

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ
«ВЫСШАЯ ШКОЛА ЭКОНОМИКИ»

На правах рукописи

Сметанин Сергей Игоревич

**АНАЛИЗ ТОНАЛЬНОСТИ ТЕКСТОВ ИЗ
СОЦИАЛЬНЫХ СЕТЕЙ НА ОСНОВЕ
МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ
МОНИТОРИНГА ОБЩЕСТВЕННЫХ
НАСТРОЕНИЙ**

РЕЗЮМЕ

диссертации на соискание учёной степени
кандидата компьютерных наук

Москва — 2022

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Национальный исследовательский университет «Высшая школа экономики».

Научный руководитель: **Комаров Михаил Михайлович**, к.т.н., PhD,
Национальный исследовательский университет
«Высшая школа экономики».

Содержание

	Стр.
Введение	4
Содержание работы	10
1 Прикладные исследования по анализу тональности текстов на русском языке	10
2 Трансферное обучение для анализа тональности текстов на русском языке	18
3 Оценка влияния погрешности ошибочной классификации на исследование социальных индикаторов	23
4 Наблюдаемое субъективное благополучие в России, основанное на данных социальной сети «Одноклассники»	30
Заключение	44
Список литературы	45

Введение

В последние годы социальные сети стали одной из основных платформ для обмена информацией, мнениями и настроением [1]. Своевременное понимание настроения населения, также определяемого как субъективное благополучие (SWB), является одной из ключевых задач межправительственных организаций и правительств [2], поскольку позволяет не только повысить скорость обратной связи для политиков [3], но и рассматривается как одно из ключевых направлений¹ для развития государства вместо используемых в настоящее время показателей, таких как валовой внутренний продукт [4]. Хотя опросные методы в настоящее время являются наиболее популярными (и довольно точными [5]) средствами измерения SWB [6] в психологических и социологических исследованиях, они также имеют ряд недостатков. Например, реактивность классического опросного исследования [7]; возможное преувеличение ответов [8]; возможное влияние сиюминутного настроения на ответы [9]; склонность респондентов вспоминать прошлые события, которые согласуются с их текущим влиянием [10]; а также общее влияние различных баесов (напр., эффект порядка вопросов [11], характеристики спроса [12] и эффект социальной желательности [13]). Опросные методы измерения SWB не могут предоставлять заинтересованным сторонам постоянные обновления о SWB, а их проведение связано с относительно высокими затратами, что затрудняет частую оценку SWB во многих странах [7; 14; 15].

Принимая во внимание существенный список ограничений, недавно исследователи из разных дисциплин начали обсуждать несколько инновационных источников цифровых данных, также называемых *цифровыми следами*, и методы, которые могут преодолеть ограничения традиционных опросных методов [7], в частности, для измерения SWB [15]. Согласно определению Howison и др. [16], цифровые следы являются наблюдаемыми (а не создаются для исследований), основанными на событиях (а не являются сводными данными) и лонгитюдными (поскольку события происходят в течение определенного периода времени)

¹В 2011 году Генеральная Ассамблея ООН приняла резолюцию A/RES/65/309, озаглавленную «Happiness: Towards a Holistic Approach to Development». Признавая, что ВВП по своей природе не предназначен для отражения счастья и благополучия отдельных лиц в стране, Генеральная Ассамблея ООН предложила государствам-членам продолжить разработку дополнительных мер, которые могут лучше отразить важность стремления к благополучию и счастью населения в рамках руководства государственной политикой.

данными, которые создаются и сохраняются в информационной системе. Как было подчеркнуто Nemeth и др. [17], эпистемологические преимущества цифровых следов заключаются в том, что они обеспечивают наблюдаемое, а не самоотчетное поведение, которое также характеризуется наблюдением в реальном времени. Поскольку данные цифровых следов распределены по времени, они дают возможность проводить исследования, которые иначе невозможно или, по крайней мере, трудно провести с использованием традиционных подходов, основанных на опросах [7]. Таким образом, цифровые следы, такие как посты в социальных сетях, могут стать полезным источником для получения данных о SWB. Чтобы отличить подходы, основанные на цифровых трассах, от классических подходов, основанных на опросах, далее они будут обозначаться как исследования о **наблюдаемом субъективном благополучии** (OSWB) [18], что явно характеризует источник данных как наблюдаемый (не самоотчетный) и не делает никаких предположений об *оценочном* или *опытном* характере данных² (оба могут быть представлены в разных пропорциях).

В существующей литературе [15; 20–25] исследуются различные варианты индексов OSWB, рассчитанных на основе текстового контента из социальных сетей. Однако одной из основных проблем в существующих исследованиях является отсутствие репрезентативных данных (с точки зрения источника данных, общей совокупности пользователей Интернета или общей численности населения анализируемой страны) и сравнения с индексами, основанными на опросах, для измерения адекватности результатов. В то же время исследования русскоязычного контента (напр., [26–28]) остаются весьма ограниченными и нацеленными на конкретные социальные сети, группы пользователей или регионы, а не на население России в целом. Эти исследования были ориентированы на конкретную группу пользователей или выборку аудитории социальной сети, но не проецировали результаты на население России в целом. Кроме того, недавний опрос [29] Всероссийского центра изучения общественного мнения (ВЦИОМ) показал, что подавляющее большинство (85%) россиян убеждены в необходи-

²Несмотря на то что споры о классификации продолжаются, до сих пор большинство исследований концептуализировали SWB либо как сочетание пережитого аффекта (*опытные* меры благополучия), либо как оценку удовлетворенности или неудовлетворенности жизнью (*оценочные* меры благополучия) [19]. Могут возникнуть вопросы об отнесении SWB на основе цифровых следов либо к *опытным*, либо к *оценочным* мерам, но в рамках данной работы считается, что пока цифровые следы нельзя однозначно отнести ни к *оценочным*, ни к *опытным* мерам, так как они могут содержать как оценочные, так и опытные характеристики одновременно и/или в разных пропорциях, особенно в зависимости от конкретного источника цифровых следов.

мости опросов общественного мнения, и около 42% респондентов утверждают, что опросы просто необходимы. Почти три четверти респондентов (72%) согласны с тем, что опросы общественного мнения помогают определить мнение людей о ситуации в месте их проживания, чтобы власти могли учитывать мнение людей при решении наболевших проблем. Более того, согласно другому недавнему опросу ВЦИОМ [30], благосостояние и благополучие чаще всего назывались респондентами главными целями России в XXI веке. Показатели SWB будут играть все более важную роль в оценке политики и принятии решений [31].

Целью данной работы является разработка моделей, методов и программных комплексов, предназначенных для мониторинга общественных настроений путем анализа тональности текстовых постов из социальных сетей, написанных на русском языке. В рамках данной цели были определены следующие задачи:

1. Проанализировать существующие исследования по анализу тональности русскоязычных текстов.
2. Проанализировать современные методы обработки естественного языка для анализа тональности для русского языка и определить наиболее эффективные с точки зрения качества классификации.
3. Разработать модель и метод оценки влияния ошибки классификации модели классификации тональности на вычисляемые индексы общественных настроений.
4. Разработать модель и метод расчета индексов общественного настроения на основе постов из социальных сетей.
5. Провести экспериментальное исследование предлагаемых моделей, методов и программных комплексов на данных из социальных сетей:
 - (a) собрать данные из социальных сетей;
 - (b) обучить модель классификации тональности;
 - (c) применение предложенных моделей, методов и программных комплексов к собранным данным для расчета индексов общественного настроения;
 - (d) проверить адекватность результатов.

Основные положения, выносимые на защиту.

1. Математическая модель исследования социальных показателей на основе цифровых следов.

2. Метод оценки влияния погрешности ошибочной классификации конкретного алгоритма классификации на вычисляемую формулу индикатора.
3. Математическая модель построения индекса общественных настроений на основе текстовых сообщений, опубликованных в социальных сетях.
4. Метод построения индекса общественных настроений по текстовым постам, опубликованным в социальных сетях, с учетом демографических характеристик пользователей.

Теоретическая и практическая значимость. Предлагаемые модели и методы открывают путь к дальнейшему развитию мониторинга общественных настроений на основе контента из социальных сетей. Предложенные модели и методы позволяют заинтересованным сторонам (напр., межправительственным организациям и правительствам) измерять общественные настроения не только автоматически, но и за прошлые периоды времени и снижать затраты на построение таких исследований, что особенно актуально в период глобальной пандемии. Для анализа настроений были выявлены наиболее эффективные подходы с точки зрения качества классификации русскоязычных текстов. Для решения проблемы отсутствия 100% точности классификационных алгоритмов была предложена новая модель и метод моделирования, позволяющий оценить влияние погрешности ошибочной классификации на вычисляемые индексы общественного настроения. Для расчета индексов настроений предложили новую математическую модель и метод расчета индикатора настроений на основе цифровых следов, учитывающий демографические характеристики пользователей и призванный сделать данную выборку пользователей репрезентативной по отношению к более широкой аудитории в плане отдельных социально-демографических характеристик. Наконец, предложенные модели и методы были применены к данным социальной сети «Одноклассники» и был рассчитан индекс общественного настроения на основе текстовых постов. Полученный индекс продемонстрировал высокую корреляцию с традиционным опросным Индексом счастья ВЦИОМ, что подтверждает адекватность предложенных моделей и методов.

Апробация работы. Основные результаты по теме диссертации были представлены и обсуждены на следующих научных конференциях и семинарах:

1. XX April International Academic Conference on Economic and Social Development, 9-12 апреля 2019. "Development of a Classifier for Analyzing the Sentiment of Russian-language Products Reviews from Online Stores".
2. IEEE 21st Conference on Business Informatics (CBI), 15-17 июля 2019. Topic: "Sentiment Analysis of Product Reviews in Russian using Convolutional Neural Networks".
3. International Conference on Computational Linguistics and Intellectual Technologies "Dialogue 2020", июнь 17-20, 2020. Topic: "Toxic Comments Detection in Russian".
4. IEEE 23rd Conference on Business Informatics (CBI), 1-3 сентября 2021. Topic: "Share of Toxic Comments among Different Topics: The Case of Russian Social Networks".
5. 6th International Research Workshop on Big Data at 2021 International Conference on Information Systems (ICIS), 12 декабря 2021. Topic: "Public Mood Monitoring Based on Social Media Content".

Личный вклад в положения, выносимые на защиту. Первая работа выполнена единолично автором диссертации. Во второй и третьей работах автор предложил ключевые научные идеи, реализовал модели и методы, провел сбор данных, провел все эксперименты, проанализировал и интерпретировал результаты, написал текст; соавтор помогал с экспертизой предметной области. Четвертая работа выполнена единолично автором диссертации.

Публикации повышенного уровня. Основные результаты по теме диссертации были представлены в 4 статьях, опубликованных в научных журналах первого уровня:

1. **Smetanin S.** The Applications of Sentiment Analysis for Russian Language Texts: Current Challenges and Future Perspectives // IEEE Access. 2020. Vol. 8. P. 110693-110719.
2. **Smetanin S., Komarov M.** Deep transfer learning baselines for sentiment analysis in Russian // Information Processing and Management. 2021. Vol. 58. No. 3. Article 102484.
3. **Smetanin S., Komarov M.** Misclassification Bias in Computational Social Science: A Simulation Approach for Assessing the Impact of Classification Errors on Social Indicators Research // IEEE Access. 2022. Vol. 10. P. 18886-18898.

4. **Smetanin S.** Pulse of the Nation: Observable Subjective Well-Being in Russia Inferred from Social Network Odnoklassniki // Mathematics. 2022. Vol. 10. No. 16. Article 2947.

Объем и структура работы. Диссертация состоит из введения, содержимого работы и заключения. Общий объем диссертации составляет 61 страница с 4 рисунками, 3 таблицами и 144 ссылками.

Содержание работы

1 Прикладные исследования по анализу тональности текстов на русском языке

Анализ тональности — это область обработки естественного языка, целью которой является выявление настроений, выраженных в определенном типе пользовательского контента, чаще всего в текстовом контенте. Анализ тональности, выраженной в текстовых коллекциях, позволяет исследователям решать широкий круг проблем, к примеру, прогнозирование фондового рынка [32] и результатов выборов [33], измерение реакции на определенные события или новости [34] и определение отношения к определенной группе населения [35].

В то время как прикладные исследования по анализу тональности англоязычного контента получили широкое распространение [36—38], неанглоязычному контенту, и особенно контенту на русском языке, пока уделялось гораздо меньше внимания со стороны исследователей. До сих пор только одно обзорное исследование [39] всесторонне рассматривало проблему анализа тональности русскоязычного контента³ и несколько других исследований [45—48] упоминало анализ тональности русскоязычного контента в контексте общего сравнения с глобально существующими подходами. Однако эти исследования были в основном сосредоточены на подходах к анализу настроений и качестве их классификации, а не на их приложениях и прикладном анализе данных. Таким образом, подтверждая пробел в знаниях, были всесторонне рассмотрены прикладные исследования по анализу тональности русскоязычного контента и определены основные текущие проблемы и ключевые направления дальнейших исследований. Для этого был выполнен поиск литературы в научных базах данных (см. полную методологию в [49] (опубликованная статья)), которые охватывают ведущие журналы и конференции по компьютерным наукам, и использован следующий поисковый запрос: (("SENTIMENT "OR "POLARITY") AND ("ANALYSIS"OR "DETECTION"OR "CLASSIFICATION"OR "OPINION MINING"OR "TOPIC MODELING") AND ("RUSSIAN"or "RUSSIA")). В полу-

³Некоторые другие исследования были посвящены различным аспектам анализа тональности контента на русском языке (напр., [40—44]), но не рассматривали анализ тональности в целом.

ченной 4041 потенциально релевантной публикации были проанализированы названия, ключевые слова и аннотации. В результате была сужена выборка литературы и получены 32 публикации, в которых описан как минимум один прикладной подход к анализу тональности для русскоязычного контента.

Были всесторонне рассмотрены выбранные исследования и далее классифицированы по используемому источнику данных⁴ на пять категорий: *пользовательский контент из социальных сетей, отзывы на товары и услуги, новости из СМИ, книги и смешанные источники данных*. *Пользовательский контент из социальных сетей* (UGC_{SN}) был наиболее распространенным источником данных, который в основном использовался для исследований по трем направлениям: отношение к разным темам [35; 50–64], индексы общественного настроения [26; 27] и поведение пользователей [65; 66]. Отношение к различным темам изучалось с разных сторон, таких как измерение уровня социальной напряженности (напр., [60]), выявление отношения к мигрантам и этническим группам (напр., [35]), изучение выраженных настроений во время украинского кризиса (напр., [58]) и исследование других важных событий (напр., [61]). В исследованиях на UGC_{SN} обычно применялась комбинация анализа тональности и тематического моделирования для извлечения интересующих тем и соответствующих настроений. В то время как UGC_{SN} , как правило, содержат субъективные тексты, ситуация меняется в случае анализа *новостей из СМИ*. Как правило, журналисты стараются избегать суждений с явной пристрастностью, потому что объективность (или, по крайней мере, общепринятая нейтральность) является их философской основой [67]. Следовательно, новостные статьи с меньшей вероятностью содержат аффективную лексику и чаще описывают содержание в объективном ключе. *Новости из СМИ* стали вторым по распространенности источником данных, который изучался в двух направлениях: построение экономических и бизнес-прогнозов на основе тональности новостей (напр., [68]) и анализ тональности, выражаемой в новостных статьях (напр., [69]). В отличие от анализа UGC_{SN} , проблем с доступом к историческим данным у исследователей не возникало, поскольку платформы средств массовой информации обычно не имеют ограничений на доступ ко всем опубликованным данным. *Отзывы о продуктах и услугах* были следующим наиболее распространенным источником данных, который анализировался с точки зрения характеристик авторов

⁴В зависимости от используемого источника данных исследования обычно имеют схожие цели, проблемы и ограничения.

отзывов (напр., [66]), характеристик продуктов и услуг (напр., [70]) и характеристики продавцов (напр., [71]). Подобно исследованиям новостей, исследования обзоров не имели проблем с доступом к историческим данным. Кроме того, в этих исследованиях можно было автоматически создавать обучающие наборы данных, используя рейтинг отзывов в качестве меток классов. *Книги* как источник данных появились только в 2019 году и до сих пор привлекали меньше внимания ученых, чем упомянутые ранее источники данных. Эти исследования были сосредоточены на влиянии настроений, выраженных в тексте учебников, на образовательном процессе (напр., [72]) и сравнении настроений, выраженных в разных учебниках (напр., [73]). Одна из основных проблем для этой группы исследований заключается в отсутствии тональных словарей и обучающих наборов данных в области текстов из учебников. Более того, учитывая, что тексты в книгах намного длиннее, чем тексты в UGC_{SN}, отзывах и новостях, и что в текстах учебников авторы могут выражать разные эмоции, исследователям было проблематично определить доминирующее настроение. Чтобы охватить более широкий спектр настроений, в некоторых исследованиях использовались *смешанные источники данных*, где наиболее распространенными вариантами использования было определение отношения к различным темам (напр., [74; 75]). Поскольку в этих исследованиях использовалась комбинация ранее упомянутых источников данных, этот тип данных можно использовать во всех упомянутых направлениях исследований. Однако, как обратная сторона медали, авторы также получили все проблемы и ограничения, связанные с комбинируемыми источниками данных.

Обзор прикладных исследований по анализу тональности русскоязычного контента можно найти в таблице 1. Как видно из распределения по годам, количество исследований русскоязычного контента увеличивалось в 2014-2016 годах и достигло максимального значения в 2017 году. Доля подходов на основе правил (40,63%) и подходов на основе машинного обучения (37,5%) практически равны, с небольшим преобладанием первых. Кроме того, в 15,6% выявленных исследований использовались сторонние сервисы для анализа тональности (напр., Medialogia, IQBuzz и Crimson Hexagon), поэтому не было возможности определить конкретные используемые модели классификации. Среди подходов, основанных на правилах, наиболее распространенным выбором были авторские модели на основе правил и SentiStrength [80]. Среди подходов, основанных на

Таблица 1 — Прикладные исследования по анализу тональности русскоязычного контента.

Категория	Тема	Цель	Статья	Подход	Уровень
Пользовательский контент из социальных сетей	Отношение к темам	Выявление отношения к этническим группам и мигрантам	[50]	ML (Logit)	DL
			[51]	ML (Logit)	DL
			[53]	ML (Logit)	DL
			[54]	RB (SentiStrength)	DL
			[35]	ML (SVM)	DL
		Выявление настроений во время украинского кризиса	[52]	RB (авторский)	DL
			[55]	RB (POLYARNIK)	DL
			[56]	RB (SentiMental)	DL
			[57]	UNK (IQBuzz)	DL
			[58]	RB (авторский)	DL
		Измерение уровня социальной напряженности	[59]	ML (SVM)	DL
			[60]	RB (SentiStrength)	DL
	Изучение реакции на метеорит в Челябинске	[61]	n/s	DL	
	Измерение реакции на Олимпиаду 2014 в Сочи	[62]	RB (SentiStrength)	DL	
	Изучение массовых протестов в России в период с 2011 по 2012 год	[63]	RB (SentiStrength)	DL	
Распределение эмоций в Санкт-Петербурге	[64]	ML (NBC)	DL		
Общественное настроение	Построение индекса субъективного благополучия	[26]	RB (авторский)	WL, DL	
		[27]	ML (GBM)	DL	
Поведение пользователей	Измерение влияния настроений на механизмы обратной связи с аудиторией	[65]	ML (BiGRU)	DL	
Отзывы на товары и услуги	Характеристики авторов	Выявление причин ухода сотрудников из российских компаний	[66]	n/s	DL
	Характеристики товаров и услуг	Оценочная оценка дорожного покрытия Северо-Западного федерального округа России	[70]	ML (NB, SGD)	DL
	Характеристики продавцов	Определение качества продукции продавцов	[71]	ML (RNTN)	DL
Новости из СМИ	Содержание новостей	Выявление актуальных тем и тональности новостей в СМИ	[76]	RB (авторский)	DL
			[77]	RB (авторский)	DL
		Изучение настроения в отношении технологий и инноваций, упоминаемых в СМИ	[78]	RB (авторский)	DL
	Сравнение онлайн-дискуссий о российских политиках	[69]	UNK (Medialogia)	DL	
Экономические и бизнес-прогнозы	Построение высокочастотного индикатора экономической активности в России	[68]	ML (SVM)	DL	
Книги	Содержание книг	Сравнение настроений, выраженных в российских учебниках по обществознанию и истории	[73]	RB (авторский)	WL
	Образовательный процесс	Измерение корреляции между настроением учебных текстов, субъективной оценкой иностранных студентов и реальным успехом образовательного процесса.	[72]	ML (n/s)	DL
Смешанные источники данных	Отношение к темам	Выявление настроений во время украинского кризиса	[79]	UNK (Crimson Hexagon)	DL
			[74]	UNK (Crimson Hexagon)	DL
		Анализ интенсивности и настроения медийного освещения политического деятеля	[75]	UNK (Medialogia)	DL

RB – подход на основе правил n/s – не указано SGB – Stochastic Gradient Descent Logit – Logistic Regression
 ML – подход на основе машинного обучения NB – Naive Bayes RNTN – Recursive Neural Tensor Network DC – уровень документа
 UNK – неизвестный подход MNB – Bidirectional Gated Recurrent Units SVM – Support Vector Machine WC – уровень слов

машинном обучении, наиболее часто используемыми вариантами были Support Vector Machine, Logistic Regression и Naive Bayes. Основное внимание уделялось базовым подходам к машинному обучению, а нейронные сети применялись только в 16,7% от всех подходов, основанных на машинном обучении. До 2018 года доля подходов на основе правил была выше или на том же уровне, что и доля подходов на основе машинного обучения, но с 2019 года доля подходов, основанных на машинном обучении, значительно превысила долю подходов, основанных на правилах.

На основе анализа выбранных исследований были определены следующие основные проблемы, с которыми чаще всего сталкиваются исследователи:

1. **Доступ к репрезентативным историческим данным.** В то время как исторические данные, такие как посты или твиты, собранные через API или парсинг, являются наиболее распространенным источником данных, обычно поставщики API предоставляют только частичный доступ ко всем общедоступным данным, которые могут не отражать полную аудиторию анализируемой платформы.
2. **Доступ к размеченным данным из целевого домена.** Только ограниченное количество исследований сделало свои наборы данных общедоступными, поэтому найти подходящий набор обучающих данных для конкретной области является актуальной проблемой. Если ни один из существующих наборов данных не подходит для целевой области исследования, исследователям приходится вручную разметить обучающий набор данных. Учитывая, что ручное аннотирование может быть ресурсоемким и трудоемким, в некоторых исследованиях использовались сторонние решения для анализа настроений без проверки качества классификации в целевом домене, и, как следствие, было сложно проверить точность их результатов. Данная проблема дополнительно усугубляется тем, что в академической литературе еще нет обзорных статей, посвященных существующим наборам данных для анализа тональности русского языка. Был проведен дополнительный анализ литературы, в результате которого было найдено 14 наборов данных для анализа тональности текстов на русском языке, которые могут быть использованы в прикладных исследованиях (см. [49] (опубликованная статья)).

3. **Извлечение тем из текстов.** Тематическое моделирование было наиболее распространенным решением для извлечения тем из текстов. Однако в случае, когда доля текстов, относящихся к целевым темам, значительно ниже 1%, тематическое моделирование, как правило, не справляется с извлечением тем [81]. Более того, тематическое моделирование демонстрирует низкую точность при анализе коротких текстов, особенно если тексты представляют собой повседневную беседу [81]. Таким образом, необходимо разработать более точные и нечувствительные к шуму подходы для извлечения тем разговора из текстов.
4. **Адекватность результатов исследования.** До сих пор ведутся серьезные споры относительно адекватности измерения реакций и настроений с помощью автоматического анализа онлайн-контента. В то время как в некоторых исследованиях [82; 83] отмечалось, что подходы на основе социальных сетей менее точны, чем традиционные опросы, другие исследования [84] констатировали более высокую эффективность автоматического анализа по сравнению с традиционными методами. Таким образом, настоятельно рекомендуется подтвердить результаты исследования результатами, полученными другим методологическим подходом, если это возможно.
5. **Полнота описываемых ограничений исследования.** Значительная часть проанализированных исследований страдает от неполного списка упомянутых ограничений. Чтобы охватить широкий спектр ограничений исследования, в дополнение к техническим и методологическим ограничениям используемого подхода, настоятельно рекомендуется указать следующие ограничения: уровень проникновения Интернета (определенные группы людей могут не учитываться в исследовании), репрезентативность аудитории источника данных (аудитория конкретной платформы может быть не репрезентативна относительно населения страны), уровень свободы СМИ и интернет-цензуры (распространение определенного вида контента может быть ограничено как политикой платформы, так и законодательно).

Также были определены следующие направления дальнейших исследований.

- 1. Трансферное обучение языковых моделей для анализа тональности.** В большинстве проанализированных работ применялись подходы на основе правил и базовые подходы к машинному обучению, и только в нескольких исследованиях [65; 71] использовались нейронные сети. Однако недавние исследования показали, что трансферное обучение предварительно обученных языковых моделей доказало свою эффективность в задаче классификации тональности, уверенно достигая хороших результатов (напр., [85–87]). Таким образом, использование трансферного обучения языковых моделей потенциально способно значительно повысить качество классификации тональности русскоязычных текстов и, следовательно, повысить точность результатов прикладных исследований.
- 2. Автоматический анализ контента как альтернатива традиционным опросам.** В настоящее время результаты автоматического анализа текстов не получается рассматривать как полноценную альтернативу классическим подходам к измерению настроений на основе массовых опросов из-за отсутствия достаточной методологической базы [88]. В частности, актуален вопрос о репрезентативности анализируемого источника данных по отношению к стране или региону, на уровне которого необходимо сделать выводы. Чтобы преодолеть это препятствие, необходимо разработать теоретическую основу для обобщения данных онлайн-пользователей на более полные группы населения [89]. Традиционный массовый опрос предполагает привязку настроений к социально демографическим группам, тогда как в данных из социальных сетей эта достоверная демографическая информация обычно отсутствует. Чтобы сравнить полученные результаты с традиционными опросами общественного мнения, исследователи могут использовать информацию о геолокации, информацию о профилях пользователей, а также системы автоматического определения пола и возраста [90–94].
- 3. Мониторинг индекса общественного настроения на основе русскоязычного контента.** В то время как для многих языков и стран уже были проделаны попытки измерить общественное настроение на основе социальных сетей (напр., [22–24]), исследования русскоязычного контента остаются весьма ограниченными [26; 95]. Данное направление

можно расширять и углублять с точки зрения объема анализируемых данных, качества моделей классификации тональности и методологии расчета индексов, а также проверки адекватности полученных результатов.

4. **Анализ тональности в диалоге.** Контекст продолжающегося диалога может полностью изменить тональность ответа пользователя по сравнению с тональностью без контекста (когда ответ рассматривается как отдельное утверждение) [96]. Как следствие, в случае анализа тональности в диалогах (напр., анализ комментариев к посту) крайне важно учитывать контекст беседы в дополнение к тональности ответа.
5. **«Лайки» и другие реакции на контент как косвенный способ выражения тональности.** Большинство проанализированных исследований измеряли выраженные настроения только через содержание постов. Однако «лайки» и другие реакции на пост потенциально могут рассматриваться пользователями как дополнительный способ выражения настроения. Следовательно, это может быть учтено в результатах мониторинга настроений.
6. **Анализ контента из менее изученных источников данных.** В то время как большинство исследований посвящено ВКонтакте, Twitter, Live Journal и YouTube, существуют и другие широко распространенные локальные социальные сети, которые имеют высокий потенциал в качестве источников данных, такие как Одноклассники, Мой Мир@Mail.Ru и RuTube. К примеру, Одноклассники широко распространены среди старшей аудитории 35+ лет, поэтому могут быть полезной площадкой для анализа мнений старшего поколения. Кроме того, доступ к репрезентативным историческим данным из Одноклассников можно запросить напрямую через OK Data Science Lab, эксклюзивную платформу, разработанную Одноклассниками для исследовательских целей.

Таким образом, были изучены существующие приложения анализа тональности для русскоязычного контента. Были определены пять категорий исследований на основе использованных источников данных, а также дополнительно обобщены и систематически охарактеризованы существующие выявленные исследования по их целям, используемому подходу анализа тональности, а также

Датасет	Классы	Средняя длина	Максимальная длина	Обучающие тексты	Тестовые тексты	Всего текстов
SentiRuEval-2016 [42]	3	87.09	172	18,03	5,560	23,595
SentiRuEval-2015 Subtask 2 [41]	3	81.49	172	8,58	7,738	16,318
RuTweetCorp [97]	3	89.17	189	n/s	n/s	334,836
RuSentiment [98]	5	82.02	800	28,218	2,967	31,185
LINIS Crowd [99]	5	n/s	n/s	n/s	n/s	n/s
Kaggle Russian News Dataset [100]	3	3911.85	381.49	n/s	n/s	8,263
RuReviews [101]	3	130.06	1007	n/s	n/s	90,000

Таблица 2 — Обзор выбранных датасетов.

основным результатам и ограничениям. Наконец, мы представили исследовательскую программу для повышения качества исследований прикладного анализа настроений и расширения существующей исследовательской базы в новых направлениях. С полным текстом статьи можно ознакомиться в [49] (опубликованная статья).

2 Трансферное обучение для анализа тональности текстов на русском языке

Учитывая, что качество результатов прикладных исследований по анализу тональности напрямую связано с качеством методов автоматической классификации тональности, выявление наиболее качественных методов является чрезвычайно актуальным и важным направлением исследований. Перенос знаний в различных задачах обработки естественного языка прошел долгий путь, начиная от использования контекстно независимых эмбедингов из моделей с обучением без учителя [102; 103] и заканчивая текущим прямым использованием предварительно обученных трансформерных блоков [86; 104] с дополнительным выходным слоем для тонкой настройки под конкретную задачу. Недавние исследования показали, что трансферное обучение предварительно обученных языковых моделей доказало свою эффективность в задаче классификации настроений, уверенно достигая хороших результатов [105]. Однако до сих пор лишь ограниченное количество исследований [106; 107] было посвящено трансферному обучению предварительно обученных языковых моделей при анализе тональности русскоязычных текстов.

Чтобы получить более глубокое представление о качестве классификации языковых моделей на русскоязычных текстах, были найдены языковые модели, которые поддерживают русский язык, и был проведен эксперимент по трансферному обучению на русскоязычных датасетах для анализа тональности. Среди доступных языковых моделей были выбраны для проведения эксперимента многоязычная версия Bidirectional Encoder Representations from Transformers (M-BERT) [86], RuBERT [106] и Multilingual Universal Sentence Encoder (M-USE) [104]. Решение было принято исходя из следующих факторов: M-BERT, RuBERT и M-USE являются единственными среди наиболее новых языковых моделей, которые официально поддерживают русский язык. M-BERT уже получила широкое признание среди исследователей, занимающихся контент-анализом неанглоязычных языков, поэтому оценка этой языковой модели в контексте анализа настроений в русском языке стала приоритетной задачей. RuBERT — это русскоязычная версия M-BERT, которая уже показала хорошие результаты классификации на RuSentiment [98], поэтому было принято решение оценить ее и на других наборах данных. По сравнению с M-BERT, M-USE привлекла к себе чуть меньше внимания исследователей. Однако, основываясь на метриках классификации, представленных в оригинальной статье, было сделано предположение, что эта языковая модель также обладает значительным потенциалом для анализа тональности русскоязычного контента.

На основе ранее определенного списка из 14 наборов данных о настроениях русскоязычных текстов (см. [49] (опубликованная статья)) были выбраны только те наборы данных, к которым применимы общие методы анализа настроений (т.е. датасеты для аспектного анализа тональности были исключены). После этого путем поиска в наукометрических базах данных было подсчитано количество цитирований для каждого набора данных (эти значения считались прокси-мерой исследовательского интереса), и были отобраны для дальнейшего анализа только те наборы данных, которые имели хотя бы одно цитирование. Следуя этой стратегии, было выбрано семь наборов данных (см. таблицу 2) для дальнейшего обучения моделей.

1. **SentiRuEval-2016** [42] — датасет из твитов о телекоммуникационных компаниях и банках, который использовался при оценке российских систем анализа настроений в 2016 году.

Датасет	Метрика	Текущий SOTA	M-BERT-*	RuBERT-*	M-USE-CNN-*	M-USE-Trans-*
SentiRuEval-2016 TC [42]	F_1	68.42	66.29	70.68	63.64	68.27
	macro F_1^{PN}	66.07	61.78	66.40	58.97	62.77
	micro F_1^{PN}	74.11	72.45	76.71	71.31	75.00
SentiRuEval-2016 Banks [42]	F_1	74.06	65.31	72.83	66.71	72.40
	macro F_1^{PN}	69.53	58.00	65.89	58.73	65.04
	micro F_1^{PN}	71.76	60.52	68.43	62.41	68.21
SentiRuEval-2015 TC [41]	F_1	68.54	60.47	64.39	60.57	64.28
	macro F_1^{PN}	63.47	53.16	57.76	52.37	57.60
	micro F_1^{PN}	67.51	57.03	61.38	57.76	61.18
SentiRuEval-2015 Banks [41]	F_1	79.51	67.65	70.58	66.32	69.62
	macro F_1^{PN}	67.44	56.97	60.95	54.74	59.12
	micro F_1^{PN}	70.09	59.32	63.33	57.61	62.17
RuSentiment [98]	F_1	n/s	71.37	72.03	66.27	68.60
	weighted F_1	78.50	75.13	75.71	71.05	73.42
Kaggle Russian News Dataset [100]	F_1	70.00	71.36	73.63	71.27	72.66
LINIS Crowd [99]	F_1	37.29	42.73	60.51	56.34	56.95
RuTweetCorp Trinary [97]	F_1	75.95	83.04	83.69	81.34	83.17
RuTweetCorp Binary [97]	F_1	78.1	80.10	80.79	78.39	79.69
RuReviews [101]	F_1	75.45	77.31	77.44	76.63	76.94

Таблица 3 — Метрики классификации тонко настроенных моделей.

2. **SentiRuEval-2015 (Tweets)** [41] — это датасет из твитов о телекоммуникационных компаниях и банках, который использовался при оценке российских систем анализа настроений в 2015 году.
3. **RuTweetCorp** [97] — это датасет из твитов общего домена, которые были размечены автоматически.
4. **RuSentiment** [98] — это датасет из общедоменных сообщений из крупнейшей российской социальной сети ВКонтакте.
5. **LINIS Crowd** [99] — это датасет из социальных и политических постов, опубликованных в блогах.
6. **Kaggle Russian News Dataset** [100] — это датасет из новостей, анонимно опубликованный на Kaggle.
7. **RuReviews** [101] — это датасет онлайн-отзывов на товары из категории «Женская одежда и аксессуары», опубликованных на одном из основных сайтов электронной коммерции в России.

Кроме того, для каждого выбранного набора данных были определены исследования с описанием подхода к анализу тональности (SOTA), который на данный момент показал самые высокие результаты с точки зрения качества классификации (см. таблицу 3).

На этапе тонкой настройки поверх предварительно обученных блоков языковой модели был добавлен softmax слой для классификации, который отвечает за предсказание окончательной вероятности меток классов c :

$$p(c|h) = \text{softmax}(Wh), \quad (1)$$

где W — матрица параметров добавленного softmax слоя для конкретной задачи классификации. На этапе обучения обучались как параметры предварительно обученной языковой модели, так и W , максимизируя логарифмическую вероятность правильной метки класса (список гиперпараметров может быть найден в [108] (опубликованная статья)). В большинстве случаев тонко настроенная модель RuBERT продемонстрировала более высокое качество классификации по сравнению с другими тонко настроенными языковыми моделями. Ближайшие метрики показала модель M-USE_{Trans}, которая часто достигала почти таких же результатов, как и RuBERT. M-USE_{Trans} всегда показывала более высокие значения метрик классификации, чем M-USE_{CNN}. В нескольких случаях нам не удалось превзойти текущие результаты SOTA. Первый случай — это модель ELMo [107], обученная на RuSentiment, которая технически также является языковой моделью. Вторым случаем — sentence-pair BERT [109], обученная на наборах данных SentiRuEval-2016 Banks, SentiRuEval-2015 TC и SentiRuEval-2015 Banks, которая также является языковой моделью. Таким образом, с учетом полученных результатов можно констатировать, что в контексте существующих подходов анализ тональности русскоязычных текстов на основе языковых моделей превосходит по качеству классификации подходы, основанные на правилах и базовом машинном обучении.

Согласно матрицам ошибок, представленным на рисунке 1, наиболее распространенными ошибками классификации были классификация нейтральных текстов как отрицательных или положительных и классификация отрицательных текстов как нейтральных. Примеры таких ошибочных классификаций можно найти в [108] (опубликованная статья). Нейтральное настроение логически расположено между негативным и позитивным настроением, поэтому вполне ожидаемо, что оно может быть неправильно классифицировано как одно из них. Более того, эта проблема выглядит как общий вызов небинарной классификации настроений. Например, Barnes и др. [110] также указывали, что наиболее распространенные ошибки происходят из классов без настроений (т.е. нейтрального класса в данном исследовании). Единственным исключением был автоматически аннотированный RuTweetCorp, который использовал твиты из новостных аккаунтов в качестве источника данных с нейтральным настроением и как следствие, нейтральные новостные твиты были легко отделимы от твитов, содержащих какую-либо эмоцию. В случае многоклассовой классифи-



Рисунок 1 — Матрицы ошибок.

кации на RuSentiment речевые акты были четко отделены от других классов. Как и ожидалось, смешанный класс был одним из самых трудно определяемых, поскольку он изначально содержал трудно интерпретируемые тексты.

Таким образом, был проведен эксперимент по трансферному обучению на нескольких наборах данных анализа тональности для русского языка. Было показано, что в контексте существующих подходов анализ тональности русскоязычных текстов на основе языковых моделей показывает более высокие результаты классификации, чем подходы, основанные на правилах и базовом машинном обучении.

3 Оценка влияния погрешности ошибочной классификации на исследование социальных индикаторов

В контексте измерения общественных настроений на основе классификации тональности постов в социальных сетях весь процесс определения тональности делегирован определенному алгоритму, который может ошибаться. Пока результаты алгоритмов классификации не полностью безошибочны, на оценку относительной распространенности определенного класса может влиять погрешность ошибочной классификации [111–113], тем самым влияя на значение вычисляемого социального индикатора (напр., индекс общественного настроения) [114]. Даже оптимальная классификация отдельных цифровых следов может привести к смещенным оценкам пропорций класса цифровых следов и, следовательно, к смещенной оценке социального показателя. Общепринятые критерии успеха классификации, такие как точность и F -мера на тестовом датасете [115], подходят для классификации на индивидуальном уровне, но могут вводить в заблуждение при характеристике популяций документов или динамики внутри популяций [116]. Несмотря на то что в значительном количестве исследований изучались методы нивелирования погрешности ошибочной классификации (напр., [113; 116]), они обычно основываются на наборе допущений, которые могут быть нарушены на практике, что ставит под сомнение эффективность данных методов.

Таким образом, существует пробел в знаниях относительно оценки влияния погрешности ошибочной классификации на конкретную формулу рассчитываемого социального индикатора без строгой привязки к количеству классов. Более того, учитывая уровень ошибок, свойственный алгоритмам автоматической классификации, качество прогнозируемого показателя можно оценивать не только с помощью метрик качества регрессии, как это делается в существующей литературе, но и с помощью корреляционных метрик. Были предложены математическая модель и метод моделирования для оценки влияния ошибочной классификации на расчетные социальные показатели с точки зрения показателей регрессии и корреляции. Предлагаемый подход и метод ориентируются на индикаторы, рассчитываемые на основе распределения классов, могут обрабатывать любое количество классов. Модель и метод основаны на следующих допущениях:

Допущение 3.1. Обучающие данные для модели классификации были размечены вручную с использованием высококачественных гайдлайнов разметки, и аннотаторы продемонстрировали высокий уровень согласованности.

Допущение 3.2. Модель классификации была обучена на обучающих данных, представляющих цифровые следы, доступные для анализа.

Допущение 3.3. Неправильная классификация не зависит от объектов, а вероятность неправильной классификации одинакова для каждого объекта в зависимости от их истинной метки класса.

Формально постановка задачи оценки влияния погрешности ошибочной классификации на рассчитываемые социальные индикаторы может быть сформулирована следующим образом (см. определение 3.1). Даны данные для анализа X , распределенные по временным интервалам TI (см. определение 3.2), обученная модель классификации f_P и ее матрица ошибок на тестовом наборе данных CM (см. определение 3.3), формула расчета индикатора I , формулы для целевой метрики качества qm_i и агрегированной целевой метрики качества aqm_i (см. определение 3.4). Необходимо оценить погрешность классификации AQ_m .

Определение 3.1. *Онлайн-модель социальных данных для исследования социальных показателей* определяется как кортеж $OSDM_{SIR} = (DT, C, I)$, где

- DT — это *Цифровые Следы* (см. определение 3.2), представляющие исходные цифровые следы для анализа,
- C — это *Классификация* (см. определение 3.3), представляющая компоненты машинного обучения и позволяющая отображать цифровые следы в соответствующие классы, представляющие научный интерес,
- I — это *Индикаторы* (см. Определение 3.4), представляющие интересные социальные индикаторы, которые должны быть рассчитаны в рамках конкретного исследования.

Определение 3.2. *Цифровые Следы* онлайн-модели социальных данных для исследования социальных показателей определяется как кортеж $DT = (TI, X, \rightarrow_{interval})$, где

- $TI = \{ti_0, ti_1, \dots, ti_K\}$ — упорядоченный набор $K \in \mathbb{N}$ непересекающихся интервалов времени, таких что $ti_i < ti_{i+1}$,
- $X = \{x_1, x_2, \dots, x_N\}$ — конечное множество $N \in \mathbb{N}$ цифровых следов,
- $\rightarrow_{interval}: TI \rightarrow P_{disj}(X)$ — функция, отображающая временные интервалы во взаимно непересекающиеся непустые подмножества цифровых следов, созданных в этом временном интервале.

Подмножество объектов цифровых следов, созданных во временном интервале ti_i , далее будет обозначаться как X_{ti_i} , т.е. $\rightarrow_{interval}(ti_i) = X_{ti_i}$. Количество элементов в подмножестве X_{ti_i} далее будет обозначаться как $N_{ti_i} \in \mathbb{N}$.

Определение 3.3. *Классификация* онлайн-модели социальных данных для исследования социальных показателей определяется как кортеж $C = (Y, f_T, f_P, CM)$, где

- $Y = \{y_1, y_2, \dots, y_M\}$ — конечное множество $M \in \mathbb{N}$ классов,
- $f_T: X \rightarrow Y$ — истинная функция отображения,
- $f_P: X \rightarrow Y$ — алгоритм, аппроксимирующий функцию отображения f (т. е. модель классификации),
- $CM \in \mathbb{N}_{\neq}^{M \times M}$ — матрица ошибок для алгоритма f_P .

Определение 3.4. *Индикаторы* онлайн-модели социальных данных для исследования социальных показателей определяется как кортеж $I = (TSI, QM, AQM)$, где

- $TSI = \{I_{ti_1}, I_{ti_2}, \dots, I_{ti_K}\} \in \mathbb{R}^K$ — вектор, представляющий индикатор временного ряда, где $I_{ti_i}: Y^{N_{ti_i}} \rightarrow \mathbb{R}$ — индикаторная функция, отобра-

- жающая множество $N_{ti_i} \in \mathbb{N}_K$ классифицированных цифровых следов, созданных в интервале времени ti_i , в значение индикатора,
- $QM = \{qm_1, qm_2, \dots, qm_U\}$ – это множество из U целевых показателей качества, где каждый элемент представляет собой функцию $qm_i : (\mathbb{R}^K \times \mathbb{R}^K) \rightarrow \mathbb{R}^l$, возвращающую вектор $K \in \mathbb{N}_K$ вещественных чисел, и
 - $AQM = \{aqm_1, aqm_2, \dots, aqm_U\}$ представляет множество $U \in \mathbb{N}$ агрегированных целевых показателей качества, где каждый i -й элемент представляет собой функцию агрегирования, подходящую для qm_i и определяется как $aqm_i : (\mathbb{R}^L)^V \rightarrow \mathbb{R}^H$, где $L \in \mathbb{N}$ – число рассчитанных целевых показателей качества, подлежащих агрегированию, и $H \in \mathbb{N}$ – размер вектора, представляющего агрегированную целевую меру качества.

TSI , рассчитанный на основе функции отображения f_T , далее будет обозначаться как TSI_T . TSI , рассчитанный на основе алгоритма f_P , далее будет обозначаться как TSI_P .

В рамках данных обозначений наш подход состоит из трех шагов.

1. Моделировать истинный индикатор TSI_T через симулирование истинной функции отображения f_T .
2. Аппроксимировать предсказанный индикатор TSI_P через аппроксимацию функции отображения алгоритма f_P на основе истинной функции отображения f_T .
3. Рассчитать целевые показатели качества qm_i предсказанного индикатора TSI_P для множества симуляций и далее рассчитать агрегированный целевой показатель качества aqm_i .

Смоделированные данные для каждого временного интервала представляют собой вектор с размерностью, равной количеству классов, и определяется следующим образом:

$$SCD_{ti_i} = (scd_{ti_i, y_1}, scd_{ti_i, y_2}, \dots, scd_{ti_i, y_M}) \in \mathbb{N}_K^M, \sum_{j=1}^M scd_{ti_i, j} = N_{ti_i}. \quad (2)$$

Кроме того, смоделированные данные могут быть представлены в виде временного ряда.

$$STS_{y_i, TI} = (scd_{ti_1, y_i}, scd_{ti_2, y_i}, \dots, scd_{ti_K, y_i}) \in \mathbb{N}_{\neq}^K, \quad (3)$$

где каждый элемент scd_{ti_i, y_j} представляет количество цифровых следов, содержащихся во временном интервале ti_i и помеченных как класс y_j . Поскольку истинный показатель неизвестен, было предложено синтетически генерировать количество объектов каждого класса для каждого анализируемого интервала времени и вычислить истинный показатель TSI_T на основе сгенерированных данных. Учитывая, что распределение в цифровых следах, доступных для анализа, равно распределению классов в обучающем наборе данных, можно ожидать, что смоделированные данные будут удовлетворять следующему условию:

$$\frac{\sum_{j=1}^K scd_{ti_j, y_i}}{\sum_{o=1}^M \sum_{j=1}^K scd_{ti_j, y_o}} = \frac{\sum_{j=1}^M cm_{y_i, y_j}}{\sum_{o=1}^M \sum_{j=1}^M cm_{y_o, y_j}}, \quad (4)$$

где cm_{y_i, y_j} — количество объектов с истинным классом y_i , классифицированных как y_j , как определено далее в уравнении (5). В то же время не предполагается, что распределение классов за указанный интервал времени будет равно распределению классов в обучающем наборе данных.

После определения истинной функции отображения и расчета истинного индикатора необходимо определить алгоритм, аппроксимирующий истинную функцию отображения (т. е. модель классификации) f_P . Для начала нам необходимы оценки вероятностей (неправильной) классификации алгоритма. Следуя [117], было сделано предположение, что ошибочные классификации независимы для разных объектов и что вероятности (ошибочной) классификации одинаковы для каждого объекта в зависимости от их истинной метки класса. Вероятности (ошибочной) классификации для каждого класса оцениваются с помощью матрицы ошибок, нормализованной по истинным классам, которая рассчитывается на основе матрицы ошибок CM . После этого необходимо скорректировать истинное распределение классов SCD_{T, ti_i} с помощью вероятностей (неправильной) классификации, чтобы аппроксимировать распределение предсказанных классов.

Матрица ошибок представлена следующим образом:

$$CM = \begin{pmatrix} cm_{y_1,y_1} & cm_{y_1,y_2} & \cdots & cm_{y_1,y_M} \\ cm_{y_2,y_1} & cm_{y_2,y_2} & \cdots & cm_{y_2,y_M} \\ \vdots & \vdots & \ddots & \vdots \\ cm_{y_M,y_1} & cm_{y_M,y_2} & \cdots & cm_{y_M,y_M} \end{pmatrix} \in \mathbb{N}_{\neq}^{M \times M}, \quad (5)$$

где каждая строка матрицы представляет экземпляры в истинном классе, а каждый столбец представляет экземпляры в предсказанном классе. Звездочка обозначает целые строки или столбцы в матрице. Например, $cm_{i,*}$ относится к i -й строке CM , а $cm_{*,j}$ относится к j -му столбцу CM .

$$cm_{y_i,y_*} = (cm_{y_i,y_1} \quad cm_{y_i,y_2} \quad \cdots \quad cm_{y_i,y_M}). \quad (6)$$

$$cm_{y_*,y_j} = (cm_{y_1,y_j} \quad cm_{y_2,y_j} \quad \cdots \quad cm_{y_M,y_j})^T. \quad (7)$$

Матрица ошибок, нормализованная по истинным классам, рассчитывается следующим образом:

$$CM^{ntc} = \begin{pmatrix} \frac{1}{\sum cm_{y_1,y_*}} & 0 & \cdots & 0 \\ 0 & \frac{1}{\sum cm_{y_2,y_*}} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \frac{1}{\sum cm_{y_M,y_*}} \end{pmatrix} \times CM \quad (8)$$

$$= \begin{pmatrix} cm_{y_1,y_1}^{ntc} & cm_{y_1,y_2}^{ntc} & \cdots & cm_{y_1,y_M}^{ntc} \\ cm_{y_2,y_1}^{ntc} & cm_{y_2,y_2}^{ntc} & \cdots & cm_{y_2,y_M}^{ntc} \\ \vdots & \vdots & \ddots & \vdots \\ cm_{y_M,y_1}^{ntc} & cm_{y_M,y_2}^{ntc} & \cdots & cm_{y_M,y_M}^{ntc} \end{pmatrix} \in \mathbb{R}^{N \times N}$$

Предполагая, что данный алгоритм классификации не имеет смещения в определенный тип ошибок и следует заданной матрице ошибок CM , возможно аппроксимировать ненормализованную матрицу ошибок используемой модели классификации для смоделированных данных следующим образом:

$$\begin{aligned}
CM' &= \begin{pmatrix} scd_{T,t_i,y_1} & 0 & \cdots & 0 \\ 0 & scd_{T,t_i,y_2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & scd_{T,t_i,y_M} \end{pmatrix} \times CM^{ntc} \\
&= \begin{pmatrix} cm'_{1,1} & cm'_{1,2} & \cdots & cm'_{1,M} \\ cm'_{2,1} & cm'_{2,2} & \cdots & cm'_{2,M} \\ \vdots & \vdots & \ddots & \vdots \\ cm'_{M,1} & cm'_{M,2} & \cdots & cm'_{M,M} \end{pmatrix} \in \mathbb{N}_{\neq}^{N \times N}, \\
&\sum_{o=1}^M cm'_{y_j,y_o} = scd_{T,t_i,y_j}
\end{aligned} \tag{9}$$

Смоделированное распределение прогнозируемых классов на основе смоделированного распределения истинных классов SCD_{T,t_i} для заданного временного интервала t_i выглядит следующим образом:

$$\begin{aligned}
SCD_{P,t_i} &= \left(\sum_{j=1}^M cm'_{y_j,y_1}, \sum_{j=1}^M cm'_{y_j,y_2}, \dots, \sum_{j=1}^M cm'_{y_j,y_M} \right) \in \mathbb{N}_{\neq}^M \\
&\sum_{j=1}^M scd_{P,t_i,y_j} = N_{t_i}
\end{aligned} \tag{10}$$

Наконец, можно вычислить $Y^{N_{t_i}}$ (т.е. набор N_{t_i} классифицированных объектов, созданных в интервале времени t_i , в значения индикатора) на основе полученных распределений классов SCD_{T,t_i} и SCD_{P,t_i} для дальнейшего расчета истинного показателя и прогнозируемого показателя соответственно. Поскольку порядок элементов в $Y^{N_{t_i}}$ не важен, можно определить порядок элементов любым способом, следуя распределениям классов. После этого можно вычислить TSI_T , TSI_P и qm_i . Повторяя всю процедуру несколько раз, можно получить несколько qm_i и вычислить aqm_i . Однако, если для таких показателей, как MAE и MSE, методы агрегирования четко определены (напр., это может быть простое среднее значение), то агрегирование корреляции, как правило, является более сложной задачей. Алгоритмы агрегирования показателей кор-

реляции представлены в [118] (опубликованная статья). В зависимости от силы агрегированных показателей корреляции, можно сделать следующие выводы:

- Если CI_{corr} является идеальным, то можно подтвердить, что существует *отсутствие* влияния погрешности ошибочной классификации на рассчитываемый индикатор, что позволяет достичь *идеального уровня* корреляции между прогнозируемым и истинным показателями.
- Если CI_{corr} является сильным, то можно подтвердить, что имеет место *слабое влияние* погрешности ошибочной классификации на рассчитываемый индикатор, что позволяет достичь *сильного уровня корреляции* между прогнозируемыми и истинными показателями.
- Если значение CI_{corr} является умеренным, то можно подтвердить *умеренное влияние* ошибки классификации на расчет индикатора, что позволяет достичь *умеренного уровня корреляции* между прогнозируемыми и истинными показателями.
- Если CI_{corr} слабый, то можно подтвердить *сильное влияние* погрешности ошибочной классификации на рассчитываемый индикатор, что позволяет достичь *слабого уровня корреляции* между прогнозируемыми и истинными показателями.
- Если CI_{corr} отсутствует, то можно подтвердить, что есть *идеальное влияние* погрешности ошибочной классификации на рассчитываемый индикатор, что позволяет добиться *отсутствия корреляции* между прогнозируемыми и истинными показателями.

Наглядные примеры оценки погрешности ошибочной классификации можно найти в [118] (опубликованная статья).

4 Наблюдаемое субъективное благополучие в России, основанное на данных социальной сети «Одноклассники»

Аффективная модель социальных данных для социально-технических взаимодействий (см. определение 4.10) состоит из двух элементов: *Актеры* и *Взаимодействия*. *Актеры* (см. определение 4.11) представляют участников Социально-Технических Взаимодействий (STI) [119], генерирующих цифровые

следы. *Взаимодействия* (см. определение 4.12) представляют структурные аспекты STI и генерируют цифровые следы, представляющие социальный обмен эмоциями (SSE) [120]. За основу формального описания модели взята модель *Онлайн-модель социальных данных для исследования социальных индикаторов*, которая была предложена ранее [118] для анализа влияния погрешности ошибочной классификации на исследование социальных индикаторов. Была применена классическая теория множеств для разработки предложенной модели, так как в недавней литературе [121; 122] был сформулирован ряд ее преимуществ в вычислительных социальных науках.

Определение 4.1. U_{type} — это конечное множество всех типов пользователей, определенных как $U_{type} = \{individual, business\}$, где

- *individual* представляет учетную запись пользователя, которая была создана для личного использования,
- *business* представляет собой учетную запись пользователя, которая была создана для использования в бизнесе.

Важно разграничить типы аккаунтов, так как от них может сильно зависеть цель использования социальной сети и, как следствие, тип контента.

Определение 4.2. AR_{type} — это конечное множество всех типов артефактов, определенных как $AR_{type} = \{post, media, response\}$, где

- *post* представляет собой текстовые и (или) медийные посты или комментарии,
- *reaction* представляет реакции на размещенные артефакты, такие как «лайки» или другие реакции,
- *media* представляет цифровые фотографии, видео и аудиоконтент.

Каждый тип артефакта представляет тип пользовательского контента (UGC). По сути, *post* представляет собой все сообщения на страницах пользователей, происходящие в социальных сетях, за исключением личных сообщений⁵. Другой пользовательский контент, такой как цифровые фотографии, видео и аудио, опубликованные в альбомах пользователей, но не опубликованные на страницах пользователей, представлен как *media*. Реакции на *post* и *media*, такие как «лайки» или «дизлайки», представлены как *reaction*.

⁵Данная модель не учитывает личные сообщения, поскольку их не только крайне проблематично получить, но и их анализ может вызвать ряд юридических, конфиденциальных и этических вопросов.

Определение 4.3. SX конечное множество полов, определяемое как $SX = \{male, female\}$ where

- *male* представляет мужской пол,
- *female* представляет женский пол.

Определение 4.4. BD — это набор дат рождения.

Определение 4.5. G — это набор географической информации.

Определение 4.6. MS — это конечное множество семейных положений, определяемое как $MS = \{married, single, divorced, widowed\}$, где

- *married* представляет человека, состоящего в культурно признанном союзе между людьми, называемыми супругами,
- *single* представляет лицо, не состоящее в серьезных отношениях или не состоящее в гражданском союзе,
- *divorced* представляет лицо, которое больше не состоит в браке, поскольку брак был расторгнут,
- *widowed* представляет лицо, чей супруг умер.

Определение 4.7. FT — это набор типов семьи (т. е. классификация семейной ячейки человека), определяемый как $FT = \{nuclear, single - parent, blended, ofchoice\}$, где

- *nuclear* представляет семью, в которую входят только супруги и не состоящие в браке дети, не достигшие совершеннолетия,
- *single - parent* представляет семью из одного родителя⁶ вместе со своими детьми,
- *blended* представляет семью со смешанными родителями⁷,
- *ofchoice* представляет собой группу людей в жизни человека, которая выполняет типичную роль семьи как системы поддержки.

Определение 4.8. $CN \in \mathbb{N}_0$ — это количество детей пользователя.

Определение 4.9. $HS \in \mathbb{N}_0$ — это количество людей, проживающих в домохозяйстве пользователя.

⁶Родитель либо овдовел, либо разведен (и не вступал в повторный брак), либо никогда не был женат.

⁷Один или оба родителя вступили в повторный брак, в результате чего дети из прежней семьи попали в новую семью.

Сочетание пола SX , даты рождения BD , семейного положения MS , типа семьи FT и количества детей CN представляет собой *демографию* населения и вызывает интерес для проведения исследований SWB. [123]. В этой модели не учитываются другие ковариаты (напр., материальные условия, качество жизни, психологические показатели), рекомендуемые для сбора наряду с показателями SWB, поскольку доступ к ним в данных социальных сетей практически отсутствует.

Определение 4.10. *Модель аффективных социальных данных для социально-технических взаимодействий* определяется как кортеж $ASDM_{STI} = \{A, I\}$, где

- A — это *Акторы*, представляющие участников социотехнических взаимодействий, генерирующих пользовательский контент, как определено далее в 4.11,
- I — это *Взаимодействия*, представляющие структурные аспекты и пользовательский контент $ASDM_{STI}$, как определено далее в 4.12.

Как предусмотрено в концептуальной модели и в Def. 4.10, *Модель аффективных социальных данных для социально-технических взаимодействий* ($ASDM_{STI}$) содержит *Акторы* (те, кто действует и взаимодействует) и *Взаимодействия* (что делается).

Определение 4.11. *Акторы* $ASDM_{STI}$ определяется как кортеж $A = (U, U_{type}, SX, BD, MS, FT, CN, HS, G, f_{U_{type}}^U, f_{S?}^U, f_{BD?}^U, f_{MS?}^U, f_{FT?}^U, f_{CN?}^U, f_{HS?}^U, f_{G?}^U)$ где

- U — конечное множество пользователей, ранжированных по u ,
- U_{type} — это конечное множество типов пользователей (см. определение 4.1), ранжированное по u_{type} ,
- SX — это конечное множество полов пользователей (см. определение 4.3), ранжированное по sx ,
- BD — это множество дат рождения пользователей, ранжированное по bd ,
- MS — это множество семейных статусов пользователей (см. определение 4.6), ранжированное по ms ,
- FT — это множество типов семей пользователей (см. определение 4.7), ранжированное по ft ,

- CN — количество детей пользователей (см. определение 4.8), ранжированное по cn ,
- HS представляет собой множество количества людей, проживающих в домохозяйствах пользователей (см. определение 4.9) в диапазоне hs ,
- G — это множество географической информации о пользователях (см. определение 4.5), ранжированное по g ,
- $f_{U_{type}}^U : U \rightarrow U_{type}$ — это функция типа пользователя, сопоставляющая каждого пользователя с типом пользователя,
- $f_{S?}^U : U \rightarrow S$ — функция пола, отображающая каждого пользователя в его пол, если он определен,
- $f_{BD?}^U : U \rightarrow BD$ — это функция даты рождения, которая сопоставляет каждого пользователя с его датой рождения, если она определена,
- $f_{MS?}^U : U \rightarrow MS$ — это функция семейного положения, отображающая каждого пользователя в семейное положение пользователя, если оно определено,
- $f_{FT?}^U : U \rightarrow FT$ — это функция типа семьи, отображающая каждого пользователя в тип семьи пользователя, если он определен,
- $f_{CN?}^U : U \rightarrow CN$ — функция количества дочерних элементов, отображающая каждого пользователя на количество детей пользователя, если оно определено,
- $f_{HS?}^U : U \rightarrow HS$ — это функция размера домохозяйства, отображающая каждого пользователя в размер домохозяйства пользователя, если он определен,
- $f_{G?}^U : U \rightarrow G$ — функция географической информации, отображающая каждого пользователя в географическую информацию пользователя, если она определена.

Формальное определение Акторов представлено в определении 4.11. Первые два элемента содержат множество пользователей (U) и множество типов пользователей (U_{type}) соответственно. Следующие шесть элементов содержат демографическую информацию, включая пол (SX), дату рождения (BD), семейное положение (MS), тип семьи (FT), количество детей (CN), количество людей, проживающих в домохозяйстве (HS), и географическую информацию (G). Остальные элементы представляют собой сопоставление функций пользо-

вателя с типом пользователя и всеми упомянутыми демографическими характеристиками, если они определены.

Определение 4.12. Взаимодействия $ASDM_{STI}$ определяются как кортеж $I = (AR, AR_{type}, S, f_{U_{feed}}^{AR}, f_{U_{author}}^{AR}, f_{AR_{type}}^{AR}, f_{AR}^{AR}, f_S^{AR}, track_T^{U,AR}, age_{AR}^U : track_T^{U,AR}, \rightarrow_{post}, \rightarrow_{react})$, где

- AR — это конечное множество артефактов, ранжированных по ar ,
- AR_{type} — это конечное множество типов артефактов (см. определение 4.2), ранжированных по ar_{type} ,
- S — это конечное множество классов настроек, ранжированных по s ,
- $f_{U_{feed}}^{AR} : AR \rightarrow U$ — это функция, отображающая артефакт в пользователя, в чьей ленте он был опубликован,
- $f_U^{AR} : AR \rightarrow U$ — это функция, отображающая артефакт в пользователя, который его создал,
- $f_{AR_{type}}^{AR} : AR \rightarrow AR_{type}$ — это функция типа артефакта, отображающая артефакт в тип артефакта,
- $f_{AR}^{AR} : AR \rightarrow AR$ — функция родительского артефакта, которая отображает артефакт в их родительский артефакт, если они определен,
- $f_S^{AR} : AR \rightarrow S$ — функция, отображающая артефакт в соответствующий ему класс тональности,
- $track_T^{U,AR} : (U \times AR) \rightarrow N$ — функция времени, которая отслеживает отметку времени артефакта, созданного пользователем.
- $age_{AR}^U : track_T^{U,AR} \times f_{BD}^U \rightarrow N?$ — функция времени, которая возвращает возраст пользователя на момент создания артефакта, если день рождения пользователя определен,
- $\rightarrow_{post} : U \rightarrow P_{disj}(AR)$ — функция, отображающая пользователей во взаимно непересекающиеся наборы их артефактов,
- $\rightarrow_{react} : U \rightarrow P(AR)$ — функция, отображающая пользователей в артефакты, на которые они отреагировали.

Как видно из определения $ASDM_{STI}$, S представляет собой конечный набор классов тональности, а f_S^{AR} представляет сопоставление между артефактом и тональностью. С точки зрения классификации тональности, S — это набор классов в обучающем датасете для анализа тональности, а f_S^{AR} — это функция, которая запускает модель классификации тональности и возвращает тональность артефакта.

Подход к расчету показателей OSWB состоит из трех шагов:

1. Выбор интересующего контента для анализа, то есть текстовые посты, публикуемые пользователями на собственных страницах.
2. Построение выборки, репрезентативной для целевой совокупности.
3. Расчет выбранных показателей OSWB на основе репрезентативной выборки данных.

Определение 4.13. $TI = \{ti_1, ti_2, \dots, ti_T\}$ — это конечное упорядоченное множество из T непересекающихся временных интервалов, таких как $ti_i < ti_{i+1}$.

Определение 4.14. $\rightarrow_{interval}: (age_{AR}^U : track_T^{U,AR} \rightarrow N?) \rightarrow TI?$ — это сопоставление метки времени создания артефакта с временным интервалом, если определен день рождения пользователя.

Определение 4.15. P — это конечное множество текстовых постов PN , публикуемых пользователями на их собственных страницах, которое рассчитывается следующим образом:

$$P = \{ar | f_{AR_{type}}^{AR}(ar) = post | \forall ar \in AR \wedge f_{U_{feed}}^{AR}(ar) = f_{U_{author}}^{AR}(ar) \wedge f_{UBD?} \neq \emptyset \wedge f_{AR}^{AR}(ar) = \emptyset\} \quad (11)$$

Определение 4.16. P_{ti_i} — конечное множество постов PN_{ti_i} , опубликованных авторами на своих страницах в течение интервала времени ti_i , которое рассчитывается следующим образом:

$$P_{ti_i} = \{p | \forall p \in P \wedge \rightarrow_{interval}(p) = ti_i\}, \sum_{i=1}^T PN_{ti_i} = PN \quad (12)$$

В рамках данной работы было принято решение ориентироваться на собственные сообщения пользователей, размещенные на их страницах, так как предполагалось, что такие сообщения с большей вероятностью будут содержать эмоциональное состояние автора по сравнению с сообщениями в других местах. Также считалось, что страницы пользователей в большинстве случаев не привязаны к определенному тематическому домену, в отличие от страниц групп и сообществ. Следовательно, эти сообщения должны содержать большее количество различных тем и, в среднем, быть источниками данных общего домена.

Определение 4.17. \dot{U}_{ti_i} — конечное множество пользователей, размещавших текстовые сообщения на своих страницах в течение интервала времени ti , которое рассчитывается следующим образом:

$$\dot{U}_{ti_i} = \{f_{U_{author}}^{AR}(p) | \forall p \in P_{ti_i}\} \quad (13)$$

После получения \dot{U}_{ti_i} необходимо проверить, что количество пользователей для каждого временного интервала ti_i не меньше минимального размера выборки n (см. в [18] (опубликованная статья)). В случае если он меньше n хотя бы для одного $ti_i \in TI$, то расчет индекса с выбранным доверительным интервалом и погрешностью невозможен.

Определение 4.18. \dot{DF} — это конечный набор функций демографического отображения DFN с определенными значениями для заданного набора пользователей, который определяется следующим образом.

$$GS = \{f | \forall f \in \{f_{S?}^U, age_{AR}^U, f_{MS?}^U, f_{FT?}^U, f_{CN?}^U, f_{HS?}^U, f_{G?}^U\}, \\ \wedge f(u) \neq \emptyset, \forall u \in U\} \quad (14)$$

Поскольку не все эти характеристики могут быть получены из данных социальных сетей, в соответствии с Руководством по составлению выборки Европейского социального обследования [124], рекомендуется использовать как минимум возрастные и половые характеристики для построения выборки.

Определение 4.19. \ddot{U}_{ti_i} — конечное множество пользователей \dot{U}_{ti_i} , представляющих целевую совокупность путем применения стратификации⁸.

Определение 4.20. \dot{P}_{ti_i} — конечное множество постов, созданных репрезентативной выборкой пользователей \ddot{U}_{ti_i} на их собственных страницах в течение интервала времени ti и определяемое следующим образом:

$$\dot{P}_{ti_i} = \{p | \forall p \in P_{ti_i} \wedge f_{U_{author}}^{AR}(p) \in \ddot{U}_{ti_i}\} \quad (15)$$

⁸Здесь N_{tp} — численность совокупности, n — общий размер выборки, k — количество страт, N_i — количество единиц выборки в i -й страте, например $\sum_1^k N_i = N$, n_i — количество единиц выборки, которые необходимо взять из i -й страты, такой как $\sum_1^k n_i = n$. Страты строятся таким образом, чтобы они были непересекающимися и однородными по изучаемому признаку. Для фиксированного k пропорциональное распределение размера страты можно рассчитать как $n_i = \frac{n}{N} N_i$, где каждый n_i пропорционален размеру страты N_i .

Далее требуется агрегировать настройки пользователей, которые размещали посты несколько раз за рассматриваемые промежутки времени.

Определение 4.21. agg_{u,ti_i} – это функция агрегации тональности, которая агрегирует тональность постов, опубликованных в течение интервала времени ti_i пользователем u , и определяется следующим образом:

$$agg_{u,ti_i} : P \times P \rightarrow S \quad (16)$$

Функция агрегирования может быть определена несколькими способами (напр., голосование большинства).

Определение 4.22. AUS_{ti_i} – это совокупное настроение пользователей, выраженное в публикации, опубликованной в течение ti_i периода времени.

$$AUS_{ti_i} = \{agg_{u,ti_i}((f_S^{AR}(p_0^u), (f_S^{AR}(p_1^u), (f_S^{AR}(\dots), (f_S^{AR}(p_j^u)) | \forall p^u \in \dot{P}_{ti_i}, \forall u \in \ddot{U}_{ti_i} \wedge f_{U_{author}}^{AR}(p^u) = u)\} \quad (17)$$

Наконец, можно рассчитать показатель OSWB.

Определение 4.23. $OSWBI_{ti_i}$ является индикатором OSWB и определяется следующим образом:

$$OSWBI_{ti_i} = \{indicator(aus) | \forall aus \in AUS_{ti_i}\} \quad (18)$$

где *indicator* — формула индикатора, которая может быть определена несколькими способами в зависимости от целей исследования (см. примеры в [18] (опубликованная статья)).

В качестве источника данных для измерения OSWB была выбрана социальная сеть «Одноклассники», одна из крупнейших в России. Распределение аудитории «Одноклассников» по возрасту наиболее близко среди всех социальных сетей к общему распределению интернет-аудитории в России [125]. Аналогичная информация была представлена в исследовании [126], где автор пришел к выводу, что «Одноклассники» – самая демократичная социальная сеть в России, поскольку ею пользуются все категории населения, в том числе «традиционные непользователи», то есть пожилые люди и люди с низким уровнем образования. Фактически, по словам Бродовской и др. [126], единственной сетью,

которой пользуются пожилые россияне, является «Одноклассники», поскольку у россиян, достигших шестидесятилетнего возраста, нет аккаунтов ни в каких зарубежных социальных сетях.

OK Data Science Lab предоставила нам 7 200 000 случайно выбранных текстовых (т.е. $\forall ar \in AR, f_{AR_{type}}^{AR}(ar) = post$) постов, опубликованных в России (т.е. $\forall u \in U, f_{G?}^U(u) = Russia$) отдельными пользователями (т.е. $\forall u \in U, f_{U_{type}}^U(u) = individual$) в своих общедоступных профилях в период с апреля 2020 г. по май 2021 г., всего около 20 000 сообщений в день. Каждый пост содержал анонимные идентификаторы пользователя (первичный идентификатор артефактов $ar \in AR$), дату рождения ($bd \in BD$), если известна, пол ($sx \in SX$), если известен, время публикации (обязательно для $\rightarrow_{interval}$), часовой пояс автора на момент публикации (обязательно для $\rightarrow_{interval}$), страна автора ($f_{G?}^U(u) = Russia$ для всех постов) на момент публикации (на основе IP и других внутренних эвристик Одноклассников, текст (необходим для функции картирования настроений f_S^{AR}) и язык текста, используемого в посте. Затем были отфильтрованы дубликаты, посты авторов без даты рождения и пола, и получили для дальнейшего анализа 7 049 907 постов, опубликованных 3 610 891 уникальным пользователем — в среднем 1,95 поста на пользователя. Было проверено, что количество уникальных авторов превышает 1537 в день.

При выборе демографических групп, в дополнение к упомянутым ранее общим рекомендациям по измерению SWB [123; 124; 127; 128], были также приняты во внимание рекомендации российских исследовательских агентств по охвату страновых аспектов: Методология ВЦИОМ СПУТНИК [129] и Методология Евробарометра РАНХиГС [130]. Таким образом, были выбраны следующие демографические переменные для постстратификации.

- **Пол.** Массив отражает половую структуру населения в целом: мужские и женские.
- **Возраст.** Массив разделен на четыре возрастные группы, отражающие генеральную совокупность: 18–24 года, 25–39 лет, 40–54 года, 55 лет и старше.

Для анализа тональности была проведена тонкая настройка RuBERT [106], XLM-RoBERTa-Large [131], RuRoBERTa-Large [132] и M-BART-Large-50 [133] на RuSentiment [98]. RuRoBERTa-Large превзошла все другие модели и достигла новых самых высоких результатов классификации – weighted $F_1 = 76.30$

(на 4.27 процентных пункта выше существующей SOTA) и $\text{macro } F_1 = 78.92$ (на 0.42 процентных пункта выше существующей SOTA). Информация о характеристиках моделей, гиперпараметрах, процедуре обучения и анализе ошибок классификации представлена в [18] (опубликованная статья). RuRoBERTa-Large была применена к данным Одноклассников для классификации тональности всех постов.

Для расчета индикаторов были использованы две формулы.

Определение 4.24. $OSWB_{PA}$ — индекс Наблюдаемого позитивного аффекта (переживание приятных эмоций и настроения), который рассчитывается следующим образом:

$$OSWB_{PA} = \frac{POS}{POS + NEG + NEU + SA + SKIP} \quad (19)$$

где POS — количество положительных постов, NEG — количество негативных постов, NEU — количество нейтральных постов, SA — количество постов с приветствиями и речевыми актами, $SKIP$ — количество неоднозначных постов, которые нельзя однозначно отнести к одному из других классов.

Определение 4.25. $OSWB_{NA}$ — индекс Наблюдаемого негативного аффекта (переживание неприятных эмоций и настроения) и определяется следующим образом:

$$OSWB_{NA} = \frac{NEG}{POS + NEG + NEU + SA + SKIP} \quad (20)$$

Были рассчитаны индикаторы для каждого месяца за период с апреля 2020 г. по март 2021 г. (12 месяцев) и была обнаружена линейная корреляция Пирсона от умеренной до сильной (в зависимости от рекомендаций по интерпретации [134]) ($r = 0.733$, $p = 0.007$) и сильная монотонная корреляции Спирмена ($r_s = 0.825$, $p = 0.001$) между $OSWB_{PA}$ (далее Observable PA) и Индексом счастья ВЦИОМ. Как видно на рисунке 2, Observable PA и Индекс счастья ВЦИОМ похожи. Оба показателя демонстрировали рост в начале анализируемого периода и резкое снижение, начиная с осени 2020 г. Поскольку в предыдущих исследованиях сообщалось, что типичная надежность шкал SWB находится в диапазоне от 0,50 до 0,84 [19; 135–138] (и даже между 0.40 и 0.66 для единичных показателей типа Индекс счастья ВЦИОМ [136]), можно считать полученную корреляцию практически близкой к единице. Интересно, что $OSWB_{NA}$ (да-



Рисунок 2 — Наблюдаемый Позитивный Аффект и Индекс Счастья ВЦИОМ с апреля 2020 по март 2021.

лее Observable NA) не показал статистически значимой корреляции с индексом ВЦИОМ.

Хорошо видны общие суточные колебания (см. рисунок 3), при этом утренние часы имеют самый низкий уровень счастья, а поздний вечер – самый высокий. Полученные общие суточные паттерны отличаются от паттернов, зарегистрированных в других исследованиях OSWB (напр., [22; 23]), поскольку в большинстве случаев ранее сообщалось о двух пиках: один рано утром, а другой поздним вечером. В данном случае предполагается, что в полученном в рамках данной работы графике не было раннего утреннего всплеска как по методологическим, так и по географическим причинам. С методологической точки зрения намеренно не рассматривались приветствия и речевые акты как проявление положительных эмоций, они относились к отдельному классу. Основная причина этого решения заключается в том, что в приветствиях и речевых действиях используются слова, связанные с настроением (обычно положительным), необязательно обозначающие основное настроение автора [98; 139]. Предполагается, что именно поэтому другие исследования сообщают о пиках в начале дня: именно здесь происходит наибольшее количество сообщений с приветствиями и речевым актом. С географической точки зрения наличие разных часовых поясов в пределах одной страны (напр., в России 11 часовых поясов) затрудняет срав-




Рисунок 3 — Дневные вариации в локальном времени.

нение колебаний между странами и может вызвать различия в колебаниях для этих стран. В отличие от других исследований, в данной работе анализировалось местное время каждого часового пояса. Отсутствие ранних утренних спайков полностью соответствует результатам классического опросного исследования, проведенного Cornelissen и др. [140]. Авторы построили индикатор Позитивного аффекта, который по форме полностью совпадает с графиком, полученным в данном исследовании: низшая точка достигается утром, затем график растет до 18 часов и начинает падать ближе к ночи. Ключевое отличие состоит в том, что рассчитанный индикатор сдвинут на несколько часов вправо относительно их индикатора (напр., нижняя точка на их индикаторе достигается в 6 утра, а на рассчитанном в данной работе в 8 утра). Полагается, что эта разница возникла из-за несоответствия рассматриваемых выборок, поскольку они опрашивали только студентов, а данное исследование было направлено на большее количество демографических групп. Похожую картину можно наблюдать и в другом исследовании [141], в котором сообщалось о показателях Результирующего аффекта и Позитивного аффекта для России. Авторы сообщили, что Результирующий аффект и Позитивный аффект улучшаются в течение дня, с самой низкой точкой около 9 утра, что соответствует результатам данного исследования.




Рисунок 4 — Недельные вариации в локальном времени.

Также можно наблюдать недельные вариации в OSWB (см. рис. 4), где в выходные выражается больше счастья, чем в будни. На уровне отдельных дней недели также можно наблюдать ранее описанные суточные вариации, имеющие разную амплитуду и экстремумы в зависимости от конкретного дня. В течение недели самый низкий уровень счастья приходится на первые три будних дня, а начиная с четверга, он растет и достигает пика в выходные. Население просыпается в лучшем настроении в субботу и достигает наивысшего уровня счастья ближе к ночи. Эти недельные вариации интуитивно ожидаемы, поскольку, как отметили Mayor и Vietti [142], недельные вариации обычно связаны с традициями и культурными различиями между будними и выходными днями в современных обществах, регулируемыми социальными практиками и поведением. Аналогичные результаты были получены и для других стран как в рамках традиционных социологических исследований (напр., [143; 144]), так и исследований на основе цифровых следов (напр., [23; 139]).

Заключение

В рамках диссертационного исследования были достигнуты следующие результаты.

1. Изучена проблема классификации тональности текстов на русском языке с применением методов машинного обучения и выявлено, что в контексте существующих подходов к классификации тональности на основе языковых моделей превосходит в терминах качества классификации подходы, основанные на правилах и базовом машинном обучении. Кроме того, были выявлены наиболее часто используемые наборы данных для анализа тональности русскоязычных текстов, для каждого из них обучена и выложена в открытый доступ модель классификации.
2. Предложены новая модель и метод оценки влияния погрешности ошибочной классификации определенного алгоритма классификации на рассчитываемые социальные индексы. Предложенная модель и метод учитывают распределение ошибок классификации между разными классами и способны оценить влияние погрешности ошибочной классификации на любую формулу социального индекса.
3. Предложены новая модель и метод расчета индикатора общественного настроения на основе цифровых следов. Предложенная модель и метод учитывают демографические характеристики пользователей, с помощью которых делают анализируемую выборку пользователей репрезентативной по отношению к более широкой аудитории по выбранным демографическим характеристикам.
4. Предложенные модели и методы были применены к данным социальной сети «Одноклассники» и был рассчитан индекс общественного настроения на основе тональности текстовых постов на русском языке. Полученный индекс продемонстрировал высокую корреляцию с традиционным опросным Индексом счастья ВЦИОМ, что подтверждает адекватность предложенных моделей и методов.

В рамках дальнейшего направления исследования предлагается рассмотреть более детальный ряд эмоций при построении OSWB индекса и в том числе изучить то, как выражение различных эмоций онлайн связано с SWB.

Список литературы

1. *Jakobi Á.* Proximity-Driven Motives in the Evolution of an Online Social Network // The Rise of Big Spatial Data. — Cham : Springer International Publishing, 2017. — с. 197—209. — DOI: [10.1007/978-3-319-45123-7_15](https://doi.org/10.1007/978-3-319-45123-7_15).
2. National Happiness Index Monitoring using Twitter for Bilanguages / D. Wang [и др.] // Social Network Analysis and Mining. — 2021. — т. 11, № 1. — с. 1—18. — DOI: [10.1007/s13278-021-00728-0](https://doi.org/10.1007/s13278-021-00728-0).
3. *Höchtel J., Parycek P., Schöllhammer R.* Big Data in the Policy Cycle: Policy Decision Making in the Digital Era // Journal of Organizational Computing and Electronic Commerce. — 2016. — т. 26, № 1/2. — с. 147—169. — DOI: [10.1080/10919392.2015.1125187](https://doi.org/10.1080/10919392.2015.1125187).
4. *Almakaeva A. M., Gashenina N. V.* Subjective Well-Being: Conceptualization, Assessment and Russian Specifics // Monitoring of Public Opinion: Economic and Social Changes. — 2020. — т. 155, № 1. — с. 4—13. — DOI: [10.14515/monitoring.2020.1.01](https://doi.org/10.14515/monitoring.2020.1.01).
5. *Sandvik E., Diener E., Seidlitz L.* Subjective Well-Being: The Convergence and Stability of Self-Report and Non-Self-Report Measures // Assessing Well-Being: The Collected Works of Ed Diener. — Dordrecht : Springer Netherlands, 2009. — с. 119—138. — DOI: [10.1007/978-90-481-2354-4_6](https://doi.org/10.1007/978-90-481-2354-4_6).
6. *Layard R.* Measuring Subjective Well-Being // Science. — 2010. — т. 327, № 5965. — с. 534—535. — DOI: [10.1126/science.118631](https://doi.org/10.1126/science.118631).
7. *Bogdanov M. B., Smirnov I. B.* Opportunities and Limitations of Digital Footprints and Machine Learning Methods in Sociology // Monitoring of Public Opinion: Economic and Social Changes. — 2021. — т. 161, № 1. — с. 304—328. — DOI: [10.14515/monitoring.2021.1.1760](https://doi.org/10.14515/monitoring.2021.1.1760).
8. *Northrup D. A.* The Problem of the Self-Report in Survey Research. — Toronto : Institute for Social Research, 1997. — ISBN 1550143123.

9. *Schwarz N., Clore G. L.* Mood, Misattribution, and Judgments of Well-Being: Informative and Directive Functions of Affective States // *Journal of Personality and Social Psychology*. — 1983. — т. 45, № 3. — с. 513–523. — DOI: [10.1037/0022-3514.45.3.513](https://doi.org/10.1037/0022-3514.45.3.513).
10. *Natale M., Hantas M.* Effect of Temporary Mood States on Selective Memory about the Self // *Journal of Personality and Social Psychology*. — 1982. — т. 42, № 5. — с. 927–934. — DOI: [10.1037/0022-3514.42.5.927](https://doi.org/10.1037/0022-3514.42.5.927).
11. Question Order Bias Revisited: A Split-Ballot Experiment on Satisfaction with Public Services among Experienced and Professional Users / M. Thau [и др.] // *Public Administration*. — 2021. — т. 99, № 1. — с. 189–204. — DOI: [10.1111/padm.12688](https://doi.org/10.1111/padm.12688).
12. *McCambridge J., De Bruin M., Witton J.* The Effects of Demand Characteristics on Research Participant Behaviours in Non-Laboratory Settings: A Systematic Review // *PLoS ONE*. — 2012. — т. 7, № 6. — e39116. — DOI: [10.1371/journal.pone.0039116](https://doi.org/10.1371/journal.pone.0039116).
13. *Van de Mortel T. F.* Faking It: Social Desirability Response Bias in Self-Report Research // *Australian Journal of Advanced Nursing*. — 2008. — т. 25, № 4. — с. 40–48.
14. *Luhmann M.* Using Big Data to Study Subjective Well-Being // *Current Opinion in Behavioral Sciences*. — 2017. — т. 18. — с. 28–33. — DOI: [10.1016/j.cobeha.2017.07.006](https://doi.org/10.1016/j.cobeha.2017.07.006).
15. Measuring Objective and Subjective Well-Being: Dimensions and Data Sources / V. Voukelatou [и др.] // *International Journal of Data Science and Analytics*. — 2020. — т. 11, № 4. — с. 1–31. — DOI: [10.1007/s41060-020-00224-2](https://doi.org/10.1007/s41060-020-00224-2).
16. *Howison J., Wiggins A., Crowston K.* Validity Issues in the Use of Social Network Analysis with Digital Trace Data // *Journal of the Association for Information Systems*. — 2011. — т. 12, № 12. — с. 767–797. — DOI: [10.17705/1jais.00282](https://doi.org/10.17705/1jais.00282).

17. *Németh R., Koltai J.* The Potential of Automated Text Analytics in Social Knowledge Building // Pathways Between Social Science and Computational Social Science: Theories, Methods, and Interpretations. — Cham, Switzerland : Springer International Publishing, 2021. — с. 49—70. — DOI: [10.1007/978-3-030-54936-7_3](https://doi.org/10.1007/978-3-030-54936-7_3).
18. *Smetanin S.* Pulse of the Nation: Observable Subjective Well-Being in Russia Inferred from Social Network Odnoklassniki // Mathematics. — 2022. — т. 10, № 16. — с. 2947. — DOI: [10.3390/math10162947](https://doi.org/10.3390/math10162947).
19. Dimensions of Subjective Well-being / A. Kapteyn [и др.] // Social Indicators Research. — 2015. — т. 123, № 3. — с. 625—660. — DOI: [10.1007/s11205-014-0753-0](https://doi.org/10.1007/s11205-014-0753-0).
20. *Singh S., Kaur P. D.* Subjective Well-Being Prediction from Social Networks: A Review // 2016 Fourth International Conference on Parallel, Distributed and Grid Computing (PDGC). — Himachal Pradesh, India : IEEE, 2016. — с. 90—95. — DOI: [10.1109/PDGC.2016.7913121](https://doi.org/10.1109/PDGC.2016.7913121).
21. Sentiment Analysis in Health and Well-Being: Systematic Review / A. Zunic, P. Corcoran, I. Spasic [и др.] // JMIR Medical Informatics. — Toronto, Canada, 2020. — т. 8, № 1. — e16023. — DOI: [10.2196/16023](https://doi.org/10.2196/16023).
22. Social Data Analysis of Brazilian's Mood from Twitter / D. N. Prata [и др.] // International Journal of Social Science and Humanity. — 2016. — т. 6, № 3. — с. 179—183. — DOI: [10.7763/IJSSH.2016.V6.640](https://doi.org/10.7763/IJSSH.2016.V6.640).
23. *Mislove A.* Pulse of the Nation: US Mood Throughout the Day Inferred from Twitter. — Northeastern University Khoury College of Computer Sciences, 2017. — URL: <http://www.ccs.neu.edu/home/amislove/twittermood/> (дата обр. 25.01.2022).
24. *Dzogang F., Lightman S., Cristianini N.* Circadian Mood Variations in Twitter Content // Brain and Neuroscience Advances. — 2017. — т. 1. — с. 2398212817744501. — DOI: [10.1177/2398212817744501](https://doi.org/10.1177/2398212817744501).
25. Using Tweets to Assess Mental Well-Being of Essential Workers During the COVID-19 Pandemic / J. Blair [и др.] // Extended Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems. — Yokohama,

- Japan : Association for Computing Machinery, 2021. — с. 236. — DOI: [10.1145/3411763.3451612](https://doi.org/10.1145/3411763.3451612).
26. *Panchenko A.* Sentiment Index of the Russian Speaking Facebook // Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference Dialogue 2014. — Moscow, Russia : Russian State University for the Humanities, 2014. — с. 506—517.
 27. Subjective Measurement of Population Ill-Being/Well-Being in the Russian Regions Based on Social Media Data / E. Shchekotin [и др.] // Monitoring of Public Opinion: Economic and Social Changes. — 2020. — т. 155, № 1. — с. 78—116. — DOI: [10.14515/monitoring.2020.1.05](https://doi.org/10.14515/monitoring.2020.1.05).
 28. The Measurement of Demographic Temperature Using the Sentiment Analysis of Data from the Social Network VKontakte / I. E. Kalabikhina [и др.] // Mathematics. — 2021. — т. 9, № 9. — с. 987. — DOI: [10.3390/math9090987](https://doi.org/10.3390/math9090987).
 29. *VCIOM.* Poll about Polls, or Towards Sociologist’s Day. — VCIOM News, 2021. — URL: <https://wciom.ru/analytical-reviews/analiticheskii-obzor/opros-ob-oprosakh-ili-navstrechu-dnju-sociologa> (дата обр. 15.01.2022).
 30. *VCIOM.* Russia’s Goals in the 21st Century. — VCIOM News, 2020. — URL: <https://wciom.ru/analytical-reviews/analiticheskii-obzor/czeli-rossii-v-xxi-veke> (дата обр. 01.02.2022).
 31. *Krueger A. B., Stone A. A.* Progress in Measuring Subjective Well-Being // Science. — 2014. — т. 346, № 6205. — с. 42—43. — DOI: [10.1126/science.1256392](https://doi.org/10.1126/science.1256392).
 32. *Carosia A. E. O., Coelho G. P., Silva A. E. A.* Analyzing the Brazilian Financial Market through Portuguese Sentiment Analysis in Social Media // Applied Artificial Intelligence. — 2020. — т. 34, № 1. — с. 1—19. — DOI: [10.1080/08839514.2019.1673037](https://doi.org/10.1080/08839514.2019.1673037).
 33. *Sharma U., Datta R. K., Pabreja K.* Sentiment Analysis and Prediction of Election Results 2018 // Social Networking and Computational Intelligence. — Singapore : Springer Singapore, 2020. — с. 727—739. — DOI: [10.1007/978-981-15-2071-6_61](https://doi.org/10.1007/978-981-15-2071-6_61).

34. *Georgiadou E., Angelopoulos S., Drake H.* Big Data Analytics and International Negotiations: Sentiment Analysis of Brexit Negotiating Outcomes // *International Journal of Information Management*. — 2020. — т. 51. — с. 102048. — DOI: <https://doi.org/10.1016/j.ijinfomgt.2019.102048>.
35. *Borodkina O., Sibirev V.* Migration Issues in Russian Twitter: Attitudes to Migrants, Social Problems and Online Resources // *Internet Science*. — Cham, Switzerland : Springer International Publishing, 2019. — с. 32–46. — DOI: [10.1007/978-3-030-34770-3_3](https://doi.org/10.1007/978-3-030-34770-3_3).
36. A Survey of Sentiment Analysis in Social Media / L. Yue [и др.] // *Knowledge and Information Systems*. — 2018. — т. 60, № 2. — с. 1–47. — DOI: [10.1007/s10115-018-1236-4](https://doi.org/10.1007/s10115-018-1236-4).
37. *Tedmori S., Awajan A.* Sentiment Analysis Main Tasks and Applications: A Survey // *Journal of Information Processing Systems*. — 2019. — т. 15, № 3. — с. 500–519. — DOI: [10.3745/JIPS.04.0120](https://doi.org/10.3745/JIPS.04.0120).
38. A Comprehensive Survey of Arabic Sentiment Analysis / M. Al-Ayyoub [и др.] // *Information Processing & Management*. — 2019. — т. 56, № 2. — с. 320–342. — DOI: [10.1016/j.ipm.2018.07.006](https://doi.org/10.1016/j.ipm.2018.07.006).
39. *Viksna R., Jēkabsons G.* Sentiment Analysis in Latvian and Russian: A Survey // *Applied Computer Systems*. — 2018. — т. 23, № 1. — с. 45–51. — DOI: [10.2478/acss-2018-0006](https://doi.org/10.2478/acss-2018-0006).
40. *Chetviorkin I., Loukachevitch N.* Evaluating Sentiment Analysis Systems in Russian // *Proceedings of the 4th Biennial International Workshop on Balto-Slavic Natural Language Processing*. — Sofia, Bulgaria : Association for Computational Linguistics, 2013. — с. 12–17.
41. SentiRuEval: Testing Object-Oriented Sentiment Analysis Systems in Russian / N. Loukachevitch [и др.] // *Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference Dialogue 2015*. — Moscow, Russia : Russian State University for the Humanities, 2015. — с. 3–13.

42. *Lukashevich N., Rubtsova Y. R.* SentiRuEval-2016: Overcoming Time Gap and Data Sparsity in Tweet Sentiment Analysis // Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference Dialogue 2016. — Moscow, Russia : Russian State University for the Humanities, 2016. — с. 416—426.
43. *Zvonarev A.* A Comparison of Machine Learning Methods of Sentiment Analysis Based on Russian Language Twitter Data // Proceedings of the 11th Majorov International Conference on Software Engineering and Computer Systems (MICSECS 2019). т. 1. — Saint Petersburg, Russia : ITMO University, 2019.
44. A Comparative Study of Publicly Available Russian Sentiment Lexicons / E. Kotelnikov [и др.] // Artificial Intelligence and Natural Language. — Cham, Switzerland : Springer International Publishing, 2018. — с. 139—151. — DOI: [10.1007/978-3-030-01204-5_14](https://doi.org/10.1007/978-3-030-01204-5_14).
45. Sentiment Analysis Using Deep Learning Techniques: A Review / Q. T. Ain [и др.] // International Journal of Advanced Computer Science and Applications. — 2017. — т. 8, № 6. — с. 424—433. — DOI: [10.14569/IJACSA.2017.080657](https://doi.org/10.14569/IJACSA.2017.080657).
46. *Zhang L., Wang S., Liu B.* Deep Learning for Sentiment Analysis: A Survey // WIREs Data Mining and Knowledge Discovery. — 2018. — т. 8, № 4. — e1253. — DOI: [10.1002/widm.1253](https://doi.org/10.1002/widm.1253).
47. Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review / H. H. Do [и др.] // Expert Systems with Applications. — 2019. — т. 118. — с. 272—299. — DOI: <https://doi.org/10.1016/j.eswa.2018.10.003>.
48. *Maerz S. F., Puschmann C.* Text as Data for Conflict Research: A Literature Survey // Computational Conflict Research. — Cham, Switzerland : Springer International Publishing, 2020. — с. 43—65. — DOI: [10.1007/978-3-030-29333-8_3](https://doi.org/10.1007/978-3-030-29333-8_3).
49. *Smetanin S.* The Applications of Sentiment Analysis for Russian Language Texts: Current Challenges and Future Perspectives // IEEE Access. — 2020. — т. 8. — с. 110693—110719. — DOI: [10.1109/ACCESS.2020.3002215](https://doi.org/10.1109/ACCESS.2020.3002215).

50. Who's Bad? Attitudes toward Resettlers from the Post-Soviet South versus Other Nations in the Russian Blogosphere / S. Bodrunova [и др.] // International Journal of Communication. — 2017. — т. 11. — с. 3242—3264.
51. Detecting Interethnic Relations with the Data from Social Media / O. Koltsova [и др.] // Digital Transformation and Global Society / под ред. D. A. Alexandrov [и др.]. — Cham, Switzerland : Springer International Publishing, 2017. — с. 16—30. — DOI: [10.1007/978-3-319-69784-0_2](https://doi.org/10.1007/978-3-319-69784-0_2).
52. Violent Conflict and Online Segregation: An Analysis of Social Network Communication across Ukraine's Regions / D. Duvanova [и др.] // Journal of Comparative Economics. — 2016. — т. 44, № 1. — с. 163—181. — DOI: [10.1016/j.jce.2015.10.003](https://doi.org/10.1016/j.jce.2015.10.003).
53. Measuring Prejudice and Ethnic Tensions in User-Generated Content / O. Koltsova [и др.] // Annual Review of CyberTherapy and Telemedicine 2017. т. 15. — San Diego, CA, USA : Interactive Media Institute, 2017. — с. 76—81. — ISBN 1554-8716.
54. *Nagornyy O.* Topics of Ethnic Discussions in Russian Social Media // Digital Transformation and Global Society / под ред. D. A. Alexandrov [и др.]. — Cham, Switzerland : Springer International Publishing, 2018. — с. 83—94. — DOI: [10.1007/978-3-030-02846-6_7](https://doi.org/10.1007/978-3-030-02846-6_7).
55. Contrasting Public Opinion Dynamics and Emotional Response During Crisis / S. Volkova [и др.] // Social Informatics. — Cham, Switzerland : Springer International Publishing, 2016. — с. 312—329. — DOI: [10.1007/978-3-319-47880-7_19](https://doi.org/10.1007/978-3-319-47880-7_19).
56. Combining Network and Language Indicators for Tracking Conflict Intensity / A. Rumshisky [и др.] // Social Informatics. — Cham, Switzerland : Springer International Publishing, 2017. — с. 391—404. — DOI: [10.1007/978-3-319-67256-4_31](https://doi.org/10.1007/978-3-319-67256-4_31).
57. *Zaezjev A.* Understanding Political Mobilization through Social Media Content Analysis: Facebook and V Kontakte in the First Days // Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference Dialogue 2018. — Moscow, Russia : Russian State University for the Humanities, 2018.

58. *Tokarev A.* Ukrainian Elites Discourse in Respect of The Donbass Territory and Population of 2009-2018: Analysis of The National Facebook Segment // MGIMO Review of International Relations. — 2018. — т. 63, № 6. — с. 194—211. — DOI: [10.24833/2071-8160-2018-6-63-194-211](https://doi.org/10.24833/2071-8160-2018-6-63-194-211).
59. Analysis of Comments of Users of Social Networks to Assess the Level of Social Tension / D. Donchenko [и др.] // Procedia Computer Science. — 2017. — т. 119. — с. 359—367. — DOI: [10.1016/j.procs.2017.11.195](https://doi.org/10.1016/j.procs.2017.11.195).
60. *Koltsova O., Nagornyy O.* Redefining Media Agendas: Topic Problematization in Online Reader Comments // Media and Communication. — 2019. — т. 7, № 3. — с. 145—156. — DOI: [10.17645/mac.v7i3.1894](https://doi.org/10.17645/mac.v7i3.1894).
61. *Rulyova N.* Russian New Media Users' Reaction to a Meteor Explosion in Chelyabinsk: Twitter Versus YouTube // Emerging Genres in New Media Environments. — Cham, Switzerland : Springer, 2017. — с. 79—97. — DOI: [10.1007/978-3-319-40295-6_4](https://doi.org/10.1007/978-3-319-40295-6_4).
62. *Kirilenko A. P., Stepchenkova S. O.* Sochi 2014 Olympics on Twitter: Perspectives of Hosts and Guests // Tourism Management. — 2017. — т. 63. — с. 54—65. — DOI: [10.1016/j.tourman.2017.06.007](https://doi.org/10.1016/j.tourman.2017.06.007).
63. Communication Power Struggles on Social Media: A Case Study of the 2011–12 Russian Protests / V. Spaiser [и др.] // Journal of Information Technology & Politics. — 2017. — т. 14, № 2. — с. 132—153. — DOI: [10.1080/19331681.2017.1308288](https://doi.org/10.1080/19331681.2017.1308288).
64. *Nenko A., Petrova M.* Comparing PPGIS and LBSN Data to Measure Emotional Perception of the City // Digital Transformation and Global Society. — Cham, Switzerland : Springer International Publishing, 2019. — с. 223—234. — DOI: [10.1007/978-3-030-37858-5_18](https://doi.org/10.1007/978-3-030-37858-5_18).
65. *Svetlov K., Platonov K.* Sentiment Analysis of Posts and Comments in the Accounts of Russian Politicians on the Social Network // 2019 25th Conference of Open Innovations Association (FRUCT). — Helsinki, Finland : IEEE, 2019. — с. 299—305. — DOI: [10.23919/FRUCT48121.2019.8981501](https://doi.org/10.23919/FRUCT48121.2019.8981501).

66. Why Employees Leave Russian Companies? Analyzing Online Job Reviews Using Text Mining / D. Sokolov [и др.] // Russian Management Journal. — 2018. — т. 16, № 4. — с. 499—512. — DOI: [10.21638/spbu18.2018.402](https://doi.org/10.21638/spbu18.2018.402).
67. *Kaplan R. L.* Politics and the American Press: The Rise of Objectivity, 1865-1920. — Cambridge, UK : Cambridge University Press, 2002. — ISBN 9780521006026.
68. *Yakovleva K.* Text Mining-based Economic Activity Estimation // Russian Journal of Money and Finance. — 2018. — т. 77, № 4. — с. 26—41. — DOI: [10.31477/rjmf.201804.26](https://doi.org/10.31477/rjmf.201804.26).
69. *Kazun A., Kazun A.* A Friend Who Was Supposed to Lose: How Donald Trump Was Portrayed in the Russian Media? // Higher School of Economics Research Paper No. WP BRP 51/PS/2017. — 2017. — т. 51. — DOI: [10.2139/ssrn.3070265](https://doi.org/10.2139/ssrn.3070265).
70. Road Pavement Assessment of the North-West Federal District Using Sentiment Analysis of the Internet User Reviews / Y. Seliverstov [и др.] // Russian Management Journal. — 2019. — т. 13, № 3. — с. 7—24. — DOI: [10.18721/JCSTCS.12301](https://doi.org/10.18721/JCSTCS.12301).
71. *Li W., Chen H.* Identifying Top Sellers In Underground Economy Using Deep Learning-Based Sentiment Analysis // 2014 IEEE Joint Intelligence and Security Informatics Conference. — The Hague, Netherlands : IEEE, 2014. — с. 64—67. — DOI: [10.1109/JISIC.2014.19](https://doi.org/10.1109/JISIC.2014.19).
72. *Kolmogorova A. V.* Emotional Tonality as a Valuable Subjective Parameter of Study Text for Russian as Foreign Language Learners // Philological Class. — 2019. — т. 57, № 3. — с. 95—101. — DOI: [10.26170/FK19-03-13](https://doi.org/10.26170/FK19-03-13).
73. Sentiment in Academic Texts / V. Solovyev [и др.] // 2019 24th Conference of Open Innovations Association (FRUCT). — Moscow, Russia : IEEE, 2019. — с. 408—414. — DOI: [10.23919/FRUCT.2019.8711900](https://doi.org/10.23919/FRUCT.2019.8711900).
74. *Brantly A. F.* From Cyberspace to Independence Square: Understanding the Impact of Social Media on Physical Protest Mobilization During Ukraine’s Euromaidan Revolution // Journal of Information Technology & Politics. — 2019. — т. 16, № 4. — с. 360—378. — DOI: [10.1080/19331681.2019.1657047](https://doi.org/10.1080/19331681.2019.1657047).

75. *Kazun A.* To Cover or not to Cover: Alexei Navalny in Russian Media // International Area Studies Review. — 2019. — т. 22, № 4. — с. 312—326. — DOI: [10.1177/2233865919846727](https://doi.org/10.1177/2233865919846727).
76. *Belyakov M.* The Analysis of News Messages of the Site of the Russian Federation Ministry of Foreign Affairs Applying Content Analysis (Article 1) // RUDN Journal of Language Studies, Semiotics and Semantics. — 2016. — № 3. — с. 58—67.
77. *Belyakov M.* The Analysis of News Messages of the RF Ministry of Foreign Affairs Web-Site by the Sentiment Analysis (Article 2) // RUDN Journal of Language Studies, Semiotics and Semantics. — 2016. — № 4. — с. 115—124.
78. Sentiment Analysis of Innovations in Russian Media / I. V. Khramoin [и др.] // 2017 Second Russia and Pacific Conference on Computer Technology and Applications (RPC). — Vladivostok, Russia : IEEE, 2017. — с. 96—99. — DOI: [10.1109/RPC.2017.8168076](https://doi.org/10.1109/RPC.2017.8168076).
79. *Etling B.* Russia, Ukraine, and the West: Social Media Sentiment in the Euromaidan Protests // Berkman Center Research Publication. — 2014. — DOI: [10.2139/ssrn.2501761](https://doi.org/10.2139/ssrn.2501761).
80. Sentiment Strength Detection in Short Informal Text / M. Thelwall [и др.] // Journal of the American Society for Information Science and Technology. — 2010. — т. 61, № 12. — с. 2544—2558. — DOI: [10.1002/asi.21416](https://doi.org/10.1002/asi.21416).
81. *Koltsova O.* Methodological Challenges for Detecting Interethnic Hostility on Social Media // Internet Science. — Cham, Switzerland : Springer International Publishing, 2019. — с. 7—18. — DOI: [10.1007/978-3-030-17705-8_1](https://doi.org/10.1007/978-3-030-17705-8_1).
82. Buzzer Detection and Sentiment Analysis for Predicting Presidential Election Results in a Twitter Nation / M. Ibrahim [и др.] // 2015 IEEE International Conference on Data Mining Workshop (ICDMW). — Atlantic City, NJ, USA : IEEE, 2015. — с. 1348—1353. — DOI: [10.1109/ICDMW.2015.113](https://doi.org/10.1109/ICDMW.2015.113).
83. *Mitchell A., Hitlin P.* Twitter Reaction to Events Often at Odds with Overall Public Opinion // Pew Research Center. — 2013.

84. *Oliveira D. J. S., Souza Bermejo P. H. de, Santos P. A. dos.* Can Social Media Reveal the Preferences of Voters? A Comparison Between Sentiment Analysis and Traditional Opinion Polls // *Journal of Information Technology & Politics*. — 2017. — т. 14, № 1. — с. 34–45. — DOI: [10.1080/19331681.2016.1214094](https://doi.org/10.1080/19331681.2016.1214094).
85. *Howard J., Ruder S.* Universal Language Model Fine-tuning for Text Classification // *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*. — Melbourne, Australia : Association for Computational Linguistics, 2018. — с. 328–339. — DOI: [10.18653/v1/P18-1031](https://doi.org/10.18653/v1/P18-1031).
86. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding / J. Devlin [и др.] // *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*. т. 1. — Minneapolis, Minnesota : Association for Computational Linguistics, 2019. — с. 4171–4186. — DOI: [10.18653/v1/N19-1423](https://doi.org/10.18653/v1/N19-1423).
87. How to Fine-Tune BERT for Text Classification? / C. Sun [и др.] // *Chinese Computational Linguistics*. — Cham, Switzerland : Springer International Publishing, 2019. — с. 194–206. — DOI: [10.1007/978-3-030-32381-3_16](https://doi.org/10.1007/978-3-030-32381-3_16).
88. *Dudina V., Judina D.* Mining Opinions on the Internet: Can the Text Analysis Methods Replace Public Opinion Polls? // *Monitoring of Public Opinion: Economic and Social Changes*. — 2017. — т. 141, № 5. — с. 63–78. — DOI: [10.14515/monitoring.2017.5.05](https://doi.org/10.14515/monitoring.2017.5.05).
89. *Dudina V.* Digital Data Potentialities for Development of Sociological Knowledge // *Sociological Studies*. — 2016. — № 9. — с. 21–30.
90. *Panicheva P., Mirzagitova A., Ledovaya Y.* Semantic Feature Aggregation for Gender Identification in Russian Facebook // *Artificial Intelligence and Natural Language*. — Cham, Switzerland : Springer International Publishing, 2018. — с. 3–15. — DOI: [10.1007/978-3-319-71746-3_1](https://doi.org/10.1007/978-3-319-71746-3_1).
91. Gender Identification in Russian Texts / R. Bhargava [и др.] // *FIRE 2017 Working Notes*. — Bangalore, India : CEUR, 2017. — с. 13–16.

92. Overview of the RUSProfiling PAN at FIRE Track on Cross-genre Gender Identification in Russian / T. Litvinova [и др.] // FIRE 2017 Working Notes. — Bangalore, India : CEUR, 2017. — с. 1—7.
93. A Comparison of Data Driven Models of Solving the Task of Gender Identification of Author in Russian Language Texts for Cases without and with the Gender Deception / A. Sboev [и др.] // Journal of Physics: Conference Series. т. 937. — Moscow, Russia : IOP Publishing, 2017. — с. 012046. — DOI: [10.1088/1742-6596/937/1/012046](https://doi.org/10.1088/1742-6596/937/1/012046).
94. A Gender Identification of Text Author in Mixture of Russian Multi-Genre Texts with Distortions on Base of Data-Driven Approach Using Machine Learning Models / A. Sboev [и др.] // AIP Conference Proceedings. т. 2116. — Rhodes, Greece : AIP Publishing, 2019. — с. 270006. — DOI: [10.1063/1.5114280](https://doi.org/10.1063/1.5114280).
95. *Gavrilova T. V.* Principles and Methods of Research Quality of Life // Quality of Life Technologies. — 2004. — т. 4, № 2. — с. 1—11. — DOI: [10.15587/2312-8372.2014.21223](https://doi.org/10.15587/2312-8372.2014.21223).
96. SemEval-2019 Task 3: EmoContext Contextual Emotion Detection in Text / A. Chatterjee [и др.] // Proceedings of the 13th International Workshop on Semantic Evaluation. — Minneapolis, Minnesota, USA : Association for Computational Linguistics, 2019. — с. 39—48. — DOI: [10.18653/v1/S19-2005](https://doi.org/10.18653/v1/S19-2005).
97. *Rubtsova Y.* A Method for Development and Analysis of Short Text Corpus for the Review Classification Task // Proceedings of the Conference on Digital Libraries: Advanced Methods and Technologies, Digital Collections (RCDL 2013). — Yaroslavl, Russia : JINR, 2013. — с. 269—275.
98. RuSentiment: An Enriched Sentiment Analysis Dataset for Social Media in Russian / A. Rogers [и др.] // Proceedings of the 27th International Conference on Computational Linguistics. — Santa Fe, New Mexico, USA : Association for Computational Linguistics, 2018. — с. 755—763.
99. *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: Proceedings of the International Conference Dialogue 2016. — Moscow, Russia : Russian State University for the Humanities, 2016. — с. 227—287.

100. *Kaggle*. Sentiment Analysis in Russian. — Kaggle, 2017. — URL: <https://www.kaggle.com/c/sentiment-analysis-in-russian> (дата обр. 30.09.2019).
101. *Smetanin S., Komarov M.* Sentiment Analysis of Product Reviews in Russian using Convolutional Neural Networks // 2019 IEEE 21st Conference on Business Informatics (CBI). т. 1. — Moscow, Russia : IEEE, 2019. — с. 482—486. — DOI: [10.1109/CBI.2019.00062](https://doi.org/10.1109/CBI.2019.00062).
102. Distributed Representations of Words and Phrases and Their Compositionality / Т. Mikolov [и др.] // Proceedings of the 26th International Conference on Neural Information Processing Systems. т. 2. — Lake Tahoe, Nevada, USA : Curran Associates Inc., 2013. — с. 3111—3119.
103. *Pennington J., Socher R., Manning C.* GloVe: Global Vectors for Word Representation // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). — Doha, Qatar : Association for Computational Linguistics, 2014. — с. 1532—1543. — DOI: [10.3115/v1/D14-1162](https://doi.org/10.3115/v1/D14-1162).
104. Multilingual Universal Sentence Encoder for Semantic Retrieval / Y. Yang [и др.] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics: System Demonstrations. — Online : Association for Computational Linguistics, 2020. — с. 87—94. — DOI: [10.18653/v1/2020.acl-demos.12](https://doi.org/10.18653/v1/2020.acl-demos.12).
105. A Survey of Sentiment Analysis Based on Transfer Learning / R. Liu [и др.] // IEEE Access. — 2019. — т. 7. — с. 85401—85412. — DOI: [10.1109/ACCESS.2019.2925059](https://doi.org/10.1109/ACCESS.2019.2925059).
106. *Kuratov Y., Arkhipov M.* Adaptation of Deep Bidirectional Multilingual Transformers for Russian Language // Computational Linguistics and Intellectual Technologies. Papers from the Annual International Conference Dialogue 2019. — Moscow, Russia : Russian State University for the Humanities, 2019. — с. 333—340.
107. *Baymurzina D., Kuznetsov D., Burtsev M.* Language Model Embeddings Improve Sentiment Analysis in Russian // Computational Linguistics and Intellectual Technologies. Papers from the Annual International Conference Dialogue 2019. — Moscow, Russia : Russian State University for the Humanities, 2019. — с. 53—63.

108. *Smetanin S., Komarov M.* Deep Transfer Learning Baselines for Sentiment Analysis in Russian // Information Processing & Management. — 2021. — т. 58, № 3. — с. 102484. — DOI: [10.1016/j.ipm.2020.102484](https://doi.org/10.1016/j.ipm.2020.102484).
109. *Golubev A., Loukachevitch N.* Improving Results on Russian Sentiment Datasets // Artificial Intelligence and Natural Language. — Cham, Switzerland : Springer International Publishing, 2020. — с. 109—121. — DOI: [10.1007/978-3-030-59082-6_8](https://doi.org/10.1007/978-3-030-59082-6_8).
110. *Barnes J., Øvrelid L., Vellidal E.* Sentiment Analysis Is Not Solved! Assessing and Probing Sentiment Classification // Proceedings of the 2019 ACL Workshop BlackboxNLP: Analyzing and Interpreting Neural Networks for NLP. — Florence, Italy : Association for Computational Linguistics, 2019. — с. 12—23. — DOI: [10.18653/v1/W19-4802](https://doi.org/10.18653/v1/W19-4802).
111. *Schwartz J. E.* The Neglected Problem of Measurement Error in Categorical Data // Sociological Methods & Research. — 1985. — т. 13, № 4. — с. 435—466. — DOI: [10.1177/0049124185013004001](https://doi.org/10.1177/0049124185013004001).
112. *Scholtus S., Delden A.* On the Accuracy of Estimators based on a Binary Classifier. — The Hague, Netherlands : Statistics Netherlands, 2020.
113. Comparing Correction Methods to Reduce Misclassification Bias / K. Kloos [и др.] // Benelux Conference on Artificial Intelligence. — Springer. Belgium, Netherlands & Luxemburg, 2020. — с. 64—90. — DOI: [10.1007/978-3-030-76640-5_5](https://doi.org/10.1007/978-3-030-76640-5_5).
114. Measurement Error Studies at the National Center for Education Statistics : тех. отч. / S. Salvucci [и др.] ; National Center for Education Statistics. — Washington, D.C., 1997. — NCES 97—464.
115. Evaluation of Classification Models in Machine Learning / J. D. Novaković [и др.] // Theory and Applications of Mathematics & Computer Science. — 2017. — т. 7, № 1. — с. 39—46.
116. *Hopkins D. J., King G.* A Method of Automated Nonparametric Content Analysis for Social Science // American Journal of Political Science. — 2010. — т. 54, № 1. — с. 229—247. — DOI: [10.1111/j.1540-5907.2009.00428.x](https://doi.org/10.1111/j.1540-5907.2009.00428.x).

117. *Delden A. van, Scholtus S., Burger J.* Accuracy of Mixed-Source Statistics as Affected by Classification Errors // *Journal of Official Statistics*. — 2016. — т. 32, № 3. — с. 619. — DOI: [10.1515/jos-2016-0032](https://doi.org/10.1515/jos-2016-0032).
118. *Smetanin S., Komarov M.* Misclassification Bias in Computational Social Science: A Simulation Approach for Assessing the Impact of Classification Errors on Social Indicators Research // *IEEE Access*. — 2022. — т. 10. — с. 18886—18898. — DOI: [10.1109/ACCESS.2022.3149897](https://doi.org/10.1109/ACCESS.2022.3149897).
119. *Vatrapu R. K.* Towards a Theory of Socio-Technical Interactions // *European Conference on Technology Enhanced Learning*. — Springer. Berlin, Heidelberg, 2009. — с. 694—699. — DOI: [10.1007/978-3-642-04636-0_70](https://doi.org/10.1007/978-3-642-04636-0_70).
120. Beyond the Emotional Event: Six Studies on the Social Sharing of Emotion / B. Rime [и др.] // *Cognition & Emotion*. — 1991. — т. 5, № 5/6. — с. 435—465. — DOI: [10.1080/02699939108411052](https://doi.org/10.1080/02699939108411052).
121. *Mukkamala R. R., Hussain A., Vatrapu R.* Towards a Set Theoretical Approach to Big Data Analytics // *2014 IEEE International Congress on Big Data*. — Anchorage, AK, USA : IEEE, 2014. — с. 629—636. — DOI: [10.1109/BigData.Congress.2014.96](https://doi.org/10.1109/BigData.Congress.2014.96).
122. Social Set Analysis: A Set Theoretical Approach to Big Data Analytics / R. Vatrapu [и др.] // *IEEE Access*. — 2016. — т. 4. — с. 2542—2571. — DOI: [10.1109/ACCESS.2016.2559584](https://doi.org/10.1109/ACCESS.2016.2559584).
123. *OECD.* OECD Guidelines on Measuring Subjective Well-Being. — Paris : OECD Publishing, 2013. — DOI: [10.1787/9789264191655-en](https://doi.org/10.1787/9789264191655-en).
124. *European Social Survey.* European Social Survey Round 9 Sampling Guidelines: Principles and Implementation. — European Social Survey, 2018. — URL: https://www.europeansocialsurvey.org/docs/round9/methods/ESS9_sampling_guidelines.pdf (дата обр. 01.02.2022).
125. *VCIOM.* Each Age has Its Own Networks. — VCIOM News, 2018. — URL: <https://wciom.ru/analytical-reviews/analiticheskii-obzor/kazhdomu-voznrastu-svoi-seti> (дата обр. 01.02.2022).

126. *Brodovskaya E., Dombrovskaya A., Sinyakov A.* Social Media Strategies in Modern Russia: Results of Multidimensional Scaling // Monitoring of Public Opinion : Economic and Social Changes. — 2016. — т. 131, № 1. — с. 283—296. — DOI: [10.14515/monitoring.2016.1.13](https://doi.org/10.14515/monitoring.2016.1.13).
127. *Gallup.* Gallup World Poll Methodology. — OECD, 2008. — URL: <https://www.oecd.org/sdd/43017172.pdf> (дата обр. 01.02.2022).
128. *Happy Planet Index.* Happy Planet Index 2016 // Methods Paper. Zugriff vom. — 2016. — т. 18. — с. 2017.
129. *VCIOM.* SPUTNIK Daily All-Russian Poll. — VCIOM News, 2022. — URL: <https://ok.wciom.ru/research/vciom-sputnik> (дата обр. 01.01.2022).
130. *RANEPA.* Eurobarometer Methodology. — Russian Presidential Academy of National Economy and Public Administration, 2020. — URL: <https://www.ranepa.ru/nauka-i-konsalting/strategii-i-doklady/evrobarometr/metodologiya-evrobarometra/> (дата обр. 01.01.2022).
131. Unsupervised Cross-lingual Representation Learning at Scale / A. Conneau [и др.] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. — Online : Association for Computational Linguistics, 2020. — с. 8440—8451. — DOI: [10.18653/v1/2020.acl-main.747](https://doi.org/10.18653/v1/2020.acl-main.747).
132. *Sberbank.* Second only to Humans: SberDevices Language Models Best in the World at Russian Text Comprehension. — 2021. — URL: <https://www.sberbank.com/news-and-media/press-releases/article?newsID=db5b6ba1-f5d1-4302-ba72-18c717c650f3&blockID=7®ionID=77&lang=en&type=NEWS> (дата обр. 01.01.2022).
133. Multilingual Translation with Extensible Multilingual Pretraining and Finetuning / Y. Tang [и др.]. — 2020. — arXiv: [2008.00401](https://arxiv.org/abs/2008.00401) [cs.CL].
134. *Akoglu H.* User's Guide to Correlation Coefficients // Turkish Journal of Emergency Medicine. — 2018. — т. 18, № 3. — с. 91—93. — DOI: [10.1016/j.tjem.2018.08.001](https://doi.org/10.1016/j.tjem.2018.08.001).
135. *Stock W. A., Okun M. A., Benito J. A. G.* Subjective Well-Being measures: Reliability and Validity among Spanish Elders // The International Journal of Aging and Human Development. — 1994. — т. 38, № 3. — с. 221—235. — DOI: [10.2190/MGGY-KFN3-M4YR-DFN4](https://doi.org/10.2190/MGGY-KFN3-M4YR-DFN4).

136. *Krueger A. B., Schkade D. A.* The Reliability of Subjective Well-Being Measures // *Journal of Public Economics*. — 2008. — т. 92, № 8/9. — с. 1833—1845. — DOI: [10.1016/j.jpubeco.2007.12.015](https://doi.org/10.1016/j.jpubeco.2007.12.015).
137. *Levin K. A., Currie C.* Reliability and Validity of an Adapted Version of the Cantril Ladder for Use with Adolescent Samples // *Social Indicators Research*. — 2014. — т. 119, № 2. — с. 1047—1063. — DOI: [10.1007/s11205-013-0507-4](https://doi.org/10.1007/s11205-013-0507-4).
138. *Lucas R. E.* Reevaluating the Strengths and Weaknesses of Self-Report Measures of Subjective Well-Being // *Handbook of Well-Being*. — Salt Lake City, UT, USA, 2018.
139. *Dzogang F., Lightman S., Cristianini N.* Diurnal Variations of Psychometric Indicators in Twitter Content // *PLoS ONE*. — San Francisco, CA, USA, 2018. — т. 13, № 6. — e0197002. — DOI: [10.1371/journal.pone.0197002](https://doi.org/10.1371/journal.pone.0197002).
140. Mapping of Circaseptan and Circadian Changes in Mood / G. Cornelissen [и др.] // *Scripta Medica*. — 2005. — т. 78, № 2. — с. 89.
141. Multi-Country Evaluation of Affective Experience: Validation of an Abbreviated Version of the Day Reconstruction Method in Seven Countries / J. L. Ayuso-Mateos [и др.] // *PLoS ONE*. — 2013. — т. 8, № 4. — e61534. — DOI: [10.1371/journal.pone.0061534](https://doi.org/10.1371/journal.pone.0061534).
142. *Mayor E., Bietti L. M.* Twitter, Time and Emotions // *Royal Society Open Science*. — 2021. — т. 8, № 5. — с. 201900. — DOI: [10.1098/rsos.201900](https://doi.org/10.1098/rsos.201900).
143. *Helliwell J. F., Wang S.* How was the Weekend? How the Social Context Underlies Weekend Effects in Happiness and Other Emotions for US Workers // *PLoS ONE*. — San Francisco, CA, USA, 2015. — т. 10, № 12. — e0145123. — DOI: [10.1371/journal.pone.0145123](https://doi.org/10.1371/journal.pone.0145123).
144. *Stone A. A., Schneider S., Harter J. K.* Day-of-Week Mood Patterns in the United States: On the Existence of ‘Blue Monday’, ‘Thank God it’s Friday’ and Weekend Effects // *The Journal of Positive Psychology*. — 2012. — т. 7, № 4. — с. 306—314. — DOI: [10.1080/17439760.2012.691980](https://doi.org/10.1080/17439760.2012.691980).