

Лекция 2.

Классификация текстов

Классификация текстов

- Примеры классификационных задач
- Общий вид: Особенности + Классификатор
- Модели: генеративные и дискриминативные
- Классические методы
- Нейросетевые методы
- Классификация с несколькими метками
- Практические советы
- Анализ и интерпретируемость

Классификация текстов

- Многоклассовая классификация (Multi-class) (много меток, правильной является только одна из них)
- Бинарная классификация (Binary) (две метки, правильной является только одна из них)
- Многометочная классификация (Multi-label) (много меток, один текст может иметь несколько правильных меток)

Датасеты для классификации текстов

Датасеты сильно различаются по:

- Типу
- Количеству меток
- Размеру
- Средней длине в токенах (числу, которое показывает, сколько в среднем токенов содержится в одном тексте датасета)

Датасеты для классификации текстов

Dataset	Type	Number of labels	Size (train/test)	Avg. length (tokens)
SST	sentiment	5 or 2	8.5k / 1.1k	19
IMDb Review	sentiment	2	25k / 25k	271
Yelp Review	sentiment	5 or 2	650k / 50k	179
Amazon Review	sentiment	5 or 2	3m / 650k	79
TREC	question	6	5.5k / 0.5k	10
Yahoo! Answers	question	10	1.4m / 60k	131
AG's News	topic	4	120k / 7.6k	44
Sogou News	topic	6	54k / 6k	737
DBPedia	topic	14	560k / 70k	67

Датасеты для классификации текстов

- SST

Stanford Sentiment Treebank — это классический и очень известный датасет для оценки тональности текста (sentiment analysis). Предложения взяты из кинокритики (сайт Rotten Tomatoes). Исходная разметка использует 5 классов:

0 — Very Negative

1 — Negative

2 — Neutral


3 — Positive

4 — Very Positive

Label: 1

Review:

Ultimately feels empty and unsatisfying , like swallowing a Communion wafer without the wine .



Датасеты для классификации текстов

- **IMDb Review**

IMDb (Internet Movie Database) — это огромная онлайн-база данных о фильмах, телесериалах и видео играх. Датасет **IMDb Review** представляет собой коллекцию отзывов зрителей на фильмы, размещенных на этом сайте

Задача: Бинарная классификация тональности (Sentiment Analysis)

Исходная разметка использует 2 класса:

Negative (0) — отрицательный отзыв (оценка пользователя ≤ 4 из 10)

Positive (1) — положительный отзыв (оценка пользователя ≥ 7 из 10)

Датасеты для классификации текстов

- IMDb Review

Label: negative

Review

Hobgoblins Hobgoblins where do I begin!?

This film gives Manos - The Hands of Fate and Future War a run for their money as the worst film ever made . This one is fun to laugh at , where as Manos was just painful to watch . Hobgoblins will end up in a time capsule somewhere as the perfect movie to describe the term : " 80 's cheeze " . The acting (and I am using this term loosely) is atrocious , the Hobgoblins are some of the worst puppets you will ever see , and the garden tool fight has to be seen to be believed . The movie was the perfect vehicle for MST3 K , and that version is the only way to watch this mess . This movie gives Mike and the bots lots of ammunition to pull some of the funniest one - liners they have ever done . If you try to watch this without the help of Mike and the bots God help you ! !

Датасеты для классификации текстов

- **Yelp Review**

Основан на реальных отзывах с платформы Yelp.

Yelp — это платформа, где пользователи оставляют отзывы о ресторанах, кафе, магазинах, салонах красоты и т.д. Датасет **Yelp Review** представляет собой огромную выборку этих отзывов, публично предоставленную Yelp для исследовательских целей.

Задача: Многоглассовая классификация

Классы: Отзывы размечены количеством звезд (1-5), что естественным образом соответствует тональности:

- **1 звезда** — Very Negative (очень негативный)
- **2 звезды** — Negative (негативный)
- **3 звезды** — Neutral (нейтральный)
- **4 звезды** — Positive (позитивный)
- **5 звезд** — Very Positive (очень позитивный)

Датасеты для классификации текстов

- Yelp Review

Label: 4

Review

I had a serious craving for Roti. So glad I found this place. A very small menu selection but it had exactly what I wanted. The serving for \$8.20 after tax is enough for 2 meals. I know where to go from now on for a great meal with leftovers. This is a noteworthy place to bring my Uncle T.J. who's a Trini when he comes to visit.

Датасеты для классификации текстов

- **Amazon Review**

Датасет Amazon Review — это один из самых масштабных и значимых ресурсов в мире NLP и Data Science. Он представляет собой колоссальную коллекцию отзывов пользователей на товары, продаваемые на Amazon.com.

Задача: Многоклассовая классификация

Классы: Отзывы размечены количеством звезд (1-5), что естественным образом соответствует тональности:

- **1 звезда** — Very Negative (очень негативный)
- **2 звезды** — Negative (негативный)
- **3 звезды** — Neutral (нейтральный)
- **4 звезды** — Positive (позитивный)
- **5 звезд** — Very Positive (очень позитивный)

Датасеты для классификации текстов

- Amazon Review

Label: 3

Review Title: Simple

Review Content:

This book was not anything special. Although I love romances, it was too simple. The symbolism was spelled out to the readers in a blunt manner. The less educated readers may appreciate it. The wording was quite beautiful at times and the plot was enchanting (perfect for a movie) but it is not heart wrenching like the movie Titanic (which was a must see!) ;)

Датасеты для классификации текстов

- **TREC QA Track**

Text REtrieval Conference — классификация вопросов по типам.

Задача: Определить тип ожидаемого ответа на вопрос

Классы: Иерархическая система меток (6 грубых классов, 50 тонких).

- **ABBR** (abbreviation) — аббревиатуры и расшифровки.
- **DESC** (description) — описания, определения, объяснения.
- **ENTY** (entity) — сущности (лица, организации, продукты и т.д.).
- **HUM** (human) — люди.
- **LOC** (location) — местоположения.
- **NUM** (numeric) — числовые значения (цена, население, даты).

Датасеты для классификации текстов

- **Yahoo! Answers**

Датасет Yahoo! Answers — коллекция вопросов пользователей, ответов и лучших ответов на эти вопросы .

Задача: Тематическая классификация (Topic Classification). Вопросы и ответы относятся к одной из множества тематических категорий

Классы: 10 крупнейших основных категорий:

Society & Culture (Общество и культура), **Science & Mathematics** (Наука и математика), **Health** (Здоровье), **Education & Reference** (Образование и справочные материалы), **Computers & Internet** (Компьютеры и интернет), **Sports** (Спорт), **Business & Finance** (Бизнес и финансы), **Entertainment & Music** (Развлечения и музыка), **Family & Relationships** (Семья и отношения), **Politics & Government** (Политика и правительство).

Датасеты для классификации текстов

Label: Society & Culture

Question Title: Why do people have the bird, turkey for thanksgiving?

Question Content: Why this bird? Any Significance?

Best Answer

It is believed that the pilgrims and indians shared wild turkey and venison on the original Thanksgiving.

Turkey's "Americanness" was established by Benjamin Franklin, who had advocated for the turkey, not the bald eagle, becoming the national bird.

Датасеты для классификации текстов

- **DBpedia**

Датасет DBpedia — это глобальный общедоступный проект, целью которого является извлечение структурированной информации из Wikipedia и предоставление к ней доступа в виде связанных данных (Linked Data)..

Источник: Wikipedia (инфобоксы, категории, геокоординаты, ссылки и т.д.)

Для ML-сообщества наиболее известен именно **датасет для классификации** (DBpedia Classification).

Число классов: 14

Данные для каждого примера:

- **Название сущности** (название статьи Wikipedia).
- **Абстракт (аннотация)** — короткое текстовое описание сущности, извлеченное из первого абзаца соответствующей статьи Wikipedia.
- **Класс** — одна из 14 категорий DBpedia.

Датасеты для классификации текстов

Label: Artist

Title: Esfandiar Monfaredzadeh

Abstract

Esfandiar Monfaredzadeh (Persian : اسفندیار منفردزاده) is an Iranian composer and director. He was born in 1941 in Tehran His major works are Gheisar Dash Akol Tangna Gavaznha. He has 2 daughters Bibinaz Monfaredzadeh and Sanam Monfaredzadeh Woods (by marriage).


Получение представлений признаков и классификация

Извлечение признаков:


- Классические методы – признаки извлекаются вручную человеком
- Нейросетевые методы – признаки извлекаются сетью: сеть запоминает, что важно

Методы классификации:

- генеративные
- дискриминативные



Генеративные модели




Learn: data distribution

$$p(x, y) = p(x|y) \cdot p(y)$$

How predict:

$$y = \arg \max_k p(x, y) = \arg \max_k p(x|y) \cdot p(y)$$

Дискриминативные модели



Learn: boundary between classes $p(y|x)$

How predict:

$$y = \arg \max_k p(y|x)$$

Классические методы

- Наивный Байес
- Логистическая регрессия
- SVM

Наивный Байес

$$y^* = \arg \max_k P(y = k|x) = \arg \max_k \frac{P(x|y = k) \cdot P(y = k)}{P(x)} =$$

$$= \arg \max_k P(x|y = k) \cdot P(y = k)$$

$$y^* = \arg \max_k P(y = k|x) = \arg \max_k P(x|y = k) \cdot P(y = k) = \arg \max_k P(x, y = k)$$

$$P(y = k) = \frac{N(y = k)}{\sum_{i=1}^K N(y = i)}$$

Вычисление $P(x|y = k)$

$$P(x|y = k) = P(x_1, x_2, \dots, x_n|y = k)$$

Наивные Байесовские предположения:

- Предположение о мешке слов (Bag of Words assumption) — порядок слов не имеет значения
- Предположение об условной независимости (Conditional Independence assumption) - признаки (слова) независимы для данного класса.

$$P(x|y = k) = P(x_1, x_2, \dots, x_n|y = k) = \prod_{i=1}^n P(x_i|y = k)$$

Вычисление $P(x|y = k)$

$$P(\text{This film is awesome} \mid y = +) =$$

- $P(\text{This} \mid y = +)$
- $P(\text{film} \mid y = +)$
- $P(\text{is} \mid y = +)$
- $P(\text{awesome} \mid y = +)$
- $P(\mid y = +)$

Вычисление $P(x|y = k)$

Используя наивные предположения, получили:

$$P(x|y = k) = P(x_1, x_2, \dots, x_n|y = k) = \prod_{i=1}^n P(x_i|y = k)$$

Вычисляем отдельные вероятности «вручную»:

$$P(x_i|y = k) = \frac{N(x_i, y = k)}{\sum_{t=1}^{|V|} N(x_t, y = k)}$$

Возможная проблема

Вычисляем отдельные вероятности «вручную»:

$$P(x_i|y = k) = \frac{N(x_i, y = k)}{\sum_{t=1}^{|V|} N(x_t, y = k)}$$

А что если числитель равен нулю? (то есть при обучении токена x_i не было в документах класса k)

$$P(x_i|y = k) = \frac{N(x_i, y = k)}{\sum_{t=1}^{|V|} N(x_t, y = k)} = 0$$

Решение проблемы

Сглаживание Лапласа (Laplace Smoothing).

Решает проблему нулевой вероятности

$$P(x_i|y = k) = \frac{\delta + N(x_i, y = k)}{\sum_{t=1}^{|V|} (\delta + N(x_t, y = k))} = \frac{\delta + N(x_i, y = k)}{\delta \cdot |V| + \sum_{t=1}^{|V|} N(x_t, y = k)}$$

Предсказание модели

Data: $x =$ This film is awesome !
 $x_1 \quad x_2 \quad x_3 \quad x_4 \quad x_5$

$$y^* = \arg \max_k P(x, y = k) = \arg \max_k P(y = k) \cdot P(x|y = k)$$

Получение прогноза

Positive class

$$P(x, y = +)$$

$$= P(y = +) \cdot P(x|y = +)$$

$$= P(y = +) \cdot 0,5$$

$$\cdot P(\text{This}|y = +)$$

$$\cdot P(\text{film}|y = +)$$

$$\cdot P(\text{is}|y = +)$$

$$\cdot P(\text{awesome}|y = +) \leftarrow \text{важное слово}$$

$$\cdot P(!|y = +)$$

$$P(\text{awesome}|y = +) \gg P(\text{awesome}|y = -)$$

Negative class

$$P(x, y = -)$$

$$= P(y = -) \cdot P(x|y = -)$$

$$= P(y = -) \cdot$$

$$\cdot P(\text{This}|y = -)$$


$$\cdot P(\text{film}|y = -)$$

$$\cdot P(\text{is}|y = -)$$


$$\cdot P(\text{awesome}|y = -)$$

$$\cdot P(!|y = -)$$

Наивный Байес: взгляд в рамках общей модели



Наивный Байес: взгляд в рамках общей модели



Проблемы наивного Байеса

This is rather good:
not bad at all!

This is rather bad:
not good at all!



this, is, good, bad,
rather, not, at, all, !

Логистическая регрессия

$h = (f_1, f_2, \dots, f_n)$ – вектор признаков входного текста

$w^{(k)} = (w_1^{(k)}, w_2^{(k)}, \dots, w_n^{(k)})$ – веса признаков

$$w^{(k)}h = w_1^{(k)} \cdot f_1 + \dots + w_n^{(k)} \cdot f_n, \quad k = 1, \dots, K$$

$$P(class = k|h) = \frac{\exp(w^{(k)}h)}{\sum_{i=1}^K \exp(w^{(i)}h)}$$

Обучение: максимизация вероятности

Есть некоторый текст. Текст имеет метку k .

- Максимизация логарифмического правдоподобия правильного класса $\log P(y = k|x) \rightarrow \max$
- Минимизация отрицательного логарифмического правдоподобия правильного класса $-\log P(y = k|x) \rightarrow \min$
- Минимизация потери кросс-энтропии:

$$-\sum_{i=1}^K p_i^* \cdot \log P(y = i|x) \rightarrow \min$$
$$(p_k^* = 1, p_i^* = 0, i \neq k)$$

Сравнение наивного Байеса и логистической регрессии

Наивный Байес:


- очень простой
- очень быстрый
- интерпретируемый
- предполагает, что признаки условно независимы
- текстовое представление: определяется вручную (и часто слишком просто, например, BOW)

Сравнение наивного Байеса и логистической регрессии

Логистическая регрессия:


- очень простая
- интерпретируемая
- не предполагает, что признаки условно независимы
- не такая быстрая (множественные итерации градиентного спуска)
- текстовое представление: определяется вручную

SVM




Классификация с помощью классических методов

Общая схема:




Классификация с помощью нейронных сетей


Вместо признаков, заданных вручную, позволим нейронной сети выявить полезные признаки



Представление текста и представление классов



Векторы текста указывают в направлении соответствующих векторов класса:



Обучение: кросс-энтропия

Есть некоторый текст. Текст имеет метку k .


Model prediction:

$P(\text{class} = i | \text{I liked...}\langle\text{eos}\rangle)$



Target:

p^*



←

k


→

Cross-entropy loss:

$$-\sum_{i=1}^K p_i^* \cdot \log P(y = i|x) \rightarrow \min \quad (p_k^* = 1, p_i^* = 0, i \neq k)$$

For one-hot targets, this is equivalent to

$$-\log P(y = k|x) \rightarrow \min$$



Feed a text to the network


I liked the cat . $\langle\text{eos}\rangle$

Correct label: 4 ← we want the model to predict this


Простейшие модели: BOE и взвешенный BOE

Sum of embeddings
(BOE: Bag of Embeddings)


Weighted sum of embeddings
(e.g., using tf-idf weights)



Свёрточные нейросети для обработки изображений и Translation Invariance



- Применить ту же операцию к небольшим частям входных данных
- найти «совпадения» с шаблонами
- сеть узнает, какие шаблоны полезны
- шаблоны развиваются от простого к сложному



Как это использовать в текстах?


Если в тексте есть некоторая фраза, и она очень важная, то, возможно, нам не очень важно, где именно она находится.

An **absolutely great** movie! I watched the premiere with my friends.

The movie about cats was **absolutely great**, and the cats were cute.

The movie is about cats running around, and it is **absolutely great**.


Типичная модель: свертка + объединение



Фильтр свертки для текста





Свертка — это линейная операция, применяемая к каждому окну




- $x_1, x_2, \dots, x_n$ - input vectors (e.g., word embeddings)
 - d (input channels) – input vector size
 - k (kernel size) – conv. window length
 - m (output channels) – number of filters
- $u_i = [x_i, \dots, x_{i+k-1}] \in \mathbb{R}^{k \cdot d}$ - concatenate representations in the i -th window
- $W \in \mathbb{R}^{(k \cdot d) \times m}$ - convolution
- $F_i = u_i \times W$ - convolution applied to the i -th window

Фильтр



Свёртка: параметры

Размер ядра: сколько токенов за один раз вы смотрите




Шаг: насколько нужно переместить фильтр на каждом шаге



Pooling (max, mean, etc) (объединение)

Max pooling: максимальное значение для каждого измерения (признака)

Mean pooling: среднее значение для каждого измерения (признака)





Max pooling:
maximum for each
dimension (feature)



Pooling and Global Pooling


Pooling: агрегация признаков в некоторой области

Global pooling: агрегация признаков по всем входным данным




Сверточные модели для классификации текстов

Несколько сверток с разными размерами ядра




Сверточные модели для классификации текстов

Стек из нескольких блоков: свертка+пулинг




Рекуррентные нейронные сети



На каждом этапе рекуррентная нейронная сеть получает новый входной вектор (например, эмбединг) и предыдущее состояние сети (которое, будем надеяться, содержит всю предыдущую информацию). Используя эти входные данные, ячейка рекуррентной нейронной сети вычисляет новое состояние, которое она выдаёт в качестве результата. Это новое состояние теперь содержит информацию как о текущих входных данных, так и об информации, полученной на предыдущих этапах.


Рекуррентные модели для классификации текстов

просто: прочитайте текст,
определите конечное состояние




Рекуррентные модели для классификации текстов

Несколько слоев: передача состояний из одной RNN в другую



Рекуррентные модели для классификации текстов


Два направления: использовать конечные состояния из прямых и обратных RNN




Многометочная классификация

Для задачи с несколькими метками нам нужно изменить два элемента в схеме с одной меткой:

- модель (способ оценки вероятностей классов);
- функцию потерь



Многометочная классификация



Функция потерь: бинарная кросс-энтропия для каждого класса

Training example: I liked the cat on the mat <eos>


Labels: k, t
↑
target

Model prediction:

$P(y_i = 1 | \dots \text{<eos>}), i = 1..K$

Target:

$p_i^*, i = 1..K$



Binary cross-entropy loss for each class:

$$-\sum_{i=1}^K [p_i^* \cdot \log P(y_i = 1|x) + (1 - p_i^*) \cdot \log P(y_i = 0|x)] \rightarrow \min,$$


where $P(y_i = 0|x) = 1 - P(y_i = 1|x)$

binary classifier loss for class i

Практические советы. Что делать с эмбедами?

Входные векторные представления слов:

- Обучение с нуля
- Использование предварительно обученных данных (Word2Vec, GloVe)
- Инициализация с использованием предварительно обученных данных, затем тонкая настройка



Какие данные у нас есть?

- обучающие данные для классификации текста (с меткой): небольшой объём; тема, специфичная для конкретной задачи
- обучающие данные для векторных представлений слов (без меток): огромные и разнообразные данные; нет специфики тем

Что делать с эмбедингами?

- обучение с нуля (данных может быть недостаточно, чтобы изучить взаимосвязи между словами)
- предобученные данные (Word2Vec, GloVe) (знают взаимосвязи между словами, но не знают специфику задачи)
- инициализация с помощью предобученных данных, затем тонкая настройка (знают взаимосвязи между словами и адаптируются к задаче)

Получение дополнительных данных (Data Augmentation)


Аугментация данных изменяет ваш набор данных различными способами, чтобы получить альтернативные версии одного и того же обучающего примера.

Она может увеличить:

- объем данных
- разнообразие данных

Data Augmentation для изображений

- переворот изображения
- геометрические преобразования (вращение, растяжение, увеличение/уменьшение масштаба)
- скрывание отдельных участков



Data Augmentation для текста

- word dropout (исключение слов)

The movie **about** cats was absolutely **great**, and the **cats** were cute.

replace with UNK

pick several words randomly

replace with random words

The movie **UNK** cats was absolutely **UNK**, and the **UNK** were cute.


The movie **mejorate** cats was absolutely **fellows**, and the **mak** were cute.

Data Augmentation для текста

- использование внешних ресурсов (например, тезауруса)

The **movie** about cats was **absolutely** great, and the cats were **cute**.

pick words where you have
synonyms and use thesaurus

A diagram illustrating text augmentation. It shows a central instruction 'pick words where you have synonyms and use thesaurus' with two arrows pointing downwards to two modified sentences. The first arrow points from the word 'movie' in the original sentence to 'film' in the first augmented sentence. The second arrow points from the word 'absolutely' in the original sentence to 'completely' in the second augmented sentence.

The **film** about cats was **certainly** great, and the cats were **nice**.

The **video** about cats was **completely** great, and the cats were **charming**.

Data Augmentation для текста

- использование отдельных моделей для перефразирования

The movie about cats was absolutely great, and the cats were cute.



Анализ сверточных фильтров

Примеры паттернов, полученных с помощью фильтров свёртки изображений:

Lower layers



Middle layers




Upper layers



Анализ сверточных фильтров

Примеры паттернов, полученных с помощью фильтров свёртки изображений:



Анализ сверточных фильтров

filter	Top n-gram	Score
1	poorly designed junk	7.31
2	simply would not	5.75
3	a minor drawback	6.11
4	still working perfect	6.42
5	absolutely gorgeous .	5.36
6	one little hitch	5.72
7	utterly useless .	6.33
8	deserves four stars	5.56
9	a mediocre product	6.91

Top n-grams for filter 4

	Score
1 still working perfect	6.42
2 works - perfect	5.78
3 isolation proves invaluable	5.61
4 still near perfect	5.6
5 still working great	5.45
6 works as good	5.44
7 still holding strong	5.37

A filter activates for a family of n-grams with similar meaning