

Методы поиска почти-дубликатов рукописных документов в больших коллекциях текстов

Бахтеев Олег Грабовой Андрей Каприелова Мариам
Кильдяков Александр Сейил Темирлан Финогеев Евгений
Чехович Юрий

Антиплагиат

Проблема

- Во многих отраслях все еще присутствуют рукописные тексты, и множество таких текстов растет.
- На текущий момент не существует методов распознавания рукописного текста, работающих с достаточным качеством.
- Задача усложняется отсутствием разметки и невозможностью до-обучить систему распознавания текста на почерке автора сочинения.

Цель Разработка метода обнаружения почти-дубликатов в изображениях рукописного текста.

Приложение Использование системы для поиска заимствований в рукописных сочинениях школьников.

Постановка задачи

$\mathcal{D}_{\text{susp}} = \{d_{\text{susp}}^i\}_{i=1}^n$ — множество рукописных текстов для проверки.

$\mathcal{D} = \{d^j\}_{j=1}^m$ — множество текстовых документов коллекции.

Документ $d_{\text{susp}}^i \in D_{\text{susp}}$ имеет один источник заимствования $g : D_{\text{susp}} \rightarrow D$.

Требуется найти отображение $f : D_{\text{susp}} \rightarrow \{0, 1\}^D$, решая задачу:

$$\hat{f} = \arg \max_{f \in \mathcal{F}} (\text{Recall@K}(f, g, D, D_{\text{susp}})),$$

где \mathcal{F} — множество рассматриваемых моделей,

$$\text{Recall@K} = \frac{1}{|D_{\text{susp}}|} \sum_{d_{\text{susp}}^i} |f(d_{\text{susp}}^i) @K \cap \{g(d_{\text{susp}}^i)\}|,$$

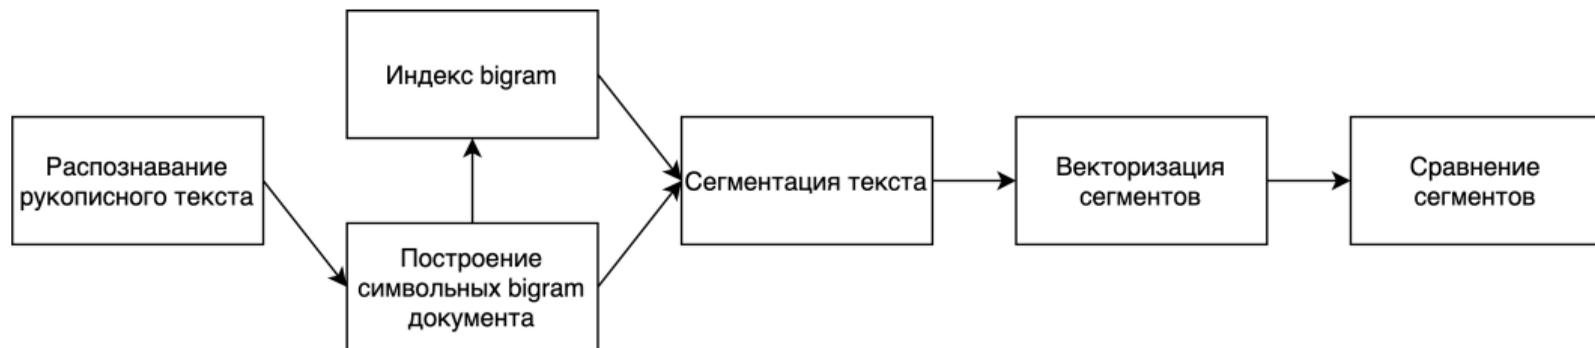
где $f(d_{\text{susp}}^i) @K$ — множество из K наибольших элементов коллекции для порядка, индуцированного $f(d_{\text{susp}}^i)$.

- Извлечем границы слов, содержащихся в сочинении **без их распознавания**.
- Получим признаки, инвариантные для различных почерков:
 - Нормализованная длина слова.
 - Нормализованная высота слова.
 - Наличие лигатур.
- Итоговый алгоритм поиска почти-дубликатов заключается в сопоставлении полученных последовательностей признаков, извлеченных из текста.

Распознавания слов:

- Бинаризация изображения и выделения строк.
- Сегментация слов на основе поиска компонент связности двухкомпонентной гауссовой смеси.
- Расстояние между последовательностями задается функцией Dynamic time warping.

- Распознавание рукописного текста (предобученная модель)¹.
- Построение символьных n-gram над распознанными символами.
- Поиск документов-кандидатов на основе полученных символьных n-gram.
- Векторизация текстовых сегментов и их попарное сопоставление (bag of n-gram).



¹ https://github.com/ai-forever/htr_datasets

Коллекция документов на основе выборки Тайга²:

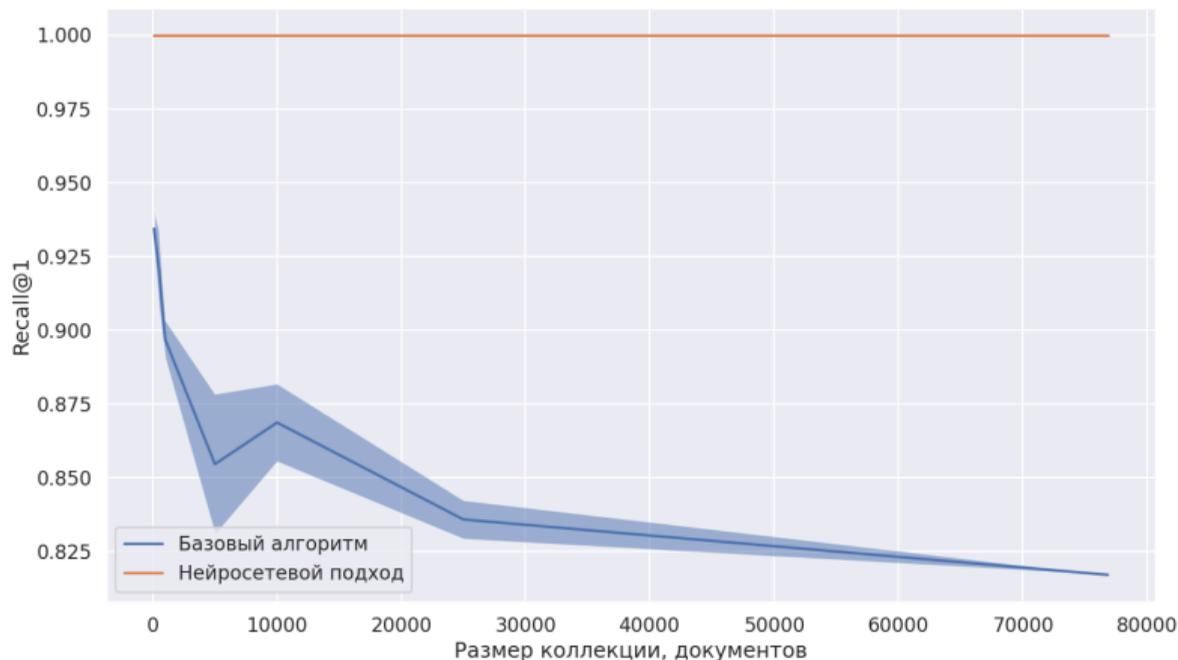
- Объем коллекции: 76855 документ.
- Препроцессинг:
 - Размер текста не менее 20,000 символов.
 - Число слов на русском языке не менее 100.

Разнородные типы текстовых изображений:

- Тексты написаны на бланках и отсканированы³.
- Тексты написаны на произвольных бланках/листах и сфотографированы.

² *Shavrina T., Shapovalova O.* To the methodology of corpus construction for machine learning: “taiga” syntax tree corpus and parser // Proceedings of the “Corpora”: 78-84, 2017.

³ *Bakhteev O., et al* Near-duplicate handwritten document detection without text recognition // Computational Linguistics and Intellectual Technologies, 2021.



Нейросетевой подход имеет значительное преимущество над базовым подходом.

Модель	Бланки государственного образца	Произвольные бланки
Базовая модель	81,6	18,2
Нейросетевой подход	100,0	61,7

При изменении качества входных данных, качество **базовой модели** значительно ухудшается.

Нейросетевой подход имеет все еще высокое качество.

- Проведено тестирование базового метода поиска почти дубликатов рукописных текстов на разнородных изображениях.
- Предложен метод поиска почти дубликатов на основе нейросетевого подхода.
- Анализ предложенного нейросетевого подхода показал его устойчивость к изменению формата данных.
- В дальнейшем планируется расширение выборки разнородных снимков рукописных текстов для увеличения качества работы нейросетевой модели.