

Biblioteca

A biblioteca Pandas é construída sob NumPy e fornece ótimas ferramentas de estruturas e de análise de dados em Python.

Em geral, importa-se a biblioteca dessa forma:
>>> import pandas as pd

Estruturas de dados no Pandas

Séries

Uma matriz uni-dimensional capaz de conter qualquer tipo de dado

a	3
b	-5
c	7
d	4

Índice

```
>>> s = pd.Series([3, -5, 7, 4], index=['a', 'b', 'c', 'd'])
```

Frame de dados (Data frame)

Uma estrutura de dados bi-dimensional com colunas de diferentes tipos

	Pais	Capital	População
1	Portugal	Lisboa	751000
2	Peru	Lima	1120000
3	Chile	Santiago	695000

```
>>> data = {
'País': ['Portugal', 'Peru', 'Chile'],
'Capital': ['Lisboa', 'Lima', 'Santiago'],
'População': [751000, 1120000, 695000]
}
```

```
>>> df = pd.DataFrame(data,
columns=['País', 'Capital', 'População'])
```

Pedindo ajuda

```
>>> help(pd.Series.loc)
```

Selecionando

Recuperar elementos

```
>>> s['b']
-5
Retorna um elemento

>>> df[1:]
País Capital População
1 Portugal Lisboa 751000
2 Peru Lima 1120000
Retorna um subconjunto de um DataFrame
```

Seleção, indexação booleana & definição

Por posição

```
>>> df.iloc[0][0]
'Portugal'
Retorna um único valor por linha & coluna

>>> df.at[0, [0]]
'Portugal'
```

Por rótulo

```
>>> df.iloc[0]['País']
'Portugal'
Retorna um único valor por rótulo de linha & coluna

>>> df.at[0, ['País']]
'Portugal'
```

Por rótulo/posição

```
>>> df.ix[2]
País Chile
Capital Santiago
População 695000
Retorna uma única linha de um subconjunto de linhas
```

```
>>> df.ix[:, 'Capital']
0 Lisboa
1 Lima
2 Santiago
Retorna uma única coluna de um subconjunto de colunas
```

```
>>> df.ix[1, 'Capital']
Lima
Retorna linhas e colunas
```

Indexação booleana

```
>>> s[~(s > 1)]
>>> s[(s < -1) | (s >= 6)]
>>> df[df['População'] > 1000000]
Retorna s, valor não é > 1
s, valor é < -1 ou >=6
Filtro para ajustar o DataFrame
```

Definição

```
>>> s['a'] = 6
Define índice a de s = 6
```

Deletando

```
>>> s.drop(['a', 'c'])
Deleta valores das linhas
>>> s.drop('País', axis=1)
Deleta valores das colunas
```

Ordem & Classificação

```
>>> df.sort_index(by='País')
>>> s.order()
>>> df.rank()
Retorna por linha ou coluna
Retorna por valores
Classifica as entradas
```

Recuperando informações de séries e dataframes

Informações básicas

```
>>> df.shape
>>> df.index
>>> df.columns
>>> df.info()
>>> df.count()
(linhas, colunas)
Descreve o índice
Descreve as colunas
Info sobre o dataframe
Número de valores não-NA
```

Resumos

```
>>> df.sum()
>>> df.cumsum()
>>> df.min/df.max()
>>> df.idmin()/df.idmax()
>>> df.describe()
>>> df.mean()
>>> df.median()
Soma de valores
Soma acumulada
Valores max e min
Valor max e min do índice
Sumário estatístico
Média dos valores
Mediana dos valores
```

Aplicando funções

```
>>> f = lambda x: x*2
>>> df.apply(f)
>>> df.applymap(f)
Aplica a função
Aplica a função por elemento
```

Alinhamento de dados

Alinhamento interno de dados

```
>>> s3 = pd.Series([7, -2, 3], index=['a', 'c', 'd'])
>>> s + s3
a      10.0
b      NaN
c       5.0
d       7.0
```

Operações aritméticas com métodos de preenchimento

É possível alinhar dados usando métodos de preenchimento.

```
>>> s.add(s3, fill_value = 0)
a      10.0
b      -5.0
c       5.0
d       7.0
>>> s.sub(s3, fill_value = 2)
>>> s.div(s3, fill_value = 4)
>>> s.mul(s3, fill_value = 3)
```

I/O

Ler e escrever em CSV

```
>>> pd.read_csv('arquivo.csv', header=None, nrows=5)
>>> pd.to_csv('meudf.csv')
```

Ler e escrever em Excel

```
>>> pd.read_excel('arquivo.xls', sheetname='Pastas1')
>>> pd.to_excel('meudf.csv', sheetname='Pastas1')
Ler múltiplas pastas de um mesmo arquivo
>>> xlsx = pd.ExcelFile(arquivo.xls)
>>> df = pd.read_excel(xlsx, 'Pastas1')
```

Ler e escrever query SQL ou tabela de dados

```
>>> from sqlalchemy import create_engine
>>> engine = create_engine('sqlite:///memory:')
>>> pd.read_sql("SELECT * FROM m_tabela;", engine)
>>> pd.read_sql_table('m_tabela', engine)
>>> pd.read_sql_query("SELECT * FROM m_tabela;", engine)
```

read_sql() é um wrapper conveniente ao redor de read_sql_table() e de read_sql_query()

```
>>> pd.to_sql(meudf, engine)
```