

# 確率・統計の初歩 (5)

別所俊一郎

2006年4月28日

## いくつかの訂正

- 「 $t$  統計量は使わない」わけではありません。「 $t$  分布を使わない」が正しい表現でした。
- $p$  値は第 1 種の過誤に対応している概念ですが、第 2 種の過誤に対応する概念として検定の検出力 power というものがあります。

判定	$H_0$ が真	$H_1$ が真
$H_0$ を棄却	第 1 種の過誤	:-)
$H_0$ を受容	:-)	第 2 種の過誤

## 信頼区間 confidence interval

- 標本の抽出は確率的なので，母平均の正確な値を知ることはできない
- ある確率（信頼水準 confidence level）で真の値が含まれるような集合（信頼集合 confidence set）を見つけることはできる．  
1変数のケースで，信頼集合が上限と下限を持つ実数の集合であるときには信頼区間 confidence interval ともいう
- 信頼集合を求めるには以下の手続きを繰り返せばよい
  1. 候補となる実数  $\mu_{Y,0}$  を取り上げ， $H_0 : \mu_Y = \mu_{Y,0}$  と  $H_1 : \mu_Y \neq \mu_{Y,0}$  を設定
  2.  $H_0$  に対応する p 値を求め， $(1 - \text{信頼水準})$  よりも大きければ，この実数  $\mu_{Y,0}$  を書き留めておく
  3. また別の実数を候補として取り上げる

## 信頼区間の設定方法

- 候補となる実数をひとつひとつ取り上げていく方法では、真の値が信頼集合に含まれる確率は信頼水準に等しい
- ただし、この方法は候補を全て検討するという点であまりに非現実的
- 実際には、「95%両側検定では標本平均より  $1.96 \times SE(\bar{Y})$  以上遠いと信頼集合から外される」という性質を用いて、

$$\bar{Y} - 1.96 \times SE(\bar{Y}) \leq Y \leq \bar{Y} + 1.96 \times SE(\bar{Y})$$

を 95%信頼区間とする。

## 異なる母集団の平均の検定 (1)

2つの異なる母集団の分布の平均の差の検定を考える．2つのグループをそれぞれ添え字  $m, w$  で表す

- 2つの母平均の差が  $d_0$  であるという帰無仮説を立てる．母平均が等しいという仮説なら  $d_0 = 0$

$$H_0 : \mu_m - \mu_w = d_0 \quad \text{v.s.} \quad H_1 : \mu_m - \mu_w \neq d_0$$

- 母平均の差  $\mu_m - \mu_w$  の推定量として  $\bar{Y}_m - \bar{Y}_w$  を考える．これを用いて検定を行うにはこの分布を知る必要がある
- いま，中心極限定理を用いると，

$$\bar{Y}_m \xrightarrow{d} N\left(\mu_m, \frac{\sigma_m^2}{n_m}\right) \quad \bar{Y}_w \xrightarrow{d} N\left(\mu_w, \frac{\sigma_w^2}{n_w}\right)$$

## 異なる母集団の平均の検定 (2)

- $\bar{Y}_m$  と  $\bar{Y}_w$  は異なる母集団からの標本から計算された標本平均であるから、互いに独立した確率変数と考えることができ、正規分布の性質を用いると、

$$\bar{Y}_m - \bar{Y}_w \xrightarrow{d} N\left(\mu_m - \mu_w, \frac{\sigma_m^2}{n_m} + \frac{\sigma_w^2}{n_w}\right)$$

- 通常は  $\sigma_m^2$  と  $\sigma_w^2$  は未知だから、一致推定量としての標本分散  $s_m^2$  ,  $s_w^2$  を用いると、標準誤差は

$$SE(\bar{Y}_m - \bar{Y}_w) = \sqrt{\frac{s_m^2}{n_m} + \frac{s_w^2}{n_w}}$$

であるから、標準化して検定統計量を求めると、 $H_0$  のもとで

$$t = \frac{(\bar{Y}_m - \bar{Y}_w) - d_0}{SE(\bar{Y}_m - \bar{Y}_w)} \xrightarrow{d} N(0, 1), \quad \text{p-value} = 2\Phi(-|t|)$$

## 異なる母集団の平均の差の信頼区間

- $d = \mu_m - \mu_w$  の信頼区間を形成する
- ほぼ先ほどと同様の手続きによって, 95%信頼区間は

$$\{(\bar{Y}_m - \bar{Y}_w) \pm 1.96 \times \text{SE}(\bar{Y}_m - \bar{Y}_w)\}$$

## 2変数の関係の捉え方

散布図 平面上の点  $(X_i, Y_i)$  で各観測値を代表させるグラフ

標本共分散 標本分散と同様に  $n - 1$  で割ると, 一致推定量となる.

$$s_{XY} \equiv \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \xrightarrow{p} \sigma_{XY}$$

標本相関  $n$  個の観測値の線形のつながりの強さを表す

$$r_{XY} \equiv \frac{s_{XY}}{s_X s_Y} \xrightarrow{p} \text{corr}(X, Y)$$

- $|r_{XY}| \leq 1$  が成り立つ
- $|r_{XY}| = 1$  であれば, 散布図上の点は直線上に並ぶ. 右上がりなら  $r_{XY} = 1$ , 右下がりなら  $r_{XY} = -1$ . 直線上に近いほど絶対値が 1 に近づく
- 2変数に非線形な関係があるとき, 相関係数がゼロに近くなるケースがある (Fig. 3.3)