



Multilingual Open-Domain Question Answering Model

Mykyta Syromiatnikov, Olexander Tsurkan and
Victoria Ruvinskaya

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

October 30, 2021

МНОГОЯЗЫЧНАЯ МОДЕЛЬ ОТВЕТА НА ВОПРОСЫ С ОТКРЫТОЙ ПРЕДМЕТНОЙ ОБЛАСТЬЮ

Сыромятников Н.В., Цуркан А.В.

проф. каф. СПО, к.т.н. Рувинская В.М.

Одесский Национальный Политехнический Университет, УКРАИНА

АННОТАЦИЯ. Рассматривается разработка многоязычной модели ответа на вопрос с открытой предметной областью. Для реализации были задействованы глубокие нейронные сети на основе архитектуры *Transformer*, методы градиентного бустинга и технологии векторного представления слов.

Введение. В последние годы сфера NLP стремительно развивается и соизмеримо расширяется спектр решаемых задач. Доказательством этому может послужить задача нахождения ответа на вопрос с открытой предметной областью (ODQA), суть которой состоит в нахождении фрагмента текста, релевантного вопросу. Источником информации при этом может служить любое хранилище документов, например Википедия, как это было в случае с DrQA [1].

Цель работы. Целью работы является создание многоязычной модели ODQA, заточенной под русский и украинский языки. Важным аспектом реализации также является повышение скорости обработки запросов путем уменьшения размеров компонентов модели без существенных потерь в качестве.

Основная часть работы. В общем случае архитектура модели нахождения ответа на вопрос состоит из двух модулей: ранжировщика и чтеца [2]. Задачей ранжировщика является сортировка документов в порядке их релевантности запросу. Чтец же находит в документе фрагмент, который с наибольшей вероятностью является ответом на заданный вопрос.

Рассмотрим реализацию ранжировщика. Стандартным подходом является сравнение сходства двух строк. Для этой задачи существуют технологии векторного представления, такие как Word2Vec (использует слова) и FastText (использует n-граммы). Однако для многоязычных моделей они не применимы. В связи с этим Facebook AI Research разработали архитектуру для использования многоязычных эмбедингов [3], представленную в библиотеке Laser.

Для оптимизации решения под нашу задачу воспользуемся классификатором, на вход которому будет подаваться горизонтальная конкатенация векторных представлений двух фраз, полученных с помощью Laser, а на выходе будем получать вероятности предсказания схожести. Сам классификатор представляет из себя модель градиентного бустинга, реализованную в библиотеке XGBoost. Используемые параметры модели: $n_estimators=1500$, $lr=0.1$, $max_depth=3$, $subsample=0.8$. Итоговые метрики моделей классификации близости предоставлены в таблице 1.

Помимо ансамбля деревьев решения (Laser-XGBoost) была рассмотрена модель на основе архитектуры Transformer. BERT – модель представления естественного языка, которая во всех слоях использует левый и правый контекст [4]. Данная модель после *fine-tuning* показывает *state-of-the-art* на многих задачах классификации текстов. В задаче определения сходства двух текстов воспользуемся *bert-base-multilingual-cased* и добавим выходным слоем линейный классификатор с последующей *sigmoid* в качестве функции активации, функция потерь – *cross-entropy loss*.

В результате оценивания Bert-classifier оказался сравним с моделью Laser-XGBoost на тестовых сетях русского и украинского языков, но в то же время он значительно медленнее. Для ускорения воспользуемся *knowledge distillation* [5]. Данный метод заключается в передаче знаний от “учительской” сети (Bert classifier) “ученику” (DistilBert-classifier), в нашем случае это 4-слойный bert-cased. Формула 1 отображает функцию потерь сети-ученика во время обучения:

$$L = \alpha * L_{cross\ entropy}(\hat{Y}_{student}, Y_{student}) + (1 - \alpha) * L_{mse}(\hat{Y}_{student}, \hat{Y}_{teacher}) \quad (1)$$

где α – гиперпараметр в пределах $[0, 1]$, во время обучения было использовано значение 0.5.

Таблица 1 – Сравнение моделей в задаче классификации схожести

Модель/метрики	F1	F1 ru	F1 uk	F1 en	Время, с 100 док-ов	Время, с 1000 док-ов
Laser-XGBoost-classifier	0.915	0.92	0.931	0.895	0.015	0.063
Bert-classifier	0.875	0.93	0.917	0.784	36.2	370
DistilBert-classifier	0.865	0.928	0.944	0.732	12	123.1

Laser-XGBoost обучена на датасете из 190 тысяч семплов запросов и контекстов на трёх языках, Bert-модели – на его сокращенной (50 тысяч семплов) версии. DistilBert по скорости превзошла Bert в 3 раза, потеряв в точности только на английском языке.

В таблице 2 модели сравниваются на задаче ранжирования. Здесь на вход, помимо запроса, поступает несколько контекстов, и при использовании базовых моделей recall будет ощутимо снижаться. Для решения этой проблемы вводится параметр W – ширина окна. $W = n$ определяет, что вычисление результатов будет проводиться по n -первым документам, отсортированным по близости к запросу. Вероятность для последовательных моделей считалась как их среднее.

Таблица 2 – Сравнительные характеристики моделей в задаче ранжирования контекстов

Модель/метрики	F1	Precision	Recall	F1 ru	F1 uk	F1 en	Время, с 100 док-ов	Время, с 1000 док-ов
Laser-XGBoost (W=20)	0.906	0.995	0.832	0.931	0.901	0.895	0.015	0.063
Laser-XGBoost (W=50)	0.945	0.977	0.915	0.965	0.945	0.929	0.015	0.063
Laser-XGBoost (W=50) → DistilBert (W=5)	0.925	0.99	0.868	0.955	0.937	0.868	6.1	6.2
Laser-XGBoost (W=50) → DistilBert (W=10)	0.943	0.99	0.9	0.964	0.944	0.914	6.1	6.2

Лучшей стала модель Laser-XGBoost с окном в 50 позиций, но наиболее целесообразно использовать последовательную Laser-XGBoost (W=50) → DistilBert (W=10), потому как она сокращает до 10 позиций результирующий набор, что повысит производительность модуля QA.

Заключительным этапом является разработка модели чтеца. На данный момент *state-of-the-art* результаты в этой задаче показывают модели на основе BERT. Воспользуемся предобученной версией BertForQA от Hugging Face и дообучим её на аугментированном датасете, состоящем из SQuAD 2.0 и SDSJ 2017. Результаты тестирования предоставлены в таблице 3.

Таблица 3 – Результаты обучения модели QA

Модель/метрики	EM	F1	EM uk	F1 uk	Время, с 10 док-ов	Время, с 1000 док-ов
BertForQA	0.63	0.71	0.74	0.823	0.225	2.35

EM – *exact match*, точное совпадение ответа с предсказанным фрагментом. Измерение для украинского языка производилось на отдельном сете из 100 вопросов, собранном вручную [6].

Итоговая архитектурная схема модели ODQA представлена на рисунке 1.

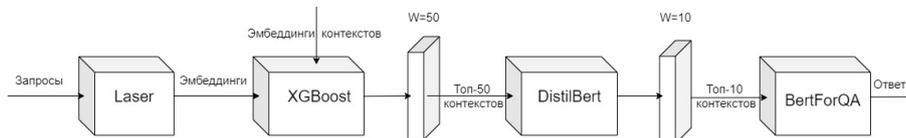


Рис. 1 – Итоговая схема модели ODQA, W – ширина окна

Выводы. В результате сравнительного анализа технологий была предложена и реализована архитектура многоязычной модели для решения задачи ответа на вопрос с открытой предметной областью. F1 ранжировщика для русского и украинского языков составила 96.4 и 94.4 единиц соответственно, при этом без существенных потерь в качестве после ускорения модели Bert в 3 раза и уменьшения размера окна выдачи (W) в 5 раз. F1 модели ответа на вопрос в виде взвешенного среднего на символьном уровне составила 71 единицу, *exact match* – 63 единицы.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Архив электронных публикаций научных статей [Электронный ресурс]. – Режим доступа: URL: <https://arxiv.org/abs/1704.00051>. – Reading Wikipedia to Answer Open-Domain Questions.
2. Архив электронных публикаций научных статей [Электронный ресурс]. – Режим доступа: URL: <https://arxiv.org/abs/1709.00023>. – R3: Reinforced Reader-Ranker for Open-Domain Question Answering.
3. Архив электронных публикаций научных статей [Электронный ресурс]. – Режим доступа: URL: <https://arxiv.org/abs/1812.10464>. – Massively Multilingual Sentence Embeddings for Zero-Shot Cross-Lingual Transfer and Beyond.
4. Архив электронных публикаций научных статей [Электронный ресурс]. – Режим доступа: URL: <https://arxiv.org/abs/1810.04805>. – Pre-training of Deep Bidirectional Transformers for Language Understanding
5. Архив электронных публикаций научных статей [Электронный ресурс]. – Режим доступа: URL: <https://arxiv.org/abs/1903.12136>. – Distilling Task-Specific Knowledge from BERT into Simple Neural Networks.
6. Dev-human-v2.0 [Электронный ресурс]. – Режим доступа: URL: <https://github.com/s-e-r-g-y/context-based-qa-for-uk/blob/master/datasets-uk/dev-human-v2.0.json>. – Назва з екрана.