

比

連続的な量が分子にくる 「割算」 の場合

2013.3


粕谷英一 (九大・理・生物)

『実証研究者は比を愛するー統計学者は比をひどく嫌う』

『比の誤用に対する警告は無視されることが多い』

Jasienski & Bazzaz(1999,Oikos)

連続量が分子



モデルケース

正規分布

正規分布する変数

正規分布する変数

正規分布する変数

正規分布する変数

比

比を新たな変数
として

(母平均 / 母平均)
が知りたい

バイオアッセイ

例. ある薬は別の薬の何倍効くか

正規分布する変数

正規分布する変数

比

(母平均 / 母平均)
が知りたい

比を新たな変数
として

差でなく比

Fiellerの信頼区間

片方が無限大になったり

離れた区間が信頼区間になったり

中間だけ信頼区間から外れたり

(Rのパッケージmratios)

正規分布する変数

正規分布する変数

比

比を新たな変数
として

(母平均 / 母平均)
が知りたい

バイオアッセイ

例. ある薬は別の薬の何倍効くか

モデルケース

連続量 正規分布

独立
(相関なし)

標準正規分布する変数

標準正規分布する変数

比

標準コーシー分布

コーシー分布

Cauchy分布

コーシー

確率密度関数

$$\frac{\gamma}{\pi \{(y-y_0)^2 + \gamma^2\}}$$

y_0 位置

γ 横の広がり


Lorenz分布
Breit-Wigner分布

標準コーシー分布


確率密度関数

$$\frac{1}{\pi \{y^2 + 1\}}$$

標準コーシー分布




拡大図



比較：標準正規分布

$$\frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}}$$

確率密度関数



コーシー分布

モーメント

モーメント 変数のk乗の期待値→k次のモーメント

期待値 (平均) 1次のモーメント


分散 2次のモーメントより

歪度 (非対称性) 3次のモーメントより


尖度 (裾の重さ) 4次のモーメントより

| | |
|------------|--------------------|
| μ | λ |
| σ^2 | λ |
| 0 | $1/\sqrt{\lambda}$ |
| 3 | $1/\lambda + 3$ |

標準コーシー分布



拡大図



正規分布

ポアソン分布



コーシー分布

モーメント


存在しない

期待値 (平均) 存在しない


分散 (正確には原点まわりの2次モーメント) 無限大

...

標準コーシー分布



拡大図




2つの標準正規分布する変数の比

(平均0で分散1の正規分布)

乱数

ratio of 2 standard normal variables



ヒストグラム

100000個

-10


+10

拡大その1

ヒストグラム

拡大その2


ratio of 2 standard normal variables



-100

+100

ratio of 2 standard normal variables




-500

+500


右半分の拡大

ヒストグラム

ratio of 2 standard normal variables




ratio of 2 standard normal variables




右半分のさらに拡大

ヒストグラム

ratio of 2 standard normal variables



ratio of 2 standard normal variables



2つの標準正規分布する変数の比

標準コーシー分布


分布のまん中から遠く離れた値が出やすい

分布の裾が重い

箱ひげ図


n=100

n=100



n=1000


n=1000



箱ひげ図


n=10000

n=10000




n=100000

n=100000




箱ひげ図

n=1000000 n=1000000



n=10000000 n=10000000




分散


2つの標準正規分布の比

拡大図

分散



分散




データの個数

データの個数


約40万倍

分散

2つの標準正規分布の比



標準正規分布



2つの標準正規分布する変数の比

標準コーシー分布

データの個数が大きくなると、
分散が大きくなる

サンプルサイズ n のサンプル平均の分布

普通は n が大きくなれば、母平均のまわりにより集まる
推定精度が改善

コーシー分布


サンプルサイズ n のサンプル平均の分布

もとのコーシー分布

推定値としての良さは、

サンプルサイズを増やしても改善しない

サンプルの平均値のばらつき（分散）



サイズnのサンプル1000個の間の分散

各サンプルサイズ2セット

正規分布する変数の比——一般の場合

正規分布変数
(平均 θ_1 分散 σ_1^2) / 正規分布変数
(平均 θ_2 分散 σ_2^2)

相関 ρ


5パラメーター
Geary(1930), Fieller(1932)

確率密度関数


Hinkley(1969) Biometrika,56:635-639参照

標準正規分布と標準正規分布の比では1山型だが、



2山型になることもある



1山型の例



2山型の例



1山型と2山型の例

Marsaglia(2000)より

例

平均2、分散1の正規分布する変数


平均5、分散4の正規分布する変数


独立 (相関なし)

n=100000での例


箱ひげ図

'箱'部分は横棒に見える





分散
拡大



約80万倍

例

X 平均 3 で分散 1 の正規分布

Z 平均 3 で分散 1 の正規分布

正規分布する変数 X


正規分布する変数 X + 正規分布する変数 Z

独立 (相関なし)

たとえば


全体は 2 つの構成部分からなる — 全体のうちその片方の構成部分の割合をイメージしてみた

箱ひげ図




n=10000

箱ひげ図



n=10000000

分散



サンプルサイズ

全体は2つの構成部分からなる
全体のうちその片方の構成部分の割合
をイメージしてみた

二項分布する変数なら
 $n=1$ 千万のとき、
標準偏差は約0.00016

回帰

目的変数が正規分布の比

説明変数 x 0~20の一樣乱数

目的変数

y


比

平均 $2x+3.5$ 、分散1の正規分布


平均1、分散1の正規分布

乱数で生成したデータの例

n=100




n=100




乱数で生成したデータの例

n=1000
n=1000




n=1000
n=1000




乱数で生成したデータの例

n=100000 n=100000



n=100000 n=100000



x



乱数で生成したデータの例 $n=1000$

y 平均 $2x+3.5$ 、分散1の正規分布
平均1、分散1の正規分布


y 平均 $2x+3.5$ 、分散1の正規分布

$n=1000$

normal $n=1000$



傾き β




β の推定値の平均 0.674

β の推定値の標準偏差 77.76

β は2.0付近に分布してもよさそうだが...

n=10000のサンプル10000個


y 平均 $2x+3.5$ 、分散1の正規分布
平均1、分散1の正規分布



β の推定値の平均 0.674

β の推定値の標準偏差 77.76

y 平均 $2x+3.5$ 、分散1の正規分布



β の推定値の平均 1.9999994

β の推定値の標準偏差 0.001731

β は2.0付近に分布してもよさそうだが...

n=10000のサンプル10000個

正規分布

→ 割り算 →

正規分布の比

よく使われる

よく知られている

伝統

老舗

魔物

”maverick”

正規分布する変数の比

単純な分布の「割り算」の結果

他とは質的にちがった分布

「ばらつきかた」が違う

データの量が増えることが'善'でない

グラフでさほど変に見えないこともある

サンプルサイズがかなり大きくないと

目立たないことがある

他の分布のつもりで分析→相当な過大評価

サンプルの平均値のような当然に見える推定量→良くない

回避

正規分布する変数の比

注意

正規分布っぽい量の比

計算

計算して分布をチェックしよう

nは変えて、大きいところまで

余談

正規分布する変数の比

1つの正規分布 / (2つの正規分布の和) なども含む

説明変数が複数の場合

リンクがidentity以外の場合

母平均とともに母分散が変化するとき

他の分布

ガンマ分布する変数

対数正規分布する変数

切断正規分布する変数