

Основы работы с Pandas

САМОСТОЯТЕЛЬНАЯ РАБОТА

<http://www.kimrt.ru>

Онлайн-курс

[Суперкомпьютерные технологии в задачах моделирования](#)

Pandas — программная библиотека на языке Python для обработки и анализа данных. Работа *pandas* с данными строится поверх библиотеки NumPy, являющейся инструментом более низкого уровня. Предоставляет специальные структуры данных и операции для манипулирования числовыми таблицами и временными рядами [1].

Установка. Для установки *pandas* выполните `pip install pandas` [2].

Работа с *pandas*. Основные структуры для хранения данных *Series* [3] и *DataFrame* [4]. *Series* – это проиндексированный одномерный массив значений. Он похож на простой словарь типа `dict`, где имя элемента будет соответствовать индексу, а значение – значению записи. *DataFrame* — это проиндексированный многомерный массив значений, соответственно каждый столбец *DataFrame*, является структурой *Series* [5]. Рассмотрим некоторые примеры обработки и запустим код из листинга 1 [6].

Листинг 1

```
# импорт библиотеки pandas
import pandas

# создание структуры series
series_1 = pandas.Series([10, 2, 14, 3, 11])

# вывод структуры
print(series_1)
```

<http://www.kimrt.ru>

Вывод при запуске кода.

```
E:\Python\Python39\pythonw.exe "E:  
0      10  
1       2  
2      14  
3       3  
4      11  
dtype: int64  
  
Process finished with exit code 0
```

Слева расположены индексы, а справа сами элементы. Также в конце таблицы указан тип хранимых данных. Можно получить элемент по индексу, например, `print(series_1[2])`.

```
E:\Python\Python39\pythonw.exe "E:  
14  
  
Process finished with exit code 0
```

С помощью `argmin` узнаем индекс элемента в структуре с наименьшим значением `print(series_1.argmax())`.

```
E:\Python\Python39\pythonw.exe "E:  
1  
  
Process finished with exit code 0
```

С помощью *between* можно найти элементы, расположенные на определенном промежутке `print(series_1.between(10, 13))`. Вошедшие элементы имеют значение *True* в левом столбце.

```
E:\Python\Python39\pythonw.exe "E:
0      True
1      False
2      False
3      False
4      True
dtype: bool

Process finished with exit code 0
```

Функция имеет параметр включения границ, по умолчанию левая и правая границы входят в промежуток. Добавим параметр, исключающий обе границы `print(series_1.between(10, 13, inclusive="neither"))`.

```
E:\Python\Python39\pythonw.exe "E:
0      False
1      False
2      False
3      False
4      True
dtype: bool

Process finished with exit code 0
```

Рассмотрим код из листинга 2.

Листинг 2

```
# импорт библиотеки
```

<http://www.kimrt.ru>

```
import pandas
# создание массива с датами
week = pandas.date_range("2022-04-20", periods=7)
# создание структуры DataFrame
df1 = pandas.DataFrame({"day": week,
                        "max temp(C)": ["+24",
"+23", "+19", "+20", "+19", "+19", "+22"],
                        "min temp(C)": ["+13",
"+13", "+14", "+12", "+9", "+11", "+11"],
                        "max wind speed(m/s)":
["+15", "14", "8", "9", "9", "7", "5"]
                        }) # ВЫВОД

print(df1)
```

При запуске кода получаем следующий вывод.

	day	max temp(C)	min temp(C)	max wind speed(m/s)
0	2022-04-20	+24	+13	15
1	2022-04-21	+23	+13	14
2	2022-04-22	+19	+14	8
3	2022-04-23	+20	+12	9
4	2022-04-24	+19	+9	9
5	2022-04-25	+19	+11	7
6	2022-04-26	+22	+11	5

Process finished with exit code 0

Эта таблица содержит прогноз погоды на неделю. В первом столбце указаны даты, во втором – максимальная температура, в третьем – минимальная температура, в четвертом – максимальная скорость ветра. Для создания массива с датами используется функция <http://www.kimrt.ru>

date_range, параметры которой начальная дата и количество периодов. Параметр, отвечающий за периодичность по умолчанию, имеет значение одни сутки, поэтому количество периодов – это количество суток. В данном случае *DataFrame* построен из словаря, где ключами являются названия столбцов, а значениями – массивы с данными. С помощью *iloc* получим данные из первой строки *print(df1.iloc[0])*.

```
day                2022-04-20 00:00:00
max temp(C)                +24
min temp(C)                +13
max wind speed(m/s)        15
Name: 0, dtype: object


Process finished with exit code 0
```

Также можно получить данные за определенную дату с помощью следующей конструкции *print(df1.loc[df1['day'] == '2022-04-24']) [7]*.

```
      day max temp(C) min temp(C) max wind speed(m/s)
4 2022-04-24          +19          +9                9


Process finished with exit code 0
```

Чтение и запись. Записать данные можно с помощью функции *to_csv*. Запишем файл *df1.to_csv('df1.csv')* и посмотрим результат.



		day	max temp (C)	min temp (C)	max wind speed(m/s)
1	0	2022-04-20	+24	+13	15
2	1	2022-04-21	+23	+13	14
3	2	2022-04-22	+19	+14	8
4	3	2022-04-23	+20	+12	9
5	4	2022-04-24	+19	+9	9
6	5	2022-04-25	+19	+11	7
7	6	2022-04-26	+22	+11	5

Теперь считаем этот файл `df2 = pandas.read_csv('df1.csv', sep=',')` и выведем результат `print(df2)`.



	Unnamed: 0	day	max temp(C)	min temp(C)	max wind speed(m/s)
0	0	2022-04-20	24	13	15
1	1	2022-04-21	23	13	14
2	2	2022-04-22	19	14	8
3	3	2022-04-23	20	12	9
4	4	2022-04-24	19	9	9
5	5	2022-04-25	19	11	7
6	6	2022-04-26	22	11	5

Process finished with exit code 0

Визуализация. Рассмотрим листинг 3 [8].

Листинг 3


```
# импорт библиотек
import pandas
import matplotlib.pyplot as plt
# создание массива с датами
week = pandas.date_range("2022-04-20", periods=7)
# создание структуры DataFrame
df1 = pandas.DataFrame({"day": week,
```

```
        "max temp(C)": ["+24",  
"+23", "+19", "+20", "+19", "+19", "+22"],  
        "min temp(C)": ["+13",  
"+13", "+14", "+12", "+9", "+11", "+11"],  
        "max wind speed(m/s)":  
["15", "14", "8", "9", "9", "7", "5"]  
    })
```

Визуализация

```
temp = df1["max temp(C)"].astype(int)  
days = df1["day"]  
plt.plot(days, temp, ls='none', marker='o')  
plt.show()
```

При запуске кода получим следующий график.



На этом графике отображена максимальная температура для каждой даты. В *days* хранятся данные для оси *x*, а в *temp* – для *y*. Значения получаем из *DataFrame*, но для температуры производит

преобразования в тип данных *int* с помощью *astype*. Далее с помощью *matplotlib* строим график.

http://www.kimrt.ru/index/course_stm/0-24

Проект реализуется победителем Конкурса на предоставление грантов преподавателям магистратуры 2020/2021 благотворительной программы «Стипендиальная программа Владимира Потанина» Благотворительного фонда Владимира Потанина.

Источники

1. Pandas. URL: <https://ru.wikipedia.org/wiki/Pandas>
2. Pandas. Getting started. URL: https://pandas.pydata.org/docs/getting_started/index.html
3. Series. URL: <https://pandas.pydata.org/docs/reference/api/pandas.Series.html#pandas.Series>
4. DataFrame. URL: <https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.html#pandas.DataFrame>
5. Введение в анализ данных с помощью Pandas. URL: <https://habr.com/ru/post/196980/>
6. 10 minutes to pandas. URL: https://pandas.pydata.org/docs/user_guide/10min.html#min
7. Select rows from DataFrame. URL: <https://datatofish.com/select-rows-pandas-dataframe/>
8. Введение в Pandas. URL: <https://khashtamov.com/ru/pandas-introduction/>