Все баллы умножаем на 4

4. Трясем Землю (40 баллов)

Вам дан файл, в котором собраны все землетрясения за некий период.

Описание колонок:

date	Дата, в которую произошло землетрясение
time	Время, в которое произошло землетрясение
latitude	Широта
longitude	Долгота
depth	Глубина, метров
mag	Магнитуда землетрясения (~сила)
magtype	Метод, использованный для подсчета магнитуды
nst	Количество сейсмических станций, использованных для определения места землетрясения
net	Название системы улавливания землетрясений, которая зафиксировала событие
place	Текстовое описание места землетрясения
type	Тип события

(i). Заполните таблицу.

Дата, в которую было максимальное количество землетрясений	2011-03-11 df.date.value_counts().head(1)
Средняя глубина землетрясения. Округлите до 3 знаков после запятой	76.856 df.depth.mean().round(3)
Средняя глубина землетрясения после 01.01.1917. Округлите до 3 знаков после запятой	77.647 df[df.date >= '1917-01-01'].depth.mean().round(3)

25-й персентиль магнитуды землетрясения	6.2 df.mag.quantile(0.25)
42-й персентиль магнитуды землетрясения	6.4 df.mag.quantile(0.42)
Система улавливания землетрясений, у которой был наибольший абсолютный прирост зарегистрированных землетрясений за период с 2000 года по сравнению с периодом до 2000 года[1]. Напишите название этой системы как в датасете, в скобочках укажите этот прирост (в землетрясениях)	pde (855) old_eq = df[df.date < '2000-01-01'].groupby('net').net.count() new_eq = df[df.date >= '2000-01-01'].groupby('net').net.count() (new_eq - old_eq).dropna().sort_values(ascending=False)
Система улавливания землетрясений, у которой был наибольший относительный прирост зарегистрированных землетрясений за период с 2000 года по сравнению с периодом до 2000 года[1]. Напишите название этой системы как в датасете, в скобочках укажите этот прирост (в процентах)	pde (846.535%) old_eq = df[df.date < '2000-01-01'].groupby('net').net.count() new_eq = df[df.date >= '2000-01-01'].groupby('net').net.count() ((new_eq - old_eq) * 100 / old_eq).dropna().sort_values(ascending=False)

Критерии:

Max – **28 баллов**

По **4 балла** за каждую из 7 ячеек

- 1 балл, если ошибка округления в пункте 2 и 3

(ii). Посмотрите внимательнее на переменную nst. Есть ли там подозрительные значения, которые могли бы быть ошибкой в сборе или обработке данных? Прокомментируйте их и причины их появления. Если нужно, проведите дополнительный анализ, не используя данные вне предоставленного файла.

Решение:

Посмотрим на распределение nst:

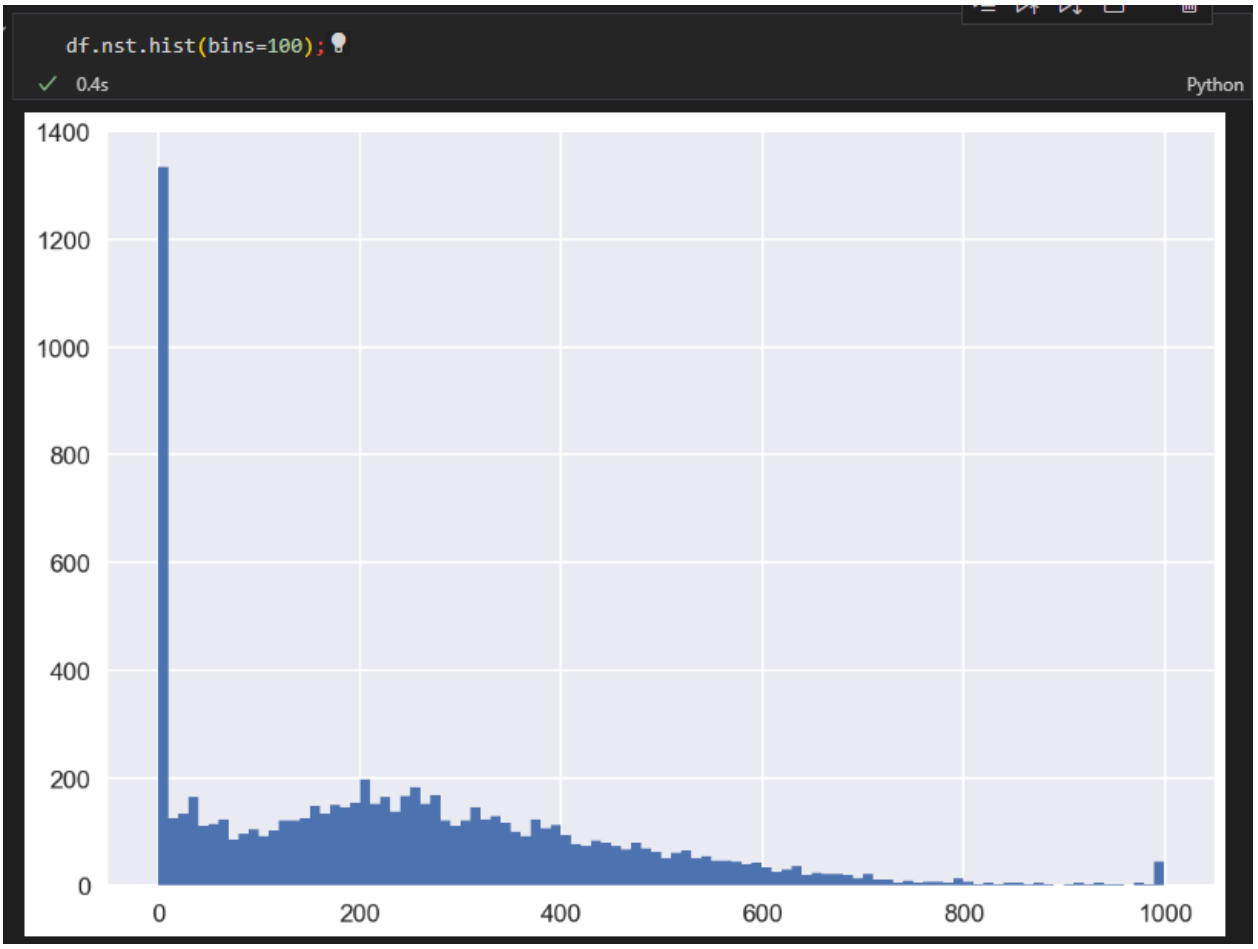

Видны подозрительные пики в 0 и 1000. Посмотрим на них внимательнее:

```
df.nst.value_counts().head(20)
```

✓ 0.1s

0.0	1283
999.0	43
203.0	27
206.0	26
208.0	26
256.0	26
245.0	24
317.0	23
229.0	23
196.0	22
214.0	22
252.0	22
276.0	21
34.0	21
155.0	21
213.0	21
241.0	21
271.0	21
223.0	21
253.0	20

Слишком много наблюдений с 0 станций и с 999 станциями. Если наблюдения с 0 станций действительно правдивые, то их доля должна падать со временем, так как станций

становится больше. Это действительно так:

```
df.loc[:, 'is_0nst'] = (df.nst == 0).astype(int)
df.loc[:, 'year'] = df.date.astype(str).apply(lambda x: x[:4])

df.groupby('year').is_0nst.mean().plot()
```

0.2s Python

```
<AxesSubplot: xlabel='year'>
```

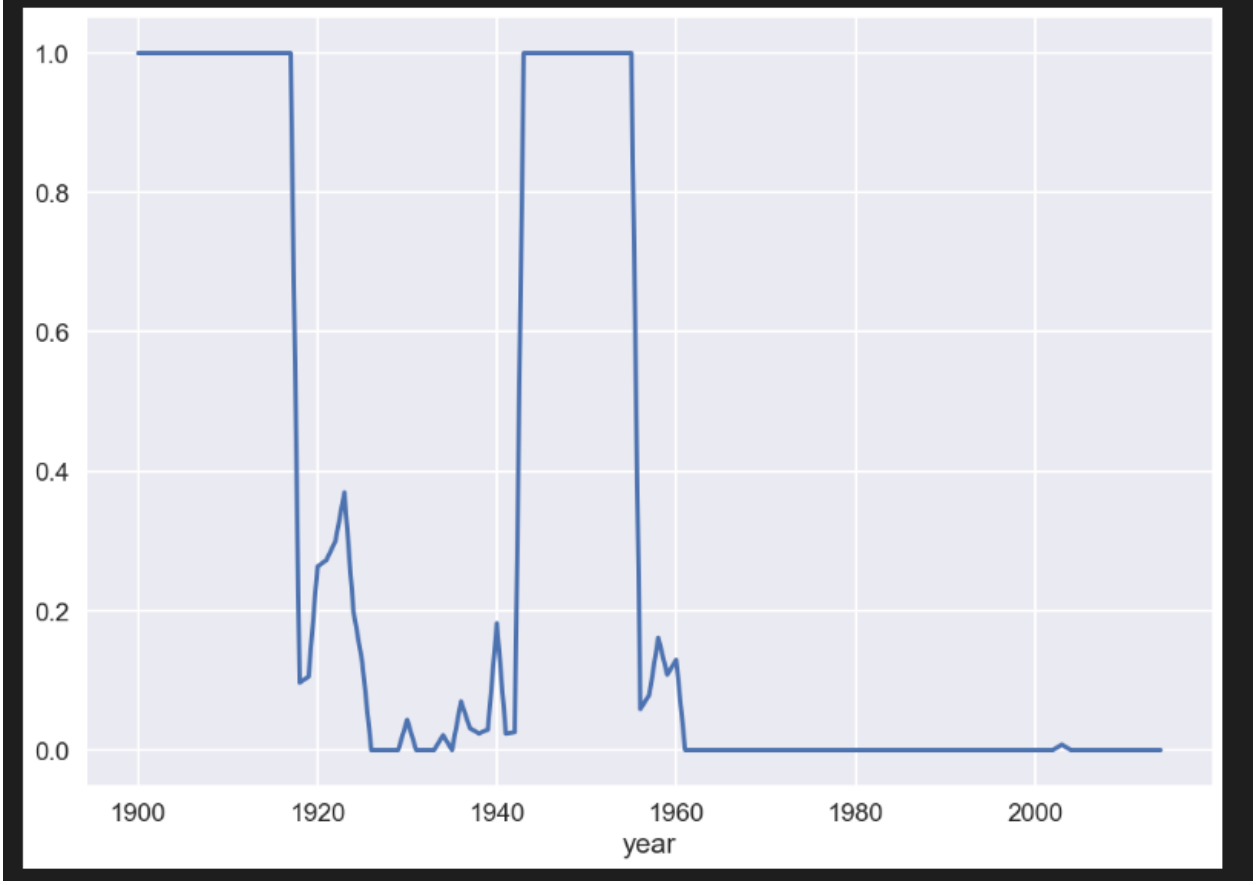

Значит, скорее всего, значение 0 в nst отображает действительность.

Наблюдения с 999 станциями распределены в 2002 -2005 году и сделаны одной станцией. Результатом таких наблюдений может быть как предварительная обработка, так и ограничения фиксирующей землетрясения системы

Критерии:

Max – **24 балла**

Нахождение 0 и 999 – по **4 балла**

Аргументация 0 – **12 баллов**

Аргументация 999 – **4 балла**

(iii). Найдите самое популярное значение в колонке place. Значит ли это, что в данном регионе было больше всего землетрясений в указанный период? *Подсказка: посмотрите на похожие названия регионов*

Решение:

```
df.place.value_counts().head(5)
```

✓ 0.3s

```
Vanuatu                                  349
Kuril Islands                            224
New Britain region, Papua New Guinea     195
Fiji region                              190
Solomon Islands                          183
Name: place, dtype: int64
```

Самое популярное значение – Vanuatu.

Давайте посмотрим на похожие названия:

```
df[(df.place.str.lower().str.contains('vanuatu')) & ~ df.place.isna()].place
```

✓ 0.1s

```
8            262km ESE of Sola, Vanuatu
15         34km E of Port-Olry, Vanuatu
24              32km W of Sola, Vanuatu
85      58km ENE of Luganville, Vanuatu
128        53km NNE of Isangel, Vanuatu
                    ...
8043                          Vanuatu
8054                          Vanuatu
8098                          Vanuatu
8222                   Vanuatu region
8225                          Vanuatu
Name: place, Length: 381, dtype: object
```

Видно, что названия не нормализованы – то есть, землетрясение может произойти в Vanuatu, но это не значит, что в place будет записано именно Vanuatu. Это повлияет на результат нашего анализа. Так, самый популярным регионом может быть Kuril Islands, которые в половине случаев будут записаны по-другому.

Критерии:

Max – **16 баллов**

Самое популярное значение – **4 балла**

Найдено, что названия не нормализованы (есть разные написания одного и того же региона) - **8 баллов**

Аргументация, что Vanuatu может быть не самым популярным регионом – **4 балла**

(iv). Постройте графики, отвечающие на следующие вопросы:

1. На каких глубинах случаются землетрясения?
2. Сколько землетрясений случалось в разные годы?
3. Как магнитуда землетрясения зависит от глубины?
4. В какое время суток случаются самые сильные землетрясения?

Возможные решения:

1. При первом приближении можно заметить большое количество неглубоких землетрясений, из-за которых сложно понять общую картину

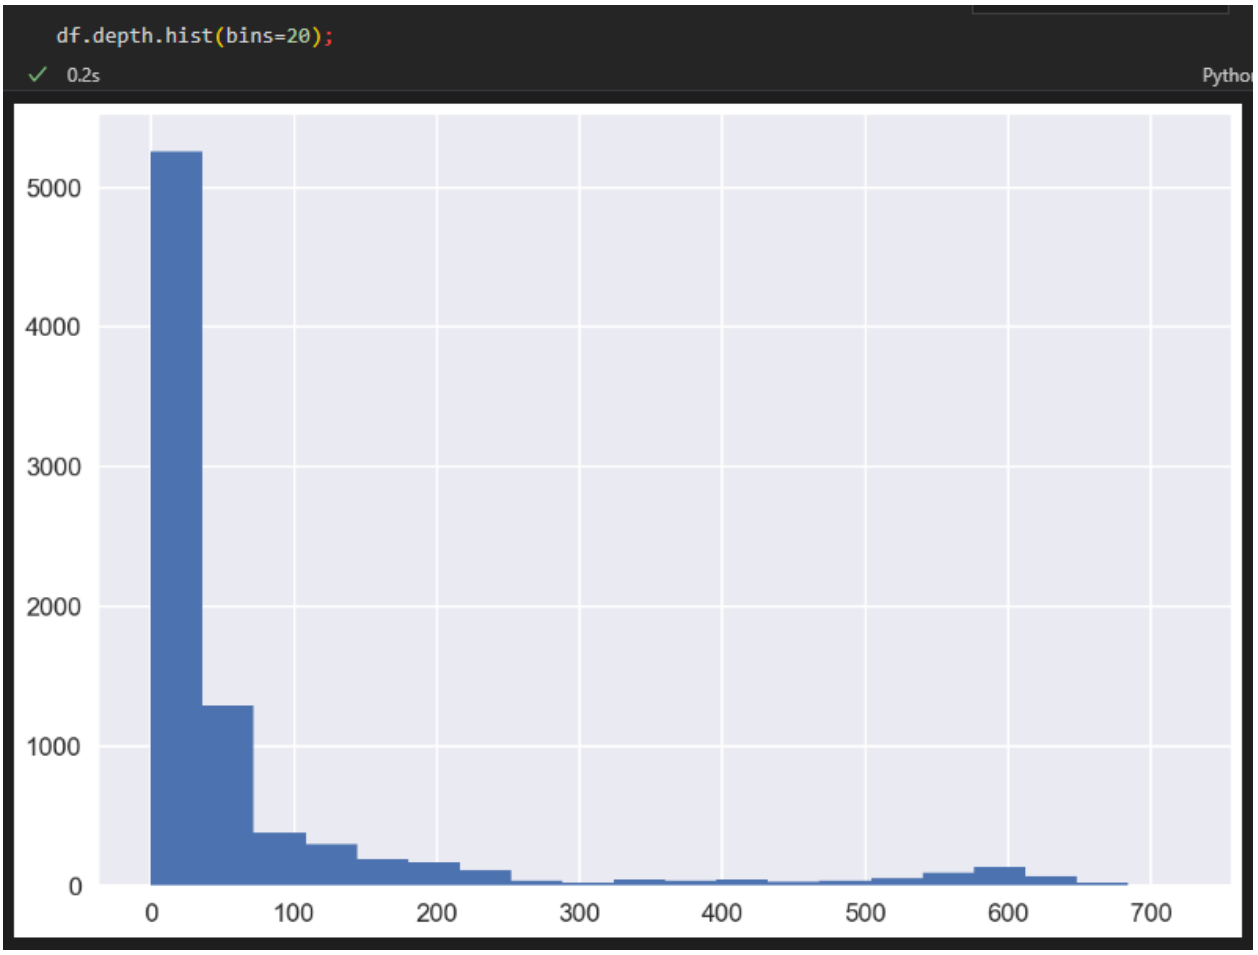

Поэтому можно либо построить два отдельных графика для больших и малых глубин, либо преобразовать ось Y в логарифмическую шкалу. Рассмотрим второй вариант.

```python
df.depth.hist(bins=100)
plt.yscale('log')
plt.xlabel('Глубина землетрясения, метров')
plt.ylabel('Количество');
```

✓ 0.4s Python

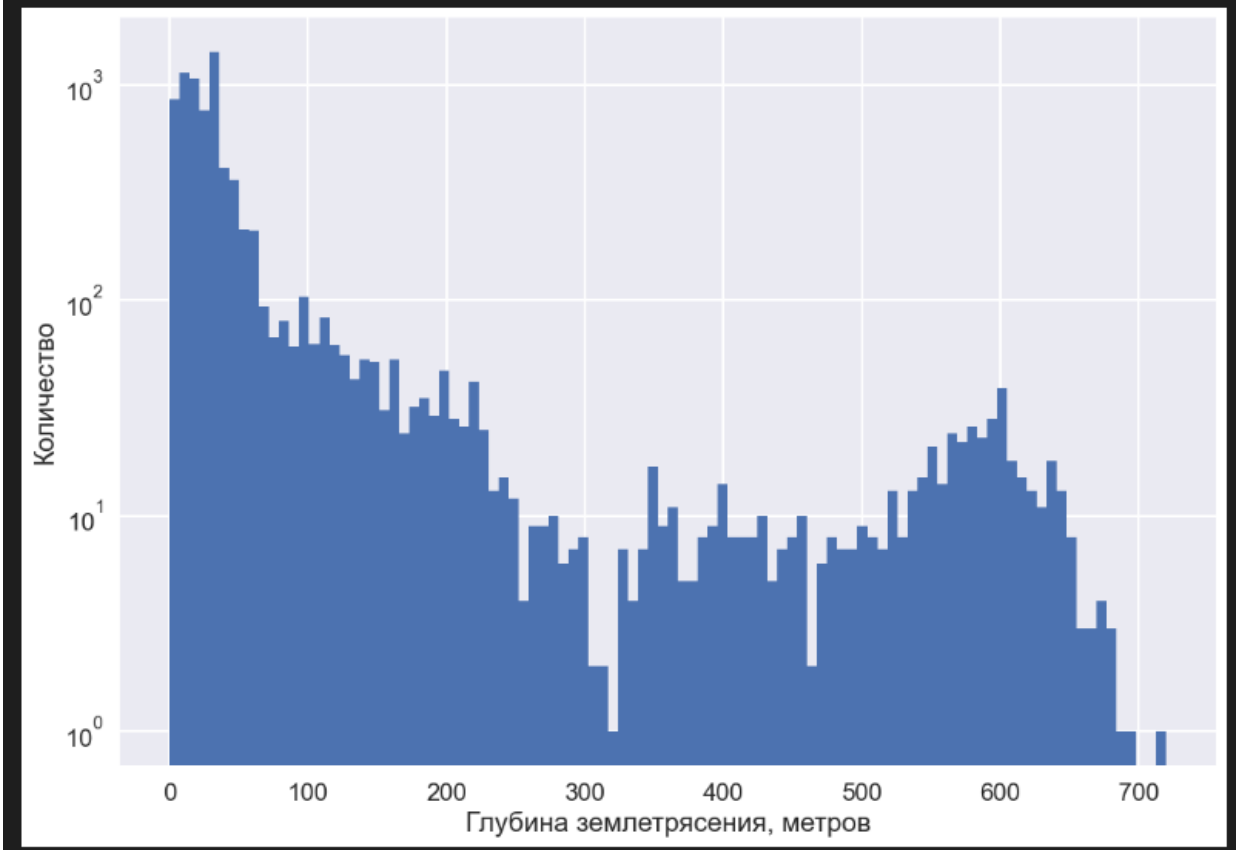

2.

```
df.loc[:, 'year'] = df.date.astype(str).apply(lambda x: x[:4])
years_cnt = df.groupby('year').date.count()
plt.bar(years_cnt.index, years_cnt, width=1)
plt.xticks([str(1900 + i*5) for i in range(24)], rotation=90)
plt.ylabel('Количество землетрясений')
plt.xlabel('Год');
```

✓ 0.4s

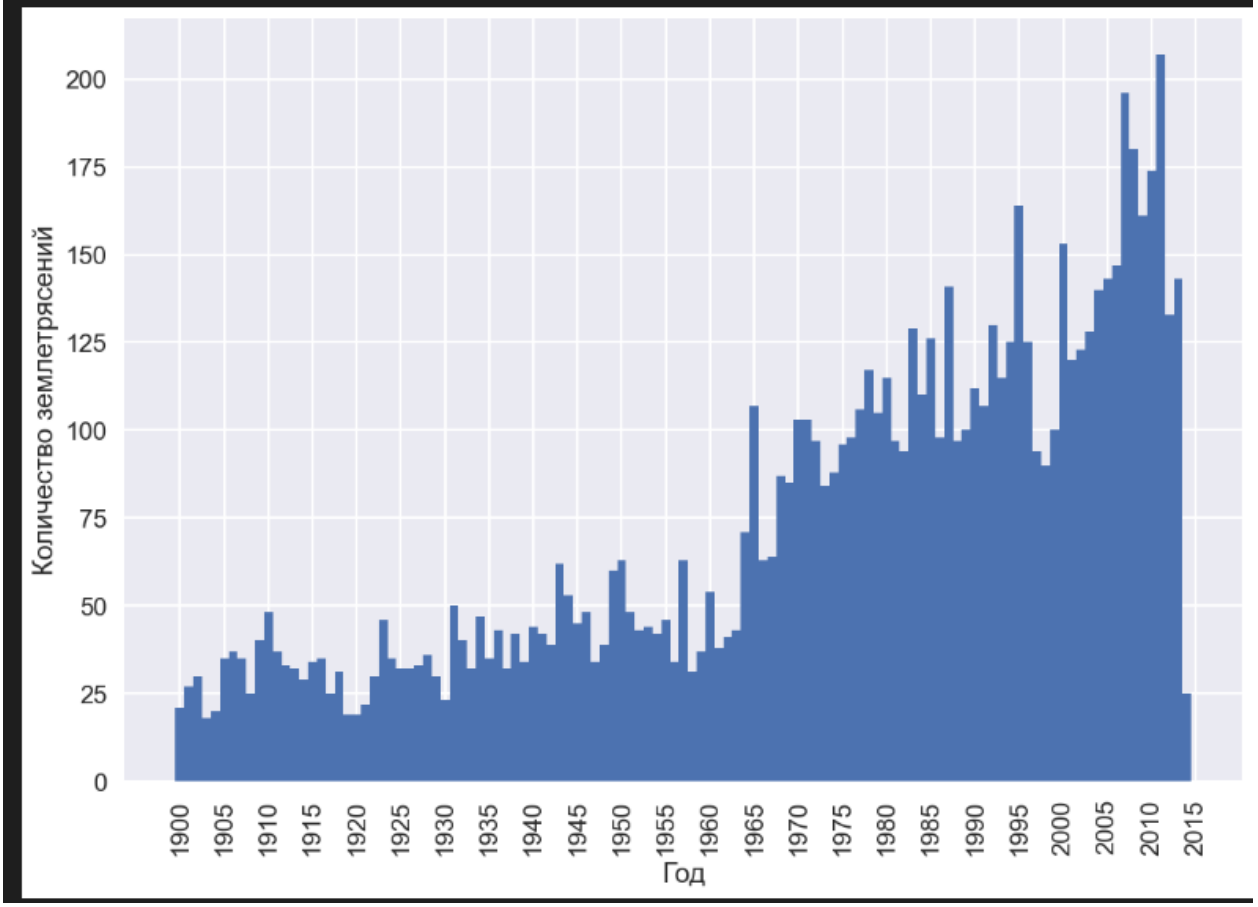

3.

```
appr = 20
df.loc[:, 'approximate_depth'] = df.depth // appr * appr
for d in df.approximate_depth.unique():
    df_depth = df[df.approximate_depth == d]
    plt.boxplot(
        df_depth.mag,
        positions=[d],
        widths=[appr],
        showmeans=True,
        labels=[f'[{d:.0f}-{d+appr:.0f})']
        )
plt.xticks(rotation=90)
df_depth = df.groupby('approximate_depth').mag.mean()

plt.xlabel('Глубина землетрясения, метров')
plt.ylabel('Магнитуда');
```

✓ 0.6s Pyth

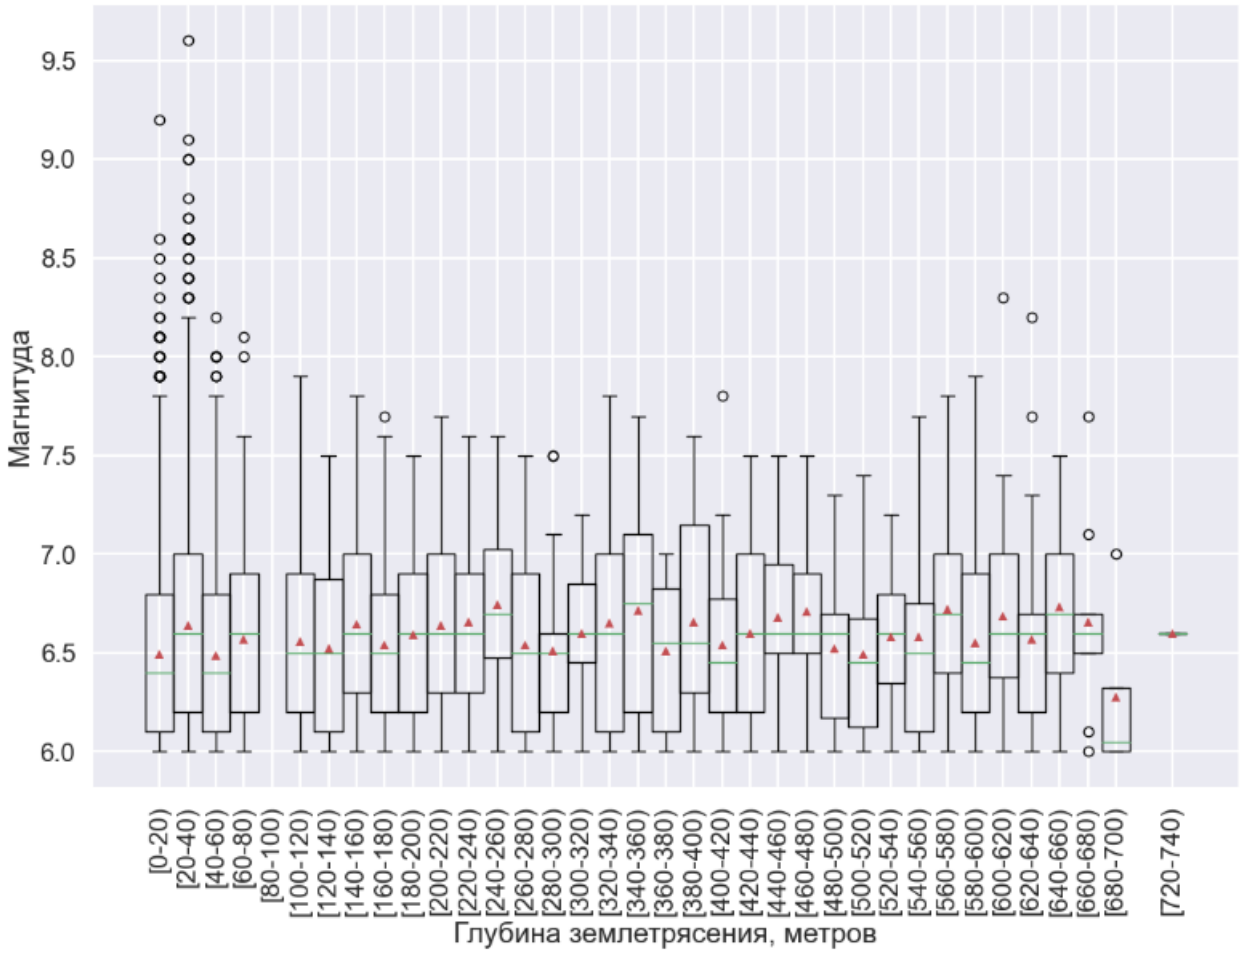

4.

```
appr = 4
df.loc[:, 'hours'] = df.time.apply(lambda x: int(x[:2])//appr*appr)
data = df.groupby('hours').mag.quantile([.90, .95, 1]).reset_index()\
    .pivot(index='hours', values='mag', columns='level_1')
for col in data:
    plt.plot(data.index, data[col], label=f'{col*100:.0f}-й персентиль')
plt.xticks(
    [d*appr for d in range(24//appr)],
    [f'[{d}-{d+appr})' for d in data.sort_index().index]
    )
plt.legend()

plt.xlabel('Время суток, часов')
plt.ylabel('Магнитуда');
```

✓ 0.2s Pytho

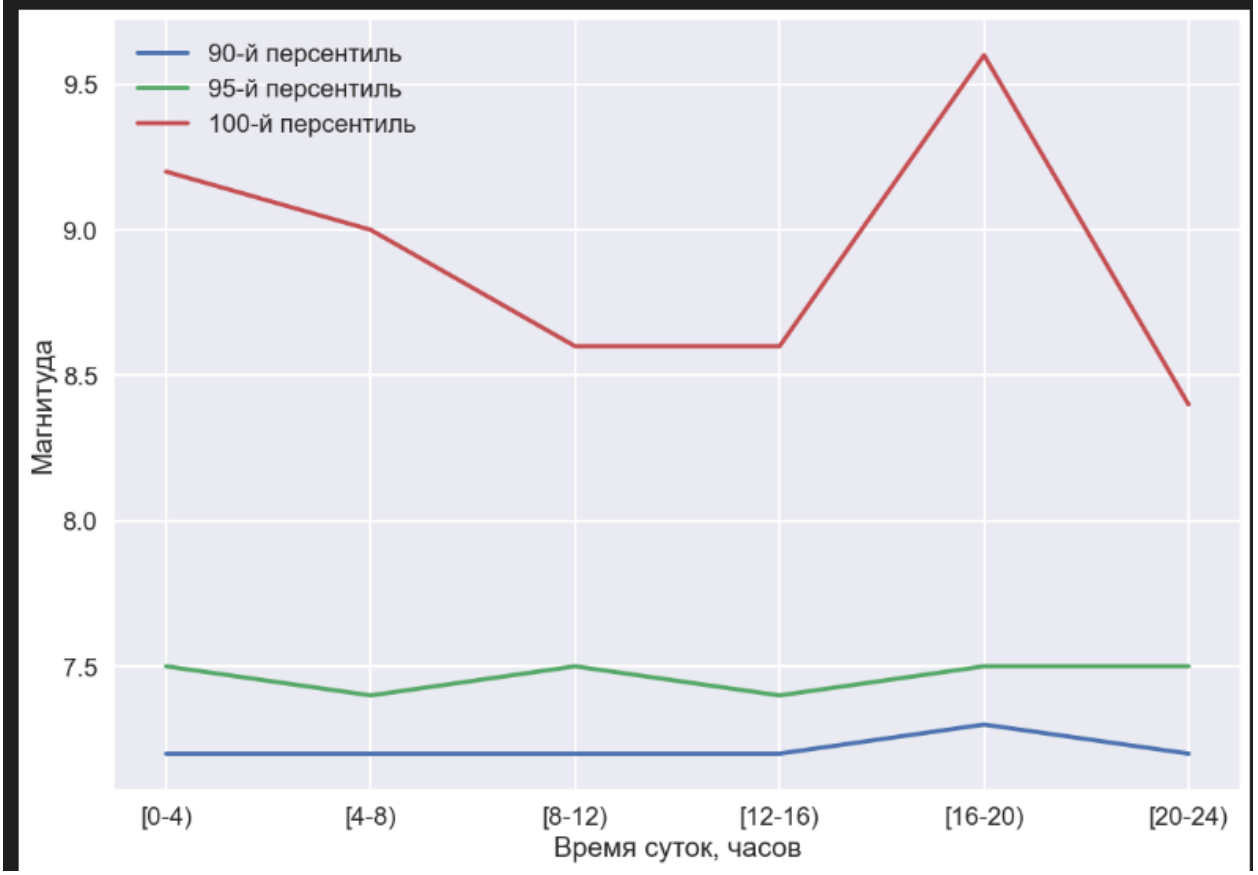

Критерии:

Max – **92 балла**

Снимаем **4 балла** за каждый график, не имеющий подходящих подписей, если из-за этого затруднено его прочтение

Ставим **0 баллов** за график, не имеющий подходящих подписей, если из-за этого невозможно его прочтение

Снимаем еще **4 балла** за перегруженный график, если это затрудняет составление выводов.

1. Max – **20 баллов**
Полный балл ставится, если отображен вид распределения и особенности в районе 40 и 600 метров. Если есть только что-то одно – **12 баллов**

2. Max – **20 баллов**
Отображена зависимость

3. Max – **28 баллов**
Полный балл ставится, если по графику можно сделать следующие выводы:
а. В среднем нет явной зависимости между силой землетрясения и глубиной
б. Экстремально сильные землетрясения происходят обычно на небольшой глубине
За только один вывод – **12 баллов**

4. Max – **24 балла**
Полный балл ставится, если рассмотрена либо зависимость высоких персентилей от времени суток, либо распределение сильных землетрясений по времени суток. При этом вывод - нет зависимости.
Если нет определения того, что такое время суток, то за задание можно получить максимум **16 баллов.**

[1] Игнорируйте системы, которые до 2000 года не регистрировали землетрясения