

### 13 比率データの分析と分割表

(この章のポイント)

- 1) 比率のデータは二項分布を前提とする。
- 2) 二項分布は、標準化して正規分布で近似する。
- 3) 分割表や適合度検定では標準化して二乗和をとり、カイ二乗分布で近似する。

#### 13.1 比率データの分析

まず、ドラマを見る可能性がある調査の対象から、独立に  $n$  人の調査を実施し、見た人を 1, 見てない人を 0 とすれば、その結果はベルヌーイ試行 (5.2 節) と考えられます。この場合、見ている人の総数  $X$  は二項分布  $B(n, P)$  (5.3 節) に従います。このとき、母比率  $P$  は真の視聴率を意味します。これに対して、標本比率  $p = X/n$  が母比率  $P$  の点推定量であり、一般的に **視聴率** といわれるのはこの値です。

$$\text{点推定量} : \hat{P} = p = \frac{X}{n}$$

データ数  $n$  が比較的小さい場合には、確率は二項分布の確率関数を用いれば直接計算できますが、比較的大きい場合にはこれが難しいため正規分布で近似します。

##### 13.1.1 正規分布による近似法

二項分布を正規分布で近似できる条件として、以下の条件があります。

$$\text{正規近似条件} : np \geq 5, n(1-p) \geq 5 \quad (13.1)$$

この条件が成り立つ時に、標本比率を正規分布で近似する方法を紹介します。二項分布に従う確率変数  $X$  の母平均と母分散は、5 章の (5.5) 式より

$$E(X) = nP, \quad \text{Var}(X) = nP(1-P)$$

です。したがって、標本比率  $p$  の母平均と母分散は、

$$E(p) = P, \quad \text{Var}(p) = P(1-P)/n \quad (13.2)$$

とわかります。正規分布で近似するとき、標本比率  $p$  を標準化した値  $u$  が、標準正規分布  $N(0, 1)$  に (近似的に) 従うことを仮定します。

$$\text{仮定 1} : u = \frac{p - P}{\sqrt{P(1-P)/n}} \sim N(0, 1) \quad (13.3)$$

まず、母比率  $P$  の区間推定を行うには、分母の  $P$  に  $p$  を代入します。

$$\text{仮定 2} : u = \frac{p - P}{\sqrt{p(1-p)/n}} \sim N(0, 1) \quad (13.4)$$

この (13.4) 式を、 $P(-1.960 \leq u \leq 1.960) = 0.95$  に代入すると、

$$P\left(-1.960 \leq \frac{p - P}{\sqrt{p(1-p)/n}} \leq 1.960\right) = 0.95$$

となります。この式を分子の  $P$  に関して解くことで、次の  $P$  の信頼率 **95%** の信頼区間 が得られます。

$$P\left(p - 1.960\sqrt{p(1-p)/n} \leq P \leq p + 1.960\sqrt{p(1-p)/n}\right) = 0.95 \quad (13.5)$$

次に、母比率  $P$  が従来の比率  $P_0$  より大きいかどうか調べたいとき、帰無仮説は等号、対立仮説は立証したいことなので、

$$\text{帰無仮説 } H_0 : P = P_0$$

$$\text{対立仮説 } H_1 : P > P_0$$

の仮説を立てます。このとき、(13.3) 式中の  $P$  に  $P_0$  を代入した  $u_0$  を求めます。

$$\text{検定統計量} : u_0 = \frac{p - P_0}{\sqrt{P_0(1 - P_0)/n}} \quad (13.6)$$

この  $u_0$  は、帰無仮説  $P = P_0$  の下では、標準正規分布  $N(0, 1)$  に従います。そこで、次の棄却域を設定すると、有意水準は 5% で、検出力が高い手法となります。

$$\text{棄却域 } R : u_0 \geq u(0.05) = 1.645$$

また、立証したいことが、従来  $P_0$  より母比率  $P$  が小さくなっているかどうかや、異なっているかどうかを調べたいときは、表 13.1 のように行います。

表 13.1 興味の対象（対立仮説）による検定方法の違い

検定名称	興味の対象	帰無仮説	対立仮説	棄却域
両側検定	異なるか	$P = P_0$	$P \neq P_0$	$ u_0  \geq u(0.025) = 1.960$
右片側検定	大きい	$P = P_0$	$P > P_0$	$u_0 \geq u(0.05) = 1.645$
左片側検定	小さい	$P = P_0$	$P < P_0$	$u_0 \leq -u(0.05) = -1.645$

### 13.1.2 直接計算法による母比率の分析

標本の大きさ  $n$  が小さくて、 $np < 5$  のときは、正規分布への近似条件 (13.1) が成り立ちません。このとき次の定理より、区間推定が行えます（章末問題 13.1.2）。

**定理 13.1**  $X$  が二項分布  $B(n, p)$  に従うとき、以下の関係式が成り立つ。

$$P(X \geq x) = \frac{1}{B(x, n - x + 1)} \int_0^p t^{x-1} (1 - t)^{n-x} dt, \quad x = 1, 2, \dots, n \quad (13.7)$$

ここで、 $(n, x)$  のときの信頼限界  $(P_L, P_U)$  は、 $P(X \geq x) = 0.025$  となる  $p$  と、 $P(X \leq x) = 0.025$  となる  $p$  と考えれば、次の 正確な 95% 区間推定 が得られます。

$$\frac{\phi_2}{\phi_1 F(\phi_1, \phi_2; 0.025) + \phi_2} \leq P \leq \frac{\phi'_2}{\phi'_1 / F(\phi'_2, \phi'_1; 0.025) + \phi'_2} \quad (13.8)$$

ただし、 $\phi_1 = 2(n - x + 1)$ ,  $\phi_2 = 2x$ ,  $\phi'_1 = 2(n - x)$ ,  $\phi'_2 = 2(x + 1)$ 。

## 13.2 2群の比率の違いの分析

2つの母集団における母比率  $P_A, P_B$  に関して、次の例題の状況を考えて下さい。

### 13.2.1 2群の標本比率の差の分布

母集団  $A$  では  $m$  人のうち  $X$  人、母集団  $B$  では  $n$  人のうち  $Y$  人である場合、各々の母集団ごとに、標本比率に関して母平均と母分散を求めて、以下のように近似できます。

$$p_A = \frac{X}{m} \sim N\left(P_A, \frac{P_A(1 - P_A)}{m}\right), \quad p_B = \frac{Y}{n} \sim N\left(P_B, \frac{P_B(1 - P_B)}{n}\right)$$

これらの差を考えると、12.2 節と同様に、以下の式が得られます。

$$p_A - p_B \sim N\left(P_A - P_B, \frac{P_A(1 - P_A)}{m} + \frac{P_B(1 - P_B)}{n}\right) \quad (13.9)$$

これを標準化すると、次の式が導かれます。

$$\text{仮定 1 : } u = \frac{(p_A - p_B) - (P_A - P_B)}{\sqrt{\frac{P_A(1 - P_A)}{m} + \frac{P_B(1 - P_B)}{n}}} \sim N(0, 1) \quad (13.10)$$

この性質を用いて、比率の差に関する、検定や区間推定が行われます。

### 13.2.2 2群の比率の差の推定

推定の際には、上記の (13.10) 式の分母の  $P_A, P_B$  を  $p_A, p_B$  で置き換えます。

$$\text{仮定 2 : } u = \frac{(p_A - p_B) - (P_A - P_B)}{\sqrt{p_A(1 - p_A)/m + p_B(1 - p_B)/n}} \sim N(0, 1) \quad (13.11)$$

このとき、母比率  $P_A - P_B$  の区間推定は、以下のように導きます。まず、

$$P(-1.960 \leq u \leq 1.960) = 0.95$$

の式の  $u$  に (13.11) 式を代入して、次の式を導きます。

$$P\left(-1.960 \leq \frac{(p_A - p_B) - (P_A - P_B)}{\sqrt{p_A(1 - p_A)/m + p_B(1 - p_B)/n}} \leq 1.960\right) = 0.95$$

この ( ) 内を  $P_A - P_B$  に関して解き直すことで、以下の信頼限界を得ます。

$$\text{点推定値 : } \widehat{P_A - P_B} = p_A - p_B$$

$$\text{信頼限界 : } p_A - p_B \pm 1.960 \sqrt{\frac{p_A(1 - p_A)}{m} + \frac{p_B(1 - p_B)}{n}}$$

### 13.2.3 2群の比率の差の検定

$P_A$  より  $P_B$  が大きいかどうかを調べる場合は、以下の仮説となります。

$$\text{帰無仮説 } H_0: P_A = P_B$$

$$\text{対立仮説 } H_1: P_A < P_B$$

検定に用いる統計量 (検定統計量) は、帰無仮説  $P_A = P_B$  の場合を考えます。そこで、(13.10) 式の  $P_A, P_B$  に共通の  $\bar{p}$  を代入すると、以下の式となります。

$$\text{検定統計量 : } u_0 = \frac{p_A - p_B}{\sqrt{\left(\frac{1}{m} + \frac{1}{n}\right)\bar{p}(1 - \bar{p})}} \quad (13.12)$$

ただし、 $\bar{p}$  とは、次の式で計算される併合比率です。

$$\text{併合比率 : } \bar{p} = \frac{x + y}{m + n}$$

対立仮説ごとに、どのように棄却域を設定するかは、次の表 13.4 のように行います。

表 13.4 興味の対象 (対立仮説) による検定方法の違い

検定名称	興味の対象	帰無仮説	対立仮説	棄却域
両側検定	異なるか	$P_A = P_B$	$P_A \neq P_B$	$ u_0  \geq u(0.025) = 1.960$
右片側検定	大きい	$P_A = P_B$	$P_A > P_B$	$u_0 \geq u(0.05) = 1.645$
左片側検定	小さい	$P_A = P_B$	$P_A < P_B$	$u_0 \leq -u(0.05) = -1.645$

### 13.3 分割表

例題 13.6 4 台の機械で作った製品の品質を 3 つの級に分類した部品数データを、表 13.5 の形式で集計した。有意水準 5% で品質に差があるかどうかを検定せよ。

表 13.5 機械ごとの部品数

	1 級品	2 級品	3 級品	計
$A_1$	13	31	6	50
$A_2$	27	15	8	50
$A_3$	29	16	5	50
$A_4$	20	19	11	50
計	89	81	30	200

表 13.6  $a \times b$  分割表

	$B_1$	$B_2$	$\cdots$	$B_b$	$T_{i\bullet}$
$A_1$	$x_{11}$	$x_{12}$	$\cdots$	$x_{1b}$	$T_{1\bullet}$
$A_2$	$x_{21}$	$x_{22}$	$\cdots$	$x_{2b}$	$T_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$
$A_a$	$x_{a1}$	$x_{a2}$	$\cdots$	$x_{ab}$	$T_{a\bullet}$
$T_{\bullet j}$	$T_{\bullet 1}$	$T_{\bullet 2}$	$\cdots$	$T_{\bullet b}$	$T$

#### 13.3.1 分割表におけるデータ

一般的に、2 つの分類項目  $A, B$  で  $A$  は  $A_1 \sim A_a$  の  $a$  種類、 $B$  は  $B_1 \sim B_b$  の  $b$  種類に分類して、その度数を  $x_{ij}$  とおくと、上記の表 13.6 の形式のデータが得られます。これを 分割表データ とい、 $x_{ij}$  は 観測度数 と呼ばれます。また、 $A_i B_j$  のことを セル といいます。

#### 13.3.2 分割表における仮説検定

##### 1) 帰無仮説と対立仮説

帰無仮説  $H_0$  :  $A$  と  $B$  に関係はない (すべての  $i, j$  で、 $p_{ij} = p_{i\bullet} p_{\bullet j}$ )

対立仮説  $H_1$  :  $A$  と  $B$  に関係がある (ある  $i, j$  で、 $p_{ij} \neq p_{i\bullet} p_{\bullet j}$ )

ここで、 $p_{ij} = P(A_i B_j)$ ,  $p_{i\bullet} = P(A_i)$ ,  $p_{\bullet j} = P(B_j)$  とします。

##### 2) 期待度数

$A_i$  の確率  $p_{i\bullet}$ ,  $B_j$  の確率  $p_{\bullet j}$  は、 $\hat{p}_{i\bullet} = \frac{T_{i\bullet}}{T}$ ,  $\hat{p}_{\bullet j} = \frac{T_{\bullet j}}{T}$  の式で推定します。

帰無仮説の下では  $\hat{p}_{ij} = \hat{p}_{i\bullet} \hat{p}_{\bullet j}$  と考えると、起こると期待される度数 (期待度数) が計算できます。

$$\text{期待度数} : t_{ij} = T \hat{p}_{ij} = \frac{T_{i\bullet} \times T_{\bullet j}}{T}$$

##### 3) 検定統計量と棄却域

この観測度数と期待度数の違いを、次の式で評価すると、帰無仮説の下で、自由度  $\phi = (a - 1)(b - 1)$  に近似的に従うことがわかっています。(章末問題 13.4 参照)

$$\text{検定統計量} : \chi_0^2 = \sum_{i=1}^a \sum_{j=1}^b \frac{(x_{ij} - t_{ij})^2}{t_{ij}}$$

そこで、次の棄却域に入れば帰無仮説を棄却して、 $A$  と  $B$  に関係があると判定します。

$$\text{棄却域 } R : \chi_0^2 \geq \chi^2(\phi, \alpha), \quad \phi = (a - 1)(b - 1)$$

### 13.4 適合度検定

適合度検定では、次の検定統計量を用います。

$$\text{検定統計量} : \chi_0^2 = \sum_{i=1}^k \frac{(x_i - t_i)^2}{t_i}$$

また、棄却域は次のように設定します。

$$\text{棄却域 } R : \chi_0^2 \geq \chi^2(\phi, \alpha), \quad \phi = k - t - 1$$

ここで、期待度数を求めるために、構造を考えて母数を推定する場合、その個数を  $t$  とします。