

< 復元抽出による標本調査 1 >

例 2 全国の高校 3 年生の男子の身長を調べたい。全国の高校 3 年生の男子全体は N 人いるとして、その身長データを $\{y_1, y_2, \dots, y_N\}$ とする。これを母集団とし、その平均と分散を、それぞれ

$$\mu = \frac{1}{N} \sum_{i=1}^N y_i \quad (\text{母平均}) \quad , \quad \sigma^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \mu)^2 \quad (\text{母分散})$$

母平均、母分散という。この母集団全てを調査するのは大変なので、その中から n 人だけ調べて、全体を推測したい。 n 人を無作為に復元抽出し、その身長データを X_1, X_2, \dots, X_n とする。 X_k は k 番目に選んだ男子の身長である。このとき X_k は

$$P(X_k = y_i) = \frac{1}{N} \quad \begin{pmatrix} i = 1, 2, \dots, N \\ k = 1, 2, \dots, n \end{pmatrix}$$

である確率変数とみなせる。この標本 X_1, X_2, \dots, X_n の平均と分散を

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k \quad (\text{標本平均}) \quad , \quad S^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2 \quad (\text{標本分散})$$

標本平均、標本分散という。このとき次の定理が成り立つ。

定理 14 (1) 各 $k = 1, 2, \dots, n$ に対し、確率変数 X_k の平均と分散は母平均と母分散に一致する。すなわち

$$E[X_k] = \mu \quad , \quad E[(X_k - \mu)^2] = \sigma^2$$

$$(2) \quad E[\bar{X}] = \mu \quad , \quad E\left[\sum_{k=1}^n (X_k - \bar{X})^2\right] = (n-1)\sigma^2$$

(注 1) この定理より標本分散の平均値は $E[S^2] = \frac{n-1}{n}\sigma^2$ となり母分散 σ^2 と異なる。そのため標本分散のかわりに

$$U = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2 \quad (\text{不偏分散})$$

を用いる。この平均は $E[U] = \sigma^2$ となる。 U を**不偏分散**という。

(注 2) 統計では未知数の数を**自由度 (degree of freedom)**という。

例えば n 個の未知数 $\{x_1, x_2, \dots, x_n\}$ の自由度は n だが、

$$\text{その平均 } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \text{ を引いた値} \\ \{x_1 - \bar{x}, x_2 - \bar{x}, \dots, x_n - \bar{x}\}$$

の自由度は $n-1$ である。

問 $y_k = x_k - \bar{x}$ ($\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$) ($k = 1, 2, \dots, n$) とおくと、 y_n の値は

$\{y_1, y_2, \dots, y_{n-1}\}$ で表されることを示せ。