

*Д.Н. Пайвин, А.В. Глазкова*

*Тюменский государственный университет, г.Тюмень*

**УДК 004.912, 004.932**

## **РАЗРАБОТКА ВЕБ-ПРИЛОЖЕНИЯ ДЛЯ ПОДБОРА ХЕШТЕГОВ К ПУБЛИКАЦИЯМ В INSTAGRAM**

**Аннотация.** В этой работе описывается принцип работы и архитектура разработанного приложения для подбора релевантных хештегов к публикациям в Instagram.

**Ключевые слова:** Instagram, веб-приложение, NER, YOLOv3, BERT, Golang

### **Введение**

Instagram – одна из платформ для общения с клиентами. У этой социальной сети более 1 миллиард активных пользователей ежемесячно [1]. В России насчитывается около 44 миллионов пользователей [2]. Instagram является популярной платформой для продвижения брендов, это подтверждают опросы среди американских маркетологов, 69% которых планирует потратить больше половины маркетингового бюджета на продвижение через Instagram [3]. Один из действенных способов продвижения поста – это использование релевантных хештегов.

Под релевантными хештегами будем понимать слова, или фразы, которые описывают содержимое поста или его часть, при этом являясь наиболее популярными.

Под популярностью хештега подразумевается число публикаций в Instagram помеченное этим хештегом. Чем больше постов помечено этим хештегом, тем он популярнее.

Хештег тогда отражает содержимое поста, когда описывает объекты на изображении прикрепленного к посту (море, лошадь, машина), или является ключевым словом (или синонимом к нему) для текста поста.

Подбор релевантных хештегов к посту является важной задачей на пути продвижения аккаунта в Instagram, которая требует:

- выделения ключевых слов, описывающих пост;
- подбор хештегов к выделенным ключевым словам;
- селекция хештегов, т.к. социальная сеть имеет ограничение максимального числа хештегов к посту (не более 30).

Зачастую автоматизация в этой области ограничивается сервисами для подбора хештегов ([instatag.ru](http://instatag.ru), [hashtags.org](http://hashtags.org)) по ключевым словам с предоставлением числа постов помеченных этими тегами.


Такой низкий уровень автоматизации данного процесса обусловлен тем, что пост в Instagram представляет собой:

- изображение, содержимое которого может варьироваться: от автомобилей до текста на изображении;
- текст, длина которого ограничена 2200 символами, который не обязательно логически связан с изображением, прикрепленным к посту.

В этой работе описывается разработанное веб-приложение, которое на основе содержимого поста (текст и изображение) осуществляло подбор релевантных хештегов.

### **Архитектура приложения**

Глобальная архитектура системы представлена на рис.1.



*Рис. 1.* Описание архитектуры на глобальном уровне.

Система принимает от пользователя изображение и текст поста. Далее в подсистеме получения тэгов производится обработка пользовательских данных и непосредственно подбор тегов. По окончании работы подсистемы подборов тэгов, пользователю отображается результат на веб-интерфейсе приложения. Детальная архитектура подсистемы для получения тегов изображена на рис.2.




Рис. 2. Архитектура подсистемы для получения тэгов.

Блоки 2.2 - 2.5 были реализованы в качестве отдельных микросервисов. Блок 2.1 и 2.6 были реализованы единым сервисом в целях оптимизации приложения.

Пользовательские данные обрабатываются в 4 этапа:

1. Отправить пользовательское изображение в сервисы распознавания объектов и извлечения текст с изображения. (Делается параллельно в целях увеличения скорости работы приложения.)
2. Распознанный текст, полученный с предыдущего этапа, “склеить” с текстом поста и отправить в сервисы поиска ключевых слов в тексте

и поиска наименованных сущностей. (Аналогично выполняется параллельно.)

3. Названия объектов, полученных на первом этапе, именованные сущности и ключевые слова, полученные на втором этапе, используются как потенциальные теги. С помощью InstagramAPI, для каждого тега получаем число постов и список тегов, которые часто употребляются с ним (релевантные теги).
4. Список потенциальных тегов сортируется в порядке убывания по числу публикаций. Отбор тегов производится по следующему принципу. Берется тег и его релевантные теги, до тех пор, пока не наберется суммарно 30 тегов (максимальное число тегов к посту в Instagram), или список потенциальных тегов не закончится.

Далее подробно рассмотрим сервисы поиска объектов на изображении, распознавание текста на изображении, поиска именованных сущностей и поиска ключевых слов в тексте.

### **Поиск объектов на изображении**

Для поиска объектов на изображении использовалась нейронная сеть архитектуры YOLOv3[4]. Выбор данной нейросети обусловлен тем, что она в 4 раза быстрее чем RetinaNet, имея при этом схожий процент распознавания по mAP метрики при 0.5 IOU (рис. 3) [4]. Сравнение проводилось на датасете COCO [5].




Рис. 3. Сравнение качества распознавания и время работ сетевых архитектур.

Архитектура YOLOv3 представлена на рис.4.




Рис. 4. Архитектура YOLOv3.

YOLOv3 — это усовершенствованная версия архитектуры YOLO. Она состоит из 106-ти сверточных слоев и лучше распознает небольшие объекты по сравнению с её предшественницей YOLOv2. Основная особенность YOLOv3 состоит в том, что на выходе есть три слоя каждый

из которых рассчитан на обнаружения объектов разного размера. Список распознаваемых объектов представлен в [6].

## Распознавание текста на изображении

Tesseract — это механизм распознавания текста с открытым исходным кодом (OCR), доступный по лицензии Apache 2.0. Его можно использовать напрямую или с помощью API для извлечения печатного текста из изображений. [7].

Tesseract 4 - поддерживает распознавание текста на основе нейронной сети (LSTM), сохраняя обратную совместимость с предыдущими версиями пакета. Tesseract поддерживает Unicode (UTF-8) и может распознавать более 100 языков "из коробки". Tesseract поддерживает различные форматы вывода : простой текст, hOCR (HTML), PDF, TSV. Неотъемлемым преимуществом Tesseract, является то, что библиотека не требует предварительных обработок изображения. На рис.5 [8] изображен принцип работы библиотеки Tesseract.




Рис. 5. Принцип работы библиотеки Tesseract.

## Поиск именованных сущностей

Для поиска именованных сущностей использовалась предобученная мультязычная модель BERT-архитектуры от проекта Deepavlov [9].

Список выделяемых сущностей представлен в официальной документации [9], в этой работе использовалось лишь небольшое подмножество доступных сущностей. Список используемых сущностей и их описание представлено ниже:

- PERSON - люди, в том числе вымышленные.
- ORGANIZATION - компании, агентства, учреждения.
- GPE - страны, города, штаты.
- WORK OF ART - названия книг, песен.
- DATE - абсолютные или относительные даты или периоды.

### **Поиск ключевых слов в тексте**

Для поиска ключевых слов в тексте использовался алгоритм TextRank, а именно его реализация [10] на языке python. Подробное описание принципа работы этого алгоритма изложен в [11].

Пример работы алгоритма TextRank. Пусть на вход подается текст: “Этот город был столицей России, в разные времена назывался Петроград и Ленинград, праздновал недавно своё трёхсотлетие и является популярным туристическим местом. Это всё Санкт-Петербург или в просторечии – Питер.” Ключевые слова, выделенные этим алгоритмом: россия, столица, называться.

### **Пример работы приложения**

Как уже упоминалось ранее, система была реализована в виде веб-приложения, где пользователь заносит текст и изображение поста. Далее пользователь нажимает кнопку “Отправить” и через небольшой промежуток времени ему возвращается список релевантных тэгов, который можно скопировать в буфер обмена с помощью кнопки “Копировать”. Пример использования приложения представлен на Рис. 6.

 Подбор тэгов

Текст	Изображение
<p>Санкт-Петербург это древний и очень красивый город нашей страны России. Он является вторым по величине после Москвы, это важнейший центр туризма, экономики, медицины, науки, культуры нашего государства. Этот город имеет очень богатое историческое наследие для всего человечества нашей планеты. Очень важными известными историческими зданиями являются Зимний дворец, Эрмитаж.</p>	<div style="display: flex; justify-content: space-between;"><span>Mosbus_2-19-2.jpg</span><span>Загрузить</span></div> 
<b>Отправить</b>	
<p style="text-align: center;">Релевантные тэги</p> <pre>#санктпетербург #спб❤ #москва #петербург #питер #мск #москвасити #санктпетербург2020 #дворцоваяплощадь #питег #питер❤ #автомобиль #авто #автосалон #автозапчасти #иномарки #автолюбитель #машине #диски #автотюнинг #руль #мазда #человек #смысл #мысли #сознание #интерес #творец #состояние #мозг</pre>	
<span style="background-color: #4a7ebb; color: white; padding: 2px 10px; border-radius: 3px;">Копировать</span>	

*Рис. 6. Пример работы приложения*

## Заключение

В результате проведенной работы было разработано веб-приложение, для подбора релевантных хештегов к посту в Instagram. Веб - часть приложения было реализована на языке javascript с использованием библиотеки jQuery. Серверная часть приложения была реализована на двух языках программирования: Golang, Python.

Golang использовался для реализации непосредственного бэкэнда веб приложения. Использование этого языка программирования позволило сделать многопоточное приложение, что повысило производительность приложения.

Python использовался для взаимодействия с высокоуровневым API используемых нейронных сетей, т.к. этот язык очень популярен в среде научного программирования.

## СПИСОК ЛИТЕРАТУРЫ

1. Number of monthly active Instagram users from January 2013 to June 2018. URL: <https://www.statista.com/statistics/253577/number-of-monthly-active-instagram-users/> проверено 10.05.2020
2. Countries with the most Instagram users 2020. URL: <https://www.statista.com/statistics/578364/countries-with-most-instagram-users/> проверено 10.05.2020
3. Influencer marketing 2019 industry benchmarks. URL: <https://mediakix.com/influencer-marketing-resources/influencer-marketing-industry-statistics-survey-benchmarks> проверено 10.05.2020
4. YOLO: Real-Time Object Detection, <https://pjreddie.com/darknet/yolo/> - проверено 10.04.2020
5. Датасет “COCO 2019” URL: <http://cocodataset.org/> - проверено 10.04.2020
6. Список распознаваемых объектов на изображении, <https://github.com/pjreddie/darknet/blob/master/data/coco.names> - проверено 10.04.2020

7. Tesseract OCR, <https://github.com/tesseract-ocr/tesseract/wiki> - проверено 09.04.2020
8. Chawla, Muskan and Jain, Rachna and Nagrath, Preeti, Implementation of Tesseract Algorithm to Extract Text from Different Images (May 1, 2020). URL: <https://ssrn.com/abstract=3589972>
9. Named Entity Recognition (NER), <http://docs.deeppavlov.ai/en/master/features/models/ner.html> - проверено 10.04.2020
10. summa – textrank, реализация алгоритма TextRank, <https://github.com/summanlp/textrank> - проверено 10.04.2020
11. Rada Mihalcea, Paul Tarau. TextRank: Bringing Order into Texts, //Department of Computer Science University of North Texas 2004. <https://web.eecs.umich.edu/~mihalcea/papers/mihalcea.emnlp04.pdf>