

# Автоматический анализ тональности текстов: проблемы и методы

Н. В. Лукашевич<sup>1</sup>

В данной работе представлен краткий обзор задач анализа тональности, а также проблем и используемых подходов. В последние годы в задачах анализа тональности активно применяются методы машинного обучения. В статье рассматриваются основные подходы машинного обучения и их особенности. На примере одного из датасетов для русского языка рассмотрен прогресс методов в задаче анализа тональности.

**Ключевые слова:** анализ тональности, таргетированный анализ тональности, лексикон оценочной лексики, машинное обучение, нейронная сеть, BERT.

## 1. Введение

Задача анализа тональности текста, т.е. выявление мнения некоторого лица (автора или субъекта, упомянутого в тексте) по поводу сущности или темы, обсуждаемых в тексте, является одной из активно развивающихся технологий в сфере автоматической обработки текстов в последнее десятилетие.

Задачи анализа тональности можно подразделить на две основные группы: общий анализ тональности и таргетированный анализ тональности. При общем анализе тональности задача системы – определить тональность автора для целого текста или фрагмента текста, например, для отзыва пользователя или поста социальной сети.

При таргетированном анализе тональности нужно определять тональность по отношению к заданной цели [1, 2], например, компании или продукту. При аспектном анализе тональности целью анализа являются аспекты (характеристики или части) некоторой сущности, например, в отзыве о ресторане необходимо извлечь отношение пользователя к еде, обслуживанию или обстановке – все эти оценки могут различаться. Еще одним видом таргетированного анализа является извлечение позиции пользователя по некоторой теме (stance detection), например, к вакцинации. Наконец, можно ставить целью извлечь отношения упоминаемых сущностей друг к другу (оценочные отношения) [3].

---

<sup>1</sup> *Лукашевич Наталья Валентиновна* — ведущий научный сотрудник НИВЦ МГУ, e-mail: louk\_nat@mail.ru.

Loukachevitch Natalia Valentinovna — leading researcher, Lomonosov Moscow State University, Research Computing Center.

Как и во многих других задачах автоматической обработки текстов, в задачах анализа тональности могут использоваться два основных типа подходов: алгоритмические методы на основе словарей и правил [3, 4] и методы на основе машинного обучения, для которых необходимо создавать размеченные вручную данные с примерами правильного решения задачи, а затем использовать специальные методы для обучения моделей автоматической разметки [1, 2]. Существуют и комбинированные методы, в которых словари оценочной лексики используются как компонент модели машинного обучения [5].

В данной статье будут рассмотрены имеющиеся словари оценочной лексики для русского языка, которые нужны для методов анализа тональности, основанных на знаниях. Мы также опишем проблемы, которые препятствуют созданию качественных алгоритмических подходов для анализа тональности. Наконец, будет представлена классификация методов машинного обучения, которые применялись в задачах анализа тональности. Прогресс методов машинного обучения будет продемонстрирован на данных тестирования таргетированного анализа тональности для русского языка SentiRuEval-2015 [6].

## **2. Словари в задаче тональности для русского языка**

Обычно предполагается, что тональность выражается с помощью оценочной (тональной) лексики, что представляет собой эксплицитный способ выражения мнения. Поэтому большое внимание уделяется разработке словарей оценочной лексики [7]. Словари могут создаваться на основе автоматической обработки текстовых коллекций, существующих толковых словарей и структурированных лексико-семантических ресурсов (тезаурусов). Для отбора лексики могут использоваться мнения экспертов или носителей языка, в последнем случае собирается некоторое множество мнений от разных людей (так называемый краудсорсинг). Рассмотрим примеры известных словарей оценочной лексики для русского языка и применяемые для их создания подходы.

В работе [9] описывается подход к автоматическому созданию словаря оценочной лексики в области товаров и услуг для русского языка ProductSentiRus. Словарь ProductSentiRus был получен применением модели машинного обучения, обученной для извлечения оценочных слов на основе совокупности их признаков, к наборам отзывов пользователей в нескольких предметных областях. Словарь представлен как список 5 тысяч слов, упорядоченных по мере снижения вычисленной вероятности их оценочности без указания позитивной или негативной тональности.

Словарь Linis-Crowd [10] создавался для анализа тональности текстов социальных сетей. Для создания словаря сначала из нескольких ресурсов были собраны слова-кандидаты, включая наиболее частотные прилагательные русского языка, употребляемые в текстах социальных сетей, образованные от них наречия, словарь ProductSentiRus [9] и др. Далее была произведена контекстная оценка тональности собранных слов, а также текстов, в которых они употреблялись, методом краудсорсинга по шкале от -2 (сильно негативный) до +2 (сильно позитивный). Оценки различных разметчиков усреднялись.

Словарь RuSentiLex [4] содержит слова и словосочетания, которые несут в себе оценочный компонент, включая явную оценку (*хороший*), эмоции (*грустно*) или коннотации, т.е. негативные или позитивные ассоциации (*кража*). Для составления словаря сначала были порождены списки слов-кандидатов на основе тезауруса RuТез [8], существующих словарей оценочной лексики, новостных статей и постов Твиттера, затем лингвисты анализировали полученные списки для формирования итогового словаря. Словарь содержит более десяти тысяч слов и выражений, выражающих оценку тональности. Если у многозначных слов тональность слова различается для некоторых значений, то тональность указана с точностью до значения.

Словарь фреймов RuSentiFrames [11] описывает тональности и эффекты, которые ассоциируются с участниками некоторой ситуации, выражаемой словом-предикатом, чаще всего глаголом или отглагольным существительным (например, *доверять, помощь*). Фрейм объединяет несколько слов и выражений, близких по смыслу и с одинаковыми ассоциированными тональностями (эффектами). Лексикон RuSentiFrames содержит следующую информацию, которая дает дополнительные возможности для анализа тональности текстов: отношение автора к участникам ситуации, позитивные или негативные отношения между участниками ситуации, позитивные или негативные эффекты относительно участников ситуации и др. В настоящее время лексикон содержит 311 фреймов с более чем 7 тысячами ассоциированных слов и выражений.

Более подробный список словарей оценочной лексики для русского языка представлен в работе [7].

### **3. Факторы, усложняющие анализ тональности текстов на естественном языке**

Факторы, усложняющие анализ тональности, можно разделить на несколько групп. К первой группе можно отнести проблемы, связанные

с изменением базовой тональности слова или выражения в конкретной предметной области (**Лексические факторы**).

Таким усложняющим фактором является многозначность оценочной лексики – некоторые слова в одних значениях могут быть нейтральными, а в других значениях иметь некоторую тональность. Например, слово *пресный* в словосочетании “пресная вода” является нейтральным, возможно с некоторой положительной ассоциацией. В то время как в других значениях “пресный на вкус”, и “пресный как неинтересный” данное слово несет негативную оценку [4].

Также слово может менять свою полярность или терять полярность в зависимости от предметной области, оставаясь при этом в одном и том же значении. Например, слова *подлый* и *предательство* не должны входить в словари оценочных слов, применяемых для анализа отзывов о фильмах, поскольку не могут использоваться для оценки собственно фильмов и их аспектов. Если эти слова встречаются в отзывах зрителей, то относятся к пересказу содержания фильма. Слово или выражение может приобрести явную тональность в некоторой предметной области без изменения значения в связи с тем, что мнение может высказываться имплицитно, с помощью так называемых оценочных фактов, т.е. формально сообщается некоторый факт, а читатель уже может сделать вывод об оценке исходя из своих знаний о мире. Например, в отзывах о ресторанах могут встретиться фразы “долго ждали” или “в супе плавают мухи”, что, с одной стороны, описывает происходящее (сообщает реальные факты), с другой стороны сообщает и оценку этому происходящему. Согласно определению [2] имплицитное мнение (оценка) – это объективное высказывание, из которого следует оценка, т.е. имплицитное мнение сообщается посредством упоминания желательного или нежелательного факта.

Очевидно, что анализ таких имплицитных форм тональности особенно сложен, поскольку в значительной мере зависит от предметной области. Таким образом, если даже для некоторого языка имеется лексикон оценочной лексики, то для анализа тональности с использованием словаря в конкретной предметной области, общий словарь должен настраиваться на конкретную предметную область: пополняться и частично даже очищаться. В частности, в словарь должны вноситься слова, связанные с типичными позитивными или негативными оценочными фактами в этой предметной области.

Вторая группа проблем анализа тональности связана с контекстом использования оценочной лексики, когда исходная тональность слова (выражения) меняется в контексте его использования (**Контекстные факторы**). В частности оценочное слово может встретиться в контексте объемлющего устойчивого выражения, названия. Например, слово

*великий* не является выражением мнения пользователя в выражении “Великая отечественная война”, поскольку это устоявшееся названия исторического события.

Часто появление оценочных слов в тексте может сопровождаться словами-модификаторами, которые усиливают (например, *очень, более*), снижают (*слишком, менее*) или преобразуют в обратную исходную тональность (например, отрицание, частицы *не, нет*), которая ассоциируется с данными словом. Таким образом, при анализе тональности нужно учитывать такие модификаторы и иметь некоторую численную модель, которая модифицирует исходные полярности слова.

Еще одним контекстным фактором является так называемый нерелевантный контекст (ирреалис), при котором сообщаемое в предложении не относится к тому, что реально происходит. Например, в предложении “Мы надеялись, что фильм нам понравится” употребляется слово *понаравится* с положительной тональностью, однако здесь ничего не говорится о том, понравился ли фильм на самом деле, т.е. в процессе автоматического анализа тональности данное слово не должно учитываться, как свидетельство позитивного отношения к фильму. Алгоритмическим решением может быть обнаружение таких контекстов по характерным признакам и снижение вклада оценочных слов внутри этих контекстов в общую оценку по тексту [3].

Третья группа усложняющих факторов связана с выражением иронии или сарказма. Под иронией понимается высказывание, содержание которого противоположно тому, что буквально сказано. Чаще всего под формально нейтральной или позитивной формой скрывается негативная тональность. Сарказм рассматривается как более резкая, агрессивная, возможно унижающая форма высказывания. Автоматическое распознавание в тексте иронии или сарказма очень сложно, требует подготовки специально размеченных текстовых данных [12]. В то же время стоит отметить, что доля таких явлений в текстах значительно меньше, чем ранее упомянутых усложняющих факторов.

## 4. Методы анализа тональности

Перечисленные в предыдущем разделе факторы значительно усложняют автоматический анализ тональности, что делает очень трудоемким применение алгоритмических методов. Поэтому большую популярность в задачах анализа тональности приобрели методы машинного обучения.

Применяемые методы машинного обучения в задачах анализа тональности могут быть разделены на три подкласса, что соответствует и некоторым историческим периодам развития методов машинного обучения в целом.

**Классические методы машинного обучения**, такие как Наивный байесовский классификатор, логистическая регрессия, метод опорных векторов (с начала 2000х годов до 2015 года) [13]. При этих подходах основным представлением текстов для классификации является векторное представление текстов на основе слов текста, к которым могут быть добавлены дополнительные признаки, например биграммы слов, знаки препинания, расположение в тексте и др. Существенной проблемой данных методов является то, что обучение в значительной степени зависит от конкретных слов, которые были в обучающей выборке – если в тестовых примерах появляются новые, отсутствующие в обучающей выборке слова, несущие существенную информацию для классификации, то методы не могут их учесть.

**Классические нейронные сети**, включая рекуррентные нейронные сети (чаще всего сети LSTM) и сверточные нейронные сети [14]. Данные методы стартуют с представлений слов в виде так называемых распределенных векторных представлений (эмбеддингов), которые обычно предобучаются на больших текстовых коллекциях, соответствующих задаче. Обучение эмбеддингов происходит так, чтобы близкие по смыслу слова получали похожие вектора. Поэтому в этих подходах снижается проблема появления новых слов в тестовой коллекции: если слово имеет векторное представление, то это представление может уже нести некоторую информацию о смысле слова, которое может быть учтено моделью. Вторая особенность нейронных сетей состоит в том, что и в рекуррентной, и в сверточной нейронной сети есть механизмы для учета последовательностей слов, поэтому при этих подходах нет необходимости специально прописывать биграммы и другие последовательности слов как признаки для представления анализируемых текстов.

**Походы на основе трансформеров** С 2019 года появились новые нейросетевые походы на основе архитектуры трансформер. В частности, модель BERT на основе трансформеров [15] предобучается на больших объемах текстовых данных и формирует контекстуализированные векторные представления слов, которые зависят от контекста слова. Такие контекстуализированные векторные представления могут быть далее использованы в различных нейросетевых архитектурах для решения различных задач. Использование архитектуры типа BERT привело к росту качества решения различных задач автоматической обработки текстов, включая задачи анализа тональности.

Изначально модель BERT обучалась на многоязычных текстовых коллекциях. В последующих исследованиях было выявлено, что дообучение BERT на коллекциях конкретного естественного языка или конкретной предметной области позволяет улучшать результаты решения задач для этого языка, этой области. В частности, в работе [16] описы-

вается дообучение исходной модели BERT для русского языка - модель RuBERT, в работе [17] такая же технология используется для обучения модели RuBERT для анализа текстов на русском языке в области компьютерной безопасности.

Рассмотрим, как менялось качество, достигаемое в задачах анализа тональности, на примере датасета SentiRuEval-2015 [6], в котором требовалось предсказать, насколько позитивной, негативной или нейтральной является информация в постах Твиттера по отношению к телекоммуникационным операторам. Основной мерой в этом тестировании 2015 года считалась средняя F-мера между позитивным и негативным классом, поскольку чаще всего необходимо найти именно позитивные или негативные сообщения, а не нейтральные [6].

Таблица 1 представляет результаты различных методов машинного обучения на данных датасета SentiRuEval-2015 на основе работы [18]. В 2015 году лучшим результатом по  $F_1$  *macro*, достигнутым участниками тестирования, было значение 48.80 – результат был получен классическим методом машинного обучения – методом опорных векторов SVM, основными признаками в которых были слова сообщения. На второй строчке Таблицы 1 приведены результаты того же классического метода опорных векторов, но который уже использует векторные представления слов, т.е. снижается проблема новых слов, и в результате мы видим рост результатов. Однако метод опорных векторов не создает представления последовательностей слов, всего предложения в целом, и поэтому рост результатов очень небольшой.

Применение рекуррентных нейронных сетей типа LSTM позволило дальше улучшить качество классификации, поскольку такая сеть формирует представление для предложения в целом. Применение двунаправленной сети LSTM (BiLSTM) еще улучшило результаты, что соответствует и результатам в решении многих других задач. Это связано с тем, что в процессе обучения формируется два представления предложения: слева направо и справа налево, что во многих случаях позволяет лучше учесть контекст.

Использование предобученных контекстуализированных векторных представлений дает возможность многоязычной модели mBERT с большим отрывом улучшить качество результатов. Использование специальной модели для русского языка RuBERT позволяет достичь дальнейшего улучшения результатов. Подходы, используемые для анализа тональности на основе BERT, могут быть разделены на две группы: 1) классификация по одному предложению; 2) классификация с использованием вспомогательных предложений, в процессе которой задача анализа тональности преобразуется в задачу классификации пары предложений.

Одним из подходов, основанных на классификации двух предложений, является подход BERT-NLI (natural language inference - вывод по тексту) [18], в котором задача ставится как оценка смысловой близости двух предложений по бинарной шкале (да/нет). На вход такой модели подается два утверждения: одно исходное, а другое вида "Тональность MASK равна ... где на месте троеточия могут стоять слова *позитивная, негативная, нейтральная*. Данная задача рассматривается как классификация на два класса: следует второе предложение из первого или нет. Для обеих применяемых моделей архитектуры BERT такая постановка задачи приводит к улучшению результатов по всем метрикам.

Таблица 1. Исследование подходов машинного обучения на данных тестирования SentiRuEval-2015: тональность сообщений по отношению к мобильным операторам [18]

N	Model	Acc.	$F_1$ macro	$F_1^{+-}$ macro	$F_1^{+-}$ micr
1	SentiRuEval-2015 [6]	–	–	48.80	53.60
2	SVM	62.86	58.29	50.27	54.70
3	CNN	60.80	57.52	49.92	53.23
4	LSTM	64.46	58.94	52.10	56.03
5	BiLSTM	65.54	59.35	53.01	56.83
6	mBERT	72.48	67.04	58.43	62.53
7	RuBERT	76.55	69.12	61.34	66.23
8	mBERT (NLI)	74.66	68.24	59.17	64.13
9	RuBERT(NLI)	76.40	68.83	63.14	67.45
10	RuBERT(NLI)+auto	<b>79.12</b>	<b>71.16</b>	<b>65.71</b>	<b>70.65</b>
11	Manual	–	–	70.30	70.90

## 5. Методы аугментации и автоматической разметки данных в задаче анализа тональности

Размечаемые вручную данные для использования методами машинного обучения всегда ограничены по размеру. В предыдущем разделе было показано, что переход на векторные представления слов и предобучение векторных представлений на больших объемах текстовых данных, позволяют значительно улучшить качество решения задачи анализа тональности. Подходами, которые и дальше могут повышать качество извлечения тональности, являются методы аугментации ручной обучающей коллекции, т.е. размножение исходных размеченных данных с помощью синонимов, перестановок слов и др., а также автоматическая доразметка

(псевдоразметка) дополнительных данных на основе некоторых ресурсов, например, словарей.

Рассмотрим данные подходы на примере работы [19] и их результаты на датасете SentiRuEval-2015. Были предложены следующие методы автоматической разметки обучающей коллекции:

а. В новостном корпусе ищутся положительные (*гений, чемпион, герой*) и отрицательные названия людей (*наглец, мошенник, лжец* и др.) из словаря оценочных слов RuSentiLex [4]. Всего было извлечено 822 негативных названия и 108 позитивных. Предполагается, что контекст такого слова также соответственно положительный или отрицательный, значит соответствующие предложения можно извлечь как позитивные или негативные относительно выделенного слова (так называемая общая коллекция). Например, предложение подается на обучение следующий образом: "MASK - это тот, кто на безвозмездной основе помогает развитию науки и искусства, оказывает им материальную помощь из собственных средств". Поскольку в данном случае замаскировано положительное слово *меценат*, то это предложение считается примером с позитивной тональностью по отношению к сущности MASK.

б. Для более специализированного анализа тональности относительно заданного типа сущностей (например, банков или мобильных операторов) создается дополнительная автоматическая коллекция. В нее включаются предложения, в которых рядом с заданной сущностью находятся только негативные или только позитивные слова из словаря оценочных слов RuSentiLex - так называемая тематическая коллекция, например, "ФАС подозревает MASK в навязывании абонентам платных услуг». Дополнительным условием является отсутствие в предложении отрицаний и других модификаторов тональности.

с. В качестве примеров нейтрального класса использовались предложения, в которых вместе с заданным типом сущностей не найдено известных оценочных слов.

Модель RuBERT была сначала предобучена на общей коллекции, затем на тематической коллекции и затем обучение было продолжено на реальных обучающих данных. Такой подход привел к улучшению результатов классификации сообщений. В Таблице 1 в строке RuBERT(NLI)+auto указаны достигнутые результаты с помощью описанной процедуры для рассматриваемого датасета. Отметим, что в строке Manual приведены результаты разметки тестового множества независимым лингвистом, представленной одним из участников тестирования SentiRuEval-2015. Видно, что результаты метода RuBERT(NLI)+auto практически достигли уровня человеческой разметки по одной из метрик.

## 6. Заключение

В данной работе представлен краткий обзор задач анализа тональности, а также проблем и используемых подходов. В последние годы в задачах анализа тональности активно применяются методы машинного обучения. В статье рассматриваются основные подходы машинного обучения и их особенности. На примере одного из датасетов для русского языка рассмотрен прогресс методов в задаче анализа тональности.

## Благодарности

Данное исследование поддержано грантом РФФИ 20-07-01059.

## References

- [1] Cambria, E., Das, D., Bandyopadhyay, S., Feraco, A., *A practical guide to sentiment analysis*, 2017.
- [2] Liu, B., Zhang, L., “Survey of opinion mining and sentiment analysis”, *Mining text data*, 2012, 415–463.
- [3] Русначенко, Н. Л., “Применение языковых моделей в задаче извлечения оценочных отношений”, *Труды Института системного программирования РАН*, **33**:3 (2021), 199–222.
- [4] Kuznetsova, E., Loukachevitch, N., Chetviorkin, I., “Testing rules for a sentiment analysis system”, *International conference on computational linguistics and intellectual technologies Dialogue-2013*, **2** (2013), 71–80.
- [5] 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.
- [6] Kiritchenko, S., Zhu, X., Mohammad, S., “Sentiment analysis of short informal texts”, *Journal of Artificial Intelligence Research*, **50** (2014), 723–762.
- [7] Loukachevitch, N., Rubtsova, Y., “Entity-oriented sentiment analysis of tweets: results and problems”, *International Conference on Text, Speech, and Dialogue TSD-2015*, 2015, 551–559.
- [8] Kotelnikov, E., Peskischeva, T., Kotelnikova, A., Razova, E., “A comparative study of publicly available Russian sentiment lexicons”, *Conference on Artificial Intelligence and Natural Language AINL-2018*, 2018, 139–151.
- [9] Loukachevitch, N., Dobrov, B., “RuThes linguistic ontology vs. Russian wordnets”, *Proceedings of Global Wordnet conference GWC-2014*, 2014, 154–162.
- [10] Chetviorkin, I., Loukachevitch, N., “Extraction of Russian sentiment lexicon for product meta-domain”, *Proceedings of COLING 2012*, 2012, 593–610.
- [11] Koltsova, O., Alexeeva, S., Kolcov, S., “An opinion word lexicon and a training dataset for Russian sentiment analysis of social media”, *Computational Linguistics and Intellectual Technologies Dialogue-2016.*, 2016, 277–287.
- [12] Loukachevitch, N., Rusnachenko, N., “Sentiment Frames for Attitude Extraction in Russian”, *Proceedings of the International Conference on Computational Linguistics and Intellectual Technologies Dialogue-2020*, 2020.

- [13] Joshi, A., Bhattacharyya, P., Carman, M., “Automatic sarcasm detection: A survey”, *ACM Computing Surveys (CSUR)*, **50**:5 (2017), 1–22.
- [14] 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.
- [15] Zhang, L., Wang, S., Liu, B., “Deep learning for sentiment analysis: A survey”, *Wiley Reviews: Data Mining and Knowledge Discovery*, **8**:4 (2018).
- [16] 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.
- [17] Kuratov, Y., Arkhipov, M., “Adaptation of deep bidirectional multilingual transformers for russian language”, *International Conference on Computational Linguistics and Intellectual Technologies Dialog-2019*, 2019.
- [18] Tikhomirov, M., Loukachevitch, N., Sirotna, A., Dobrov, B., “Using bert and augmentation in named entity recognition for cybersecurity domain”, *International Conference on Applications of Natural Language to Information Systems*, 16–24.
- [19] Golubev, A., Loukachevitch, N., “Improving results on Russian sentiment datasets”, *Conference on Artificial Intelligence and Natural Language AINL-2020*, 2020, 109–121.
- [20] Golubev, A., Loukachevitch, N., “Use of Augmentation and Distant Supervision for Sentiment Analysis in Russian”, *International Conference on Text, Speech, and Dialogue TSD-2021*, 2021, 184–196.

## **Automatic sentiment analysis of texts: problems and methods**

### **Loukachevitch N.V.**

This paper provides a brief overview of the problems of sentiment analysis, as well as the problems and approaches used. In recent years, machine learning methods have been actively used in sentiment analysis problems. The article discusses the main approaches of machine learning and their features. On the example of one of the datasets for the Russian language, the progress of methods in the problem of sentiment analysis is considered.

*Keywords:* sentiment analysis, targeted sentiment analysis, sentiment lexicon, machine learning, neural network, BERT.

## **References**

- [1] Cambria, E., Das, D., Bandyopadhyay, S., Feraco, A., *A practical guide to sentiment analysis*, 2017.
- [2] Liu, B., Zhang, L., “Survey of opinion mining and sentiment analysis”, *Mining text data*, 2012, 415–463.

- [3] Kuznetsova, E., Loukachevitch, N., Chetviorkin, I., “Testing rules for a sentiment analysis system”, *International conference on computational linguistics and intellectual technologies Dialogue-2013*, **2** (2013), 71–80.
- [4] 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.
- [5] Kiritchenko, S., Zhu, X., Mohammad, S., “Sentiment analysis of short informal texts”, *Journal of Artificial Intelligence Research*, **50** (2014), 723–762.
- [6] Loukachevitch, N., Rubtsova, Y., “Entity-oriented sentiment analysis of tweets: results and problems”, *International Conference on Text, Speech, and Dialogue TSD-2015*, 2015, 551–559.
- [7] Kotelnikov, E., Peskischeva, T., Kotelnikova, A., Razova, E., “A comparative study of publicly available Russian sentiment lexicons”, *Conference on Artificial Intelligence and Natural Language AINL-2018*, 2018, 139–151.
- [8] Loukachevitch, N., Dobrov, B., “RuThes linguistic ontology vs. Russian wordnets”, *Proceedings of Global Wordnet conference GWC-2014*, 2014, 154–162.
- [9] Chetviorkin, I., Loukachevitch, N., “Extraction of Russian sentiment lexicon for product meta-domain”, *Proceedings of COLING 2012*, 2012, 593–610.
- [10] Koltsova, O., Alexeeva, S., Kolcov, S., “An opinion word lexicon and a training dataset for Russian sentiment analysis of social media”, *Computational Linguistics and Intellectual Technologies Dialogue-2016.*, 2016, 277–287.
- [11] Loukachevitch, N., Rusnachenko, N., “Sentiment Frames for Attitude Extraction in Russian”, *Proceedings of the International Conference on Computational Linguistics and Intellectual Technologies Dialogue-2020*, 2020.
- [12] Joshi, A., Bhattacharyya, P., Carman, M., “Automatic sarcasm detection: A survey”, *ACM Computing Surveys (CSUR)*, **50:5** (2017), 1–22.
- [13] 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.
- [14] Zhang, L., Wang, S., Liu, B., “Deep learning for sentiment analysis: A survey”, *Wiley Reviews: Data Mining and Knowledge Discovery*, **8:4** (2018).
- [15] 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.
- [16] Kuratov, Y., Arkhipov, M., “Adaptation of deep bidirectional multilingual transformers for russian language”, *International Conference on Computational Linguistics and Intellectual Technologies Dialog-2019*, 2019.
- [17] Tikhomirov, M., Loukachevitch, N., Sirotina, A., Dobrov, B., “Using bert and augmentation in named entity recognition for cybersecurity domain”, *International Conference on Applications of Natural Language to Information Systems*, 16–24.
- [18] Golubev, A., Loukachevitch, N., “Improving results on Russian sentiment datasets”, *Conference on Artificial Intelligence and Natural Language AINL-2020*, 2020, 109–121.
- [19] Golubev, A., Loukachevitch, N., “Use of Augmentation and Distant Supervision for Sentiment Analysis in Russian”, *International Conference on Text, Speech, and Dialogue TSD-2021*, 2021, 184–196.