

## 14 一元配置分散分析

(この章のポイント)

- 1) 3つ以上の群のデータについての違いは、平方和で分析できる。
- 2) 平方和の比で分析するので、F分布で検定する。
- 3) 最適水準における母平均の区間推定はt分布が利用できる。

## 14.1 3つ以上の群のデータ

11章で1群、12章では2群のデータの比較の方法について紹介しました。しかし、臨床試験では実際の投薬用量を決めるためにも、3つ以上の用量での実験が行われています。以下の例題を見てみましょう。

**例題 14.1** 臨床試験で、対照群、低用量群、高用量群の3群比較を行う。各群  $n = 5$  人についての測定データを、表 14.1 に示す。

表 14.1 3群のデータ

群	データ $x_{ij}$	和 $T_i$	データ数 $n_i$	平均 $\bar{x}_i$	二乗和	平方和 $S_i$
対照群 $A_1$	20 25 17 18 15	95	5	19	1863	58
低用量群 $A_2$	18 17 12 14 19	80	5	16	1314	34
高用量群 $A_3$	23 26 21 19 21	110	5	22	2448	28
計	-----	285	15	--	5625	120

$a$  個の群から、各々  $n_i$  個のデータを取り、下記の仮定を設定します。

仮定： $x_{ij} \sim N(\mu_i, \sigma^2)$ ,  $i = 1, \dots, a$ ;  $j = 1, \dots, n_i$

ここで、各群のデータの母分散が同じ(等分散)であるとの仮定をおいています。もちろん、3つ以上の母分散が異なるかどうかの検定を行う手法もあります。

## 14.2 平方和の分解

各群のデータ数  $n_i \equiv n$  は一定とします。各群での母平均  $\mu_i$  について、これらが等しいかどうかを調べます。

帰無仮説： $\mu_1 = \mu_2 = \dots = \mu_a$

対立仮説：その他

まずデータのばらつきを、各群での標本平均  $\bar{x}_i$  を介して、2つの変動に分解します。

$$\text{データの分解: } x_{ij} - \bar{x} = (x_{ij} - \bar{x}_i) + (\bar{x}_i - \bar{x}) \quad (14.1)$$

一つ目は、母平均の違いを、各群での標本平均の変動  $\bar{x}_i - \bar{x}$  で捉えます。これは 群間変動 です。二つ目は、群の中での変動  $x_{ij} - \bar{x}_i$  で、誤差的なばらつきを意味します。これは 群内変動 です。これらの二乗和を、それぞれ、要因平方和 (群間平方和)  $S_A$ 、誤差平方和 (群内平方和)  $S_E$  といいます。

$$\text{要因平方和: } S_A = n \sum_{i=1}^a (\bar{x}_i - \bar{x})^2 \quad (14.2)$$

$$\text{誤差平方和: } S_E = \sum_{i=1}^a \sum_{j=1}^n (x_{ij} - \bar{x}_i)^2 \quad (14.3)$$

このことを、表 14.1 の 15 個のデータで表現すると、以下のようになります。

表 14.2 データの分解

(a) データ : $x_{ij}$		(b) 総平均 : $\bar{x}$																																				
<table style="width: 100%; border-collapse: collapse;"> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_1</math></td><td style="padding: 2px 5px;">20</td><td style="padding: 2px 5px;">25</td><td style="padding: 2px 5px;">17</td><td style="padding: 2px 5px;">18</td><td style="padding: 2px 5px;">15</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_2</math></td><td style="padding: 2px 5px;">18</td><td style="padding: 2px 5px;">17</td><td style="padding: 2px 5px;">12</td><td style="padding: 2px 5px;">14</td><td style="padding: 2px 5px;">19</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_3</math></td><td style="padding: 2px 5px;">23</td><td style="padding: 2px 5px;">26</td><td style="padding: 2px 5px;">21</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">21</td></tr> </table>	$A_1$	20	25	17	18	15	$A_2$	18	17	12	14	19	$A_3$	23	26	21	19	21	-	<table style="width: 100%; border-collapse: collapse;"> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_1</math></td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_2</math></td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_3</math></td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td><td style="padding: 2px 5px;">19</td></tr> </table>	$A_1$	19	19	19	19	19	$A_2$	19	19	19	19	19	$A_3$	19	19	19	19	19
$A_1$	20	25	17	18	15																																	
$A_2$	18	17	12	14	19																																	
$A_3$	23	26	21	19	21																																	
$A_1$	19	19	19	19	19																																	
$A_2$	19	19	19	19	19																																	
$A_3$	19	19	19	19	19																																	
(c) 群間変動 : $\bar{x}_i - \bar{x}$		(d) 群内変動 : $x_{ij} - \bar{x}_i$																																				
<table style="width: 100%; border-collapse: collapse;"> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_1</math></td><td style="padding: 2px 5px;">0</td><td style="padding: 2px 5px;">0</td><td style="padding: 2px 5px;">0</td><td style="padding: 2px 5px;">0</td><td style="padding: 2px 5px;">0</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_2</math></td><td style="padding: 2px 5px;">-3</td><td style="padding: 2px 5px;">-3</td><td style="padding: 2px 5px;">-3</td><td style="padding: 2px 5px;">-3</td><td style="padding: 2px 5px;">-3</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_3</math></td><td style="padding: 2px 5px;">3</td><td style="padding: 2px 5px;">3</td><td style="padding: 2px 5px;">3</td><td style="padding: 2px 5px;">3</td><td style="padding: 2px 5px;">3</td></tr> </table>	$A_1$	0	0	0	0	0	$A_2$	-3	-3	-3	-3	-3	$A_3$	3	3	3	3	3	+	<table style="width: 100%; border-collapse: collapse;"> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_1</math></td><td style="padding: 2px 5px;">1</td><td style="padding: 2px 5px;">6</td><td style="padding: 2px 5px;">-2</td><td style="padding: 2px 5px;">-1</td><td style="padding: 2px 5px;">-4</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_2</math></td><td style="padding: 2px 5px;">2</td><td style="padding: 2px 5px;">1</td><td style="padding: 2px 5px;">-4</td><td style="padding: 2px 5px;">-2</td><td style="padding: 2px 5px;">3</td></tr> <tr><td style="border-right: 1px solid black; padding: 2px 5px;"><math>A_3</math></td><td style="padding: 2px 5px;">1</td><td style="padding: 2px 5px;">4</td><td style="padding: 2px 5px;">-1</td><td style="padding: 2px 5px;">-3</td><td style="padding: 2px 5px;">-1</td></tr> </table>	$A_1$	1	6	-2	-1	-4	$A_2$	2	1	-4	-2	3	$A_3$	1	4	-1	-3	-1
$A_1$	0	0	0	0	0																																	
$A_2$	-3	-3	-3	-3	-3																																	
$A_3$	3	3	3	3	3																																	
$A_1$	1	6	-2	-1	-4																																	
$A_2$	2	1	-4	-2	3																																	
$A_3$	1	4	-1	-3	-1																																	

(c) より、 $S_A = n \sum_{i=1}^a (\bar{x}_i - \bar{x})^2 = 5\{0^2 + (-3)^2 + 3^2\} = 90$

(d) より、 $S_E = \sum_{i=1}^a \sum_{j=1}^n (x_{ij} - \bar{x}_i)^2 = 1^2 + 6^2 + \dots + (-1)^2 = 120$

がわかります。一般的に、データの総平方和  $S_T$  を、

$$\text{総平方和 : } S_T = \sum_{i=1}^a \sum_{j=1}^n (x_{ij} - \bar{x})^2 \tag{14.4}$$

とおくと、これら 3 つの平方和には、

$$S_T = S_A + S_E \tag{14.5}$$

の関係が成り立ちます。これを 平方和の分解 といいます。

これが成り立つ理由は、

$$\sum_{i=1}^a \sum_{j=1}^n (\bar{x}_i - \bar{x})(x_{ij} - \bar{x}_i) = \sum_{i=1}^a (\bar{x}_i - \bar{x}) \left\{ \sum_{j=1}^n (x_{ij} - \bar{x}_i) \right\} = 0 \tag{14.6}$$

の  $\{ \}$  内が「群内の偏差の和がゼロ」であることから導かれます。なお、表 14.2 の (d) で、各群内の 5 つずつの和がゼロより確かめられます。

### 14.3 分散分析表による検定

群による母平均の違いについては、自由度を考慮して、F 検定を行います。各要因の自由度は、総自由度  $\phi_T = an - 1$ 、要因自由度  $\phi_A = a - 1$ 、誤差自由度  $\phi_E = a(n - 1)$  です。各要因ごとに、自由度 1 当りの平方和 (平均平方)  $V$  を求めて、最終的に、検定統計量は  $F_0 = V_A/V_E$  で求めます。

なお、棄却域は

$$\text{棄却域 } R : F_0 \geq F(\phi_A, \phi_E; 0.05)$$

のように、必ず右片側検定となります。これは、対立仮説の下では、 $F_0$  が大きくなる傾向があるからです。ここまでの計算結果を、表にまとめます。

表 14.3 分散分析表

要因	平方和	自由度	平均平方	$F_0$ 値	限界値
因子 $A$	$S_A$	$\phi_A = a - 1$	$V_A = S_A/\phi_A$	$F_0 = V_A/V_E$	$F(0.05)$
誤差 $E$	$S_E$	$\phi_E = a(n - 1)$	$V_E = S_E/\phi_E$	--	--
計 $T$	$S_T$	$\phi_T = an - 1$	--	--	--

帰無仮説の下で、この検定統計量  $F_0$  が  $F(\phi_A, \phi_E)$  分布に従う理由は、章末問題 14.1 を参照して下さい。

例題 14.2 表 14.1 のデータについて、一元配置分散分析を行え。

表 14.4 分散分析表

要因	平方和	自由度	平均平方	$F_0$ 値	限界値
因子 A	90	2	45.0	4.50	3.89
誤差 E	120	12	10.0	---	---
計 T	210	14	---	---	---

結論 :  $F_0 = 4.50 \geq 3.89 = F(2, 12; 0.05)$  より、有意水準 5% で、要因 A によって母平均には違いがあるといえる。

#### 14.4 投与群での母平均の推定

母平均  $\mu_i$  の点推定値は  $\bar{x}_i$  です。この点推定量の分布は、 $n$  個の平均ですから、

$$\bar{x}_i \sim N(\mu_i, \sigma^2/n) \quad (14.7)$$

となります。ここで、 $S_E/\sigma^2 \sim \chi^2(\phi_E)$  であることを利用すると、(14.7) 式を標準化して、分母の  $\sigma^2$  に  $V_E$  を代入することで、自由度が  $\phi_E$  の t 分布が導かれます。そこで、 $\mu_i$  の 95% 信頼限界は、次のようになります。

$$\begin{aligned} \text{信頼上限} &: \bar{x}_i + t(\phi_E, 0.025)\sqrt{V_E/n} \\ \text{信頼下限} &: \bar{x}_i - t(\phi_E, 0.025)\sqrt{V_E/n} \end{aligned}$$

例題 14.3 表 14.1 のデータについて、高用量群の母平均の推定を行え。

解答 : 点推定値は、 $\hat{\mu}_3 = \bar{x}_3 = 22.0$ 、95% 信頼限界は、 $\bar{x}_3 \pm t(12, 0.025)\sqrt{10.0/5} = 22.0 \pm 2.179\sqrt{2} = 22.0 \pm 3.1 = 18.9, 25.1$  となる。

このように実験を始めても、途中でデータが脱落することがあります。例えば病院の患者であれば、より重症の疾患が見つかり、そちらの治療を優先して病院に来なくなることがあり得ます。そのような場合、各群のデータ数が異なることとなります。データ数が揃っている場合を バランスケース、揃っていない場合を アンバランスケース といいます。アンバランスケースは、次節で議論します。

#### 14.5 サンプルサイズが異なる場合の分析 \*

各群での平均と、総平均は、次の式で推定します。

$$\bar{x}_i = \sum_{j=1}^{n_i} x_{ij}/n_i, \quad \bar{\bar{x}} = \sum_{i=1}^a \sum_{j=1}^{n_i} x_{ij}/N, \quad \left( \text{ただし、} N = \sum_{i=1}^a n_i \right)$$

##### 14.5.1 アンバランスケースの平方和の分解

$$\text{要因平方和} : S_A = \sum_{i=1}^a n_i (\bar{x}_i - \bar{\bar{x}})^2 \quad (14.8)$$

$$\text{誤差平方和} : S_E = \sum_{i=1}^a \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2 \quad (14.9)$$

$$\text{総平方和} : S_T = \sum_{i=1}^a \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2 \quad (14.10)$$

例題 14.4 臨床試験で、対照群、低用量群、中用量群、高用量群の 3 群比較を行う。\$n\_1 = 4, n\_2 = 5, n\_3 = 3, n\_4 = 4\$ で、総人数 \$N = 16\$ 人についての測定データを表 14.5 に示す。

表 14.5 4 群のデータ

群	データ $x_{ij}$	和 $T_i$	データ数 $n_i$	平均 $\bar{x}_i$	二乗和	平方和 $S_i$
対照群 $A_1$	18 23 18 17	76	4	19	1466	22
低用量群 $A_2$	16 19 20 12 13	80	5	16	1330	50
中用量群 $A_3$	19 18 23	60	3	20	1214	14
高用量群 $A_4$	24 23 20 21	88	4	22	1946	10
計	-----	304	16	--	5956	96

### 14.5.2 アンバランケースでの検定

自由度は、 $\phi_A = a - 1, \phi_E = \sum_{i=1}^a (n_i - 1) = N - a$  となります。以下、平均平方や  $F_0$  値、棄却限界値を求めて要因に意味があるかどうかの検定ができます。これらを分散分析表にまとめます。

表 14.7 分散分析表

要因	平方和	自由度	平均平方	$F_0$ 値	限界値
因子 $A$	84	3	28.0	3.50	3.49
誤差 $E$	96	12	8.0	--	--
計 $T$	180	15	--	--	--

結論 :  $F_0 = 3.50 \geq 3.49 = F(3, 12; 0.05)$  より、有意水準 5% で、要因  $A$  によって母平均には違いがあるといえる。

### 14.5.3 アンバランケースでの母平均の推定

母平均  $\mu_i$  の点推定値は  $\bar{x}_i$  です。この点推定量の分布は、 $n_i$  個の平均ですから、

$$\bar{x}_i \sim N(\mu_i, \sigma^2/n_i) \quad (14.11)$$

となります。ここで、 $S_E/\sigma^2 \sim \chi^2(\phi_E)$  であることを利用すると、(14.11) 式を標準化して、分母の  $\sigma^2$  に  $V_E$  を代入することで、自由度が  $\phi_E$  の  $t$  分布が導かれます。そこで、 $\mu_i$  の 95% 信頼限界は、次のようになります。

$$\text{信頼上限、下限} : \bar{x}_i \pm t(\phi_E, 0.025) \sqrt{V_E/n_i}$$

例題 14.6 表 14.5 のデータについて、中用量群の母平均の推定を行え。

解答 : 点推定値は、 $\hat{\mu}_3 = \bar{x}_3 = 20.0$ 、95% 信頼限界は、 $\bar{x}_3 \pm t(12, 0.025) \sqrt{8.00/3} = 20.0 \pm 2.179 \sqrt{8/3} = 20.0 \pm 3.6 = 16.4, 23.6$  となる。

## 14.6 まとめ

3 つ以上の母平均の違いは、母平均の推定値の変動を平方和で捉えます。誤差平方和は、各群ごとに計算して併合するだけで大丈夫です。(併合するとき、カイ二乗分布の再生性を利用します。)

このように計算すると、母平均の推定値や、要因平方和、誤差平方和は、互いに独立になりますので、 $t$  分布や  $F$  分布で検定や推定が可能です。また、サンプルサイズが異なるときも同様に計算できます。ちなみに、自由度は、いくつの平均についての平方和かで、その個数から 1 を引けば求められます。