

УДК 004.89

DOI: [10.26102/2310-6018/2024.44.1.012](https://doi.org/10.26102/2310-6018/2024.44.1.012)

## Идентификация автора текста для открытого множества кандидатов в контексте кибербезопасности

А.С. Романов✉

*Томский государственный университет систем управления и радиоэлектроники,  
Томск, Российская Федерация*

**Резюме.** В работе рассмотрены методы определения авторства любительских сочинений по мотивам популярных произведений литературы и кинематографа. Данные для проведения исследования включают тексты 5 самых популярных тематик онлайн-библиотеки Ficbook. Наиболее распространенной является задача атрибуции с закрытым набором. Относительно практических задач можно предполагать, что не всегда истинный автор анонимного текста будет присутствовать в списке кандидатов. Поэтому процесс определения автора рассматривался как усложненная модификация классической задачи классификации – приведению к виду открытого множества авторов. Предложенные методы основаны на авторской комбинации fastText и One-Class SVM с отбором информативных признаков и статистических оценках мер сходства векторных представлений. Статистические методы оказались наименее эффективны даже для простого, кросс-тематического, случая, в котором данные методы уступают в точности одноклассовому SVM до 15 %. Для той же кросс-тематической задачи средняя точность авторской методики на основе совместного применения fastText и One-Class SVM составляет 85 %. В сложном случае внутри тематической классификации авторов точность представленной методики варьируется от 75 до 78 % в зависимости от тематической группы.

**Ключевые слова:** определение автора текста, fastText, машинное обучение, анализ текста, информационная безопасность.

**Благодарности:** данная работа выполнена при финансовой поддержке Министерства науки и высшего образования РФ в рамках базовой части государственного задания ТУСУРа на 2023–2025 гг. (проект № FEWM-2023-0015).

**Для цитирования:** Романов А.С. Идентификация автора текста для открытого множества кандидатов в контексте кибербезопасности. *Моделирование, оптимизация и информационные технологии*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1510> DOI: 10.26102/2310-6018/2024.44.1.012

## Text authorship identification for open set of candidates in cybersecurity context

A.S. Romanov✉

*Tomsk State University of Control Systems and Radioelectronics, Tomsk,  
the Russian Federation*

**Abstract.** The paper considers the methods of authorship identification for fanfiction texts based on popular works of literature and cinema. The data for the study include texts from 5 popular topics of Ficbook online library. The most common is the closed set attribution task. Regarding practical issues, it can be assumed that the true author of an anonymous text will not always be included in the candidates set. Therefore, the process of author identification was regarded as a more complex version of the typical classification problem – the open set of authors. The proposed methods are based on the machine learning methods: fastText and One-Class SVM with informative features selection and statistical approaches of vector representation similarity measures. Statistical methods have proven to be the least

effective even for the simple cross-thematic case. In comparison with the method based on One-Class SVM, the difference in accuracy reaches 15 %. For cross-thematic attribution, the average accuracy of the method based on the combination of One-Class SVM with feature selection and fastText was 85 %, while for the more complex task – classification within a group – it ranged from 75 to 78 % depending on the thematic group.

**Keywords:** text authorship attribution, fastText, machine learning, text analysis, information security.

**Acknowledgements:** this research was funded by the Ministry of Science and Higher Education of the Russian Federation as basic part of the state assignment of TUSUR for 2023–2025 (project No. FEWM-2023-0015).

**For citation:** Romanov A.S. Text authorship identification for open set of candidates in cybersecurity context. *Modeling, Optimization and Information Technology*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1510> DOI: 10.26102/2310-6018/2024.44.1.012 (In Russ.).

## Введение

Идентификация пользователя в сети Интернет может быть осуществлена на основе поступающей от него текстовой информации [1, 2]. Это подчеркивает необходимость внедрения мер кибербезопасности для защиты интеллектуальной собственности и личных данных, поскольку обработка такой информации требует строгого соблюдения правил приватности. В общепринятом варианте методы атрибуции применяются к классическим литературным произведениям [3]. Это обусловлено тем, что признанные писатели имеют устоявшийся стиль, на основе которого сформированное признаковое пространство четко разграничивает авторов между собой [4]. Рассматриваемые в данной статье тексты, созданные не профессиональными писателями, написаны поклонниками всемирно известных произведений и более известны как фанфики. При создании фанфиков авторы-любители опираются на особенности исходного произведения и его сюжетный мир, включая тематическую лексику, имена главных героев, внося собственное видение сюжетных линий в собственной текстовой интерпретации оригинального произведения.

В ранних работах доказано, что метод опорных векторов (SVM) с отбором информативных признаков и fastText эффективны для решения задачи определения авторства художественных произведений [1]. Ввиду этого целью данного исследования является апробация данных методов к любительским текстам, написанных авторами с активно прогрессирующим стилем письма [5]. Новизна исследования заключается в разработке методов открытой атрибуции в контексте русскоязычных любительских текстов на основе совместного использования fastText и одноклассового SVM. Проблема определения авторства любительского русскоязычного текста в случае открытого множества кандидатов не рассматривалась в научных трудах на момент 2024 года, чему уделено внимание в настоящей работе.

Для мирового сообщества использование фанфиков в задачах атрибуции не ново. На конференции PAN-2022 [6] основное внимание уделяется межфандомной атрибуции, то есть тексты являются фанфиками различных фандомов (тематических категорий). Участники должны рассматривать задачу как открытую атрибуцию (истинный автор текста может не присутствовать в списке кандидатов). В соревновании использовался датасет Aston 100 Idiolects Corpus [7]. Победителям [8] удалось добиться точности 70 %.

Для русскоязычных исследований фанфики остаются малоизученной областью, поскольку исследователи отдают предпочтения классическим текстам и сообщениям из социальных сетей. Касаясь фанфиков, ученые-лингвисты изучают вопросы влияния феноменов фанатского творчества в современной прозе [9, 10], пока безотносительно определения авторства подобных работ.

Определение авторства зачастую проводится в рамках криминалистических экспертиз [11, 12]. В таких работах авторы исследуют текст на различных уровнях (символов, слов, предложений, абзацев и текста в целом), а также проводят лексический, синтаксический и структурный анализ с целью формирования признаков пространства. Судебные эксперты отмечают необходимость корректировки признаков стиля письма для атрибуции продуктов Интернет-коммуникации [13]. Основное положение, изложенное в работе Т. П. Соколовой, состоит в модификации признаков в сторону семантических для оптимизации производства судебных автороведческих экспертиз.

### Математическая постановка задачи открытой атрибуции

При математической постановке задачи открытой атрибуции процесс установления авторства задан конечными множествами: текстов с известным авторством  $\mathbf{T}$ , анонимных текстов  $\mathbf{T}'$ , авторов –  $\mathbf{A}$ , разделенным на подмножества  $\mathbf{A}_{test}$  и  $\mathbf{A}_{train}$ . Вносится замечание о том, что некоторые анонимные тексты не были написаны ни одним из авторов-кандидатов, то есть мощность выборки авторов, чьи тексты используются при тестировании, больше, чем мощность множества авторов для обучения. Таким образом, требования к формированию наборов данных для обучения и тестирования заданы логическим выражением  $(|\mathbf{A}_{test}| > |\mathbf{A}_{train}|) \wedge (\mathbf{A}_{test} \cap \mathbf{A}_{train} = \mathbf{A}_{train})$ .

При решении задачи для каждого анонимного текста вычисляется целевая функция  $f(t_i)$  для всех  $t_i \in \mathbf{T}'$ , представляющая распределение вероятностей принадлежности к авторам  $p(a_1), p(a_2), \dots, p(a_n)$ . Все новые авторы, внедряемые на этапе тестирования, объявляются отдельным классом -1 и при отсутствии достаточной схожести вектора признаков анонимного текста с известными образцами, анонимный текст относят к отрицательному классу. Достаточная схожесть в данном контексте определяется в зависимости от метода открытой атрибуции (пороговое значение, мера сходства между векторами и т. д.). Конечным ответом в вопросе разрешения авторства является выбор автора с максимальным значением вероятности на основе расчета целевой функции.

Также задача разделяется на простой (кросс-тематический) и сложный (внутри тематический) случаи. Каждый элемент множества авторов имеет корреспондирующую ему метку  $k_i$  тематической категории, заданных множеством таких категорий  $\mathbf{K} = \{k_1, k_2, \dots, k_m\}$ . Для решения простого случая следует сформировать выборку авторов, с различными  $k_i$ , то есть тексты относятся к более, чем одной тематической категории. В случае внутри тематической классификации  $k_i$  для всех авторов будут идентичны, то есть все тексты относятся к одной тематической категории. Таким образом, при классификации следует оперировать исключительно особенностями авторского стиля письма.

### Сбор и анализ данных

Поскольку исследования проводятся для русскоязычных текстов, важно учесть это при формировании набора данных и выборе источника. Онлайн-библиотека Ficbook [14] содержит множество текстов, имеет активную аудиторию. Критериями при выборе тематических категорий (фандомов) послужили популярность и наличие объемных текстов. Под популярностью будем понимать появление новых авторов и текстов. На основе выделенных критериев были отобраны 5 самых популярных тематик: Гарри Поттер (ГП), Вселенная Марвел (ВМ), Шерлок ВВС, Наруто, Звездные войны (ЗВ).

Помимо требований к фандомам были определены критерии для самих текстов:  
1. Отсутствие метки «перевод» и соавторов. В случае совместной работы не получится установить авторский вклад, что внесет «шумы» при подсчете признаков.

2. Количество образцов. Использовались авторы с 5 и более текстами.

Получен набор данных, содержащий 686 авторов и 6569 текстов. Информация о количестве авторов и текстов в каждом наборе приведена на Рисунке 1, статистические характеристики слов и символов – в Таблице 1.

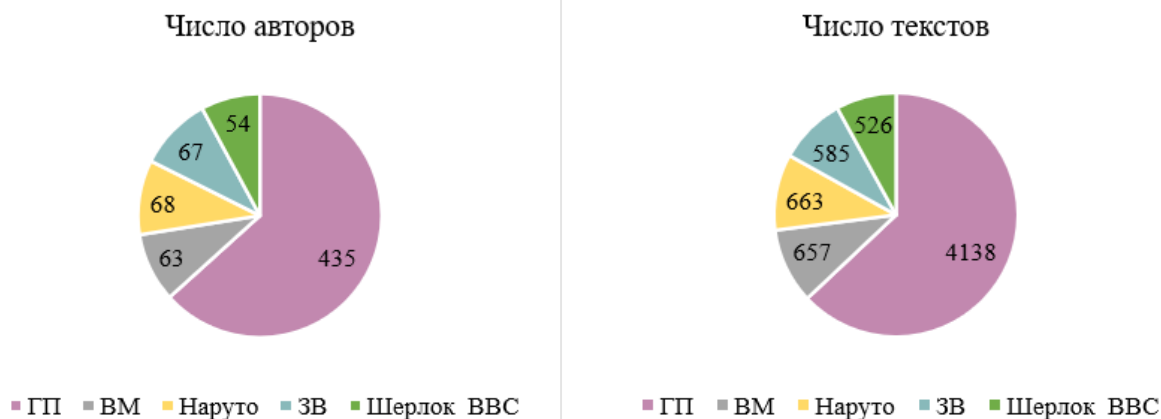


Рисунок 1 – Информация о количестве текстов и авторов  
Figure 1 – Information about the number of texts and authors

Таблица 1 – Статистические характеристики набора данных любительских текстов  
Table 1 – Statistical characteristics of the fanfiction text dataset

| Характеристика              | Все     | ГП      | ВМ     | Наруто | ЗВ     | Шерлок ВВС |
|-----------------------------|---------|---------|--------|--------|--------|------------|
| Кол-во слов в наборе данных | 2091662 | 1317747 | 237249 | 188751 | 157949 | 158766     |
| Ср. длина текста, символов  | 153473  | 103425  | 156742 | 147934 | 140995 | 155461     |

### Методы определения автора текста в случае открытого множества кандидатов

Поскольку на момент 2024 года не существует общепринятых методов открытой атрибуции, при выборе методов авторы основываются на результатах закрытой атрибуции. Оптимальным решением признана комбинация One-Class SVM с отбором признаков [15] и fastText. Подробное описание предложенных методов приведено далее.

*Метод на основе One-Class SVM и fastText.* Первоначально тексты, представленные в виде вектора признаков, подаются на вход One-Class SVM, который в данном случае используется как инструмент для детектирования аномалий. Под аномалиями будем понимать тексты, относящиеся к отрицательному классу. One-Class SVM строит нелинейную поверхность, где аномальные данные отсекаются границей отсечения. Классифицированные как положительные (не являющиеся аномалиями) классифицируются с помощью fastText в виде естественного текста. С помощью fastText мы получаем присвоенную метку автора для образцов положительных классов. На этапе оценки работы метода в расчет точности включаются все классы.

*Метод на основе порогового значения вероятностей.* При применении функции активации Softmax [16] к fastText на выходе получаем вектор вероятностей, длина которого соответствует числу классов обучающей выборки  $\mathbf{P} = [p_1, p_2, \dots, p_n]$ , и  $\sum_{i=1}^n p_i = 1$

На основе полученного вектора формируется минимальное пороговое значение вероятности принадлежности [17] текста какому-либо из обучающих классов  $p_{threshold} = \min(p_i \in \mathbf{P})$ . В случае, если минимальная вероятность принадлежности к какому-либо из классов для тестового образца не превышает  $p_{threshold}$ , такой текст будет отнесен к множеству отрицательных классов. В случае преодоления порогового значения, текст будет отнесен к неотрицательному классу с максимальным значением вероятности.

*Метод на основе расстояния Евклида.* В методе на основе Евклидова расстояния [18] для каждого текста вычисляется вектор из 400 предварительно отобранных информативных признаков [5]. Затем для каждого положительного класса на основе обучающей выборки, состоящей из  $n$  классов, рассчитывается центроидный вектор  $i$ -ого класса на основе признаков пространства  $j$  из 400 признаков [15] вычисляется по формуле (1):

$$C_i = \bigcup_{j=1}^{400} \left[ \frac{\sum_{j=1}^n j}{n} \right]. \quad (1)$$

Для определения принадлежности тестового образца к одному из классов с помощью расстояния Евклида требуется рассчитать расстояние от собственного вектора признаков тестируемого образца до каждого из центроидов классов, полученных по (1) с помощью выражения (2):

$$d(\mathbf{T}_i, \mathbf{C}_j) = \sqrt{(x_{t_i} - x_{c_j})^2 + \dots + (z_{t_i} - z_{c_j})^2}, \quad (2)$$

где  $\mathbf{C}_j$ , – центроид и  $j$  соответствует мощности множества неотрицательных классов.

Для определения порогового значения каждого неотрицательного класса  $d_{threshold}(\mathbf{C}_j)$  вычисляется максимальное отклонение обучающих образцов от центроида. В случае получения  $d(\mathbf{T}_i, \mathbf{C}_j) > d_{threshold}(\mathbf{C}_j)$  тестовый образец будет классифицирован как принадлежащий к -1 классу.

*Метод на основе косинусного сходства.* Подобие на основе косинусного сходства также определяется с помощью центроидов обучающих классов [19, 20]. Отличие данного метода заключается в том, что пороговым признается минимальное расстояние меры косинусного сходства обучающего объекта по отношению к центроиду класса (3):

$$s(\mathbf{T}_i, \mathbf{C}_i) = \frac{\mathbf{T} \cdot \mathbf{C}}{\|\mathbf{T}\| \cdot \|\mathbf{C}\|} = \frac{\sum_{i=1}^n \mathbf{T}_i \times \mathbf{C}_i}{\sqrt{\sum_{i=1}^n (\mathbf{T}_i)^2} \times \sqrt{\sum_{i=1}^n (\mathbf{C}_i)^2}}. \quad (3)$$

В случае, если мера косинусного сходства тестового образца не превышает пороговое значение ни одного из неотрицательных классов, текст относят к -1 классу.

### Методика

В связи с экспериментально доказанной эффективностью fastText и SVM с отбором признаков [1, 5], было принято решение о разработке методов открытой атрибуции с опорой на полученные выводы, то есть попытке их совместного использования. Предложенная методика представлена на Рисунке 2.

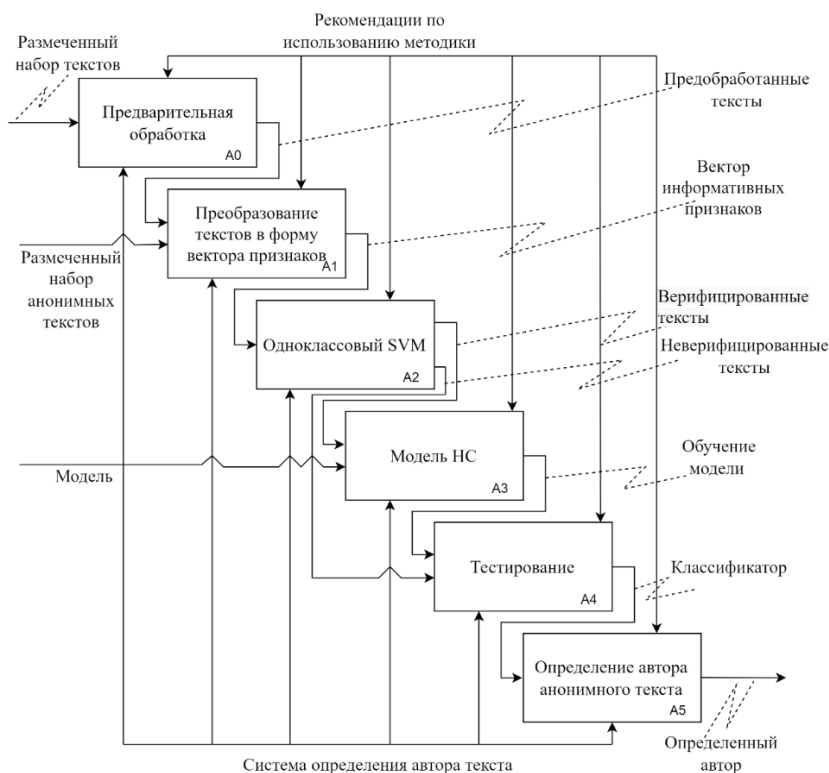


Рисунок 2 – Методика открытой атрибуции  
Figure 2 – Methodology of open attribution

### Экспериментальная оценка предложенной методики

Все образцы текстов в данном исследовании созданы писателями-любителями с прогрессирующим стилем письма, а также содержат попытки подражания исходному произведению, на основе которого написаны фанфики. Данный факт вносит дополнительное усложнение при проведении экспериментальной оценки методики, а также свидетельствует о приближенности к задачам кибербезопасности. При оценке результатов применялась процедура перекрестной проверки. Чтобы оценить качество классификации, использовалась точность, рассчитываемая как доля верно классифицированных текстов.

Параметры fastText идентичны описанным в работе [5]. Параметры One-Class SVM: *linear kernel*; *regularization=1*; *gamma=scale*; *stopping criterion=1e-5*. Согласно математической постановке задачи, обучение проходило на меньшем количестве авторов, чем тестирование. Разделение исходного множества на обучающую и тестовую выборки осуществляется в соотношении 80:20. Эксперименты проводились для 2+1, 4+1, 9+1 и 19+1 авторов. Второе слагаемое включает всех авторов отрицательного класса, их количество устанавливается как 30 % от числа авторов обучающей выборки. Длина каждого текста составляет 25000 символов. Результаты кросс-тематической классификации представлены на Рисунке 3, классификации внутри тематической группы – на Рисунке 4. Для экспериментов с кросс-тематическими данными, результаты для каждой из групп (ГП, Шерлок ВВС, Наруто, ВМ, ЗВ) представлены как среднее значение, полученное при проведении экспериментов с другими группами.




Рисунок 3 – Результаты межгрупповой классификации  
Figure 3 – Results of cross-group classification

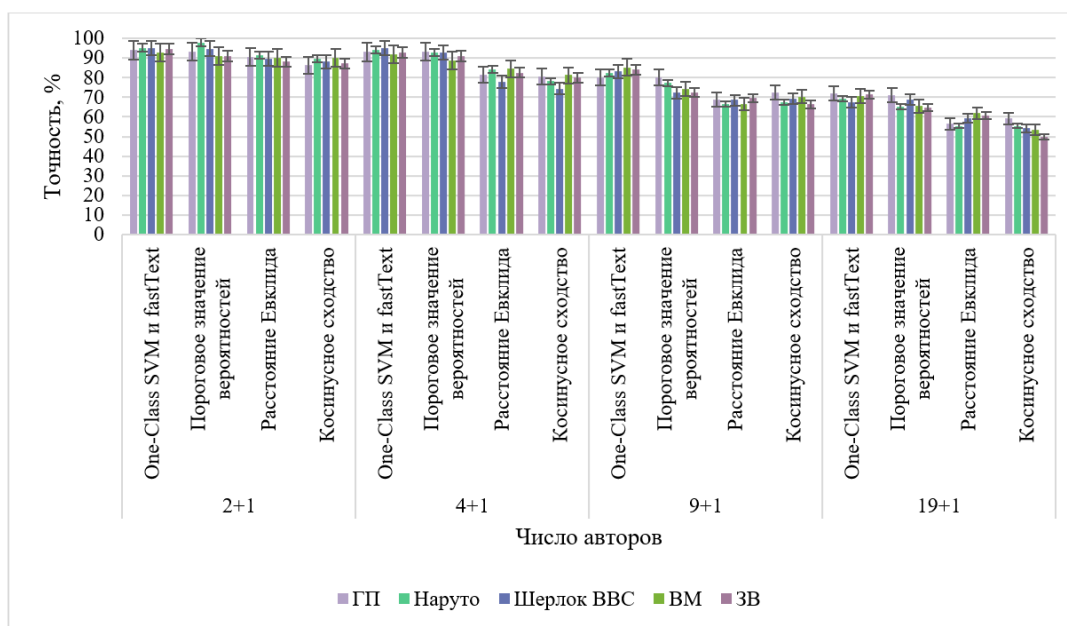


Рисунок 4 – Результаты классификации внутри группы  
Figure 4 – Results of in-group classification

В случае кросс-тематической классификации результаты варьируются не более 7 % в рамках тематических категорий, что свидетельствует об отсутствии переобучения предложенных методов и их адекватности в решении задачи. Внедрение 3 и более авторов отрицательного класса (случае 9+1, 19+1) негативно влияет на точность классификации всех предложенных методов, точность снижается на 9–15 % в сравнении с экспериментами для 2+1 и 4+1 классов, где внедрялось от 1 до 2 авторов -1 класса. Во всех случаях максимальная точность достигается при использовании методов, основанных на машинном обучении (комбинация одноклассового метода опорных векторов и fastText и пороговое значение вероятности fastText). В качестве обоснований

полученных результатов можно отметить способности нейронных сетей к самостоятельному выявлению неявных семантических связей в авторских текстах в случае fastText и сформированное признаковое пространство, с которым работал One-Class SVM. Методы, основанные на косинусном сходстве и расстоянии Евклида признаны наименее эффективными в решении задачи. Та же тенденция отмечена в случае внутри тематической классификации. Данный случай осложнен использованием одинаковых имен собственных во всех текстах (ввиду использования сюжета исходной тематики). Для 2+1 авторов все представленные методы демонстрируют точность выше 80 %. В случае 4+1 классов сохранить такую точность удастся с использованием методов, основанных на машинном обучении. По результатам самого сложного эксперимента (19+1 авторов) удастся отметить выигрыш в точности комбинации One-Class SVM и fastText в сравнении с методов на основе порогового значения вероятностей на 2-5 % в зависимости от тематической группы.

### Заключение

В результате исследования разработана методика идентификации автора текста для случая открытого множества кандидатов. При разработке методики учитывалась важность сформированного признакового пространства, содержащего распределения частот слов и символов, и преимущества нейронных сетей, зарекомендовавших себя в задачах классификации текста.

Метод, использующий пороговую вероятностную функцию, показывает результаты, сопоставимые с комбинацией fastText и One-Class SVM при классификации пар тематических категорий. Однако он уступает в более сложных сценариях. Например, точность авторской комбинации One-Class SVM и fastText достигает 80 % для 9+1 классов в сложных случаях, в то время как эффективность второго метода остается ниже 75 % в аналогичных условиях. По сравнению со статистическими подходами, основанными на евклидовом расстоянии и косинусном сходстве, применение One-Class SVM совместно с fastText улучшает результаты на 2–15 %. Кроме того, анализ работы One-Class SVM с fastText в рамках одной тематической группы подчеркивает его независимость от конкретной темы анализируемых текстов, поскольку разница в результатах между разными группами не превышает 8 % при одинаковом количестве классов. В случаях как парного сравнения различных тематических категорий, так и внутригрупповой классификации, точность составляет более 95 %.

В области кибербезопасности предложенная методика может быть использована для защиты интеллектуальной собственности, идентификации фишинговых и мошеннических сообщений, которые часто имитируют стиль написания реальных авторов, и случаев нарушения авторских прав и кражи интеллектуальной собственности, путем сравнения стилей письма в различных текстах.

### СПИСОК ИСТОЧНИКОВ

1. Romanov A., Kurtukova A., Shelupanov A., Fedotova A., Goncharov V. Authorship identification of a Russian-language text using support vector machine and deep neural networks. *Future Internet*. 2020;13(1):3. DOI: 10.3390/fi13010003.
2. Romanov A., Kurtukova A., Sobolev A., Shelupanov A., Fedotova A. Determining the age of the author of the text based on deep neural network models. *Information*. 2020;12(11):589. DOI: 10.3390/info11120589.
3. Jafariakinabad F., Kien A. H. Unifying lexical, syntactic, and structural representations of written language for authorship attribution. *SN Computer Science*. 2021;6(2):481. DOI: 10.1007/s42979-021-00911-2.



4. Mahor U., Aarti K. A Comparative Study of Stylometric Characteristics in Authorship Attribution. *Information and Communication Technology for Competitive Strategies (ICTCS 2021) ICT: Applications and Social Interfaces*. Singapore, Springer Nature Singapore. 2022. p. 71–81. DOI: 10.1007/978-981-19-0095-2.
5. Fedotova A., Romanov A., Kurtukova A., Shelupanov A. Authorship attribution of social media and literary Russian-language texts using machine learning methods and feature selection. *Future Internet*. 2021;14(1):4. DOI: 10.3390/fi14010004.
6. PAN: series of scientific events and shared tasks on digital text forensics and stylometry. URL: <https://pan.webis.de> (дата обращения: 19.01.2024).
7. The 100 Idiolectic Project. URL: <https://fold.aston.ac.uk/handle/123456789/17> (дата обращения: 19.01.2024).
8. Najafi M., Tavan E. Text-to-text transformer in authorship verification via stylistic and semantical analysis. *Proceedings of the CLEF*. 2022. URL: <https://ceur-ws.org/Vol-3180/paper-215.pdf> (дата обращения: 19.01.2024).
9. Drozdova A., Petrov V. Modern classic in the web environment: narrative variations of V. Nabokov’s in fanfiction. *Acta Universitatis Sapientiae, Film and Media Studies*. 2020;18(1):89–107. DOI: 10.2478/ausfm-2020-0005.
10. Shafirova L., Cassany D., Bach C. Transcultural literacies in online collaboration: a case study of fanfiction translation from Russian into English. *Language and Intercultural Communication*. 2020;20(6):531–545. DOI: 10.1080/14708477.2020.1812621.
11. Swain S., Mishra G., Sindhu C. Recent approaches on authorship attribution techniques – an overview. In: *2017 International conference of Electronics, Communication and Aerospace Technology (ICECA)*. IEEE. Coimbatore, India. 2017. p. 557–566. DOI: 10.1109/icesa.2017.8203599.
12. Hedegaard S., Simonsen J.G. Lost in translation: Authorship attribution using frame semantics. In: *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*. 2011. p. 65–70. URL: <https://aclanthology.org/P11-2012.pdf> (дата обращения: 19.01.2024).
13. Соколова Т.П. Проблемы экспертной идентификации в судебном автороведении. *Вестник Университета имени О.Е. Кутафина (МГЮА)*. 2022;2(90):67–76.
14. Ficbook: Fanfiction book. URL: <https://ficbook.net/> (дата обращения 19.01.2024).
15. Романов А.С. Методы отбора признаков в задаче определения авторства в контексте кибербезопасности. *Моделирование, оптимизация и информационные технологии*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1489>. DOI: 10.26102/2310-6018/2024.44.1.001.
16. Mohammed A.A., Umaashankar V. Effectiveness of hierarchical softmax in large scale classification tasks. *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE. 2018. p. 1090–1094. DOI: 10.1109/ICACCI.2018.8554637.
17. Lei K., Fu Q., Yang M., Liang Y. Tag recommendation by text classification with attention-based capsule network. *Neurocomputing*. 2020;391:65–73. DOI: 10.1016/j.neucom.2020.01.091.
18. Suwanda R., Syahputra Z., Zamzami E.M. Analysis of Euclidean distance and Manhattan distance in the K-means algorithm for variations number of centroid K. *Journal of Physics: Conference Series, IOP Publishing*. 2020;1566(1):012058. DOI: 10.1088/1742-6596/1566/1/012058.

19. Martín-del-Campo-Rodríguez C., Sidorov G., Batyrshin I. Unsupervised authorship attribution using feature selection and weighted cosine similarity. *Journal of Intelligent & Fuzzy Systems*. 2022;42(5):4357–4367.
20. Park K., Hong J.S., Kim W. A methodology combining cosine similarity with classifier for text classification. *Applied Artificial Intelligence*. 2020;34(5):396–411. DOI: 10.1080/08839514.2020.1723868.

## REFERENCES

1. Romanov A., Kurtukova A., Shelupanov A., Fedotova A., Goncharov V. Authorship identification of a Russian-language text using support vector machine and deep neural networks. *Future Internet*. 2020;13(1):3. DOI: 10.3390/fi13010003.
2. Romanov A., Kurtukova A., Sobolev A., Shelupanov A., Fedotova A. Determining the age of the author of the text based on deep neural network models. *Information*. 2020;12(11):589. DOI: 10.3390/info11120589.
3. Jafariakinabad F., Kien A.H. Unifying lexical, syntactic, and structural representations of written language for authorship attribution. *SN Computer Science*. 2021;6(2):481. DOI: 10.1007/s42979-021-00911-2.
4. Mahor U., Aarti K. A comparative study of stylometric characteristics in authorship attribution. *Information and Communication Technology for Competitive Strategies (ICTCS 2021) ICT: Applications and Social Interfaces*. Singapore, Springer Nature Singapore. 2022. p. 71–81. DOI: 10.1007/978-981-19-0095-2.
5. Fedotova A., Romanov A., Kurtukova A., Shelupanov A. Authorship attribution of social media and literary Russian-language texts using machine learning methods and feature selection. *Future Internet*. 2021;14(1):4. DOI: 10.3390/fi14010004.
6. PAN: series of scientific events and shared tasks on digital text forensics and stylometry. URL: <https://pan.webis.de> (accessed on 19.01.2024).
7. The 100 Idiolectic Project. URL: <https://fold.aston.ac.uk/handle/123456789/17> (accessed on 19.01.2024).
8. Najafi M., Tavan E. Text-to-text transformer in authorship verification via stylistic and semantical analysis. *Proceedings of the CLEF*. 2022. URL: <https://ceur-ws.org/Vol-3180/paper-215.pdf> (accessed on 19.01.2024).
9. Drozdova A., Petrov V. Modern classic in the web environment: narrative variations of V. Nabokov’s in fanfiction. *Acta Universitatis Sapientiae, Film and Media Studies*. 2020;18(1):89–107. DOI: 10.2478/ausfm-2020-0005.
10. Shafirova L., Cassany D., Bach C. Transcultural literacies in online collaboration: a case study of fanfiction translation from Russian into English. *Language and Intercultural Communication*. 2020;20(6):531–545. DOI: 10.1080/14708477.2020.1812621.
11. Swain S., Mishra G., Sindhu C. Recent approaches on authorship attribution techniques – an overview. In: *2017 International conference of Electronics, Communication and Aerospace Technology (ICECA)*. IEEE. Coimbatore, India. 2017. p. 557–566. DOI: 10.1109/iceca.2017.8203599.
12. Hedegaard S., Simonsen J.G. Lost in translation: Authorship attribution using frame semantics. In: *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*. 2011. p. 65–70. URL: <https://aclanthology.org/P11-2012.pdf> (accessed on 19.01.2024).

13. Sokolova T.P. Problems of expert identification in forensic authorship. *Courier of Kutafin Moscow State Law University (MSAL) = Vestnik Universiteta imeni O.E. Kutafina (MGYuA)*. 2022;2(90):67–76. (In Russ).
14. Ficbook: Fanfiction book. URL: <https://ficbook.net/> (accessed on 19.01.2024).
15. Romanov A.S. Feature selection methods for authorship attribution in cybersecurity context. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii = Modeling, Optimization and Information Technology*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1489>. DOI: 10.26102/2310-6018/2024.44.1.001. (In Russ.).
16. Mohammed A.A., Umaashankar V. Effectiveness of hierarchical softmax in large scale classification tasks. In: *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE. 2018. p. 1090–1094. DOI: 10.1109/ICACCI.2018.8554637.
17. Lei K., Fu Q., Yang M., Liang Y. Tag recommendation by text classification with attention-based capsule network. *Neurocomputing*. 2020;391:65–73. DOI: 10.1016/j.neucom.2020.01.091.
18. Suwanda R., Syahputra Z., Zamzami E.M. Analysis of Euclidean distance and Manhattan distance in the K-means algorithm for variations number of centroid K. *Journal of Physics: Conference Series, IOP Publishing*. 2020;1566(1):012058. DOI: 10.1088/1742-6596/1566/1/012058.
19. Martín-del-Campo-Rodríguez C., Sidorov G., Batyrshin I. Unsupervised authorship attribution using feature selection and weighted cosine similarity. *Journal of Intelligent & Fuzzy Systems*. 2022;42(5):4357–4367.
20. Park K., Hong J.S., Kim W. A methodology combining cosine similarity with classifier for text classification. *Applied Artificial Intelligence*. 2020;34(5):396–411. DOI: 10.1080/08839514.2020.1723868.

#### ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATION ABOUT THE AUTHOR

**Романов Александр Сергеевич**, кандидат технических наук, доцент, доцент кафедры комплексной информационной безопасности электронно-вычислительных систем (КИБЭВС) Томского государственного университета систем управления и радиоэлектроники (ТУСУР), Томск, Российская Федерация.

*e-mail:* [alex.romanov@gmail.com](mailto:alex.romanov@gmail.com)

ORCID: [0000-0002-2587-2222](https://orcid.org/0000-0002-2587-2222)

**Aleksandr S. Romanov**, Candidate of Engineering Sciences, Associate Professor, Associate Professor at the Department of Complex Information Security of Electronic Computer Systems (KIBEVS), Tomsk State University of Control Systems and Radioelectronics (TUSUR), Tomsk, the Russian Federation.

*Статья поступила в редакцию 24.01.2024; одобрена после рецензирования 08.02.2024; принята к публикации 20.02.2024.*

*The article was submitted 24.01.2024; approved after reviewing 08.02.2024; accepted for publication 20.02.2024.*