

Анализ данных в Python (политология)

Дедлайн: 1 декабря 23.59

Домашнее задание 1

Тестируем гипотезу, влияет ли снижение количества конкурентных штатов во время президентских выборах в США на уровень знаний граждан о политике.

Обратите внимание, что задание принимается архивом, в котором лежит блокнот и пять файлов csv (те, которые вы создаете или изменяете во время работы).

Оригинальные файлы, пожалуйста, загружайте по ссылкам с git.

Данные:

https://github.com/rogovich/Data/tree/master/docs/Plotly_HW

1 балл

Общее оформление кода, графиков, написание промежуточных выводов.

Штрафы по 0.25 балла за каждый случай отсутствия заголовков, неработающий код, ошибки в коде (например, ненужные преобразования переменных), отсутствие выводов в ячейках markdown и т.д.

1.

а. Пройти по ссылке

https://nbviewer.jupyter.org/github/rogovich/Data/blob/master/docs/Plotly_HW/FairVote%20-%20Press%20Room.html

В статье есть три таблицы, нужно написать код, который сможет обратиться к странице, достать информацию для каждой таблицы, преобразует ее в pandas dataframe и сохраните каждую в csv, положите эти три файла в архив с выполненным заданием.

Названия колонок в таблице можно задать вручную (с помощью парсинга тоже можно, но иногда слишком много трудозатрат, поэтому, если не понимаете, как сделать легко, то просто делайте вручную :)! В таблице три достаточно одного уровня заголовка — Year, Landslide, Comfortable, Competitive

2,4 балла (каждая корректно сохраненная таблица + работающий код для ее парсинга оценивается в 0.8 балла)

Table 1. Campaign Events between September 5 and November 4, 2008*

Rank	State	Events	% of total	Cumulative %
1	OH	62	20.7	20.7
2	FL	46	15.3	36.0
3	PA	40	13.3	49.3
4	VA	23	7.7	57.0
5	MO	21	7.0	64.0
6	CO	20	6.7	70.7
7	NC	15	5.0	75.7
8	NV	12	4.0	79.7
9	NH	12	4.0	83.7
10	MI	10	3.3	87.0
11	IN	9	3.0	90.0
12	NM	8	2.7	92.7
13	WI	8	2.7	95.3
14	IA	7	2.3	97.7
15	MN	2	0.7	98.3
16	ME	2	0.7	99.0
17	DC	1	0.3	99.3
18	TN	1	0.3	99.7
19	WV	1	0.3	100.0

Table 2. Ad spending by candidates from September 24 to November 4, 2008*

Rank	State	Ad \$ spent	% of total	Cumulative %
1	FL	\$29,249,985	18.2	18.2
2	PA	\$24,903,675	15.5	33.7
3	OH	\$16,845,415	10.5	44.1
4	VA	\$16,634,262	10.3	54.5
5	NC	\$9,556,598	5.9	60.4
6	IN	\$8,964,817	5.6	66.0
7	WI	\$8,936,200	5.6	71.5
8	MO	\$7,970,313	5.0	76.5
9	CO	\$7,944,875	4.9	81.4
10	NV	\$7,108,542	4.4	85.9
11	MI	\$5,780,198	3.6	89.5
12	MN	\$4,262,784	2.6	92.1
13	IA	\$3,713,223	2.3	94.4
14	NM	\$3,134,146	1.9	96.4
15	NH	\$2,924,839	1.8	98.2
16	MT	\$971,040	0.6	98.8
17	ME	\$832,204	0.5	99.3

Table 3. Increasing partisanship of states over time

Year	States within each two-party partisanship range		
	(60%+) Landslide	(55%+) Comfortable	(under 55%) Competitive
1960	6	11	33
1964	12	15	24
1968	6	14	31
1972	7	16	28
1976	8	10	33
1980	10	11	30
1984	5	16	30
1988	2	23	26
1992	3	16	32
1996	10	14	27
2000	15	14	22
2004	15	18	18
2008	16	19	16

- b. Загрузите файлы csv, которые вы сохранили в предыдущем пункте для каждой таблицы. В plotly построить интерактивную визуализацию для таблицы 3 из статьи, которая будет отражать, как на протяжении лет менялось соотношение landslide, comfortable и competitive штатов. Написать вывод.

1 балл

- c. Постройте в plotly визуализации для таблиц 1 и 2, которые отражают долю приведенных штатов в рекламном бюджете/политических событиях. Для таблицы 1 используйте столбчатый график. Для таблицы 2 - круговую диаграмму. Обратите внимание, что в таблице 2 в сумме нет 100% и перед тем как строить круговую диаграмму, нужно решить эту проблему. Напишите вывод к каждой визуализации.

1 балл (0.5 балла за каждую визуализацию)

Постройте для одного из графиков выше древовидную карту.

<https://plot.ly/python/treemaps/>

<https://python-graph-gallery.com/200-basic-treemap-with-python/>

Дополнительные 0.5 балла

2. По ссылке загрузите данные о ходе кампании в 2008 году

https://github.com/rogovich/Data/blob/master/docs/Plotly_HW/2008_campaign_data.xlsx?raw=true

Создайте новые переменные - общее количество визитов депутатов (переменные Visit), общее количество расходов на рекламу по радио и телевидению (переменные air), расходы на рекламу на душу населения (переменные Spend и StatePop).

0.6 балла

3. По ссылке загрузите данные опроса National Annenberg Election Survey.

https://github.com/rogovich/Data/blob/master/docs/Plotly_HW/naes_phone.xlsx?raw=true

В нем мы создаем переменную political knowledge.

- a. С помощью codebook

https://github.com/rogovich/Data/blob/master/docs/Plotly_HW/NAES08-Phone-Codebook.pdf

Найдите в наборе данных naes_phone переменные измеряющие political knowledge и штат проживания респондента и выделите их из датасета.

Разберитесь как закодированы переменные political knowledge и приведите их к виду 1 - правильный ответ, 0 - все остальное (нет ответа/неправильный ответ и т.д.). Создайте новую переменную, которая измеряет средний уровень political knowledge для респондента (сумма правильных ответов разделенная на количество вопросов).

Правильные ответы на вопросы:

- i. Supreme Court
- ii. Two-thirds

- iii. Democratic
- iv. Nominated by the president and confirmed by Senate

2 балла

- b. С помощью текстового файла `state_of_residency.txt` перекодируйте колонку с номерами штатов в текстовый формат (двухбуквенный код).

1 балл

- c. Сохраните получившийся датафрейм в csv и положите в архив. Перед сохранением в датафрейме должно быть пять колонок для каждого респондента: штат (двухбуквенный код), ответы на четыре вопроса (1/0), средний уровень `political knowledge`.
- d. В датафрейме, в котором находится информация о ходе кампаний (файл [2008_campaign_data.xlsx](#)) создайте новую переменную на основе датафрейма, полученного в предыдущем пункте. Найдите значение переменной `political knowledge` для каждого штата как среднее значение для всех респондентов из этого штата. Например, его можно получить, если сгруппировать датафрейм из предыдущего пункта по штатам и взять среднее значение PK. А дальше соединить таблицы с помощью [pandas.merge\(\)](#), или подставить нужные значения через `apply`, или...

1.5 балла

- 4. В `plotly` создать две тепловые карты (географические) США для трат на рекламу по штатам и визитов кандидатов в штаты для 2008 года (новые переменные, созданные в п. 2). Написать вывод о трендах.

1 балл

- 5. В `plotly` построить пузырьковый график, который будет отображать наличие или отсутствие связи между расходами на рекламу и визитами кандидата в штат во время предвыборной кампании 2008 года и знаниями о политике жителей этих штатов (три переменных на одном графике — `y`, `x` и цвет или размер). Написать общий вывод.

0.5 балла