

Многопрофильная олимпиада «Путь к успеху» Секция «Основы искусственного интеллекта»

Задание заключительного тура

Вступление

Кто мы? Мы команда BliIT, которая любит собирать данные, создавать и преобразовывать большие датасеты, а также придумывать неожиданные гипотезы.

А кто ты? Говорят, ты Data Scientist, умеешь работать с большими данными, получать описательные статистики и круто их визуализировать. Но мы не знаем: junior, middle, senior ли ты. Вот и узнаем кто есть кто 😊!

Тема задания: *Анализируй визуализируя!*

Вам представлен датасет (файл: YT_comments_dataset.pqt) с комментариями одного из популярных русскоязычных каналов в YouTube (скачать файл: <https://drive.google.com/file/d/1wzg7pXDi2dAi0FEOUWgeGR4qXEXmd5yJ/view>).

Мы поскрабили все, что можно было, почистили данные и передаем эту ценную информацию тебе.

Что мы ждём от тебя:

1. Получить основные показатели описательной статистики.
2. Представить визуализацию содержимого датасета.
3. Определить: чей канал ты анализировал(ла) (Название канала)

В качестве ответа мы ждём файл в форматах: ru или ipynb.

Кстати, комментарии к коду будут не лишними, заработаешь больше баллов!

ОПИСАНИЕ ДАТАСЕТА

ДАТАСЕТ СОДЕРЖИТ СЛЕДУЮЩИЕ ПОЛЯ:

- ПОЛЕ "DATE" - СОДЕРЖИТ ДАТУ И ВРЕМЯ РАЗМЕЩЕНИЯ КАЖДОГО КОММЕНТАРИЯ;
- ПОЛЕ "TEXT" - СОДЕРЖИТ ТЕКСТ КОММЕНТАРИЯ;
- ПОЛЕ "AUTHOR" - СОДЕРЖИТ НИКНЕЙМ АВТОРА КОММЕНТАРИЯ;
- ПОЛЕ "AVATAR" - СОДЕРЖИТ URL АВАТАРА АВТОРА КОММЕНТАРИЯ;
- ПОЛЕ "VIDEO ТЕМЕ" - СОДЕРЖИТ ТЕМУ (О КОМ ИЛИ О ЧЕМ) ВИДЕО, ПОД КОТОРЫМ

ОСТАВЛЕН КОММЕНТАРИЙ.

Подробнее о задании

1. Получить следующие данные из датасета:
 - количество записей в датасете;
 - типы записей;
 - количество уникальных комментаторов;
 - вывести имя автора, аватар, количество комментариев данного автора;
 - вывести 5 самых обсуждаемых героев выпусков на основании количества комментариев.

2. Получить частоту комментирования видео пользователя по дням недели и по годам:

День недели	Год	2017	2018	2019	2020	2021
Понедельник						
...						
Воскресенье						

3. Получить количество комментариев по годам:

Год	Количество комментариев
2017	
2018	
2019	
2020	
2021	

4. С помощью анализа социальных сетей исследователи получили список самых популярных эмодзи. Необходимо получить по каждому автору комментариев статистику использования данных эмодзи:

- определить эмоциональную окраску комментариев на всем канале;
- определить самых доброжелательных комментаторов (топ-10), самых негативных комментаторов (топ-10), самых эмоциональных комментаторов (топ-10).

Изображение эмодзи	В Unicode	Эмоциональная окраска
	U+1F600	Позитивный
	U+1F601	Позитивный
	U+1F923	Позитивный
	U+1F602	Позитивный
	U+1F609	Позитивный
	U+1F60A	Позитивный
	U+1F60D	Позитивный

	U+1F618	Позитивный
	U+1F914	Нейтральный
	U+1F612	Нейтральный
	U+1F60E	Позитивный
	U+1F62D	Негативный
	U+1F48B	Позитивный
	U+1F495	Позитивный
	U+2764	Позитивный
	U+2665	Позитивный
	U+1F44D	Позитивный
	U+1F937	Нейтральный
	U+1F525	Позитивный
	U+1F44E	Негативный
	U+1F644	Негативный
	U+1F922	Негативный
	U+1F620	Негативный
	U+1F92E	Негативный
	U+1F615	Негативный
	U+1F928	Негативный
	U+1F47F	Негативный
	U+2642	Негативный
	U+1F926	Негативный
	U+1F929	Позитивный

	U+1F970	Позитивный
	U+1F44F	Позитивный

5. Визуализировать полученные данные:
- частоту комментирования по дням неделям и годам (График 1);
 - количество комментариев по годам (График 2);
 - определить доминирующую эмоцию каждого автора из топ-10 самых активных комментаторов. Построить график, отображающий доминирующую эмоцию по каждому автору из топ-10 самых активных комментаторов. На графике вывести по каждому автору его аватар, вывести доминирующие эмоции в виде эмодзи (График 3).

Вывод графиков должен быть реализован с анимацией (построение графика, вывод дополнительной, уточняющей информации).

Все графики должны содержать легенды, подписи осей, название графика.

6. Написать в конце ноутбука название канала, чьи комментарии были в датасете.