

統計分析シリーズ (IV)

茨城大学教授 所 一 夫

IV 小標本の場合の母平均の推定

1. 正規型母集団からの標本

前号では標本の大きさが大で中心極限定理が用いられる場合、すなわち標本調査といわれる技法についてその考え方と方法を述べたが、実は推計学の大きな特徴は標本の大きさが小さい場合（小標本）であっても、調査した数値を通して「どの範囲までの事がどの程度の確率で確認できるか。」という問題が考えられることである。

その例としてここでは母集団が正規分布 $N(M, S^2)$ と見られる場合（これを正規型母集団という。）について、調査して得られた標本値から、指定された信頼係数のもとに母平均の信頼区間がどのように求められるかを考えて見よう。

正規型母集団といえ、何か特別の場合にしか適用できない理論のようにも見えるが、分布を示す図表の山が一つで、そこから左右が対称となるような分布では正規型と見てよい場合が多く、またもとの分布では正規分布と見られない場合でも、適当に変数を変換すれば変換した変数に関しては正規分布と見られる場合が多い。したがって以下の理論は実際問題では広く用いられるものである。

またこの場合には必ずしも乱数表によりランダムサンプルを抽出するということではなく、その母集団から無作為に抽出されたと考えられる標本の調査値を標本値 (x_1, x_2, \dots, x_n) として考える場合が多い。

このような場合について前と同様に標本平均 \bar{x} を作ると、この \bar{x} は種々の値をとるが、この \bar{x} の分布は標本調査の場合と同様に

(a) \bar{x} の平均は母平均 M に等しく、

(b) \bar{x} の標準偏差 $s(\bar{x})$ はもとの母集団の標準偏差 S に対して、 $s(\bar{x}) = S/\sqrt{n}$ となる。これは標本調査の場合で母集団の大きさ N が無限大になった場合である。

(c) また \bar{x} の分布は正規分布になっていることなどが数理統計学により明らかにされている。

これらの結果をもとにして標本調査の場合と同様に母平均 M の区間推定が考えられる。

2. 母集団標準偏差 S が既知の場合

この場合は標本調査の場合と比べて、標本標準偏差が $s(\bar{x}) = S/\sqrt{n}$ となっただけのちがいで他は全く同様である。すなわち $\bar{x} = (x_1 + x_2 + \dots + x_n)/n$ とすれば、信頼係数 95% では M の信頼区間は

$$\left(\bar{x} - 2\frac{S}{\sqrt{n}}, \quad \bar{x} + 2\frac{S}{\sqrt{n}} \right)$$

であり、信頼係数 99.7% では次のようになる。

$$\left(\bar{x} - 3\frac{S}{\sqrt{n}}, \quad \bar{x} + 3\frac{S}{\sqrt{n}} \right)$$

例 ある年度の入学試験の採点について某高校から発表された結果によると、某中学からの志願者は 9 名あり、それらの受験生の得点は

290, 280, 275, 260, 255, 243, 237, 220, 217,

で、全志願者の得点の標準偏差 S は 22.5 であった。この結果から、その中学の生徒たちの（母集団における）平均は何点ぐらいと見られるか。信頼係数 95% でその信頼区間を求めよ。

解 問題の意味はこの 9 人によって代表される母集団の母平均を区間推定することであるが、この母集団を正規型母集団と考えて問題を解こうとするものである。試験の点数の分布は一般には正規分布とは限らない。しかし高校入試の点数は例年正規型に近いと見られるので、ここに例題として取りあげたものである。

示された結果によれば

$$\bar{x} = (290 + 280 + \dots + 217) / 9 = 253$$

$$S = 22.5 \text{ より } s(\bar{x}) = 22.5 / \sqrt{9} = 7.5$$

であるから、信頼係数 95% では信頼区間は

$$(253 - 2 \times 7.5, \quad 253 + 2 \times 7.5), \text{ すなわち } (238, 268)$$

とわかる。

すなわち「もし判断が誤ることがあったとしてもその確率は 5% 以下である。」という条件のもとでは母平均は 238 点と 268 点の間と考えてよいという結論が出たわけである。

上例では標本の大きさが 9 であるから n が小さく、標本調査の考えで処理することはできない。しかし「入試の点数の分布が正規型と見られる。」という従来からの知識を判断の資料として加えることによって、この事実に対する確率判断がなされる事を示したものである。

この例のほかにバックされた食品の実際の目方とか、工場から大量生産方式によって製造された製品の計量などについて、その計量に対する保証を与える方法として上の区間推定法が用いられる事が多い。

3. 母集団の標準偏差が未知の場合

前例の入試の点数の場合で、高校側から母集団標準偏差 S の値が知らされていない場合にはどのようにしてこの中学の生徒の母平均を区間推定したらよいか、ということがこの問題である。

問題を整理して見ると (x_1, x_2, \dots, x_n) を $N(M, S^2)$ なる正規型母集団 (M, S は未知) からの無作為標本とするとき、 $(\bar{x} - d < M < \bar{x} + d)$ となる確率を与えられた信頼係数に等しくするような d を求めることである。

この場合には標本平均を \bar{x} 、標本から求めた標準偏差 (これを標本標準偏差という) を s 、すなわち

$$\begin{aligned} \bar{x} &= (x_1 + x_2 + \dots + x_n) / n \\ s^2 &= \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n-1} \\ &= \frac{x_1^2 + x_2^2 + \dots + x_n^2}{n} - \bar{x}^2 \end{aligned}$$

として
$$t = \frac{(\bar{x} - M)\sqrt{n-1}}{s}$$

なる式を作ると、この t の値は抽出された標本の値によって種々の値をとるが、その分布は $t = 0$ を対称の軸とした (正規分布と似た) 分布をしている。

この分布を自由度 $n-1$ の t 分布 といっている。そしてこの分布に対して自由度 $(n-1)$ の種々の値に対して、

$(|t| > t_0)$ となる確率が 0.05 とか 0.01 などになるような t_0 の値が表示されている。この表を t 分布の表という。(この表も統計数値表または多くの数理統計学の本に付いている。)

次に確率が 0.05 の場合の t_0 の値を示す t 分布表の一部を示す。

確率 0.05 の t 分布の表

自由度	t_0 の値	自由度	t_0 の値	自由度	t_0 の値
5	2.571	14	2.145	23	2.069
6	2.447	15	2.131	24	2.064
7	2.365	16	2.120	25	2.060
8	2.306	17	2.110	26	2.053
9	2.262	18	2.101	27	2.052
10	2.228	19	2.093	28	2.048
11	2.201	20	2.086	29	2.045
12	2.179	21	2.080	30	2.042
13	2.160	22	2.074	∞	1.960

この表で自由度 $n-1$ 、 $(|t| > t_0)$ となる確率が 0.05 となるような t_0 を示した表の値を $t_{n-1, 0.05}$ のように書くが、この表記法によると表より $t_{5, 0.05} = 2.571$ 、 $t_{10, 0.05} = 2.228$ である。そして自由度が 5 の t 分布では $(|t| > t_{5, 0.05} = 2.571)$ となる確率が 0.05 となっているのである。これらの関係より

$$t = \frac{(\bar{x} - M)\sqrt{n-1}}{s} > t_{n-1, 0.05}$$

となる確率は 0.05 であるから

$$\frac{|\bar{x} - M|\sqrt{n-1}}{s} \leq t_{n-1, 0.05}$$

となる確率は 0.95 である。したがって

$$\left(\frac{|\bar{x} - M|}{s} \leq t_{n-1, 0.05} / \sqrt{n-1} \right) \text{ となる確率が 95\% である、ゆえに } \left(\frac{\bar{x} - t_{n-1, 0.05} s / \sqrt{n-1}}{\bar{x} + t_{n-1, 0.05} s / \sqrt{n-1}} \right) \leq M \leq$$

なる確率が 95% であるから求めようとする信頼区間は

$$\left(\bar{x} - t_{n-1, 0.05} \frac{s}{\sqrt{n-1}}, \bar{x} + t_{n-1, 0.05} \frac{s}{\sqrt{n-1}} \right)$$

である。

例 前例の 9 人の点数から (S 未知)、この 9 人が抽出されたと考えられる母集団の母平均を信頼係数 95% で区間推定せよ。

$$\text{解 } \frac{x}{9} = \frac{290 + 280 + 275 + 260 + 255 + 243 + 237 + 220 + 217}{9}$$

$$= 253$$

$$\frac{s^2}{n-1} = \frac{(290-253)^2 + (280-253)^2 + \dots + (217-253)^2}{9(9-1)}$$

$$= \frac{5376}{72}$$

$$\therefore s / \sqrt{n-1} = \sqrt{5376 / 72} = 8.64$$

また t 分布の表より $t_{8, 0.05} = 2.306$

$$\therefore t_{8, 0.05} s / \sqrt{n-1} = 2.306 \times 8.64 = 20$$

ゆえに上の計算より求める信頼区間は

$$(253 - 20, 253 + 20) \text{ すなわち大略 } (233, 273)$$

である。

この結果を前例の結果 $(253-15, 253+15)$ と比べてみると信頼区間の幅がだいぶ大きくなっているが、これは前の場合には、後の場合のほかに $S = 22.5$ という情報がいっていたために、より精密な判断がなされたわけである。

以上小標本でも判断の下せる母平均の推定法を紹介したが、この場合についても信頼係数と信頼区間の幅を与えてこれを満足させる標本の大きさ n を求める問題がある。しかしこの問題は前号の方法を参考にして適当に解決されるものと思うので今回は詳述しない。