

# Анализ данных в Python (политология)

**Дедлайн:** 9 декабря 23.59

**Поздний дедлайн:** 12 декабря 23.59 (12 декабря закрывается соревнование, вы не сможете больше отправлять решения, до 10 декабря 23.59 штраф один балл, до 12 декабря 23.59 штраф 2 балла)

## Домашнее задание 2

Участвуем в соревновании на kaggle.

<https://www.kaggle.com/t/78b4150e88c84935b37e550fbb636a4f>

По ссылке можно скачать данные и baseline решение (базовое решение, которое будем стараться улучшать).

Чтобы выполнить это ДЗ физически нужно время, потому что данные немаленькие и считаться это будет не быстро. Поэтому каждый эксперимент это 1-3 часа (вы естественно можете заниматься своими делами, но лучше следить, что там происходит).

Что понадобится: аккаунт kaggle, аккаунт Google и 3,5 гб свободного места на гугл диске.

Аккаунт kaggle может быть создан с любой почты, логин любой. Но когда вы будете участвовать в соревновании, вам нужно будет во вкладке Team указать префикс POL и полностью имя и фамилию.

The screenshot shows the Kaggle competition page for 'Texts classification'. The page has a dark blue header with the competition name and a 'InClass Prediction Competition' logo. Below the header, the title 'Texts classification' is displayed in English and Russian ('Многоклассовая классификация текстов объявлений'). The page indicates '10 teams - 15 days to go'. A navigation bar at the top includes 'Overview', 'Data', 'Notebooks', 'Discussion', 'Leaderboard', 'Rules', 'Team' (which is underlined in blue), 'My Submissions', and a blue 'Submit Predictions' button. A 'Manage Team' button is located in a sidebar. The main content area shows a text input field with 'POL Tatiana Rogovich' and a 'Save Team Name' button. A note below the input field states: 'This name will appear on your team's leaderboard position.'

# Оценивание

Макс. 11 баллов

Если вы делаете любой пункт, кроме 1, вы кратко комментируете свои действия в блокноте и сдаете в лмс на проверку блокнот (все шаги должны быть в нем зафиксированы).

Перед началом работы, из вкладки data на kaggle вам нужно скачать файлы train и test и положить их в папку на своем гугл-диске. Дальше загрузить их по инструкции в видео:  
<https://www.youtube.com/watch?v=DKGmFZgR8K8&feature=youtu.be>

## 1. 4 балла

Вы запускаете блокнот на базовое предсказание, генерируете файл submission и отправляете его на kaggle с названием baseline submission.

Если вы делаете только эту часть, вы не отправляете мне блокнот (так как ничего не правите), но на экзамене я спрошу вас по одному из шагов в этом блокноте и попрошу объяснить, что именно мы делаем (мы все это будем разбирать на занятиях).

## 2. 2 балла

- Вы очищаете текст от стоп-слов, чисел и пунктуации, применяете стемминг (это нужно сделать внутри собственной функции).
- Дальше делаете все то же самое, что в блокноте. Не забудьте применить функцию по очистке к Train и Test.

Рекомендую сохранить файлы train и test с очищенным текстом в csv у себя на диске. Этот шаг занимает много времени и потом вам будет проще запускать модель без него (если что-то сорвалось или вы делаете задание в несколько подходов).

- Напишите, улучшилось ли качество предсказания на тестовой выборке внутри блокнота по сравнению с базовым блокнотом.
- Отправляете на kaggle submission с название baseline clean text submission.
- После сабмита напишите в блокноте, улучшилось ли качество предсказания по сравнению с базовым блокноте на тестовой выборке kaggle.

## 3. 1 балл

- Если вы делали пункт 2, то к очищенному тексту применяете tf idf vectorizer, но с такими настройками, чтобы он не учитывал слова, которые встречаются очень часто во всех документах (стоп-слова для корпуса). Оставьте только 100 000 признаков. Посмотрите в документации на параметры max\_df и max\_features.

[https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_extraction.text.TfidfVectorizer.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfVectorizer.html)

- Дальше делаете то, что в блокноте. Напишите, улучшилось ли качество предсказания на тестовой выборке внутри блокнота по сравнению с базовым блокнотом
- Отправляете на kaggle submission с название tf idf max submission.
- После сабмита напишите в блокноте, улучшилось ли качество предсказания по сравнению с базовым блокноте на тестовой выборке kaggle.

## 4. 1 балл

- Если делали пункт 2 и 3, то к tf idf матрице, которая у вас уже есть (после пункта 3), применяете классификатор MultinomialNB из коробки и считаете метрику ошибки для тестовой выборки в блокноте.

- Реализуете подбор параметра сглаживания  $\alpha$  по сетке для значений 0.01, 0.05, 0.1, 0.5, 1. Для каждой модели считаете метрику ошибки на отложенной тестовой выборке внутри блокнота.
- Выбираете параметр  $\alpha$ , который дает лучший результат. Обучаете MultinomialNB с этим параметром на всей выборке.
- Отправляете на kaggle submission с названием naive bias submission.
- После сабмита напишите в блокноте, улучшилось ли качество предсказания по сравнению с базовым блокноте на тестовой выборке kaggle.

## 5. 2 балла

- К очищенному тексту применяете CountVectorizer с ограничением 10000 признаков и n-граммами от 1 до 2 (включаем только отдельно стоящие слова и пары слов).
- Как модель для предсказания используете MultinomialNB и опять реализуете подбор параметра сглаживания  $\alpha$  по сетке для значений 0.01, 0.05, 0.1, 0.5, 1.
- Напишите, улучшилось ли качество предсказания на тестовой выборке внутри блокнота по сравнению с базовым блокнотом и вашими предыдущими экспериментами.
- Отправляете на kaggle submission с названием naive bias submission.
- После сабмита напишите в блокноте, улучшилось ли качество предсказания по сравнению с базовым блокноте на тестовой выборке kaggle.

## Дополнительные баллы

Если после 12 декабря окажется, что ваша модель пробила второй baseline, то прибавляем 1 балл к итоговой оценке. Не забудьте на странице My Submissions поставить галочку Use for Final Score модель с самой высокой оценкой на части тестовых данных.


Вы можете делать дополнительные эксперименты, не описанные в этом блокноте.



**baseline2 - 10 баллов**

## Что присыпаем:

1. В лмс загружаете скачанный блокнот, в котором зафиксированы все ваши шаги с короткими комментариями (перед каждым шагом пишете, что вы делаете).
2. Также в лмс загружаете скриншот вашей страницы My Submissions, на котором видны все ваши submissions и оценка за них.
3. Пункт засчитывается выполненным только при наличии блокнота с этими шагами + скриншота с нужным сабмитом. Если делаете только первый пункт на 4 балла - присыпаете только скриншот.



Overview Data Notebooks Discussion Leaderboard Rules Team My Submissions Submit Predictions

> `kaggle competitions submit -c texts-classification-ml-hse-2019 -f submission.csv -m "Message"`

1 submissions for **POL** Sort by Most recent

All Successful Selected

Submission and Description	Public Score	Use for Final Score
<a href="#">my_submission.csv</a> 3 days ago by <a href="#">Tatiana Rogovich</a> baseline test	0.84736	<input type="checkbox"/>

No more submissions to show