

レシピ61 SATの加重平均点を州ごとにapplyで計算（P171）

- `groupby` メソッドには、関数を使って各グループで計算を行うメソッドが4種類あり、戻り値は以下

メソッド	戻り値
<code>agg</code>	スカラー値
<code>filter</code>	Boolean
<code>tranform</code>	渡されるグループと同じ長さのSeries
<code>apply</code>	スカラー値、Series、DataFrame <b>柔軟に使える！</b>

- `apply` は、グループに対して1回しか呼び出せないで、グループ分けしていないカラムで呼び出される `transform` や `agg` と対照的
- このレシピでは、数学と言語能力のSAT点数の加重平均を、大学データセットを使い、州ごとに求める
- 学校ごとの学部学生の人数で点数に重みを与える

(1) collegeデータセットを読み込み、UGDS、SATMTMID、SATVRMIDカラムの欠損値がある行を削除する（欠損なしデータが必須）

- 'UGDS'・・・学部学生数
- 'SATMTMID'・・・SAT Math Median（大学進学のための標準テスト（Standardized Test）の、言語能力の点数・中央値）
- 'SATVRMID'・・・SAT Verbal Median（SATの数学の点数・中央値）

```
In [112... college = pd.read_csv('college.csv')
subset = ['UGDS', 'SATMTMID', 'SATVRMID']
college2 = college.dropna(subset=subset)

print(f'college.shape:{college.shape}')
print(f'college2.shape:{college2.shape}')
```

```
college.shape:(7535, 27)
college2.shape:(1184, 27)
```

```
In [113... print('\u25b2college2.sample\n')
college2.head(2)
```

```
▼college2.sample
```

	INSTNM	CITY	STABBR	HBCU	MENONLY	WOMENONLY	RELAFFIL	SATVRMID	SATMTMID	DISTANCEONLY	...	UGDS_2MOR	UGDS_NRA	UGDS_UNKN	PPTUG_EF	CURROPER	PCTPELL	PCTFLOAN	UG25ABV	MD_EARN_WNE_P10	GRAD_DEBT_MDN_SUPP
0	Alabama A & M University	Normal	AL	1.0	0.0	0.0	0	424.0	420.0	0.0	...	0.0000	0.0059	0.0138	0.0656	1	0.7356	0.8284	0.1049	30300	33888
1	University of Alabama at Birmingham	Birmingham	AL	0.0	0.0	0.0	0	570.0	565.0	0.0	...	0.0368	0.0179	0.0100	0.2607	1	0.3460	0.5214	0.2422	39700	21941.5

2 rows × 27 columns

(2) 次にSATの数学だけ加重平均を取る関数を作成する

- 加重平均とは、{学生数\*平均点}の合計 ÷ 学生数の合計

```
In [114... def weighted_math_average(df):
    weighted_math = df['UGDS'] * df['SATMTMID']
    return int(weighted_math.sum() / df['UGDS'].sum())
```

(3) 州でグループ化して、applyメソッドにこの関数を渡すと、加重平均のスカラー値が得られる

```
In [115... college2.groupby('STABBR').apply(weighted_math_average).head()
```

```
Out[115... STABBR
AK      503
AL      536
AR      529
AZ      569
CA      564
dtype: int64
```

(4) 参考までに `agg` メソッドに同じ関数を渡すとどうなるか

```
In [116... # college2.groupby('STABBR').agg(weighted_math_average).head()
# これはエラーになるため、割愛（本と同じようにならない）
# KeyError: 'UGDS'
```

(5)

- `apply` のよいところは、Seriesを返して複数の新たなカラムを作れること
- 返されたSeriesのインデックスは新たなカラム名になる
- ユーザー定義関数を、2つのSAT点の加重平均および算術平均を各グループの大学数とともに計算するように修正する
- この5つの値をSeriesで返す

- Pythonの `OrderedDict`
  - 順序付き辞書
  - Ptyhonの通常の辞書は要素の順番を保持しない（Python3.7以降は順序付きらしい？）
  - collectionsモジュールに順番が保持された辞書として `OrderDict` が用意されている

```
In [117... from collections import OrderedDict

def weighted_average(df):

    data = OrderedDict()

    # 加重平均（学生数*SAT数学or言語で戻した点数 ÷ 全学生数）
    weight_m = df['UGDS'] * df['SATMTMID']
    weight_v = df['UGDS'] * df['SATVRMID']
    wm_avg = weight_m.sum() / df['UGDS'].sum()
    wv_avg = weight_v.sum() / df['UGDS'].sum()

    # 加重平均と算術平均の列を作成
    data['weighted_math_avg'] = wm_avg
    data['weighted_verbal_avg'] = wv_avg
    data['math_avg'] = df['SATMTMID'].mean()
    data['verbal_avg'] = df['SATVRMID'].mean()
    data['count'] = len(df)

    return pd.Series(data)

# return pd.Series(data, dtype='int')
# 書籍ではdtype='int'になっているが、これだと以下エラーになる
# ValueError: Trying to coerce float values to integers
```

```
In [118... college2.groupby('STABBR').apply(weighted_average).head(10)
```

```
Out[118... weighted_math_avg  weighted_verbal_avg  math_avg  verbal_avg  count
STABBR
AK      503.000000      555.000000  503.000000  555.000000      1.0
AL      536.137917      533.383387  504.285714  508.476190     21.0
AR      529.112332      504.876157  515.937500  491.875000     16.0
AZ      569.313985      557.303350  536.666667  538.333333      6.0
CA      564.945420      539.316605  562.902778  549.083333     72.0
CO      553.123820      547.033996  540.214286  537.714286     14.0
CT      545.341834      533.417563  522.500000  517.857143     14.0
DC      621.905104      623.514036  588.333333  589.166667      6.0
DE      569.954949      553.534560  495.000000  486.666667      3.0
FL      565.324731      565.815873  521.842105  529.289474     38.0
```

（補足）割愛（P175）

- Seriesではなく、DataFrameでの返し方