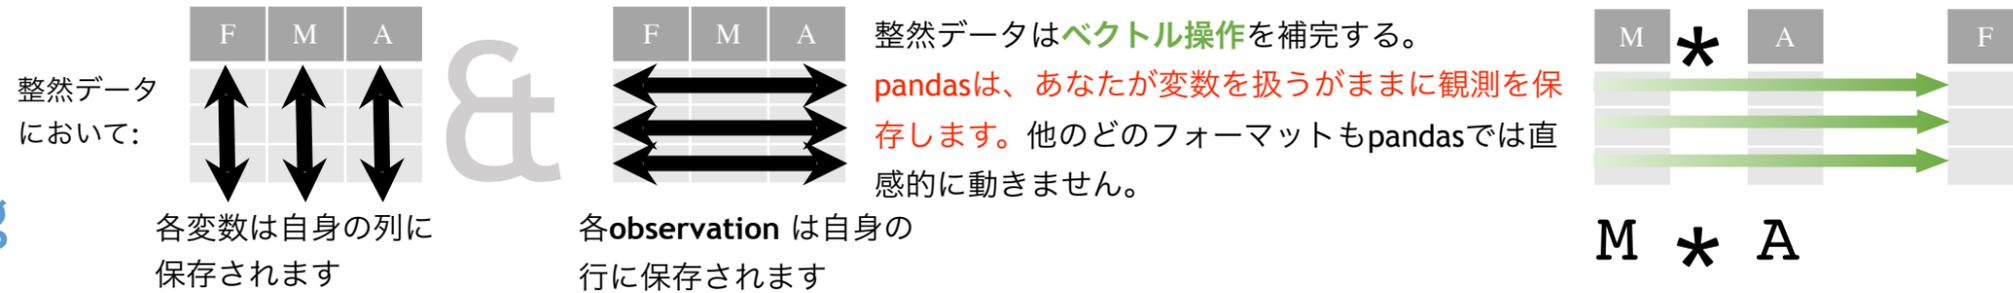


# Data Wrangling

## with pandas Cheat Sheet

<http://pandas.pydata.org>

### 整然データ (Tidy Data) - pandasにおける議論の基盤



### 文法 - DataFrameの作成

	a	b	c
1	4	7	10
2	5	8	11
3	6	9	12

```
df = pd.DataFrame(
    {"a": [4, 5, 6],
     "b": [7, 8, 9],
     "c": [10, 11, 12]},
    index = [1, 2, 3])
各column(列)の値をセットする
```

```
df = pd.DataFrame(
    [[4, 7, 10],
     [5, 8, 11],
     [6, 9, 12]],
    index=[1, 2, 3],
    columns=['a', 'b', 'c'])
各row(行)の値をセットする
```

n	v	a	b	c
d	1	4	7	10
	2	5	8	11
e	2	6	9	12

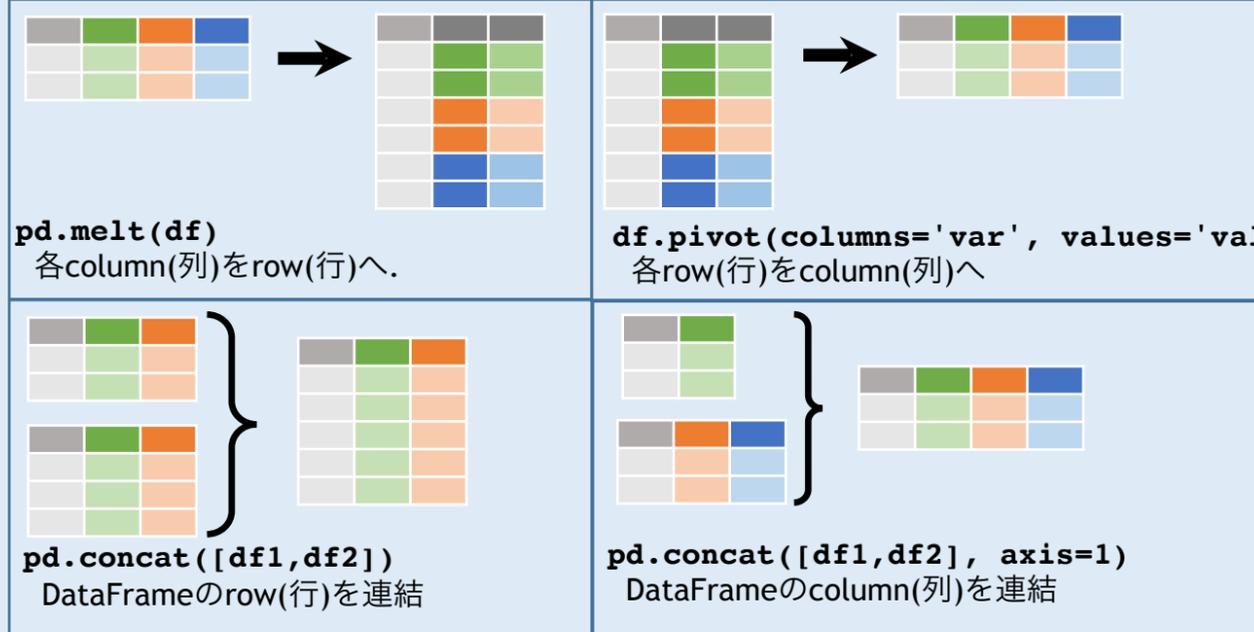
```
df = pd.DataFrame(
    {"a": [4, 5, 6],
     "b": [7, 8, 9],
     "c": [10, 11, 12]},
    index = pd.MultiIndex.from_tuples(
        [('d', 1), ('d', 2), ('e', 2)]),
    names=['n', 'v'])
MultiIndexでDataframeを作成する
```

### メソッドチェーン

pandasにおける多くのメソッドはDataframeを返します。そのため、メソッドの返り値にそのまま別のメソッドを適用するメソッドチェーンが便利に使えます。この手法はコードの可動性を大いにあげます。

```
df = (pd.melt(df)
      .rename(columns={'variable': 'var',
                       'value': 'val'})
      .query('val >= 200'))
```

### データの整形(Reshaping Data) - データセットのレイアウト変更



```
df.sort_values('mpg')
column(列)の値を使ってrow(行)をソート(昇順)

df.sort_values('mpg', ascending=False)
column(列)の値を使ってrow(行)をソート(降順)

df.rename(columns = {'y': 'year'})
DataFrameのcolumn(列)名を変更

df.sort_index()
DataFrameのindexを使ってソート

df.reset_index()
DataFrameのindexをリセット

df.drop(columns=['Length', 'Height'])
指定した長さのcolumn(列)を削除
```

### Observations(行)の一部を抜き出し



```
df[df.Length > 7]
与えられた条件に合った行を抜き出す

df.sample(frac=0.5)
行を[frac]ランダムで行を取得 ※fracは割合(1 = 100%)

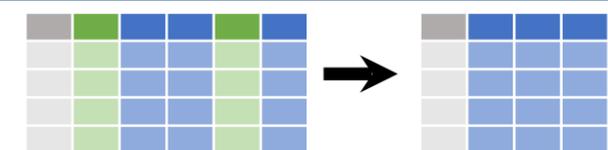
df.sample(n=10)
n行をランダムで取得

df.iloc[10:20]
指定位置の行を取得

df.nlargest(n, 'value')
'value'列のn行を降順で取得

df.nsmallest(n, 'value')
'value'列のn行を昇順で取得
```

### 変数(列)からの一部取得



```
df[['width', 'length', 'species']]
複数column(列)を列名を指定して取得

df['width'] or df.width
1つのcolumn(列)を列名を指定して取得

df.filter(regex='regex')
column(列)を正規表現でフィルタリング
```

#### regex (正規表現) の例

'\.'	ピリオド '.' を含む文字列にマッチ
'Length\$'	末尾に 'Length' のある文字列にマッチ
'^Sepal'	冒頭に 'Sepal' のある文字列にマッチ
'^x[1-5]\$'	'x' で始まり且つ末尾が 1-5 のいずれかである文字列にマッチ
'^(?!Species\$).*'	'Species' 以外の文字列とマッチ

```
df.loc[:, 'x2': 'x4']
x2からx4までの全てのcolumn(列)を取得

df.iloc[:, [1, 2, 5]]
1, 2, 5番目(indexが5番目)の列を取得(indexは0から数える)

df.loc[df['a'] > 10, ['a', 'c']]
与えられた条件に合ったrow(行)で且つ指定されたcolumn(列)を取得
```

Logic in Python (and pandas)		
<	より小さい	!= 等しくない
>	より大きい	df.column.isin(values) valuesが含まれているcolumnに場合trueを返す
=	と等しい	pd.isnull(obj) nullである
<	以下	pd.notnull(obj) nullでない
>	以上	&,  , ~, ^, df.any(), df.all() Logical and, or, not, xor, any, all

# データの要約

**df['w'].value\_counts()**  
変数の出現回数をカウント

**len(df)**  
# DataFrameの行数を出力

**df['w'].nunique()**  
ユニークな値をカウントして出力

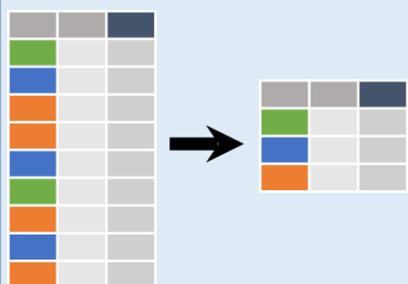
**df.describe()**  
Basic descriptive statistics for each column (or GroupBy)



pandasは様々な種類のpandasオブジェクト(DataFrame columns, Series, GroupBy, Expanding and Rolling(下記参照))を操作する **summary functions(要約関数)**を提供し、各グループに対して1つの値を返します。DataFrameに適用された場合、結果は各column(列)にSeries型で返されます。例:

- sum()** 各オブジェクトの値を合計
- min()** 各オブジェクトの最小値を取得
- count()** 各オブジェクトのNA/null以外の値をカウント
- max()** 各オブジェクトの最大値を取得
- median()** 各オブジェクトの中央値を取得
- mean()** 各オブジェクトの平均を取得
- quantile([0.25, 0.75])** 各オブジェクトの分位値を取得
- var()** 各オブジェクトの分散値を取得
- std()** 各オブジェクトの標準偏差を取得
- apply(function)** 各オブジェクトに適用

# データのグループ化



**df.groupby(by="col")**  
"col"列の値でグループ化した GroupByオブジェクトを返す

**df.groupby(level="ind")**  
インデックスレベル"ind"でグループ化したGroupByオブジェクトを返す

上述した要約関数(summary function)は全てgroupにも適用可能です。その他GroupByの関数:

**size()** 各グループの長さ

**agg(function)** 関数を使ってグループを集計

下記関数もgroupに対して適用できます。この場合、関数はグループ毎に適用され、返されるベクトルの長さは元のDataFrameと同じになります。

- shift(1)** 1行ずつ後ろにずらした値をコピー
- shift(-1)** 1行ずつ前にずらした値をコピー
- rank(method='dense')** ランク付け(同数はギャップなしで計算)
- cumsum()** 累積和
- rank(method='min')** ランク付け(同数は小さい値にする)
- cummax()** 累積最大値
- rank(pct=True)** [0~1]の値でランク付け
- cummin()** 累積最小値
- rank(method='first')** ランク付け。同数の場合indexが小さい方が上位
- cumprod()** 累積積

# window関数

**df.expanding()**  
要約関数を累積的に適用可能にした Expanding オブジェクトを返す

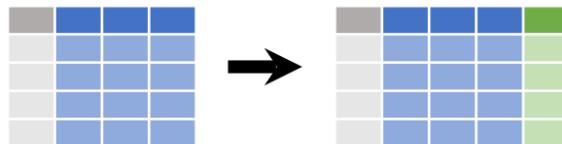
**df.rolling(n)**  
長さnのwindowに要約関数を適用可能にしたRollingオブジェクトを返す

# 欠損データを扱う

**df.dropna()**  
NA/nullを含むrow(行)を除外する

**df.fillna(value)**  
NA/nullをvalueに置換

# 新しいColumn(列)の作成



**df.assign(Area=lambda df: df.Length\*df.Height)**  
1つ以上の新たなcolumn(列)を計算して追加

**df['Volume'] = df.Length\*df.Height\*df.Depth**  
新たなcolumn(列)を1つ追加

**pd.qcut(df.col, n, labels=False)**  
column(列)の値をn分割



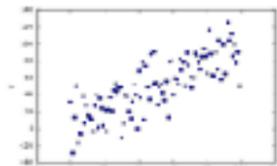
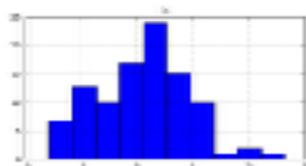
pandasはDataFrameの全てのcolumn(列)または選択された1列(Series型)を操作できる**vector functions(ベクトル関数)**を提供します。それらの関数は各列(column)に対してベクトル値を返します。また、各Seriesには1つのSeriesを返します。例:

- max(axis=1)** 要素ごとの最大値を取得
- min(axis=1)** 要素ごとの最大値を取得
- clip(lower=-10, upper=10)** 下限を-10,上限を10に設定してトリミング
- abs()** 絶対値を取得

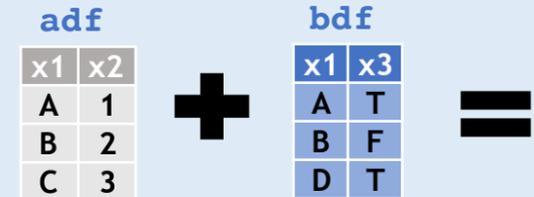
# プロット(描画)

**df.plot.hist()**  
各列のヒストグラムを描画

**df.plot.scatter(x='w', y='h')**  
散布図を描画



# データの結合



標準的な結合

**pd.merge(adf, bdf, how='left', on='x1')**  
bdfをadfのマッチする行へ結合

**pd.merge(adf, bdf, how='right', on='x1')**  
adfをbdfのマッチする行へ結合

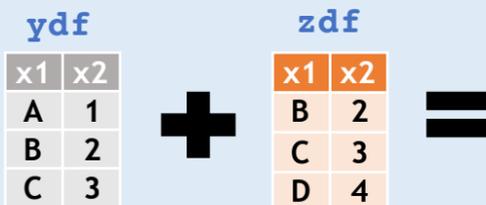
**pd.merge(adf, bdf, how='inner', on='x1')**  
adfとbdfを双方にある行のみ残して結合

**pd.merge(adf, bdf, how='outer', on='x1')**  
全ての値と行を残して結合

フィルタリング結合

**adf[adf.x1.isin(bdf.x1)]**  
adfの中でbdfにマッチする行

**adf[~adf.x1.isin(bdf.x1)]**  
adfの中でbdfにマッチしない行



集合ライクな結合

**pd.merge(ydf, zdf)**  
ydfとzdf両方にある行

**pd.merge(ydf, zdf, how='outer')**  
ydfとzdfの両方もしくは片方にある行

**pd.merge(ydf, zdf, how='outer', indicator=True).query('\_merge == "left\_only"').drop(columns=['\_merge'])**  
ydfにはあるがzdfにはない行