

## КОМПЬЮТЕРНЫЕ СИСТЕМЫ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ COMPUTER SCIENCE

doi: 10.17586/2226-1494-2021-21-1-85-91

УДК 004.85

### Построение психологического портрета человека с применением технологий обработки естественного языка

Татьяна Михайловна Татарникова<sup>1✉</sup>, Павел Юрьевич Богданов<sup>2</sup>

<sup>1,2</sup> Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 190000, Российская Федерация

<sup>2</sup> Российский государственный гидрометеорологический университет, Санкт-Петербург, 192007, Российская Федерация

<sup>1</sup> [Tm-tatarn@yandex.ru](mailto:Tm-tatarn@yandex.ru)✉, <http://orcid.org/0000-0002-6419-0072>

<sup>2</sup> [45bogdanov@gmail.com](mailto:45bogdanov@gmail.com), <http://orcid.org/0000-0002-7533-7316>

#### Аннотация

**Предмет исследования.** Предложено решение по автоматическому построению психологического портрета человека на основе анализа его речевого поведения. Показано, что для формирования тренировочного набора данных могут использоваться сообщения в социальных сетях, мессенджерах, чатах, как в формате текстовых сообщений, так и аудио- и видеозвонок. Раскрыты функции составляющих классификатора психотипов по речевому поведению человека. Выполнено сравнение между мультиклассовой и бинарной классификациями, исходя из минимизации функции потерь. **Методы.** Психологический портрет соответствует типологии Майерс–Бриггс, согласно которому человек может быть отнесен к одному из 16 типов. Привлечены технологии Text Mining для обработки естественного языка и модель глубокого обучения для обработки речи. Набор данных для обучения и тестирования сформирован записями речи людей, переведенной в текстовый формат. Метки классов формируются содержимым вектора параметров текста, который представляет собой словарь часто встречаемых слов. Для автоматического построения психологического портрета человека применяется алгоритм глубокого обучения на базе рекуррентных нейронных сетей типа LSTM. Алгоритм опробован как для мультиклассовой, так и бинарной классификации. Объективность предлагаемого подхода к построению психологического портрета обеспечивается наличием разнообразного контента, созданного человеком в разное время в соответствии с жизненными ситуациями, профессией, увлечениями и другими обстоятельствами. **Основные результаты.** Предложен новый подход к автоматическому построению психологического портрета человека, основанный на бинарной классификации и модели глубокого обучения. Продемонстрирована сходимость результатов бинарной классификации с тестовым множеством речевого поведения разных людей. Использование сети LSTM в бинарной классификации позволило достичь точности 83 % правильного определения психотипа и снизить потери до 25 %. **Практическая значимость.** Автоматическое построение психологического портрета человека по его речевому поведению помогает разным специалистам: психологам, социологам, кадровым работникам в принятии решений при работе с конкретным человеком. Метод анализа личных качеств человека по его речевому поведению доведен до программной реализации.

#### Ключевые слова

психологический портрет человека, речевое поведение, обработка естественного языка, классификация по типу темперамента, Text Mining, машинное обучение, глубокое обучение

**Ссылка для цитирования:** Татарникова Т.М., Богданов П.Ю. Построение психологического портрета человека с применением технологий обработки естественного языка // Научно-технический вестник информационных технологий, механики и оптики. 2021. Т. 21, № 1. С. 85–91. doi: 10.17586/2226-1494-2021-21-1-85-91

### Human psyche creation by application of natural language processing technologies

Tatiana M. Tatarnikova<sup>1✉</sup>, Pavel Yu. Bogdanov<sup>2</sup>

<sup>1,2</sup> Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 190000, Russian Federation

<sup>2</sup> Russian State Hydrometeorological University (RSHU), Saint Petersburg, 192007, Russian Federation

<sup>1</sup> [Tm-tatarn@yandex.ru](mailto:Tm-tatarn@yandex.ru)✉, <http://orcid.org/0000-0002-6419-0072>

<sup>2</sup> [45bogdanov@gmail.com](mailto:45bogdanov@gmail.com), <http://orcid.org/0000-0002-7533-7316>

© Татарникова Т.М., Богданов П.Ю., 2021

### Abstract

**Subject of Research.** The paper proposes a solution for the human psyche automatic creation based on his speech behavior analysis. It is shown that messages in social networks, instant messengers and chats can be used to form a training data set, both in the format of text messages and audio and video calls. The functions of the psychological type classifier constituents are revealed by the human speech behavior. A comparison is made between multiclass and binary classification based on the loss function minimization. **Methods.** The human psyche corresponded to the Myers-Briggs type indicator, which subsumes a person to one of 16 types. The technologies of Text Mining for natural language processing and a deep learning model for speech processing were used. The data set for training and testing was formed by recordings of people's speech translated into text format. Class labels were formed by the content of a text parameters vector, which is a dictionary of frequently encountered words. A deep learning algorithm was used for the human psyche automatic creation and was based on recurrent neural networks of the Long Short-Term Memory type. The algorithm was tested both for multiclass and binary classification. The objectivity of the proposed approach to a human psyche creation was ensured by the variety of content created by a person at various time in accordance with life situations, profession, hobbies and other circumstances. **Main Results.** A new approach to the automatic human psyche creation is proposed, based on the binary classification and a deep learning model. The convergence of the binary classification results with the test set of the speech behavior of various people is demonstrated. The Long Short-Term Memory network application in binary classification makes it possible to achieve an accuracy equal to 83 % of the psychological type correct determination and reduce the losses to 25 %. **Practical Relevance.** Automatic human psyche creation based on his speech behavior enables various specialists (such as psychologists, sociologists, human resources staff members) to make decisions when working with a specific person. Analysis of a human personal qualities by his speech behavior is software-implemented.

### Keywords

human psyche, speech behavior, natural language processing, classification by temperament type, Text Mining, machine learning, deep learning

**For citation:** Tatarnikova T.M., Bogdanov P.Yu. Human psyche creation by application of natural language processing technologies. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2021, vol. 21, no. 1, pp. 85–91 (in Russian). doi: 10.17586/2226-1494-2021-21-1-85-91

## Введение

Речевое поведение характеризует общую эрудицию человека, особенности поведения, эмоциональное состояние, интеллект. Речь является важнейшим индикатором при составлении психологического портрета человека. Знание особенностей поведения позволяет самым разным специалистам в принятии решений при работе с конкретным человеком, например: рекомендовать выбор будущей профессии; вовремя устранять или корректировать нежелательные проявления поведения; находить способы мотивации и многое другое.

Существует несколько способов построения психологического портрета человека:

- 1) специалисты-психологи, которые через изучение особенностей мышления, проявление чувств и эмоций могут определить психотип человека. Недостатком этого способа является время, необходимое специалисту для работы с пациентом и, конечно то, что к психологу обращаются только в случае возникновения жизненных проблем;
- 2) различные онлайн-тестирования, недостатком которых является отсутствие возможностей для индивидуального проявления;
- 3) способ самоопределения, который не всегда дает верные результаты.

В настоящее время люди активно общаются в социальных сетях, мессенджерах, чатах, как посредством текстовых сообщений, так и аудио- и видеозвонков. Создается и накапливается огромный контент, который может служить характеристикой речевого поведения человека. При этом контент разнообразен, поскольку связан с разными временными и жизненными ситуациями человека, его профессией, увлечениями и т. д.

В свою очередь в области искусственного интеллекта существуют технологии обработки естественного языка (Natural Language Processing, NLP), позволяющие решать множество задач, таких как машинный перевод, сентимент-анализ текста, автоматические ответы на вопросы, а также классификацию текста [1]. С помощью обработки предложений естественного языка можно классифицировать текст по темам, адресам, переданному настроению и многим другим меткам. Эти обстоятельства позволили предложить новый, можно сказать технологичный, метод построения психологического портрета человека без финансовых и временных затрат со стороны человека, и как ожидается, объективный. Безусловно есть и другие способы автоматического построения психологического портрета человека, например, по тому, как он набирает текст на клавиатуре, реагирует на изображение на экране и другие, но все они требуют времени для фиксации результатов, их накопления и обработки.

Таким образом, цель работы — разработка метода, который позволит автоматически анализировать личные качества человека по его речевому поведению. В качестве обработки речи использована технология обработки естественного языка. Для автоматического анализа речи применяется модель LSTM (Long short-term memory) – вид рекуррентной нейронной сети, способный изучать долгосрочные зависимости в данных.

## Категории классификации

Самым популярным разделением людей является разделение по типу темперамента. Данное разделение людей существует в психологии, где каждый тип характеризуется своими чертами поведения, характера,

стремлениями и желаниями. Разделение производится на четыре типа: холерики, меланхолики, сангвиники и флегматики. Популярность в настоящее время получила типология Майерс–Бриггс (Myers-Briggs Type Indicator) поскольку предоставляет более подробный портрет человека, позволяя тем самым глубже изучить и понять личность, включая симпатии, антипатии, сильные и слабые стороны, возможные карьерные предпочтения и совместимость с другими людьми [2]. Согласно этой типологии, человек может быть отнесен к одному из 16 типов (рис. 1), а каждый психотип описывается кодом из четырех букв [3]: ISTJ — Инспектор; ISTP — Изобретатель; ISFJ — Хранитель; ISFP — Посредник; INFJ — Гуманист; INFP — Романтик; INTJ — Аналитик; INTP — Критик; ESTP — Маршал(Командир); ESTJ — Администратор; ESFP — Политик; ESFJ — Энтузиаст; ENFP — Инициатор; ENFJ — Наставник; ENTP — Новатор; ENTJ — Предприниматель.

Индикатор типа состоит из четырех различных шкал [3].

1. Шкала E–I (Extraversion (Экстраверсия) — Introversion (Интроверсия)). Экстраверты являются ориентированными на действия, социальное общение, заряжаются энергией после общения с другими людьми. Интроверты ориентированы на размышления, глубокое и значимое социальное взаимодействие и заряжаются энергией после проведения времени в одиночестве.
2. Шкала S–N (Sensing (Ощущение) — Intuition (Интуиция)). Люди, предпочитающие чувства, уделяют большое внимание реальности, особенно тому, чему они могут научиться с помощью собственных чувств. Они, как правило, сосредотачиваются на фактах и деталях и принимают решения, исходя из практического опыта. Те, кто предпочитает интуицию, уделяют больше внимания ощущениям и впечатлениям. Им нравится думать о возможностях, воображать будущее и принимать решения, опираясь на абстрактные теории.
3. Шкала T–F (Thinking (Мышление) — Feeling (Чувство)) фокусируется на том, как люди принимают

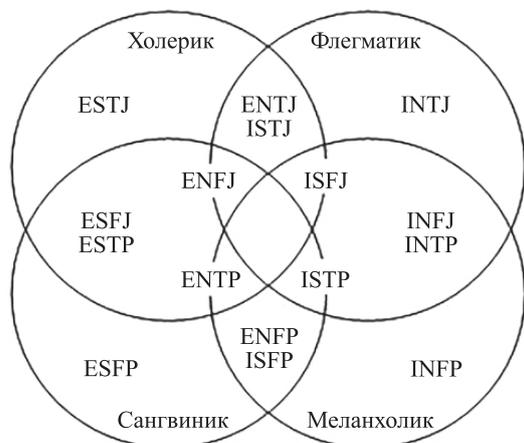


Рис. 1. Психотипы по Майерс–Бриггс  
Fig. 1. Psychological types according to Myers-Briggs

решения, основываясь на информации, полученной ими в результате своих ощущений или интуитивных функций. Это люди, которые уделяют больше внимания фактам и объективным данным — предпочитают думать. Они склонны быть последовательными, логичными и беспристрастными при выборе решений. Те, кто предпочитает чувства, чаще принимают решения, исходя из эмоций и мнения других людей.

4. Шкала J–P (Judging (Суждение) — Perceiving (Восприятие)) включает в себя то, как люди взаимодействуют с внешним миром. Те, кто склоняется к суждению, предпочитают структуру и твердые решения. Люди, склонные к восприятию, более открытые, гибкие и адаптируемые. Эти две тенденции взаимодействуют с другими шкалами. Все люди тратят некоторое время на экстраверсию. Шкала (J–P) помогает описать, как воспринимается новая информация человеком.

### Описание предлагаемого решения

Классификатор [4] психотипов по речевому поведению человека содержит следующие элементы (рис. 2):  
— тренировочный набор данных (data set);  
— вектор параметров  $\mathbf{P}_j, j = \overline{1, N}$  характеризующих классы текстов, где  $N$  — размер data set;  
— метки классов  $m_i, i = \overline{1, M}$ , где  $M$  — количество классов (от 1 до 16);  
— алгоритм машинного обучения;  
— прогнозирующая модель.

Data set сформирован записями речи людей, переведенной в текстовый формат с помощью алгоритмов распознавания речи Google Speech-to-Text — технологии перевода аудиозаписи в текст [5]. Программа может работать как с текстовыми файлами, так и с аудиофайлами формата \*.wav. Data set состоит из 16 каталогов по числу психотипов. Каждый каталог содержит корпуса текстов из социальных сетей, аудиозаписи речи знакомых людей, переведенные в текстовый формат, а также сообщения, комментарии знаменитых людей, принадлежащих к соответствующему психотипу. Значительную часть data set составляют записи из социальных сетей, поскольку общение в микроблоге, где люди выражаются простым языком, больше похоже на реальную речь. Кроме того, сообщения имеют ограниченную длину,

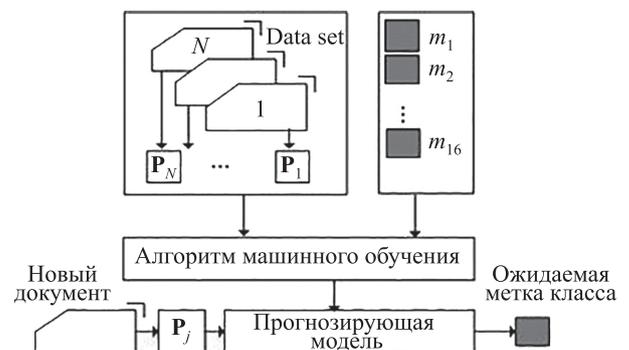


Рис. 2. Структура классификатора психотипов  
Fig. 2. Classifier structure of psychological types

что дает возможность собрать data set автоматически с помощью парсинга страниц. Сообщения на иностранном языке известных людей с предопределенным индикатором психотипа переводились на русский язык. В целом data set включает 2603 сообщения 101 человека.

Формирование вектора текста происходит в два этапа [6].

1. Применение функций технологии Text Mining: токенизация — разбиение текста на слова (токены); фильтрация — удаление ненужных слов; нормализация — приведение всех букв к одному регистру, удаление знаков препинания, пробелов; лемматизация — сведение словоформ к первоначальной базовой форме [7].
2. Формирование вектора параметров **P**. Вектор **P** представляет собой словарь часто встречаемых слов, построенный в соответствии с показателем TF-IDF (Term Frequency — Inverse Document Frequency) [8]

$$TF - IDF(t, d, D) = TF(t, d) IDF(t, D),$$

где *TF* — показатель частоты слова *t* в каждом документе *d* из корпуса объемом *D* документов; *IDF* — показатель веса редких слов во всех документах корпуса.

Показатель *TF* рассчитывается следующим образом:

$$TF(t, d) = \frac{n_t}{\sum_{k=1}^K n_k},$$

где *n<sub>t</sub>* — количество слова *t* в документе *d*; *K* — количество слов в документе *d*.

Показатель *IDF* оценивается по формуле:

$$IDF(t, D) = \log \frac{D}{DF(t)}$$

где *D* — число документов в корпусе; *DF(t)* — число документов в корпусе, которые содержат *t*.

Метки классов – словарь сопоставления каждому психотипу числового идентификатора:

ISTJ — 0000, ISTP — 0001, ISFJ — 0010, ISFP — 0011, INFJ — 0100, INFP — 0101, INTJ — 0110, INTP — 0111, ESTP — 1000, ESTJ — 1001, ESFP — 1010, ESFJ — 1011, ENFP — 1100, ENFJ — 1101, ENTP — 1110, ENTJ — 1111.

Для автоматического анализа речи с целью классификации психотипа и, соответственно, построения психологического портрета человека применяется алгоритм глубокого обучения на базе рекуррентных нейронных сетей типа LSTM [9, 10]. Алгоритм опробован как для мультиклассовой, так и бинарной классификации.

Сети LSTM — это тип рекуррентной нейронной сети, которая в скрытых слоях содержит специальные LSTM-блоки, сохраняющие информацию [9, 10]. Блок LSTM включают в себя ячейку памяти и набор вентилях, управляющих процессами ввода информации в память, вывода из памяти или забывания информации. Структура сети и блока LSTM приведены на рис. 3, где *A* — блок LSTM; *x<sub>j</sub>*, *h<sub>j</sub>* — соответственно входной и выходной вектор в момент времени *j*, *j* = 0,  $\bar{t}$ ; *i<sub>j</sub>* — вектор входного вентиля *j*-го блока LSTM — вес получения новой информации; *c<sub>j</sub>* — вектор состояний *j*-го блока LSTM; *o<sub>j</sub>* — вектор выходного вентиля *j*-го блока LSTM — кандидат на выход; *f<sub>j</sub>* — вектор вентиля забывания *j*-го блока LSTM — вес запоминания старой информации; *S* — дифференцируемая функция, например, сигмоидальная функция;  $\otimes$  — поэлементное умножение значений на входе операции.

Функция активации выходного слоя сети LSTM — нормализованная экспонента для мультиклассовой классификации — *f* и сигмоидальная функция для бинарной классификации —  $\sigma$ . Функция *f* является вектором, представляющим вероятностные распределения списка потенциальных исходов

$$f(x_j) = \frac{e^{x_j}}{\sum_j e^{x_j}}$$

где *f* — вектор, каждая координата которого равняется вещественному числу в интервале [0, 1]; *x<sub>j</sub>* — входное значение *j*-го нейрона.

Каждое значение вектора *f* является вероятностью отнесения к определенному классу. Позиция, на которой находится максимальное значение вектора, определяет метку класса *m<sub>i</sub>*, *i* = 1, *M*, к которому относится входная последовательность.

Функция  $\sigma$  возвращает одно значение «0» или «1», которое определяет предсказанный класс

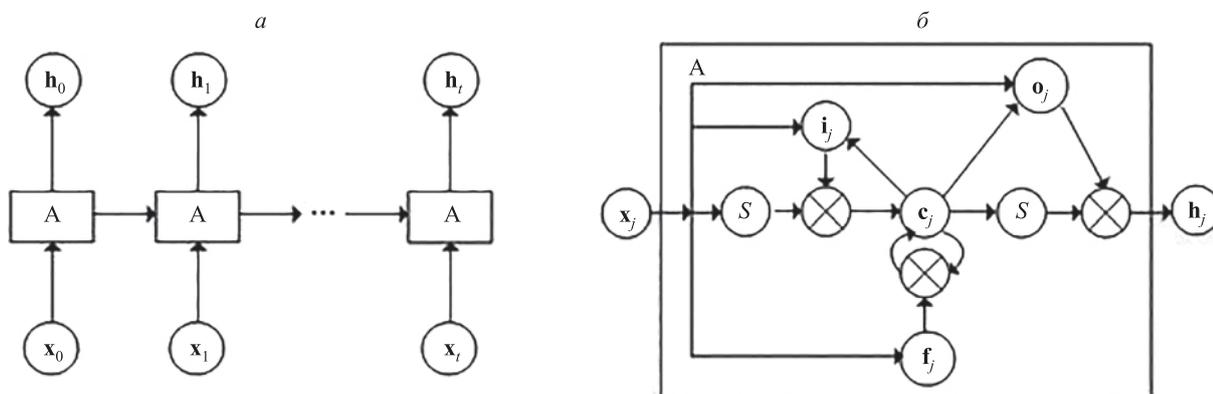


Рис. 3. Структура: сети LSTM (а); блока LSTM (б)  
Fig. 3. Structure: LSTM network (a); LSTM block (b)

$$\sigma(x) = \frac{1}{1 + e^{-x}},$$

где  $x$  — входное значение нейрона выходного слоя.

В качестве функции потерь использована категориальная перекрестная энтропия (Categorical Cross-Entropy, CCE) для мультиклассовой классификации и бинарная перекрестная энтропия (Binary Cross Entropy, BCE) для бинарной классификации [11]. Функция потерь показывает то, насколько близко предсказание модели к ожидаемому классу [12].

Категориальная перекрестная энтропия считает оценку, которая суммирует среднюю разницу между фактическим и прогнозируемым распределениями вероятностей для всех классов

$$CCE = -\sum_{i=1}^n (x_i \log(y_i)),$$

где  $y_i$  — прогнозируемое значение;  $x_i$  — истинное значение;  $n$  — размер вектора  $x_i$  ( $y_i$ ),  $n = 16$ .

Бинарная перекрестная энтропия задается уравнением:

$$BCE = -\sum_{i=1}^2 (x_i \log(y_i)) = -x_1 \log(y_1) - (1 - x_1) \log(1 - y_1),$$

где  $n = 2$ .

Гиперпараметры для алгоритма обучения определены экспериментальным путем в следующей последовательности [13]:

- 1) генерируется сетка возможных значений гиперпараметров;
- 2) выполняется случайный поиск с использованием перекрестной проверки (50 итераций);
- 3) на модели с лучшими гиперпараметрами выполняется поиск по сетке их возможных значений с использованием перекрестной проверки, центрированной по этим значениям.

Данная методология выбора гиперпараметров благодаря случайному поиску позволяет охватить более широкий диапазон значений для каждого гиперпараметра с меньшим временем выполнения поиска в сравнении с полным перебором. Как только диапазон поиска сужается, то каждая комбинация настроек гиперпараметров может быть проверена экспериментально.

Сетка гиперпараметров выглядит следующим образом:

- размер словаря: [10, 15, 20, 25];
- размер LSTM-слоя: [25, 50, 75, 100];
- число уровней: [1, 2];
- выходной слой: [2, 16];
- двунаправленность: [True, False];
- вероятность прореживания скрытого слоя [0, 2] — фиксировано для уменьшения мощности пространства гиперпараметров;
- скорость обучения: [ $10^{-3}$ ,  $10^{-2}$ ,  $10^{-1}$ ].

В итоге выбраны следующие значения гиперпараметров: размер словаря — 10, скорость обучения —  $10^{-2}$ , и получена следующая архитектура сети LSTM: число уровней — 1, размер LSTM-слоя — 100, сеть LSTM — однонаправленная.

Прогнозирующая модель представляет собой ту же LSTM-модель, на вход которой подается тестовое множество data set. Все корпуса текстов разделены случайно по количеству записей на два множества: обучающее и тестовое в соотношении 80:20 % соответственно. Наличие тестового набора данных необходимо для доказательства качества точности предсказаний модели.

### Обсуждение результатов

Известно, что при недостаточном количестве тренировочных данных модель может достичь переобучения — модель показывает приемлемые результаты на тренировочном наборе данных, но сравнительно хуже результаты на тестовом наборе данных [14, 15]. Данный случай произошел при мультиклассовой классификации. В ходе обучения LSTM-модели получена точность равная 37 %. Изменение функции точности представлено на рис. 4, а. На рис. 4, б можно заметить, что значение функции потерь для тренировочных данных снижается в процессе обучения, но для тестовых данных возрастает, что является признаком переобучения.

Для того чтобы избежать переобучения, необходимо произвести корректировку модели и data set. Корректировка не привела к заметным результатам, несмотря на предпринятые попытки [16, 17]:

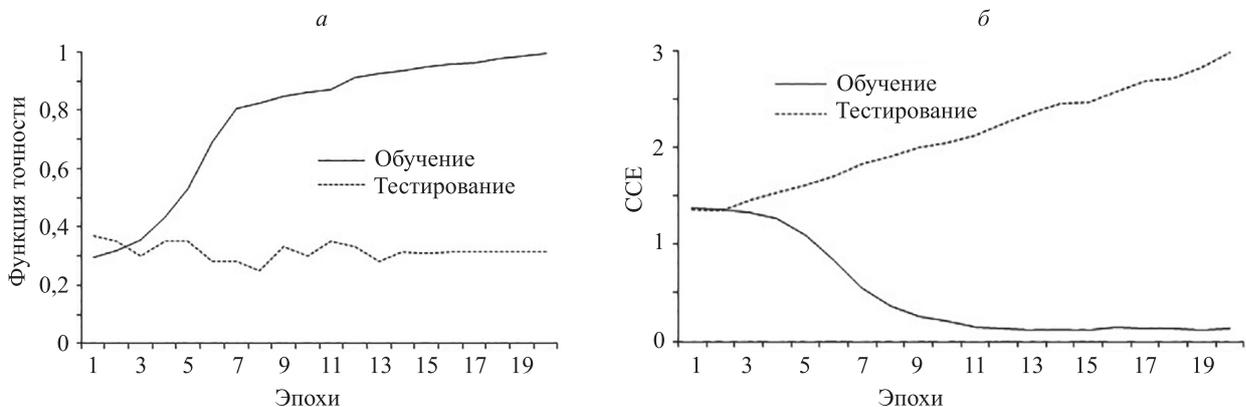


Рис. 4. Результаты мультиклассовой классификации: изменение функции точности (а) и функции потерь (б)

Fig. 4. Multiclass classification results: change in accuracy function (a) and loss function (b)

- увеличение объема data set;
- исправление опечаток и перевод транслитераций. Поскольку данные собраны из социальной сети, то в тексте часто встречаются опечатки, ошибки в словах, транслитерации, и избавиться от данного «шума» можно либо вручную, либо программно;
- изменение архитектуры сети LSTM;
- поиск семантических синонимов и сокращение расстояния между их кодировками на базе векторной модели Word2Vec.

Изменение архитектуры сети LSTM происходило в соответствии с вероятностью прореживания скрытого слоя. Это эффективный способ предотвращения переобучения моделей. Случайным образом сбрасываются некоторые соединения между слоями. Эффект заключается в замене результатов обучения на более обобщенные. Во время обучения часть нейронов на определенном слое будет деактивирована, что приводит к улучшению обобщения, так как деактивация нейронов способствует тому, что слой начинает изучать разными нейронами одну и ту же задачу.

Таким образом, были сделаны выводы о том, что мультиклассовая классификация не подходит для решения задачи построения психологического портрета человека по его речевому поведению. В данных, используемых в настоящей работе, не прослеживаются явные закономерности, и по ним нельзя точно определить принадлежность к определенному психотипу. Это происходит из-за того, что обычно классификация текста выполняется по темам, например, по заголовку статьи в газете. В нашем случае разделить речь людей, которые говорят о своей жизни, занятии и интересах становится неразрешимой задачей, поскольку на практике большинство людей используют одинаковый словарный запас.

При бинарной классификации применялся другой подход: во-первых, определялась принадлежность к каждому типу гуманист — не гуманист, романтик — не романтик, аналитик — не аналитик и т. д.; во-вторых, после выполнения 16 классификаций стали известны 16 меток, сопоставленных с психотипами. При получении нескольких положительных меток результат определялся по смежным характеристикам типов. При

возникновении ситуации, когда получены все положительные или все отрицательные метки, принималось среднее решение по 16 типам. Такой подход позволил не только увеличить точность, но и увеличить возможности для анализа характера человека, так как после классификации получена не одна метка, а все 16. При возникновении данной ситуации решение о психотипе человека принималось экспертом. На рис. 5 приведены результаты бинарной классификации на тестовом наборе данных.

Использование сети LSTM в бинарной классификации позволило достичь точности 83 % правильного определения психотипа и снизить потери до 25 %.

### Заключение

Продемонстрирована возможность применения технологий обработки естественного языка для извлечения информации о психологическом портрете человека из текстового описания. Психологический портрет соответствует типологии Майерс–Бриггс, согласно которому человек может быть отнесен к одному из 16 типов.

Реализовано два подхода к классификации текста, сгенерированного человеком – мультиклассовая и бинарная классификации. Для обучения выбрана модель LSTM-сети – модель глубокого обучения, которая эффективна при обработке естественного языка.

Результаты эксперимента и многочисленные корректировки модели и data set показали, что мультиклассовая классификация не подходит для решения задачи построения психологического портрета человека по его речевому поведению, поскольку невозможно проследить явные закономерности между психотипами и представленными корпусами текстов.

Предложен подход, основанный на бинарной классификации с моделью обучения LSTM-сети. Точность подхода на данный момент составила более 80 %. В перспективе возможно повышение точности, так как планируется добавление параметров, увеличение объема данных и другие шаги. Подход демонстрирует возможность автоматического решения задачи определения психотипа человека при наличии записи его речи в разных жизненных ситуациях.

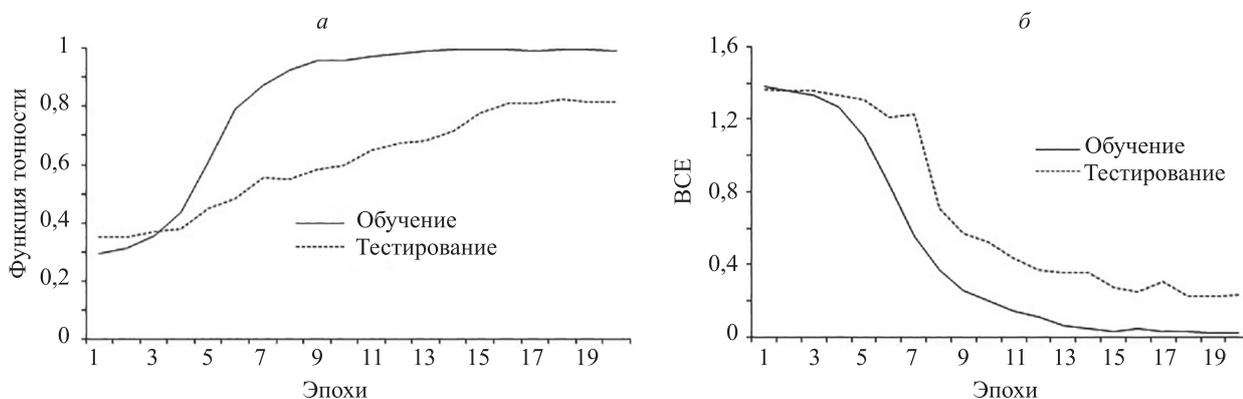


Рис. 5. Результаты бинарной классификации: изменение функции точности (а) и функции потерь (б)  
 Fig. 5. Binary classification results: change in the accuracy function (a) and loss function (b)

## Литература

1. Eisenstein J. *Introduction to Natural Language Processing*. Cambridge: MIT Press, 2019. 536 p.
2. Gary S.J., Alexander R.A., Friedl L. Item analysis of the Myers-Briggs Type Indicator // *Educational and Psychological Measurement*. 1985. V. 45. N 4. P. 789–796. doi: 10.1177/0013164485454009
3. Thompson B., Borrello G. Construct Validity of the Myers-Briggs Type Indicator // *Educational and Psychological Measurement*. 1986. V. 46. N 3. P. 745–752. doi: 10.1177/0013164486463032
4. Татарникова Т.М. Анализ данных. СПб.: СПбГЭУ, 2018. 85 с.
5. Богданов Д.С. Системы распознавания речи: классификация, методы и алгоритмы реализации // *Аллея науки*. 2018. Т. 7. № 11(27). С. 819–823.
6. Советов Б.Я., Татарникова Т.М., Яшин А.И. Использование технологии TextMining для выявления скрытых угроз в сообщениях, распространяемых по социальным сетям // *Известия СПбГЭТУ ЛЭТИ*. 2019. № 4. С. 26–32.
7. Aggarwal C.C., Zhai C. *Mining Text Data*. Springer, 2012. 527 p. doi: 10.1007/978-1-4614-3223-4
8. Шереметьева С.О., Осминин П.Г. Методы и модели автоматического извлечения ключевых слов // *Вестник Южно-Уральского государственного университета. Серия: Лингвистика*. 2015. Т. 12. № 1. С. 76–81.
9. Forsyth D. *Applied Machine Learning*. Springer, 2019. 494 p. doi: 10.1007/978-3-030-18114-7
10. Weiss K., Khoshgoftaar T.M., Wang D. A survey of transfer learning // *Journal of Big Data*. 2016. V. 3. N 1. P. 9. doi: 10.1186/s40537-016-0043-6
11. Yosinski J., Clune J., Bengio Y., Lipson H. How transferable are features in deep neural networks? // *Advances in Neural Information Processing Systems*. 2014. V. 4. P. 3320–3328.
12. Liu D., Tan Y., Khoram E., Yu Z. Training deep neural networks for the inverse design of nanophotonic structures // *ACS Photonics*. 2018. V. 5. N 4. P. 1365–1369. doi: 10.1021/acsp Photonics.7b01377
13. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // *Advances in Neural Information Processing Systems*. 2012. V. 2. P. 1097–1105.
14. Müller A.C., Guido S. *Introduction to Machine Learning with Python: A Guide for Data Scientists*. O'Reilly Media, 2016. 400 p.
15. Berrar D., Lopes P., Dubitzky W. Incorporating domain knowledge in machine learning for soccer outcome prediction // *Machine Learning*. 2019. V. 108. N 1. P. 97–126. doi: 10.1007/s10994-018-5747-8
16. Mohri M., Rostamizadeh A., Talwalkar A. *Foundations of Machine Learning*. Second Edition. Cambridge: MIT Press, 2018.
17. Alpaydin E. *Machine Learning: The New AI*. Cambridge: MIT Press, 2017. 206 p.

## Авторы

**Татарникова Татьяна Михайловна** — доктор технических наук, доцент, профессор, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 190000, Российская Федерация; заведующий кафедрой, Российский государственный гидрометеорологический университет, Санкт-Петербург, 192007, Российская Федерация, [sc 36715607400](mailto:Tm-tatarn@yandex.ru), [Tm-tatarn@yandex.ru](http://orcid.org/0000-0002-6419-0072), <http://orcid.org/0000-0002-6419-0072>

**Богданов Павел Юрьевич** — старший преподаватель, Российский государственный гидрометеорологический университет, Санкт-Петербург, 192007, Российская Федерация, [45bogdanov@gmail.com](mailto:45bogdanov@gmail.com), <http://orcid.org/0000-0002-7533-7316>

Статья поступила в редакцию 07.11.2020  
Одобрена после рецензирования 20.11.2020  
Принята к печати 19.01.2021

## References

1. Eisenstein J. *Introduction to Natural Language Processing*. Cambridge: MIT Press, 2019. 536 p.
2. Gary S.J., Alexander R.A., Friedl L. Item analysis of the Myers-Briggs Type Indicator. *Educational and Psychological Measurement*, 1985, vol. 45, no. 4, pp. 789–796. doi: 10.1177/0013164485454009
3. Thompson B., Borrello G. Construct Validity of the Myers-Briggs Type Indicator. *Educational and Psychological Measurement*, 1986, vol. 46, no. 3, pp. 745–752. doi: 10.1177/0013164486463032
4. Tatarnikova T.M. *Data Analysis*. St. Petersburg, SPbSEU Publ., 2018, 85 p. (in Russian)
5. Bogdanov D.S. Speech recognition systems: classification, methods, and algorithms for implementation. *Alley of Sciences*, 2018, vol. 7, no. 11(27), pp. 819–823. (in Russian)
6. Sovetov B.Ya., Tatarnikova T.M., Yashin A.I. Use of technology TextMining for identifying hidden threats in communications distributed by social networks. *Izvestiya SPbGETU LETI*, 2019, no. 4, pp. 26–32. (in Russian)
7. Aggarwal C.C., Zhai C. *Mining Text Data*. Springer, 2012, 527 p. doi: 10.1007/978-1-4614-3223-4
8. Sheremetyeva S.O., Osminin P.G. On methods and models of keyword automatic extraction. *Bulletin of the South Ural State University. Series: Linguistics*, 2015, vol. 12, no. 1, pp. 76–81. (in Russian)
9. Forsyth D. *Applied Machine Learning*. Springer, 2019, 494 p. doi: 10.1007/978-3-030-18114-7
10. Weiss K., Khoshgoftaar T.M., Wang D. A survey of transfer learning. *Journal of Big Data*, 2016, vol. 3, no. 1, pp. 9. doi: 10.1186/s40537-016-0043-6
11. Yosinski J., Clune J., Bengio Y., Lipson H. How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 2014, vol. 4, pp. 3320–3328.
12. Liu D., Tan Y., Khoram E., Yu Z. Training deep neural networks for the inverse design of nanophotonic structures. *ACS Photonics*, 2018, vol. 5, no. 4, pp. 1365–1369. doi: 10.1021/acsp Photonics.7b01377
13. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 2012, vol. 2, pp. 1097–1105.
14. Müller A.C., Guido S. *Introduction to Machine Learning with Python: A Guide for Data Scientists*. O'Reilly Media, 2016, 400 p.
15. Berrar D., Lopes P., Dubitzky W. Incorporating domain knowledge in machine learning for soccer outcome prediction. *Machine Learning*, 2019, vol. 108, no. 1, pp. 97–126. doi: 10.1007/s10994-018-5747-8
16. Mohri M., Rostamizadeh A., Talwalkar A. *Foundations of Machine Learning*. Second Edition. Cambridge, MIT Press, 2018.
17. Alpaydin E. *Machine Learning: The New AI*. Cambridge, MIT Press, 2017, 206 p.

## Authors

**Tatiana M. Tatarnikova** — D.Sc., Associate Professor, Professor, Saint Petersburg Electrotechnical University “LETI”, Saint Petersburg, 190000, Russian Federation; Head of Chair, Russian State Hydrometeorological University (RSHU), Saint Petersburg, 192007, [sc 36715607400](mailto:Tm-tatarn@yandex.ru), [Tm-tatarn@yandex.ru](http://orcid.org/0000-0002-6419-0072), <http://orcid.org/0000-0002-6419-0072>

**Pavel Yu. Bogdanov** — Senior Lecturer, Russian State Hydrometeorological University (RSHU), Saint Petersburg, 192007, Russian Federation, [45bogdanov@gmail.com](mailto:45bogdanov@gmail.com), <http://orcid.org/0000-0002-7533-7316>

Received 07.11.2020  
Approved after reviewing 20.11.2020  
Accepted 19.01.2021



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»