАЧЕСТВА КЛАССИФИКАЦИИ ДЛЯ МЕТОДОВ С НАИЛУЧШИМИ ПОКАЗАТЕЛЯМИ.....	82

## ВВЕДЕНИЕ

На данный момент общение в интернете, в частности общение в социальных сетях, является значимой частью жизни многих людей. В социальной сети чаще происходит неформальное эмоционально окрашенное общение, поэтому текст сообщений, размещённых в публичном пространстве, можно использовать для оценки эмоциональной окраски текста. Уже не одно десятилетие достаточно много внимания исследователи уделяют анализу тональности и эмоциональной окраски текста и речи. В данной работе представлено исследование по оценке эмоциональной окраски постов и словосочетаний в этих постах в социальной сети «ВКонтакте».

**Актуальность работы** обуславливается интересом автора и научного сообщества к рассмотрению эмоциональной окраски текста с лингвистической точки зрения, а также значительным вниманием исследователей к задаче анализа тональности текстов. Оценка эмоциональной окраски текстов имеет множество практических применений, например, в маркетинге, в приложениях при работе с клиентами, в политологии при работе с политически окрашенными текстами, в здравоохранении. Изучается потенциал анализа эмоций для выявления и предотвращения различных форм онлайн-злоупотреблений, например, запугивания пользователей. Кроме того, растёт интерес к тому, как эмоции передаются в разных языках и культурах, и как это может повлиять на оценку эмоциональной окраски различной информации [28]. Большой интерес исследователей вызывает межъязыковой анализ тональности [42].

**Новизна** исследования заключается в том, что выделены классы эмоций с учётом тональности для коротких текстов сообщений на основе эмбдзи из социальной сети «ВКонтакте» для русского языка и проведены эксперименты по оценке качества методов машинного обучения на данных с выделенными классами. В данном исследовании предлагается комбинация тонального анализа и анализа эмоций, адаптированная шкала эмоций, выражение эмоций на уровне выделенных словосочетаний. Новизна

представленной в исследовании разметки заключается в том, что используются эмодзи в качестве основания для разметки.

Эмодзи — это цифровые изображения или значки, которые используются в текстовых сообщениях в различных социальных сетях, в том числе «ВКонтакте». Язык эмодзи своего рода графический язык, где вместо слов используются сочетания картинок. Впервые эмодзи появились в Японии и распространились по всему миру. В настоящее время использование эмодзи достаточно популярно и доступно в самых разных стилях и дизайнах. Популярность эмодзи обусловлена тем, что они могут передавать эмоции и добавлять контекст к текстовому общению. В некоторых случаях эмодзи помогают преодолевать языковые барьеры и делают общение более доступным среди людей, которые владеют разными языками.

**Объектом** исследования является эмоционально-оценочный компонент в постах социальной сети «ВКонтакте». Пост в социальной сети — это публикация информации, которой делятся пользователи социальной сети. В данном исследовании рассматривается текстовая информация. **Предметом** исследования являются лингвистические средства выражения эмоциональной оценки содержания постов, прежде всего, на уровне словосочетаний.

**Целью** исследования является изучение возможностей определения эмоциональной окраски текста постов и словосочетаний в них на русском языке методами машинного обучения, используя текстовые данные, собранные из публичных сообществ в социальной сети «ВКонтакте».

Для достижения цели исследования необходимо было выполнить следующие задачи:

- 1) собрать текстовые данные постов из социальной сети «ВКонтакте»;
- 2) выполнить отбор постов, наиболее подходящих для цели исследования;
- 3) провести оценку используемых в собранных данных эмодзи, распределить их по классам эмоций и тональности;
- 4) автоматически разметить выбранные данные по сформированным классам эмоций и тональности;



5) выделить словосочетания из текста постов, которые распределены по классам эмоций и тональности;

6) провести эксперименты с помощью методов машинного обучения таких как, логистическая регрессия (Logistic Regression), наивный байесовский классификатор (Gaussian NB), метод опорных векторов (SVM), градиентный бустинг (Gradient Boosting), случайный лес (Random Forest), классификатор дерева решений (Decision Tree Classifier), также провести эксперименты нейросетевыми методами (одномерная свёрточная нейросеть CNN, рекуррентная нейросеть LSTM и рекуррентная нейросеть GRU);

7) провести оценку результатов экспериментов по метрикам качества F1-меры;

8) сделать выводы о возможности оценки эмоциональной окраски текста постов и словосочетаний в них методами машинного обучения.

**Материалом** исследования являются посты на русском языке в социальной сети «ВКонтакте» и словосочетания, которые встречаются в этих постах. Посты получены с помощью открытого API (Application Programming Interface), которым можно пользоваться для сбора данных. Данные взяты из 100 наиболее популярных сообществ «ВКонтакте» на 5 февраля 2023 года. Статистика по самым популярным сообществам взята с сайта «TOPPOST»<sup>1</sup>. Со списком выбранных групп можно ознакомиться в Приложении А. Выбор постов из социальной сети «ВКонтакте» в качестве материала исследования обусловлен тем, что данная социальная сеть является популярной платформой, которой пользуются русскоязычные пользователи. В постах пользователи выражают собственное мнение и открыто взаимодействуют посредством различных реакций (лайки, комментарии, репосты). Данное исследование выполнено на материале русского языка.

В качестве методов исследования выбраны методы машинного обучения (логистическая регрессия (Logistic Regression), наивный

---

<sup>1</sup> <https://vktoppost.ru/>, дата обр. 5.02.2023.

байесовский классификатор (Gaussian NB), метод опорных векторов (SVM), градиентный бустинг (Gradient Boosting), случайный лес (Random Forest), классификатор дерева решений (Decision Tree Classifier)) и нейросетевые методы (одномерная свёрточная нейросеть CNN, рекуррентная нейросеть LSTM и рекуррентная нейросеть GRU), которые в последнее время активно применяются в задачах анализа тональности, в частности для определения эмоций в тексте.

Теоретическая значимость исследования состоит в систематизации приёмов анализа эмоциональной окраски и тональности текста с учётом экстралингвистических маркеров (эмодзи). Практическая значимость состоит в том, что в результате исследования был получен набор данных с разметкой эмоций, который может быть использован как эталон для оценки эффективности работы новых моделей и алгоритмов, создаваемых для решения рассматриваемой проблемы.

**Структура** работы включает в себя введение, 3 главы, заключение, список литературы из 59 наименований и 3 приложения.

## **ГЛАВА 1. Лингвистические исследования категории эмоциональности**

### **1.1 Теоретические подходы к исследованию эмоциональности**

Данное исследование опирается на теоретические подходы к категории эмоции в лингвистике.

В антропоцентрических областях исследований долгое время существовали лакуны, связанные с пониманием природы и эмоциональной сферы человека. Можно сказать, что практически до XX века преимущество было на стороне интеллектуалистической трактовки природы индивида и общества. Во второй половине XX века усиливается внимание исследователей к эмоциональной сфере жизни человека.

Предложенные к настоящему времени различные версии теории дифференциальных эмоций выделяют более 10 основных эмоций, среди которых, страх, удивление, радость, гнев, интерес (любопытство), печаль (горе, грусть), отвращение, презрение, стыд, вина, гордость, удовольствие, счастье и другие эмоции [41].

Следует отметить, что ни одна из теорий и концепций эмоций не является исчерпывающей и универсальной, что вполне объяснимо в силу различий в организации словарного состава языков мира, на материале которых эти концепции описаны, также это объясняется различиями в понимании сути эмоций и объёма этого феномена [6]. Базовые эмоции универсальны и узнаваемы во всех этнических культурах, но различаются по своим формам проявления [58].

Эмоции выступают в качестве субъективной оценки воспринимаемой и обрабатываемой информации о мире. Исследователи говорят о двух вариантах эмоциональной оценки: положительной эмоциональной оценке и отрицательной эмоциональной оценке. Под эмоциональной оценкой понимается эмотивное отношение субъекта речи к обозначаемому, выдаваемое за признак оцениваемого объекта [21]. Разделение эмоций на позитивные и негативные достаточно условно, поскольку одно и то же

состояние человека может представлять собой сложное единство противоположных переживаний.

С 80-х годов XX в. разрабатывается новая область исследований - лингвистика эмоций «эмотиология». Задача эмотиологии состоит в исследовании субъективных компонентов значения единиц языка, а также в формировании и структурировании знаний об эмотивном коде языка [11].

В трактовке понятия эмоциональности нет единства среди лингвистов. Так большинство зарубежных лингвистов при анализе репрезентации эмоций в языке больше внимания уделяют изучению классов слов или отдельных лексем, называющих эмоции, в то время как отечественные исследователи предпочитают связывать понятие эмоциональности с оценочностью и часто ограничивают эмотивную лексику словами, выражающими и описывающими эмоции.

Существуют различные методы анализа и описания эмоциональности, например, психологический метод семантического дифференциала, т. е. помещение слова, исследуемого на эмоциональность, в серию шкал оценочных антонимичных прилагательных (Ч. Осгуд [47]); метод идентификации Ш. Балли [2]; метод погружения эмотива в нейтральные или противоположные контексты, его опущения из эмотивного контекста или замены его нейтральным синонимом; гедонистический метод Б.И. Додонова (если слово вызывает приятные или неприятные эмоции, то оно эмотивно) [9]; метод модальной рамки (А. Вежбицкая [58]) — вынесение внутрисмысловой предикации за пределы слова; метод контрастирования нормальной речи и речи в состоянии эмоциональной напряженности, анализ лексико-семантических и синтаксических сдвигов эмоциональной речи (Э. Л. Носенко [17]); комбинаторно-семантический анализ, вскрывающий эмоциональность слова (М. В. Никитин [16]) и другие методы.

Языковой материал анализируется следующими методами: моделирование лексико-семантического поля эмоциональности, лексикографическое отражение эмоциональности [10]. Также анализ языкового материала может проводиться методом типологического описания эмоциональных единиц по

таким типам, как отношение и реакция, явление и реакция [20]. Исследование текстового материала проводится с помощью внешнего подхода по отношению к тексту (метод лингвистического интервьюирования и метод контрастирования переводов) и с помощью внутреннего подхода (применение элементов текстологического анализа). Валентный метод связывает исследование языковой и речевой эмоциональности, этот метод существует на всех уровнях языка: на уровне морфем, лексем, синтагм [24].

По мнению некоторых лингвистов, эмоциональные элементы следует рассматривать как «смутные, переменчивые явления», внеязыковые по своей природе [26]. Согласно этой точке зрения, эмоции в языке выражаются только непонятно, например, с помощью ритма, интонации, просодии.

Авторы лексикоцентрических теорий эмоциональности признают словарные единицы основным экспонентом эмоций и относят к эмотивному фонду классы лексем. Некоторые исследователи, например, Т. А. Ван Дейк, И. В. Арнольд рассматривают эмоциональность как характеристику текста [4; 1].

Многими лингвистами (С.Б. Берлизон, Т.Г. Винокур, В.Г. Гак, Т.В. Лиховидова, Н.А. Лукьянова, Д.Н. Шмелёв и др.) была доказана ведущая роль эмоционально-оценочного компонента в значении многих слов на материале разных языков и диалектов [25; 33].

Специалист по лингвистике В. И. Шаховский считает эмоциональность семантической характеристикой единиц языка. Эмоции имеют как физиологические, так и оценочные параметры. В. И. Шаховский выделяет следующие параметры эмоций: параметр «полярность эмоций» подразумевает, что все эмоции имеют своё противопоставление, специфика этого параметра в том, что эмоции не исключают друг друга (например, в выражении «слёзы радости»). Параметр «плотность эмоций» связан с параметром количественного измерения. Параметр «предвосхищение эмоций» основан на вероятности эмоциогенного события — стрессора. Параметр «экспрессия эмоций» позволяет кодифицировать, подавлять, скрывать или имитировать эмоции [23].

В. И. Шаховский считает, что «эмоции — одна из форм отражения мира, отношения, в которых они находятся к человеку, т.е. не свойства предметов и явлений, а их значение для жизни человека, эмоции являются способом оценки этого значения для конкретного человека и через неё — информацией о состоянии внутреннего «я», его сознания и психики. Эмоции есть только там, где есть интерес и отношение» [23].

Для лингвистики эмоций необходимо создавать словари эмотивного лексико-фразеологического фонда языка и словари лексико-семантического поля эмоциональности конкретного языка [35], а также различные словари для перевода с одного языка на другой.

По мнению некоторых лингвистов, является ошибкой стремление с математической точностью определить корреляции определённых наборов понятийных и семантических признаков, а также установить строгую иерархию всех аспектов и компонентов значения слова, так как контекстуальное значение языковой единицы никогда полностью не совпадает со словарным значением, а является лишь одним из множества его вариантов [24].

## **1.2 Модели эмоций и тональности**

Анализ тональности текста (sentiment analysis) — одно из направлений в компьютерной лингвистике, в рамках которого решается задача выявления мнения автора текста по поводу того, что обсуждается в тексте. Тональность текста и эмоции в тексте — это связанные категории, но не одно и то же [5]. В данном исследовании задача идентификации эмоций рассматривается как подзадача определения тональности текста. Задача анализа тональности имеет множество различных подзадач, среди которых наиболее известными являются:

1. идентификация субъективности или объективности (subjectivity/objectivity identification);

2. классификация по полярности текста (положительный или отрицательный) на уровне документа, предложения или аспекта;
3. классификация текста по эмоциональным состояниям, которые можно определить по тексту;
4. распознавание сарказма или иронии;
5. обобщение настроений (sentiment summarization).

Тональность текста можно рассматривать как с точки зрения автора текста, так и с точки зрения адресата, воспринимающего текст. Поскольку в данном исследовании эмодзи являются средством разметки эмоций, а эмодзи проставляет сам автор текста, то в этом исследовании тональность и эмоциональная окраска текста рассматривается с точки зрения автора этого текста.

Системы выявления эмоций из текста могут либо определять отдельные категории эмоций, либо многомерные характеристики эмоций [45]. Наиболее часто используемыми моделями отдельных эмоций являются модель П. Экмана [30] и модель Р. Плутчика [44]. В модели П. Экмана 6 различных классов эмоций: 1) гнев; 2) удивление; 3) отвращение; 4) удовольствие; 5) страх; 6) грусть. Р. Плутчик разделяет эмоции на 8 основных эмоций по 4 пары, каждая пара эмоций связана с определённым действием. Модель Р. Плутчика представлена в Таблице 1.

Таблица 1. Модель эмоций Р. Плутчика

Пара действий	Пара эмоций
принятие - отвержение	одобрение - отвращение
разрушение - защита	гнев - страх
воспроизведение - лишение	радость - горе
исследование - ориентация	ожидание - испуг

В многомерных моделях эмоций используются признаки положительного или негативного направления эмоции (valence), степени выраженности эмоции (arousal) и интенсивности эмоций (intensity) [38]. В таких моделях разные

эмоции рассматриваются как зависимые и связанные друг с другом. Некоторыми из широко используемых многомерных моделей эмоций являются двумерная модель Дж. Рассела (Russell's 2D circumplex) [49] (рис. 1), колесо эмоций Р. Плутчика (Plutchik's 2D wheel of emotion) [44] (рис. 2) и трехмерная модель Дж. Рассела (Russell's 3D), состоящая из трёх измерений: 1) удовольствие (pleasure) — неудовольствие (displeasure); 2) сильно выраженная эмоция (arousal) — слабо выраженная эмоция (nonarousal); 3) доминирование эмоции (dominance) — подчинение эмоции (submissiveness) [50].

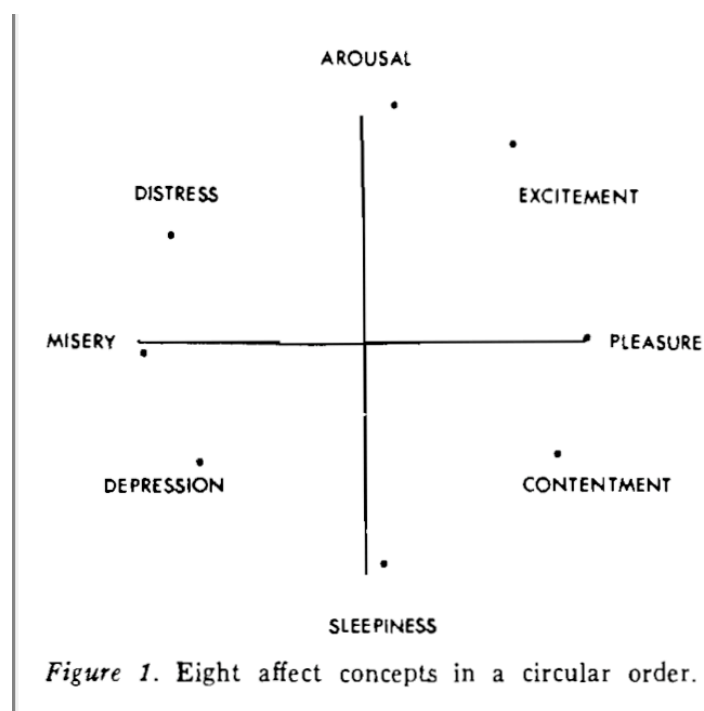


Рис. 1. Двумерная модель Дж. Рассела [49]



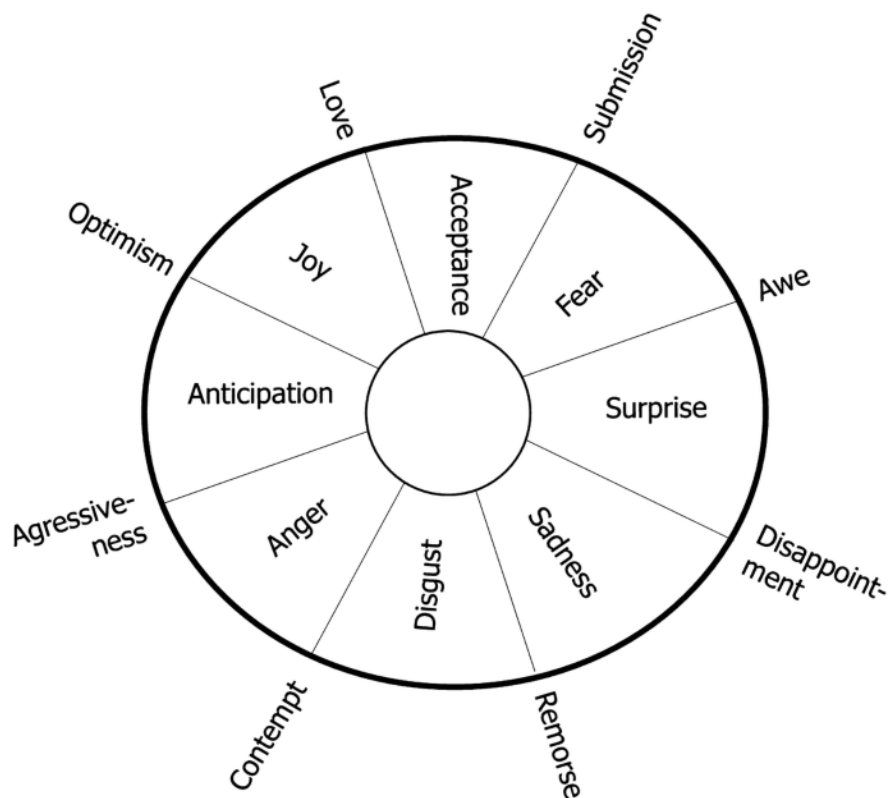


Рис. 2. Колесо эмоций Р. Плутчика

В данной работе выделяются классы, в которых учитывается и эмоциональная составляющая, и тональная составляющая, поскольку в некоторых случаях достаточно сложно определить тональность эмоции. Например, рассмотрим эмоцию удивления. В выражении «Какой позор!» присутствует эмоция удивления с отрицательной тональностью, а в выражении «Какая красота!» эмоция удивления с положительной тональностью. Хотя выражение «Какая красота!» может быть произнесено с иронией и иметь отрицательную тональность, в речи тональность можно определить по интонации, с которой произносится выражение, а в тексте тональность можно постараться определить по контексту. В данном исследовании таким контекстом являются эмодзи, с помощью которых можно установить отношение автора к высказыванию.

### 1.3 Методы определения эмоций в тексте

В целом, анализ эмоциональной окраски текста подразумевает собой применение методов, с помощью которых можно определить, к какому классу тональности и эмоциональной окраски относится тот или иной текст. В основном используются алгоритмы на основе словарей и правил [13, 39] и методы на основе машинного обучения. Также существуют комбинированные методы, в которых словари оценочной лексики являются компонентом модели машинного обучения [37].

Словарный анализ тональности является классическим способом анализа, который основан на словарях эмоционально окрашенной лексики. Под эмоционально окрашенной лексикой понимаются слова и словосочетания, которые передают в тексте позитивное или негативное отношение к каким-либо объектам, например, слова «прекрасный», «ужасный». Существует классификация словарей оценочной лексики:

- 1) по составу — словари включают только отдельные слова или слова и словосочетания;
- 2) по шкале тональности — каждому элементу словаря приписывается только знак тональности (позитивная или негативная) или тональность представлена более детальной шкалой, например, действительные числа в диапазоне  $[-1, +1]$  [22];
- 3) по предметной области — словари могут быть универсальными или предметно-ориентированными;
- 4) по количеству языков — словари могут включать оценочную лексику для одного языка или являться многоязычными.

Существуют такие словари, как тональный словарь русского языка КартаСловСент<sup>2</sup> [14], который включает в себя слова и выражения русского языка, снабжённые тональной меткой («положительное», «отрицательное», «нейтральное») и скалярным значением силы эмоционально-оценочного заряда из непрерывного диапазона  $[-1, +1]$ . Набор данных для словаря

---

<sup>2</sup> <https://github.com/dkulagin/kartaslov/tree/master/dataset/kartaslovsent>, дата обр. 6.05.2023.

размечался краудсорсингом, то есть данные размечались широким кругом лиц, необязательно специалистов, на добровольных началах с применением информационных технологий.

Также упомянем интересный научный проект «Информационно-поисковая система «Эмоции и чувства в лексикографических параметрах: Словарь эмотивной лексики русского языка»»<sup>3</sup>, который сейчас находится на реконструкции. Данный проект направлен на изучение языковой картины эмоций, репрезентируемой в лексической семантике эмотивной лексики в русском языке. В проекте предполагается отображение полученных результатов в виде электронной версии толкового словаря русской эмотивной лексики. Вся эмотивная лексика распределена по 37 классам с учётом типа обозначаемой эмоции: 1) беспокойство; 2) вдохновение; 3) вера; 4) влечение; 5) высокомерие; 6) горе; 7) грусть; 8) доброта; 9) дружба; 10) жалость; 11) желание; 12) жестокость; 13) злость; 14) искренность; 15) лицемерие; 16) любовь; 17) любопытство; 18) наглость; 19) надежда; 20) неверие; 21) недовольство; 22) неприязнь; 23) обида; 24) одиночество; 25) одобрение; 26) протест; 27) равнодушие; 28) радость; 29) смелость; 30) смирение; 31) сомнение; 32) спокойствие; 33) страх; 34) стыд; 35) уважение; 36) удивление; 37) удовольствие. Внутри этих классов лексика распределена по группам с учётом лексико-грамматических характеристик, функций и характера интерпретации эмоций. На рис. 3 представлены функционально-семантические группы для класса «любопытство»: эмоциональное состояние, эмоциональное воздействие, эмоциональное отношение, внешнее выражение эмоций, эмоциональная характеристика и эмоциональное качество. Внутри функционально-семантических групп лексика распределена по значениям: I. основные значения; II. номинативно-производные значения; III. переносные значения.

---

<sup>3</sup> <https://lexrus.ru/default.aspx?p=2875>, дата обр. 6.05.2023.

	Лексема	Грамматическая характеристика	Дефиниция	Иллюстрация
<i>Эмоциональное состояние</i>				
I.	Заинтересованность			
	Любопытство			
	Любопытствовать / любопытствовать			
II	Занятно <sub>2</sub>			
	Интересно <sub>2</sub>			
	Любопытно <sub>2</sub>			
	Небезразлично <sub>2</sub>			
<i>Эмоциональное воздействие</i>				
I	Заинтересовать / заинтересовывать			
	Заинтриговать / заинтриговывать			
	Интриговать			
	Занимательный			
	Интересничать			
	Интересный			
	Интересовать			
II	Интриговать <sub>2</sub>			
	Небезразличный <sub>2</sub>			
	Увлечь <sub>3</sub>			
<i>Эмоциональное отношение</i>				
I.	Заинтересоваться / заинтересовываться			
	Интерес			
	Поинтересоваться			
<i>Внешнее выражение эмоций</i>				
I	Глазеть			
	Интересоваться			
	Любопытничать			
	Любопытный			
	Нравнодушие			
	Полюбопытствовать			
II	Заняться <sub>2</sub>			
	Зевать <sub>2</sub>			
	Увлечься / увлекаться <sub>2</sub>			
III	Ухватиться / ухватываться <sub>3</sub>			
<i>Эмоциональная характеристика</i>				
I	Зевака			
	Любознательный			
	Небезразличный			
	Небезынтересный			
	Нравнодушный			
	Пытливый			
	Ротозей			
	Увлекательный			
II	Заинтересованный <sub>2</sub>			
	Занятый			
<i>Эмоциональное качество</i>				
I	Занимательность			
	Любознательность			
	Пытливость			

Рис. 3. Функционально-семантические группы для класса «любопытство»

Словарь эмоций NRC Emotion Lexicon<sup>4</sup> представляет собой список английских слов и их ассоциаций с 8 основными эмоциями: гнев (anger), страх (fear), ожидание (anticipation), доверие (trust), удивление (surprise), печаль (sadness), радость (joy) и отвращение (disgust) и 2 тональностями: отрицательной (negative) и положительной (positive). Разметка слов в данном словаре была сделана вручную с помощью краудсорсинга. Слова в этом словаре автоматически переведены с английского на 108 языков. На рис. 4 представлен пример перевода на русский язык с разметкой по 8 эмоциям и 2 тональностям.

<sup>4</sup> <https://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm>, дата обр. 6.05.2023.

Eng-Rus-Emotion-Lexicon

English	Russian	Positive	Negative	Anger	Anticipation	Disgust	Fear	Joy	Sadness	Surprise	Trust
hatred	ненависть	0	1	1	0	1	1	0	1	0	0
implement	воплощать в жизнь	0	0	0	0	0	0	0	0	0	0
life	жизнь	0	0	0	0	0	0	0	0	0	0
loathing	ненависть	0	1	0	0	1	0	0	0	0	0
lovely	прекрасный	1	0	0	1	0	0	1	1	1	1

Рис. 4. NRC Emotion Lexicon с переводом на русский язык

Метод, основанный на словарях, достаточно трудоёмок, так как необходимо составить и разметить словарь, выделить эмотивную лексику в разных типах текстов. Словарный подход работает в ограниченной предметной области, эмоциональная окраска и тональность одного и того же слова может быть различной в зависимости от предметной области. При анализе необходимо учитывать различия между словарями эмоций для разных тем и языков. В связи с этим создание универсального словаря для всех областей не представляется возможным. В данном исследовании выделенные посты могут относиться к разным областям, поскольку сообщества из «ВКонтакте» отобраны на основе их популярности, а не по темам, поэтому в данном исследовании не использовался словарный подход.

Подход, основанный на правилах, усложняет словарный метод и позволяет добиться достаточно хорошей точности определения эмотивной лексики, но также является трудоёмким, поскольку необходимо сформировать правила определения эмоций и тональности в тексте.

Большую популярность в задачах анализа тональности приобрели методы машинного обучения. С начала 2000-х годов широко применяются классические методы машинного обучения, такие как логистическая регрессия (Logistic regression), метод опорных векторов (Support Vector Machine), наивный байесовский классификатор (Naive Bayes classifier) [43]. Для некоторых задач обработки текста большое значение имеет последовательность слов в тексте. Для работы с последовательностями в тексте широко применяются классические нейронные сети, например,

рекуррентные нейронные сети (Recurrent Neural Networks) и свёрточные нейронные сети (Convolutional Neural Networks) [59].

В настоящее время достаточно широко применяются методы анализа тональности текста на основе машинного обучения, которые чаще относятся к задачам классификации или регрессии. Работу алгоритмов машинного обучения можно разделить на следующие этапы:

- 1) использование готовых библиотек для работы с методами машинного обучения (например, написанные на языке программирования Python) или написание собственных методов;
- 2) обучение на размеченных данных;
- 3) проверка работы методов на тестовых данных;
- 4) оценка качества работы алгоритма.

Решение задачи классификации текстовых данных с помощью моделей машинного обучения можно разбить на следующие этапы:

- 1) разметка данных или использование уже размеченных данных;
- 2) обработка данных, например, разбиение текста на отдельные токены, приведение полученных токенов к нормальной форме;
- 3) выбор модели классификации;
- 4) применение модели классификации;
- 5) оценка качества модели с помощью метрик качества классификации;
- 6) если качество выбранной модели низкое, то выбирается другая модель классификации и проводятся эксперименты для этой модели;
- 7) если качество выбранной модели достаточно высокое для поставленной задачи, то данную модель применяют к неразмеченным данным для определения того, к какому классу относятся эти данные.

В процессе формирования обучающей выборки для модели машинного обучения производят выбор некоторой части данных в различных пропорциях разбиения размеченных/неразмеченных данных, чаще всего используются пропорции 30/70 или 20/80 размеченных/неразмеченных данных. Данные, выбранные для обучения модели, классифицируют либо вручную, либо автоматически с экспертной оценкой данной разметки. Эти

данные необходимы для предварительной обработки и приведения текстов в числовое представление, поскольку модели машинного обучения могут работать только с числовыми данными. Модель по данным обучения ищет скрытые закономерности по числовым представлениям текста и относит текст к тому или иному классу.

Этап обработки текстовых данных для задач машинного обучения является довольно важной задачей. Модели машинного обучения работают только с количественными данными, определяемыми по корпусу текстов, в качестве представлений таких данных используются векторные представления текстов. Для того, чтобы векторное представление текста было наиболее информативно для модели и лучшим образом указывало содержание текста, необходимо проводить унификацию текстовых данных, удалять из текста не несущие смысла слова и знаки. На этапе обработки текстовых данных текст может приводиться к нижнему регистру, так как для компьютера одно и то же слово, написанное в разном регистре, будет восприниматься как разные слова. Из текста удаляются спецсимволы, опечатки, слова с неправильной кодировкой, знаки пунктуации. Для некоторых задач удаляются из текста стоп-слова, обычно к стоп-словам относят служебные части речи, такие как предлоги, частицы, союзы и междометия, которые довольно часто встречаются в тексте, но которые могут не нести какой-либо смысловой нагрузки и не являются значимыми для решаемой задачи. При обработке текста также может производиться стемминг или лемматизация слов. Стемминг — процесс нахождения основы слова, может применяться для языков с не очень богатой морфологией, например, для английского языка. Лемматизация — процесс нахождения нормальной формы слова, чаще применяется для языков с богатой морфологией, например, для русского.

Модели энкодеров предложений (sentence encoder) сопоставляют текстам векторы в многомерном пространстве. Векторы, полученные таким образом, являются похожими по своим параметрам для семантически близких текстов, и называются распределёнными векторными вложениями

или эмбедингами (embedding). На данный момент чаще всего для получения таких векторов используются различные нейросетевые модели.

При векторизации текста происходит преобразование текстового представления в числовое для возможности работы с моделью машинного обучения. Наиболее популярными методами векторизации являются: прямое кодирование (one-hot encoding), мешок слов (Bag of Words), TF-IDF и так же построение эмбедингов слов или целых текстов, например, Word2Vec или Doc2Vec. Прямое кодирование (one-hot encoding) позволяет категориальные данные, например, значения категории цвета: красный, синий, зелёный, конвертировать в векторное представление, состоящее из нулей и единиц. В мешке слов (Bag of Words) не учитывается порядок слов, но сохраняется информация о количестве слов. Метод векторизации на основе TF-IDF (TF — term frequency, IDF — inverse document frequency) учитывает важность слова в контексте отдельного текста, являющегося частью корпуса текстов. Методы Word2Vec основаны на дистрибутивной семантике, эти методы позволяют создавать векторно-семантические модели. Doc2Vec — инструмент для представления целых документов в виде векторов, является обобщением Word2Vec.

На этапе выбора модели классификатора и её обучения производится подбор наиболее подходящей для задачи исследования модели и поиск оптимальных гиперпараметров для выбранной модели. Далее вкратце будут описаны используемые в данном исследовании модели машинного обучения, которые показывают достаточно хорошие результаты по метрикам качества обучения для задач анализа тональности.

Модель логистической регрессии (Logistic Regression) — это статистическая модель, которая используется для прогнозирования вероятности возникновения события путём сравнения этого события с логистической кривой. Модель выдаёт ответ в виде вероятности бинарного события, т.е. 1 или 0.

Модель наивного байесовского классификатора (Gaussian NB) основана на применении теоремы Байеса с предположениями о независимости



событий. Формула Байеса:  $P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$ , где  $P(A)$  - априорная

вероятность гипотезы  $A$ ;  $P(A|B)$  - вероятность гипотезы  $A$  при наступлении события  $B$  (апостериорная вероятность);  $P(B|A)$  - вероятность наступления события  $B$  при истинности гипотезы  $A$ ;  $P(B)$  - полная вероятность наступления события  $B$ .

Метод опорных векторов (Support Vector Machine, SVM) — это алгоритм обучения с учителем на основе линейного классификатора. Свойством метода является непрерывное уменьшение эмпирической ошибки классификации. Данный алгоритм может плохо работать с сильно несбалансированными наборами данных.

Метод градиентного бустинга (Gradient Boosting) — это метод машинного обучения для построения модели предсказания в виде ансамбля слабых предсказывающих моделей, чаще всего деревьев решений. Структура дерева принятия решений представляет собой «листья» и «ветки». На «ветках» дерева решений записываются признаки, от которых зависит целевая функция, т.е. функция, подлежащая оптимизации в целях решения некоторой задачи, а в «листьях» записываются значения этой целевой функции.

Метод случайного леса (Random Forest) — это алгоритм машинного обучения, основной идеей которого является использование большого ансамбля решающих деревьев. Каждое из деревьев ансамбля даёт невысокое качество классификации, но за счёт большого количества деревьев результат получается достаточно хорошим.

Классификатор дерева решений (Decision Tree Classifier) — классификатор на основе структуры деревьев принятия решений, с помощью которого можно выполнять мультиклассовую классификацию набора данных.

Для некоторых задач применяются модели ансамблевого обучения, т.е. модели на основе работы нескольких классификаторов. При таком подходе рассматривается мажоритарное или мягкое голосование классификаторов. Мажоритарное голосование означает, что отбирается метка класса,

выбранная большинством классификаторов. При мягком голосовании рассматриваются вероятности предсказания каждого класса, эти вероятности усредняются и класс с большей вероятностью является результативной меткой.

Из нейросетевых моделей в данной работе использовались модели одномерной свёрточной нейросети (CNN; архитектура CNN предложена в 1988 году), рекуррентной нейросети LSTM (Long Short-Term Memory; архитектура LSTM предложена в 1997 году) и рекуррентной нейросети GRU (Gated Recurrent Units; механизм GRU создан в 2014 году). В качестве идеи в архитектуре свёрточной нейросети используются особенности зрительной коры головного мозга человека, модель часто применяется для обработки изображений. Название «свёрточная» сеть получила из-за наличия операции свёртки, т.е. операции, когда каждый фрагмент изображения умножается на матрицу свёртки поэлементно и результат суммирования записывается в аналогичную позицию выходного изображения. В рекуррентных нейронных сетях связи между элементами сети образуют направленную последовательность, в этой сети может использоваться внутренняя память для обработки последовательностей произвольной длины, что позволяет применять модели рекуррентных нейросетей к таким задачам, как распознавание текста или речи. В рекуррентных нейронных сетях есть циклы, за счёт которых вход нейрона может быть соединён с его выходом. LSTM — особая разновидность архитектуры рекуррентных нейронных сетей, которая способна к обучению долгосрочным зависимостям. Управляемый рекуррентный блок (GRU — Gated Recurrent Units) — механизм нейронных сетей, объединяющий кратковременную и долгосрочную виды памяти в одно состояние.

В 2017 году появилась архитектура глубоких нейронных сетей Transformer, изначально применявшаяся для задач машинного перевода. В данной архитектуре не требуется обработки последовательностей по порядку, благодаря чему легче, чем в рекуррентных нейронных сетях, происходит процесс распараллеливания, и модель на основе Transformer может быть быстрее обучена. В 2019 году стали популярны новые подходы к анализу

текста на основе нейросетевой архитектуры Transformer, такие как модель BERT [29]. Использование архитектуры серии BERT для различных задач автоматической обработки текста привело к росту качества решений этих задач, в том числе и в задачах анализа тональности.

Первоначально модель BERT обучалась на многоязычных текстовых данных, затем в ряде исследований было выявлено, что дообучение BERT на данных конкретного естественного языка, позволяет получить лучшие результаты решения задач для этого языка. Так, например, в работе [15] исследователи описывают модель RuBERT, которая дообучена на модели BERT для русского языка. Обучение с переносом знаний от заранее обученных языковых моделей позволяет эффективно решать задачи классификации тональности и эмоций [34; 56].

#### **1.4 Метрики оценки качества моделей классификации**

На этапе оценки качества обученной модели производится оценка с помощью различных метрик, для задач машинного обучения используются разные метрики в зависимости от задачи. Метрики нужны для того, чтобы понять, насколько хорошо модель запомнила закономерности из обучающей выборки. Качество модели нельзя оценивать на обучающей выборке, качество модели можно оценивать на тестовой отложенной выборке данных. Также при достаточности времени и вычислительных ресурсов для оценки качества модели прибегают к более надёжным способам проверки, например, к кросс-валидации. Кросс-валидация — это метод оценки модели машинного обучения, который заключается в разбиении известного набора данных для использования одной части данных для обучения модели, а другой части — для тестирования обученной модели.

Для оценки качества моделей в задачах классификации чаще всего используются такие метрики, как точность (precision), доля правильных ответов (accuracy), полнота (recall) и F1-мера (F1-measure). На рис. 5 представлены формулы расчёта для точности, полноты и доли правильных ответов в случае бинарной классификации, то есть когда данные могут

принадлежать к одному из двух классов. Метрики качества рассчитываются относительно выбранного целевого класса. True Positive (TP) — это верное срабатывание алгоритма (верный положительный ответ), т.е. если алгоритм сработал, предсказал целевой класс, и объект действительно относится к целевому классу. False Positive (FP) — это ложное срабатывание (ошибка), т.е. если алгоритм сработал, предсказал класс объекта как целевой, а объект не относится к целевому классу. False Negative (FN) — это ложный пропуск (ложный негативный ответ, ошибка), т.е. если алгоритм пропускает объект, предсказал нецелевой класс, а истинный класс объекта является целевым. True Negative (TN) — это истинный пропуск, т.е. если алгоритм пропускает объект, предсказал нецелевой класс, и истинный класс объекта и есть нецелевой.

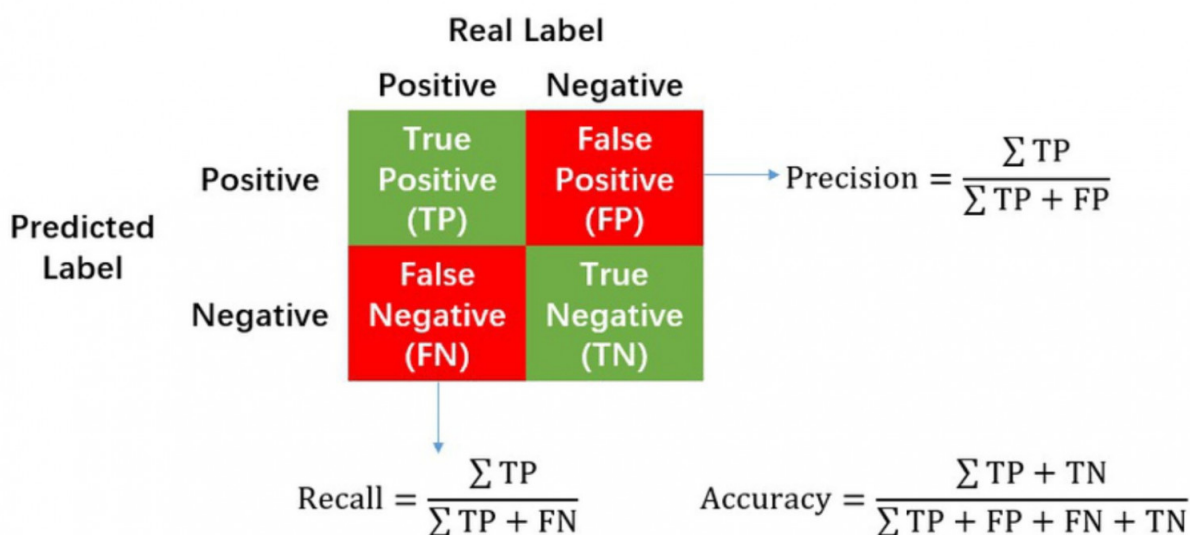


Рис. 5. Метрики для классификации [18]

Доля правильных ответов (ассигасу) может принимать значения в диапазоне от 0 до 1, где 0 — значит, что все предсказания модели ошибочные, а 1 — значит, что все предсказания модели правильные. Данная метрика является достаточно простой, но имеет ряд проблем: 1) эта метрика необъективна при дисбалансе классов в наборе данных и 2) с помощью этой метрики невозможно оценить вес для разных ошибок (FP, FN).

Точность — это доля истинных срабатываний (TP) от общего количества срабатываний (TP + FP), показывает, насколько можно доверять модели классификации в случае срабатывания. Данная метрика является приемлемой для задач, где важна чистота классификации. Метрика точности будет равна 1 в случае, когда FP = 0. Метрика точности будет стремиться к 1 при минимизации ошибки ложного срабатывания (FP). Полнота является долей объектов, истинно относящихся к целевому классу (TP) от общего числа объектов, которые модель отнесла к целевому классу (TP + FN). Метрика полноты является приемлемой для задач, где важно количество классификаций. Данная метрика будет равна 1 при FN = 0. Метрика полноты будет стремиться к 1 при минимизации ошибки ложного пропуска (FN). Количественно метрики точности и полноты изменяются от 0 до 1, где 0 — значит, что все предсказания модели ошибочные, 1 — значит, что все предсказания модели правильные.

Для того, чтобы снижать и ошибки ложного срабатывания (FP), и ошибки ложного пропуска (FN), применяют метрику F1-меры. Диапазон значений данной метрики от 0 до 1. F1-мера является средним гармоническим точности и полноты, данная метрика предполагает одинаковую важность (вес) точности и полноты:

$$F1 = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}} = 2 * \frac{Recall * Precision}{Recall + Precision} = \frac{TP}{TP + \frac{FP + FN}{2}}$$

В случае мультиклассовой классификации, то есть когда данные могут принадлежать к более, чем двум классам, расчёт метрик оценки качества усложняется. Когда задача классификации на  $K$  классов ставится как  $K$  задач об отделении класса  $i$  от остальных классов, где  $i = 1, \dots, K$ , тогда для каждой задачи считается матрица ошибок (confusion matrix), то есть таблица с TP, FN, FP, TN (рис. 5). Таким образом, получают  $K$  матриц ошибок, из которых выводится итоговое значение метрики. Для того, чтобы не тратить слишком много времени для анализа метрик каждого класса в мультиклассовой

классификации, используют усреднённые метрики, полученные микроусреднением (micro), макроусреднением (macro) или взвешенным усреднением (weighted).

Микроусреднение (micro) — это усреднение элементов матрицы ошибок (TP, FN, FP, TN) между бинарными классификаторами, затем по усреднённой матрице ошибок считаются точность, полнота и F1-мера. Метрики по микроусреднению объективны, когда данные сбалансированы.

Макроусреднение (macro) — это расчёт точности, полноты для каждого классификатора отдельно, а затем усреднение полученных метрик. Макроусреднение может использоваться, когда есть дисбаланс классов, в этом случае всем классам даётся одинаковый вес, независимо от их количества в наборе данных.

Взвешенное усреднение (weighted) может использоваться, когда есть дисбаланс классов, в этом случае вес классам даётся согласно количеству объектов в этих классах, наибольший вес получают классы с самым большим количеством объектов. Для задачи классификации по нескольким классам можно использовать взвешенную метрику F1-меры, так как при оценке качества модели мультиклассовой классификации не вычисляется общая метрика F1-меры, а производится вычисление F1-меры для каждого класса в соотношении один класс к остальным классам. При таком подходе оценивается качество для каждого класса отдельно, словно для каждого класса существуют отдельные классификаторы.

Порядок усреднения влияет на результат в случае дисбаланса классов, то есть когда к разным классам принадлежит разное количество объектов, а не количество примерно одного порядка. Микроусреднение (micro) сделает вклад маленького по численности объектов класса в общую метрику незаметным, тогда как при макроусреднении (macro) среднее считается уже для нормированных величин и в этом случае вклад каждого класса будет одинаковым.

## **Выводы**

В 1 главе представлены теоретические предпосылки данного исследования, были приведены некоторые подходы к исследованию эмоций в лингвистике. Категория эмоциональности является достаточно сложным феноменом, для изучения которого существует множество подходов и точек зрения. Различны мнения по поводу того, что такое эмоциональность, к какому компоненту лексического значения принадлежит эмоциональность. Проблема изучения категории эмоциональности является одной из актуальных проблем современной лингвистики.

Также в 1 главе представлены возможности выбора среди разных типов методов и алгоритмов для решения задачи по выявлению эмоций и тональности в тексте. На основании рассмотренных возможностей есть основания считать, что в данном исследовании стоит выбрать модели машинного обучения для оценки эмоциональной окраски текста постов и словосочетаний в них, поскольку другие методы (на основе словарей и правил) являются достаточно трудоёмкими и не используются для анализа текстов из разных предметных областей.

## **ГЛАВА 2. Исследования корпусов социальных сетей в области тональной и эмоциональной оценки**

Данные из социальных сетей являются материалом исследования для множества задач, так, например, в работе [12] исследуются мнения пользователей «ВКонтакте» о рождении детей. Лучшие результаты получены на основе применения нейросетевой модели BERT [29], в версии Conversational RuBERT, для создания которой использовалась русскоязычная модель RuBERT [15], дообученная на русскоязычных диалогах и текстах социальных сетей.

В работе [3] публикации сообществ «ВКонтакте» используются для оценки качества жизни людей по таким категориям, как «образование», «здравоохранение», «безопасность», «социальное обеспечение», «работа

органов власти», «экология» и «доступность товаров и услуг». Исследователи отдали предпочтение модели RuBERT-tiny<sup>5</sup>, так как эта модель имела лучшие показатели полноты в большинстве категорий: «образование» — 58%, «здравоохранение» — 79%, «политика» — 41%, «доступность товаров и услуг» — 39% и «ЖКХ и инфраструктура» — 70%.

В работе [55] проводится исследование по определению токсичных комментариев на русском языке. В данной работе говорится о том, что Модели Multilingual BERT и Multilingual USE являются одними из самых распространённых и успешных в исследовательских работах. Исследователи применили модель Multinomial Naive Bayes (MNB), которая хорошо себя показала в задачах по классификации текстов [32], [52]. Для создания модели авторы взяли Bag-of-Words [33] и векторизацию TF-IDF [46]. В качестве второй модели использовалась нейросеть Bidirectional Long Short-Term Memory (BiLSTM). Для слоя эмбединга были предварительно обучены эмбединги Word2Vec (dim = 300) [40] на основе коллекции русскоязычных Twitter-сообщений из RuTweetCorp [48]. Поверх эмбедингов Word2Vec авторы добавили два слоя нейросети Bidirectional LSTM. Также использовалась модель RuBERT. Оценка работы моделей глубокого обучения производилась на наборе данных с русскоязычными токсичными комментариями Russian Language Toxic Comments Dataset [27]. Данный набор данных представляет собой коллекцию аннотированных комментариев с сайтов Двач<sup>6</sup> и Пикабу<sup>7</sup>. Russian Language Toxic Comments Dataset опубликован на Kaggle<sup>8</sup> в 2019-м году и содержит 14412 комментариев, из которых 4826 помечены как токсичные, а 9586 — как нетоксичные. Средняя длина комментария 175 символов, минимальная — 21 символ, максимальная — 7403 символа. В данном исследовании лучший показатель по метрике качества F1-мера = 92.20% показала модель RuBERT.

---

<sup>5</sup> <https://huggingface.co/cointegrated/rubert-tiny>, дата обр. 4.05.2023.

<sup>6</sup> <https://2ch.hk/>, дата обр. 6.05.2023.

<sup>7</sup> <https://pikabu.ru/>, дата обр. 6.05.2023.

<sup>8</sup> <https://www.kaggle.com/>, дата обр. 6.05.2023.



В статье [54] описывается размеченный набор данных из почти 10000 предложений, взятых из разных интернет-источников. Данные размечены по 5 базовым эмоциям: joy (радость, удовольствие), sadness (грусть, печаль), surprise (удивление), fear (страх), anger (гнев, злость). Выбранные эмоции не взаимоисключают друг друга (рис. 6).

text (string)	labels (sequence)	source (string)	sentences (list)
"Суровый гималайский медведь ."	[ ]	"lj"	[ [ { "forma": "Суровый", "lemma": "суровый" }, { "forma": "гималайский", ...
"Так, обнаружено несколько проблем с дисплеем (выгорание, странные зеленые..."	[ ]	"lenta"	[ [ { "forma": "Так", "lemma": "так" }, { "forma": " ", "lemma": " " }, { ...
"У меня остается только один вопрос - является ли этот приступ отчаяния ( а..."	[ 2 ]	"lj"	[ [ { "forma": "у", "lemma": "у" }, { "forma": "меня", "lemma": "я" }, { ...
"Забавно как люди в возрасте удивляются входящим звонкам на..."	[ 0 ]	"twitter"	[ [ { "forma": "Забавно", "lemma": "Забавно" }, { "forma": "как", "lemma": ...
"Издание The Register отмечает, что у владельцев гаджетов пока нет повода..."	[ ]	"lenta"	[ [ { "forma": "Издание", "lemma": "издание" }, { "forma": "The", "lemma": ...
"Мы в ужасе от того, что на этот раз был убит человек."	[ 3 ]	"lenta"	[ [ { "forma": "Мы", "lemma": "мы" }, { "forma": "в", "lemma": "в" }, { ...
"Все они , к сожалению , для школьников или просто детей ."	[ 1 ]	"lj"	[ [ { "forma": "Все", "lemma": "весь" }, { "forma": "они", "lemma": "они" }, ...

Рис. 6. Пример данных из набора cedr<sup>9</sup>

На наборе данных cedr была дообучена модель rubert-tiny2<sup>10</sup> [8]. Модель rubert-tiny2 является доработанной версией модели rubert-tiny<sup>11</sup> [7]. Для rubert-tiny2 расширен словарь модели с 29564 до 83828 токенов, увеличена максимальная длина текста с 512 до 2048 токенов. Модель rubert-tiny2 получилась достаточно качественной. Данная модель стала занимать больше памяти, чем модель rubert-tiny, так как увеличилась матрица эмбедингов, но за счёт увеличения покрытия словаря rubert-tiny2 стала чуть быстрее работать и давать более качественные эмбединги текстов.

На наборе данных [54] была дообучена модель rubert-tiny2 для классификации эмоций в предложениях на русском языке, получена модель

<sup>9</sup> <https://huggingface.co/datasets/cedr>, дата обр. 6.05.2023.

<sup>10</sup> <https://huggingface.co/cointegrated/rubert-tiny2>, дата обр. 6.05.2023.

<sup>11</sup> <https://huggingface.co/cointegrated/rubert-tiny>, дата обр. 6.05.2023.

rubert-tiny2-cedr-emotion-detection<sup>12</sup>. Задача классификации эмоций в данном случае является задачей мультиклассовой классификации, так как в одном предложении может присутствовать несколько эмоций. Модель rubert-tiny2-cedr-emotion-detection была обучена с помощью оптимизатора Adam (Adam optimizer) в течение 40 эпох со скоростью обучения (learning rate) равной 1e-5 и размером пакета (batch size) равным 64. Adam optimizer - это оптимизатор скорости обучения, который очень популярен для задач глубокого обучения. На рис. 7 можно увидеть оценки результатов по метрикам качества для модели rubert-tiny2-cedr-emotion-detection. Усреднённая по 6 классам метрика F1-мера macro составляет 83.05%.

label	no emotion	joy	sadness	surprise	fear	anger	mean	mean (emotions)
AUC	0.9286	0.9512	0.9564	0.8908	0.8955	0.7511	0.8956	0.8890
F1 micro	0.8624	0.9389	0.9362	0.9469	0.9575	0.9261	0.9280	0.9411
F1 macro	0.8562	0.8962	0.9017	0.8366	0.8359	0.6820	0.8348	0.8305

Рис. 7. Метрики качества модели rubert-tiny2-cedr-emotion-detection

На рис. 8 приведён пример работы модели rubert-tiny2-cedr-emotion-detection.

<sup>12</sup> <https://huggingface.co/cointegrated/rubert-tiny2-cedr-emotion-detection>, дата обр. 6.05.2023.

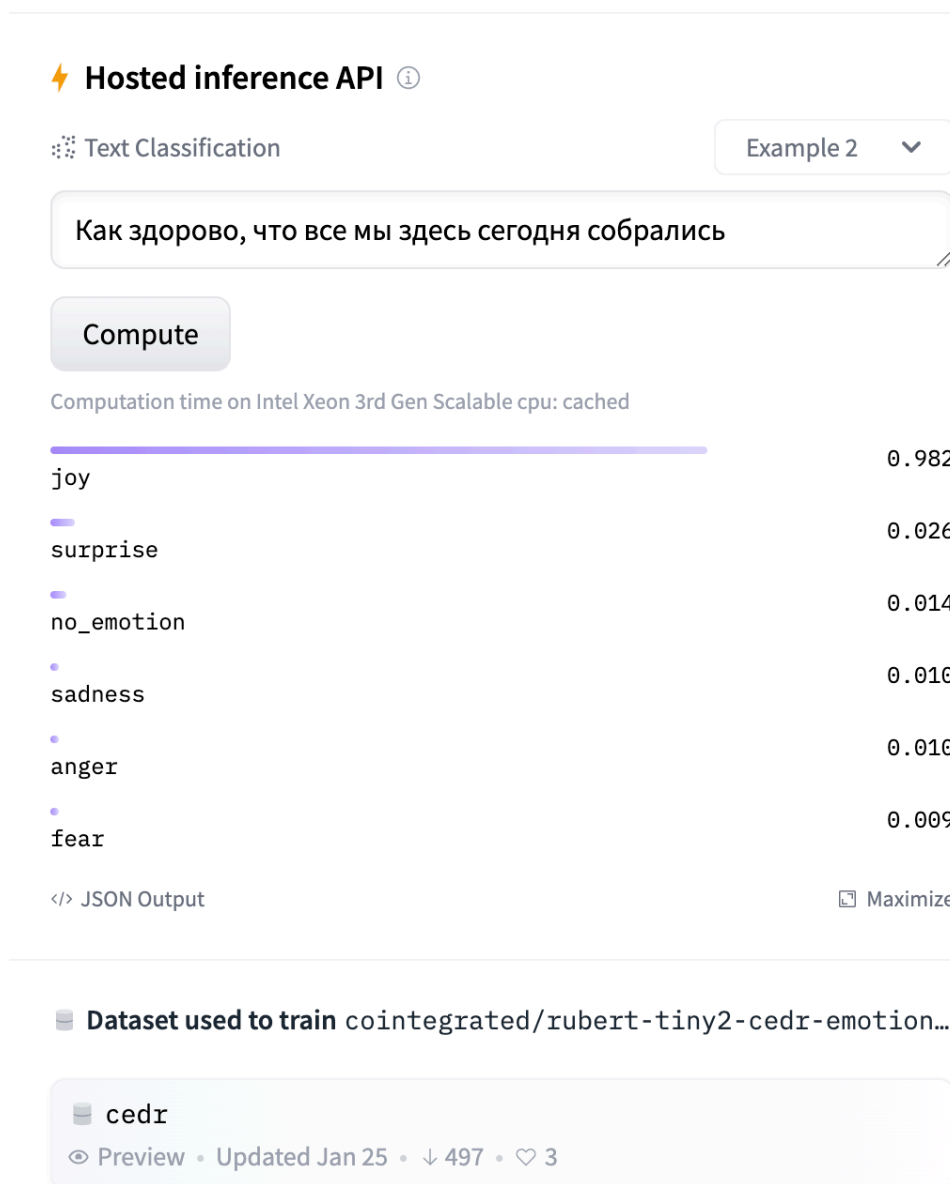


Рис. 8. Пример классификации текста по эмоциям с помощью модели rubert-tiny2-cedr-emotion-detection

В исследовании [31] описывается разработка системы, которая сочетает в себе лингвистические, стилистические и основанные на тональности характеристики текста сообщений на английском языке в Tweeter для предсказания эмоций пользователей.

В статье [53] представлен набор данных из сообщений Tweeter на английском языке «Emotion Dataset for Emotion Recognition Tasks»<sup>13</sup>,

<sup>13</sup> <https://www.kaggle.com/datasets/parulpandey/emotion-dataset>, дата обр. 6.05.2023.

размеченный по 6 базовым эмоциям: гнев (anger), страх (fear), удовольствие (joy), любовь (love), грусть (sadness) и удивление (surprise). В данном наборе данных около 33 % твитов с эмоцией удовольствия, затем следуют по убыванию твиты с эмоцией грусти и гнева. Распределение твитов по эмоциям представлено на рис. 9.




Рис. 9. Распределение твитов по эмоциям в наборе данных «Emotion Dataset for Emotion Recognition Tasks»

### **Выводы**

Поскольку анализ тональности и эмоциональной окраски текста является актуальной задачей, то исследований в данной области достаточно много. В данной работе для исследования выбран корпус текста постов из социальной сети «ВКонтакте», так как эта платформа достаточно популярна среди русскоязычной аудитории. Для дообучения на полученном наборе данных выбрана модель rubert-tiny2, так как эта модель работает с текстами на русском языке и имеет качественные эмбединги текстов.

## **ГЛАВА 3. Экспериментальное исследование эмоциональной окраски постов и словосочетаний**

В данном исследовании предполагается, что по эмодзи, присутствующим в постах, можно оценить эмоциональную окраску постов и словосочетаний, которые встречаются в этих постах. Для оценки эмоциональной окраски текста можно использовать методы машинного обучения, работа которых оценивается метриками качества классификации.

### **3.1 Сбор и разметка экспериментального корпуса эмоционально окрашенных текстов**

Стиль текста, представленный в материале исследования (посты в социальной сети «ВКонтакте»), можно охарактеризовать как разговорный и неформальный, поэтому можно полагать, что в таких текстах достаточно представлен эмоционально-экспрессивный компонент.

Для многих задач автоматической обработки текста необходимы специально размеченные текстовые данные, например, для автоматического распознавания в тексте иронии или сарказма [36].

Набор данных для данного исследования создавался самостоятельно из постов социальной сети «ВКонтакте». Были собраны посты из 100 наиболее популярных групп социальной сети «ВКонтакте» на 5 февраля 2023 года. В Приложении А представлен список выделенных сообществ.

Были изучены правила доступа к публичным данным «ВКонтакте». API «ВКонтакте» представлен в открытом доступе<sup>14</sup>, с помощью открытых методов был написан скрипт для скачивания текста постов и комментариев к этим постам. Для работы с API «ВКонтакте» необходим токен пользователя для авторизации, код скрипта приведён в проекте Github<sup>15</sup>. С помощью скрипта было скачано 28 751 пост и 131 955 комментариев к этим постам в виде таблиц. В таблице с постами 4 колонки: postID — id поста, postDate —

---

<sup>14</sup> <https://dev.vk.com/method>, дата обр. 30.04.2023.

<sup>15</sup> <https://github.com/kholann/evaluation-emotional-annotation>, дата обр. 6.05.2023.

дата публикации поста, `postText` — текст поста и `groupID` — id сообщества. В таблице с комментариями к постам 5 колонок: `commentId` — id комментария, `commentatorId` — id пользователя, который сделал комментарий, `postID` — id поста, `postDate` — дата публикации поста и `commentText` — текст комментария.

Для эффективной работы с данными необходима их предобработка. Для этого из текста скаченных сообщений были удалены id пользователей и id групп, текст переведён в нижний регистр. Для экспериментов использовались 3 варианта текста: 1) текст с сохранённой пунктуацией и с эмодзи; 2) текст без пунктуации и без эмодзи; 3) лемматизированный текст с пунктуацией и с эмодзи. Для приведения текста постов к нормальной форме использовался лемматизатор `pymorphy2`<sup>16</sup>.

Достаточно сложно однозначно разделить эмоции на категории, так как они могут по-разному интерпретироваться разными людьми, поэтому присутствует некоторая субъективность в выделении классов с учётом эмоциональной и тональной составляющих. В дальнейшем планируется провести экспертную оценку автоматической разметки постов по выделенным классам.

Варианты разметки данных могут быть такими:

- 1) по эмодзи (используется в данном исследовании);
- 2) с помощью имеющихся размеченных наборов данных на английском языке с переводом на русский язык (например, есть наборы данных из Twitter). В данном случае необходимо учитывать ограничения при переводе с одного языка на другой, так как эмоциональная и тональная составляющие не во всех случаях одинаково выражаются в различных языках [19];
- 3) использование размеченного набора данных на русском языке (например, набор данных `cedr` [54]);

---

<sup>16</sup> <https://github.com/pymorphy2/pymorphy2>, дата обр. 30.04.2023.

4) с помощью экспертов, что может занимать значительные временные и материальные ресурсы;

5) с помощью платформ для разметки, в разметке может принять участие практически любой желающий (например, платформа Яндекс.Толока<sup>17</sup>). Процесс разметки происходит быстрее, но разметчики могут не обладать экспертизой или достаточными знаниями, что может повлиять на качество разметки;

б) с помощью уже обученной модели машинного обучения с достаточно высокими метриками качества классификации.

Для оценки эмоциональной окраски проведена автоматическая разметка данных на основе использованных в тексте эмодзи. В качестве маркеров для разметки текста в данной работе использовались эмодзи, которые присутствуют в постах. Разметка на основе эмодзи является ограничением данного исследования, поскольку такой разметки может быть недостаточно для точной классификации текста по эмоциям и тональности, особенно в том случае, если эмодзи использовались авторами постов неоднозначно. Для пояснения значений эмодзи и их классификации использовались карточки эмодзи с сайта «Смайлики Эмодзи»<sup>18</sup> (рис. 10)

Карточка эмодзи 😏	
Название	Смех с закрытыми глазами (Насмешка)
Английское название	Grinning Squinting Face (Smiling Face with Open Mouth & Closed Eyes)
Категория	Смайлы и эмоции (Smileys & Emotion)
Тематический набор	Улыбающийся смайл
Другие наборы	😏 1 апреля (День смеха)
✔ Смайл в ВКонтакте	😏

Рис. 10. Карточка эмодзи с сайта «Смайлики Эмодзи»

<sup>17</sup> <https://toloka.ai/>, дата обр. 6.05.2023

<sup>18</sup> <https://emojiio.ru/>, дата обр. 2.05.2023.

Собран словарь эмодзи из скачанных постов, состоящий из 146 эмодзи, которые входят в тематическую группу Smileys & Emotion.

Выделенные 146 эмодзи распределены по 15 классам. В этих классах учитывается эмоциональная составляющая и тональная составляющая, поскольку однозначно категоризировать эмоции достаточно сложно, например, для такой эмоции, как удивление, может присутствовать как положительная, так и отрицательная тональность.

smile	positive/negative	0	невиданная щедрость 🤔
sadness	negative	4	талантливые были актеры 😞
joy	positive	2	плюсани, если смотрел 😊
smile	positive/negative	0	ждет игра и этот волшебный свет за окном 😊
smile	positive/negative	0	он чертов гений 😂
joy	positive	2	медляки, под которые мы танцевали в молодости 🥰
joy	positive	2	anivar. самое новое 🥰
disgust	neutral/skeptical	10	хороший был актер 😞
joy	positive	2	плюсани, если нравится этот актёр 🤔
smile	positive/negative	0	я помню нагиева с волосами 😊
joy	positive	2	новые медляки♥
joy	positive	2	шикарный новый альбом 🥰

Рис. 11. Примеры постов из различных классов


































Для обучения и оценки алгоритмов машинного обучения были выбраны посты с 1 эмодзи и длиной поста не более 11 токенов вместе с эмодзи. Сообщения, состоящие только из одних эмодзи без текста, убраны из выборки, в итоге получилось 9220 постов. В дальнейшем планируется исследовать тексты с другими параметрами по количеству эмодзи и количеству токенов в посте. Полученные 9220 постов автоматически размечены по 15 выделенным классам. Получен набор данных в виде таблицы с колонками: 1) `img_emoji` — изображение эмодзи; 2) `word_count` — количество слов в посте; 3) `count_emoji` — количество эмодзи в посте; 4) `emotion` — эмоция; 5) `tonality` — тональность; 6) `class` — числовое значение





№	эмоция	настроение (тональность)	эмодзи	количество постов	пример текста поста
3	удовольствие (joy)	позитивное (positive)		724	<p>«шикарный новый альбом 🥰»</p> <p>«лучшая новость за сегодня 😁»</p>
4	нет эмоции (no_emotion)	позитивное/негативное (positive/negative)		486	<p>«легенды детства возвращаются 😎» (+/-)</p> <p>«так исторически сложилось 😬» (+/-)</p>

№	эмоция	настроение (тональность)	эмодзи	количество постов	пример текста поста
5	грусть (sadness)	негативное (negative)	                  	365	<p>«грустный фильм 🙄»</p> <p>«мы будем скучать 💔»</p>
6	страх (fear)	негативное (negative)	       	122	<p>«как не сойти с ума в таких условиях? 😱»</p> <p>«я мстю и мстя моя страшна!!! 😡»</p>
7	стыд (shame)	негативное (negative)		122	<p>«что ты несешь 😳»</p> <p>«да прям таки не смущайте... 😳»</p>
8	гнев (anger)	негативное (negative)	      	94	<p>«что это, если не жиза? 😡»</p> <p>«ррррот закрой 😡»</p>
9	отвращение (disgust)	негативное (negative)	  	86	<p>«🤢 вот твари»</p> <p>«не смотрю такое 🤢»</p>

№	эмоция	настроение (тональность)	эмодзи	количество постов	пример текста поста
10	удивление (surprise)	позитивное/ негативное (positive/negative)	    	103	«шикарный плейлист  » (+)  «каждый самовыражается как может  » (+/-)
11	отвращение (disgust)	нейтральное/ скептическое (neutral/skeptical)		36	«ну все, кабзда...  »  «какое неприятное лицо  »
12	удивление (surprise)	негативное (negative)	    	44	«нас пытаются развести  »  «  это дно...»
13	нет эмоции (no_emotion)	негативное (negative)	     	33	«хэйтеры, откисайте  »  «ну и ты вали диванный критик тут сидишь.  »
14	грусть (sadness)	позитивное/ негативное (positive/negative)		20	«в телевизоре ничего не меняется  » (-)  «это замечательно  » (+)
15	испуг (fear)	позитивное/ негативное (positive/negative)	  	9	«до мурашек!  » (+/-)  «чем мелче блоха тем больней кусает  » (-)

№	эмоция	настроение (тональность)	эмодзи	количество постов	пример текста поста
<b>всего:</b>			146	9220	

Самое большое количество эмодзи 26 из 146 относится к классу joy positive (удовольствие позитивное настроение).

Среди выбранных данных больше всего постов (5954 поста) с эмодзи из класса smile positive/negative (улыбка позитивное/негативное настроение).

emotion	tonality	class	clean_text
smile	positive/negative	0	почему бы и нет 😂
smile	positive/negative	0	как сесть на диету 😄
smile	positive/negative	0	когда в душе ещё щенок 😊

Рис. 12. Примеры постов из класса smile positive/negative

Данные в полученном наборе несбалансированны, больше всего постов относится к классу smile positive/negative (числовое значение класса = 0), как можно увидеть на рис. 13. В дальнейшем планируется провести эксперименты на сбалансированных данных.




Рис. 13. Распределение постов по классам эмоций и тональности




Рис. 14. Количество слов в посте по классам эмоций и тональности

### 3.2 Эксперименты по автоматической классификации постов методами машинного обучения

В рамках данного исследования был проведён ряд экспериментов методами машинного обучения, которые были выбраны на основании того, какие из этих методов показывали наилучшие оценки по метрикам качества в различных исследованиях по анализу тональности текста.

Процедура классификации текстов состоит из таких этапов как:

1. предварительная обработка текстов (очистка от «шума»);
2. векторизация (извлечение признаков);
3. построение классификатора;
4. оценка полученных результатов.

Выбор метода для анализа эмоциональной окраски текста зависит от требований решаемой задачи и характера набора данных. Например, если набор текстовых данных небольшой, то может быть достаточно более простого метода машинного обучения, такого как наивный байесовский классификатор. Для большого же набора текстовых данных может быть более подходящим метод на основе нейронных сетей, например, нейронная сеть с долгой краткосрочной памятью LSTM (Long short-term memory) или свёрточная нейронная сеть CNN (Convolutional Neural Network).

Для того, чтобы узнать, какой метод больше всего подходит для данного исследования, был проведён ряд экспериментов. Тестовая выборка данных составляла 20% из общего числа постов, то есть  $9220 * 0,2 = 1844$  поста. Для оценки эмоциональной окраски размеченных постов использовались классические методы машинного обучения из пакета `scikit-learn`<sup>19</sup>.

Эксперименты проводились для текста с пунктуацией и с эмодзи, для текста без пунктуации и без эмодзи, для лемматизированного с помощью `ru morphology2` текста с пунктуацией и с эмодзи.

Использовались представления слов в виде мешка слов (Bag of Words - BoW), предобученные плотные векторные представления слов для русского

---

<sup>19</sup> <https://scikit-learn.org/stable/>, дата обр. 4.05.2023.

языка из библиотеки Navес<sup>20</sup> (часть проекта Natasha<sup>21</sup>, состоящая из коллекций предобученных плотных векторных представлений слов для русского языка) и Word2Vec<sup>22</sup> для классических методов машинного обучения, таких как, логистическая регрессия Logistic Regression<sup>23</sup>, наивный байесовский классификатор GaussianNB<sup>24</sup>, метод опорных векторов SVM<sup>25</sup>, градиентный бустинг Gradient Boosting<sup>26</sup> (GB), случайный лес Random Forest<sup>27</sup>, классификатор дерева решений DecisionTreeClassifier<sup>28</sup>.

Также проведены эксперименты с использованием ансамблей классификаторов с мажоритарным и мягким голосованием с помощью VotingClassifier.<sup>29</sup>

Для экспериментов использовались нейросетевые модели: одномерная свёрточная нейросеть CNN<sup>30</sup>, рекуррентная нейросеть LSTM<sup>31</sup> (Long Short-Term Memory) и рекуррентная нейросеть GRU<sup>32</sup> (Gated Recurrent Units).

В экспериментах с нейросетями использовался токенизатор из Keras. Keras — это высокоуровневый API нейронной сети, который может работать

---

<sup>20</sup> <https://natasha.github.io/navес/>, дата обр. 2.05.2023.

<sup>21</sup> <https://github.com/natasha>, дата обр. 6.05.2023.

<sup>22</sup> <https://tedboy.github.io/nlps/generated/generated/gensim.models.Word2Vec.html>, дата обр. 2.05.2023.

<sup>23</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.LogisticRegression.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html), дата обр. 2.05.2023.

<sup>24</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.naive\\_bayes.GaussianNB.html](https://scikit-learn.org/stable/modules/generated/sklearn.naive_bayes.GaussianNB.html), дата обр. 3.05.2023.

<sup>25</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html>, дата обр. 3.05.2023M

<sup>26</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html>, дата обр. 3.05.2023.

<sup>27</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>, дата обр. 3.05.2023.

<sup>28</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeClassifier.html>, дата обр. 3.05.2023.

<sup>29</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.VotingClassifier.html>, дата обр. 3.05.2023.

<sup>30</sup> [https://www.tensorflow.org/api\\_docs/python/tf/keras/Sequential](https://www.tensorflow.org/api_docs/python/tf/keras/Sequential), дата обр. 2.05.2023.

<sup>31</sup> [https://www.tensorflow.org/api\\_docs/python/tf/keras/layers/LSTM](https://www.tensorflow.org/api_docs/python/tf/keras/layers/LSTM), дата обр. 2.05.2023.

<sup>32</sup> [https://www.tensorflow.org/api\\_docs/python/tf/keras/layers/GRU](https://www.tensorflow.org/api_docs/python/tf/keras/layers/GRU), дата обр. 2.05.2023.



поверх других платформ Deep Neutral Network (DNN) для упрощения разработки.

### 3.3 Результаты оценки эмоциональной окраски текста постов

Для оценки качества классификации использовались метрики: F1-мера по макроусреднению (macro) и F1-мера по взвешенному усреднению (weighted)<sup>33</sup>. Выбор данных метрик для оценки эмоциональной окраски текста постов обусловлен тем, что полученный набор данных не является сбалансированным.

По F1-мере лучший результат получился для модели BoW + VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи, F1-мера macro равна 69.70%, F1-мера weighted равна 82.06%. Полученные результаты представлены в Таблице 3 (лучшие результаты выделены жирным шрифтом).

Таблица 3. Результаты оценки эмоциональной окраски текста для классических методов машинного обучения

	Модель	F1 macro%	F1 weighted %
текст с пунктуацией и с эмодзи	BoW + Logistic Regression	51.74	78.97
	BoW + SVC	40.26	72.21
	BoW + RandomForestClassifier	65.10	80.54
	BoW + DecisionTreeClassifier	63.79	79.55
	BoW + GaussianNB	28.49	62.17
	BoW + GradientBoostingClassifier	65.27	81.48
	BoW + VotingClassifier (hard)	64.64	81.34
	BoW + VotingClassifier (soft)	67.99	82.02
	Navec + Logistic Regression	11.31	49.51
	Navec + SVC	6.78	50.25

<sup>33</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1\\_score.html](https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1_score.html), дата обр. 6.05.2023.

	<b>Модель</b>	<b>F1 macro%</b>	<b>F1 weighted %</b>
	Navec + RandomForestClassifier	11.02	51.75
	Navec + DecisionTreeClassifier	10.66	46.40
	Navec + GaussianNB	1.15	4.34
	Navec + GradientBoostingClassifier	8.19	49.25
	Navec + VotingClassifier (hard)	10.50	51.68
	Navec + VotingClassifier (soft)	11.02	52.07
	Word2Vec + Logistic Regression	5.17	48.99
	Word2Vec + SVC	5.17	48.99
	Word2Vec + RandomForestClassifier	23.44	62.53
	Word2Vec + DecisionTreeClassifier	19.22	56.44
	Word2Vec + GaussianNB	1.43	7.60
	Word2Vec + GradientBoostingClassifier	15.45	56.24
	Word2Vec + VotingClassifier (hard)	13.76	55.77
	Word2Vec + VotingClassifier (soft)	16.21	57.54
<b>текст без пунктуации и без эмодзи</b>	BoW + Logistic Regression	8.33	52.19
	BoW + SVC	6.99	50.60
	BoW + RandomForestClassifier	15.36	53.06
	BoW + DecisionTreeClassifier	14.62	50.57
	BoW + GaussianNB	10.86	39.11
	BoW + GradientBoostingClassifier	12.58	51.35
	BoW + VotingClassifier (hard)	14.38	52.34
	BoW + VotingClassifier (soft)	14.80	53.45
	Navec + Logistic Regression	12.28	50.47
	Navec + SVC	7.67	50.36
	Navec + RandomForestClassifier	10.57	51.80
	Navec + DecisionTreeClassifier	10.43	46.41
	Navec + GaussianNB	1.05	1.05

	Модель	F1 macro%	F1 weighted %
	Navec + GradientBoostingClassifier	9.12	49.62
	Navec +VotingClassifier (hard)	11.41	51.92
	Navec +VotingClassifier (soft)	11.89	52.67
	Word2Vec + Logistic Regression	5.17	48.99
	Word2Vec + SVC	5.17	48.99
	Word2Vec + RandomForestClassifier	9.71	51.74
	Word2Vec + DecisionTreeClassifier	9.83	44.48
	Word2Vec + GaussianNB	0.01	0.01
	Word2Vec + GradientBoostingClassifier	8.58	48.09
	Word2Vec +VotingClassifier (hard)	8.78	50.46
	Word2Vec +VotingClassifier (soft)	8.91	50.82
лемматизированный текст с пунктуацией и с эмóдзи	BoW + Logistic Regression	51.49	78.64
	BoW + SVC	40.16	72.11
	BoW + RandomForestClassifier	66.77	81.43
	BoW + DecisionTreeClassifier	66.60	79.68
	BoW + GaussianNB	27.26	60.74
	BoW + GradientBoostingClassifier	67.01	81.74
	BoW +VotingClassifier (hard)	63.35	81.32
	BoW +VotingClassifier (soft)	<b>69.70</b>	<b>82.06</b>
	Navec + Logistic Regression	11.39	49.15
	Navec + SVC	6.59	50.04
	Navec + RandomForestClassifier	11.14	51.98
	Navec + DecisionTreeClassifier	10.89	46.68
	Navec + GaussianNB	1.14	4.83
	Navec + GradientBoostingClassifier	7.35	49.20
	Navec +VotingClassifier (hard)	10.50	51.60
Navec +VotingClassifier (soft)	10.91	51.73	

	<b>Модель</b>	<b>F1 macro%</b>	<b>F1 weighted %</b>
	Word2Vec + Logistic Regression	5.17	48.99
	Word2Vec + SVC	5.17	48.99
	Word2Vec + RandomForestClassifier	25.85	64.19
	Word2Vec + DecisionTreeClassifier	19.91	56.79
	Word2Vec + GaussianNB	1.40	6.56
	Word2Vec + GradientBoostingClassifier	17.77	57.97
	Word2Vec + VotingClassifier (hard)	13.43	55.47
	Word2Vec + VotingClassifier (soft)	15.09	59.41

Лучший результат среди использованных нейросетевых моделей показала рекуррентная нейросеть GRU на 15 эпохах обучения: F1-мера макро равна 48.77%, F1-мера weighted равна 83.74%. Полученные результаты представлены в Таблице 4 (лучшие результаты выделены жирным шрифтом).

Таблица 4. Результаты оценки эмоциональной окраски текста для нейросетевых методов

	<b>Модель</b>	<b>F1 macro%</b>	<b>F1 weighted %</b>
токенизатор Keras optimizer='adam' epochs=5	Одномерная сверточная нейросеть	17.42	71.54
	Рекуррентная нейросеть LSTM	11.85	62.66
	Рекуррентная нейросеть GRU	28.29	78.42
токенизатор Keras optimizer='adam' epochs=10	Одномерная сверточная нейросеть	40.20	81.86
	Рекуррентная нейросеть LSTM	23.44	78.39
	Рекуррентная нейросеть GRU	43.15	83.85
токенизатор Keras optimizer='adam' epochs=15	Одномерная сверточная нейросеть	27.77	78.96
	Рекуррентная нейросеть LSTM	29.34	79.81

	<b>Модель</b>	<b>F1 macro%</b>	<b>F1 weighted %</b>
	Рекуррентная нейросеть GRU	<b>48.77</b>	<b>83.74</b>

Получили, что в случае макроусреднения, т.е. когда всем классам даётся одинаковый вес, независимо от их количества в наборе данных, лучший результат F1-мера macro = 69.70% для модели BoW +VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи. В случае же взвешенного усреднения, т.е. когда вес классам даётся согласно количеству объектов в этих классах, лучший результат F1-мера weighted = 83.74% для модели рекуррентной нейросети GRU на 15 эпохах обучения.

В Таблице 5 представлены примеры того, как модели с лучшими показателями: BoW +VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи и рекуррентная нейросеть GRU на 15 эпохах обучения предсказывают классы для различных текстов.

Таблица 5. Примеры текстов с предсказанными классами

<b>Модель</b>	<b>Пример текста</b>	<b>Класс, предсказанный моделью</b>
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	Какая красота!	smile positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		no_emotion neutral/skeptical
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	Какая красота 😊	smile positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		smile positive/negative

Модель	Пример текста	Класс, предсказанный моделью
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	ничего не меняется	smile positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		smile positive/negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	ничего не меняется 😞	sadness negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		sadness negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	жизнь прекрасна?	smile positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		smile positive/negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	жизнь прекрасна 😲	surprise positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		surprise positive/negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	какая муть, блин	smile positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		smile positive/negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	какая муть 😬	shame negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		shame negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	до мурашек!	smile positive/negative

Модель	Пример текста	Класс, предсказанный моделью
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)	до мурашек!	smile positive/negative
BoW +VotingClassifier (soft) на лемматизированном тексте с пунктуацией и с эмодзи	до мурашек! 🐛	fear positive/negative
Рекуррентная нейросеть GRU (токенизатор Keras optimizer='adam' epochs=15)		sadness negative

### 3.4 Модель на основе rubert-tiny2

В качестве эксперимента была дообучена модель rubert-tiny2<sup>34</sup> с платформы Hugging Face<sup>35</sup>. Hugging Face представляет собой коллекцию готовых предварительно обученных моделей машинного обучения. Библиотека Transformers<sup>36</sup> предоставляет различные инструменты и интерфейсы для загрузки и использования предобученных моделей, что позволяет экономить время и ресурсы, так как нет необходимости обучать модели с нуля.

Производилось дообучение модели rubert-tiny2, которая использовалась для обучения модели rubert-tiny2-cedr-emotion-detection<sup>37</sup> на 6 классах. В данной работе дообучение выполнялось на полученных данных с 15 классами. В таблице 6 представлены значения для F1-меры для дообученной модели по 15 классам. Среднее F1 macro равно 50.92%, F1 weighted равно 92.92%. Дальнейшие планы связаны с экспериментами на сбалансированных данных и других параметрах модели.

<sup>34</sup> <https://huggingface.co/cointegrated/rubert-tiny2>, дата обр. 3.05.2023.

<sup>35</sup> <https://huggingface.co/>, дата обр. 30.04.2023

<sup>36</sup> <https://huggingface.co/docs/transformers/index>, дата обр. 30.04.2023

<sup>37</sup> <https://huggingface.co/cointegrated/rubert-tiny2-cedr-emotion-detection>, дата обр. 3.05.2023.

Таблица 6. Результаты оценки эмоциональной окраски текста для дообученной модели ruBERT-tiny2 по 15 классам

	<b>binary</b>	<b>micro</b>	<b>macro</b>	<b>weighted</b>
<b>0</b>	0.6383	0.5618	0.5413	0.5720
<b>1</b>	0.1611	0.7007	0.4895	0.7509
<b>2</b>	0.1982	0.9035	0.5734	0.8892
<b>3</b>	0.0837	0.8812	0.5101	0.8949
<b>4</b>	0.1087	0.9555	0.5429	0.9480
<b>5</b>	0.0000	0.9886	0.4971	0.9830
<b>6</b>	0.0000	0.9837	0.4959	0.9757
<b>7</b>	0.0000	0.9897	0.4974	0.9846
<b>8</b>	0.0000	0.9892	0.4973	0.9838
<b>9</b>	0.0000	0.9864	0.4966	0.9797
<b>10</b>	0.0000	0.9962	0.4990	0.9943
<b>11</b>	0.0000	0.9962	0.4990	0.9943
<b>12</b>	0.0000	0.9951	0.4988	0.9927
<b>13</b>	0.0000	0.9973	0.4993	0.9959
<b>14</b>	0.0000	0.9995	0.4999	0.9992

### 3.5 Оценка эмоциональной окраски словосочетаний

Тональность и эмоциональная окраска словосочетаний могут отличаться от параметров отдельных слов, которые входят в то или иное словосочетание, смыслы слов в словосочетании неаддитивны. Для оценки эмоциональной окраски словосочетаний нельзя просто складывать или вычитать эмоционально-тональные составляющие словосочетания. Например в словосочетании «хороший день» слово «хороший» имеет положительную



тональность, а слово «день» не имеет никакой тональности, поэтому всё словосочетание имеет положительную тональность. В таком же словосочетании, как «хороший лжец», слово «хороший» имеет положительную тональность, а слово «лжец» имеет отрицательную тональность, но всё словосочетание имеет так же отрицательную тональность, поскольку главным словом в данном словосочетании является слово «лжец».

В данной работе выделяются словосочетания из текста постов, которые автоматически размечены по классам эмоций и их тональности на основании эмодзи в этих постах. Текст постов переведён в нижний регистр, приведён к нормальной форме с помощью лемматизатора `rumorphy2`, убраны стоп-слова такие, как частицы, предлоги, спецсимволы, местоимения, встречающиеся имена собственные, числа. Из демонстрационных примеров словосочетаний убрана нецензурная лексика, но при разметке постов эта лексика сохранялась. Полученные тексты постов распределены по 15 выделенным классам на основании встречающихся в них эмодзи. Для оценки эмоциональной окраски из полученных текстов постов извлечены словосочетания: биграммы, триграммы и тетраграммы, посчитана их встречаемость в постах, относящихся к тому или иному классу эмоций и тональности. Отдельно для каждого из 15 классов оценивалась эмоциональная окраска полученных словосочетаний. В Таблице 7 приведены примеры словосочетаний по выделенным 15 классам.

Таблица 7. Словосочетания по классам эмоций и тональности

№	эмоция	настроение (тональность)	примеры биграмм	примеры триграмм	примеры тетраграмм
1	улыбка (smile)	позитивное/ негативное (positive/ negative)	'фильм стоит', 'хороший фильм', 'день жизнь'	'главное успеть сделать', 'сделать вид спать', 'важный полезный совет'	'главное успеть сделать вид', 'сделать вид спать занят', 'юмор продлевать жизнь доказано'
2	нет эмоции (no_emo- tion)	нейтральное/ скептическое (neutral/ skeptical)	муж дочка', 'девочка расти', 'чебурашка девочка'	'летний хвастаться шикарный', 'понятие хороший вкуса', 'развод активный поиск'	'идеальный хвастаться фотография отпуск', 'позволять подсмотреть ночной жизнь', 'семья идеальный пример подражание'
3	удовольс- твие (joy)	позитивное (positive)	'безумно красивый', 'день рождение', 'лайк смотреть'	'настоящий радость мамочки', 'невероятный любовь хозяин', 'успеть купить вкусный'	'вкусный цена чёрный пятница', 'ранний хит покорять страна', 'хороший мультсериал детства смотреть'

№	эмоция	настроение (тональность)	примеры биграмм	примеры триграмм	примеры тетраграмм
4	нет эмоции (no_emotion)	позитивное/ негативное (positive/ negative)	'кот понял', 'ночной кайф', 'легендарный режиссёр'	'фильм легендарный режиссёр', 'легенда детство возвращаться', 'родитель дети капли'	'чересчур хорош собственный персонай', 'простой рецепт канапе вкусно', 'необычный образ муж оценить'
5	грусть (sadness)	негативное (negative)	'перестать работать', 'нездоровый отношение', 'прощай легенда'	'дядя поправляться скорее', 'отличный фильм растрогать', 'талантливый актеры уйти'	'талантливый актеры уйти жизнь', 'кош порвать рука лоскут', 'перестать работать уйти эпоха'
6	страх (fear)	негативное (negative)	'страшно представить', 'сойти ум', 'ум условиях'	'сойти ум условиях', 'природа случаться брак', 'чересчур ревнивый муж'	'катиться мир вымирать настоящий', 'уникальный кадр сверхсекретн ый боевой', 'страшно представить случиться волос'

№	эмоция	настроение (тональность)	примеры биграмм	примеры триграмм	примеры тетраграмм
7	стыд (shame)	негативное (negative)	'последствие липосакции', 'пластически й операция', 'устроить истерика'	'устроить истерика женщина', 'результат грудной вскармливания', 'мэйбить бэйбить высказаться'	'мэйбить бэйбить высказаться трек', 'последний время выглядеть пугающе', 'мода пойти показывать сцена'
8	гнев (anger)	негативное (negative)	'вечера снять', 'слышать треки', 'начинать шашковать'	'выходить настроить серьёзно', 'злой хозяин кормить', 'сгинуть тупой дура'	'злой хозяин кормить пушистика', 'сгинуть тупой дура мусор', 'аудиозапись вложение ужас ужасный'
9	отвраще ние (disgust)	негативное (negative)	'ходячий пропоганда', 'хороший кривляка', 'блевотный сериал'	'блевотный сериал примитивный', 'невероятный муть тратить', 'бесит силиконовый бабка'	'рекламирова ть инфоцыган человек кидать', 'чат сломали предупрежде ние объяснение', 'инфоцыган человек кидать деньги'

№	эмоция	настроение (тональность)	примеры биграмм	примеры триграмм	примеры тетраграмм
10	удивлен ие (surprise)	позитивное/ негативное (positive/ negative)	'ночной кайф', 'новинка пятница', 'чересчур большой'	'запомниться зрителю приходиться', 'рано радоваться стал', 'слабо пройтись мосту'	'насколько должный нравиться душа', 'должный нравиться душа спать', 'главное получиться спокойный ночь'
11	отвраще ние (disgust)	нейтральное/ скептическое (neutral/ skeptical)	'особый разница', 'человек поплатиться', 'поплатиться жизнь'	'чел залить плохой', 'рассказывать неприятный вещь', 'соц сеть мир'	'чел залить плохой качестве', 'удалили недосмотрет ь пара часть', 'грудь уменьшить делать операции'
12	удивлен ие (surprise)	негативное (negative)	'громкий инсайд', 'максимально непривычно', 'напасть распростран ить'	'стрим максимально непривычно', 'отведать пища бог', 'гардероб квартира маленький'	'выкинуть окно машины просьба', 'заценить удар особый выражение', 'интересно дурак поехать снимать'

№	эмоция	настроение (тональность)	примеры биграмм	примеры триграмм	примеры тетраграмм
13	нет эмоции (no_emotion)	негативное (negative)	'хэйтеры откисайт', 'ржал пацан', 'гонки показывают'	'понимать мамный трудно', 'приложение работать вопрос', 'проблема интернетом вернуть'	'приложение работать вопрос дудосит', 'добавить чёрный тема тёмный', 'бот работать стикер выдавать'
14	грусть (sadness)	позитивное/ негативное (positive/ negative)	'часть разочаровать ся', 'забаганный продукт', 'телефон ошибка'	'игра боженька смолвить', 'женский юмор бессмысленны й', 'юмор бессмысленны й беспощадный'	-
15	испуг (fear)	позитивное/ негативное (positive/ negative)	'набить логотип', 'мелкий блоха', 'больной кусает'	'мелкий блоха больной', 'блоха больной кусает', 'призрак кондиционер преследовать'	-

В приложении Б представлена визуализация словосочетаний для выделенных 15 классов эмоций и тональности.

### Выводы

В главе 3 представлен процесс получения и обработки набора данных, описаны проведённые эксперименты, приведены результаты метрик оценки качества используемых моделей машинного обучения. На основании анализа исследовательских работ была выделена линейка алгоритмов для проведения экспериментов. По метрикам качества классификации текста постов и

словосочетаний в них лучший результат по метрике F1-мера macro = 69.70% показала модель BoW + VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи. Лучшие результаты по метрике качества классификации F1-мера weighted показала модель рекуррентной нейросети GRU на 15 эпохах обучения F1-мера weighted = 83.74% и дообученная модель на основе rubert-tiny2 с метрикой F1-мера weighted = 92.92%.

## ЗАКЛЮЧЕНИЕ

В ходе данного исследования было предложено решение проблемы оценки эмоциональной окраски русскоязычного текста постов и словосочетаний в этих постах методами машинного обучения с использованием размеченных на основе эмодзи текстовых данных, собранных из публичных групп в социальной сети «ВКонтакте», тем самым, поставленная цель была достигнута.

В данной работе представлена оценка эмоциональной окраски постов и словосочетаний в них из социальной сети «ВКонтакте», описан процесс получения, обработки и использования полученного набора данных. Приводятся результаты экспериментов с использованием методов машинного обучения с оценкой работы методов по метрикам качества классификации. По оценке качества классификации текста постов и словосочетаний в них лучший результат по метрике F1-мера macro = 69.70% показала модель BoW + VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи. Лучшие результаты по метрике качества классификации F1-мера weighted получены для модели рекуррентной нейросети GRU F1-мера weighted = 83.74% и дообученной модели на основе rubert-tiny2 F1-мера weighted = 92.92%.

С практической точки зрения, результаты исследования могут быть использованы для анализа мнений, анализа отзывов клиентов, мониторинга социальных сетей. Оценка эмоциональной окраски текста может быть полезна во многих ситуациях, например, для того, чтобы понять какое настроение выражено в тексте. Понимая эмоции, выраженные в тексте, организации могут лучше учитывать потребности и предпочтения своих клиентов и соответствующим образом скорректировать стратегии своей деятельности. Понимание эмоций можно использовать в личном общении, чтобы оценить настроение человека и отреагировать соответствующим образом. В целом, оценка эмоциональной окраски текста может помочь



улучшить общение, укрепить отношения и принимать более взвешенные решения.

Так как эксперты не размечали полученные данные, а использовалась автоматическая разметка постов на основании встречающихся в этих постах эмодзи, в дальнейшем планируется провести экспертную оценку полученной автоматической разметки постов по выделенным классам. Дальнейшие планы связаны с проведением экспериментов на сбалансированных данных. В будущем можно продолжить исследование с использованием текстов с другими параметрами по количеству эмодзи и токенов в тексте.

## СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Арнольд И.В. Стилистика. Современный английский язык: Учебник для вузов. - 7-е изд. / И.В. Арнольд. - М.: Флинта: Наука, 2005. - 384 с.
2. Балли Ш. Общая лингвистика и вопросы французского языка / пер. с 3-го фр. изд. Вентцель Е.В., Вентцель Т.В. - М., 1955. - 416 с.
3. Басина П., Гойко В., Петров Е., Бакулин В. Классификация публикаций сообществ «ВКонтакте» для оценки качества жизни населения. // Компьютерная лингвистика и интеллектуальные технологии: по материалам международной конференции «Диалог 2022», 2022.
4. Ван Дейк Т.А. Язык. Познание. Коммуникация / Т.А. Ван Дейк. - М.: Высшая школа, 1989. - 307 с.
5. Верхоляк О. В. Автоматическое распознавание эмоциональных состояний дикторов по голосовым характеристикам и тональности текста высказывания : Дис. ... канд. технич. наук 05.13.17 / Верхоляк О.В. - СПб, 2021. - 331 с.
6. Вилюнас В.К. Основные проблемы психологической теории эмоций // Психология эмоций. Тексты. - М., 1984.
7. Дале Д. Маленький и быстрый BERT для русского языка, url: <https://habr.com/ru/post/562064/>, дата обр. 6.05.2023.
8. Дале Д. Рейтинг русскоязычных энкодеров предложений, url: <https://habr.com/ru/articles/669674/>, дата обр. 6.05.2023.
9. Додонов Б. И. Эмоция как ценность. - М.: Политиздат, 1977. - 272 с.
10. Зайнульдинов А.А., Керо Хервилья Э. Ф. Лексикографическое описание эмоционально-оценочной лексики в русском и испанском языках // Вопросы языкознания. - 2019. - №2. - с. 96-110.
11. Ионова С.В. Лингвистика эмоций: основные проблемы, результаты и перспективы // Язык и эмоции: личностные смыслы и доминанты в речевой деятельности. Сб. науч. труд. - Волгоград: ВГПУ, ЦОП «Центр», 2004. - с.5.

12. Калабихина И.Е., Лукашевич Н.В., Банин Е.П., Алибаева К.В. Автоматический анализ репродуктивных ценностей сети ВКонтакте // XII Международная научная конференция «Интеллектуальные системы и компьютерные науки», 2021.

13. Кузнецова Е. С., Лукашевич Н. В., Четверкин И. И. Тестирование правил для системы анализа тональности // Компьютерная лингвистика и интеллектуальные технологии: по материалам международной конференции «Диалог 2013», 2, 2013, 71–80.

14. Кулагин Д.И. Открытый тональный словарь русского языка КартаСловСент // Компьютерная лингвистика и интеллектуальные технологии: По материалам ежегодной Международной конференции «Диалог». Вып. 20, М.: Изд-во РГГУ, 2021. — С. 1106-1119.

15. Куратов Ю., Архипов М. Адаптация глубоких двунаправленных многоязычных моделей на основе архитектуры Transformer для русского языка // Компьютерная лингвистика и интеллектуальные технологии: по материалам международной конференции «Диалог 2019», 2019.

16. Никитин М. В. Лексическое значение слова (структура и комбинаторика). - М., Высшая школа, 1983.

17. Носенко Э. Л. Эмоциональное состояние и речь. - Киев : Вища школа, 1981. - 195 с.

18. Осовский Н. Precision и recall. Как они соотносятся с порогом принятия решений?, url: <https://habr.com/ru/articles/661119/>, дата обр. 6.05.2023.

19. Петрова Ю.А. К проблеме перевода эмотивной лексики // ЯЗЫК И КУЛЬТУРА: Сборник статей XXIX Международной научной конференции (16–18 октября 2018 г.), Часть 2, Томск: Изд-во Дом Томского государственного университета, 2019. — С. 241-246.

20. Прудникова И.А. Типологии эмоциональных единиц применительно к лингвистическому исследованию // Наука и современность. - 2011. - с. 119-124.

21. Стадульская Н.А. Эмоционально-оценочный и экспрессивный компоненты в семантике прагматонимов // Вестник Томского государственного педагогического университета. - 2007. - №4. - с. 36-41.
22. Чернышев М. В. Система автоматического сентимент-анализа текстов на английском языке: Дис. ... канд. филол. наук 10.02.21 / Чернышев М.В. - Минск, 2019. - 145 с.
23. Шаховский В.И. Категоризация эмоций в лексико-семантической системе языка. - М.: Книжный дом «ЛИБРОКОМ», 2019. - 206 с.
24. Шаховский В.И. Эмотивный компонент значения и методы его описания: учебное пособие к спецкурсу. - Волгоград: Изд. ВГПИ им. А.С. Серафимовича, 1983. - 96 с.
25. Шмелёв Д. Н. Проблемы семантического анализа лексики (На материале рус. яз.) — М. : Наука, 1973.
26. Якобсон Р. Лингвистика и поэтика // Структурализм: «за» и «против». - М., 1975. - с. 193-227.
27. Belchikov, A. Russian language toxic comments, url: [https://www.kaggle.com/blackmoon/russian-language-toxic-comments.](https://www.kaggle.com/blackmoon/russian-language-toxic-comments), дата обр. 6.05.2023.
28. Calvo, R. A., D'Mello, S. Affect detection: An interdisciplinary review of models, methods, and their applications // IEEE Transactions on affective computing, 1(1), 2010, 18-37.
29. Devlin, J., Chang, Ming-Wei, Lee, K., Toutanova, K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 1, 2019, 4171–4186.
30. Ekman P. An argument for basic emotions // Cognition Emotion, vol. 6, nos. 3–4, pp. 169–200, May 1992.
31. Fahim Anzum, Gavrilova M.L. Emotion Detection from Micro-Blogs Using Novel Input Representation // IEEE Access, Volume 10, 2022.

32. Frank, E., Bouckaert, R. Naive bayes for text classification with unbalanced classes // In: Fürnkranz, J. et al. (eds.) Knowledge discovery in databases: PKDD 2006. pp. 503–510. Springer Berlin Heidelberg, Berlin, Heidelberg, 2006.
33. HaCohen-Kerner Y., Miller D., Yigal Y. The influence of preprocessing on text classification using a bag-of-words representation // PloS one, vol. 15, no. 5, 2020.
34. Howard J., Ruder S. Universal language model fine-tuning for text classification // in Proc. 56th Annu. Meeting Assoc. Comput. Linguistics, vol. 1, 2018, pp. 328–339.
35. Johnson-Laird P. N., Oatley K. The Language of Emotions: An Analysis of a Semantic Field // Cognition and Emotion. - 1989. - V.3 - p.81-123.
36. Joshi, A., Bhattacharyya, P., Carman, M. Automatic sarcasm detection: A survey // ACM Computing Surveys (CSUR), 50:5, 2017, 1–22.
37. Kiritchenko, S., Zhu, X., Mohammad, S. Sentiment analysis of short informal texts // Journal of Artificial Intelligence Research, 50, 2014, 723–762.
38. Kollias D., Zafeiriou S. Exploiting multi-CNN features in CNN-RNN based dimensional emotion recognition on the OMG in-the-wild dataset // IEEE Transactions on Affective Computing, vol. 12, no. 3, pp. 595–606, 2020.
39. Loukachevitch, N., Levchik, A. Creating a general Russian sentiment lexicon // Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16), 2016, 1171–1176.
40. Mikolov, T. et al. Distributed representations of words and phrases and their compositionality // In: Proceedings of the 26th international conference on neural information processing systems—volume 2. pp. 3111–3119. Curran Associates Inc., Red Hook, NY, USA, 2013.
41. Ortony A., Turner T.J. What's Basic About Basic Emotions? // Psychological Review. – 1990. – No. 3. – P. 315-331.
42. Pandurang Thakkar, Gaurish. Cross-lingual sentiment analysis of official EU Slavic languages // Doctoral thesis, 2022.

43. Pang, B., Lee, L., Vaithyanathan, S. Thumbs up? Sentiment Classification using Machine Learning Techniques // Proceedings of Conference on Empirical Methods in Natural Language Processing EMNLP– 2002, 2002, 79–86.
44. Plutchik R. A general psychoevolutionary theory of emotion // in Theories of emotion. Elsevier, 1980, pp. 3–33.
45. Ps S., Mahalakshmi G. Emotion models: a review // International Journal of Control Theory and Applications, vol. 10, no. 8, pp. 651–657, 2017.
46. Qaiser S., Ali R. Text mining: use of TF-IDF to examine the relevance of words to documents // International Journal of Computer Applications, vol. 181, no. 1, pp. 25–29, 2018.
47. Osgood C E., Suci G, Tannenbaum P. The Measurement of Meaning// Semantic Differential Technique. Chicago, 1968.
48. Rubtsova, Y. A method for development and analysis of short text corpus for the review classification task // Proceedings of conferences Digital Libraries: Advanced Methods and Technologies, Digital Collections (RCDL'2013). Pp. 269–275, 2013.
49. Russell J.A. A circumplex model of affect // Journal of Personality and Social Psychology, vol. 39, no. 6, p. 1161, 1980.
50. Russell J. A., Mehrabian A. Evidence for a three-factor theory of emotions // Journal of Research in Personality, vol. 11, no. 3, pp. 273–294, 1977.
51. Saif M. Mohammad. Sentiment Analysis: Automatically Detecting Valence, Emotions, and Other Affectual States from Text // To Appear as a Book chapter in The 2nd Edition of Emotion Measurement, Elsevier, 2021.
52. Sang-Bum Kim et al. Some effective techniques for naive bayes text classification // IEEE Transactions on Knowledge and Data Engineering. 18, 11, 1457–1466, 2006.
53. Saravia E., Toby Liu H., Huang Y., Wu J., Chen Y. CARER: Contextualized Affect Representations for Emotion Recognition // In Proceedings of the 2018 Conference on Empirical Methods in Natural

Language Processing, pages 3687–3697, Brussels, Belgium. Association for Computational Linguistics, 2018.

54. Sboev, A., Naumov, A., Rybka, R. Data-Driven Model for Emotion Detection in Russian Texts // 2020 Annual International Conference on Brain-Inspired Cognitive Architectures for Artificial Intelligence: Eleventh Annual Meeting of the BICA Society, *Procedia Computer Science* 190, 2021, 637–642.

55. Smetanin S. Toxic Comments Detection in Russian // *Computational Linguistics and Intellectual Technologies, Proceedings of the International Conference «Dialogue 2020»*, 2020.

56. Sun C., Qiu X., Xu Y., Huang X. How to fine-tune BERT for text classification? // in *Chinese Computational Linguistics*, M. Sun, X. Huang, H. Ji, Z. Liu, and Y. Liu, Eds. Cham, Switzerland: Springer, 2019, pp. 194–206.

57. Svetlov K., Platonov K. Sentiment analysis of posts and comments in the accounts of Russian politicians on the social network // in *Proc. 25th Conf. Open Innov. Assoc. (FRUCT)*, Nov. 2019, pp. 299–305.

58. Wierzbizcka A. *Emotions Across Languages and Cultures: Diversity and Universals (Studies in Emotion and Social Interaction)*. - 1st ed. - Cambridge University Press, 1999. - 361 p.

59. Zhang, L., Wang, S., Liu, B. Deep learning for sentiment analysis: A survey // *Wiley Reviews: Data Mining and Knowledge Discovery*, 8:4, 2018.

## ПРИЛОЖЕНИЕ А.

### Список популярных групп «ВКонтакте» на 5 февраля 2023 года

id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
91050183	<u>Леонардо Дайвинчик</u>	16 391 174	4 180
27895931	<u>Новинки Музыки   Новая Музыка 2023</u>	15 763 975	
58170807	<u>КиноКайф - Лучшие фильмы</u>	13 403 388	842
43215063	<u>Киномания ▶ Лучшие фильмы</u>	13 308 160	417
22822305	<u>ВКонтакте</u>	13 122 247	
22798006	<u>Киномания - Лучшие фильмы</u>	12 554 565	-318
57846937	<u>МДК</u>	12 030 069	-213
26419239	<u>Смейся до слёз :D</u>	11 593 676	14
45441631	<u>ПРИКОЛЫ   Смеяка</u>	11 439 645	-208
31836774	<u>Чёткие приколы</u>	9 310 801	
23064236	<u>Четкие Приколы</u>	8 634 877	-40
29246653	<u>Корпорация зла</u>	6 992 330	11
113071474	<u>Я ♥ КИНО</u>	8 299 753	2 479
40567146	<u>Лайфхак</u>	7 902 867	102
56106344	<u>Палата №6</u>	7 848 380	
40498005	<u>Психология отношений</u>	7 593 069	-217
30179569	<u>Убойный юмор</u>	7 241 939	
26750264	<u>5 лучших фильмов</u>	7 235 033	-85



id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
36164349	<u>Сарказм</u>	7 139 433	
48319873	<u>ИМПЕРИЯ КИНО  </u> <u>АВАТАР 2  </u> <u>НОВИНКИ 2022</u>	7 083 730	-12
28477986	<u>НЕ ПОВЕРИШЬ!</u>	7 074 306	
460389	<u>БОРЩ</u>	7 070 180	-26
26669118	<u>Красиво сказано . . .</u>	7 032 051	-9
26062647	<u>Kate Mobile</u>	6 897 205	
38683579	<u>Литература  </u> <u>Великие поэты</u>	6 578 716	3
33769500	<u>Достойные фильмы</u>	6 518 820	109
39009769	<u>Cook Good -</u> <u>лучшие рецепты</u>	6 387 206	-32
147845620	<u>VK Музыка</u>	6 429 370	
57876954	<u>Vine Video</u>	6 167 174	-143
55662720	<u>Психология</u>	6 146 235	-166
19802817	<u>Фильмы 2023 и</u> <u>Сериалы – Онлайн</u> <u>кино</u>	6 153 969	1 018
48512305	<u>Телеканал ТНТ</u>	6 060 418	
43879004	<u>Шедевры</u> <u>кулинарии  </u> <u>Вкусные рецепты</u>	5 841 903	131
36184135	<u>Идеи дизайна</u> <u>интерьера</u>	5 824 195	-29
39728801	<u>90-60-90  </u> <u>Спортивные</u> <u>девушки</u>	5 789 194	-1 342
66678575	<u>Овсянка, сэр!</u>	5 761 678	462

id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
45703770	<u>Музыка</u>	5 594 770	-59
34491673	<u>Убойные приколы</u>	5 498 332	24
27902394	<u>Приложение ВКонтакте</u>	5 444 602	
22741624	<u>Улетные приколы</u>	5 425 804	44
23243883	<u>Действительно смешно</u>	5 382 526	12
45595714	<u>Академия Порядочных Парней</u>	5 371 261	-117
14785431	<u>Фильмы 2023 Новинки кино онлайн</u>	5 728 818	4 139
6136139	<u>Знаете ли Вы?</u>	5 311 068	
45064245	<u>Школа красоты</u>	5 306 156	-122
29573241	<u>NR.Music</u>	5 311 765	-48
25554967	<u>СМС приколы</u>	5 289 259	-83
29559271	<u>Science Наука</u>	5 189 649	405
45045130	<u>МЕМЫ</u>	5 182 218	53
28627911	<u>40 КГ</u>	5 065 889	-35
28905875	<u>Рифмы и Панчи</u>	5 112 021	
35983383	<u>Популярная музыка</u>	5 025 671	174
34757875	<u>Салон красоты</u>	4 955 804	-134
40553536	<u>NETFLIX   Новинки кино 2023</u>	5 407 542	1 540
23830580	<u>Необычный Гороскоп</u>	4 948 684	
35061290	<u>Эгоист</u>	4 919 089	



id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
24713873	<u>5 умных мыслей</u>	4 922 767	97
29686754	<u>Шпильки   Женский Журнал</u>	4 892 974	-120
31976785	<u>Наука и Техника</u>	4 872 114	-16
48946342	<u>YUMMY   ВКУСНЫЕ РЕЦЕПТЫ</u>	4 845 697	-59
40835481	<u>Черный юмор</u>	4 843 266	-86
12648877	<u>Begin English. Английский язык для всех</u>	4 809 651	-392
135209264	<u>Бот Максим</u>	4 825 917	
18464856	<u>Лучшие рецепты Повара</u>	4 848 211	1 227
39410028	<u>Оптимист</u>	4 782 993	
28761941	<u>Я в шоке!</u>	4 785 133	74
26030283	<u>Сарказм</u>	4 780 295	
23245066	<u>Женские Хитрости   Лайфхакерша</u>	4 767 507	-59
32432151	<u>Я тебя люблю</u>	4 764 120	132
34118551	<u>Факты</u>	4 738 288	-151
141959356	<u>НЕНОРМАЛЬНО</u>	4 735 809	-208
26858816	<u>iFeed</u>	4 673 412	-141
71729358	<u>ПОЗОР</u>	4 687 896	
65662695	<u>Книга Рекордов</u>	4 637 024	-38
40335272	<u>Фильмы</u>	4 612 691	
46466345	<u>С нами стыдно, зато весело!</u>	4 605 884	

id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
19799369	<u>Темная сторона</u>	4 582 182	-178
36008740	<u>Я хочу...</u>	4 574 007	356
30318830	<u>Любовный Гороскоп</u>	4 564 980	
32194285	<u>Food.ru — Главная кухня страны</u>	4 534 168	
1959	<u>RECORD</u>	4 557 918	
33159467	<u>Смешно До Боли Ў</u>	4 527 087	
68114884	<u>Я тебя люблю</u>	4 522 195	
28293246	<u>Just love</u>	4 518 457	
184225789	<u>ТОПОР — Хранилище</u>	4 551 424	
19043	<u>Европа Плюс</u>	4 505 241	
45588871	<u>Омар Хайям и другие великие философы</u>	4 496 061	-197
79483347	<u>История Человечества</u>	4 474 025	-10
46117626	<u>Просто Вкусно</u>	4 525 895	1 694
25346844	<u>5 интересных фактов</u>		
28261265	<u>FUN</u>		
45608667	<u>Шутник</u>		
22866546	<u>Клубная музыка</u>		
32477579	<u>Современная Девушка</u>		
2158488	<u>LIVE</u>		




id группы	Название	Подписчики	Прирост (за текущие сутки начиная с 0:00) к 5.02.2023
46509740	<u>Маникюр 2023   Дизайн но</u>		
39236729	<u>Полный Бак</u>		
34451036	<u>Рецепты</u>		
23148107	<u>МДК</u>		
157369801	<u>СберКот</u>		

## ПРИЛОЖЕНИЕ Б.




### Визуализация словосочетаний для классов эмоций и тональности






удовольствие +






нет эмоции +/-



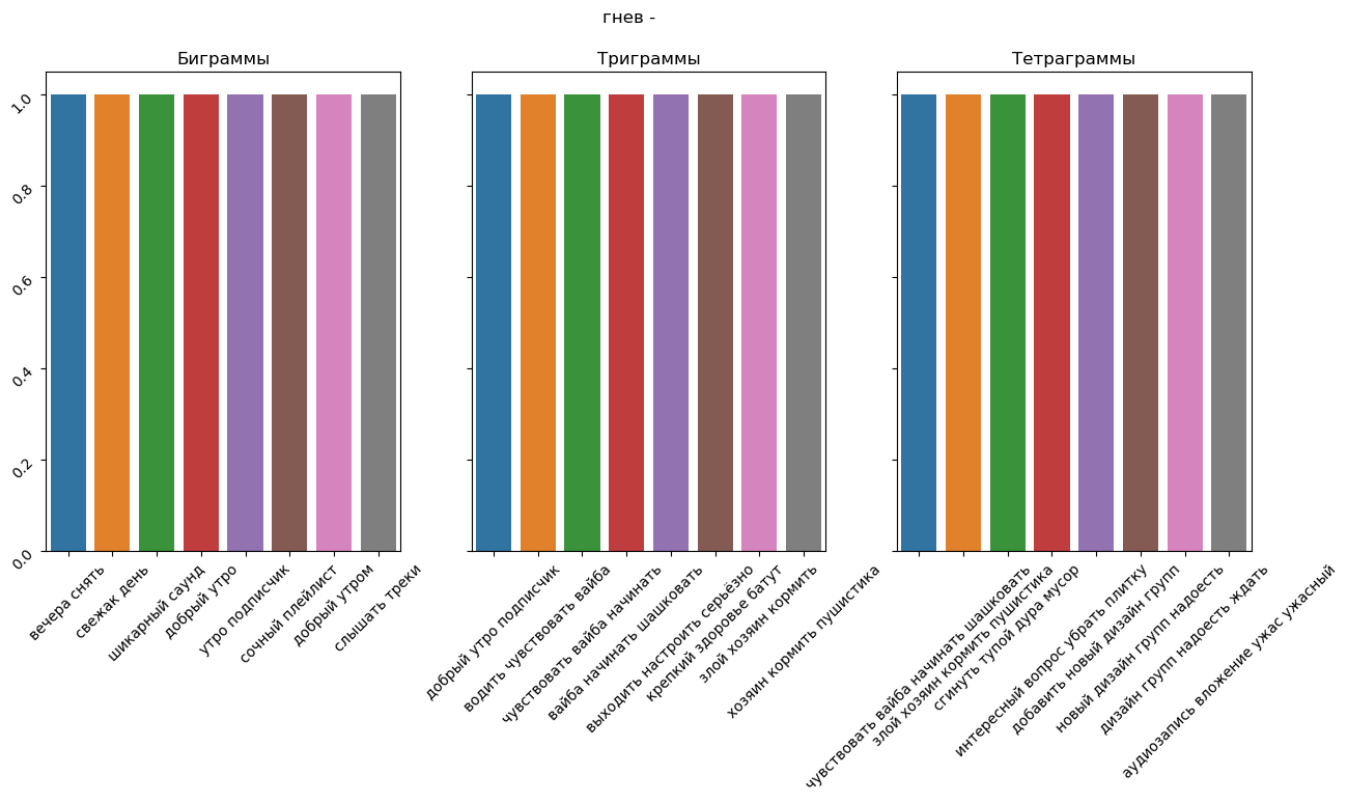
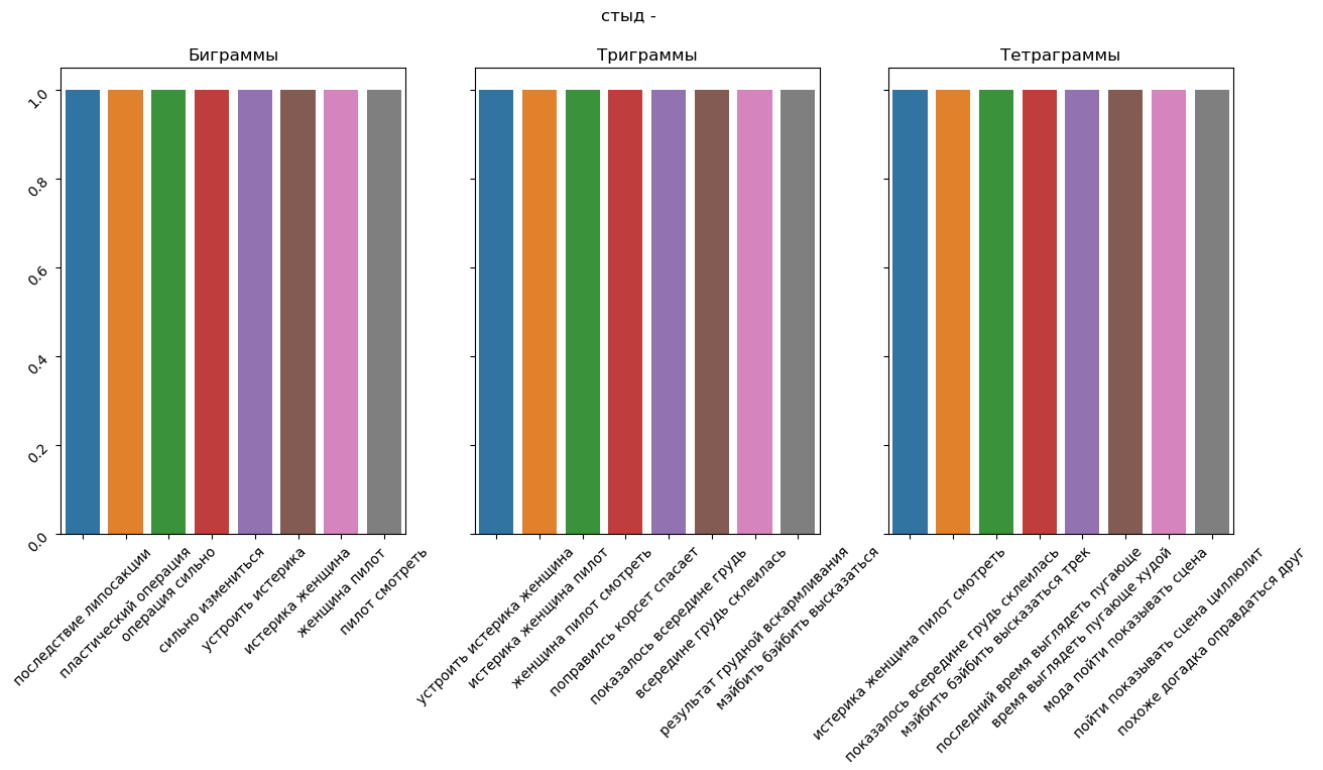
грусть -


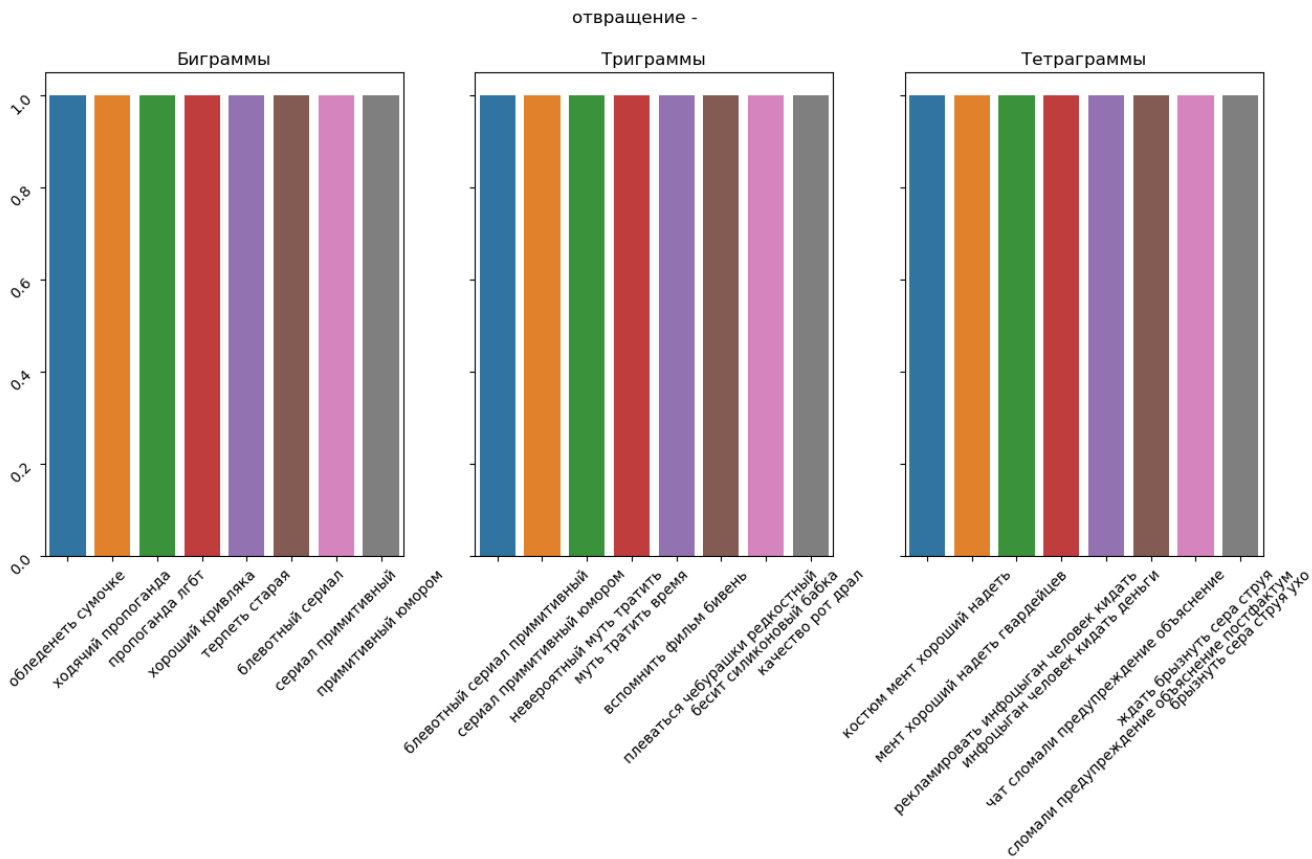


страх -






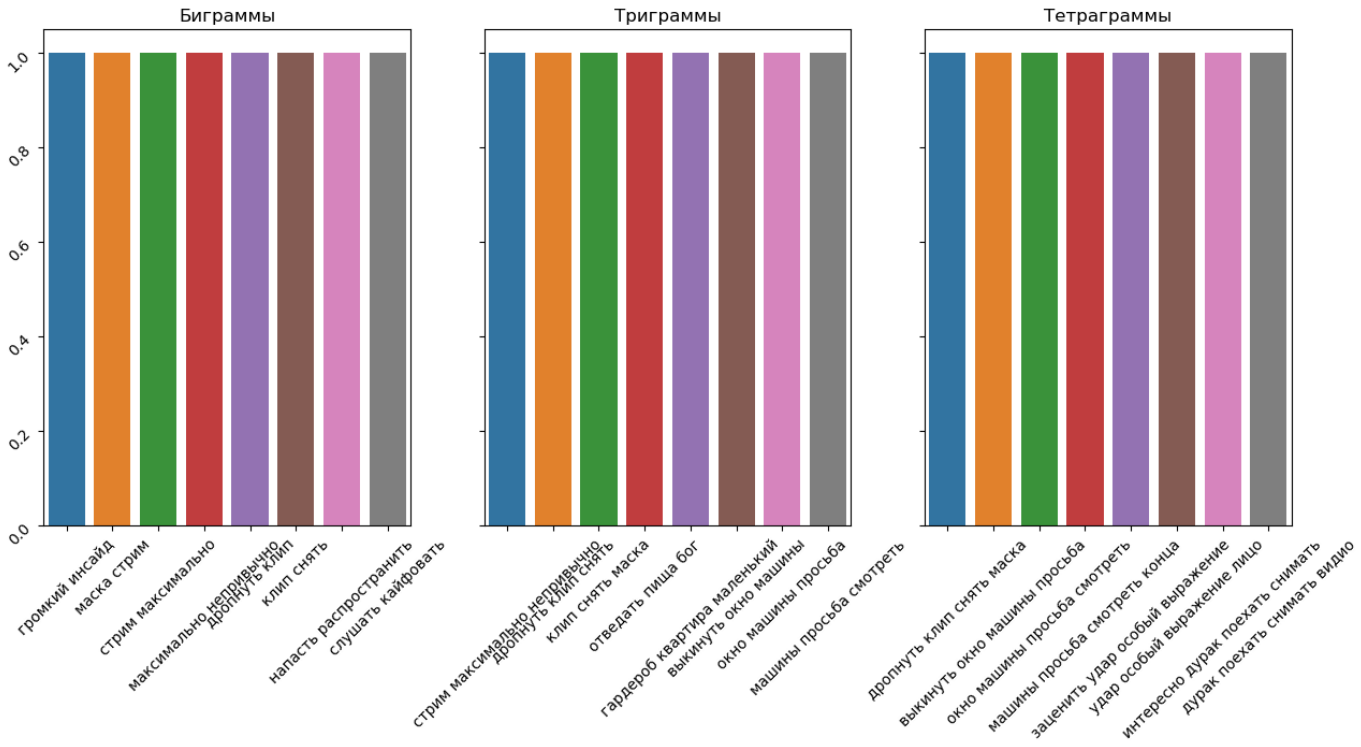





отвращение нейтральное/скептическое настроение




удивление -





нет эмоции -



грусть +/-



испуг +/-



## ПРИЛОЖЕНИЕ В.

### Метрики оценки качества классификации для методов с наилучшими показателями

Нумерация классов:

```
0 smile positive/negative
1 no_emotion neutral/skeptical
2 joy positive
3 no_emotion positive/negative
4 sadness negative
5 fear negative
6 shame negative
7 anger negative
8 disgust negative
9 surprise positive/negative
10 disgust neutral/skeptical
11 surprise negative
12 no_emotion negative
13 sadness positive/negative
14 fear positive/negative
```

Модель BoW + VotingClassifier (soft) (мешок слов + ансамблевый метод с мягким голосованием) на лемматизированном тексте с пунктуацией и с эмодзи:

VotingClassifier	precision	recall	f1-score	support
0	0.80	0.99	0.88	1166
1	0.92	0.53	0.67	203
2	0.95	0.57	0.71	152
3	0.94	0.59	0.73	101
4	1.00	0.62	0.76	86
5	1.00	0.50	0.67	26
6	1.00	0.62	0.77	24
7	1.00	0.60	0.75	15
8	1.00	0.50	0.67	14
9	1.00	0.78	0.88	18
10	1.00	0.50	0.67	8
11	1.00	0.60	0.75	15
12	1.00	0.36	0.53	11
13	1.00	1.00	1.00	3
14	0.00	0.00	0.00	2
accuracy			0.83	1844
macro avg	0.91	0.58	0.70	1844
weighted avg	0.86	0.83	0.82	1844

Рекуррентная нейросеть GRU (токенизатор Keras optimizer = 'adam', epochs = 15):

	precision	recall	f1-score	support
0	0.86	0.97	0.91	1231
1	0.81	0.67	0.73	190
2	0.79	0.66	0.72	146
3	0.74	0.63	0.68	90
4	0.92	0.70	0.80	70
5	1.00	0.61	0.76	18
6	0.93	0.65	0.76	20
7	1.00	0.29	0.44	21
8	1.00	0.20	0.33	10
9	0.80	0.42	0.55	19
10	1.00	0.44	0.62	9
11	0.00	0.00	0.00	8
12	0.00	0.00	0.00	6
13	0.00	0.00	0.00	3
14	0.00	0.00	0.00	3
accuracy			0.85	1844
macro avg	0.66	0.42	0.49	1844
weighted avg	0.84	0.85	0.84	1844