

# フィッシャー情報量とクラメル・ラオの下限

清家大嗣

2023年5月15日

## 1 前提

パラメータ  $\theta$  の分布関数  $f$  から得られた、標本  $x$  についての尤度関数  $L(\theta; x)$  は次式で表される (ここで、分布関数  $f$  から得られた標本から、パラメータ  $\theta$  を推測している。因果が逆転していることに注意したい.)。

$$L(\theta; x) = f(x; \theta) \quad (1)$$

また、確率密度関数の性質から、尤度関数は常に正の値を取るため、以下の対数尤度関数を定義できる。

$$l(\theta; x) = \log L(\theta; x) \quad (2)$$

対数尤度関数をパラメータ一回微分した値は、スコア関数  $U(\theta; x)$  と呼ばれる (スコア関数が 0 になるパラメータ  $\theta$  を選択するケースを授業ではよく学ぶ)。

$$U(\theta; x) = \frac{\partial l(\theta; x)}{\partial \theta} \quad (3)$$

スコア関数の二乗の期待値をフィッシャー情報量  $I(\theta)$  と呼ぶ。

$$I(\theta) = E[U(\theta; x)^2] = \int_{x \in \Omega} \left\{ \frac{\partial}{\partial \theta} \log f(x; \theta) \right\}^2 f(x; \theta) dx \quad (4)$$

ここで、 $\Omega$  は標本空間である。

## 2 スコア関数の性質

### 2.1 期待値

定義式の通りに計算すると、0 になることが分かる (標本空間全体に対する確率密度関数の積分結果は 1, 積分と微分の可換が成立することを仮定)。

$$E[U(\theta; x)] = \int_{x \in \Omega} \frac{\partial \log f(x; \theta)}{\partial \theta} f(x; \theta) dx \quad (5)$$

$$= \int_{x \in \Omega} \frac{\partial f(x; \theta)}{\partial \theta} dx \quad (6)$$

$$= \frac{\partial}{\partial \theta} \int_{x \in \Omega} f(x; \theta) dx = \frac{\partial}{\partial \theta} 1 = 0 \quad (7)$$

## 2.2 分散

分散の公式と、期待値が 0 であることより、フィッシャー情報量と一致する.

$$\text{Var}(U(\theta; \mathbf{x})) = E[U^2(\theta; \mathbf{x})] = \int_{\mathbf{x} \in \Omega} \left\{ \frac{\partial}{\partial \theta} \log f(\mathbf{x}; \theta) \right\}^2 d\mathbf{x} \quad (8)$$

$$= I(\theta) \quad (9)$$

## 3 クラメル・ラオの下限 ( $n$ 個の標本データから予測する不偏推定量の分散の下限評価)

### 3.1 前提

パラメータ  $\theta$  の分布関数  $f$  から得られる  $n$  個の標本  $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$  について考える. この場合の結合確率密度  $f_n(\mathbf{x}; \theta)$  は次式で与えられる (各データを確率変数とみなし, 互いに独立していると考え).

$$f_n(\mathbf{x}; \theta) = f(x_1; \theta) \cdot f(x_2; \theta) \cdot \dots \cdot f(x_n; \theta) \quad (10)$$

また, 対数尤度関数  $L_n(\theta; \mathbf{x})$  は次式で与えられる.

$$L_n(\theta; \mathbf{x}) = \log f_n(\mathbf{x}; \theta) = \sum_{i=1}^n \log f(x_i; \theta) \quad (11)$$

従って,  $n$  個分の標本のスコア関数は次式のようなになる.

$$U_n(\theta; \mathbf{x}) = \frac{\partial L_n(\theta; \mathbf{x})}{\partial \theta} = \sum_{i=1}^n \frac{\partial}{\partial \theta} \log f(x_i; \theta) \quad (12)$$

和の期待値は期待値の和になり, 互いに独立な確率変数の和の分散は分散の和になる. 従って, スコア関数  $U_n(\theta; \mathbf{x})$  の期待値・分散はそれぞれ以下のようなになる ( $I(\theta)$  は, フィッシャー情報量).

$$E[U_n(\theta; \mathbf{x})] = 0 \quad (13)$$

$$\text{Var}[U_n(\theta; \mathbf{x})] = nI(\theta) \quad (14)$$

同様に, スコア関数の二乗の期待値をフィッシャー情報量  $I_n(\theta)$  と定義する.

$$I_n(\theta) = E[U_n(\theta; \mathbf{x})^2] = \int_{\mathbf{x} \in \Omega} \left\{ \frac{\partial}{\partial \theta} \log f_n(\mathbf{x}; \theta) \right\}^2 f_n(\mathbf{x}; \theta) d\mathbf{x} \quad (15)$$

最後に,  $n$  個の標本データから得られる  $\theta$  の不偏推定量を  $\hat{\theta}_n(\mathbf{x})$  で表記する. 不偏推定量のため, 下式を満たす.

$$\theta = E[\hat{\theta}_n(\mathbf{x})] \quad (16)$$

### 3.2 主張

パラメータ  $\theta$  の不偏推定量  $\hat{\theta}_n(\mathbf{x})$  の分散の下限がフィッシャー情報量  $I(\theta)$  で評価できる.

$$\text{Var}[\hat{\theta}_n(\mathbf{x})] \geq \frac{1}{I(\theta)} \quad (17)$$

### 3.3 証明

不偏推定量の定義より、次式が成立する.

$$\theta = E[\hat{\theta}_n(\mathbf{x})] = \int_{\mathbf{x} \in \Omega^n} \hat{\theta}_n(\mathbf{x}) f_n(\mathbf{x}; \theta) d\mathbf{x} \quad (18)$$

両辺を  $\theta$  で微分して整理する (各標本データを互いに独立な確率変数と見做していることを 2 行目の変形で利用).

$$1 = \int_{\mathbf{x} \in \Omega^n} \hat{\theta}_n(\mathbf{x}) \left\{ \frac{\partial}{\partial \theta} f_n(\mathbf{x}; \theta) \right\} d\mathbf{x} \quad (19)$$

$$= \int_{\mathbf{x} \in \Omega^n} \hat{\theta}_n(\mathbf{x}) \left\{ \frac{\partial}{\partial \theta} \log f_n(\mathbf{x}; \theta) \right\} f_n(\mathbf{x}; \theta) d\mathbf{x} \quad (20)$$

従って、スコア関数の定義 (3 式) より、以下の式が成立する.

$$1 = E[\hat{\theta}_n(\mathbf{x}) U_n(\theta; \mathbf{x})] \quad (21)$$

$U_n(\theta; \mathbf{x})$  は、各標本データ  $x_i$  が互いに独立な確率変数であるため、期待値は 0 となる. それ故、次式が成り立つ ( $\theta$  は、母数であるため定数).

$$1 = E[(\hat{\theta}_n(\mathbf{x}) - \theta) U_n(\theta; \mathbf{x})] \quad (22)$$

コーシー・シュワルツの不等式 (この証明は、 $\sum_{i=1}^n (a_i x - b)^2 \geq 0$  の判別式を利用することで簡単に与えられる) を利用して、次式が成立する.

$$E[(\hat{\theta}_n(\mathbf{x}) - \theta)^2] E[U_n(\theta; \mathbf{x})^2] \geq E[(\hat{\theta}_n(\mathbf{x}) - \theta) U_n(\theta; \mathbf{x})]^2 = 1 \quad (23)$$

これは、次式の成立を主張していることに他ならない.

$$\text{Var}[\hat{\theta}_n(\mathbf{x})] = E[(\hat{\theta}_n(\mathbf{x}) - \theta)^2] \geq \frac{1}{E[U_n(\theta; \mathbf{x})^2]} = \frac{1}{I_n(\theta)} \quad (24)$$

## 4 フィッシャー情報量の公式

$$\frac{\partial^2}{\partial \theta^2} \log f(x; \theta) = \frac{\partial}{\partial \theta} \left\{ \frac{1}{f(x; \theta)} \frac{\partial f(x; \theta)}{\partial \theta} \right\} \quad (25)$$

$$= -\frac{1}{\{f(x; \theta)\}^2} \left\{ \frac{\partial f(x; \theta)}{\partial \theta} \right\}^2 + \frac{1}{f(x; \theta)} \frac{\partial^2 f(x; \theta)}{\partial \theta^2} \quad (26)$$

$$= -\left\{ \frac{\partial \log f(x; \theta)}{\partial \theta} \right\}^2 + \frac{1}{f(x; \theta)} \frac{\partial^2 f(x; \theta)}{\partial \theta^2} \quad (27)$$

上式の平均を取ることで、次の公式が得られる (第二項が 0 になるのは、積分と微分の順序が可換である場合のみを考えているため).

$$E\left[\frac{\partial^2}{\partial \theta^2} \log f(x; \theta)\right] = -I(\theta) + \int_{\mathbf{x} \in \Omega} \frac{\partial f(x; \theta)}{\partial \theta^2} dx \quad (28)$$

$$= -I(\theta) \quad (29)$$

## 5 クラメル・ラオ限界の応用例

母数の推定値のバラツキは小さい程よい. これは、自明と考えられる. 24 式の主張は、このバラツキ改善に限界があり、それはフィッシャー情報量 (スコア関数の二乗値) に依存するということである (つまり、元々の分布関数に依存).

具体例として, 互いに独立に正規分布に従う  $n$  個分の標本データに関する, 母平均  $\mu$  を標本平均  $\bar{x}$  で推定することを考える. つまり, 先ほどの  $\theta \rightarrow \mu, \hat{\theta} \rightarrow \bar{x}$  としたケースである.  $n$  標本データが得られた場合のフィッシャー情報量  $I_n(\theta)$  は次式で与えられる (28, 29 式を利用).

$$I_n(\theta) = nI(\theta) = -nE\left[\frac{\partial^2}{\partial\theta^2} \log f(x; \theta)\right] \quad (30)$$

$$= n \cdot \frac{1}{\sigma^2} \quad (31)$$

従って,

$$\text{Var}[\hat{\mu}] \geq \frac{1}{I_n(\theta)} = \frac{\sigma^2}{n} \quad (32)$$

つまり, 標本平均の分散が  $\sigma^2/n$  であるという事実から, 推定量の分散がクラメルラオの下限となっていることが分かる. この条件を満たすとき, 推定量は漸近有効であるという.

## 参考文献

なし