

Pandas 的数据读取与输出

Guangyao Zhao

2022-12-01

Contents

数据读取	1
数据输出	4

Pandas 提供了丰富的数据类型读取接口，比如 CSV, Excel, JSON 等。在此只介绍前两者。

数据读取

`read_csv()` 的参数如下：

```
1 pandas.read_csv(filepath_or_buffer, # 文件路径
2                   sep=_NoDefault.no_default, # 分隔符, 和 delimiter 一样, 两者选其一即可
3                   delimiter=None,
4                   header='infer', # 表头, 默认为第一行
5                   names=_NoDefault.no_default, # 如果表头设置为 None, 则可自定义表头名称, 即 columns 名称
6                   index_col=None, # 索引列, 默认无
7                   usecols=None, # 选择要使用的列
8                   squeeze=None,
9                   prefix=_NoDefault.no_default, # 给表头添加前缀, 比如原表头名称为 '1,2,3'; 添加前缀 'ORP_'
10                  mangle_dupe_cols=True, # 表头名称如果重复, 比如有两列 'ORP', 使用该选项后可将其转化为 ' ORP_'
11                  dtype=None, # 数据类型
12                  engine=None,
13                  converters=None,
14                  true_values=None,
```

```
15     false_values=None,
16     skipinitialspace=False,
17     skiprows=None, # 跳过指定行
18     skipfooter=0,
19     nrows=None,
20     na_values=None, # 空值替换, 若想将 '5, 5.0' 设置为空值, 则可使用 na_values=[5, 5.0]
21     keep_default_na=True, # 是否保留 NaN 为空值, 此选项和 na_values 共同决定空值有哪些
22     na_filter=True, # 是否检查空值, 如果确定文件中无空值, 则可将其设置为 False, 提高运行速度
23     verbose=False,
24     skip_blank_lines=True, # 是否跳过空行
25     parse_dates=None, # 是否对时间日期进行解析
26     infer_datetime_format=False, # 如果开启了 parse_dates 选项, 而且 datetime 字符串的格式都
27     keep_date_col=False,
28     date_parser=None,
29     dayfirst=False,
30     cache_dates=True,
31     iterator=False,
32     chunksize=None,
33     compression='infer',
34     thousands=None, # 是否设置千分位分隔符
35     decimal='.', # 小数点标识符
36     lineterminator=None, # 行结束标识符, 比如 'a,b,c~1,2,3~4,5,6', 将 lineterminator='~', 则读
37     quotechar='''',
38     quoting=0,
39     doublequote=True,
40     escapechar=None,
41     comment=None, # 注释标识符, 比如 comment='#', 则会被忽视
42     encoding=None,
43     encoding_errors='strict',
44     dialect=None,
45     error_bad_lines=None,
46     warn_bad_lines=None,
47     on_bad_lines=None,
48     delim_whitespace=False, # 空格分隔符, 和 delimiter, sep 冲突, 相当于 sep='\s+'
49     low_memory=True,
50     memory_map=False,
```

```
51     float_precision=None,  
52     storage_options=None)
```

和 `read_csv()` 相比, `read_excel()` 仅仅多了一个 `sheet_name()` 选项:

```
1 pandas.read_excel(io,  
2                     sheet_name=0, # 要读取的 sheet 名称, 可以是一个也可以是多个, 如果不指定则默认第一个。int |  
3                     header=0,  
4                     names=None,  
5                     index_col=None,  
6                     usecols=None,  
7                     squeeze=None,  
8                     dtype=None,  
9                     engine=None,  
10                    converters=None,  
11                    true_values=None,  
12                    false_values=None,  
13                    skiprows=None,  
14                    nrows=None,  
15                    na_values=None,  
16                    keep_default_na=True,  
17                    na_filter=True,  
18                    verbose=False,  
19                    parse_dates=False,  
20                    date_parser=None,  
21                    thousands=None,  
22                    decimal='.',  
23                    comment=None,  
24                    skipfooter=0,  
25                    convert_float=None,  
26                    mangle_dupe_cols=True,  
27                    storage_options=None)
```

可以看到大部分命令和 `read_csv` 基本一致, 但是多了 `sheet_name` 选项。如果 csv 文件格式能满足需求, 则尽量避免使用 `excel`, 因为前者更通用, 读取数据快且处理方法更丰富。

数据输出

处理后的表格也可以进行相应的输出。`to_csv()` 的参数如下：

```
1 DataFrame.to_csv(path_or_buf=None, # 路径  
2                 sep=',', # 分隔符  
3                 na_rep=' ', # 空值代替符号  
4                 float_format=None,  
5                 columns=None, # 表头名称  
6                 header=True, # 是否含有表头, 和 columns 结合使用, 也可直接在此传入表头名称  
7                 index=True,  
8                 index_label=None,  
9                 mode='w',  
10                encoding=None,  
11                compression='infer', # 是否压缩, 不常用  
12                quoting=None,  
13                quotechar='"',  
14                lineterminator=None,  
15                chunksize=None,  
16                date_format=None,  
17                doublequote=True,  
18                escapechar=None,  
19                decimal='.',  
20                errors='strict',  
21                storage_options=None)
```

`to_excel()` 和 `to_csv()` 相比, 特殊之处在于前者支持多 sheet:

```
1 with pandas.ExcelWriter('xxx.xlsx') as writer:  
2     df1.to_excel(writer, sheet_name='name1')  
3     df2.to_excel(writer, sheet_name='name2')
```