

正規分布の分散における優越性と同等性の ベイズ流指標および F 検定の p 値との関係

京都大学大学院医学研究科 社会健康医学系専攻 医療統計学 土居正明

生物統計において連続量の応答変数をもつ2群の比較を行う際、応答変数の分散が両群で異なると考えられることはよくみられる。応答変数が正規分布に従う場合、頻度論の方法による分散の比較には F 検定がよく用いられる。本研究では「過去の類似した状況のデータを利用できる」「(設定したモデルのもとで)一方の群の分散が他方より大きくなる確率、などの直感的に理解しやすい指標を計算できる」などの利点を持つベイズ流の優越性指標と同等性指標を提案し、 F 検定の p 値との関係を検討する。

なお、本稿では紙面の都合上、平均既知の場合に絞って記載する。

1 分散の優越性を示すベイズ流指標

応答変数 x_{i1}, \dots, x_{in_i} に対して ($i = 1, 2$), $x_{i1}, \dots, x_{in_i} \stackrel{ind}{\sim} N(\mu_i, \sigma_i^2)$ とし、 $\mathbf{x}_i := (x_{i1}, \dots, x_{in_i})'$ とおく。このとき、分散の優越性を示すベイズ流指標として、 $\theta := \Pr(\sigma_1^2 > \sigma_2^2 | \mathbf{x}_1, \mathbf{x}_2)$ を考えると、以下が成り立つ。

定理 1 σ_i^2 の事後分布が逆ガンマ分布 $Inv-Ga(a_i, b_i)$ ($a_i, b_i > 0; i = 1, 2$) のとき、 θ は以下のように表せる。

$$\theta = F_{2a_1, 2a_2} \left(\frac{b_1/a_1}{b_2/a_2} \right).$$

ここで、逆ガンマ分布 $Inv-Ga(a_i, b_i)$ の確率密度関数は $f(\sigma_i^2 | a_i, b_i) = b_i^{a_i} (\sigma_i^2)^{-a_i-1} / \Gamma(a_i) \cdot \exp(-b_i/\sigma_i^2)$ であり、 $F_{n,m}(x)$ は、自由度 (n, m) の F 分布の累積分布関数である。

いま、 σ_i^2 の事前分布を逆ガンマ分布 $Inv-Ga(\nu_i/2, \nu_i\tau_i^2/2)$ とおく ($i = 1, 2$)。このとき、分散の事後分布は $Inv-Ga(a_i, b_i)$ となる (ここで、 $T_i^2 := 1/n_i \sum_{j=1}^{n_i} (x_{ij} - \mu_i)^2$, $a_i := (\nu_i + n_i)/2$, $b_i := (\nu_i\tau_i^2 + n_i \cdot T_i^2)/2$)。これより、定理 1 から、ベイズ流指標 θ は以下のように表せる。

$$\theta = F_{\nu_1+n_1, \nu_2+n_2} \left(\frac{(\nu_1\tau_1^2 + n_1 \cdot T_1^2)/(\nu_1 + n_1)}{(\nu_2\tau_2^2 + n_2 \cdot T_2^2)/(\nu_2 + n_2)} \right).$$

定理 2 θ と、 $H_0: \sigma_1^2 = \sigma_2^2$, $H_1: \sigma_1^2 > \sigma_2^2$ に対する F 検定の p 値の間に以下の関係が成り立つ。

$$\lim_{(\nu_1, \nu_2) \rightarrow (0, 0)} \theta = 1 - p.$$

この定理は、「事前分布の情報量を 0 に減らした極限において、ベイズ流指標と F 検定の p 値に対する $1 - p$ が一致する」ことを示すものと解釈できる。次に、無情報事前分布を直接与えた場合の p 値との対応を示す。

系 1 分散の事前分布が $f(\sigma_i^2) \propto (\sigma_i^2)^{-1}$ のとき ($i = 1, 2$)、 $\theta = 1 - p$ が成り立つ。

2 分散の同等性を示すベイズ流指標

Δ を $0 < \Delta < 1/2$ を満たす定数とする。このとき、分散の同等性を示すベイズ流指標 $\theta_e(\Delta) := \Pr(\Delta < \sigma_1/\sigma_2 < 1/\Delta)$ を考えると、以下が成り立つ。

定理 3 分散の事後分布が $\sigma_i^2 \sim Inv-Ga(a_i, b_i)$ のとき ($a_i, b_i > 0; i = 1, 2$)、以下が成り立つ。

$$\theta_e(\Delta) = F_{2a_1, 2a_2} \left(\frac{b_1/a_1}{b_2/a_2} \cdot \frac{1}{\Delta^2} \right) - F_{2a_1, 2a_2} \left(\frac{b_1/a_1}{b_2/a_2} \cdot \Delta^2 \right).$$

系 2 分散の事前分布を $f(\sigma_i^2) \propto (\sigma_i^2)^{-1}$ とおく ($i = 1, 2$)。ここで、 $H_0^{(1)}: \sigma_1/\sigma_2 = \Delta$, $H_1^{(1)}: \Delta < \sigma_1/\sigma_2$ に関する F 検定の p 値を $p^{(1)}$, $H_0^{(2)}: \sigma_1/\sigma_2 = 1/\Delta$, $H_1^{(2)}: \sigma_1/\sigma_2 < 1/\Delta$ に関する F 検定の p 値を $p^{(2)}$ とおく。このとき、以下が成り立つ。

$$\theta_e(\Delta) = 1 - (p^{(1)} + p^{(2)}).$$

当日は、平均未知の場合の対応、および他の分布に関する同様の関係式との関連についても述べる。