

МОДЕЛИРОВАНИЕ ПОЛИТИЧЕСКИХ ВЗГЛЯДОВ РОССИЙСКИХ ПОЛЬЗОВАТЕЛЕЙ СОЦИАЛЬНОЙ СЕТИ ВКОНТАКТЕ

© 2019 г. *И.В. Козицин^{1,2,a}, А.Г. Чхартишвили¹, А.М. Марченко²,
Д.О. Норкин², С.Д. Осипов², И.А. Утешев², В.Л. Гойко³,
Р.В. Палкин³, М.Г. Мягков^{3,4}*

¹Институт проблем управления им. В.А. Трапезникова РАН, Москва

²Московский физико-технический институт, Долгопрудный

³Томский государственный университет, Томск

⁴Университет Орегона, Юджин, США

^akozitsin.ivan@mail.ru

Работа выполнена при частичной поддержке РФФИ (проект 18-29-22042).

DOI:10.1134/S023408791908001X

Предложены две модели машинного обучения для автоматического определения политических взглядов российских пользователей ВКонтакте, в основе которых лежит микроподход к анализу данных ВКонтакте. Результаты приложены к различным научным и прикладным сферам. Одна из них – мониторинг общественного мнения: в результате апробации на выборке, состоящей из 22 миллионов цифровых отпечатков аккаунтов совершеннолетних пользователей, были построены две оценки распределения симпатий соответствующих пользователей в преддверии выборов Президента РФ 2018 года. При использовании этих оценок для построения ретроспективного прогноза результатов выборов средние абсолютные ошибки составили 12 и 19.4 процентов соответственно, причем в первом случае были верно расставлены три первых места. Кроме того, представлен подход к калибровке параметров математических моделей динамики мнений, а именно, величин, отвечающих за сами мнения пользователей. В основе данного подхода лежат оценки, генерируемые построенными алгоритмами.

Ключевые слова: оценка политических взглядов пользователей, анализ онлайн социальных сетей, модели динамики взглядов, машинное обучение, общественное мнение.

MODELLING RUSSIAN USERS' POLITICAL PREFERENCES

*I.V. Kozitsin^{1,2}, A.G. Chkhartishvili¹, A.M. Marchenko², D.O. Norkin², S.D. Osipov²,
I.A. Uteshev², V.L. Goiko³, R.V. Palkin³, M.G. Myagkov^{3,4}*

¹Trapeznikov Institute of Control Sciences RAS, Moscow, Russian Federation

²Moscow Institute of Physics and Technology, Dolgoprudny, Russian Federation

³Tomsk State University, Tomsk, Russian Federation

⁴University of Oregon, Eugene, USA

In this paper, we present two machine learning models that can predict Russian VKontakte users' political preferences. They imply operationing at the users-level. We consider thoroughly its different applications; one of them is public opinion monitoring. To demonstrate it, we test them on the sample of 22 mil of Russian users of age. Finally, we retrieve two estimations of public opinion. In case we value the outcome of the 2018 Presidential election by these estimations, we get MAE of 12 and 19.4 percent correspondingly. Moreover, one of the algorithms finds correctly the first three places. Another prominent utility relates to the calibration of opinion dynamics models where we can use scores generated by the machine learning algorithms to estimate users' opinions numerically.

Keywords: users' political leaning prediction, online social networks analysis, opinion dynamics, machine learning, public opinion.

1. Введение

Растущая популярность онлайн-социальных сетей (таких как Твиттер, Фейсбук или ВКонтакте) привела к тому, что все больше людей пользуются этими платформами для общения, выражения своих мнений и получения новой информации. Попутно пользователи оставляют за собой в веб-пространстве *информационные следы* (цифровые отпечатки) [1]. Самыми популярными примерами здесь являются *лайки*, *репосты* и *комментарии* (данные термины являются утвердившимися как в практике, так и в исследованиях социальных сетей; они обозначают действия, совершаемые пользователями с помощью функционала платформы, которые становятся видны другим пользователям и позволяют идентифицировать тех, кто их совершил).

В [2] была предложена следующая классификация задач, связанных с онлайн-социальными сетями (далее – ОСС), ключевую роль в решении которых играют информационные следы пользователей: задачи *мониторинга* и *анализа* ОСС, задачи *прогнозирования* и задачи *управления*.

Одной из наиболее популярных прикладных задач, относящихся к первому типу, является предсказание скрытых характеристик пользователей (возраст, пол, религия, кредитоспособность и т.д.) [3]. Однако рост популярности ОСС привел к тому, что данные, генерируемые пользователями этих платформ, начали использовать не только для анализа, прогнозирова-

ния и управления объектами, которые принадлежат ОСС, но и для построения выводов относительно сущностей, которые находятся за пределами ОСС. Здесь уместно привести следующие примеры [1,4]: 1) прогнозирование возникновения событий (митинги, межнациональные конфликты, эпидемии различных заболеваний); 2) анализ ОСС с целью построения оценки результатов соцопросов или политических выборов.

Все подходы, направленные на решение обозначенных выше проблем, зиждутся на предположении, что ОСС являются отражением текущего состояния общества [5] и, следовательно, могут быть использованы для анализа самого общества.

Если говорить о задачах управления, то они актуальны в сфере маркетинга, а также в области политических технологий, где цель – добиться того, чтобы пользователь приобрел конкретный товар или проголосовал соответствующим образом на выборах.

2. Постановка задачи

В данной работе в фокусе нашего внимания находится следующая проблема мониторинга и анализа ОСС: разработка алгоритма для определения политических взглядов российских пользователей ВКонтакте. Более точно, нашей целью является построение отображения ρ множества U российских пользователей социальной сети ВКонтакте в некоторое пространство взглядов C . Элементы C однозначно описывают политические предпочтения пользователей относительно заранее выбранного спектра:

$$\rho: U \rightarrow C. \tag{1}$$

Пространство взглядов C может быть непрерывным или дискретным, его элементами могут быть скаляры или векторы.

Эта задача имеет большое теоретическое и прикладное значение. Имея в руках подобный инструмент, можно собирать информацию о том, как меняются мнения пользователей со временем. Полученные данные можно анализировать с точки зрения различных теорий формирования мнений, в том числе известных математических моделей, описывающих динамику взглядов [6–12]. Таким образом, данный подход может быть использован для мониторинга и прогнозирования общественного мнения (пользователей ОСС).

Существующие работы в направлении, связанном с предсказанием политических взглядов пользователей по их цифровым следам, утверждают, что рассматриваемая задача поддается решению, однако есть определенные

ограничения, которые нужно аккуратно учитывать. Основным препятствием является *проблема обобщения* [13-15]. Для построения алгоритма и его калибровки необходимо иметь базу данных с *размеченными пользователями* – аккаунтами, чьи политические взгляды известны (например, через открытые опросы, посредством экспертной оценки или каким-нибудь другим способом). Однако нет гарантий, что собранная коллекция может отражать все возможные взаимосвязи между электронными следами пользователей и их политическими предпочтениями. Таким образом, мы должны быть аккуратны при обобщении с имеющейся в нашем распоряжении базы данных на пользователей ОСС за ее пределы. В таких случаях могут быть применены математические модели, основанные на положениях о поведении индивидов [16].

Как уже говорилось ранее, одной из перспективных задач является применение анализа ОСС для построения оценки результатов соцопросов и политических выборов, в которых голосуют далеко не только пользователи ОСС. При использовании алгоритма типа (1) для вышеупомянутых целей также возникает проблема обобщения: усредненные характеристики «обитателей» ОСС отличаются от усредненных характеристик всего населения страны (например, в среднем, пользователи ОСС более молодые). Более того, в случае выборов нужно учитывать дополнительные факторы, например, явку избирателей. Помимо этого, среди пользователей ОСС имеются боты (искусственные аккаунты, созданные для продвижения какого-либо продукта, бренда или персоны) и виртуалы (пользователи, которые за денежное вознаграждение выполняют функции ботов). Этих акторов, которые далеко не всегда легко идентифицируемы, следует рассматривать с определенной долей осторожности, так как их поведение, как правило, является нетипичным для обычного пользователя.

Тем не менее, анализ данных из ОСС в целом и применение алгоритма (1) для оценивания результатов социальных опросов и выборов в частности обладают некоторыми явными достоинствами. Во-первых, пользователи ОСС образуют весьма значимую долю граждан. К примеру, на 20 февраля 2018 года в социальной сети Вконтакте зарегистрировано около 22 млн валидных россиян старше 18-ти лет (под валидностью пользователя мы имеем в виду, что пользователь заходит в данную ОСС хотя бы раз в месяц), в то время как при социологических опросах количество респондентов составляет несколько тысяч. Более того, в силу смещенности по возрасту, данная выборка отвечает за более активную часть населения (имеется в виду не электоральная активность, а большая мобильность – к примеру, возможность уча-

ствовать в митингах и демонстрациях). При этом, в силу растущей популярности ОСС, с течением времени возрастной дисбаланс будет сглаживаться, и все больше пожилых людей будут ими пользоваться (так как они уже сейчас ими пользуются – находясь в более молодом возрасте).

Большинство подходов к решению поставленной задачи могут быть сгруппированы в два класса: микроподходы и макроподходы [1]. Микроподходы оперируют данными на уровне пользователя, пытаясь оценить политические взгляды каждого по отдельности [14]. ОСС обладают свойством ярко выраженной персонализированности, тем самым для каждого конкретного пользователя имеется возможность собрать достаточное количество данных. При этом, агрегируя эту информацию по пользователям, можно построить макропрогноз. Напротив, макроподходы подразумевают работу сразу с агрегированными показателями [17]. Простейшим примером здесь является частотный анализ. Идея, предложенная в [17], состоит в том, что уровень поддержки кандидата/партии пропорционален числу его/ее упоминаний в ОСС. Более продвинутый подход состоит в учете эмоционального окраса контекста, в котором находится упоминание [18]. Еще один метод состоит в мониторинге числа подписчиков аккаунтов политиков/партий в ОСС: больше подписчиков – больше голосов.

В данной работе используется микроподход. Его преимуществом является большая информативность, использующая высокую персонализированность ОСС.

Дальнейшее изложение построено следующим образом. В разделе 3 дано описание предлагаемой нами методологии. В разделе 4 продемонстрировано, каким образом построенные алгоритмы могут быть использованы в научных и прикладных задачах. В силу ограничений на объем публикации, некоторые технические детали опущены или изложены кратко. Для более подробного ознакомления с ними см. “Вспомогательные_Материалы.docx” [19]. В том же репозитории находятся файлы с данными и код, необходимые для воспроизведения результатов.

3. Методы

3.1. Краткий обзор методологии. Задачу предсказания политических взглядов мы сводим к задаче классификации относительно заранее заданного политического спектра [20]. Для построения, настройки, тестирования и отбора моделей классификаторов мы используем базу данных из размеченных пользователей сети ВКонтакте. Чтобы продемонстрировать применимость предлагаемого подхода к задаче мониторинга общественного мнения, мы апробируем ее на 22 млн выборке валидных российских пользователей,

информация о которых была собрана за месяц до выборов Президента РФ 2018. Тем самым, мы имеем возможность сопоставить полученный прогноз с результатами выборов.

3.2. Базы данных. В исследовании используются две базы данных. Первая (БД1) содержит пользователей, чьи политические взгляды считаются известными; на ней модели машинного обучения обучаются и тестируются. Вторая (БД2) состоит из 22288537 млн валидных (посещающих Вконтакте хотя бы раз в месяц) аккаунтов россиян старше 18 лет. Применяя алгоритм (1) к этой выборке, мы получаем оценку распределения симпатий российских пользователей в преддверии выборов.

3.2.1. БД1. БД1 конструируется следующим образом. Согласно теории селективной экспозиции, человек предпочитает получать информацию, несущую в себе идеологию, близкую к его собственным взглядам [21–23]. Поэтому мы предполагаем, что подписчики политических аккаунтов являются сторонниками политических фигур, деятельности которых посвящены эти аккаунты. К примеру, пользователь, подписанный на официальный аккаунт В.В. Жириновского, скорее всего является его сторонником.

Далее мы фиксируем следующий политический базис: В.В. Путин, П.Н. Грудинин, В.В. Жириновский и А.А. Навальный. Таким образом, рассматривается задача классификации с 4 классами. Иными словами, пространство P в (1) состоит из четырех элементов, которые мы формализуем с помощью натуральных чисел следующим образом: класс 1 – сторонники П.Н. Грудинина, класс 2 – сторонники В.В. Жириновского, 3 – сторонники А.А. Навального, класс 4 – сторонники В.В. Путина:

$$P = \{1, 2, 3, 4\}. \quad (2)$$

Остальные политические фигуры в силу малого числа подписчиков их аккаунтов-представителей не рассматриваются. Тем самым, мы не учитываем, к примеру, таких политических игроков, как К.А. Собчак или Г.А. Явлинский. (Впрочем, предварительные эксперименты показали, что сторонники К.А. Собчак и Г.А. Явлинского мало отличимы от сторонников А.А. Навального с точки зрения нашего подхода.) Еще одним важным ограничением такого пространства мнений является тот факт, что, рассматривая набор классов (2), мы неявно предполагаем, что все пользователи должны иметь четко выраженные политические взгляды (без нейтральных и протестных мнений). Распределение пользователей БД1 по классам представлено в табл.1. Вся информация была выкачана в обезличенном виде 10 февраля 2018 года.

Таблица 1. Численность классов БД1.

Класс 1	Класс 2	Класс 3	Класс 4	Всего пользователей
92632	92144	93951	138551	417278

3.2.2. БД2. Для создания БД2 20 февраля 2018 года был получен список всех пользователей ВКонтакте старше 18 лет, которые на момент запроса пользовались данной платформой хотя бы раз за последний месяц и указали РФ в качестве страны, где они живут. Дата выкачки данных – 20 февраля 2018.

3.3. Пространство признаков.

3.3.1. Выбор признаков. Под признаками понимаются свойства аккаунтов, которые в дальнейшем будут закодированы специальным образом [20,24]. В результате этой процедуры формируется числовая матрица объектов-признаков, строкам которой соответствуют свойства аккаунтов. Основным фактором успешного решения поставленной задачи является выбор наиболее информативных характеристик аккаунтов. Мы использовали следующие признаки:

1. Подписки на *интересные страницы*¹ (далее – ИС: *публичные страницы* и аккаунты *популярных пользователей* – тех, у кого более 1000 подписчиков), которые считаются² основными источниками информации в ВКонтакте.

2. Выбранные пользователем политические взгляды в соответствии с его самооценкой из списка, предлагаемого платформой (они полностью отличаются от рассматриваемого нами базиса, см. [19], раздел 3).

Также в целях анализа мы выкачали пол и возраст пользователей.

В соответствии с теорией селективной экспозиции, подписки на информационные источники потенциально являются чрезвычайно информативным типом признаков. В частности, в смежных работах [13,14] подход, основанный на использовании *только* подписок пользователя, был успешно использован для решения аналогичной задачи. Чтобы учесть *ограниченное внимание* пользователя [25] и *алгоритмы ранжирования контента*, которые использует ВКонтакте³, мы скачиваем только первые 200 ИС пользователя, не рассматривая остальные.

Определение 1. Надежностью признака будем называть относительную частоту его присутствия на страницах пользователей (в случае, если она не скрыта настройками приватности).

¹ “Интересные страницы” – это название поля, используемое платформой ВКонтакте

² Согласно https://vk.com/page-64975608_48466494, <http://online-vkontakte.ru/2015/12/publik-ili-gruppa-vkontakte.html>, <https://vk.com/@live-club-vs-public>

³ См., к примеру, <https://vk.com/blog/newsfeed-algorithms>

К примеру, в рамках БД1 примерно у 22 процентов пользователей нет ни одной подписки на ИС – надежность признака ИС равна 77.9 процентов (см. табл.2). С другой стороны, политические взгляды пользователей также способствуют росту качества классификации (пусть и незначительному – см. [19], раздел 11) в рамках БД1. В то время как ИС пользователей является относительно надежными признаками, признак “политические взгляды”, хоть и видится чрезвычайно важным в контексте рассматриваемой задачи, но намного реже заполняется пользователями и, следовательно, не является надежным источником для построения прогноза.

Возраст и пол указаны у 36.7 и 98.2 процентов пользователей БД1 соответственно.

Таблица 2. Надежность признаков в БД1.

Тип признаков	Доля пользователей, у кого они присутствуют
ИС	0.779
Политические взгляды	0.195

3.3.2. Кодировка. Для обработки признаков используется *one-hot* кодирование [24], при котором каждый признак формализуется с помощью только нулей и единиц: создается N вспомогательных признаков, где N равняется числу всевозможных значений фокального признака. Единица, которая обязана присутствовать ровно на одном из фиктивных признаков, означает, что признак принимает именно это значение. Размерность пространства признаков после кодировки составила 2109398 – это количество уникальных интересных страниц среди пользователей БД1.

3.4. Классификаторы. В результате процедуры отбора (см. [19], раздел 6) мы выделяем две модели классификатора.

3.4.1. Логит модель. Первая – так называемая *логит модель* (логистическая регрессия, далее – ЛГ) [24]. Преимуществом данного класса классификаторов является скорость обучения, а также возможность интерпретирования результатов и, в силу линейности, относительно низкая вероятность переобучения.

Обозначим

$$\mathbf{X}^{train} = \begin{pmatrix} \mathbf{X}_1^{train} \\ \dots \\ \mathbf{X}_m^{train} \end{pmatrix} \in \mathbb{R}^{m \times n},$$

где $\mathbf{X}_i^{train} \in \mathbb{R}^{1 \times n}$ – строка, описывающая признаки i -го элемента выборки. Соответствующий вектор меток обозначим $\mathbf{y}^{train} = (y_1 \dots y_m)^T \in \mathbb{R}^m$. При

бинарной классификации полагается, что $y_i \in \{-1, 1\}$, и решается следующая оптимизационная задача:

$$\min_{\omega, \omega_0} \sum_{i=1}^m \log \{ \exp(-y_i((\mathbf{X}_i^{train}, \omega) + \omega_0)) + 1 \}, \quad (3)$$

где $\omega \in \mathbb{R}^n$ и $\omega_0 \in \mathbb{R}^1$ – коэффициенты регрессии. Как только они найдены, появляется возможность оценить апостериорную вероятность принадлежности объекта классу:

$$\Pr\{y_i = 1 | \mathbf{X}_i\} = 1 / (1 + \exp\{-y_i((\mathbf{X}_i^{train}, \omega) + \omega_0)\}) = 1 - \Pr\{y_i = -1 | \mathbf{X}_i\}. \quad (4)$$

Работая с многоклассовой задачей классификации (в нашем случае $l=4$), мы сводим ее к бинарной с помощью схемы One-vs-Rest [24], в рамках которой обучается l классификаторов, каждый из которых учится отличать объекты соответствующего класса от объектов всех остальных классов в совокупности. При классификации объекта выбирается класс, соответствующий наибольшей вероятности в (4).

Чтобы избежать переобучения, используется L2-регуляризация с коэффициентом $C = 0.1$, в рамках которой вместо (3) минимизируется модифицированная функция потерь:

$$C \sum_{i=1}^m \log \{ \exp(-y_i((\mathbf{X}_i^{train}, \omega) + \omega_0)) + 1 \} + \frac{1}{2} (\omega, \omega).$$

Результаты, которые показывает ЛГ на тестовой выборке, приведены на рис. 1.




Рис.1. Матрицы ошибок (см. [19], раздел 5) для ЛГ (слева) и НС (справа). Средняя полнота: 0.613 и 0.638 соответственно.

3.4.2. Нейронная сеть. Другая модель – *многослойный перцептрон* (разновидность нейронной сети [26], далее – НС, показывает большую среднюю полноту (см. [19]), однако дольше обучается, трудно интерпрети-

руема и имеет тенденцию к переобучению. Построенный классификатор в ходе обучения *методом обратного распространения* ошибки решает следующую оптимизационную задачу:

$$\min_{\text{веса}} -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^l \mathbf{1}_{\{y_i=j\}} * \log \{\text{Pr}_{\text{model}}(y_i = j)\},$$

где $\mathbf{1}_{\{y_i=j\}}$ – индикаторная функция события $y_i = j$, $\text{Pr}_{\text{model}}(y_i = j)$ – апостериорная вероятность того, что класс пользователя i равен j , генерируемая НС, а минимизация происходит за счет настройки весов НС, зашитых в ее архитектуру, представленную в табл.3. Необходимо отметить, что для данной функции потерь $y_i \in \{1, 2, 3, 4\}$. Чтобы преодолеть проблему переобучения, для каждой из *эпох обучения* мы анализируем, как НС классифицирует тестовую выборку в данный момент и в итоге выбираем ту конфигурацию, которая отвечает наибольшей средней полноте.

Таблица 3. Архитектура НС.

Тип	Многослойный перцептрон
Число внутренних слоев	2
Число нейронов на входном слое ⁴	100
Число нейронов на выходном слое	4
Число нейронов на внутренних слоях	20, 10
Активаторные функции	На выходном слое – softmax, на остальных – relu
Алгоритм обучения	Метод обратного распространения ошибки
Функция потерь	Кросс-энтропия
Число эпох обучения	100

В результате классификации пользователя i на выходном слое генерируются четыре числа, которые иногда трактуются как вероятности принадлежности объекта соответствующим классам:

$$\mathbf{c}_i = (c_{i1}, c_{i2}, c_{i3}, c_{i4}), \quad (5)$$

в котором, компонента $c_{ij} \geq 0$. При этом $c_{i1} + c_{i2} + c_{i3} + c_{i4} = 1$. Далее, после дискретизации, выбирается тот класс $j_i \in \{1, 2, 3, 4\}$, которому соответствует наибольшая компонента вектора \mathbf{c}_i :

⁴ Число нейронов на входном слое равно числу признаков, однако после применения процедуры снижения размерности (см. [18], раздел 10) размерность пространства признаков уменьшилась с 2109398 до 100.

$$j_i = \arg \max_j c_{ij}. \tag{6}$$

Стоит отметить, что вероятности (4) также могут быть приведены к виду (5) при соответствующей нормировке. В таком случае их можно интерпретировать по аналогии.

3.5. Результаты ЛГ и НС в рамках БД1. Качество классификации моделей ЛГ и НС представлено на рис.2. Исходя из матриц ошибок, можно сделать вывод, что классификаторы достаточно успешно отличают сторонников В.В. Путина от пользователей других классов, в то время как уловить различия между этими классами – гораздо более трудная задача. Таким образом, если предположить, что искомая зависимость в БД1 и БД2 одна и та же и она *обнаружена* классификаторами, то наиболее точным будет прогноз числа пользователей, симпатизирующих В.В. Путину и, следовательно, числа пользователей, поддерживающих других кандидатов.

4. Результаты анализа БД2

В данном разделе мы демонстрируем применимость нашей методологии к мониторингу общественного мнения.

4.1. Агрегированная оценка общественного мнения. База БД2 была обработана с помощью ЛГ и НС (при формализации данных БД2 использовались те же процедуры, что и для БД1, включая отсеивание аномалий – в результате осталось 11820412 аккаунтов). Агрегируя результаты классификации, получаем показатели, представленные в табл.4.

Таблица 4. Оценка распределения симпатий пользователей БД2.

	ЛГ	НС	Итоги выборов	Экзитпол-нормировка
В.В. Путин	0.527	0.38	0.767	0.706
П.Н. Грудинин	0.256	0.168	0.118	0.117
В.В. Жириновский	0.123	0.228	0.057	0.08
А.А. Навальный	0.094	0.224	None	None
Другие	None	None	0.058	0.097

Использование подобных оценок для оценивания итогов выборов не совсем корректно. Например, потому, что А.А. Навальный не участвовал в них. Кроме того, необходимо учитывать фактор явки, нерепрезентативность пользователей ВКонтакте по отношению к населению страны в целом, а также тот факт, что электоральное поведение не всегда совпадает с симпатиями голосующего.

Однако если интерпретировать полученные показатели как оценку ре-

зультатов выборов (сравнивая их с официальными результатами), рассматривая тех пользователей БД1, которых классификаторы определили сторонниками А.А. Навального как голоса, полученные не рассматриваемыми нами кандидатами в совокупности, то оценка, сделанная ЛГ, правильно расставляет первые три места. При этом средняя абсолютная ошибка составляет 0.12. Напротив, прогноз НС правильно расставляет только первое место, средняя абсолютная ошибка равна 0.194. Кроме того, используя возрастные паттерны голосующих, полученные через результаты экзитпола⁵, мы построили распределение голосов при условии, возрастной состав голосующих совпадает с возрастным составом БД2. В этом случае распределение мест остается неизменным, а средняя абсолютная ошибка для ЛГ и НС составляет 0.09 и 0.163 соответственно.

4.2. Анализ демографических и географических паттернов. Как уже говорилось в разделе 3.1, микроподход позволяет извлекать дополнительную информацию из результатов классификации. Рассмотрим возрастные особенности построенных оценок. На рис.2 показано, как меняется уровень поддержки П.Н. Грудина, В.В. Жириновского, А.А. Навального и В.В. Путина в зависимости от возраста (согласно ЛГ и НС). При построения этих графиков мы для большей достоверности исключили пользователей, указавших свой возраст старше 80 лет.




Рис.2. Агрегированные результаты классификации ЛГ по возрастам с нормировкой (слева) и без нормировки (справа). Аналогичные графики для НС представлены в [19], раздел 13.

Кроме того, можно анализировать и географические паттерны классификации. Пользователи в своих профилях могут указывать родной город, а также текущий город проживания. Имея в руках подобную информацию, в предположении, что в БД2 данная информация указана пользователями честно, можно проранжировать города в соответствии с уровнем поддержки

⁵ https://wciom.ru/fileadmin/file/reports_conferences/2018/2018-03-18_vybory2018.pdf

В.В. Путина. В табл.5 приведены пять городов с наибольшими и наименьшими показателями соответственно⁶.

Таблица 5.

	ЛГ		НС	
	Город	Уровень поддержки	Город	Уровень поддержки
Наибольшие показатели	Каспийск	0.737	Каспийск	0.587
	Кизляр	0.728	Кизляр	0.584
	Махачкала	0.717	Махачкала	0.567
	Хасавюрт	0.71	Донецк	0.563
	Владикавказ	0.7	Дербент	0.563
Наименьшие показатели	Санкт-Петербург	0.433	Санкт-Петербург	0.278
	Дубна	0.435	Дубна	0.292
	Долгопрудный	0.44	Кондопога	0.314
	Москва	0.454	Петрозаводск	0.317
	Королёв	0.466	Сосновый Бор	0.318

В качестве городов использовались текущие города проживания, имеющие не менее 3000 представителей в БД2. Наличие в полной версии таблицы городов, не входящих в состав РФ (например, Донецк), связано с тем, что пользователь при регистрации может указать страну, в которой на самом деле не проживает. Аналогично для текущих городов проживания.

4.3. Анализ апостериорных вероятностей. В разделах 4.1 и 4.2 представлены результаты классификации, полученные с помощью дискретизации показателей (4), (5). Однако можно построить альтернативную оценку. Компоненту c_{ij} вектора (5) можно трактовать как вероятность того, что пользователь i принадлежит классу j . В таком случае, $\sum_i c_{ij}$ можно интерпретировать как математическое ожидание числа представителей класса j . В табл.6 представлены соответствующие результаты. Их отличие от результатов, приведенных в табл.4, состоит в том, что пользователи, которые классифицируются *неуверенно* (при дискретизации приходится находить максимум из мало отличающихся чисел: $c_{i1} \approx c_{i2} \approx c_{i3} \approx c_{i4}$), дают примерно равный вклад в каждую из сумм.

Необходимо отметить, что предложенная трактовка носит достаточно условный характер и должна быть использована с большой осторожностью. С точки зрения теории машинного обучения, описанные апостериорные ве-

⁶ Полные версии таблиц см. в [19], папка “finished_BD2”.

роятности дают *нормированную оценку удаленности* классифицируемых объектов от *границы класса* [24]. В связи с этим, более содержательным вопросом является изучение их динамики.

Таблица 6. Оценка распределения доверия пользователей БД2 на основе апостериорных вероятностей.

	Класс 1	Класс 2	Класс 3	Класс 4
ЛГ	0.22	0.217	0.212	0.352
НС	0.202	0.233	0.245	0.319

4.3.1. Случай непрерывного пространства мнений. Числа в (5) можно использовать как оценку взглядов пользователей, рассматривая их с точки зрения агентных моделей динамики мнений [6], [11], а именно для тех моделей, которые используют непрерывные пространства мнений.

Например, можно рассмотреть пространство мнений, формализуемое строкой из четырех неотрицательных чисел, в сумме составляющих единицу, которые визуализируют политические предпочтения индивида относительно выбранного нами политического базиса (П.Н. Грудинин, В.В. Жириновский, А.А. Навальный и В.В. Путин). К примеру, строка $\mathbf{p}=(0 \ 1 \ 0 \ 0)^T$ означает, что агент является ярым сторонником В.В. Жириновского, а агент с мнением $\mathbf{p}=(0.25 \ 0.25 \ 0.25 \ 0.25)^T$ не знает, кому отдать свои предпочтения (здесь может подразумеваться как ситуация, когда он не имеет своих политических взглядов, так и случай, когда он ко всем относится одинаково отрицательно). В таком случае для оценки \bar{p}_i мнения \mathbf{p}_i пользователя i можно использовать строку \mathbf{c}_i с апостериорными вероятностями, генерируемыми классификаторами ЛГ и НС:

$$\bar{\mathbf{p}}_i = \mathbf{c}_i.$$

Как было отмечено, результаты, полученные ЛГ и НС, наиболее достоверны применительно к определению принадлежности пользователя к классу 4 (является сторонником В.В. Путина/ не является). В связи с этим, наиболее содержательной частью вектора \mathbf{c}_i являются компонента c_{i4} и конструкция $\max\{c_{i1}, c_{i2}, c_{i3}\}$. В связи с этим, целесообразно рассмотреть пространство мнений, формализуемое отрезком $[0,1]$, в котором единица соответствует максимальной поддержке В.В. Путина, ноль – минимальной, а $1/2$ – состоянию максимальной неопределенности. Мнение агента i обозначим p_i .

В данной работе для оценки \bar{p}_i мнения p_i агента i предлагается использовать следующую конструкцию:

$$\bar{p}_i = \frac{c_{i4}}{c_{i4} + \max\{c_{i1}, c_{i2}, c_{i3}\}}. \quad (7)$$

Графики распределений, которые порождает оценка (7), представлены в [18], раздел 12.

4.3.2. Случай дискретного пространства мнений. Необходимо отметить, что метки классов, полученные в результате дискретизации (6), можно адаптировать для калибровки мнений агентов в моделях социального влияния, использующих дискретные пространства мнений, которые по своей структуре сходны рассматриваемому нами политическому спектру (2) [27].

4.3.3. Применение. Зафиксируем множество пользователей I_0 . Применив к нему отображение (1) в момент времени t , получим матрицу $\mathbf{C}(t)$, состоящую из строк (5), которую, как было показано до этого, можно использовать для оценивания мнений пользователей. Полученную в результате соответствующих преобразований матрицу (или просто вектор) $\bar{\mathbf{P}}(t)$, используемый для оценки мнений пользователей, принято называть снимком (снимком) мнений пользователей в момент времени t [28].

Собирая снимки мнений пользователей, можно анализировать их текущее состояние, а также их динамику с позиции указанных выше моделей динамики мнений, а также других подходов, например, *моделей информационного противоборства* [29–33]. Кратко перечислим список возможных направлений для исследований в данной области: 1) сетевой анализ (изучения связи мнений пользователей с топологией графа дружбы ВКонтакте – анализ ассортативности); 2) определение влияния окружения пользователя в ОСС на динамику его взглядов; 3) задача *восстановления* сети влияния по серии имеющихся снимков; 4) прогнозирование динамики общественного мнения на основании имеющейся серии снимков.

5. Заключение

Построенные нами модели для оценивания политических взглядов пользователей открывают широкий спектр возможностей и могут быть использованы как в научных (калибровка мнений моделей социального влияния), так и прикладных (мониторинг общественного мнения) сферах. Дальнейшие наши исследования будут посвящены анализу динамики общественного мнения.

СПИСОК ЛИТЕРАТУРЫ

1. *L. Phillips, C. Dowling, K. Shaffer, N. Hodas, and S. Volkova.* Using social media to predict the future: a systematic literature review // ArXiv Prepr., 2017, ArXiv170606134.
2. *Д.А. Губанов, А.Г. Чхартушвили.* Концептуальный подход к анализу онлайн-социальных сетей // Управление большими системами: сборник трудов, 2013, №45; англ. пер.: *D.A. Gubanov, A.G. Chkhartishvili.* A conceptual approach to online social networks analysis // Automation and Remote Control, 2015, v.76, №8, p.1455-1462.
3. *M. Kosinski, D. Stillwell, T. Graepel.* Private traits and attributes are predictable from digital records of human behavior // Proceedings of the National Academy of Sciences, 2013, v.110, №15, p.5802-5805.
4. *H. Schoen, D. Gayo-Avello, P. Takis Metaxas, E. Mustafaraj, M. Strohmaier, & P. Gloor.* The power of prediction with social media // Internet Research, 2013, v.23, №5, p.528-543.
5. *R.I. Dunbar, V. Arnaboldi, M. Conti & A. Passarella.* The structure of online social networks mirrors those in the offline world // Social Networks, 2015, v.43, p.39-47.
6. *A.V. Proskurnikov, R. Tempo.* A tutorial on modeling and analysis of dynamic social networks. Part I // Annual Reviews in Control, 2018.
7. *А.А. Белолипецкий, И.В. Козицин.* Динамический вариант математической модели коллективного поведения // Известия Российской академии наук. Теория и системы управления, 2017, №3, с.47-58; англ. пер.: *A.A. Belolipetskii, I.V. Kozitsin.* Dynamic variant of mathematical model of collective behavior // Journal of Computer and Systems Sciences International, 2017, v.56, №3, p.385-396.
8. *И.В. Козицин.* Обобщение модели Краснощечекова на случай разложимой матрицы социальных связей // Математическое моделирование, 2017, т. 29, №12, с.3-15; англ. пер.: *I.V. Kozitsin.* Generalization of Krasnoshchekov's model for the case of a decomposable matrix of social interactions // Mathematical Models and Computer Simulations, 2018, v.10, №4, p.398-406.
9. *I.V. Kozitsin, A.A. Belolipetskii.* Opinion convergence in the Krasnoshchekov model // The Journal of Mathematical Sociology, 2018, p.1-18.
10. *П.С. Краснощечков.* Простейшая математическая модель поведения. Психология конформизма // Математическое моделирование, 1998, v.10, №7, с.76-92; *P.S. Krasnoshchekov.* Prosteishaiia matematicheskaia model povedeniia. Psikhologiia konformizma // Matematicheskoe modelirovanie, 1998, v.10, №7, s.76-92.
11. *A.V. Proskurnikov, R. Tempo.* A tutorial on modeling and analysis of dynamic social networks. Part II // Annual Reviews in Control, 2018.
12. *Е.Д. Корнилина, А.П. Петров.* Динамическая модель близости позиций пользователей социальных сетей // Математическое моделирование, 2012, т.24, №10, с.89-97; англ. пер.: *E.D. Kornilina, A.P. Petrov.* Dynamic model of proximity of positions of social network users // Mathematical Models and Computer Simulations, 2013, v.5, №3, p.213-219.
13. *P. Barberá.* How social media reduces mass political polarization. Evidence from Germany, Spain, and the US // Job Market Paper, New York University, 2014, v. 46.
14. *P. Barberá.* Birds of the same feather tweet together: Bayesian ideal point estimation using Twitter data // Political Analysis, 2015, v. 23, №1, p.76-91.

15. R. Cohen, D. Ruths. Classifying political orientation on Twitter: It's not easy! // ICWSM, 2013.
16. А.П. Михайлов, В.А. Шведовский, А.И. Маслов, В.Ф. Ковалев. Обобщенная модель электорального поведения и ее применение к изучению этнополитических конфликтов // Математическое моделирование, 2003, т.15, №8, с.39-56;
A.P. Mikhailov, V.A. Shvedovskii, A.I. Maslov, V.F. Kovalev. Obobshchennaia model elektoralnogo povedeniia i ee primenenie k izucheniiu etnopoliticheskikh konfliktov // Matematicheskoe modelirovanie, 2003, t.15, №8, s.39-56.
17. A. Tumasjan, T.O. Sprenger, P.G. Sandner & I.M. Welpe. Predicting elections with twitter: What 140 characters reveal about political sentiment // In Fourth international AAAI conference on weblogs and social media, 2010.
18. A. Boutet, H. Kim, E. Yoneki. What's in Twitter, I know what parties are popular and who you are supporting now! // Social Network Analysis and Mining, 2013, v.3, №4, .1379-1391.
19. <https://dataverse.harvard.edu/privateurl.xhtml?token=f30ac99c-98b3-49c5-ac6a-b321b1f35f37>.
20. P. Flach. Machine learning: the art and science of algorithms that make sense of data. – Cambridge University Press, 2012.
21. D. Frey. Recent research on selective exposure to information // Advances in experimental social psychology. – Academic Press, 1986, v.19, p.41-80.
22. A. Chkhartishvili, I. Kozitsin. Binary Separation Index for Echo Chamber Effect Measuring // 2018 Eleventh International Conference "Management of large-scale system development". -IEEE, 2018, p.1-4.
23. K. Garimella, G. De Francisci Morales, A. Gionis & M. Mathioudakis. Political discourse on social media: Echo chambers, gatekeepers, and the price of bipartisanship // Proceedings of the 2018 World Wide Web Conference on World Wide Web. – International World Wide Web Conferences Steering Committee, 2018, p.913-922.
24. В. Вьюгин. Математические основы машинного обучения и прогнозирования. – Litres, 2017;
V. Viugin. Matematicheskie osnovi mashinnogo obuchenia & prognozirovania. – Litres, 2017.
25. L. Weng, A. Flammini, A. Vespignani & F. Menczer. Competition among memes in a world with limited attention // Scientific reports, 2012, v.2, p.335.
26. I. Goodfellow, Y. Bengio & A. Courville. Deep learning. MIT press, 2016.
27. C. Castellano, D. Vilone, A. Vespignani. Incomplete ordering of the voter model on small-world networks // EPL (Europhysics Letters), 2003, v.63, №1, p.153.
28. V. Amelkin, P. Bogdanov, A.K. Singh. A distance measure for the analysis of polar opinion dynamics in social networks // Data Engineering (ICDE), 2017 IEEE 33rd International Conference on. -IEEE, 2017, p.159-162.
29. А.П. Михайлов, А.П. Петров, Н.А. Маревцева, И.В. Третьякова. Развитие модели распространения информации в социуме // Математическое моделирование, 2014, т.26, №3, с.65-74;
англ. пер.: A.P. Mikhailov, A.P. Petrov, N.A. Marevtseva, I.V. Tretiakova. Development of a Model of Information Dissemination in Society // Mathematical Models and Computer Simulations, 2014, v.6, №5, p.535-541.
30. А.П. Петров, А.И. Маслов, Н.А. Цаплин. Моделирование выбора позиций индивидами при информационном противоборстве в социуме // Математическое моделирование, 2015, т.27, №12, с.137-148;

- англ. пер.: *A.P. Petrov, A.I. Maslov, N.A. Tsaplin*. Modeling Position Selection by Individuals during Information Warfare in Society // *Mathematical Models and Computer Simulations*, 2016, v.8, №4, p.401-408.
31. *A.P. Petrov, O.G. Proncheva*. Modeling Propaganda Battle: Decision-Making, Homophily, and Echo Chambers // *Ustalov D., Filchenkov A., Pivovarova L., Žižka J. (eds) Artificial Intelligence and Natural Language. AINL 2018. Communications in Computer and Information Science*, v.930. Springer, Cham, 2018, p.197-209.
32. *А.П. Михайлов, А.П. Петров, Г.Б. Прончев, О.Г. Прончева*. Моделирование спада общественного внимания к прошедшему разовому политическому событию // *Доклады Академии наук*, 2018, т.480, №4, с.397-400;
англ. пер.: *A.P. Mikhailov, A.P. Petrov, G.B. Pronchev & O.G. Proncheva*. Modeling a Decrease in Public Attention to a Past One-Time Political Event. *Doklady Mathematics*, 2018, v.97, №3, p.247–249.
33. *А.П. Михайлов, Н.А. Маревцева*. Модели информационной борьбы // *Математическое моделирование*, 2011, т.23, №10, с.19-32;
англ. пер.: *A.P. Mikhailov and N.A. Marevtseva*. Models of Information Warfare // *Mathematical Models and Computer Simulations*, 2012, v.4, №3, p.251-259.

Поступила в редакцию 21.01.19

После доработки 21.03.19

Принята к публикации 08.04.19