

レシピ43 DataFrameの行のマスキング（P113）

- mask メソッドは、whereメソッドと正反対の演算をする
- mask はデフォルトでは「True」を欠損値等で置き換える（whereはFalseを置き換える）
- このレシピでは、映画データセットで2010年より後の映画にマスキングをして、欠損値のある行をすべてフィルタリングする

(1) データセットを読み込み、映画の題名をインデックスにし、基準を作る

```
In [9]: movie = pd.read_csv('movie.csv', index_col='movie_title')
c1 = movie['title_year'] >= 2010
c2 = movie['title_year'].isnull()
criteria = c1 | c2
```

(2) mask メソッドを使い、2010年より後の映画の行の値を欠損値にする。title_yearの元の値が欠損の映画もマスキングされる

```
In [13]: # わかりづらいので、title_yearを先頭にもってくる
first_col = movie.pop('title_year')
movie.insert(0, 'title_year', first_col)
movie.head()
```

Out[13]:

	title_year	color	director_name	num_critic_for_reviews	duration	director_facebook_likes	actor_3_facebook_likes
movie_title							
Avatar	2009.0	Color	James Cameron	723.0	178.0	0.0	
Pirates of the Caribbean: At World's End	2007.0	Color	Gore Verbinski	302.0	169.0	563.0	
Spectre	2015.0	Color	Sam Mendes	602.0	148.0	0.0	
The Dark Knight Rises	2012.0	Color	Christopher Nolan	813.0	164.0	22000.0	
Star Wars: Episode VII - The Force Awakens	NaN	NaN	Doug Walker	NaN	NaN	131.0	

5 rows × 27 columns

```
In [22]: # cf.criteria (比較演算子は | (or)。2010年以降の映画、または年が空欄の映画を指す)
(movie['title_year'] >= 2010) | (movie['title_year'].isnull())
```

Out[22]:

movie_title		
Avatar	False	
Pirates of the Caribbean: At World's End	False	
Spectre	True	
The Dark Knight Rises	True	
Star Wars: Episode VII - The Force Awakens	True	
...		
Signed Sealed Delivered	True	

The FollowingTrue
A Plague So PleasantTrue
Shanghai CallingTrue
My Date with DrewFalse
Name: title_year, Length: 4916, dtype: bool

mask

- 条件に対し「True」になったものに処理（欠損値にする、等）を行う
- デフォルトでは、Trueデータを欠損値でマスクする（以下の画面では上でTrueになった行がNaNに変わった）

In [30]:

movie.mask(criteria).head()

Out[30]:

	title_year	color	director_name	num_critic_for_reviews	duration	director_facebook_likes	actor_3_faceb
movie_title							
Avatar	2009.0	Color	James Cameron	723.0	178.0	0.0	
Pirates of the Caribbean: At World's End	2007.0	Color	Gore Verbinski	302.0	169.0	563.0	
Spectre	NaN	NaN	NaN	NaN	NaN	NaN	
The Dark Knight Rises	NaN	NaN	NaN	NaN	NaN	NaN	
Star Wars: Episode VII - The Force Awakens	NaN	NaN	NaN	NaN	NaN	NaN	

5 rows × 27 columns

maskによってNaN行が多数できている

(3) それらの欠損行を削除すれば、取出したいものだけが残る

- すべての値がNaNである行を削除 `dropna(how='all')`

In [26]:

movie_mask = movie.mask(criteria).dropna(how='all')
movie_mask.head()

Out[26]:

	title_year	color	director_name	num_critic_for_reviews	duration	director_facebook_likes	actor_3_faceb
movie_title							
Avatar	2009.0	Color	James Cameron	723.0	178.0	0.0	
Pirates of the Caribbean: At World's End	2007.0	Color	Gore Verbinski	302.0	169.0	563.0	
Spider-Man 3	2007.0	Color	Sam Raimi	392.0	156.0	0.0	
Harry Potter and the Half-Blood Prince	2009.0	Color	David Yates	375.0	153.0	282.0	

	title_year	color	director_name	num_critic_for_reviews	duration	director_facebook_likes	actor_3_faceb
movie_title							
Superman Returns	2006.0	Color	Bryan Singer	434.0	169.0		0.0

5 rows × 27 columns



(4)

- (3) のやり方とは別にBooleanインデックスでも同じことをやってみる。
- `equals` で結果が同じであればよい -> なぜかFalse

```
In [39]: movie_boolean = movie[movie['title_year'] < 2010] # isNullの行は除外される?(5)の結果からは対象外になっている模様
movie_mask.equals(movie_boolean)
```

Out[39]: False

(5) Falseの理由は何？ 同じshapeかを確認してみる -> True

```
In [29]: movie_mask.shape == movie_boolean.shape
```

Out[29]: True

(6)

- maskメソッドが多くの欠損値を作った
- 欠損値はfloat型なので、NaNが含まれる整数カラム全体もfloat型になってしまっている
- **`equals` メソッドは、カラムの値が同じでもデータ型が違うとFalseを返す**
- データ型をチェックしてみる

```
In [32]: movie_mask.dtypes == movie_boolean.dtypes
```

Out[32]: title_year True
color True
director_name True
num_critic_for_reviews True
duration True
director_facebook_likes True
actor_3_facebook_likes True
actor_2_name True
actor_1_facebook_likes True
gross True
genres True
actor_1_name True
num_voted_users False
cast_total_facebook_likes False
actor_3_name True
facenumber_in_poster True
plot_keywords True
movie_imdb_link True
num_user_for_reviews True
language True
country True
content_rating True
budget True
actor_2_facebook_likes True
imdb_score True

aspect_ratio True
movie_facebook_likes False
dtype: bool

(7)

- 3つのカラムのデータ型が違っていた
- 以下よくわからない
- テストモジュール（ユーザーは開発者が主）に `assert_frame_equal` 関数があり、SeriesとDataFrameの等価性をデータ型は無視してチェックする
- 等価ならば、**None**を返す（要は見た目反応がない）、等しくない場合はエラーを返す

In [35]:

```
from pandas.testing import assert_frame_equal
assert_frame_equal(movie_boolean, movie_mask, check_dtype=False)
```

(補足)

- マスキングを使った場合と、Booleanインデックス法ではBooleanの方が1桁速い

In [40]:

```
%timeit movie.mask(criteria).dropna(how='all')
```

21.8 ms ± 2.66 ms per loop (mean ± std. dev. of 7 runs, 10 loops each)

In [42]:

```
%timeit movie[movie['title_year'] < 2010]
```

1.58 ms ± 76.6 µs per loop (mean ± std. dev. of 7 runs, 1000 loops each)

以上

In []: