

пассажирам в единицу времени, сравнимое с метро. Описанный способ построения плана развозки пассажиров с помощью этой транспортной системы позволяет оптимизировать перевозку пассажиров общественным транспортом, увеличить наполняемость транспортного средства на маршруте, значительно сократить время, затрачиваемое пассажиром в пути. Это приведет к повышению качества услуг, предоставляемых населению, к снижению энергопотребления и, как следствие, к увеличению прибыли перевозчиков.

#### **Список цитированных источников**

1. Жогал, А. Н. Автоматический городской интеллектуальный пассажирский транспорт / А. Н. Жогал, В. Н. Шуть, Е. В. Швецова // Транспорт и инновации: вызовы будущего : материалы Междунар. науч. конф., Минск, 30 мая 2019 г. – Минск : Нац. б-ка Беларуси, 2019. – С. 23–33.
2. Shut, V. Mobile Autonomous Robots - a New Type of City Public Transport / V. Shut, V. Kasyanik // Transport and Telecommunication. – 2013. – Vol. 12, № 4. – P. 39–44.
3. Пролиско, Е. Е. Высокопроизводительный вид городского пассажирского транспорта на базе современных информационных технологий / Е. Е. Пролиско, В. Н. Шуть // Актуальные направления научных исследований XXI века – теория и практика : сб. науч. тр. Междунар. заоч. науч.-практ. конф., Воронеж, 14–15 нояб. 2016 г. – Воронеж : ВГЛУ, 2016. – Т. 4, № 5. – Ч. 3. – С. 336–341.
4. Пролиско, Е. Е. Динамическая модель работы транспортной системы «Инфобус» / Е. Е. Пролиско, В. Н. Шуть // Искусственный интеллект. Интеллектуальные транспортные системы : материалы науч.-техн. конф., Брест, 25–28 мая 2016 г. – Брест : БрГТУ, 2016. – С. 49–54.
5. Шуть, В. Н. Высокопроизводительная система городской транспортировки пассажиров / В. Н. Шуть, Е. Е. Пролиско // Електроніка та інформаційні технології : матеріали VIII укр.-пол. науч.-практ. конф., Львов, 27–30 авг. 2016 г. – Львов : Львов. нац. ун-т им. І. Франка, 2016. – С. 62–64.
6. Persia, L. High capacity robotic urban cluster-pipeline passengers transport / L. Persia [et al.] // Искусственный интеллект. Интеллектуальные транспортные системы : материалы Междунар. науч.-техн. конф., Брест, 25–28 мая 2016 г. / Брест. гос. техн. ун-т ; редкол.: В. А. Головкин [и др.]. – Брест, 2016. – P. 62–68.
7. Сукасян, Т. М. Оптимизация развозки пассажиров городским транспортом / Т. М. Сукасян // Сотрудничество – катализатор инновационного роста : сб. материалов 6 Белорус.-Балт. форума, Минск, 22–23 дек. 2020 г. / Белорус. нац. техн. ун-т. – Минск, 2020. – С. 94–95.

УДК 004.89

*Хацкевич А. С.*

*Научный руководитель: к. т. н., доцент Крапивин Ю. Б.*

## **НЕЙРОСЕТЕВОЙ ПОДХОД К РЕШЕНИЮ ЗАДАЧИ СЕНТИМЕНТ-АНАЛИЗА ТЕКСТА**

Целью настоящей работы является разработка программного средства, использующего библиотеки для реализации нейронных сетей и обработки текста на естественном языке, обеспечивающего возможность sentiment-анализа текста, а именно классификации тональности текста по трем категориям: «положительный», «отрицательный», «нейтральный».

Объект исследования – нейросетевая модель анализа тональности текста.

Предмет исследования – средства реализации нейронной сети, методы обработки текста.

**Сентимент-анализ** – это область компьютерной лингвистики, которая занимается изучением мнений и эмоций в текстовых документах. Целью анализа тональности является нахождение мнений в тексте и определение их свойств. В контексте данной работы – определение позиции автора относительно упомянутой темы, а именно: «положительной», «отрицательной» или «нейтральной».

Несмотря на то, что тональность является лишь одной из характеристик мнения, именно задача классификации тональности является наиболее часто изучаемой в наши дни. Это можно объяснить несколькими причинами:

- определение автора и темы является гораздо более трудными задачами, чем классификация тональности, поэтому имеет смысл сначала решить более простую задачу;

- во многих случаях достаточно лишь определить тональность, т. к. другие характеристики, например имя автора, уже известны;

- сентимент-анализ находит свое практическое применение в разных областях:
  - социология – сбор данных из социальных сетей о взглядах общества;
  - политология – сбор данных из блогов о политических взглядах населения;
  - маркетинг – анализ социальных сетей, чтобы узнать какие товары пользуются наибольшим спросом, мнение покупателей о товаре.

В качестве входного слоя нейронной сети в данной работе использовался предобученный слой-вложение модели word2vec. Для его получения была произведена предобработка текстов из размеченного корпуса англоязычных постов пользователей социальной сети Twitter [1] путем удаления специальных символов, знаков препинания и последующей токенизации предложений.

Для решения проблемы переобучения был включен слой-отсев [2]. Принцип работы слоя-отсева заключается в «исключении» некоторых нейронов из процесса обучения, что означает, что при любых входных значениях или параметрах этот нейрон возвращает значение 0. Вероятность «исключения» каждого из нейронов одинакова. Это означает следующее (формула 1):

при условии, что:

$$h(x) = xW + b, \quad (1)$$

где  $h(x)$  – линейная проекция входного  $d_i$ -мерного вектора  $x$  на  $d_h$ -мерное пространство выходных значений;  $a(h)$  – функция активации,

применение слоя-отсева к данной проекции на этапе обучения можно представить как измененную функцию активации (формула 2).

$$f(h) = \neg(D \oplus a(h)), \quad (2)$$

где  $D = (X_1, \dots, X_{d_h})$  –  $d_h$ -мерный вектор случайных величин  $X_i$ , распределённых по закону Бернулли.

$X_i$  имеет следующее распределение вероятностей (формула 3):

$$f(k; p) = \begin{cases} p, k = 1 \\ 1 - p, k = 0 \end{cases}, \quad (3)$$

где  $k$  – все возможные выходные значения.

Применение слоя-отсева к  $i$ -ому нейрону (формула 4):

$$O_i = X_i a\left(\sum_{k=1}^{d_i} w_{kxk} + b\right) = \begin{cases} a\left(\sum_{k=1}^{d_i} w_{kxk} + b\right), X_i = 1 \\ 0, X_i = 0 \end{cases}, \quad (4)$$

где  $P(X_i = 0) = p$ .

Так как на этапе обучения нейрон с вероятностью  $q$  (формула 5) остается в сети, на этапе тестирования необходимо эмулировать поведение ансамбля нейронных сетей, использованного при обучении, умножая функцию активации на  $q$ .

$$q = 1 - p, \quad (5)$$

где  $p$  – вероятность «удаления» нейрона из сети.

Таким образом, на этапе обучения (формула 6):

$$O_i = X_{ia} \left( \sum_{k=1}^{d_i} w_{kxk} + b \right), \quad (6)$$

на этапе тестирования (формула 7):

$$O_i = qa \left( \sum_{k=1}^{d_i} w_{kxk} + b \right). \quad (7)$$

Для решения проблемы долговременной зависимости, которая заключается в потере возможности связывать актуальную информацию и точку ее применения по мере роста расстояния между ними и характерная для классических рекуррентных нейронных сетей, использовалась модификация архитектуры рекуррентных нейронных сетей – долгая краткосрочная память [3].

Повторяющаяся модель в сети долгой краткосрочной памяти состоит из трех взаимодействующих слоев:

1. Слой фильтра забывания определяет, какую информацию можно удалить из состояния ячейки. Он просматривает значения предыдущего состояния ячейки и входных данных и возвращает число от 0 («полностью удалить») до 1 («полностью сохранить») для каждого значения в состоянии ячейки (формула 8).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (8)$$

где  $h_{t-1}$  – предыдущее состояние ячейки,  $x_t$  – входные данные.

2. Слой входного фильтра определяет, какая из новой информации будет храниться в ячейке. Состоит из двух частей: сначала сигмоидальная функция решает, какие значения следует обновить (формула 9), а затем функция гиперболического тангенса определяет вес передаваемых значений, определяя их уровень важности в диапазоне от  $-1$  до  $1$  (формула 10).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (9)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c). \quad (10)$$

3. Слой выходного фильтра определяет информацию, которая необходима на выходе. Сигмоидальный слой решает, какая информация попадет на выход (формула 11), а слой гиперболического тангенса дает на выходе значения из диапазона от  $-1$  до  $1$  (формула 12), которые перемножаются с выходными значениями сигмоидального слоя, что позволяет выводить только требуемую информацию.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (11)$$

$$h_t = o_t * \tanh(C_t), \quad (12)$$


где  $h_t$  – выходные данные.

Тестирование производилось путем анализа результатов обучения на тестовой выборке (рис. 1). Результатом тестирования являлась точность полученных результатов (максимум – 100%). Чтобы избежать переобучения, были использованы чекпойнты, останавливающие обучение при отсутствии значительного прироста точности.

Наилучшие результаты были достигнуты на 8 эпохах (табл. 1).

Таблица 1 – Результаты тестирования с использованием разного количества эпох

Количество эпох	Результаты обучения
1	74,77 %
2	76,59 %
3	77,03 %
4	77,32 %
5	77,45 %
6	77,63 %
7	77,70 %
8	77,74 %



**Рисунок 1 – График зависимости точности нейронной сети от эпохи: Training acc – точность на обучающей выборке, Validation acc – точность на выборке тестирования**

Также было произведено тестирование путем анализа результатов классификации тональности предложений (рис. 2).

```
predict("I love the music")  
  
{'label': 'POSITIVE',  
 'score': 0.9656286239624023,  
 'elapsed_time': 0.4439425468444824}
```

**Рисунок 2 – Результат классификации тональности предложения «I love the music»: label – присвоенный класс, score – значение по шкале отрицательности-положительности, elapsed\_time – затраченное время**

**Список цитированных источников**

1. Go, A., Bhayani, R. and Huang, L., Twitter sentiment classification using distant supervision: CS224N Project Report, Stanford, 2009 – 12 с.
2. Антонио Джулли. Библиотека Keras – инструмент глубокого обучения: перевод с англ. яз. Слинкин А. А. / Антонио Джулли, Сутжит Пал. – М. : ДМК Пресс, 2018 – 294 с.
3. Duyu Tang, Bing Qin, Xiaocheng Feng, and TingLiu, Target-dependent sentiment classification with long short-term memory, 2015 – 21 с.