



Искусственный интеллект: разметка данных и построение моделей в каскаде

Онищук О.Н.

О лекторе



Онищук Олег Николаевич

- Руководитель направления аналитики данных,
Правовой департамент Центрального Аппарата ПАО «Сбербанк»
- Магистр в сфере международного частного права, МГЮА, 2018
Магистерская диссертация: «Блокчейн как технология охраны авторских прав в трансграничных отношениях»



План лекции



Часть 2. Разметка данных

- Что такое разметка
- Инструменты разметки
- Влияние плохой разметки на результат

Часть 3. Построение иерархического NER

- Как модели искусственного интеллекта могут работать в каскаде.
- Применение каскада ML моделей в LegalTech



Разметка данных

Разметка. Основное и важное



- Разметка (аннотирование) данных - это добавление меток или тегов к обучающему набору данных для придания контексту и значению данных.
- Все виды данных, включая текст, изображения, аудио и видео, размечаются перед вводом в модель искусственного интеллекта.
- Размеченные данные помогают моделям машинного обучения изучать и распознавать закономерности, делать прогнозы или генерировать аналитические данные на основе помеченных данных.
- Качество и точность аннотаций к данным имеют решающее значение для производительности и надежности моделей машинного обучения.

Разметка. Классификация по типам задач



Компьютерное зрение («Computer Vision» или «CV»)

В CV аннотирование данных включает в себя маркировку и разметку визуальных элементов на изображениях, фотографиях и видео для обучения моделей по таким задачам, как:

- распознавание объектов,
- распознавание лиц,
- отслеживание движения,
- автономное вождение,
- и другим.

Разметка. Классификация по типам задач



Обработка данных в естественном языке («Natural language processing» или «NLP»):

В NLP разметка данных фокусируется на текстовой информации и элементах, связанных с языком.

Аннотация данных NLP предназначена для обучения моделей искусственного интеллекта понимать человеческую речь, понимать естественный язык и выполнять такие задачи, как:

- классификация текста,
- анализ настроений,
- распознавание именованных объектов (NER)
- машинный перевод.



Разметка данных

I. Задачи компьютерного зрения (CV)

Разметка для CV




I. Классификация изображений (Image categorization)

- Решает главную задачу: «Что изображено на картинке?»
- Ответ: на изображении {объект}

В процессе создания аннотаций для данной задачи могут быть использованы различные методы, такие как аннотация в виде ограничивающего прямоугольника, семантическая сегментация и аннотация с ориентирами.

Пример таксономии категорий тэгов модели Image Analysis 3.2 (Microsoft Azure):



Результат отработки модели Image Analysis 3.2 (Microsoft Azure):



Предоставляем изображение CV модели:



Получаем на выходе:

JSON

```
{  
    "categories": [  
        {  
            "name": "people_",  
            "score": 0.81640625  
        }  
    ],  
    "requestId": "bae7f76a-1cc7-4479-8d29-48a694974705",  
    "metadata": {  
        "height": 200,  
        "width": 300,  
        "format": "Jpeg"  
    }  
}
```



Разметка для CV

II. Распознавание / обнаружение объектов

Решает задачи: «Что, где и сколько изображено на картинке?»

Определение наличия, местоположения и количества объектов на изображении и нанесение на них меток называется распознаванием объектов.

Интересующие объекты на изображении могут быть помечены различными способами, включая ограничивающие рамки, полигоны, рамки с надписями и т.д.

Разметка для CV



III. Сегментация

Сегментация - это сложный метод разметки изображений, который включает в себя разделение изображения на разделы или сегменты и их разметку в соответствии с их визуальным содержанием.

Распространенные типы Сегментации в CV:

- Распознавание границ
- Семантическая сегментация
- Сегментация по экземплярам
- Паноптическая сегментация

Разметка для CV



Семантическая сегментация

Задача: «Что это? Это тот же объект?»


Установление границ между связанными объектами на изображении и присвоение им одинакового идентификатора.

При данном методе компьютерного зрения каждому пикселью изображения присваивается метка или категория.



Разметка для CV

Семантическая сегментация



Разметка для CV



Сегментация по экземплярам

Задача: «Что это? Ага, это такой же объект. Чуть левее – что-то другое»


Сегментация по экземплярам - это более продвинутая версия семантической сегментации, которая позволяет различать различные экземпляры объектов на изображении.

В отличие от семантической сегментации, которая группирует все пиксели одного класса в одну категорию, сегментация по экземплярам присваивает уникальные метки каждому экземпляру объекта.

Разметка для CV



Сегментация по экземплярам





Разметка для CV

Распознавание границ

Задача: «Граница 1 ведет до... Граница 2 означает...»

Аннотации к изображениям для распознавания границ необходимы для обучения моделей машинного обучения распознавать узоры на изображениях без надписей.

Узоры могут быть простыми и сложными, иметь значения прямого действия или подразумеваемые, - например знак «STOP» или двойная сплошная линия разметки дорожного полотна.



Разметка для CV

Паноптическая сегментация

Задача: «На картинке обнаружено {O1, O2, N1, M1...} с точностью до пикселя»


Паноптическая сегментация - это задача компьютерного зрения, которая сочетает в себе семантическую сегментацию и сегментацию по экземплярам для получения полного представления об изображении.

Она направлена на разделение изображения на семантически значимые области и идентификацию каждого экземпляра объекта в них.



Разметка для CV

Разметка для паноптической сегментации



Разметка для CV



Примеры сегментации

Классификация




Кошка

Классификация
+ локализация



Кошка

Обнаружение
объектов



Кошка + утка +
собака

Сегментация по
экземплярам



Кошка + утка +
собака

Единичный объект

Множество объектов



Разметка для CV

Популярные инструменты для разметки CV

- Encord Annotate
- Scale
- CVAT
- Labelbox
- Playment
- Appen
- Dataloop
- V7 Labs
- Hive
- Labelstudio
- Supervisely
- VoTT

* наименования представлены в качестве примера, носят информативный характер для образовательных целей и не являются рекламой

** все зарегистрированные товарные знаки принадлежат их правообладателям



Разметка данных

II. Задачи обработки естественного языка NLP



Типы разметки для NLP

В зависимости от задач:

- Именованные сущности (Entity annotation)
- Части речи (POS annotation)
- Синтаксические зависимости (Dependency annotation)
- Семантические роли (Semantic role annotation)
- Кореферентность (Coreference annotation)
- Связи (Named entity linking или «NEL»)

В зависимости от уровня:

- Токен (Token-level)
- Предложение (Sentence-level)
- Документ (Document-level)



Типы разметки для NLP

- Token-level annotation: разметка отдельных токенов (слов или символов) в тексте.
- Sentence-level annotation: аннотация отдельных предложений в тексте.
- Document-level annotation: аннотация целого документа или текста.



Типы разметки для NLP

Разметка именованных сущностей (Entity annotation): метод аннотации именованных сущностей, таких как имена, даты, места и организации.

Это позволяет NER и LLM извлекать соответствующую информацию из текстовых данных и использовать ее для принятия решений или классификации.

Типы разметки для NLP



Разметка части речи (Part-of-speech или POS annotation): метод аннотации частей речи, таких как глаголы, существительные, прилагательные и т.д.

Это позволяет системам NER и LLM понимать грамматическую структуру текста и извлекать соответствующую информацию.



Типы разметки для NLP

Разметка зависимостей (Dependency annotation): метод аннотации синтаксических зависимостей между словами в тексте.

Это позволяет системам NER и LLM понимать синтаксическую структуру текста и извлекать соответствующую информацию.



Типы разметки для NLP

Разметка семантики (Semantic role annotation): метод аннотации семантических ролей, таких как агент, пациент, тема документа, роль в документе и т.д.

Это позволяет системам NER и LLM понимать смысл текста и извлекать соответствующую информацию.



Типы разметки для NLP

Разметка кореферентности (Coreference annotation): метод аннотации кореферентности, то есть связей между словами или фразами, которые относятся к одному и тому же объекту или сущности.

Это позволяет системам NER и LLM понимать контекст текста и извлекать соответствующую информацию.

Если сократить – находим псевдонимы и объединяем с одним и тем же объектом, к которому другие сущности принадлежат (кореферентны).



Типы разметки для NLP

Связывание сущностей (Named entity linking): метод аннотации сущностей, который включает в себя поиск и привязку именованных сущностей в тексте к соответствующим записям в базе знаний или базе данных.

Разметка для NLP | NER



Популярные инструменты для разметки текста

- Labelbox
- Diffgram
- Prodigy
- Brat
- TagMe

* наименования представлены в качестве примера, носят информативный характер для образовательных целей и не являются рекламой

** все зарегистрированные товарные знаки принадлежат их правообладателям

Методы разметки (CV + NLP)



- Ориентир
- Ограничивающие рамки, иногда – «2D боксы»
- Многоугольная сегментация
- Полилинии
- Отслеживание
- Трехмерные ограничивающие рамки иногда – «Трехмерные кубоиды»
- Полигональная аннотация



Иерархический NER

Часть 3: Построение иерархического NER

Построение иерархического NER




⚠ Требования! ⚠

- I. Понимать технические возможности вашего инструментария
- II. Данные. Вычищенные, разнообразные, в большом количестве
- III. Иметь чёткое и понятное ТЗ (и составлять такое же)
- IV. Понимать, какие операции необходимы с документом
(извлечение, нормализация, построение графов знаний и т.д.)
- V. По возможности, - сегментируйте! (документ, операции с документом)
- VI. Научный подход хорош, но это не повод отказываться от экспериментов. Пробуйте новые инструменты и подходы.
Всегда.


Построение иерархического NER



Построение иерархического NER



ИТОГИ



Ну и что-нибудь «на почитать»



- «Named Entity Recognition in Historic Legal Text: A Transformer and State Machine Ensemble Method» - [ссылка](#)
- «E-NER - An Annotated Named Entity Recognition Corpus of Legal Text»
- [ссылка](#)
- «Named entity recognition in the Romanian legal domain» - [ссылка](#)
- «Legal Named Entity Recognition with Multi-Task Domain Adaptation» - [ссылка](#)
- «SemEval-2023 Task 6: LegalEval - Understanding Legal Texts» - [ссылка](#)



Спасибо за внимание!