

第4章 標本分布論と漸近分布論

4.1 標本分布論の枠組み

4.1.1 ランダム標本

定義 4.1 X_1, X_2, \dots, X_n が母集団分布 $f(x)$ からの標本の大きさが n の/ランダム標本であるとは, X_1, X_2, \dots, X_n は互いに独立な確率変数列であって, 各 $X_i, i = 1, 2, \dots, n$ は確率関数または確率密度関数 $f(x)$ に従うときをいう. また, X_1, X_2, \dots, X_n は独立同一に確率関数または確率密度関数 $f(x)$ に従うともいう.

注意 4.1 多くの場合は $n > 1$ である. また, $\mathbf{X} = (X_1, X_2, \dots, X_n)$ の同時確率関数または同時確率密度関数は

$$f_{\mathbf{X}}(x_1, x_2, \dots, x_n) = \prod_{k=1}^n f(x_k)$$

である.

4.1.2 統計量と標本分布

定義 4.2 X_1, X_2, \dots, X_n をある母集団分布からの標本の大きさが n のランダム標本とし, $T(x_1, x_2, \dots, x_n)$ をランダム標本 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ の値域上で定義された実数値または実ベクトル値関数とする. このとき, 確率変数または確率ベクトル $Y = T(X_1, X_2, \dots, X_n)$ を統計量という. さらに, 統計量 Y の確率分布を Y の標本分布とよぶ.

例 4.1 ランダム標本の算術平均は統計量であり, 標本平均という. 通常

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{1}{n} \sum_{i=1}^n X_i$$

と記す.

また,

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

で定義される統計量を標本分散という.

補題 4.1 x_1, x_2, \dots, x_n を実数列とし, $\bar{x}_n = (1/n)(x_1 + x_2 + \dots + x_n)$ と $s_n^2 = (1/(n-1)) \sum_{i=1}^n (x_i - \bar{x}_n)^2$ とおく. このとき,

$$(1) \quad \min_a \sum_{i=1}^n (x_i - a)^2 = \sum_{i=1}^n (x_i - \bar{x}_n)^2.$$

$$(2) \quad (n-1)s_n^2 = \sum_{i=1}^n x_i^2 - n\bar{x}_n^2.$$

となる.

証明 (1) を証明するために, \bar{x}_n を加えて引けば,

$$\begin{aligned} \sum_{i=1}^n (x_i - a)^2 &= \sum_{i=1}^n (x_i - \bar{x}_n + \bar{x}_n - a)^2 \\ &= \sum_{i=1}^n (x_i - \bar{x}_n)^2 + 2 \sum_{i=1}^n (x_i - \bar{x}_n)(\bar{x}_n - a) + \sum_{i=1}^n (\bar{x}_n - a)^2 \\ &= \sum_{i=1}^n (x_i - \bar{x}_n)^2 + n(\bar{x}_n - a)^2 \end{aligned} \quad (4.1)$$

となる. 最後の等式は

$$\sum_{i=1}^n (x_i - \bar{x}_n)(\bar{x}_n - a) = (\bar{x}_n - a) \sum_{i=1}^n (x_i - \bar{x}_n) = 0$$

よりわかる. (4.1) は $a = \bar{x}_n$ の時に最小になることがわかる.

(2) を示すためには, (4.1) において, $a = 0$ とすればよい. □

定理 4.1 X_1, X_2, \dots, X_n をある母集団分布からの標本の大きさが n のランダム標本とし, g を X_1 の値域上で定義された実数値関数とする. $g^2(X_2)$ の期待値が存在するとき,

$$\mathbb{E}\left[\sum_{i=1}^n g(X_i)\right] = n\mathbb{E}[g(X_1)], \quad (4.2)$$

$$\text{VAR}\left[\sum_{i=1}^n g(X_i)\right] = n\text{VAR}[g(X_1)] \quad (4.3)$$

が成立する.

証明 (4.2) は期待値の線形性と

$$\mathbb{E}\left[\sum_{i=1}^n g(X_i)\right] = \sum_{i=1}^n \mathbb{E}[g(X_i)] = n\mathbb{E}[g(X_1)]$$

からわかる¹ .

(4.3) を示すために , 分散の定義と期待値の線形性から

$$\begin{aligned}
 \text{VAR}\left[\sum_{i=1}^n g(X_i)\right] &= \mathbb{E}\left[\left\{\sum_{i=1}^n g(X_i) - \mathbb{E}\left[\sum_{i=1}^n g(X_i)\right]\right\}^2\right] \\
 &= \mathbb{E}\left[\left\{\sum_{i=1}^n (g(X_i) - \mathbb{E}[g(X_i)])\right\}^2\right] \\
 &= \mathbb{E}\left[\sum_{i=1}^n (g(X_i) - \mathbb{E}[g(X_i)])^2 + \sum_{i \neq j} (g(X_i) - \mathbb{E}[g(X_i)])(g(X_j) - \mathbb{E}[g(X_j)])\right] \\
 &= \sum_{i=1}^n \mathbb{E}[(g(X_i) - \mathbb{E}[g(X_i)])^2] \\
 &\quad + \sum_{i \neq j} \mathbb{E}[(g(X_i) - \mathbb{E}[g(X_i)])(g(X_j) - \mathbb{E}[g(X_j)])]
 \end{aligned} \tag{4.4}$$

となる . しかし ,

$$\sum_{i=1}^n \mathbb{E}[(g(X_i) - \mathbb{E}[g(X_i)])^2] = \sum_{i=1}^n \text{VAR}[g(X_i)] = n \text{VAR}[g(X_1)]$$

と $i \neq j$ に対して ,

$$\mathbb{E}[(g(X_i) - \mathbb{E}[g(X_i)])(g(X_j) - \mathbb{E}[g(X_j)])] = \mathbb{E}[g(X_i)g(X_j)] - \mathbb{E}[g(X_i)]\mathbb{E}[g(X_j)] = 0$$

となる . ただし , 最後の等号は定理 3.2 からわかる . 上のふたつの式を (4.4) に代入すれば , (2) は示される . \square

系 4.1 X_1, X_2, \dots, X_n をある母集団分布からの標本の大きさが n のランダム標本とする . X_1^2 の期待値が存在するとき ,

$$\begin{aligned}
 \mathbb{E}\left[\sum_{i=1}^n a_i X_i\right] &= \sum_{i=1}^n a_i \mathbb{E}[X_i], \\
 \text{VAR}\left[\sum_{i=1}^n a_i X_i\right] &= \sum_{i=1}^n a_i^2 \text{VAR}[X_i]
 \end{aligned}$$

¹連続型の場合を考える . X_1, X_2, \dots, X_n の同時確率密度関数を $f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n)$ としたとき ,

$$\begin{aligned}
 \mathbb{E}\left[\sum_{i=1}^n g(X_i)\right] &= \int \cdots \int \sum_{i=1}^n g(x_i) f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) \Pi_{i=1}^n dx_i \\
 &= \sum_{i=1}^n \int \cdots \int g(x_i) f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) \Pi_{i=1}^n dx_i \\
 &= \sum_{i=1}^n \int g(x_i) f_{X_i}(x_i) dx_i \\
 &= \mathbb{E}[g(X_i)]
 \end{aligned}$$

よりわかる . ただし , $f_{X_i}(x_i)$ は X_i の周辺確率密度関数である .

が成立する．ただし， a_1, a_2, \dots, a_n は定数である．

定理 4.2 X_1, X_2, \dots, X_n を平均 μ と分散 $\sigma^2 < \infty$ の母集団分布からの標本の大きさが n のランダム標本とする．このとき，

$$(1) \quad \mathbb{E}[\bar{X}_n] = \mu,$$

$$(2) \quad \text{VAR}[\bar{X}_n] = \frac{\sigma^2}{n},$$

$$(3) \quad \mathbb{E}[S_n^2] = \sigma^2.$$

となる．

証明 (1) を示すために，定理において， $g(x) = x$ とすれば，

$$\mathbb{E}[\bar{X}_n] = \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n X_i\right] = \frac{1}{n} n \mathbb{E}[X_1] = \mathbb{E}[X_1] = \mu$$

となることがわかる．

(2) は分散の性質と定理を同様に利用すれば，

$$\text{VAR}[\bar{X}_n] = \frac{1}{n^2} \text{VAR}\left[\sum_{i=1}^n X_i\right] = \frac{1}{n^2} n \text{VAR}[X_1] = \frac{1}{n} \text{VAR}[X_1] = \frac{\sigma^2}{n}$$

となることがわかる．

(3) を示すために補題 4.1 を使えば，

$$\begin{aligned} \mathbb{E}[S_n^2] &= \mathbb{E}\left[\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right] = \frac{1}{n-1} \mathbb{E}\left[\sum_{i=1}^n X_i^2 - n\bar{X}_n^2\right] \\ &= \frac{1}{n-1} (n\mathbb{E}[X_1^2] - n\mathbb{E}[\bar{X}_n^2]) \end{aligned} \quad (4.5)$$

となる．しかし，

$$\begin{aligned} \mathbb{E}[X_1^2] &= \text{VAR}[X_1] + (\mathbb{E}[X_1])^2 = \sigma^2 + \mu^2, \\ \mathbb{E}[\bar{X}_n^2] &= \text{VAR}[\bar{X}_n] + (\mathbb{E}[\bar{X}_n])^2 = \frac{\sigma^2}{n} + \mu^2 \end{aligned}$$

となる．これらと (4.5) をあわせれば，

$$\mathbb{E}[S_n^2] = \frac{1}{n-1} \left(n(\sigma^2 + \mu^2) - n \left(\frac{\sigma^2}{n} + \mu^2 \right) \right) = \sigma^2$$

となることがわかる．

□

定理 4.3 X_1, X_2, \dots, X_n を積率母関数 $M_X(t)$ を持つ母集団分布からの標本の大きさが n のランダム標本とする．このとき，

$$M_{\bar{X}_n}(t) = (M_X(t/n))^n$$

が成立する．

証明

$$M_{\bar{X}_n}(t) = \mathbb{E}[e^{t\bar{X}_n}] = \mathbb{E}\left[\prod_{i=1}^n e^{tX_i/n}\right] = \prod_{i=1}^n \mathbb{E}[e^{tX_i/n}] = [M_X(t/n)]^n$$

からわかる． □

例 4.2 X_1, X_2, \dots, X_n を正規分布 $N(\mu, \sigma^2)$ からの標本の大きさが n のランダム標本とする．このとき，標本平均 \bar{X}_n は正規分布 $N(\mu, \sigma^2/n)$ に従うことがわかる．なぜならば，

$$\begin{aligned} M_{\bar{X}_n}(t) &= [pe^{t/n} + (1-p)]^n = \exp\left[n\left(\frac{t}{n}\mu + \frac{1}{2}\left(\frac{t}{n}\right)^2\sigma^2\right)\right] \\ &= \exp\left[t\mu + \frac{(\sigma^2/n)t^2}{2}\right] \end{aligned}$$

からわかる．

例 4.3 X_1, X_2, \dots, X_n を母数 p のベルヌーイ分布からの標本の大きさが n のランダム標本とする．ただし， $0 < p < 1$ である．このとき，標本平均 $n\bar{X}_n$ は母数 n と p の二項分布に従うことがわかる．なぜならば，

$$M_{n\bar{X}_n}(t) = \prod_{i=1}^n \mathbb{E}[e^{tX_i}] = [pe^t + (1-p)]^n$$

からわかる．