polyserial 相関係数

青木繁伸

2019 年 4 月 27 日

1　目的

2 変数のうちの片方が連続変数，もう一方が順序カテゴリー変数の場合の相関係数を求める。順序カテゴリー変数が潜在的には正規分布に従うと仮定できる場合について polyserial 相関係数を求める。

R の **polycor** パッケージにある `polyserial()` を **Python** に翻訳・修正したものである。

R の **polycor** の情報

```
Package:                            polycor
Version:                            0.7-9
Date:                               2016-08-26
Title:                              Polychoric and Polyserial Correlations
Authors@R:                          person("John", "Fox", role = c("aut", "cre"), email =
                                    "jfox@mcmaster.ca")
Depends:                            R (>= 3.3.0)
Imports:                            stats, mvtnorm, Matrix
ByteCompile:                        yes
LazyLoad:                           yes
Description:                        Computes polychoric and polyserial correlations by quick
                                    "two-step" methods or ML, optionally with standard errors;
                                    tetrachoric and biserial correlations are special cases.
License:                            GPL (>= 2)
URL:                                https://r-forge.r-project.org/projects/polycor/,
                                    http://CRAN.R-project.org/package=polycor
Author:                             John Fox [aut, cre]
Maintainer:                         John Fox <jfox@mcmaster.ca>
Repository:                         CRAN
Repository/R-Forge/Project:         polycor
Repository/R-Forge/Revision:        13
Repository/R-Forge/DateTimeStamp:   2016-08-26 18:25:37
Date/Publication:                   2016-08-27 00:22:11
NeedsCompilation:                   no
Packaged:                           2016-08-26 18:45:33 UTC; rforge
Built:                              R 3.5.0; ; 2018-04-23 16:48:15 UTC; unix
```

参考文献

Drasgow, F. (1986) Polychoric and polyserial correlations. Pp. 68 − 74 in S. Kotz and N. Johnson, eds., *The Encyclopedia of Statistics, Volume 7*. Wiley.

2 使用法

```
import sys
sys.path.append("statlib")
from multi import polyserial
polyserial(x, y, two_step=False, bins=4, verbose=True)
```

2.1 引数

x	連続変数ベクトル
y	順序カテゴリー変数ベクトル
two_step	相関係数だけを推定するときは False，順序カテゴリー変数のカットポイントも含めて推定するときは True。
bins	連続変数の分割数
verbose	必要最小限のプリント出力をする

2.2 戻り値の名前

"method"	分析手法
"rho"	相関係数の推定値
"SE"	相関係数の標準誤差
"chisq"	元の変数が二変量正規分布に従うかどうかの検定統計量（χ^2 分布にしたがう）
"df"	自由度
"pvalue"	p 値
"colCuts"	順序カテゴリー変数のカットポイント

3 使用例

```
x = [0.7492, -0.22295, 0.11472, 0.53715, -0.51242, 0.35807, 0.49264,
-0.51353, -0.94197, 1.15984, 1.12984, -1.02436, -1.07608, -0.30467,
0.54926, 1.35279, 2.40187, 0.37274, -0.74321, 1.71418, 0.47398,
-0.78159, 1.2034, -1.21809, 0.22509, -0.01787, 0.14278, -0.57617,
0.88083, 1.46454, -0.20298, 0.94596, -1.04114, 1.2703, 0.1639,
-0.15033, -0.41042, 1.59887, 0.58806, 0.72434, 0.89338, 0.34713,
1.42137, 0.56944, 0.73173, -1.15237, 1.72124, -0.76932, 0.07062,
-0.75912, -0.08296, 0.06515, -0.00246, 0.10176, -0.34965, -1.53095,
1.55971, -0.20873, 0.11238, 2.08786, 1.83424, 0.70741, -0.70681,
-1.48295, -2.36075, 1.81494, 0.20038, 2.29407, -0.80354, 0.0154,
-1.43625, -0.96287, 0.15512, -1.27466, 0.90138, -1.42222, -0.02011,
-0.16987, 1.55233, -0.10292, -0.39256, -0.35841, -1.03065, 0.29056,
1.69807, 0.54179, 0.24826, -1.52018, 2.50281, -0.2621, -0.89337,
-0.09901, 0.80746, 1.50104, -0.29506, 0.39425, 0.83788, 1.47223,
0.70706, -0.42811]
```

```
y = [3, 2, 1, 2, 2, 4, 3, 3, 2, 3, 4, 1, 3, 2, 2, 4, 4, 3, 1, 2,
1, 3, 4, 2, 1, 4, 2, 2, 3, 1, 1, 4, 1, 4, 1, 2, 4, 3, 2, 3, 3,
4, 4, 2, 3, 1, 2, 2, 4, 2, 1, 1, 2, 3, 2, 1, 4, 2, 3, 2, 4, 4,
1, 3, 1, 3, 1, 2, 2, 2, 1, 1, 3, 2, 2, 2, 2, 2, 2, 2, 2, 2,
1, 2, 3, 3, 2, 3, 1, 2, 3, 2, 3, 2, 2, 2, 3, 2, 2]
```

```
import matplotlib.pyplot as plt
plt.scatter(y, x, alpha=0.3)
```

```
<matplotlib.collections.PathCollection at 0x11ae56f98>
```

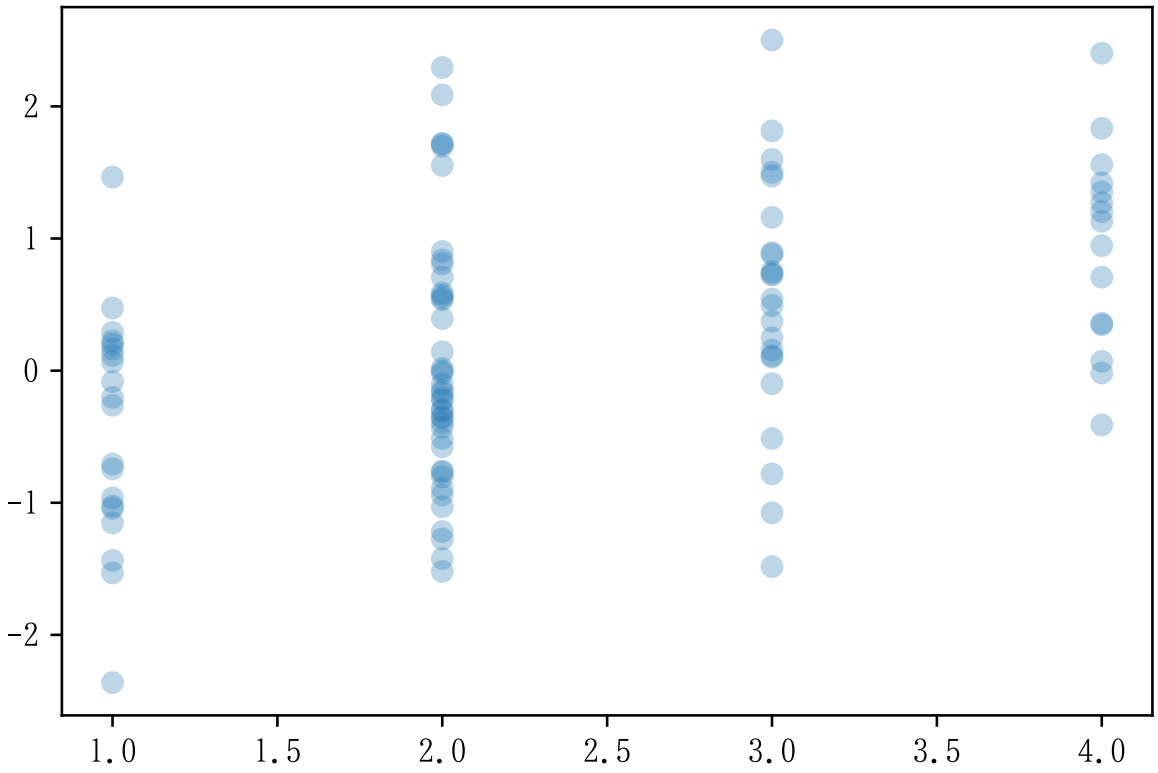


```
import sys
sys.path.append("statlib")
from multi import polyserial

a = polyserial(x, y, two_step = True)
```

```
Polyserial Correlation:  two step ML estimator = 0.467,  Std.Err. = 0.079169
Test of bivariate normality: chisq = 5.4889,  df = 11,  p value= 0.9052
```

```
a = polyserial(x, y)
```

```
Polyserial Correlation:  ML estimator = 0.46619,  Std.Err. = 0.080643
Test of bivariate normality: chisq = 5.4841,  df = 11,  p value= 0.90548
   Threshold  Std.Err.
0  -0.845491  0.133969
1   0.305882  0.118274
2   1.042709  0.144710
```

```
a = polyserial(x, y, bins=6)
```

```
Polyserial Correlation:  ML estimator = 0.46619,  Std.Err. = 0.080643
Test of bivariate normality: chisq = 12.914,  df = 19,  p value= 0.84293
   Threshold  Std.Err.
0  -0.845491  0.133969
1   0.305882  0.118274
2   1.042709  0.144710
```