

統計.

まず、言葉の定義をいくつかする.

母集団 : 統計の対象となる集まり.

例 : 20歳の日本人全体, ある工場で作られる製品全体 など.

個体 : 母集団の中の1つずつ

特性標識 : 着目する性質

→ 統計学では、着目する性質について、母集団全体の特徴を調べたい.

特に次のものが重要.

母平均 : 母集団の平均値.

母分散 : 母集団の分散値.

母比率 : 条件Cをみたす確率.

例 : 製品の不良品の割合, 160cm以上165cm以下の割合 など.

母分布 : 上記のような母集団の特徴.

→ これらを調べるにはどうすればよいか.

方法1 全数調査 : 全部調べる.

→ 時間と費用がかかる

方法2 標本(サンプル)調査 : 一部を取り出して調べる.

→ 信頼性と、時間・費用のバランスが大事.

・ 標本の数のことを標本の大きさ(サイズ)という.

・ 標本を調べるときは、無作為に個体をとって調べ、元に戻す。(復元抽出)

これをくり返す. この方法を **独立な任意抽出** という.

標本変量

特性 X が数値で表れるとき、1つ目の標本の特性を X_1 とする。

→ X_1 の値は母分布に従うので、 X_1 は確率変数として扱える。

例. 製品の不良率が 3% であるとする。 X を不良 (1), 良 (0) とするとき、

X_1 のとり値と確率は、

X_1	1	0
確率	0.03	0.97

とできる。これは離散型の確率変数。

これをくり返すと、母分布に従う独立な確率変数 X_1, \dots, X_n を得る。

これらを **標本変量**、 (X_1, \dots, X_n) を **標本** という。

実際に抽出を行うと、 x_1, \dots, x_n が得られる。

この (x_1, \dots, x_n) を (X_1, \dots, X_n) の **実現値**, **標本値** という。

標本 (X_1, \dots, X_n) に対し、次を定義する。

$$\text{標本平均} : \bar{X} = \frac{1}{n} (X_1 + \dots + X_n)$$

$$\begin{aligned} \text{標本分散} : S^2 &= \frac{1}{n-1} \left((X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2 \right) \\ &= \frac{1}{n-1} (X_1^2 + \dots + X_n^2 - n \cdot \bar{X}^2) \end{aligned}$$

$$\text{標本標準偏差} : S = \sqrt{S^2}$$

これらも、確率変数として扱える。

例題. 標本 (3.2, 1.5, 3.5, 2.8, 3.0) の平均 \bar{X} と分散 S^2 の実現値を求めよ。

$$\text{答. } \bar{X} = \frac{1}{5} (3.2 + 1.5 + 3.5 + 2.8 + 3.0) = 2.8$$

$$S^2 = \frac{1}{5-1} (3.2^2 + 1.5^2 + 3.5^2 + 2.8^2 + 3.0^2 - 5 \times 2.8^2) = 0.595 \quad \text{である}$$

問題 標本(1.67, 1.72, 1.70, 1.72, 1.69)の平均 \bar{X} と分散 S^2 の実現値を求めよ.

答 $\bar{X} = \frac{1}{5} (1.67 + 1.72 + 1.70 + 1.72 + 1.69) = 1.70$

$$S^2 = \frac{1}{5-1} ((-0.03)^2 + (0.02)^2 + 0^2 + (0.02)^2 + (0.01)^2)$$

$$= \frac{1}{4} (0.0018) = 0.00045$$

である.

定理 2.5.1 母平均を μ , 母分散を σ^2 とすると. 標本平均 \bar{X} は.

(i) $E(\bar{X}) = \mu$

(ii) $V(\bar{X}) = \frac{\sigma^2}{n}$

である.

⊙ 1つの標本 X_i は $E(X_i) = \mu$, $V(X_i) = \sigma^2$ なの? 定理 1.7.2 より求まる.

定理 2.5.2 n が十分大きければ.

\bar{X} はほぼ $N(\mu, \frac{\sigma^2}{n})$ に従う.

定理 2.5.5

$E(S^2) = \sigma^2$ である.

⊙ $E(S^2) = E\left(\frac{1}{n-1} (X_1^2 + \dots + X_n^2 - n \cdot \bar{X}^2)\right)$

$$= \frac{1}{n-1} (E(X_1^2) + \dots + E(X_n^2) - n \cdot E(\bar{X}^2))$$

$$= \frac{1}{n-1} ((\sigma^2 + \mu^2) + \dots + (\sigma^2 + \mu^2) - n \left(\frac{\sigma^2}{n} + \mu^2\right))$$

$$= \sigma^2.$$

$V(X_i) = E(X_i^2) - E(X_i)^2$ より

$E(X_i^2) = \sigma^2 + \mu^2$ である

標本度数と標本比率

標本として得られる結果を、 k 個の階級 C_1, C_2, \dots, C_k に分類する。

各階級 C_i に属する個数 N_i をその階級の **標本度数** という。

標本が n 個なら $N_1 + \dots + N_k = n$ である。

また、標本の中で各階級が占める比率

$$P_i = \frac{N_i}{n} \quad \text{を} \quad \text{標本比率} \quad \text{という。}$$

これは、 $P_1 + \dots + P_k = 1$ を満たす

これらを表にしたものを **度数分布表**。

グラフにしたものを **ヒストグラム** という。

また、各級に至るすべての度数を足したものを **累積度数** という。

P53, 54 の表、グラフをみるとわかりやすい。

問題 P55. 問1 を解け。