

# 第7章「統計学における情報量」

## 1. Hartley 情報量

定義  $N$  個の要素からなる集合を  $A[N]$  で表すとき, 集合  $A[N]$  がもつ情報量

$$\Lambda(A[N]) = \log_2 N$$

を Hartley 情報量という.

・性質

$$(H1) \quad \Lambda(A[NM]) = \Lambda(A[N]) + \Lambda(A[M])$$

$$(H2) \quad \Lambda(A[N]) \leq \Lambda(A[N+1])$$

$$(H3) \quad \Lambda(A[2]) = 1 \quad (\text{単位集合は bit (binary unit)})$$

## 2. Shannon 情報量

定義 1 離散確率分布  $p = (p_1, \dots, p_n)$  に対して,

$$H(p) = - \sum_{k=1}^n p_k \log_2 p_k$$

を, 離散確率分布  $p$  の Shannon 情報量という. 熱力学では, エントロピーと呼ばれる.

・解釈 事象  $A_k$  上で  $-\log_2 p_k$  という値を確率  $p_k$  で取る確率変数  $X$  を考えれば,  $H(p) = E(X)$  となる.

・性質

(S1)  $H(p) \geq 0$  であり, 最小値  $H(p) = 0$  は一点分布 (ある  $i$  に対して  $p_i = 1$ ) のときに達成される.

(S2)  $H(p)$  の最大値は  $\log_2 n$  であり, 離散一様分布 ( $p_i = 1/n$ ) の場合に達成される.

(S3) 不等式  $-p_i \log_2 p_i - p_j \log_2 p_j \geq -(p_i + p_j) \log_2 (p_i + p_j)$  が成り立つ. すなわち, 事象の合併によりエントロピーは減少する.

(注) エントロピーは, 加算無限の離散分布に対しても定義される.

(例) 非負整数上の確率分布の平均  $\mu (> 0)$  が与えられているとき, エントロピーを最大にする分布は, 幾何分布である.

定義 2 密度関数  $f(x)$  に対するエントロピーは,

$$H(f) = - \int_{-\infty}^{\infty} f(x) \log f(x) dx$$

により定義される。

(例) 密度関数の平均, 分散が与えられたとき, エントロピーを最大にする分布は, 正規分布である。

### 3. Kullback 情報量

定義 1 離散確率分布  $p = (p_1, \dots, p_n)$  と  $q = (q_1, \dots, q_n)$  に対して, 分布  $p$  を  $q$  で置き換えたときの増加情報量

$$I(q||p) = \sum_{k=1}^n q_k \log_2 \frac{q_k}{p_k}$$

を離散分布に対する Kullback 情報量という。

・統計学的解釈 真の確率分布  $q$  と, モデル  $p$  との分布の距離を測る。

・性質

1.  $I(q||p) \geq 0$

2.  $I(q||p) = 0 \iff p = q$

(証明) 値  $p_k/q_k$  を確率  $q_k$  で取る確率変数を  $Z$  とすると,

$$E(Z) = \sum_{k=1}^n \frac{p_k}{q_k} q_k = 1$$

また,

$$h(z) = -\log_2 z$$

を定義すると,  $E(h(Z)) = I(q||p)$  である。ここで,  $h(z)$  は,  $h''(z) = 1/(z^2 \log 2) > 0$  であるから, 狭義の凸関数であり,

$$h(z) \geq -z + 1$$

が成立する。これより,  $E(h(Z)) \geq 0$  で, 等号は  $p = q$  のときに限る。

(問 1) 二項確率モデル  $p = (0.7, 0.3)$  と真の分布  $q = (0.6, 0.4)$  があるとき, Kullback 情報量を求めよ。また,  $r = (0.5, 0.5)$  と  $p$  では, どちらが  $q$  に近いか。

定義 2 真の密度関数を  $g(x)$ , モデルに基づく密度関数を  $f(x)$  とするとき,

$$I(g||f) = \int_{-\infty}^{\infty} g(x) \log \frac{g(x)}{f(x)} dx$$

をモデルに関する真の分布の Kullback 情報量という。常に非負であり, 0 になるのは  $f(x) = g(x)$  のときに限る。

(問 2) 真の分布が  $N(0, 1)$  のとき, 2 つの正規分布  $N(0.5, 1)$  と  $N(0, 1.5)$  とでは, どちらが  $N(0, 1)$  に近いであろうか。

## 4 . Fisher 情報量

定義  $L(\theta)$  をパラメータ  $\theta$  をもつ対数尤度関数とするととき ,

$$I(\theta) = E[(L'(\theta))^2]$$

を Fisher 情報量という .

正則性の条件のもとで ,

$$I(\theta) = -E[L''(\theta)]$$

が成り立つ .

・ Kullback 情報量との関係

$$\lim_{h \rightarrow 0} \frac{1}{h^2} I(\theta || \theta + h) = \frac{1}{2} I(\theta)$$

$\theta$  の近傍での Kullback 情報量  $I(\theta || \theta + h)$  が Fisher 情報量  $I(\theta)$  に比例していることから , Fisher 情報量は分布族の局所情報量を表している .

・ Fisher 情報量の有用性

推定において , 推定量のよさを測る量として , 重要な役割をはたす .