

УДК 004.056; 004.032.26

DOI: [10.26102/2310-6018/2021.35.4.034](https://doi.org/10.26102/2310-6018/2021.35.4.034)

## Риск-анализ контента социальных сетей на основе нейросетевой классификации эмоциональной окраски текста сообщений

Е.С. Соколова, К.А. Разинкин✉, Д.Н. Савищенко, Е.Ю. Чапурин

*Воронежский государственный технический университет,  
Воронеж, Российская Федерация  
kostyr@mail.ru✉*

**Резюме.** Одним из перспективных направлений Data Science в рамках практико-ориентированных подходов к анализу социальных сетей (Social network analysis), с точки зрения формализации мнений пользователей сети (агентов), является класс методов анализа контента, предназначенный для автоматизированного выявления в текстах эмоционально окрашенной лексики и эмоциональной оценки авторов по отношению к объектам, речь о которых идет в тексте. С помощью такого анализа можно изучить массив сообщений и иных данных и определить, как они эмоционально окрашены – позитивно, негативно или нейтрально. В статье предложен сравнительный анализ двух подходов к исследованию возможностей классификации текстовых последовательностей в зависимости от их эмоциональной окраски: на основе рекуррентной нейронной сети (RNN) и с использованием графовых сверточных сетей (GCN). Первый подход реализован на основе глубокого обучения с использованием инструмента Deep Learning Designer (MathWorks® MATLAB R2021b). Второй подход основан на использовании сверточных графовых нейросетей для классификации текста. Реализация GCN осуществлена на языке Python с использованием соответствующего набора библиотек для анализа данных. Кроме этого, в работе показано, что полученная модель может использоваться при оценке рисков, где получаемое значение используется в качестве корректирующего коэффициента при расчетах риска вовлеченности пользователя.

По результатам сравнения двух подходов показано, что при использовании GCN снижается процент обучающих данных, что свидетельствует о чувствительности метода к меньшему количеству обучающих данных, а также повышению точности модели при сопоставимых настраиваемых параметрах обучения.

**Ключевые слова:** эмоциональная окраска текста, рекуррентная нейросеть, глубокое обучение, графовые сверточные сети, риск анализ

**Для цитирования:** Соколова Е.С., Разинкин К.А., Савищенко Д.Н., Чапурин Е.Ю. Риск-анализ контента социальных сетей на основе нейросетевой классификации эмоциональной окраски текста сообщений. *Моделирование, оптимизация и информационные технологии.* 2021;9(4). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1105> DOI: 10.26102/2310-6018/2021.35.4.034

## Risk analysis of social media content based on neural network classification of a message text emotional coloring

E.S. Sokolova, K.A. Razinkin✉, D.N. Savishchenko, E.Yu. Chapurin

*Voronezh State Technical University,  
Voronezh, Russian Federation  
kostyr@mail.ru✉*

**Abstract:** One of the promising areas of Data Science within the framework of practice-oriented approaches to the analysis of social networks (Social network analysis) from the point of view of network users' (agents') opinion formalization is a class of content analysis methods designed for automated identification of emotionally colored vocabulary in texts and emotional evaluation of authors in relation to the objects referred to in the text. With the help of such an analysis, it is possible to study an array of messages and other data and determine how they are emotionally colored - positively, negatively or neutrally. The article offers a comparative analysis of two approaches to the study of text sequences classification possibilities depending on their emotional coloring: one by means of a recurrent neural network (RNN) and another involving graph convolutional networks (GCN). The first approach is implemented through deep learning utilizing the Deep Learning Designer tool (MathWorks © MATLAB R2021b). The second approach is based on the application of convolutional graph neural networks for text classification. GCN implementation is carried out in Python using the appropriate set of libraries for data analysis. In addition, the paper shows that the resulting model can be used in risk assessment, where the resulting value serves as a correction factor in calculating the risk of user involvement.

Based on the results of the two approaches comparison, it is shown that when using GCN, the percentage of training data decreases, which indicates the sensitivity of the method to a smaller amount of training data, while the accuracy of the model increases with comparable configurable training parameters.

**Keywords:** emotional coloring of the text, recurrent neural network, deep learning, graph convolutional networks, risk analysis

**For citation:** Sokolova E.S., Razinkin K.A., Savchenko D.N., Chapurin E.Y. Risk Analysis of Social Media Content based on Neural Network Classification of a Message Text Emotional coloring.

*Modeling, Optimization and Information Technology*. 2021;9(4). Available from:

<https://moitvvt.ru/ru/journal/pdf?id=1105> DOI: 10.26102/2310-6018/2021.35.4.034 (In Russ).

## Введение

Классификация текста является фундаментальной проблемой в обработке естественного языка (NLP). Существует множество применений классификации текста, таких как организация документов, фильтрация новостей, обнаружение спама, анализ мнений и т. д. [1]. В последнее время в качестве одного из направлений кибербезопасности принято выделять масштабируемые средства интеллектуального анализа данных и процессов в распределенных системах, включая социальные сети. В этой связи контент-анализ в части классификации мнений пользователей сети с последующим риск-анализом контента социальных сетей на основе нейросетевой классификации эмоциональной окраски текста сообщений приобретает очевидную актуальность, так как от качества этапа предварительной классификации текста зависят следующие этапы разработки методов и реализации средств интеллектуального анализа данных и процессов в распределенных системах и, в частности, социальных сетях [2].

Важным промежуточным шагом для классификации текста является представление текста. Традиционные методы представляют текст с элементами ручной работы, такими как разреженные лексические функции (например, набор слов и n-грамм). Модели глубокого обучения широко используются для изучения текстовых представлений, включая сверточные и рекуррентные нейронные сети (RNN), такие как LSTM (Long short-term memory) [3].

В последнее время широкое внимание привлекло новое направление исследований в области машинного обучения, называемое графовыми нейронными сетями [4]. Данный тип нейросетей эффективен в задачах, которые, как считается, имеют выраженную реляционную структуру и могут работать с ней (структурой) напрямую.

В данной статье описан процесс создания модели численной оценки эмоциональной окраски контента на базе нейронной сети, включающий: сравнительный

анализ двух подходов к исследованию возможностей классификации текстовых последовательностей в зависимости от их эмоциональной окраски: на основе рекуррентной нейронной сети (RNN) и с использованием графовых сверточных сетей (GCN). Кроме этого в работе показано, что полученная модель может использоваться при оценке рисков, где получаемое значение используется в качестве корректирующего коэффициента при расчетах риска вовлеченности пользователя.

### Материалы и методы

В работе решались четыре ключевые задачи, а именно:

1. Классификация контента в зависимости от эмоциональной окраски текста на основе рекуррентной нейронной сети (RNN)
2. Классификация контента в зависимости от эмоциональной окраски текста на основе использования графовых сверточных сетей (GCN)
3. Сравнение результатов классификации на основе RNN и GCN.
4. Использование полученной модели (GCN) при оценке рисков, где получаемое значение используется в качестве корректирующего коэффициента при расчетах, например, риска вовлеченности.

В качестве исходных данных был использован набор данных [5, 6], состоящий из 1600000 публикаций социальной сети Twitter, каждая из которых оценена экспертами как позитивная или негативная (Рисунок 1).

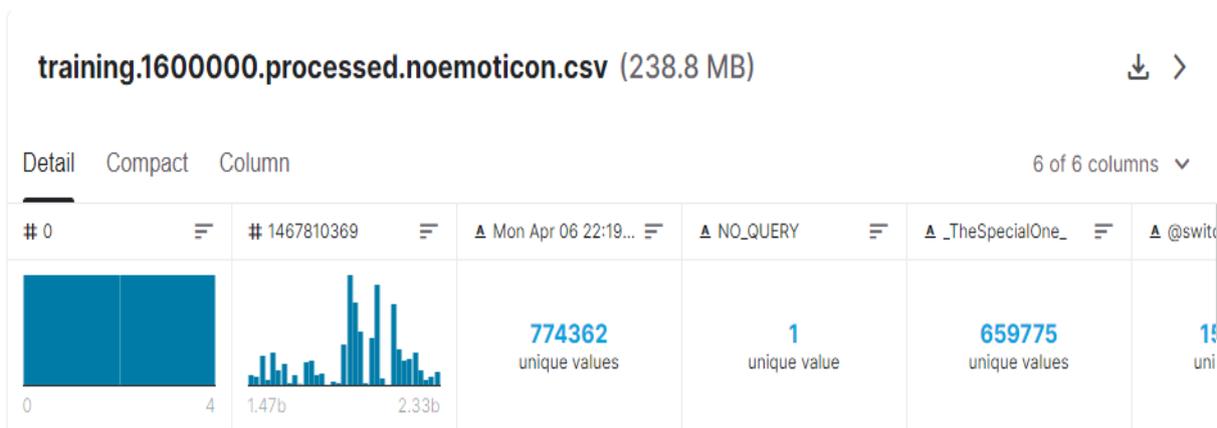


Рисунок 1 – Скриншот стартовой страницы для загрузки используемого dataset  
Figure 1 – Screenshot of the start page for loading the dataset in use

В качестве классификатора текстовых данных при решении первой задачи использовалась сеть долговременной кратковременной памяти глубокого обучения (LSTM) [7,8]. Сеть LSTM – это тип рекуррентной нейронной сети (RNN), которая может изучать долгосрочные зависимости между временными шагами данных последовательности. Чтобы ввести текст в сеть LSTM, осуществлялось преобразование текстовых данных в числовые последовательности за счет использования кодировки слов, которая сопоставляет документы последовательностям числовых индексов. Реализация проводилась с использованием интерактивного инструмента глубокого обучения Matlab Deep Learning Designer tool (MathWorks © MATLAB R2021b). При этом реализовывались четыре этапа обучения и использования сети LSTM: импорт и предварительная обработка данных; преобразование слов в числовые последовательности с использованием кодировки слов; создание и обучение сети LSTM; классификация новых текстовых данных с помощью обученной сети LSTM.

Предварительная обработка текстовых данных предполагает создание функции, маркирующей и предварительно обрабатывающей текстовые данные. Функция preprocessText тулбокса Text Mining Matlab, выполняет следующие действия [9]:

Маркирует (токенизирует) текст с помощью функции tokenizedDocument.

Преобразует текст в нижний регистр, используя функцию lower.

Удаляет знаки препинания с помощью функции erasePunctuation.

На Рисунке 2 представлен дизайн сети LSTM для нашей задачи.

Сеть содержала 6 слоев. Результаты анализа структуры сети перед ее обучением, представлена на Рисунке 3. Как видно из рисунка. Ошибок и предупреждений на данном этапе не было.

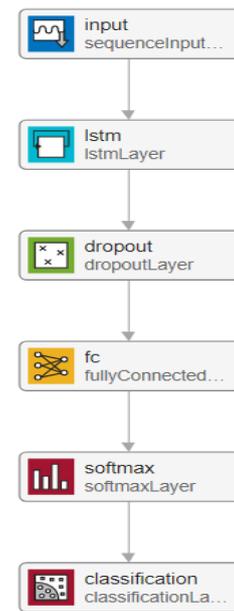


Рисунок 2 – Структура сети LSTM  
Figure 2 – LSTM network structure

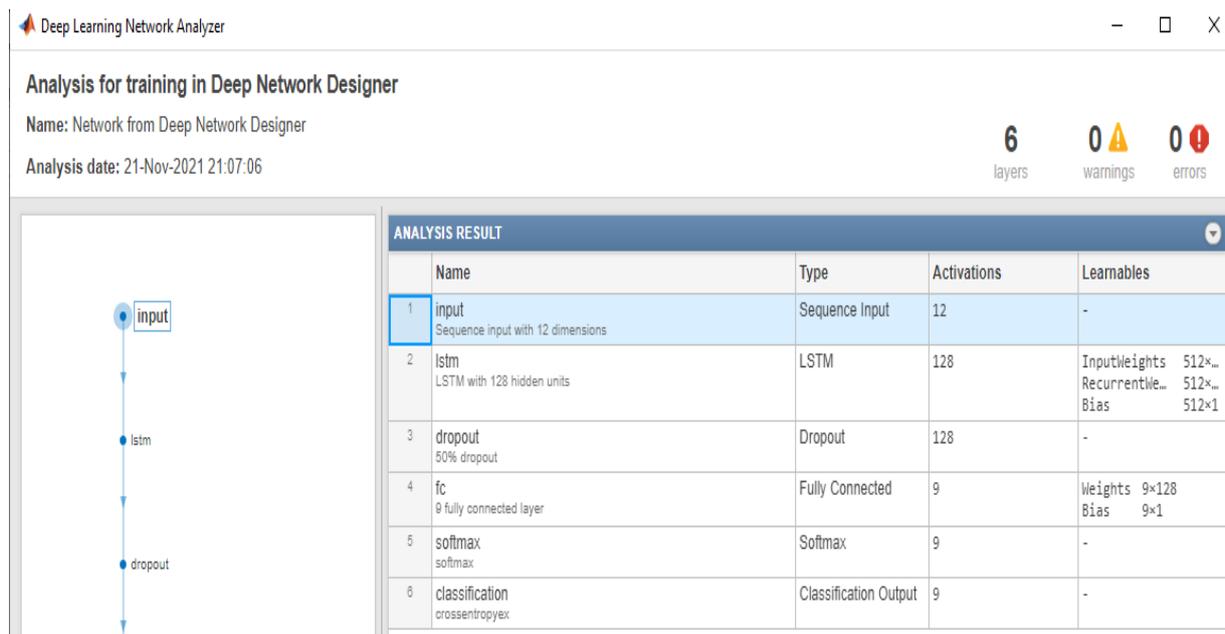


Рисунок 3 – Результаты анализа структуры нейросети перед обучением  
Figure 3 – Results of the analysis of the structure of the neural network before training

На Рисунке 4 представлен результат обучения нейросети LSTM. Из рисунка видно, что показатели качества обученности модели вполне приемлемы, а именно: точность проверки – 90,63 %; количество эпох – 30; количество итераций – 24; число итераций в одной эпохе – 24; частота – 50 итераций. Вычисления проводились с использованием одного CPU.

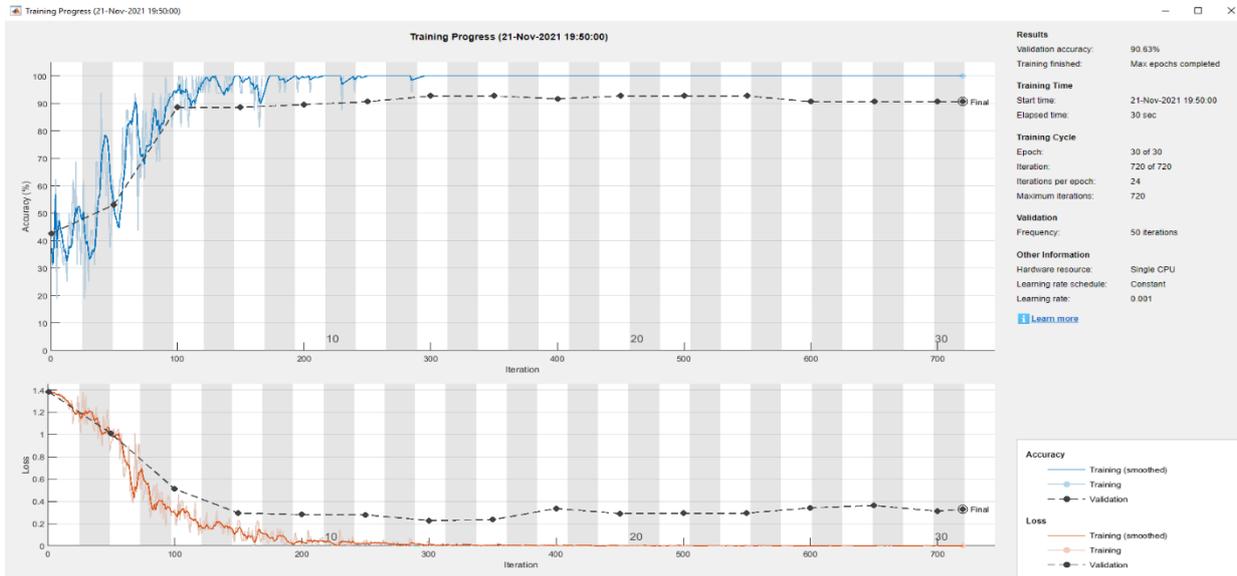


Рисунок 4 – Скриншот результатов обучения нейросети  
Figure 4 – Screenshot of neural network training results

Второй этап исследования предполагает классификацию контента в зависимости от эмоциональной окраски текста на основе использования графовых сверточных сетей (GCN).

GCN – это многослойная нейронная сеть, которая работает непосредственно на графике и индуцирует встраивание векторов узлов на основе свойств их окрестностей [8].

Формально рассмотрим граф  $G(V, E)$ , где  $V$  ( $|V| = n$ ) и  $E$ -наборы узлов и ребер соответственно.

Предполагается, что каждый узел связан сам с собой, т. е.  $(v, v) \in E$  для любого  $v$ . Пусть  $X \in \mathbb{R}^{n \times m}$  – матрица, содержащая все  $n$  узлов с их функциями, где  $m$  – размерность векторов функций, каждая строка  $x_v \in \mathbb{R}^m$  – вектор функций для  $v$ . Введем матрицу смежности  $A$  из  $G$  и ее матрицу степеней  $D$ , где  $D_{ii} = \sum_j A_{ij}$ . Диагональные элементы  $A$  имеют значение 1 из-за самоциклов. GCN может собирать информацию только о ближайших соседях с одним слоем свертки. Когда несколько слоев GCN укладываются друг на друга, информация о более крупных районах интегрируется. Для однослойного GCN новая  $k$ -мерная матрица объектов узлов  $L^{(1)} \in \mathbb{R}^{n \times k}$  вычисляется как

$$L^{(1)} = \rho(\tilde{A}XW_0), \quad (1)$$

где  $\tilde{A} = D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$  – нормализованная симметричная матрица смежности, а  $W_0 \in \mathbb{R}^{m \times k}$   $k$  – весовая матрица. является функцией активации, например,  $\text{ReLU} \rho(x) = \max(0, x)$ .  
Как упоминалось ранее, можно включить информацию о районах более высокого порядка, сложив несколько слоев GCN:

$$L^{(j+1)} = \rho(\tilde{A}L^{(j)}W_j), \quad (2)$$

где  $j$  обозначает номер слоя, а  $L^{(0)} = X$ .

При построении свёрточной сети текстовых графов (Text GCN) наиболее приоритетным для нас является граф, который содержит узлы слов и узлы документов, с целью непосредственного моделирования глобального совпадения слов. Количество узлов в текстовом графе  $|V|$  – это количество документов (размер популяции) плюс количество уникальных слов (словарный размер) в популяции. При этом необходимо сформировать матрицу признаков  $X = I$  в качестве идентификационной матрицы, что означает, что каждое слово или документ представлены в виде одномерного вектора в качестве входных данных для Text GCN.

Далее формируются ребра между узлами на основе появления слов в документах (ребра документа-слова) и совместного появления слов во всей популяции (ребра слова – слова). Вес границы между узлом документа и узлом слова – это частота термина – обратная частота документа (TF-IDF) слова в документе, где частота термина – это количество раз, когда слово появляется в документе, обратный документ к частоте – это логарифмически масштабированная обратная доля числа документов, содержащих это слово. Использование веса TF-IDF лучше, чем использование только частоты терминов. Чтобы использовать глобальную информацию о совпадениях слов, используется скользящее окно фиксированного размера для всех документов в корпусе для сбора статистики совпадений, при этом используется точечная взаимная информация (PMI – популярная мера для словесных ассоциаций), для вычисления весов между двумя словесными узлами. Использование PMI дает лучшие результаты, чем использование количества совпадений слов в наших предварительных экспериментах [8].

Формально вес ребра между узлом  $i$  и узлом  $j$  определяется как

$$A_{ij} = \begin{cases} PMI(i, j) & i, j \text{ это слова, } PMI(i, j) > 0 \\ TF - IDF_{ij} & i \text{ является документом, } j \text{ является словом} \\ 1 & i = j \\ 0 & \text{в противном случае} \end{cases} \quad (3)$$

Значение PMI пары слов  $i; j$  вычисляется как

$$PMI(i, j) = \log \frac{p(i, j)}{p(i)p(j)} \quad (4)$$

$$p(i, j) = \frac{\#W(i, j)}{\#W} \quad (5)$$

$$p(i) = \frac{\#W(i)}{\#W}, \quad (6)$$

где  $\#W(i)$  – количество раздвижных окон в корпусе, содержащих слово  $i$ ,  $\#W(i; j)$  – количество раздвижных окон окна, содержащие как слова  $i$ , так и  $j$ , а  $\#W$  – общее количество скользящих окон в корпусе. Позитивное значение PMI подразумевает высокую семантическую корреляцию слов в корпусе, в то время как отрицательное значение PMI указывает на незначительную или нулевую семантическую корреляцию в корпусе. Поэтому мы добавляем ребра только между парами слов с положительными значениями PMI.

После построения текстового графика мы помещаем график в простой двухслойный GCN, как в (Kipf, 2017), вложения узла второго слоя (слово/документ) имеют тот же размер, что и набор меток, и подаются в классификатор softmax:

$$Z = \text{soft max} \left( \text{ReLU} \left( \tilde{A} X W_0 \right) W_1 \right) \quad (7)$$

где  $\tilde{A} = D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$  совпадает с уравнением 1, и  $\text{soft max}(x_i) = \frac{\exp(x_i)}{\sum_i \exp(x_i)}$

Функция потерь определяется как ошибка перекрестной энтропии по всем помеченным документам:

$$L = - \sum_{d \in Y_D} \sum_{f=1} Y_{df} \ln Z_{df}, \quad (8)$$

где  $Y_D$  – набор индексов документов с метками, а  $a$  – размерность выходных объектов, равная количеству классов,  $Y$  – матрица индикаторов меток. Параметры веса  $W_0$  и  $W_1$  могут быть обучены с помощью градиентного спуска. В уравнении (7)  $E_1 = \tilde{A} X W_0$  содержит вложения документа первого слоя и слов и

$$E_2 = \text{ReLU} \left( \tilde{A} X W_0 \right) W_1.$$

Общая текстовая модель GCN схематично проиллюстрирована на Рисунке 1. Двухуровневая GCN может разрешить передачу сообщений между узлами, которые находятся на расстоянии не более двух шагов. Таким образом, хотя на графике нет прямых границ документа-документа, двухслойный GCN позволяет обмениваться информацией между парами документов.

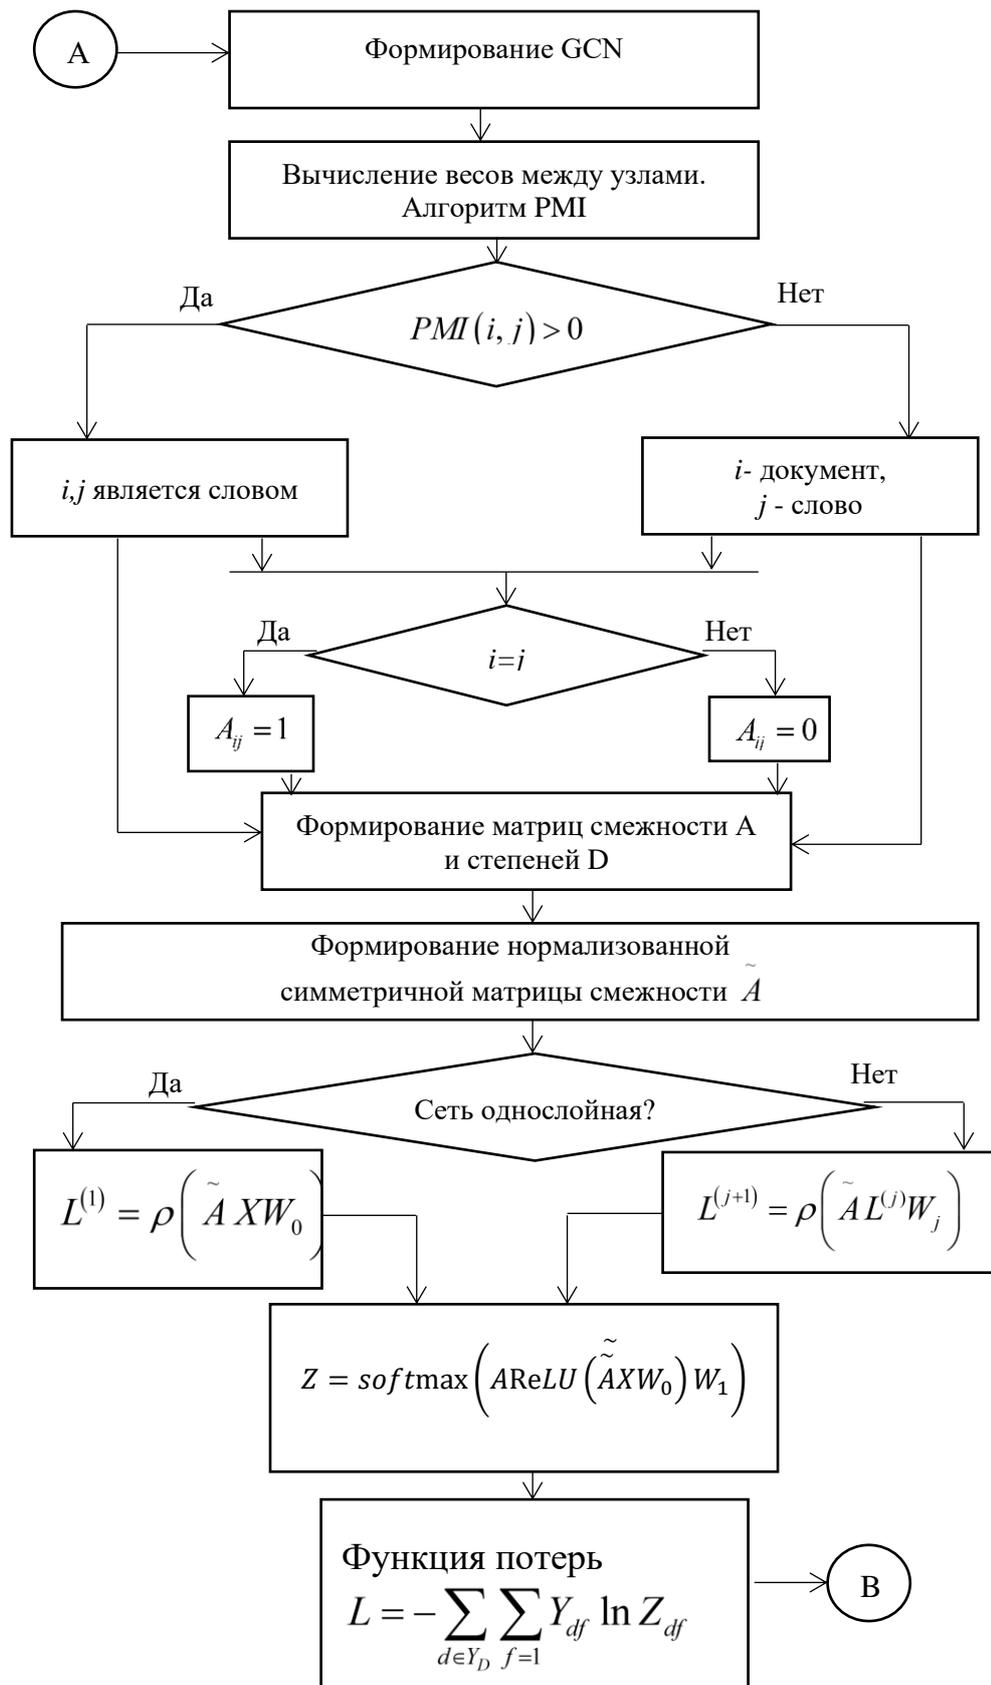
В нашем предварительном эксперименте мы обнаружили, что двухслойный GCN работает лучше, чем однослойный GCN, в то время как большее количество слоев не улучшило производительность.

На Рисунке 5 представлен алгоритм классификации контента в зависимости от эмоциональной окраски текста на основе использования графовых сверточных сетей (GCN).



Рисунок 5 – Алгоритм классификации контента в зависимости от эмоциональной окраски текста на основе использованием графовых свёрточных сетей (GCN)

Figure 5 – Algorithm for classifying content depending on the emotional coloring of the text based on the use of graph convolutional networks (GCN)



## Эксперименты

Выбрав исходные данные необходимо привести их в вид, пригодный для восприятия программным обеспечением. Реализация GCN осуществлена на языке Python с использованием соответствующего набора библиотек для анализа данных.

Процесс обработки прост в понимании и включает следующие этапы [7, 10]:

- Выбор необходимых данных из базы. В нашем случае необходим текст опубликованной записи и её оценка, которые помещаются в карту (map) для дальнейшей работы.

- Удаление из текста спец символов и особых конструкций (ссылок, имен пользователей).

- Удаление стоп-слов (шумовых слов). К таким словам относят предлоги, союзы и прочие слова, не несущие смысловой нагрузки. Списки этих слов давно известны и имеются в открытом доступе, нами был использован список библиотеки NLTK.

- Токенизация – разбиение текста на слова (с сохранением порядка использования), нам необходимо, чтобы текст воспринимался как поток слов, а не символов. Кроме выделения отдельных слов для каждой записи формируется общий набор, содержащий множество используемых слов.

- Разделение исходного набора данных. Поскольку для машинного обучения требуется минимум два набора данных, необходимо разбить имеющийся на 2 части: для обучения и тестирования. В среднем соотношение их объемов составляет 4 к 1, где для обучения используется больше данных [11]. В нашем случае это 1 280 000 и 320 000 записей, выбранных случайно.

В итоге мы получаем наборы слов, ассоциированные с их оценками, представленные в необходимом для работы виде.

Следующий этап – обучение модели векторного представления слов. Данная модель позволяет представить любое слово в виде вложения – набора чисел (вектора) заданной длины в диапазоне от -1 до 1. Значения вектора вычисляются на основе контекста, в котором слово употребляется.

Представление слов в векторном виде имеет ряд полезных свойств, наиболее важное из которых – понятие аналогий. Для векторов сходство вычисляется с помощью коэффициента косинусного сходства [25]. Для неких векторов  $\vec{q}$  и  $\vec{d}$  коэффициент вычисляется по формуле (9):

$$Sim(\vec{q}, \vec{d}) = \frac{\vec{q} \cdot \vec{d}}{|\vec{q}| |\vec{d}|} = \frac{\sum_{i=1}^n q_i d_i}{\sqrt{\sum_{i=1}^n q_i^2} \cdot \sqrt{\sum_{i=1}^n d_i^2}}, \quad (9)$$

где  $q_i$  и  $d_i$  –  $i$ -е компоненты векторов  $\vec{q}$  и  $\vec{d}$  соответственно.

Данная модель является вспомогательной и будет использована далее при обучении основной модели в качестве одного из параметров. Векторное представление также построено на базе нейронной сети, поэтому требует обучения, которое происходит на тех же исходных данных.

Заключительный этап – составление модели оценки эмоциональной окраски контента. Имея все необходимые параметры, запускаем процесс обучения нейронной сети, используя специальную библиотеку для работы с моделями на основе машинного обучения.

В итоге получаем модель для оценки эмоциональной окраски контента в виде числового коэффициента от 0 до 1, где 0 – максимально негативная запись, а 1 – максимально позитивная.

Для оценки моделей машинного обучения обычно используются две метрики: точность (accuracy) и потери (loss) [10]. Поскольку при обучении модель работает с двумя наборами данных: для обучения и для тестирования, то метрики строятся отдельно для каждого из них.

Точность определяется как отношение правильно предсказанных результатов к общему количеству предсказаний. Данная метрика вычисляется на каждом этапе (эпохе) обучения, итоговая точность модели равна значению на последнем этапе. График изменения точности модели изображен на Рисунке 6.

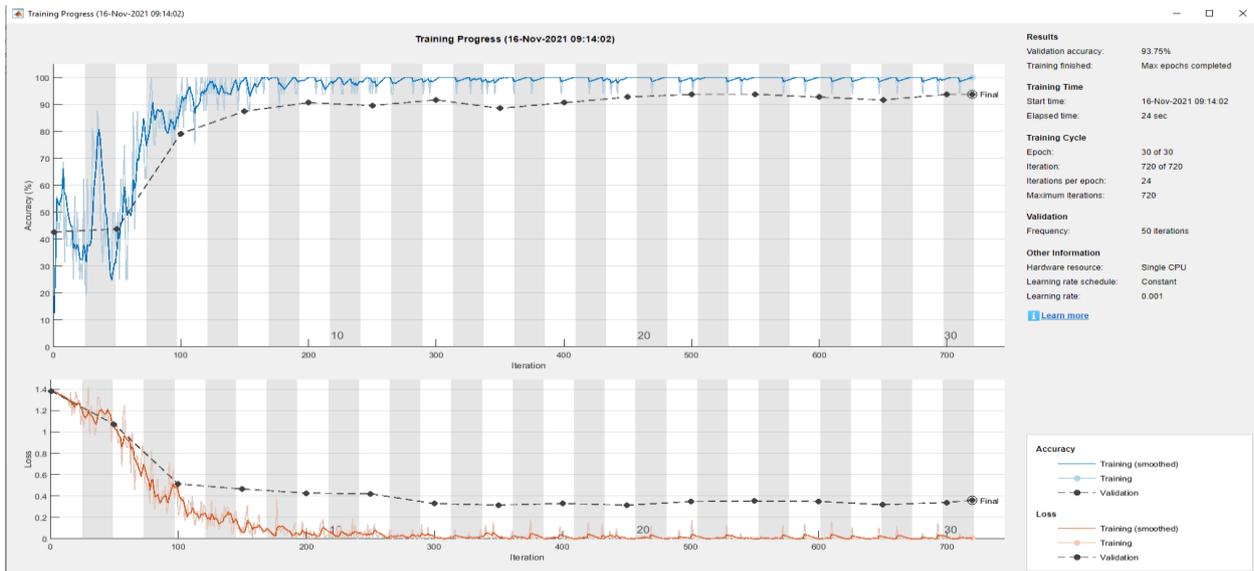


Рисунок 6 – Показатели качества модели  
Figure 6 – Model quality indicators

На этом графике синяя (нижняя) функция показывает точность при обучении, а красная (верхняя) – при тестировании. Как можно заметить, на этапе тестирования точность модели намного выше, именно для повышения качества модели используются два набора данных.

Итоговая точность полученной модели составила 93,75 %. Для наглядности также строится матрица ошибок, показывающая доли верных и неверных предсказаний. Данная матрица изображена на Рисунке 7.

Здесь на пересечении POSITIVE-POSITIVE и NEGATIVE-NEGATIVE указана доля правильного предсказания позитивных и негативных текстов соответственно. Остальные указывают на ошибочное предсказание.

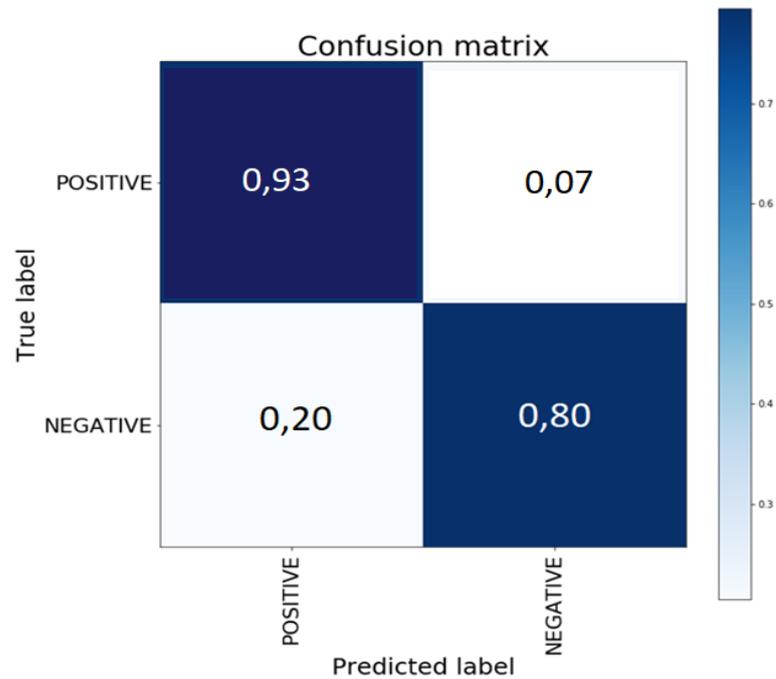


Рисунок 7 – Матрица ошибок  
Figure 7 – Matrix of errors

Потери вычисляются с помощью логистической функции потерь, вычисляемой по формуле 9:

$$\text{logloss} = -\frac{1}{l} \cdot \sum_{i=1}^l (y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)), \quad (9)$$

где  $\hat{y}_i$  – ответ алгоритма на  $i$ -ом объекте,  $y_i$  – истинная метка класса на  $i$ -ом объекте, а  $l$  – размер выборки.

Сравнение точности классификации текстовых последовательностей в зависимости от их эмоциональной окраски на основе рекуррентной нейронной сети (RNN) и с использованием графовых сверточных сетей (GCN) представлено на Рисунке 8.

На верхнем графике представлена функция точности в зависимости от количества итераций обучения с использованием рекуррентной нейросетей (LSTM). Как видно из графика точность составила – 90,63 %. На нижнем графике – представлена функция точности в зависимости от количества итераций обучения с использованием графовых сверточных сетей (GCN). Как видно из графика, точность составила 93,75 %.

Полученная модель может использоваться при оценке рисков, где получаемое значение используется в качестве корректирующего коэффициента при расчетах, например, риска вовлеченности [13-16].

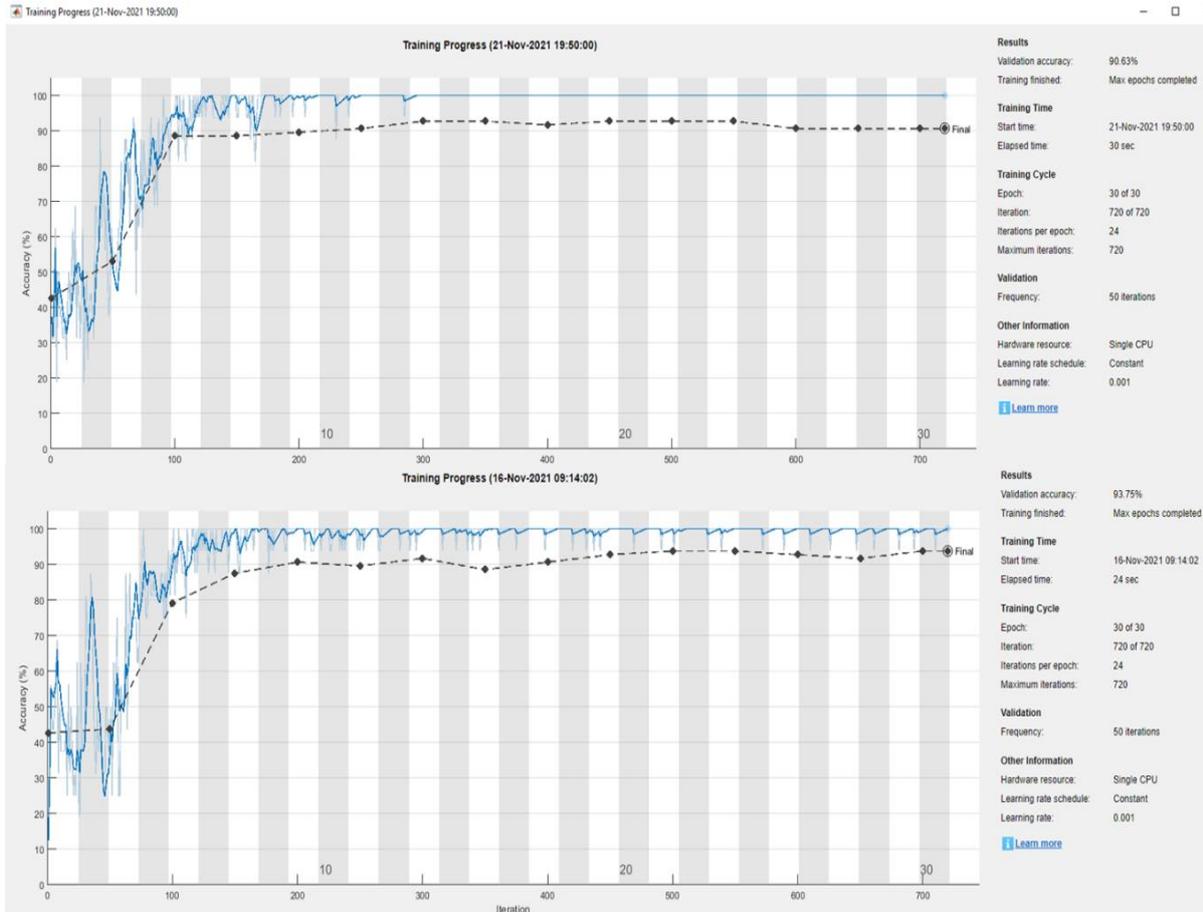


Рисунок 8 – Сравнение точности классификации текста с использованием двух нейросетевых подходов

Figure 8 – Comparison of text classification accuracy using two neural network approaches

Разумно предположить, что записи негативной эмоциональной окраски обладают большим риском, нежели нейтральные и позитивные. Если обозначить получаемый коэффициент как  $k_{emot}$ , то при известных значениях риска вовлеченности  $Risk(t)$  [17], можно скорректировать значение риска с учетом эмоциональной окраски контента, согласно формуле (10):

$$Risk_{emot} = Risk(t) \cdot (1 - k_{emot}). \quad (10)$$

При этом изначально похожая динамика рисков неких двух контентов разной эмоциональной окраски преобразуется в вид, подобный Рисунку 9.

Здесь нижний график соответствует контенту меньшей эмоциональной окраски, нежели верхний.

Таким образом, полученная модель не только имеет хорошую точность, но и является удобной в использовании в других математических системах и моделях.

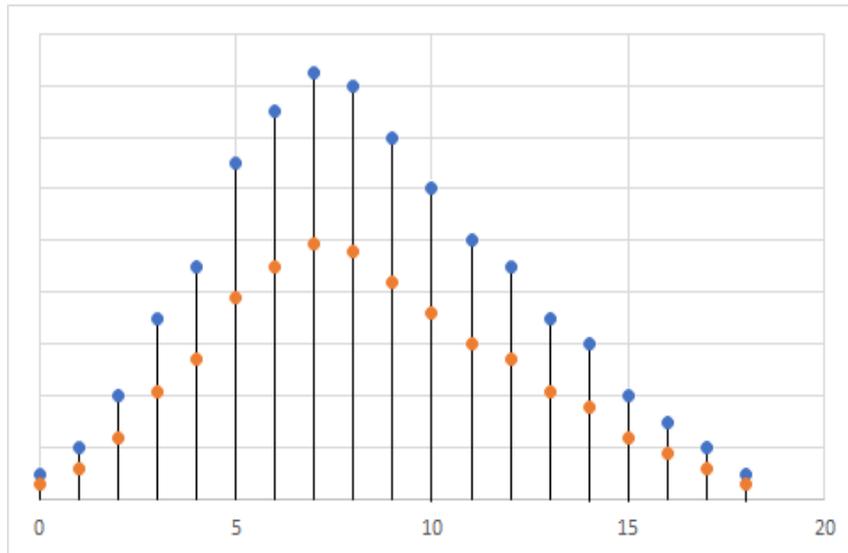


Рисунок 9 – Динамика риска  
Figure 9 – Dynamics of risk

### Заключение

Сегодня защита информации становится все более актуальной проблемой для личности, общества и государства [18, 20]. При этом волнуют не только традиционные темы получения достоверных данных [19, 21-23], но и вопросы их глубокого интеллектуального анализа [27].

В данной работе был рассмотрен процесс создания модели оценки эмоциональной окраски контента на базе нейронной сети [8]. Несмотря на то, что исследования в данной области уже проводились, их результатами являются в основном тезаурусы. Разработанные модели на основе машинного обучения обычно закрыты для публичного доступа. Публичные же модели либо имеют узкую специализацию анализа, либо не описывают процесс реализации. К тому же использование в качестве вспомогательной модели Word2vec делает разработанную модель уникальной.

Полученная модель обладает достаточно хорошим показателем точности – 93,75 %, что является лучшим (на 3,32 %) показателем по сравнению с рекуррентной сетью, а диапазон значений эмоциональной окраски (от 0 до 1) позволяет удобно использовать его в качестве коэффициента при риск-анализе контента различных социальных сетей.

### СПИСОК ИСТОЧНИКОВ

1. Aggarwal, C. C., Zhai, C. X. A survey of text classification algorithms. In Mining text data. Springer. In *Mining Text Data*. 2012;163–222.
2. Остапенко А.Г., Чапурин Е.Ю., Калашников А.О., Остапенко О.А., Остапенко Г.А. *Социальные сети и риск-мониторинг*. Под ред. член-корр. РАН Д.А. Новикова. М.: Горячая линия-Телеком; 2019;(4).
3. Hochreiter, S., and Schmidhuber, J. *Long short-term memory*. *Neural computation*. 1997. 9(8):1735–1780.
4. Battaglia, P. W.; Hamrick, J. B.; Bapst, V.; Sanchez-Gonzalez, A.; Zambaldi, V.; Malinowski, M.; Tacchetti, A.; Raposo, D.; Santoro, A.; Faulkner, R.; et al. *Relational inductive biases, deep learning, and graph networks*. *arXiv preprint*. 2018;(1).

5. Dataset sentiment analysis with tweets. Доступно по: <https://www.kaggle.com/vandalko/keras-lstm-twitter-sentiment-analysis/data>
6. Twitter API. Доступно по: <https://developer.twitter.com/en/products/twitter-api>
7. Deep learning for humans. Доступно по: <https://keras.io/>
8. Yao, Liang, Chengsheng Mao, and Yuan Luo. Graph convolutional networks for text classification. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019;33:7370-7376.
9. Rafael E. Banchs. *Text Mining with MATLAB*. Springer International Publishing; 2012. 468 с.
10. Accuracy and Loss. Доступно по: <https://docs.paperspace.com/machine-learning/wiki/accuracy-and-loss>
11. Чапурин Е.Ю. Инструментарий для исследования распределенных компьютерных систем в условиях распространения вирусного контента: тематическое моделирование вредоносных. *Информация и безопасность*. 2020;23(2):291-304.
12. Sentiment Analysis template. Доступно по: <https://github.com/floydhub/sentiment-analysis-template>
13. Белоножкин В.И., Дергачев Ю.А., Турчин А.С. Методика оценки и регулирования рисков при функционировании программных средств, формирующих технический канал утечки информации за счет программно-управляемых побочных электромагнитных излучений. *Информация и безопасность*. 2020;23(1):51-66.
14. Ружицкий Е., Шварцкопф Е.А., Манмарева В.В. Риск-ранжирование общедоступных интернет-ресурсов на основе среднесуточных измерений информационных процессов восприятия их пользователями вбрасываемых контентов. *Информация и безопасность*. 2020;23(1):97-106.
15. Ермаков С.А., Каценко Я.М., Болгов А.А. Оценка и регулирование рисков нарушения информационной безопасности телекоммуникационных сетей связи и управления промышленного интернета вещей. *Информация и безопасность*. 2020;23(1):107-114.
16. Остапенко А.Г. «Инфодемия» и социальные сети: индуцированные риски и шансы. *Информация и безопасность*. 2020;23(2):235-244.
17. Остапенко А.Г. «Инфодемия» и социальные сети: модели эпидемического процесса. *Информация и безопасность*. 2020;23(2):285-290.
18. Остапенко А.Г., Соколова Е.С., Пастернак Ю.Г. Формализация описания моновирусных эпидемических процессов в сетях. *Информация и безопасность*. 2020;23(4):497-510.
19. Штефанович Ю., Шварцкопф Е.А., Манмарева В.В. Векторная оценка опасности распространения вирусных контентов на основе среднесуточной реактивности пользователей интернет-ресурсов. *Информация и безопасность*. 2020;23(1):79-86.
20. Чапурин Е.Ю., Гуслияников А.Е., Паринава Л.В. Программно-технический комплекс для риск-анализа деструктивных контентов социальных сетей: структура, внешний вид и базы данных. *Информация и безопасность*. 2020;23(3):389-398.
21. Чапурин Е.Ю., Гуслияников А.Е., Паринава Л.В. Программно-технический комплекс риск-анализа деструктивных контентов социальных сетей: основные компоненты и уязвимости. *Информация и безопасность*. 2020;23(3):409-418.
22. Остапенко А.Г., Остапенко А.А., Лантюхов Н.М. К вопросу о трендах и инструментарии социо-информационного глобального противоборства. *Информация и безопасность*. 2020;23(4):519-524
23. Москалева Е.А., Баранников Н.И., Каребин Д.С. Картографическое исследование деятельности киберпреступных группировок в контексте повышения эффективности мер защиты. *Информация и безопасность*. 2020;23(3):431-446.

24. Сердечный А.Л., Марков Р.В., Герасимов И.В. Картографический подход исследования процессов распространения деструктивного контента в сообществах единой тематики социальной сети «ВКонтакте». *Информация и безопасность*. 2020;23(2):203-214.
25. Чапурин Е.Ю., Гуслянников А.Е., Разинкин К.А. Деструктивность контента, его классификаторы и сканеры для риск-анализа социальных сетей. *Информация и безопасность*. 2020;23(3):375-378.
26. Ружицкий Е., Шварцкопф Е.А., Манмарева В.В. Тематическая классификация интернет-ресурсов на основе векторной иллюстрации по группам потенциально опасных контентов. *Информация и безопасность*. 2020;23(1):123-132.
27. Гречишкин А.В., Рахманин Д.Н., Свиридов А.В. Модемы телекоммуникационных сетей связи и управления: защита от атак внедрения вредоносного кода на основе экспертной оценки средств защиты модема и регулирования рисков. *Информация и безопасность*. 2020;23(2):305-314.

## REFERENCES

1. Aggarwal, C. C., Zhai, C. X. A survey of text classification algorithms. In Mining text data. Springer. *In Mining Text Data*. 2012;163-22.
2. Ostapenko A.G., Chapurin E.Yu., Kalashnikov A.O., Ostapenko O.A., Ostapenko G.A. social media and risk monitoring. Ed. Corresponding Member RAS D.A. Novikov. M.: Hotline-Telecom; 2019;(4). (In Russ.)
3. Hochreiter, S., and Schmidhuber, J. Long short-term memory. *Neural computation*. 1997.9(8):1735-1780.
4. Battaglia, P.W.; Hamrick, J.B.; Bapst, V.; Sanchez-Gonzalez, A.; Zambaldi, V.; Malinowski, M.; Tacchetti, A.; Raposo, D.; Santoro, A.; Faulkner, R.; et al. *Relational inductive biases, deep learning, and graph networks*. *arXiv preprint*. 2018;(1).
5. Dataset sentiment analysis with tweets. Available at: <https://www.kaggle.com/vandalko/keras-lstm-twitter-sentiment-analysis/data>
6. Twitter API. Available at: <https://developer.twitter.com/en/products/twitter-api>
7. Deep learning for humans. Available at: <https://keras.io/>
8. Yao, Liang, Chengsheng Mao, and Yuan Luo. "Graph convolutional networks for text classification. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019;33: 7370-7376.
9. Rafael E. Banchs. *Text Mining with MATLAB*. Springer International Publishing; 2012. 468 p.
10. Accuracy and Loss. Available at: <https://docs.paperspace.com/machine-learning/wiki/accuracy-and-loss>
11. Chapurin E.Yu. Toolkit for the study of distributed computer systems in the context of the spread of viral content: thematic modeling of malware. *Informatsiya i bezopasnost' = Information and security*. 2020;23 (2):291-304. (In Russ.)
12. Sentiment Analysis template. Available at: <https://github.com/floydhub/sentiment-analysis-template>
13. Belonozhkin V.I., Dergachev Yu.A., Turchin A.S. Methodology for assessing and regulating risks in the operation of software tools that form a technical channel of information leakage due to program-controlled incidental electromagnetic radiation *Informatsiya i bezopasnost' = Information and security*. 2020;23(1):51-66. (In Russ.)
14. Ruzhitskiy E., Schwarzkopf E.A., Manmareva V.V. Risk ranking of publicly available Internet resources based on average daily measurements of information processes of

- perception of their content by users. *Informatsiya i bezopasnost' = Information and security*. 2020;23(1):97-106. (In Russ.)
15. Ermakov S.A., Katsenko Ya.M., Bolgov A.A. Assessment and regulation of risks of violation of information security of telecommunication communication networks and industrial Internet of things control. *Informatsiya i bezopasnost' = Information and security*. 2020;23(1):107-114. (In Russ.)
  16. Ostapenko A.G. Infodemia and Social Networks: Induced Risks and Opportunities. *Informatsiya i bezopasnost' = Information and security*. 2020;23(2):235-244. (In Russ.)
  17. Ostapenko A.G. «Infodemia» and social networks: models of the epidemic process. *Informatsiya i bezopasnost' = Information and security*. 2020;23(2):285-290. (In Russ.)
  18. Ostapenko A.G., Sokolova E.S., Pasternak Yu.G. Formalization of the description of monoviral epidemic processes in networks. *Informatsiya i bezopasnost' = Information and security*. 2020;23(4):497-510. (In Russ.)
  19. Shtefanovich Y., Schwarzkopf E.A., Manmareva V.V. Vector assessment of the danger of spreading viral content based on the average daily reactivity of Internet users. *Informatsiya i bezopasnost' = Information and Security*. 2020;23(1):79-86. (In Russ.)
  20. Chapurin E.Yu., Guslyannikov A.E., Parinova L.V. A software and hardware complex for risk analysis of the descriptive content of social networks: structure, appearance and databases. *Informatsiya i bezopasnost' = Information and security*. 2020;23(3):389-398. (In Russ.)
  21. Chapurin E.Yu., Guslyannikov A.E., Parinova L.V. Software and hardware complex for risk analysis of destructive content of social networks: main components and vulnerabilities. *Informatsiya i bezopasnost' = Information and security*. 2020;23(3):409-418. (In Russ.)
  22. Ostapenko A.G., Ostapenko A.A., Lantuykhov N.M. On the issue of trends and tools of socio-informational global confrontation. *Informatsiya i bezopasnost' = Information and security*. 2020;23(4):519-524
  23. Moskaleva E.A., Barannikov N.I., Karebin D.S. Cartographic study of the activities of cybercriminal groups in the context of increasing the effectiveness of protection measures. *Informatsiya i bezopasnost' = Information and security*. 2020;23(3):431-446. (In Russ.)
  24. Heart A.L., Markov R.V., Gerasimov I.V. A cartographic approach to the study of the processes of dissemination of destructive content in communities of a single subject of the social network "VKontakte". *Informatsiya i bezopasnost' = Information and security*. 2020;23(2):203-214. (In Russ.)
  25. Chapurin E.Yu., Guslyannikov AE, Razinkin KA Content destructiveness, its classifiers and scanners for risk analysis of social networks. *Informatsiya i bezopasnost' = Information and security*. 2020;23(3):375-378. (In Russ.)
  26. Ruzhitskiy E., Schwarzkopf E.A., Manmareva V.V. Thematic classification of Internet resources based on vector illustration into groups of potentially dangerous content. *Informatsiya i bezopasnost' = Information and security*. 2020;23(1):123-132. (In Russ.)
  27. Grechishkin A.V., Rakhmanin D.N., Sviridov A.V. Telecommunication and control modems: protection against malicious code injection attacks based on expert assessment of modem protection and risk management. *Informatsiya i bezopasnost' = Information and security*. 2020;23(2):305-314. (In Russ.)

## ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT AUTHORS

**Соколова Елена Сергеевна**, старший преподаватель кафедры систем информационной безопасности «Воронежский государственный технический университет», Воронеж, Российская Федерация  
*e-mail:* [lenoks.sokolova@mail.ru](mailto:lenoks.sokolova@mail.ru)

**Sokolova Elena Sergeevna**, Senior Lecturer of the Department of Information Security Systems, Voronezh State Technical University

**Разинкин Константин Александрович**, д.т.н., доцент, профессор кафедры систем информационной безопасности, Воронежский государственный технический университет, Воронеж, Российская Федерация  
*e-mail:* [kostyr@mail.ru](mailto:kostyr@mail.ru)  
ORCID: [0000-0002-2032-3777](https://orcid.org/0000-0002-2032-3777)

**Razinkin Konstantin Aleksandrovich**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Information Security Systems, Voronezh State Technical University, Voronezh, Russian Federation

**Савищенко Дмитрий Николаевич**, студент кафедры систем информационной безопасности, Воронежский государственный технический университет, Воронеж, Российская Федерация  
*e-mail:* [dima.uragan@live.ru](mailto:dima.uragan@live.ru)

**Savishchenko Dmitry Nikolaevich**, Student of Department of Information Security Systems, Voronezh State Technical University, Voronezh, Russian Federation

**Чапурин Евгений Юрьевич**, ассистент кафедры систем информационной безопасности Воронежский государственный технический университет, Воронеж, Российская Федерация  
*e-mail:* [evgeny.chapurin@mail.ru](mailto:evgeny.chapurin@mail.ru)

**Chapurin Evgeny Yuryevich**, Assistant of the Department of Information Security Systems, Voronezh State Technical University, Voronezh, Russian Federation

*Статья поступила в редакцию 05.12.2021; одобрена после рецензирования 25.12.2021; принята к публикации 28.12.2021.*

*The article was submitted 05.12.2021; approved after reviewing 25.12.2021; accepted for publication 28.12.2021.*