

データの読み込み

```
In [1]: import matplotlib.pyplot as plt  
import numpy as np  
import pandas as pd  
# 以上3つのライブラリが「3種の神器」
```

```
In [2]: Data=pd.read_csv("D:/2022_数理統計学/StatData/StatData01_2.csv") # 読み出したいファイルのパス
```

```
In [3]: Data # 読み込んだデータを見る。データには自動的に、0番から番号がつく。
```

Out[3]:

| | 階級値 (c_j) | 度 数 (f_j) |
|----|-----------|-----------|
| 0 | 22 | 1 |
| 1 | 24 | 4 |
| 2 | 26 | 5 |
| 3 | 28 | 15 |
| 4 | 30 | 18 |
| 5 | 32 | 20 |
| 6 | 34 | 18 |
| 7 | 36 | 11 |
| 8 | 38 | 4 |
| 9 | 40 | 2 |
| 10 | 42 | 2 |

```
In [4]: # 日本語は避ける方がよい  
# ついでに簡単な変数名 (x, f) にしてしまう  
Data = Data.rename(columns={'階級値 (c_j)': 'x'}) # Data= とすることで上書きされる。  
Data = Data.rename(columns={'度 数 (f_j)': 'f'}) # Data= とすることで上書きされる。  
Data.head()
```

Out[4]:

| | x | f |
|---|----|----|
| 0 | 22 | 1 |
| 1 | 24 | 4 |
| 2 | 26 | 5 |
| 3 | 28 | 15 |
| 4 | 30 | 18 |

```
In [5]: # ファイルを読み込む段階でカラム名を変更しておくことも可能
Data=pd.read_csv("D:\2022_数理統計学\StatData\StatData01_2.csv", # 読み出したいファイルのパス
                 skiprows=1,          # データファイルの最初の1行を飛ばす
                 names=['x', 'f'])    # カラム名を付ける
Data.head()
```

Out[5]:

| | x | f |
|---|----|----|
| 0 | 22 | 1 |
| 1 | 24 | 4 |
| 2 | 26 | 5 |
| 3 | 28 | 15 |
| 4 | 30 | 18 |

度数分布表で統計量を計算する

```
In [6]: Data['xf']=Data['x']*Data['f']
Data['x^2f']=Data['x']**2*Data['f']
Data
```

Out[6]:

| | x | f | xf | x^2f |
|----|----|----|-----|-------|
| 0 | 22 | 1 | 22 | 484 |
| 1 | 24 | 4 | 96 | 2304 |
| 2 | 26 | 5 | 130 | 3380 |
| 3 | 28 | 15 | 420 | 11760 |
| 4 | 30 | 18 | 540 | 16200 |
| 5 | 32 | 20 | 640 | 20480 |
| 6 | 34 | 18 | 612 | 20808 |
| 7 | 36 | 11 | 396 | 14256 |
| 8 | 38 | 4 | 152 | 5776 |
| 9 | 40 | 2 | 80 | 3200 |
| 10 | 42 | 2 | 84 | 3528 |

```
In [7]: # 各カラムの総和
Data.sum()
```

Out[7]:

| | |
|--------|--------|
| x | 352 |
| f | 100 |
| xf | 3172 |
| x^2f | 102176 |
| dtype: | int64 |

```
In [8]: size=Data['f'].sum() # カラム Frequency (f) の総和の計算
sum_xf=Data['xf'].sum()
sum_xxf=Data['x^2f'].sum()
size, sum_xf, sum_xxf
```

Out[8]: (100, 3172, 102176)

```
In [9]: mean=sum_xf/size # 平均値の計算  
mean
```

```
Out[9]: 31.72
```

```
In [10]: var=sum_xxf/size-mean**2 # 分散公式による計算  
var
```

```
Out[10]: 15.601600000000076
```

```
In [11]: std=np.sqrt(var) # 分散の平方根が標準偏差  
std
```

```
Out[11]: 3.949886074306457
```

```
In [12]: # まとめ  
StatSummary=pd.DataFrame([  
    ['平均値', mean],  
    ['分散', np.round(var, 2)],  
    ['標準偏差', np.round(std, 2)],  
    ['データ数', size]  
])  
StatSummary=StatSummary.rename(columns={0:'統計量'})  
StatSummary=StatSummary.rename(columns={1:'値'})  
StatSummary
```

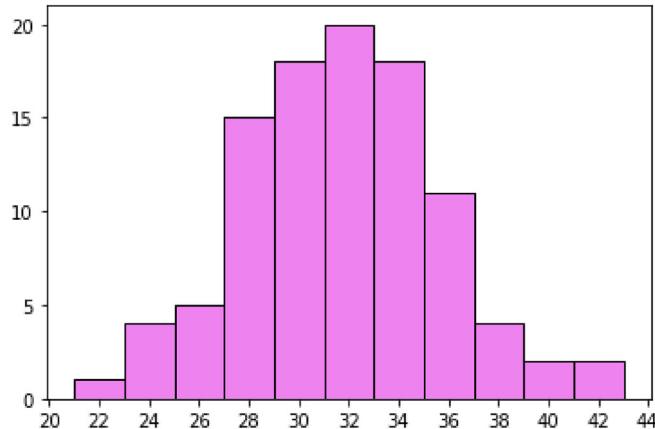
```
Out[12]:
```

| | 統計量 | 値 |
|---|------|--------|
| 0 | 平均値 | 31.72 |
| 1 | 分散 | 15.60 |
| 2 | 標準偏差 | 3.95 |
| 3 | データ数 | 100.00 |

ヒストグラム

In [13]:

```
# ヒストグラム
# plt.figure(figsize=(10, 5))
plt.bar(Data['x'], Data['f'],      # 棒グラフ（横軸と縦軸の変数を指定）
        width=2,                  # 棒の幅
        color='violet',
        ec='k')
plt.xticks(np.arange(20, 46, 2))
plt.yticks(np.arange(0, 25, 5))
plt.show() # 付帯データを表示せず、グラフのみ表示
```



In []: