

正準判別分析

青木繁伸

2020年3月17日

1 目的

正準判別分析を行う。

2 使用法

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

結果のプロット

```
import sys
sys.path.append("statlib")
from multi import candis
candis_plot(obj, type="score", ax1=1, ax2=2, color="black", color2="blue", alpha=0.5)
```

2.1 引数

data	説明変数と群変数のみからなるデータフレーム（最後列が群変数）
make_dummy	ダミー変数への変換が必要な場合には True を指定する。デフォルトは False
verbose	必要最小限のプリント出力をする
obj	candis() の返すオブジェクト
type	デフォルトは "score" で、正準判別得点をプロットする "stdcoef" で正準判別係数をプロットする。
ax1	横軸にとる解の番号
ax2	縦軸にとる解の番号
color	マークの色（デフォルトは黒）
color2	マークに添えるテキストの色（デフォルトは青）
alpha	アルファチャネル（デフォルトは 0.5）

2.2 戻り値の名前

"means"	全体と各群の変数ごとの平均値
"univariate"	单变量統計
"betweenss"	群間平方和・積和行列
"withinss"	群内平方和・積和行列
"pooledcov"	プールされた分散・共分散
"pooledr"	プールされた相関係数
"eigenvalues"	固有値
"canonicalcorr"	正準相関係数
"WilksLambda"	Wilks の λ
"stdcoef"	標準化判別係数
"structure"	構造行列
"coef"	判別係数
"centroids"	各群の重心
"score"	正準判別得点
"pBayes"	各群に属するベイズ確率 p
"p"	各群に属する確率
"classification"	判別結果
"result"	判別結果表
"correctRate"	正判別率
"vnames"	説明変数の名前のベクトル
"ngroup"	群の数
"nax"	解の次元数（個数）

3 使用例

3.1 2群判別

```
import pandas as pd

data = pd.read_csv("data/iris.csv")
data = data.iloc[50:, :]

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

a = candis(data, verbose=True)

Wilks' Lambda      chi.sq.   d.f.      p value
```

```
Axis 1      0.21611 147.068771      4  8.645274e-31
```

Discriminant coefficients

```
          Axis 1  
sl      -0.943118  
sw      -1.479429  
pl      1.848451  
pw      3.284730  
constant -4.418986
```

Standardized discriminant coefficients

```
          Axis 1  
sl -0.546185  
sw -0.470720  
pl 0.947414  
pw 0.786070
```

Structure matrix

```
          Axis 1  
sl 0.298567  
sw 0.170031  
pl 0.668495  
pw 0.775718
```


Results of classification

	versicolor	virginica
versicolor	48	2
virginica	1	49


Correct rate = 97.0

```
from multi import candis_plot  
  
candis_plot(a, type="stdcoef")
```

Standardized coefficient



```
from multi import candis_plot  
candis_plot(a, type="score")
```



3.2 3群以上の判別

```

import pandas as pd

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

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

a = candis(data, verbose=True)

```

Wilks' Lambda

	Wilks' Lambda	chi.sq.	d.f.	p value
Axis 1	0.023439	546.115296	8	8.870785e-113
Axis 2	0.777973	36.529664	3	5.786050e-08

Discriminant coefficients

	Axis 1	Axis 2
sl	0.829378	0.024102
sw	1.534473	2.164521
pl	-2.201212	-0.931921

```
pw      -2.810460  2.839188  
constant 2.105106 -6.661473
```

Standardized discriminant coefficients

	Axis 1	Axis 2
sl	0.426955	0.012408
sw	0.521242	0.735261
pl	-0.947257	-0.401038
pw	-0.575161	0.581040

Structure matrix

	Axis 1	Axis 2
sl	-0.222596	0.310812
sw	0.119012	0.863681
pl	-0.706065	0.167701
pw	-0.633178	0.737242

Results of classification

	setosa	versicolor	virginica
setosa	50	0	0
versicolor	0	48	2
virginica	0	1	49


Correct rate = 98.0

```
print(a["means"])
```

	grand mean	setosa	versicolor	virginica
sl	5.843333	5.006	5.936	6.588
sw	3.057333	3.428	2.770	2.974
pl	3.758000	1.462	4.260	5.552
pw	1.199333	0.246	1.326	2.026

3.3 標準化判別係數

```
from multi import candis_plot  
  
candis_plot(a, type="stdcoef")
```



3.4 正準判別得点

```
from multi import candis_plot  
  
candis_plot(a, type="score")
```

