

pandas時系列データ(基本)

- 「Pythonによるデータ分析入門」P347～より抜粋

標準ライブラリ関連

datetime

```
from datetime import datetime

now = datetime.now()
now
>>datetime.datetime(2021, 5, 8, 9, 49, 16, 657431)

now.year, now.month, now.day
>>(2021, 5, 8)

delta = datetime(2021, 5, 8) - datetime(2021, 1, 1)
delta
>>datetime.timedelta(days=127)

delta = datetime(2021, 5, 8, 9, 36) -datetime(2021,1,1)
delta
>>datetime.timedelta(days=127, seconds=34560)

delta.days
>>127
```

timedelta

```
from datetime import timedelta
start = datetime(2021, 5,8)
start + timedelta(60)
>>datetime.datetime(2021, 7, 7, 0, 0)
```

strftime,.strptime

```
stamp = datetime(2021, 5, 8)
stamp
>>datetime.datetime(2021, 5, 8, 0, 0)
str(stamp)
>>'2021-05-08 00:00:00'

stamp.strftime('%Y%m%d')
>>'20210508'

stamp.strftime('%y-%m-%d')
>>'21-05-08'

# 文字列をdate型へ型を合わせてパース
value = '20210508'
datetime.strptime(value, '%Y%m%d')
>>datetime.datetime(2021, 5, 8, 0, 0)

datestrs = ['2021/4/1', '2021/5/1']
[datetime.strptime(x, '%Y/%m/%d') for x in datestrs]
>>[datetime.datetime(2021, 4, 1, 0, 0), datetime.datetime(2021, 5, 1, 0, 0)]
```

Datetimeフォーマット一覧

型	説明
%Y	yyyy
%y	yy
%m	月 mm
%d	日 dd
%H	時間(24時間)
%I	時間(12時間)
%M	2桁の分
%S	2桁の秒
%w	曜日(0:日曜～)
%F	%Y-%M-%dの短縮形2021-5-8
%D	%m%d%yの短縮形 08/05/21

dateutil.parser > parse

```
from dateutil.parser import parse

# 自動でパースしてくれる
parse('2021/5/8')
>>datetime.datetime(2021, 5, 8, 0, 0)

parse('2021/5/8 10:15')
>>datetime.datetime(2021, 5, 8, 10, 15)

# これは無理なのでstrptimeでパースがよい
parse('210508')
>>datetime.datetime(2008, 5, 21, 0, 0)

# これも無理、年は4桁がよいのかも
parse('21/5/8')
>>datetime.datetime(2008, 5, 21, 0, 0)
```

Pandas関連

pd.to_datetime()

- 日時データに変換
- pandasの場合、標準の日付であればパース可能

```
datestrs = ['2021-05-08 10:20:00', '2021-05-09 10:20:00']

pd.to_datetime(datestrs)

>> DatetimeIndex(['2021-05-08 10:20:00', '2021-05-09 10:20:00'],
dtype='datetime64[ns]', freq=None)
```

pd.date_range()

- 日時データ範囲を生成

```
pd.date_range('2021/5/1', '2021/5/10')
>> DatetimeIndex(['2021-05-01', '2021-05-02', '2021-05-03', ~
'2021-05-10'], dtype='datetime64[ns]', freq='D')

pd.date_range(start='2021/5/1', periods=10)
>> DatetimeIndex(['2021-05-01', '2021-05-02', '2021-05-03', ~
'2021-05-10'], dtype='datetime64[ns]', freq='D')

pd.date_range(end='2021/5/28', periods=5)
>> DatetimeIndex(['2021-05-24', '2021-05-25', '2021-05-26', ~
'2021-05-28'], dtype='datetime64[ns]', freq='D')

# タイムスタンプとしては午前零時に標準化したい場合
pd.date_range('2021-05-09 12:24:28', periods=5, normalize=True)
>> DatetimeIndex(['2021-05-09', '2021-05-10', '2021-05-11', ~
'2021-05-13'], dtype='datetime64[ns]', freq='D')
```

```
# 毎月1日
pd.date_range('2021/5/1', periods=5, freq='MS')
>>DatetimeIndex(['2021-05-01', '2021-06-01', '2021-07-01', ~
'2021-09-01'],dtype='datetime64[ns]', freq='MS')

# 毎月末
pd.date_range('2021/5/1', periods=5, freq='M')
>>DatetimeIndex(['2021-05-31', '2021-06-30', '2021-07-31', ~
'2021-09-30'],dtype='datetime64[ns]', freq='M')
```

時系列の基準頻度(P359より抜粋)

文字	オフセットクラス	説明
B	BusinessDay	毎営業日
M	MonthEnd	暦通りの月末ごと
BM	BusinessMonthEnd	月の最終営業日
MS	MonthBegin	暦通りの月初ごと
BMS	BusinessMonthBegin	月の営業開始日ごと
W-MON,W-TUE,...	Week	毎週指定した曜日ごと

```
# 時系列のサンプル作成
index = pd.date_range('2021/5/1', periods=100)
ts = pd.DataFrame(np.random.randn(100), index=index, columns=['VALUE'])

# 5月だけを取り出す
ts['2021/5']

# 以降を取り出す
ts['2021/5/25:']

# 一定期間を取り出す
ts['2021/5/25':'2021/6/12']
```

文字列⇄日時の型変換

- note.mknk.meより
- `pd.read_csv`等で取り込んだ場合、すべて文字列になっている

	A	B
0	2017-11-01 12:24	2017年11月1日 12時24分
1	2017-11-18 23:00	2017年11月18日 23時00分
2	2017-12-05 5:05	2017年12月5日 5時05分
3	2017-12-22 8:54	2017年12月22日 8時54分
4	2018-01-08 14:20	2018年1月8日 14時20分
5	2018-01-19 20:01	2018年1月19日 20時01分

1. 読み込み後: 文字列→datetime型に変換(読み込み後)

```
df.dtypes
>>A object
>>B object
>>dtype: object

type(df['A'][0])
>>str

# 文字列→datetime型へ変換(デフォルト)
pd.to_datetime(df['A'])
>>0    2017-11-01 12:24:00
>>1    2017-11-18 23:00:00
>>2    2017-12-05 05:05:00
~ |
>>Name: A, dtype: datetime64[ns]

# 文字列→datetime型へ変換(フォーマット指定。上記でうまくいかない場合)
pd.to_datetime(df['A'], format='%Y年%m月%d日% %H時%M分')
>>0    2017-11-01 12:24:00
>>1    2017-11-18 23:00:00
>>2    2017-12-05 05:05:00
~
>>Name: B, dtype: datetime64[ns]

# 重要: 列を新規追加(datetime型)(オリジナルを変えず列を追加するのがよい)
df['X'] = pd.to_datetime(df['A'], ~)
```

	A	B	X
0	2017-11-01 12:24	2017年11月1日 12時24分	2017-11-01 12:24:00
1	2017-11-18 23:00	2017年11月18日 23時00分	2017-11-18 23:00:00
2	2017-12-05 5:05	2017年12月5日 5時05分	2017-12-05 05:05:00
3	2017-12-22 8:54	2017年12月22日 8時54分	2017-12-22 08:54:00
4	2018-01-08 14:20	2018年1月8日 14時20分	2018-01-08 14:20:00
5	2018-01-19 20:01	2018年1月19日 20時01分	2018-01-19 20:01:00

df.dtypes

```
>>A          object
>>B          object
>>X    datetime64[ns]
>>dtype: object
```

年の抽出

df['X'].dt.year ←month, dayでも同様

```
0    2017
1    2017
2    2017
3    2017
4    2018
5    2018
Name: X, dtype: int64
```

曜日(6:日曜日)を表示

df['X'].dt.dayofweek

```
0    2
1    5
2    1
3    4
4    0
5    4
Name: X, dtype: int64
```

月曜日だけを表示

df[df['X'].dt.dayofweek == 0]

	A	B	X
4	2018-01-08 14:20	2018年1月8日 14時20分	2018-01-08 14:20:00

2. 読み込み後:datetime型→文字列に変換

```
# datetime型→文字列に変換(デフォルト)
df['X'].astype(str)
>>0    2017-11-01 12:24:00
>>1    2017-11-18 23:00:00
>>2    2017-12-05 05:05:00
>>~
>>Name: X, dtype: object

# datetime型→文字列に変換(フォーマット指定)
df['X'].dt.strftime('%Y年%m月%d日')
>>0    2017年11月01日
>>1    2017年11月18日
>>2    2017年12月05日
>>~
>>Name: X, dtype: object

# 列を新規追加
df['日付'] = df['X'].dt.strftime('%Y年%m月%d日')
```


3. 読み込み時: 文字列→datetime型に変換

```
url =  
'https://raw.githubusercontent.com/nkmk/python-snippets/8501c6f55aa9b1c5ec  
fc940f18ba4aef23325cd8/notebook/data/src/sample_datetime_multi.csv'
```

```
# parse_datesに、datetime型へ変換したい列(列:0)を渡す  
df_csv = pd.read_csv(url, parse_dates=[0])  
df_csv
```

	A	B
0	2017-11-01 12:24:00	2017年11月1日 12時24分
1	2017-11-18 23:00:00	2017年11月18日 23時00分
2	2017-12-05 05:05:00	2017年12月5日 5時05分
3	2017-12-22 08:54:00	2017年12月22日 8時54分
4	2018-01-08 14:20:00	2018年1月8日 14時20分
5	2018-01-19 20:01:00	2018年1月19日 20時01分

```
df_csv.dtypes  
>>A      datetime64[ns]  
>>B              object  
>>dtype: object
```

```
# 標準的な書式でない場合は「date_parser」に読み込む書式を渡して読み込む  
# Lambda箇所はわかりにくい(dateはデフォルト?)
```

```
df_csv2 = pd.read_csv(url,  
                      parse_dates=[1],  
                      date_parser=lambda date: pd.to_datetime(date, \  
                      format='%Y年%m月%d日 %H時%M分'))
```

	A	B
0	2017-11-01 12:24	2017-11-01 12:24:00
1	2017-11-18 23:00	2017-11-18 23:00:00
2	2017-12-05 5:05	2017-12-05 05:05:00
3	2017-12-22 8:54	2017-12-22 08:54:00
4	2018-01-08 14:20	2018-01-08 14:20:00
5	2018-01-19 20:01	2018-01-19 20:01:00

```
df_csv2.dtypes  
>>A              object  
>>B      datetime64[ns]  
>>dtype: object
```

→仮にdate_parserなしで読み込むと、Bはobjectのまま読み込まれる

```
# indexに指定した列をdatetime型へ変換する場合(parse_dates=True)
df_csv3 = pd.read_csv(url,
                       index_col=1,
                       parse_dates=True,
                       date_parser=lambda date: pd.to_datetime(date,\
                       format='%Y年%m月%d日 %H時%M分'))
```

df_csv3

	A
B	
2017-11-01 12:24:00	2017-11-01 12:24
2017-11-18 23:00:00	2017-11-18 23:00
2017-12-05 05:05:00	2017-12-05 5:05
2017-12-22 08:54:00	2017-12-22 8:54
2018-01-08 14:20:00	2018-01-08 14:20
2018-01-19 20:01:00	2018-01-19 20:01

pd.read_excel()でもparse_dates, date_parser を利用可能

DatetimeIndex

- datetime64[ns]型のDataFrameで日付をindexにするとDatetimeIndexになる
- いろんな機能が使えるらしいがよくわかっていない

```
df_i = df.set_index('X')
df_i
```

	A	B
X		
2017-11-01 12:24:00	2017-11-01 12:24	2017年11月1日 12時24分
2017-11-18 23:00:00	2017-11-18 23:00	2017年11月18日 23時00分
2017-12-05 05:05:00	2017-12-05 5:05	2017年12月5日 5時05分
2017-12-22 08:54:00	2017-12-22 8:54	2017年12月22日 8時54分
2018-01-08 14:20:00	2018-01-08 14:20	2018年1月8日 14時20分
2018-01-19 20:01:00	2018-01-19 20:01	2018年1月19日 20時01分

```
df_i.index.strftime('%Y%m%d')
>>Index(['20171101', '20171118', '20171205', '20171222', '20180108',
>>'20180119'], dtype='object', name='X')
```