

ИНТЕЛЛЕКТУАЛЬНЫЕ ИНФОРМАЦИОННЫЕ СИСТЕМЫ И ТЕХНОЛОГИИ

УДК 007:681.512.2

НЕЙРОСЕТИ НОВОГО МНОГОПОЛЯРНОГО МИРА: КЛАССИФИКАЦИЯ ЭЛЕКТРОННЫХ НОВОСТЕЙ

И. Ю. Каширин, д.т.н., профессор кафедры ВПИМ РГРТУ, Рязань, Россия;
orcid.org/0000-0003-1694-7410, e-mail: igor-kashirin@mail.ru

Рассматривается новая технология автоматической идентификации новостных материалов средств массовой информации с разделением их на прозападный контент и статьи независимых государств. В качестве источников контента используются отечественные издательства: RT, Meduza, Kremlin, Globalaffairs, Themoscowntimes, RussiaBeyond, Rossiyasegodnya, Interfax, SputnikInternational и другие. Западные информационные издания представлены в исследовании издательствами: msnbc, bloomberg, cnn, springer, nbcnew, thrguardian, facebook, nytimes, france24 и другими.

Используемые в исследовании теоретические основы опираются на концепцию нейронных сетей с концентрацией внимания, а именно двунаправленную модель с transformer-архитектурой Bert.

Экспериментальная часть материала использует программное обеспечение, ориентированное на язык Python v.3 (Anaconda 3). Программная реализация сбора текстового корпуса, последующей обработки контента и нейросетевого анализа предполагает применение инструментария nltk, transformers 4.34.1, BeautifulSoup, wordcloud, BertForSequenceClassification, torch 3.12.4, newspaper, json, tensorflow 2.14.0, accelerate 0.20.1, sklearn. Кроме перечисленного программного обеспечения, в исследованиях используется разработанный автором пакет htmlgrabber v.2.0. Выполненная серия экспериментов позволяет квалифицировать представленную технологию как технологию идентификации электронных новостей, не уступающую по эффективности имеющимся на сегодняшний день международным аналогам.

Целью работы является создание новой нейросетевой технологии, применяемой при автоматической идентификации информационного контента на естественном языке для классификации электронных новостей на западные и независимые.

Ключевые слова: нейронные Bert-сети, анализ естественного языка, идентификация новостного контента, transformer-архитектура, сборка текстового корпуса, предобученные модели.

DOI: 10.21667/1995-4565-2024-87-29-40

Введение

Современный мир с политической точки зрения стал многополярным. Подавляющее число мировых средств массовой информации (СМИ), способных формировать социальное мышление и поведение, пока еще идеологически и экономически принадлежат США и полностью зависимым от них странам Западной Европы (всего – 86 %), Японии (8 %). Целенаправленное информационное воздействие на среднестатистического обывателя сейчас определяется как информационная война, вызывающая в слабых странах либо идеологию безоговорочного подчинения, либо цветные революции с последующей потерей суверенитета. В то же время, с выходом на лидерское место Китая, СМИ независимых стран становятся все более заметными в международной конъюнктуре и пользуются непропорциональным спросом.

Способствовать многополярности стала и современная высокотехнологическая наука, авангардом которой является искусственный интеллект. Извлечение знаний из больших дан-

ных [1, 2] (Data Minig) приобрело массовый характер и стало применяться во всех сферах жизни информационного общества. Например, нейронные сети [3, 4] с успехом способны анализировать такие нюансы электронных материалов СМИ, как:

- анализ изображений [3];
- анализ настроений [4, 5];
- разжигание ненависти [6];
- верификация фейк-новостей [7, 8];
- определение авторства [9];
- вычисление семантического сходства предложений [10].

Множество исследований посвящено определению токсичности электронных материалов [11]. **Токсичным контентом** принято считать негативную информацию в разнообразных ее проявлениях, оказывающую деструктивное психологическое воздействие как на отдельную личность, так и глобальный социум. Такое воздействие является не только причиной психических заболеваний, но и провокацией горячих войн.

Какую из разновидностей токсичности и с чьей точки зрения будут анализировать модели глубокого обучения, включая нейросети, зависит от предварительной подготовки данных для обучения этих моделей, а иногда и от политической ориентации авторов этих моделей. С точки зрения автора настоящей статьи технологии, о которых идет здесь речь, должны использоваться всеми различными коллективами специалистов в области искусственного интеллекта с опорой на идеологию разных политических полюсов современного мира.

Сказанное определяет **цель** исследования: «разработка автоматической системы идентификации новостных материалов с духовно-нравственной точки зрения (контент независимых стран) и с точки зрения материального самосохранения (контент зависимых государств) на основе технологии нейронных сетей». Обе точки зрения в той или иной мере имеют право на жизнь. Таким образом, нейросеть должна определить, какой группе СМИ, условно назовем их «западной» и «восточной», принадлежит авторство электронного новостного материала. Анализу подлежат только СМИ, имеющие **англоязычную** версию контента.

Теоретическая часть

Архитектура идентификации электронных новостей

Полный жизненный цикл проектирования и применения новой, рассматриваемой здесь технологии идентификации новостных материалов (рисунок 1), включает шесть главных этапов:

- добыча данных;
- предварительная обработка информации;
- накопление данных;
- проектирование и обучение нейронных сетей;
- применение обученных моделей на конкретных примерах;
- интегральная оценка результата работы.

Перечисленные этапы изначально образуют строгую последовательность, названную пайплайном (конвейером).

Добыча данных для сборки текстового корпуса

Особенностью первого этапа, добычи данных, является извлечение информации новостных материалов с использованием соответствующих электронных web-ресурсов. Эта информация должна включать уникальный идентификатор материала, наименование СМИ, Интернет-адрес статьи, название статьи, список авторов, дату публикации, текст новостного материала и целевую метку для обучения нейронной сети (рисунок 2). Новостные материалы должны быть не просто собраны, но и разделены по тематическим рубрикам, в локальных рамках которых можно более эффективно производить анализ контента с достаточной для поставленной задачи подробностью.

В качестве источников контента используются отечественные издательства: RT, Meduza, Kremlin, Globalaffairs, Themoscwotimes, RussiaBeyond, Rossiyasegodnya, Interfax, SputnikInternational и другие. Западные информационные издания представлены в исследовании издательствами: msnbc, bloomberg, cnn, springer, nbcnew, thrguardian, facebook, nytimes, france24 и другими.

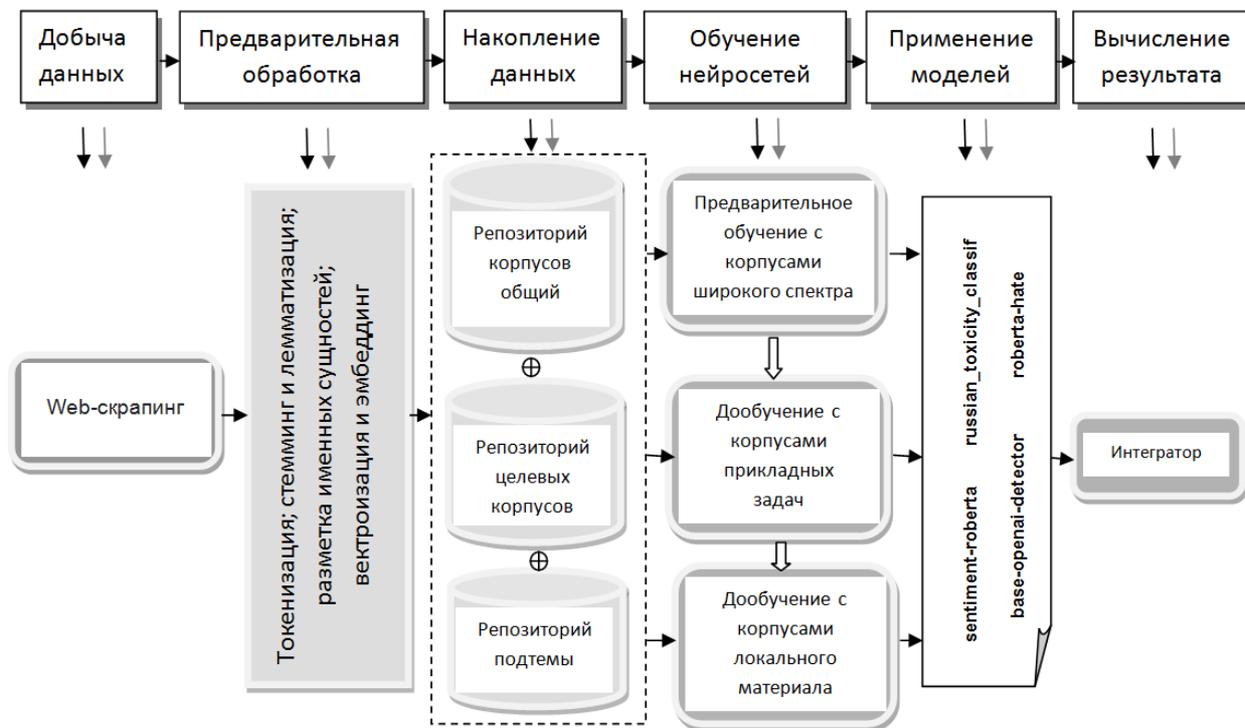


Рисунок 1 – Архитектура системы идентификации электронных новостей
 Figure 1 – Architecture of electronic news identification system

id	media	title	authors	date	text	website	label
1	0	RT Vladimir Putin — RT	Russia Today	None	EU state tells Ukrainians they will have to go...	https://www.rt.com/trends/vladimir-putin-russi...	1
2	1	RT Vladimir Putin President of Russia	Russia Today	None	Vladimir Putin newsInVisit RT to read news abo...	https://www.rt.com/tags/vladimir-putin-russian...	1
3	2	RT Putin's 2024 Campaign Headquarters Open	The Moscow Times,Farida Rustamova,Dec.	2023-12-21 00:00:00	Russian President Vladimir Putin's 2024 campai...	https://www.themoscowtimes.com/2023/12/21/puti...	1
4	3	RT Western leaders should 'stop playing the fool'...	Var AuthorsIstajsearch,Ajaxurl,Https,Www.Gl...	2023-12-22 05:52:15+00:00	Western nations that expect Russia to collapse...	https://www.globalvillagespace.com/western-lea...	1
5	4	RT Russia's Second Front in Europe	David Shedd,Ivana Stradner,Daniel Byman,Peter ...	2023-11-07 00:00:00-05:00	Like Russian President Vladimir Putin, Vucic u...	https://www.foreignaffairs.com/eastern-europe-...	1

Рисунок 2 – Структура записи базы данных электронных новостных ресурсов
 Figure 2 – The structure of database entry of electronic news resources

Учитывая международный дисбаланс контента (92 % – прозападные СМИ, 8 % – независимые СМИ), особое внимание следует уделять контенту независимых СМИ, которые так же, как и прозападные, защищены от копирования массовой информации. Весьма желатель-

но производить последующее обучение нейросетевых моделей на сбалансированных информационных выборках.

Сложность реализации этого этапа заключается в необходимости сбора информации с web-сайтов и других web-ресурсов, содержащих новостные статьи, причем в больших объемах, исчисляемых тысячами индивидуальных материалов. Такой сбор информации можно произвести только с помощью специальных программ – интеллектуальных агентов или так называемых поисковых роботов. Подавляющее большинство электронных версий СМИ содержатся на web-ресурсах, имеющих автоматические средства блокирования роботов.

Для преодоления указанных трудностей используются новые технологии web-скрапинга [12], моделирующие доступ от разных потребителей с помощью подмены данных о поисковых браузерах и организующие запросы через прокси-серверы. В представленной здесь технологии используется пакет программ htmlgrabber v.2.0, разработанный автором статьи. Проведенные работы по формированию корпуса контента для обучения моделей показали, что htmlgrabber не уступает по эффективности аналогичным программным средствам зарубежных производителей [12].

Предварительная обработка данных

Второй этап, предварительная обработка информации, является достаточно изученным и многократно реализованным в различных системах [13]. В то же время особенности технологий глубокого обучения моделей Data Mining чаще всего предполагают создание собственных специализированных фреймворков предварительной обработки отдельно для каждой из имеющихся моделей.

Общепотребительными процедурами на этом этапе являются также:

- обработка пропусков, исключение NaN-полей;
- обработка противоречий;
- очистка текста от неграмматических конструкций;
- поиск явных и неявных дубликатов;
- обнаружение выбросов как существенных текстовых отклонений;
- исключение рекламы.

Стандартными этапами предварительной обработки естественно-языковой информации, относящимися к кодированию, являются:

- токенизация;
- удаление стоп-слов;
- стемминг и лемматизация;
- разметка именованных сущностей;
- векторизация и эмбединг.

Накопление данных во времени

Этап накопления данных, являющийся в приведенной архитектуре (рисунок 1) третьим, предполагает, что первые два этапа тщательно протестированы и хорошо отрегулированы. На этом этапе формулируются требования к искомому контенту, который разбивается на тематические локалы (рубрики). Для каждой локали определяются ключевые слова, лексические шаблоны и средства фильтрации. Фильтры и шаблоны способны выделить в объемном тексте отвечающие им предложения, содержащие как общие соображения, так и точные факты, которые можно подвергать анализу и верификации. Далее приводится пример шаблона на языке Python v.3 для поиска предложений, касающихся действий президента России.

```
import spacy
nlp = spacy.load('en_core_web_sm')
from spacy.matcher import PhraseMatcher
phrase_matcher = PhraseMatcher(nlp.vocab)
phrases = ['Putin', 'President of Russia', 'president said', 'Putin claims']
patterns = [nlp(text) for text in phrases]
```


Достаточно информативным способом контроля собранного корпуса является частотная диаграмма встречаемости в текстах словарных n -грамм (рисунок 4).

В представленной технологии были использованы триграммы, т.е. словосочетания из трех слов. При рассмотрении диаграмм следует учитывать, что статистическому анализу подвергаются уже нормализованные тексты с исключением стоп-слов.

Рассмотренные средства визуализации позволяют выявить контрафактные словосочетания, которые могут представлять собой фрагменты, похожие на обычный текст статьи:

- фрагменты html-разметки сайта;
- служебные номера информационных материалов;
- словосочетания из рекламных вставок.

В этом случае средства фильтрации текстов должны быть модернизированы включением в них дополнительных стоп-слов. С течением времени корпус текстов увеличивается и словарь стоп-слов становится все более избирательным, однако электронные СМИ тоже претерпевают изменения. Таким образом, этап визуального контроля не может быть полностью исключен из технологии подготовки текстовых корпусов.

Выбор и обучение нейронных сетей

Четвертым этапом рассматриваемой технологии является обучение нейросетей. Для обработки естественно-языковых текстов можно использовать четыре наиболее известных концепции:

- лексическую модель языка [14];
- статистическую модель машинного обучения [1];
- классическую двунаправленную рекуррентную нейронную сеть [15];
- трансферные модели обучения с концентрацией внимания [16].

Модели машинного обучения перечислены здесь в порядке их исторического развития. Кратко их можно описать следующим образом.

Фактически все эти модели представляют собой инструментальные программные средства формализации структур предложения на естественном языке.

Лексические модели берут начало из основ математической лингвистики и исходят из представления синтаксической и даже семантической структуры предложения с помощью формальных грамматик. Грамматики могут записываться в форме Бэкуса – Наура, набором порождающих правил или сетевой схемой, например, расширенной рекурсивной сетью переходов [14]. При этом предложения анализируются почти в строгом соответствии с грамматикой, т.е. с жесткой последовательностью слов определенных заранее частей речи. Небольшое исключение составляют лишь трансформационные фрагменты грамматик, позволяющие «передвигать» фрагменты предложений, если они стоят не на своих местах, отклоняясь от строгих правил грамматики (рисунок 5).

Положительным свойством такой модели является абсолютно полное и точное «понимание» синтаксической структуры предложения, а иногда и понимание его семантики. Однако сложность использования лексической модели более значима с практической точки зрения: ведь вручную описать все возможные схемы предложений с различными оттенками смысла не представляется возможным. И все-таки в достаточно узких предметных областях с заданно строго очерченными целями такой подход может дать ожидаемый эффект.

Статистические модели машинного обучения [1] для анализа естественного языка основаны на предварительной векторизации текста, слова и отдельные фрагменты которого представляются в форме чисел. Числа являются входными признаками для обучения моделей, например: с помощью логистической регрессии, градиентного спуска или метода опорных векторов. Достоинством такой модели является ее простота, нетребовательность к вычислительным ресурсам и оперативность обучения. Серьезные недостатки в том, что эти модели практически не учитывают последовательность n -грамм и «забывают» предыдущие этапы обучения, что затрудняет учет контекста слов.

Нейронные сети стали существенным продвижением в технологиях обработки текстов. Классические нейросети обладают теми же недостатками, что и предыдущие модели.

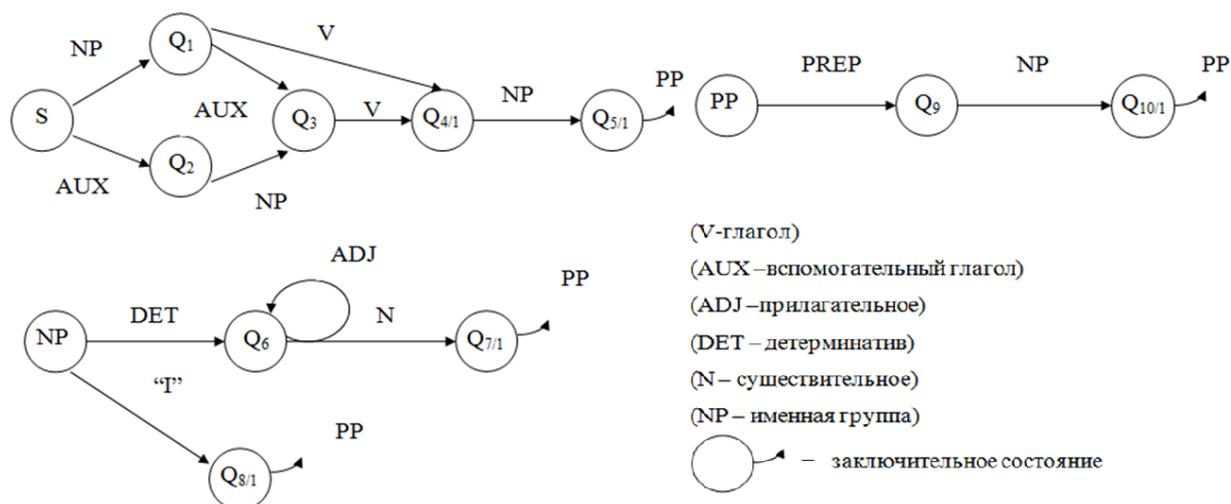


Рисунок 5 – Пример сетевой грамматики простого повествовательного предложения
 Figure 5 – Example of network grammar for a simple narrative sentence

Однако вскоре свое развитие получили рекуррентные сети (Recurrent Neural Network, RNN), в которых для каждого слова в предложении учитывается его контекст. Для каждого элемента последовательности вычислений результирующий выход зависит от предыдущих вычислений, т.е. RNN обладают памятью, учитывающей предшествующую информацию.

В *двунаправленных рекуррентных нейронных сетях* (Bidirectional RNN) предполагается, что выход в определенный момент времени зависит не только от предыдущих элементов в последовательности, но и от последующих элементов. Таким образом, учитывается контекст, стоящий слева и справа от рассматриваемого текущего слова. По сути дела, Bidirectional RNN – это просто два уровня RNN, расположенных один над другим. Выход будет определен на основе скрытого состояния обеих RNN.

Наиболее эффективным типом RNN считаются LSTM-сети [17], способные хранить долгосрочные зависимости и более детально вычислять скрытые состояния нейросети. Память в LSTM называется ячейками, принимающими в качестве входных данных предыдущее состояние и текущий входной параметр. Ячейки решают, какую память хранить, а какую стирать. При этом объединяются предыдущее состояние, текущая память и входной параметр. При всей своей эффективности рекуррентные нейросети имеют весьма значимые характеристики вычислительной сложности. Их дообучение на новых наборах данных требует «стирания» последних слоев сети с заменой на новые.

Работа BERT- сетей

Совершенно неожиданно существенным прорывом в области анализа естественно-языковых текстов стали нейронные сети, не использующие рекуррентных соединений. Ими стали сети с *механизмом концентрации внимания* на наиболее важных словах в предложении в сравнении с другими словами. Механизм внимания подбирает множители-веса, увеличивающие вес значимых слов в тексте. Это делает более точной работу нейросети.

Кроме того, в этих сетях используется архитектурное решение «энкодера-декодера» в случае с системами перевода с языка на язык или просто энкодера в других случаях.

Таковыми моделями являются BERT-сети [18] или Bidirectional Encoder Representations from Transformers – это нейросеть компании Google, имеющая эффективные результаты для многих стандартных NLP-задач, называемых бенчмарками. Программы BERT-модели есть в открытом доступе.

Фактически BERT является трансформером без декодирующей части с более мощным размером сети и слоев. BERT предобучается на «маскированной языковой модели». Модель

должна предсказать слово не в начале или конце предложения, а в любом месте вообще. Например, не «Урусла утверждает, что Россия нанесла ядерный удар в X», а «Урусла утверждает, что Россия нанесла X удар в Хиросиме». Модель называется маскированной потому, что искомая словоформа заменяется переменным токеном [X, MASK]. Это дало возможность подать на вход и учесть все части предложения, а не только левые и правые словоформы. В классическом трансформере [18] это было недопустимо.

BERT-модели апробированы на таких бенчмарках MNLI, как, например, определение связанности двух предложений: противоречат ли они друг другу, подтверждают друг друга или нейтральны. Идентификация одинаковых по смыслу вопросов входит в набор из 9 задач набора бенчмарков GLUE.

Для дообучения (файнтюнинга) в BERT нет необходимости стирать часть сети модели. Просто поверх модели добавляется новый слой нейронов. Его матрицы весов заполнены случайными числами, которые нужно вновь обучить. При этом предыдущие предобученные слои полностью сохраняются.

Упрощенная схема работы BERT-модели демонстрируется рисунком 6.

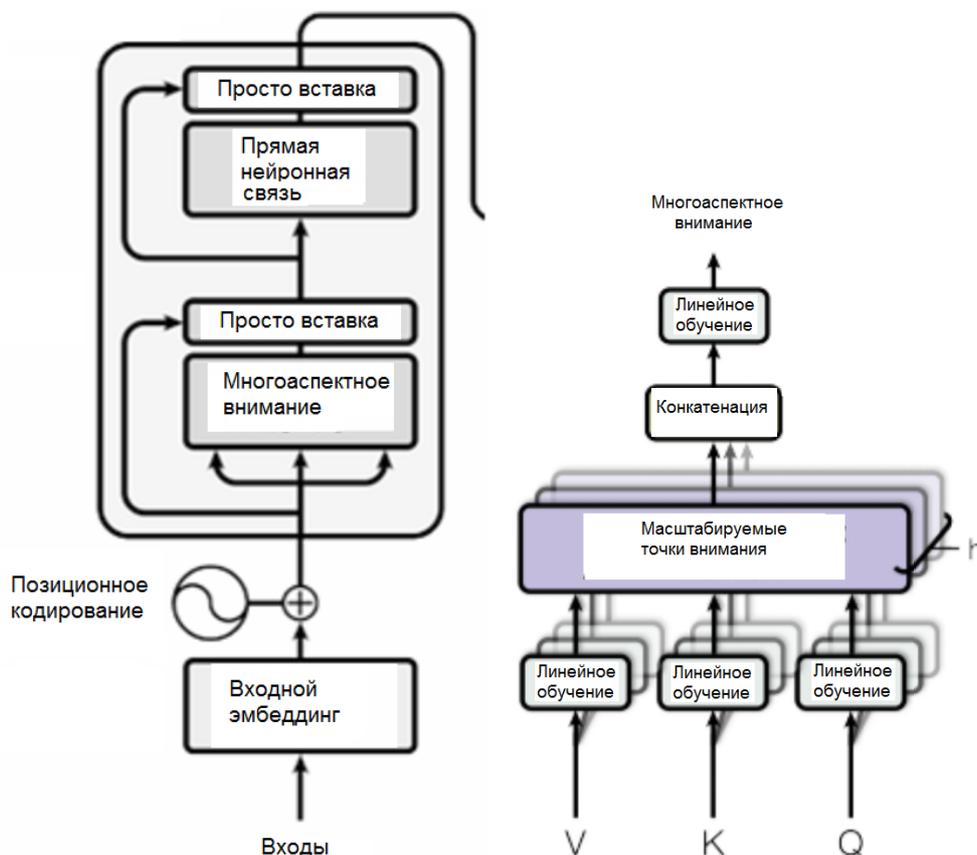


Рисунок 6 – Упрощенная схема работы BERT-сетей
Figure 6 – Simplified diagram of BERT networks

Здесь каждое слово параллельно проходит через слои нейросети, причем некоторые слои – это обычные полносвязные уровни, другие – сокращены (простая вставка). К инновации относится модуль многосвязного внимания, представляющий собой слой, обеспечивающий для каждого входного вектора взаимосвязь с другими словами посредством механизма внимания аналогично RNN.

На вход этого слоя подаются векторы Query и пары (Key, Value). Каждый вектор преобразуется обучаемым линейным преобразованием. Затем последовательно вычисляется скалярное произведение Q со всеми K, результат скалярных произведений активируется посредством softmax, и с результирующими весами все векторы V суммируются в единый вектор.

Новый слой нейронов по структуре полностью аналогичен старым. Он содержит классифицирующий токен С, определяя который BERT предсказывает тип связи между предложениями: противоречащие друг другу, взаимно подтверждающие друг друга или нейтральные по отношению к смыслу друг друга.

В результате приведенного краткого обзора моделей обучения в новой технологии, решающей поставленную вначале задачу, делается выбор в пользу BERT-сети. Новый подход, разработанный и апробированный автором, предполагает использование сразу нескольких уже предобученных нейросетей этого класса:

- нейросеть идентификации текстов GPT2 roberta-base-openai-detector [19];
- нейросеть анализа фейк-новостей [fake-news] bert-base-uncased [20];
- конвертор анализа настроений siebert/sentiment-roberta-large-english [21];
- классификатор разжигания ненависти roberta-hate-speech-dynabench-r4-target [22];
- идентификатор токсичности SkolkovoInstitute/russian_toxicity_classifier [23].

Каждая из этих нейросетей изначально анализирует окраску текста в своей целевой области и обладает своими преимуществами и недостатками. Однако, такое предобучение позволяет оценить новостные материалы для задачи поиска идеологической окраски (западная, восточная) с различных точек зрения. К тому же главным компонентом новой нейронной сети все-таки является дообучение на новых заведомо классифицированных материалах.

Таким образом, задачей *интегратора* в архитектуре рисунка 1 является правильная расстановка весов для результатов выбранных моделей. Интегратором рассчитываются веса соответственно коэффициентам точности, полученным в результате практических экспериментов. В этом заключается основа нового подхода в представленной технологии.

Экспериментальные исследования

В Рязанском государственном радиотехническом университете на основе новой технологии была проведена серия экспериментов с электронными изданиями следующих отечественных СМИ: RT, Meduza, Kremlin, Globalaffairs, Themoscowntimes, RussiaBeyond, Rossiasegodnya, Interfax, SputnikInternational и других. Из зарубежных СМИ были использованы: msnbc, bloomberg, cnn, springer, nbcnew, thrguardian, facebook, nytimes, france24 и другие. Публикации СМИ первой группы на этапе обучения помечались как «восточные», СМИ второй группы были предварительно отнесены к классу «западные».

Все перечисленные СМИ являлись источниками накапливаемого с помощью оригинальной программы htmlgrabber v.2.0. корпуса текстов на локальную тему «президент Российской Федерации Путин». Всего был собран банк статей из 450 электронных материалов общим размером 324 Кбайта. Количество восточных и западных статей было примерно сбалансировано (250 западных и 200 восточных). Общие результаты экспериментов сведены в таблицу.

В таблице 1 две характеристики F1: «запад» предполагает, что все западные СМИ должны быть распознаны как нетоксичные, «восток» предполагает, что все восточные СМИ должны быть распознаны как нетоксичные.

Таблица 1 – Основные характеристики использования предобученных моделей

Table 1 – Main characteristics of using pre-trained models

Наименование предобученной модели	Объем занимаемой памяти	Время дообучения	Точность F1 запад	Точность F1 восток
[fake-news] bert-base-uncased	387 Мб	51 мин	0.5453	0.8150
roberta-base-openai-detector	475 Мб	2 мин	0.7192	0.7027
SkolkovoInstitute/russian_toxicity_classifier	678 Мб	2,2 мин	0.6714	0.7059
siebert/sentiment-roberta-large-english	1,322 Гб	4 мин	0.7547	0.7894
facebook/roberta-hate-speech-dynabench-r4-target	470 Мб	3,1 мин	0.6780	0.6944

Заключение

Прикладное значение полученных результатов заключается в получении новой технологии вычисления идеологической окраски статей СМИ. Новая технология апробирована на новой задаче и не уступает по точности обученных моделей известным зарубежным аналогам. Накопление корпуса текстов и дообучение моделей в настоящее время продолжается.

Исходя из полученных результатов, проблему классификации можно поставить шире, если подвергнуть анализу электронные средства информации *отдельных стран* и попытаться выявить в них *информационные зависимости*. Можно, например, исследовать, *от чего* зависит трактовка новых мировых событий со стороны СМИ разных стран и политических партий.

Библиографический список

1. **Анастасьев А.А., Асташкин М.С., Агафонов П.А., Каширин И.Ю.** Определение достоверности новостей с использованием ИИ-моделей, основанных на знаниях. ИАСУ'23 – Artificial intelligence in management, control, and data processing systems. Proceedings of the II All-Russian scientific conference (Moscow, April 27-28, 2023): In 5 volumes. Moscow, Publishing House «KDU», 2023. Vol. 2. Pp.21-27.
2. **Каширин И.Ю.** Идентификация достоверности новостей с помощью моделей машинного обучения // Вестник Рязанского государственного радиотехнического университета. 2023. № 83. С. 36-47.
3. **Сатыбалдина Д.Ж., Овечкин Г.В., Калымова К.А.** Система распознавания статических жестов рук с использованием камеры глубины // Вестник Рязанского государственного радиотехнического университета. 2020. № 72. С. 93-105.
4. **Каширин И.Ю.** Нейронные сети для идентификации пользователя на основе анализа посещений новостного сайта // Вестник Рязанского государственного радиотехнического университета. 2022. № 82. С.104-111.
5. **Goularas D., Kamis S.** Evaluating deep learning techniques in sentiment analysis using Twitter data // 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML), 12–17. <https://doi.org/10.1109/Deep-ML.2019.00011>.
6. **Mullah N.S., Zainon W.M.** Advances in machine learning algorithms for hate speech detection in Social Media: A Review // IEEE Access, 9, 88364-88376. <https://doi.org/10.1109/access.2021.3089515>.
7. **Jang S.M., Kim J.K.** Third person effects of fake news: Fake news regulation and media literacy interventions // Computers in Human Behavior, 2018. 80, 295-302.
8. **Vicario M.D., Quattrociochi W., Scala A., Zollo F.** Polarization and fake news: Early warning of potential misinformation targets // ACM Transactions on the Web (TWEB). 2019, 13(2), 1-22.
9. **Clark E. et al.** All that's «human» is not gold: Evaluating human evaluation of generated text // In Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume1: LongPapers), 2021, 7282-7296.
10. **Turney P. D.** Similarity of Semantic Relations // ACM Journal on Computational Linguistics, 2006. Vol. 32. No.3. Pp. 379-416.
11. **Rupapara V., Rustam F., Shahzad H. F. et al.** Impact of SMOTE on Imbalanced Text Features for Toxic Comments Classification Using RVVC Model // IEEE Access, 9 (2021).
12. **Kotouza M.T. et al.** Towards fashion recommendation: an AI system for clothing data retrieval and analysis // In IFIP International Conference on Artificial Intelligence Applications and Innovations. Springer, Cham, 2020. 433-444.
13. **Каширин И.Ю.** Бинарные иерархические числа для вычисления семантической формулы предложений естественного языка // Вестник Рязанского государственного радиотехнического университета. 2023. № 86. С.110-121.
14. **Kashirin I.Yu., Khoroshevsky V.F.** Development of an ATN-oriented linguistic processor. Suwalki, 15-21 June, Poland, 1987.
15. **Junyoung Ch., Caglar G., Kyunghyun Ch., Yoshua B.** Gated feedback recurrent neural networks. NIPS, 2015.
16. **Usama M., Ahmad B., Song E., Hossain M.S., Alrashoud M., Muhammad G.** Attention-based sentiment analysis using convolutional and recurrent neural network // Fut. Generat. Comput. Syst. Pp. 571-578. doi: 10.1016/j.future.2020.07.022.

17. **Aslam M., Lee S.J., Khang S.H., Hong S.** Two-Stage Attention Over LSTM With Bayesian Optimization for Day-Ahead Solar Power Forecasting // IEEE Access, 9 (2021), pp. 107387-107398.
18. **Goldberg Y.** Assessing BERT's syntactic abilities. arXiv preprint arXiv:1901.2019.05287.
19. **Hartmann J., Heitmann M., Siebert Ch., Schamp Ch.** More than a Feeling: Accuracy and Application of Sentiment Analysis // International Journal of Research in Marketing. 2023. Volume 40, Issue 1, Pages 75-87.
20. **Yang F., Pentyala S.K., Mohseni S., Du M., Yuan H., Linder R., Ragan E.D., Ji S., Hu X.** Xfake: Explainable fake news detector with visualizations // The World Wide Web Conference. 2019. Pp. 3600-3604.
21. **Alantari H.J., Currim I.S., Deng Y., Singh S.** An empirical comparison of machine learning methods for text-based sentiment analysis of online consumer reviews // International Journal of Research in Marketing, 39 (1) (2022), pp. 1-19.
22. Roberta Hate Speech Dynabench R4 Target [Электронный ресурс]. Update date: 2 September, 2021 URL: <https://www.aimodels.fyi/models/huggingFace/c25caddf-0dc3-485a-b7fb-da1f4bd098b4> (дата обращения: 17.10.2023).
23. S-nlp/russian_toxicity_classifier [Электронный ресурс]. Update date: 2 October, 2021 URL: https://huggingface.co/s-nlp/russian_toxicity_classifier (дата обращения: 27.12.2023).

UDC 007:681.512.2

NEURAL NETWORKS OF NEW MULTIPOLAR WORLD: CLASSIFICATION OF ELECTRONIC NEWS

I. Yu. Kashirin, Dr. Sc. (Tech.), full professor, RSREU, Ryazan, Russia;
orcid.org/0000-0003-1694-7410, e-mail: igor-kashirin@mail.ru

A new technology for automatic identification of news media materials is being considered, dividing them into pro-Western content and the articles from independent states. Domestic publishers are used as content sources: RT, Meduza, Kremlin, Globalaffairs, Themoscowtimes, RussiaBeyond, RossiyaSegodnya, Interfax, SputnikInternational and others. Western information publications are represented in the study by publishers: msnbc, bloomberg, cnn, springer, nbcnew, thrguardian, Facebook, nytimes, france24 and others. The theoretical foundations used in the study are based on the concept of neural networks with concentration of attention, namely a bidirectional model with Bert transformer architecture.

The experimental part of the material uses software oriented to Python v.3 (Anaconda 3). The software implementation of text corpus collection, subsequent content processing and neural network analysis involves the use of nltk, transformers 4.34.1, BeautifulSoup, wordcloud, BertForSequenceClassification, torch 3.12.4, newspaper, json, tensorflow 2.14.0, accelerate 0.20.1, sklearn. In addition to the listed software, the research uses the htmlgrabber v.2.0 package developed by the author. The performed series of experiments allows us to qualify the presented technology as an electronic news identification technology, which is not inferior in efficiency to the international analogues available today.

The aim of the work is to create a new neural network technology used in the automated identification of information content in natural language to classify electronic news into Western and independent.

Keywords: neural Bert networks, natural language analysis, identification of news content, transformer architecture, text corpus assembly, pre-trained models.

DOI: 10.21667/1995-4565-2024-87-29-40

References

1. **Anastasiev A.A., Astashkin M.S., Agafonov P.A., Kashirin I.Yu.** Opredeleniye dostovernosti novostey s ispol'zovaniyem ML-modeley, osnovannykh na znaniyakh. IIASU'23 – Artificial intelligence in management, control, and data processing systems. Proceedings of the II All-Russian scientific conference (Moscow, April 27-28, 2023): In 5 volumes. Moscow, Publishing House «KDU», 2023. Vol. 2. Pp.21-27.

2. **Kashirin I.Yu.** Identifikaciya dostovernosti novostej s pomoshch'yu modelej mashinnogo obucheniya. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2023, no. 83, pp. 36-47. (in Russian).
3. **Satybaldina D.Zh., Ovechkin G.V., Kalymova K.A.** Sistema raspoznavaniya staticheskikh zhestov ruk s ispol'zovaniem kamery glubiny. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2020, no. 72, pp. 93-105. (in Russian).
4. **Kashirin I.Yu.** Neyronnyye seti dlya identifikatsii pol'zovatelya na osnove analiza poseshcheniy novostnogo sayta. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2022, no. 82, pp. 104-111. (in Russian).
5. **Goularas D., Kamis S.** Evaluating deep learning techniques in sentiment analysis using Twitter data. *2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML)*, 12–17. <https://doi.org/10.1109/Deep-ML.2019.00011>.
6. **Mullah N.S., Zainon W.M.** Advances in machine learning algorithms for hate speech detection in Social Media: A Review. *IEEE Access*, 9, 88364-88376. <https://doi.org/10.1109/access.2021.3089515>.
7. **Jang S.M., Kim J.K.** Third person effects of fake news: Fake news regulation and media literacy interventions. *Computers in Human Behavior*. 2018, 80, pp. 295-302.
8. **Vicario M.D., Quattrociochi W., Scala A., Zollo F.** Polarization and fake news: Early warning of potential misinformation targets. *ACM Transactions on the Web (TWEB)*. 2019, 13(2), 1-22.
9. **Clark, E.** et al. All that's «human» is not gold: Evaluating human evaluation of generated text. *In Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume1: Long Papers)*, 2021, 7282-7296.
10. **Turney P. D.** Similarity of Semantic Relations. *ACM Journal on Computational Linguistics*. 2006, vol. 32, no.3, pp. 379-416.
11. **Ruparapa V., Rustam F., Shahzad H. F. et al.** Impact of SMOTE on Imbalanced Text Features for Toxic Comments Classification Using RVVC Model. *IEEE Access*, 9 (2021).
12. **Kotouza M.T.** et al. Towards fashion recommendation: an AI system for clothing data retrieval and analysis. *In IFIP International Conference on Artificial Intelligence Applications and Innovations*. Springer, Cham. 2020, 433-444.
13. **Kashirin I.Yu.** Binarnyye iyerarkhicheskiye chisla dlya vychisleniya semanticheskoy formuly predlozheniy yestestvennogo yazyka. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2023. № 86. C.110-121. (in Russian).
14. **Kashirin I.Yu., Khoroshevsky V.F.** *Development of an ATN-oriented linguistic processor*. Suwalki, 15-21 June, Poland, 1987.
15. **Junyoung Ch., Caglar G., Kyunghyun Ch., Yoshua B.** *Gated feedback recurrent neural networks*. NIPS, 2015.
16. **Usama M., Ahmad B., Song E., Hossain M.S., Alrashoud M., Muhammad G.** Attention-based sentiment analysis using convolutional and recurrent neural network. *Fut. Generat. Comput. Syst.* Pp. 571-578. doi: 10.1016/j.future.2020.07.022.
17. **Aslam M., Lee S.J., Khang S.H., Hong S.** Two-Stage Attention Over LSTM With Bayesian Optimization for Day-Ahead Solar Power Forecasting. *IEEE Access*, 9 (2021), pp. 107387-107398.
18. **Goldberg Y.** *Assessing BERT's syntactic abilities*. arXiv preprint arXiv:1901. 2019. 05287.
19. **Hartmann1 J., Heitmann M., Siebert Ch., Schamp Ch.** More than a Feeling: Accuracy and Application of Sentiment Analysis. *International Journal of Research in Marketing*. 2023 Volume 40, Issue 1, pp. 75-87.
20. **Yang F., Pentyala S.K., Mohseni S., Du M., Yuan H., Linder R., Ragan E.D., Ji S., Hu X., Xfake:** Explainable fake news detector with visualizations. *The World Wide Web Conference*. 2019, pp. 3600-3604.
21. **Alantari H.J., Currim I.S., Deng Y., Singh S.** An empirical comparison of machine learning methods for text-based sentiment analysis of online consumer reviews. *International Journal of Research in Marketing*, 39 (1) (2022), pp. 1-19.
22. Roberta Hate Speech Dynabench R4 Target [Electronic resource]. Update date: 2 September, 2021 URL: <https://www.aimodels.fyi/models/huggingFace/c25caddf-0dc3-485a-b7fb-da1f4bd098b4> (date of application: 17.10.2023).
23. S-nlp/russian_toxicity_classifier [Electronic resource]. Update date: 2 October, 2021 URL: https://huggingface.co/s-nlp/russian_toxicity_classifier (date of application: 27.12.2023).