

第5章 統計学の基礎：復習

5.1 確率変数，確率分布について

確率変数は、通常、大文字のアルファベット（例えば、 X ）で表すのに対して、実際に起こった値（すなわち、実現値）を小文字（例えば、 x ）で表す。

確率変数には離散型確率変数と連続型確率変数がある。まず、離散型確率変数 X を考える。 X の取り得る値は分かっている。例えば、 $X = x_1, x_2, \dots, x_n$ の n 通りの値を取るものとする。それぞれの値には確率が割り当てられる。すなわち、 $\text{Prob}(X = x_i) = p_i$ と表記し、「確率変数 X が x_i を取る確率は p_i である」と読む。 p_i は確率であり、しかも、 X は x_1, x_2, \dots, x_n のいずれかの値を取るもので、 $\sum_{i=1}^n p_i = 1$ となる。また、 p_i は x_i の関数であり、 $f(x_i)$ と表すことができる。 $f(x_i)$ を確率関数と呼ぶ。 $f(x_i)$ は、(i) $f(x_i) \geq 0$ 、(ii) $\sum_{i=1}^n f(x_i) = 1$ を満たす関数でなければならない。

X をサイコロを投げて出た目としよう。このとき、 X の取る値は 1, 2, 3, 4, 5, 6 で、それぞれの目が出る確率は $\frac{1}{6}$ となる。したがって、 $x_i = i$ 、 $p_i = \frac{1}{6}$ 、 $i = 1, 2, 3, 4, 5, 6$ となる。

X が連続型確率変数の場合は、ある値 a から別の値 b までの区間に入る確率 $\text{Prob}(a < X < b)$ という意味になる（ただし、 $a < b$ ）。この場合、 $f(x)$ 、 $x = a$ 、 $x = b$ 、 x 軸で囲まれた面積が確率を表すことになる。すなわち、

$$\text{Prob}(a < X < b) = \int_a^b f(x)dx,$$

となり、 $f(x)$ を確率密度関数、または、密度関数と呼ぶ。 $f(x)$ は、(i) $f(x) \geq 0$ 、(ii) $\int_{-\infty}^{\infty} f(x)dx = 1$ を満たす連続関数でなければならない。

離散型の $f(\cdot)$ と連続型の $f(\cdot)$ の違いは、前者は $f(\cdot)$ そのものが確率を表すのに対して、後者の $f(\cdot)$ は面積が確率を表す（すなわち、連続型の $f(\cdot)$ の高さ

は確率を表さない)。

分布関数 (累積分布関数)： 分布関数 (累積分布関数) $F(x)$ は、

$$F(x) = \text{Prob}(X \leq x) = \begin{cases} \sum_{i=1}^r f(x_i) & X \text{ が離散型確率変数のとき} \\ \int_{-\infty}^x f(t)dt & X \text{ が連続型確率変数のとき} \end{cases}$$

ただし、離散型の場合、 r は $x_r \leq x < x_{r+1}$ となる r である。すなわち、離散型の場合、 $F(x)$ は 0 と 1 の間の階段状 (階段関数) となる。

同時確率分布： 2つの確率変数 X, Y を考える。離散型の場合、 X の取る値を x_1, x_2, \dots, x_n とし、 Y の取る値を y_1, y_2, \dots, y_m としたとき、 X が x_i を取り、かつ、 Y が y_j を取る確率を同時確率分布と呼び、下記のように表す。

$$\text{Prob}(X = x_i, Y = y_j) = p_{ij}$$

p_{ij} は x_i, y_j の関数となり、 $p_{ij} = f(x_i, y_j)$ と表す。 $f(x_i, y_j)$ を同時確率関数と呼ぶ。

連続型の場合は、 X が c と d の間の値 (ただし、 $a < b$) を取り、かつ、 Y が c と d の間の値 (ただし、 $c < d$) を取る確率は、下記のように表される。

$$\text{Prob}(a < X < b, c < Y < d) = \int_a^b \int_c^d f(x, y)dydx$$

$f(x, y)$ を同時確率密度関数 (または、同時密度関数) と呼ぶ。

5.2 期待値・分散・共分散の定義・定理

5.2.1 期待値の定義

定義(期待値, 1変数): 確率変数 X , ある関数 $g(\cdot)$ とするとき, $g(X)$ の期待値は次のように定義される。

$$E(g(X)) = \begin{cases} \sum_{i=1}^n g(x_i)f(x_i), & X \text{ が離散型確率変数のとき} \\ \int_{-\infty}^{\infty} g(x)f(x)dx, & X \text{ が連続型確率変数のとき} \end{cases} \quad (5.1)$$

ただし, $f(\cdot)$ は確率関数 (離散型のとき), または, 密度関数 (連続型のとき) を表す。

定義(期待値, 2変数): 確率変数 X, Y , ある関数 $g(\cdot, \cdot)$ とするとき, $g(X, Y)$ の期待値は次のように定義される。

$$E(g(X, Y)) = \begin{cases} \sum_{i=1}^n \sum_{j=1}^m g(x_i, y_j)f(x_i, y_j), & X, Y \text{ が離散型確率変数のとき} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y)f(x, y)dydx, & X, Y \text{ が連続型確率変数のとき} \end{cases} \quad (5.2)$$

ただし, $f(\cdot, \cdot)$ は確率関数 (離散型のとき), または, 密度関数 (連続型のとき) を表す。

2変数 (X, Y) を n 変数 (X_1, X_2, \dots, X_n) に拡張することも出来る。

5.2.2 期待値の定理

定理(1変数): X を確率変数とする。 $a + bX$ の期待値は,

$$E(a + bX) = a + bE(X), \quad (5.3)$$

となる。ただし, a, b は定数とする。 $g(X) = a + bX$ に対応する。

定理 (2変数)： X, Y を確率変数とする。 $X + Y$ の期待値は,

$$E(X + Y) = E(X) + E(Y), \quad (5.4)$$

となる。 $g(X, Y) = X + Y$ に対応する。

定理 (多変数)： n 個の確率変数 X_1, X_2, \dots, X_n を考える。このとき, $\sum_{i=1}^n c_i X_i$ の平均は,

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i), \quad (5.5)$$

となる。

5.2.3 分散・共分散の定義・定理

定義 (1変数)： X を確率変数とする。 X の分散 $\sigma^2 = V(X)$ は,

$$\sigma^2 = V(X) = E((X - \mu)^2), \quad (5.6)$$

である。ただし, $\mu = E(X)$ とする。 $g(X) = (X - \mu)^2$ に対応する。

定義 (1変数)： X を確率変数とする。 X の標準偏差 σ は,

$$\sigma = \sqrt{V(X)} \quad (5.7)$$

である。

定理 (1変数)： X を確率変数とする。 X の分散は,

$$V(X) = E(X^2) - \mu^2, \quad (5.8)$$

と書き換えられる。ただし, $\mu = E(X)$ とする。

定理 (1変数)： X を確率変数とする。 $a + bX$ の分散は,

$$V(a + bX) = V(bX) = b^2 V(X), \quad (5.9)$$

となる。ただし, a, b は定数とする。

定理 (1 変数): X を平均 μ , 分散 σ^2 の確率変数とする。 $Z = \frac{X - \mu}{\sigma}$ について,

$$E(Z) = 0, \quad V(Z) = 1, \quad (5.10)$$

となる。この変換を標準化, または, 基準化と呼ぶ。

定義 (2 変数): X, Y を確率変数とする。 X と Y の共分散 $\sigma_{XY} = \text{Cov}(X, Y)$ は,

$$\sigma_{XY} = \text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y)), \quad (5.11)$$

となる。 $\text{Cov}(X, Y)$ について, $g(X, Y) = (X - \mu_X)(Y - \mu_Y)$ に対応する。

定義 (2 変数): X, Y を確率変数とする。 X と Y の相関係数 ρ_{XY} は,

$$\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} = \frac{\sigma_{XY}}{\sigma_X\sigma_Y}, \quad (5.12)$$

となる。ただし, $\sigma_X^2 = V(X)$, $\sigma_Y^2 = V(Y)$ とする。

定理 (2 変数): X, Y を確率変数とする。 X と Y の共分散は,

$$\text{Cov}(X, Y) = E(XY) - \mu_X\mu_Y, \quad (5.13)$$

と書き換えられる。 $E(XY)$ について, $g(X, Y) = XY$ に対応する。

定理 (2 変数): X, Y を確率変数とする。 $X + Y$ の分散は,

$$V(X + Y) = V(X) + 2\text{Cov}(X, Y) + V(Y), \quad (5.14)$$

となる。

定理 (2 変数): X, Y を確率変数とする。 X と Y が独立のとき, X と Y の共分散は,

$$\text{Cov}(X, Y) = 0, \quad (5.15)$$

となる。

定理 (2変数)： X, Y を確率変数とする。 X と Y が独立のとき、 $X + Y$ の分散は、

$$V(X + Y) = V(X) + V(Y), \quad (5.16)$$

となる。

定理 (多変数)： n 個の独立な確率変数 X_1, X_2, \dots, X_n を考える。このとき、 $\sum_{i=1}^n c_i X_i$ の分散は、

$$V\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i^2 V(X_i), \quad (5.17)$$

となる。

5.3 正規分布について

確率変数 X の密度関数 $f(x)$ が、

$$f(x) = (2\pi\sigma^2)^{-1/2} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right),$$

となるとき、 $f(x)$ を正規分布と呼ぶ。ただし、 $\exp(x) = e^x$ である。 e は自然対数の底と呼ばれ、 $e = \lim_{n \rightarrow \infty} \left(1 + \frac{1}{n}\right)^n = 2.7182818284590452353602874713\dots$ と定義される。

上記の正規分布は、

$$E(X) = \mu, \quad V(X) = \sigma^2,$$

となる（期待値の定義通りに計算すればよい）。

確率変数 X が上記の密度関数 $f(x)$ となるとき、 $X \sim N(\mu, \sigma^2)$ と表す。 $X \sim N(\mu, \sigma^2)$ とは、「 X は平均 μ 、分散 σ^2 の正規分布に従う」という意味である。すなわち、 N は正規分布 (Normal distribution) のアルファベットの頭文字で、 \sim は「に従う」と読む。

定理（標準化，基準化）： (5.10) のように X を基準化する。

$$X \sim N(\mu, \sigma^2) \quad \text{のとき,} \quad Z = \frac{X - \mu}{\sigma} \sim N(0, 1) \quad (5.18)$$

基準化によって， X がどの分布に従う確率変数であっても，平均 0，分散 1 に変換することができるということを (5.10) の定理は示している。(5.18) では，さらに進んで， X が正規分布であれば， Z も正規分布となるということを言っている。この証明は，変数変換（置換積分）を利用して証明することになる（本書では証明略）。平均 0，分散 1 の正規分布 $N(0, 1)$ は，標準正規分布と呼ばれる。

標準正規分布の確率分布表があれば，一般の正規分布の確率を得ることができる。すなわち， μ と σ^2 が既知とするとき， Z が z より大きい確率 $\text{Prob}(Z > z)$ について， $\text{Prob}(Z > z) = \text{Prob}(X > \mu + z\sigma)$ となる。同様に， X が x より大きい確率 $\text{Prob}(X > x)$ について， $\text{Prob}(X > x) = \text{Prob}\left(Z > \frac{x - \mu}{\sigma}\right)$ となる。174 ページの付表 1 を用いると，標準正規分布の確率，すなわち， $\text{Prob}(Z > z)$ を求めることができる。

(5.5) 式と (5.16) 式によって， n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の分布（平均，分散が同じ分布）に従うとき， $\sum_{i=1}^n c_i X_i$ の平均，分散は，

$$E\left(\sum_{i=1}^n c_i X_i\right) = \mu \sum_{i=1}^n c_i, \quad V\left(\sum_{i=1}^n c_i X_i\right) = \sigma^2 \sum_{i=1}^n c_i^2$$

となる。ただし，すべての i について $\mu = E(X_i), \sigma^2 = V(X_i)$ とする。

n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布に従うものとする。すなわち，すべての i について $X_i \sim N(\mu, \sigma^2)$ とする。このとき，

$$\sum_{i=1}^n c_i X_i \sim N\left(\mu \sum_{i=1}^n c_i, \sigma^2 \sum_{i=1}^n c_i^2\right)$$

となる。すなわち，正規分布に従う確率変数の加重和もまた正規分布となる。この証明はそれほど簡単ではなく，積率母関数を利用して証明することになる（本書では証明略）。

特に、標本平均 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ を考えると、

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

となる（すべての i について、 $c_i = \frac{1}{n}$ の場合を考えればよい）。

5.4 統計値・統計量，推定値・推定量について

1. 理論標本，理論観測値 $\Rightarrow X_1, X_2, \dots, X_n \Rightarrow$ 確率変数
2. 実現された標本，実現された観測値，実現値，観測値 $\Rightarrow x_1, x_2, \dots, x_n \Rightarrow$ 観測データ

1. 理論観測値 X_1, X_2, \dots, X_n の関数 \Rightarrow 統計量
2. すべての i について、 $\mu = E(X_i)$ と仮定する。
3. 母平均 μ の推定に使われる統計量 $\Rightarrow \mu$ の推定量

(a) $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ は μ の推定量

(b) $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ は σ^2 の推定量

4. 実現された標本を用いて実際に計算された推定量の値 \Rightarrow 推定値

(a) $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ は μ の推定値

(b) $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ は σ^2 の推定値

5. μ や σ^2 の推定量の候補は無数に考えられる。

5.5 大数の法則と中心極限定理

5.5.1 大数の法則

大数の法則：その**1** n 個の確率変数 X_1, X_2, \dots, X_n は互いに独立ですべて同じ分布にしたがい、すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$ とする。 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ (すなわち、標本平均) とする。

$n \rightarrow \infty$ のとき、

$$\bar{X} \rightarrow \mu$$

となる。

大数の法則：その**2** n 個の確率変数 X_1, X_2, \dots, X_n を考える (互いに独立である必要はなく、同じ分布である必要もない)。

$$\mu = \lim_{n \rightarrow \infty} \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) < \infty, \quad \sigma^2 = \lim_{n \rightarrow \infty} \frac{1}{n} V\left(\sum_{i=1}^n X_i\right) < \infty$$

とする。

$n \rightarrow \infty$ のとき、

$$\bar{X} \rightarrow \mu$$

となる。

5.5.2 中心極限定理

中心極限定理：その**1** n 個の確率変数 X_1, X_2, \dots, X_n は互いに独立ですべて同じ分布にしたがい、すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$, $V(X_i) = \sigma^2$ とする。 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ とする。

$n \rightarrow \infty$ のとき、

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow N(0, 1)$$

となる。 $E(\bar{X}) = \mu$, $V(\bar{X}) = \sigma^2/n$ に注意せよ。

中心極限定理：その2 n 個の確率変数 X_1, X_2, \dots, X_n を考える（互いに独立である必要はなく、同じ分布である必要もない）。

$$\mu = \lim_{n \rightarrow \infty} \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) < \infty, \quad \sigma^2 = \lim_{n \rightarrow \infty} \frac{1}{n} V\left(\sum_{i=1}^n X_i\right) < \infty$$

とする。

$n \rightarrow \infty$ のとき、

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow N(0, 1)$$

となる。

5.6 推定量の望ましい性質

$\hat{\alpha}, \hat{\beta}$ の性質を求めるために

5.6.1 不偏性

ある母集団のある母数 θ に対して、 θ の推定量として $\hat{\theta}$ を考える。このとき、

$$E(\hat{\theta}) = \theta$$

となるとき、 $\hat{\theta}$ は θ の不偏推定量であると言う。 $\hat{\theta}$ は不偏性を持つと言う。 $E(\hat{\theta}) - \theta$ は偏りと定義される。

n 個の確率変数 X_1, X_2, \dots, X_n に関して、すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$ とするとき、標本平均 \bar{X} は μ の不偏推定量である。

証明：

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu$$

このように、 $E(\bar{X}) = \mu$ なので、標本平均 \bar{X} は μ の不偏推定量となる。

5.6.2 有効性 (最小分散性)

ある母数 θ に対して, $\hat{\theta}_1$ と $\hat{\theta}_2$ の 2 つの不偏推定量を考える。このとき, $V(\hat{\theta}_1) \leq V(\hat{\theta}_2)$ が成り立つとき, $\hat{\theta}_1$ は $\hat{\theta}_2$ より有効であると言う。

ある母数 θ に対して, 可能なすべての不偏推定量を考え, $\hat{\theta}$ が最も小さな分散を持つ不偏推定量であるとする。このとき, $\hat{\theta}$ を最小分散不偏推定量, または, 最良不偏推定量と言う。

一般に, 有効推定量が存在するとは限らない。代わりに, 推定量 $\sum_{i=1}^n c_i X_i$ (すなわち, 線形推定量) の中で最も小さい分散を持つ推定量を求めることを考える。この推定量を最良線形不偏推定量と呼ぶ。

標本平均 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ は不偏推定量の中で最も小さな分散を持つ推定量である。

証明:

期待値を取ると,

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i) = \mu \sum_{i=1}^n c_i$$

となる。 $\sum_{i=1}^n c_i X_i$ が不偏推定量になるためには $\sum_{i=1}^n c_i = 1$ が必要となる。分散は,

$$V\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n V(c_i X_i) = \sum_{i=1}^n c_i^2 V(X_i) = \sigma^2 \sum_{i=1}^n c_i^2$$

となる。

したがって, 最良線形不偏推定量を得るためには, $\sum_{i=1}^n c_i = 1$ の条件のもとで, $\sum_{i=1}^n c_i^2$ を最小にする c_1, c_2, \dots, c_n を求めればよい。ラグランジュ未定乗数法を用いれば, $c_i = \frac{1}{n}$ が得られる。

5.6.3 一貫性

ある母数 θ について推定量 $\hat{\theta}$ を考える。 n 個の標本から構成された推定量を $\hat{\theta}^{(n)}$ と定義する。数列 $\hat{\theta}^{(1)}, \hat{\theta}^{(2)}, \dots, \hat{\theta}^{(n)}, \dots$ を考える。十分大きな n について、 $\hat{\theta}^{(n)}$ が θ に確率的に収束するとき、 $\hat{\theta}$ は θ の一致推定量であると言う。

$$\hat{\theta} \rightarrow \theta, \quad \text{または,} \quad \text{plim } \hat{\theta} = \theta,$$

と表現する。plim とは probability limit の略である。

$E(\hat{\theta}) = \theta$ とする。 $n \rightarrow \infty$ のとき $V(\hat{\theta}) \rightarrow 0$ が成り立てば、 $\hat{\theta}$ は θ の一致推定量である。

μ の推定量 \bar{X} を調べる。

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

である。

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

となる。 $n \rightarrow \infty$ のとき、

$$V(\bar{X}) = \frac{\sigma^2}{n} \rightarrow 0$$

となるので、 \bar{X} は μ の一致推定量であると言える。

5.7 χ^2 分布

m 個の確率変数 Z_1, Z_2, \dots, Z_m は、互いに独立な標準正規分布に従うものとする。このとき、 $Y = \sum_{i=1}^m Z_i^2$ は、自由度 m の χ^2 分布に従う。

$Y \sim \chi^2(m)$, または、 $Y \sim \chi_m^2$ と表記する。

χ^2 (カイ二乗) 分布表から確率を求める。

$Y \sim \chi^2(m)$ のとき、 $E(Y) = m$, $V(Y) = 2m$ となる。(証明略)

1. 2つの独立な χ^2 分布からの確率変数 X, Y を考える。 $X \sim \chi^2(n)$, $Y \sim \chi^2(m)$ とする。このとき、 $Z = X + Y \sim \chi^2(n + m)$ となる。(証明略)

2. n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布 $N(\mu, \sigma^2)$ に従うものとする。

3. $\frac{X_i - \mu}{\sigma} \sim N(0, 1)$ なので、 $\left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2(1)$ となる。
 $\frac{X_1 - \mu}{\sigma}, \frac{X_2 - \mu}{\sigma}, \dots, \frac{X_n - \mu}{\sigma}$ はそれぞれ独立なので、

$$\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2(n)$$

となる。

4. μ を \bar{X} に置き換えると、

$$\sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sigma}\right)^2 \sim \chi^2(n-1)$$

となる。(証明は後述)

さらに、

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

を定義すると、

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

となる。 S^2 は σ^2 の不偏推定量である(後述)。

5. すなわち、

$$E\left(\frac{(n-1)S^2}{\sigma^2}\right) = n-1 \quad V\left(\frac{(n-1)S^2}{\sigma^2}\right) = 2(n-1),$$

となる。

5.8 t 分布

正規分布の重要な定理： n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布 $N(\mu, \sigma^2)$ に従うものとする。このとき、

$$\sum_{i=1}^n c_i X_i \sim N\left(\mu \sum_{i=1}^n c_i, \sigma^2 \sum_{i=1}^n c_i^2\right)$$

となる。ただし、 c_1, c_2, \dots, c_n は定数とする。

t 分布： Z を標準正規分布、 Y を自由度 m の χ^2 分布に従い、両者は独立な確率変数とする。このとき、 $U = \frac{Z}{\sqrt{Y/m}}$ は、自由度 m の t 分布に従う。

$U \sim t(m)$ 、または、 $U \sim t_m$ と表記する。

$U \sim t(m)$ のとき、 $m > 1$ について $E(U) = 0$ 、 $m > 2$ について $V(U) = \frac{m}{m-2}$ となる。(証明略)

t 分布表から確率を求める。(表 10.1.3 を見よ)

1. ゼロを中心に左右対称。($E(U) = 0$)
2. t 分布は、標準正規分布より裾野の広い分布(なぜなら、 $V(U) = \frac{m}{m-2} > 1$)
3. $m \rightarrow \infty$ のとき、 $t(m) \rightarrow N(0, 1)$ となる。(期待値は $m > 1$ について $E(U) = 0$ 、分散は $V(U) = \frac{m}{m-2} \rightarrow 1$)

5.9 標本平均 \bar{X} の分布

X_1, X_2, \dots, X_n の n 個の確率変数は、互いに独立で、平均 μ 、分散 σ^2 の正規分布に従うものとする。

1. $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$ なので、 $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$ となる。
2. $\frac{(n-1)S^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi^2(n-1)$ である。(証明は略)

3. $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ と $\frac{(n-1)S^2}{\sigma^2}$ は独立。(証明は略)

すなわち, \bar{X} と S^2 は独立。

4. したがって,

$$\frac{\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}}{\sqrt{\frac{(n-1)S^2}{\sigma^2} / n - 1}} = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

を得る。

重要な結果は,

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

ただし, $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$, $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ である。

σ^2 を S^2 に置き換えると, 正規分布から t 分布になる。

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1) \implies \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

5.10 区間推定 (信頼区間)

\bar{X} の分布を利用して, μ の信頼区間を求める。

1. \bar{X} の分布は以下の通り。

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

となる。

2. $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ を自由度 $n-1$ の t 分布の上から $100 \times \frac{\alpha}{2}$ % 点, $100 \times (1 - \frac{\alpha}{2})$ % 点の値とする。このとき,

$$\text{Prob}\left(t_{1-\alpha/2}(n-1) < \frac{\bar{X} - \mu}{S/\sqrt{n}} < t_{\alpha/2}(n-1)\right) = 1 - \alpha$$

となる。ただし、自由度と α が決まれば、 $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ は t 分布表から得られる。

3. t 分布は左右対称なので、

$$\begin{aligned} t_{1-\alpha/2}(n-1) &= -t_{\alpha/2}(n-1) & t_{\alpha/2}(n-1) &= |t_{1-\alpha/2}(n-1)| \\ t_{1-\alpha/2}(n-1) &= -|t_{\alpha/2}(n-1)| \end{aligned}$$

となる。

4. 書き直して、

$$\text{Prob}\left(\bar{X} - t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}} < \mu < \bar{X} + t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

となる。

5. μ が区間 $(\bar{X} - t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}}, \bar{X} + t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}})$ にある確率は $1 - \alpha$ である。

6. 推定量 \bar{X} , S^2 をその推定値 \bar{x} , s^2 で置き換える。ただし、 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$,

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ とする。}$$

7. 区間 $(\bar{x} - t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}, \bar{x} + t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}})$ を信頼係数 $1 - \alpha$ の信頼区間といい、 $\bar{x} - t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}$ を信頼下限、 $\bar{x} + t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}$ を信頼上限と呼ぶ。

5.11 仮説検定

\bar{X} の分布を利用して、 μ の仮説検定を行う。

1. 帰無仮説 $H_0: \mu = \mu_0$ 対立仮説 $H_1: \mu \neq \mu_0$

2. 帰無仮説 $H_0: \mu = \mu_0$ が正しいもとの分布は、

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1)$$

となる。

3. $\text{Prob}(t_{1-\alpha/2}(n-1) < \frac{\bar{X} - \mu_0}{S/\sqrt{n}} < t_{\alpha/2}(n-1)) = 1 - \alpha$

$t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ をそれぞれ自由度 $n-1$ の t 分布の上から $100 \times \frac{\alpha}{2}$ % 点, $100 \times \frac{1-\alpha}{2}$ % 点の値とする。

自由度と α が決まれば, $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ は t 分布表から得られる。

4. α を有意水準と呼ぶ。慣習的に $\alpha = 0.01, 0.05$ が使われる。

5. $-t_{\alpha/2}(n-1) > \frac{\bar{X} - \mu_0}{S/\sqrt{n}}$, または, $\frac{\bar{X} - \mu_0}{S/\sqrt{n}} > t_{\alpha/2}(n-1)$ ならば, 帰無仮説 $H_0: \mu = \mu_0$ は, 分布の端にあり, 起こりにくいと考える。

\implies 有意水準 α で帰無仮説 $H_0: \mu = \mu_0$ を棄却する。

6. 実際の検定手続:

(a) \bar{X}, S^2 を実績値で置き換えて,

$$\frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

を得る。ただし, $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ とする。

(b) $-t_{\alpha/2}(n-1) > \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$, または, $\frac{\bar{x} - \mu_0}{s/\sqrt{n}} > t_{\alpha/2}(n-1)$ ならば, 有意水準 α で帰無仮説 $H_0: \mu = \mu_0$ を棄却する。