Многоязычный поиск ранее проверенных утверждений для верификации фактов

Николаев Е.Н.
nikolaev.en@phystech.edu

Центр когнитивного моделирования МФТИ

2024 – Научно-исследовательский семинар



Мотивация



Количество контента, публикуемое в медиа, существенно превосходит возможности специалистов по проверке фактов, особенно учитывая кросс-языковую природу данных. Автоматизированный подход на основе нейросетей может помочь им, извлекая уже существующие методы проверки фактов, относящиеся к исследуемому контенту.

Задача



Задача: Разработать систему для эффективного поиска проверенных утверждений (истинных или ложных) релевантных запросу

Формальная постановка задачи



Дано:

- Запрос Q, содержащий одно или несколько утверждений $\{Q_1, Q_2, \ldots, Q_k\}$.
- Корпус C состоящий из документов (проверенных утверждений) D_i, потенциально позволяющих подтвердить или опровергнуть утверждения, приведенные в запросе Q.

Формальная постановка задачи

Цель: Составить поисковую функцию $R(Q, C) \to \{D_1, D_2, \ldots, D_k\}$, выбирающая top-$k$ релевантных документов, удовлетворяющих следующим требованиям:

1. Каждое утверждение Q_i из $\{Q_1, Q_2, \ldots, Q_k\}$ должно подтвержаться или опровергаться каким либо D_j из $\{D_1, D_2, \ldots, D_k\}$..
2. Каждое утверждение D_j из $\{D_1, D_2, \ldots, D_k\}$ должно подтвержать или опровергать какое либо утверждение Q_i из $\{Q_1, Q_2, \ldots, Q_k\}$.

Данные

Для проведения экспериментов и оценки эффективности модели был выбран датасет MultiClaim

- 28 тысяч запросов на 27 языках из социальных сетей.
- 206 тысяч проверенных утверждений на 39 языках, написанных профессиональными специалистами по проверке фактов.
- 31 тысяча пара пост-утверждение.

Методы оценки



- Success-at-10 – вхождение всех необходимых проверенных утверждений в top-10 наиболее веротяных утверждений.

Базовая схема поиска

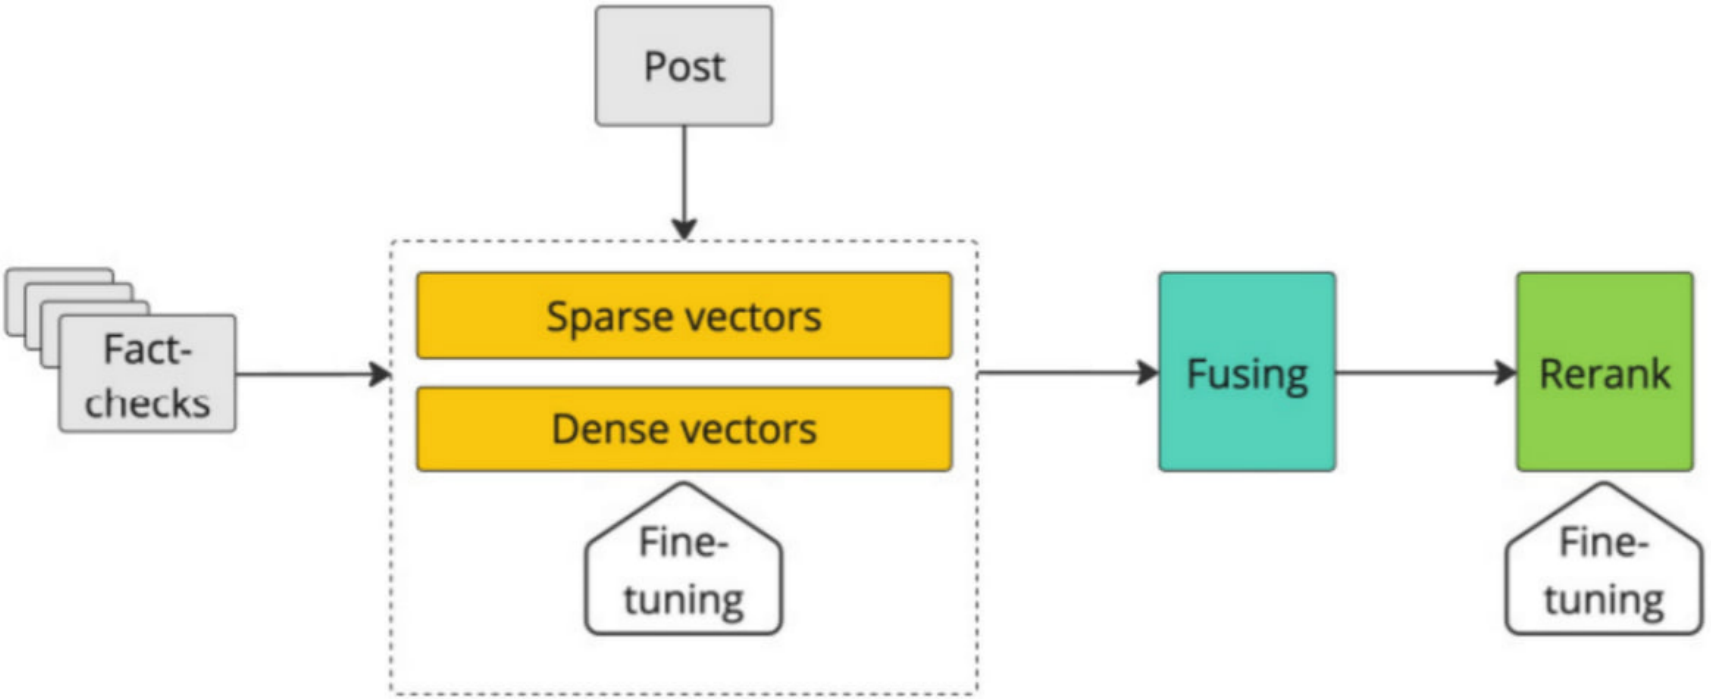

Базовый подход к поиску утверждений

Векторный поиск



Для опоры на лексическую составляющую текста были выбраны следующие подходы:

1. BM25
2. BGE-m3-lexical

Для опоры на семантическую составляющую текста были выбраны следующие модели:

1. stella_en_1.5B_v5
2. BGE-m3-dense
3. multilingual-e5-large-instruct (промт *"Given a post on a social network, retrieve the claims it contains"*)

Для объединения резултата был использован Reciprocal rank fusion (RRF)

Реранкер



Для улучшения качества выдачи также был произведено повторное ранжирование с помощью модели BAAI/bge-reranker-v2-m3.

Эта модель имеет кросс-энкодерную архитектуру т.е. оценивает соотвествие запроса и ответа в виде query[SEP]answer

Дообучение



Обучение проводилось в 2 этапа с опорой на результат sparse-составляющей векторного поиска:

1. Позитивные примеры берутся из top-5. Негативные примеры выбираются случайно по всей выборке. Отношение pos:neg = 1:5
2. Позитивные примеры берутся входят в диапозон 4-15 наиболее вероятных при sparse-поиске. Негативные примеры берутся из top-25. Отношение pos:neg = 1:8

Дообучение

Для дообучения dense-составляющей была использована модель BAAI/BGE-m3 и использованием contrastive loss

Contrastive Loss

$$L(x_1, x_2, y) = \frac{1}{2}\left(y \cdot d(x_1, x_2)^2 + (1-y) \cdot \max(0, m - d(x_1, x_2))^2\right)$$

где:

- x_1, x_2 — векторы признаков для двух объектов,
- y — метка: $y = 1$, если объекты похожи, и $y = 0$, если непохожи,
- $d(x_1, x_2)$ — косинусное расстояние между x_1 и x_2,
- m — зазор (margin), который определяет минимальное желаемое расстояние между непохожими объектами.

Дообучение

Для обучения реранкера была взята модель BAAI/bge-reranker-v2-m3.

В силу существенного дисбаланса позитивного и негативного классов при обучении использовалась функция потерь Focal Loss с коэфициентами $\alpha = 0.9$ и $\gamma = 4.0$

Focal Loss

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t)$$

где:

- p_t — вероятность правильной классификации,
- α_t — весовой коэффициент для класса,
- γ — фокусирующий параметр (гамма).

Результаты

Sparse	Dense	Fusion	Rerank	Mono	Cross
BGE-m3-lexical	–	–	No	80.44	61.17
–	BGE-m3-dense	–	No	78.91	65.9
–	BGE-m3-dense-finetuned	–	No	67.02	65.4
BGE-m3-lexical	BGE-m3-dense-finetuned	1:1	Yes	<u>85.90</u>	**67.2**
		8:2	No	85.43	<u>66.95</u>
		8:2	Yes	**86.01**	66.57
BM25	–	–	No	62.96	56.15

Таблица: Результат межъязыковых (Cross) и одноязычных (Mono) заданий. Измеряется как Success-at-10, %. Слияние $k : n$ указывает на sparse k и dense вес n при RRF.

Дальнейшие шаги



1. Продолжение дообучения моделей
2. Оичстка и преобразование исходного текста с помощью LLM
3. Использование дополнительных моделей для поиска
4. Улучшение механизма агрегации поиска

Спасибо за внимание!

nikolaev.en@phystech.edu