

確率統計基礎講義 A

若木宏文

wakaki@hiroshima-u.ac.jp

<http://home.hiroshima-u.ac.jp/wakaki/lecture/index.shtml>

2019.6.5

目次

4.2 F -分布

μ の信頼領域

F -分布の定義

F -分布の特性

4.2. F -分布

μ の信頼領域 (続き)

Σ が未知の場合： Σ を, その推定量

$S = (n - 1)^{-1} \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})'$ で置き換えた領域を考える.

$$T^2 = n(\bar{\mathbf{X}} - \boldsymbol{\mu})' S^{-1} (\bar{\mathbf{X}} - \boldsymbol{\mu})$$

は n を大きくすると, χ_p^2 に分布収束するので, n が大きければ,

$$\{\boldsymbol{\mu} \mid n(\bar{\mathbf{X}} - \boldsymbol{\mu})' S^{-1} (\bar{\mathbf{X}} - \boldsymbol{\mu}) \leq \chi_p^2(0.05)\}$$

は信頼係数がほぼ 95% の信頼領域となる.

n が大きくない場合に信頼係数が 95% となるような区間を求めるためには, $\chi_p^2(0.05)$ を T^2 の分布の上側 5% 点で置き換える必要がある.

定義

F-分布

定義 X と Y が独立で, $X \sim \chi_m^2$, $Y \sim \chi_n^2$ であるとき

$$U = \frac{X/m}{Y/n}$$

の従う分布を **自由度 m, n の F-分布** といい, $U \sim F_{m,n}$ と書く.

※ $\mathbf{X}_1, \dots, \mathbf{X}_n \stackrel{i.i.d.}{\sim} N_p(\boldsymbol{\mu}, \Sigma)$ のとき

$$T^2 = n(\bar{\mathbf{X}} - \boldsymbol{\mu})' S^{-1} (\bar{\mathbf{X}} - \boldsymbol{\mu})$$

とすると

$$\frac{n-p}{(n-1)p} T^2 \sim F_{p, n-p}$$

F -分布の確率密度関数

$U \sim F_{m,n}$ の確率密度関数は

$f(u; m, n)$

$$= \begin{cases} \frac{\Gamma[(m+n)/2]}{\Gamma(m/2)\Gamma(n/2)} \left(\frac{m}{n}\right)^{m/2} u^{m/2-1} \left(1 + \frac{m}{n}u\right)^{-(m+n)/2} & (u > 0) \\ 0 & (u \leq 0) \end{cases}$$



$(m, n \in \mathbb{N})$

注 4.2.1) この確率密度関数によって $F_{m,n}$ を定義してもよい。この場合, m, n は自然数でなくてもよい。

Memo

F -分布の特性

- $F_{m,n}$ は常に右に歪んだ分布であり, m が大きくなれば対称な分布に, n が大きくなれば自由度 m のカイ2乗分布を m で割った分布に近づく.



分布の特性 (続き)

2. $U \sim F_{m,n}$ のとき

$$E[U] = \frac{n}{n-2} \quad (n \geq 3), \quad \text{Var}[U] = \frac{2n^2(n+m-2)}{m(n-2)^2(n-4)} \quad (n \geq 5)$$

$n \geq 2r + 1$ ならば

$$E[U^r] = \left(\frac{n}{m}\right)^r \frac{m(m+2) \cdots \{m + (2(r-1))\}}{(n-2)(n-4) \cdots (n-2r)}$$

3. $T \sim t_n$ のとき $T^2 \sim F_{1,n}$ である.

レポート問題 6

特性 2, 3 を示せ.

4.3. 一元配置分散分析

問題設定

データ: ある湖の4地点で取られた酸素溶解量の無作為標本

地点	酸素溶解量 (%)					平均	
A_1	7.8	6.4	8.2	6.9		7.324	
A_2	6.7	6.8	7.1	6.9	7.3	6.960	
A_3	7.2	7.4	6.9	6.4	6.5	6.880	
A_4	6.0	7.4	6.5	6.9	7.2	6.8	6.800

問題: 4地点における酸素融解量に有意な差はあるか?

問題設定 (続き)

モデル化: 要因 A について k 個の水準 A_1, \dots, A_k を考え, それぞれの水準における次の標本が得られるとする.

$$\begin{aligned} \text{第 1 水準} & : Y_{11}, \dots, Y_{1n_1} \\ & \quad \vdots \\ \text{第 } k \text{ 水準} & : Y_{k1}, \dots, Y_{kn_k} \end{aligned}$$

統計モデル:

$$Y_{i1}, \dots, Y_{in_i} \stackrel{i.i.d.}{\sim} N(\mu_i, \sigma^2) \quad (i = 1, \dots, k)$$

(水準が異なれば独立)

仮説検定問題:

$$H_0 : \mu_1 = \dots = \mu_k \text{ (帰無仮説)}$$

$$H_1 : \mu_1, \dots, \mu_k \text{ のうちどれかは異なる (対立仮説)}$$

検定統計量

郡内平方和： $\bar{Y}_i = n_i^{-1} \sum_{j=1}^{n_i} Y_{ij}$ とおくと

$$\begin{aligned}
 W &= \min_{(\mu_1, \dots, \mu_k) \in \mathbb{R}^k} \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \mu_i)^2 = \sum_{i=1}^k \min_{\mu_i \in \mathbb{R}} \sum_{j=1}^{n_i} (Y_{ij} - \mu_i)^2 \\
 &= \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 \quad (\text{郡内平方和と呼ぶ})
 \end{aligned}$$

平方和： $\bar{Y} = n^{-1} \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}$ ($n = \sum_{i=1}^k n_i$) とおくと

$$S_0^2 = \min_{\mu \in \mathbb{R}} \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \mu)^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 \quad (\text{平方和})$$

検定統計量 (続き)

平方和の分解：

$$\begin{aligned}
 B &= S_0^2 - W = \sum_{i=1}^k \sum_{j=1}^{n_i} \{(Y_{ij} - \bar{Y})^2 - (Y_{ij} - \bar{Y}_i)^2\} \\
 &= \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})(2Y_{ij} - \bar{Y} - \bar{Y}_i) = \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})^2 \\
 &= \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2 \quad (\text{群間平方和と呼ぶ})
 \end{aligned}$$

$$S_0^2 = B + W = \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

が成り立つ。

検定統計量 (続き)

定理 4.3.1 B と W は独立であり $W/\sigma^2 \sim \chi_{n-k}^2$. H_0 が正しいときは $B/\sigma^2 \sim \chi_{k-1}^2$ が成り立つ. 従って H_0 の下で

$$T = \frac{B/(k-1)}{W/(n-k)} \sim F_{k-1, n-k}$$

※ H_0 が正しいとき, $(k-1)^{-1}B$, $(n-k)^{-1}W$ はともに σ^2 の不偏推定量となるが, H_0 が正しくない (H_1 が正しい) ときは $E[(k-1)^{-1}B] > \sigma^2$ であることがわかる.

$T > c$ のとき, H_0 を棄却する検定方法を考えることができる. c として, $F_{k-1, n-k}$ の上側 5% 点を得れば, 優位水準 5% の検定となる.

平方和の2次形式による表現

$\mathbf{Y}_i = (Y_{i1}, \dots, Y_{in_i})'$ ($i = 1, \dots, k$) とし,

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \vdots \\ \mathbf{Y}_k \end{pmatrix}, \quad D = \begin{pmatrix} \mathbf{1}_{n_1} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{n_2} & \cdots & \mathbf{0} \\ \vdots & & \ddots & \\ \mathbf{0} & \cdots & \mathbf{0} & \mathbf{1}_{n_k} \end{pmatrix}$$

とすると

$$(D'D)^{-1}D'\mathbf{Y} = (\bar{Y}_1, \dots, \bar{Y}_k)'$$

$$D(D'D)^{-1}D'\mathbf{Y} = (\mathbf{1}'_{n_1}\bar{Y}_1, \dots, \mathbf{1}'_{n_k}\bar{Y}_k)'$$

より

$$W = \mathbf{Y}'(I_n - D(D'D)^{-1}D')\mathbf{Y}$$

Memo

B と W の独立性

$$Q = D(D'D)^{-1}D', P = \frac{1}{n}\mathbf{1}_n\mathbf{1}'_n \text{ とおくと}$$

$$P\mathbf{Y} = \frac{1}{n}\mathbf{1}_n\mathbf{1}'_n\mathbf{Y} = (\mathbf{1}'_{n_1}\bar{Y}, \dots, \mathbf{1}'_{n_1}\bar{Y})$$

$$B = (Q\mathbf{Y} - P\mathbf{Y})'(Q\mathbf{Y} - P\mathbf{Y}) = \mathbf{Y}'(Q - P)\mathbf{Y}$$

となる.

$$\varepsilon_{ij} = Y_{ij} - \mu_i \quad (i = 1, \dots, k; j = 1, \dots, n_i),$$

$$\boldsymbol{\varepsilon} = (\varepsilon_{11}, \dots, \varepsilon_{1n_1}, \dots, \varepsilon_{kn_k}), \quad \boldsymbol{\mu} = (\mathbf{1}'_{n_1}\mu_1, \dots, \mathbf{1}'_{n_k}\mu_k)'$$

とおくと $\varepsilon_{11}, \dots, \varepsilon_{kn_k} \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$ で,

$$B = (\boldsymbol{\varepsilon} + \boldsymbol{\mu})'(Q - P)(\boldsymbol{\varepsilon} + \boldsymbol{\mu}),$$

$$W = (\boldsymbol{\varepsilon} + \boldsymbol{\mu})'(I_n - Q)(\boldsymbol{\varepsilon} + \boldsymbol{\mu}) = \boldsymbol{\varepsilon}'(I_n - Q)\boldsymbol{\varepsilon}$$

となり, $(I_n - Q)(Q - P) = O_{n \times n}$ となるから,

B と W は独立となる.

Memo

検定結果

酸素溶解量のデータで仮説検定を行ってみると,
 $n = 20$, $k = 4$ で, $F_{3,16}$ の上側 5% 点は, 3.2389 である.

$$T = \frac{0.7180/3}{4.2675/16} = 0.8973$$

となるので, 有意水準 5% で仮説を棄却できない.