

母平均の区間推定と標準化 (1)

岩村 英之

無限に数字のつまった壺を考えよう。この壺の中の数字 X が平均 μ 、標準偏差 σ の正規分布に従うならば、次のような操作を施してつくられる新しい変数 Z は、平均 0、標準偏差 1 の正規分布（すなわち標準正規分布）に従う。

$$Z = \frac{X - \mu}{\sigma}$$

これは、いわば全員の背番号を「一定の規則に従って」付け替えただけ。

$$\text{新しい背番号} = \frac{\text{もとの背番号} - 5}{2}$$

(たとえば $\mu = 5$, $\sigma = 2$ とすれば)。したがって、最初の背番号の下で 10 番から 20 番までの人が全体の 50 パーセントを占めていたとすれば、新たな背番号の下では $(10 - 5)/2 = 2.5$ 番から $(20 - 5)/2 = 7.5$ 番までの人が全体の 50 パーセントを占めていることになる。当たり前だが重要な点なので、確認しておきたい。

今、私たちが

- この壺から試しにひとつだけ取り出したところ、 X_1 という数字が出た。
- さらに、この X_1 は、もしこの壺の平均（つまり母平均）が μ_1 であるならば 95 パーセントの確率で出てくるはずの値（＝複数あるので区間になる）に入っているとす（図 1 上半分）。

すでに見たとおり、新しい背番号 $\frac{X - \mu_1}{\sigma}$ は標準正規分布に従う。

そして、新しい背番号の下では（つまり標準正規分布では）-1.96 から 1.96 までの人が 95 パーセントを占めていることがわかっている。

よって、 X_1 が最初の背番号で 95 パーセント区間に入っているならば、彼の新しい背番号 $\frac{X_1 - \mu_1}{\sigma}$ は新しい背番号の下での（つまり標準正規分布における）95 パーセント区間、すなわち -1.96 から 1.96 の区間に入っているはず（図 1 下半分）。

⇨ このことを逆から見れば、「 $\frac{X_1 - \mu_1}{\sigma}$ が -1.96 から 1.96 の範囲に入っていれば、 X_1 は μ_1 の下での 95 パーセント区間に入っている」。

もう少し大きい母平均 μ_2 （これは μ_1 より十分に大きいとする）について考えてみる。

- X_1 は、母平均が μ_2 であるならば 95 パーセントの確率で出てくるはずの区間には入っていないとする（図 2 上半分）。

もとの背番号で 95 パーセントに入っていないならば、新しい背番号でも $\frac{X_1 - \mu_2}{\sigma}$ は -1.96 から 1.96 の範囲に入っていないはず（図 2 下半分）。

⇨ 「 $\frac{X_1 - \mu_2}{\sigma}$ が -1.96 から 1.96 の範囲に入っていなければ、 X_1 は μ_2 の下での 95 パーセント区間に入っていない。」

以上をまとめると、次のようになる。

平均はわからないが標準偏差が σ とわかっている正規母集団から偶然取り出した値が、 X_1 であったとする。

ケース A ある μ について $\frac{X_1 - \mu}{\sigma}$ が -1.96 から 1.96 の範囲に入っている

⇒ X_1 はその μ のもとで十分起こり得る値

⇒ その μ を「あり得ない」と断じる積極的理由はない

ケース B ある μ について $\frac{X_1 - \mu}{\sigma}$ が -1.96 から 1.96 の範囲に入っていない

⇒ X_1 はその μ のもとで起こる可能性が低い値

⇒ その μ が本物である可能性はかなり低い

私たちは、偶然取り出した X_1 が「ケース A」の条件を満たすような μ を探しているわけだが、そのような μ はひとつだけではない。実際、「ある μ について $\frac{X_1 - \mu}{\sigma}$ が -1.96 から 1.96 の範囲に入っている」という条件を数式で言い換えれば、

$$-1.96 \leq \frac{X_1 - \mu}{\sigma} \leq 1.96$$

となるが、この式を満たす μ は明らかにひとつではない。この連立不等式を μ について解けば、

$$X_1 - 1.96\sigma \leq \mu \leq X_1 + 1.96\sigma$$

となる。これが、 X_1 だけを証拠に特定することのできる、「母平均のあり得る区間」である。95 パーセント信頼区間と呼ぶ。

なぜ標準化するのか。いちいち標準化などせずに、もとの背番号のまま、「もし母平均が ○○ だったら何番から何番までが 95 パーセントを占めるか。偶然取り出した X_1 はその範囲に入っているか」と考えればよいのではないだろうか。標準化した世界で考えることのメリットはなんだろうか？




图 1: $\mu = \mu_1$




图 2: $\mu = \mu_2$

今、分散が σ^2 である母集団から 2 回ランダムサンプリングを行い、その平均を計算することを考える。1 回目に出る値を x_1 、2 回目に出る値を x_2 とする。したがって、2 回の平均は $\frac{x_1+x_2}{2}$ となる。今、この $\frac{x_1+x_2}{2}$ がもとの母集団に比べてどれくらいばらつくのかを考えてみる。

$$\begin{aligned}\frac{x_1+x_2}{2} \text{の分散} &= \frac{x_1}{2} \text{の分散} + \frac{x_2}{2} \text{の分散} \\ &= \left(\frac{1}{2}\right)^2 \times (x_1 \text{の分散}) + \left(\frac{1}{2}\right)^2 \times (x_2 \text{の分散}) \\ &= \frac{1}{4} \times [(x_1 \text{の分散}) + (x_2 \text{の分散})] \\ &= \frac{1}{4} \times [\sigma^2 + \sigma^2] \\ &= \frac{1}{2} \sigma^2\end{aligned}$$

分散の平方根が標準偏差である。したがって、

$$\frac{x_1+x_2}{2} \text{の標準偏差} = \frac{\sigma}{\sqrt{2}}$$