

線形判別分析

青木繁伸

2020年3月17日

1 目的

線形判別分析を行う。

2 使用法

```
import sys
sys.path.append("statlib")
from multi import disc
disc(data, make_dummy=False, verbose=True)
```

2.1 引数

<code>data</code>	分類に必要な説明変数と、群を表す変数が最終列（最も右側の列）になるように用意されたデータフレーム
<code>make_dummy</code>	ダミー変数への変換が必要な場合には <code>True</code> を指定する。デフォルトは <code>False</code>
<code>verbose</code>	必要最小限のプリント出力をする

2.2 戻り値の名前

<code>"ncase"</code>	サンプルサイズ
<code>"p"</code>	説明変数の個数
<code>"vname"</code>	説明変数の名前
<code>"gVname"</code>	群変数の名前
<code>"ng"</code>	群の数
<code>"gName"</code>	群の名前
<code>"num"</code>	各群のサンプルサイズ
<code>"t"</code>	全体の変動・共変動行列
<code>"w"</code>	群内変動・共変動
<code>"names2"</code>	2群判別の対象とする群の名前
<code>"cFunction"</code>	分類関数の係数
<code>"dFunction"</code>	判別関数の係数

"partialF"	分類関数の係数の検定統計量
"partialP"	分類関数の係数の検定統計量の p 値
"df1"	第 1 自由度
"df2"	第 2 自由度
"wilksLambda"	ウィルクスの Λ
"wilksLambdaF"	ウィルクスの Λ の検定統計量
"wilksLambdaP"	ウィルクスの Λ の検定統計量の p 値
"wilksLambdaDf1"	第 1 自由度
"wilksLambdaDf2"	第 2 自由度
"distance"	各群の重心からの距離 (χ^2 分布にしたがう)
"df"	自由度 (説明変数の個数に等しい)
"Pvalue"	各群の所属する確率 p
"prediction"	どの群に所属するか判別
"correct"	正しい判別がされたデータ数
"correctTable"	判別表
"correctRate"	正判別率
"discriminantValue"	判別値 (2 群の場合)

3 使用例

3.1 3 群判別の場合

```
import pandas as pd

data = pd.read_csv("data/iris.csv")

import sys
sys.path.append("statlib")
from multi import disc

a = disc(data)
```

coefficients of discriminant functions

	setosa:versicolor	setosa:virginica	versicolor:virginica	\
sl	-7.845958	-11.098318	-3.252360	
sw	-16.515361	-19.902591	-3.387230	
pl	21.642090	29.197184	7.555094	
pw	23.832640	38.477524	14.644884	
constant	13.455863	-18.059850	-31.515713	

	F	p value
sl	4.721152	1.032884e-02

```

sw      21.935928  4.831201e-09
pl      35.590175  2.756205e-13
pw      24.904333  5.143154e-10
constant      NaN      NaN

```

```

coefficients of classification functions
      setosa  versicolor  virginica
sl      -47.088333  -31.396418  -24.891698
sw      -47.175741  -14.145020  -7.370559
pl       32.861278  -10.422902  -25.533090
pw       34.796822  -12.868458  -42.158226
constant 170.419715 143.507990 206.539415

```

```

result of discrimination
      setosa  versicolor  virginica
setosa      50          0          0
versicolor   0         48          2
virginica    0          1         49

```

correct rate = 98.0 %

3.2 2 群判別の場合

```

data = data.iloc[0:100, :]

a = disc(data)

```

```

coefficients of discriminant functions
      setosa:versicolor      F  p value
sl      -3.052770  0.715527  0.399741
sw      -18.022959 25.700452  0.000002
pl       21.766195 24.597600  0.000003
pw       30.844165 10.705452  0.001490
constant -13.961740      NaN      NaN

```

```

coefficients of classification functions
      setosa  versicolor
sl      -50.078491  -43.972951
sw      -36.233259  -0.187341
pl       7.889082  -35.643307
pw       70.340670   8.652340

```

```
constant 173.031449 200.954928
```

```
result of discrimination
```

```
          setosa  versicolor
setosa         50           0
versicolor     0           50
```

```
correct rate = 100.0 %
```

3.3 ダミー変数への変換が必要な場合

ファイル "data/disc-2.csv" はデータの値は数値ではなく文字列で入力されている。このような場合、`disc()` は `make_dummy=True` によりダミー変数への変換を行う。

なお、文字列とはいえ、単に数字を文字列 ("1", "2" など) にしただけではダミー変数に変換してくれないので注意が必要である。

```
dat = pd.read_csv("data/disc-2.csv")
print(dat.iloc[:10, :])
```

```
      X1  X2  X3  X4  X5  X6  X7  X8  X9  X10  X11  X12  \
0  two  zero  one  one  zero  one  zero  one  one  two  two  zero
1  zero  zero  zero  one  one  zero  zero  zero  zero  two  two  zero
2  one  one  zero  zero  two  zero  zero  zero  zero  zero  one  zero
3  one  zero  one  two  two  one  one  zero  zero  two  two  one
4  zero  zero  zero  one  two  zero  zero  one  two  one  zero  zero
5  two  one  zero  zero  zero  one  two  zero  two  zero  zero  one
6  two  zero  one  two  zero  one  two  one  one  zero  zero  zero
7  two  one  zero  one  one  zero  two  zero  zero  zero  one  zero
8  zero  one  zero  one  zero  zero  one  zero  two  two  zero  zero
9  one  one  one  zero  zero  one  one  zero  two  one  zero  one

      Y
0  one
1  zero
2  zero
3  one
4  zero
5  one
6  one
7  zero
8  zero
9  one
```

```
a = disc(dat, make_dummy=True)
```

coefficients of discriminant functions

	one:zero	F	p value
X1_two	-2.359861	5.310797	0.023787
X1_zero	0.648009	0.441030	0.508535
X2_zero	-1.565254	3.675798	0.058778
X3_zero	2.379234	6.912939	0.010259
X4_two	-1.343930	2.051702	0.155932
X4_zero	-0.167736	0.024722	0.875457
X5_two	0.471475	0.256853	0.613684
X5_zero	-2.699780	7.675514	0.006957
X6_zero	1.315415	2.434396	0.122647
X7_two	-1.555243	2.827480	0.096564
X7_zero	0.396980	0.172979	0.678591
X8_zero	-0.981076	1.551497	0.216550
X9_two	-0.425616	0.189369	0.664614
X9_zero	0.381231	0.150127	0.699443
X10_two	0.371998	0.142256	0.707047
X10_zero	1.575304	2.350639	0.129177
X11_two	0.662651	0.440749	0.508670
X11_zero	0.418863	0.171787	0.679637
X12_zero	1.871882	6.670181	0.011626
constant	-0.253238	NaN	NaN

coefficients of classification functions

	one	zero
X1_two	-10.656689	-5.936967
X1_zero	-5.954703	-7.250722
X2_zero	-5.886602	-2.756095
X3_zero	-0.638733	-5.397202
X4_two	-8.075466	-5.387606
X4_zero	-9.714089	-9.378617
X5_two	-4.582641	-5.525592
X5_zero	-8.809773	-3.410212
X6_zero	-7.010496	-9.641326
X7_two	-10.044999	-6.934513
X7_zero	-3.790067	-4.584026
X8_zero	-2.746170	-0.784018
X9_two	-9.709664	-8.858432
X9_zero	-7.204916	-7.967378

X10_two -9.522287 -10.266284
X10_zero -9.277515 -12.428124
X11_two -5.761038 -7.086341
X11_zero -7.576423 -8.414149
X12_zero -2.523230 -6.266994
constant 24.427116 24.933593

result of discrimination

	one	zero
one	40	10
zero	5	45

correct rate = 85.0 %