

雑感 合併2集団の分散

■ 「データの分析」が2015年からのセンター試験に出題される。大学入試センターが2013年11月に「試作問題」を1題だけ公表したが、巷に、この分野の問題は少ない。

一般社団法人統計質保証推進委員会が、2011年から「統計検定」を実施しており、その3級、2級の内容に、この「データの分析」の内容が含まれる。

■ 2012年と2013年に行われた統計検定の問題から「データの分析」に該当する問題をピックアップし、(著作権へ配慮して) その類題を生徒向けの練習問題用に12題作ってみた。

2014年5月の名古屋の気温や2013年に発生した31個の台風など最新の気象データなども用いたため、生徒が関心を示してくれそうな予感があるがどうだろうか。

■ ところで、2013年11月17日に行われた統計検定第3級の間12に次のような問題がある。

ある学習塾にはA組とB組の2クラスがある。先日行った数学の模擬試験の結果は次の通りであった。

A組: 受験者19名 平均点65.0点 標準偏差9.6点

B組: 受験者25名 平均点57.0点 標準偏差14.4点

[2] 2つのクラスをまとめた44名のこの試験の標準偏差の求め方として適切なものを、次の①~⑤のうちから一つ選べ。

① $(9.6+14.4) \div 2$

② $\sqrt{(9.6 \times 19 + 14.4 \times 25) \div 44}$

③ $\sqrt{(9.6^2 \times 19 + 14.4^2 \times 25) \div 44}$

④ $\sqrt{9.6^2 \times 19 + 14.4^2 \times 25 + (65.0 - 60.5)^2 \times 19 + (57.0 - 60.5)^2 \times 25}$

⑤ $\sqrt{9.6^2 \times 19 + 14.4^2 \times 25 + (65.0 - 60.5)^2 \times 19 + (57.0 - 60.5)^2 \times 25} \div 44$

■ 選択肢があるので、⑤あたりだと見当はつくものの、こんな「公式」は知らない。ネットで少し探してみたが、探し方が悪いためだろうが「公式」は見つからなかった。

となれば、導くしかない。

集団X: データ数 m , 平均値 \bar{x} , 標準偏差 σ_X

集団Y: データ数 n , 平均値 \bar{y} , 標準偏差 σ_Y

とし、2集団X, Yを合併した集団Zに対して、

集団Z: データ数 $m+n$, 平均値 M , 標準偏差 σ

とするとき、

$$\sigma^2 = \frac{1}{m+n} \{ \sigma_X^2 m + \sigma_Y^2 n + (\bar{x} - M)^2 m + (\bar{y} - M)^2 n \}$$

を示す。

■ まず、 $\sigma^2 = \frac{1}{m+n} \left(\sum_{k=1}^m (x_k - M)^2 + \sum_{k=1}^n (y_k - M)^2 \right)$ である。

$$\sum_{k=1}^m x_k + \sum_{k=1}^n y_k = M(m+n), \quad \sigma_X^2 = \frac{1}{m} \sum_{k=1}^m (x_k)^2 - (\bar{x})^2 \text{ から}$$

$$\sum_{k=1}^m (x_k)^2 = \sigma_X^2 m + (\bar{x})^2 m \quad \text{などより}$$

$$(m+n)\sigma^2 = \sum_{k=1}^m (x_k - M)^2 + \sum_{k=1}^n (y_k - M)^2$$

$$= \sum_{k=1}^m (x_k)^2 + \sum_{k=1}^n (y_k)^2 - M^2(m+n)$$

$$= \sigma_X^2 m + \sigma_Y^2 n + (\bar{x})^2 m + (\bar{y})^2 n - M^2(m+n)$$

$$= \sigma_X^2 m + \sigma_Y^2 n + \{(\bar{x})^2 - M^2\}m + \{(\bar{y})^2 - M^2\}n$$

示すべき式に近づいたが、ビミョーに異なる。

しかし、実用上これで十分なような気がする。

もう一息だが、示すべき式が分かっていることなので、卑怯だが、その形に強引に持ち込む。

ここで、

$$\{(\bar{x})^2 - M^2\}m + \{(\bar{y})^2 - M^2\}n$$

$$= \{(\bar{x})^2 - 2\bar{x}M + M^2\}m + \{(\bar{y})^2 - 2\bar{y}M + M^2\}n$$

$$+ 2\bar{x}Mm + 2\bar{y}Mn - 2M^2(m+n)$$

$$= (\bar{x} - M)^2 m + (\bar{y} - M)^2 n + 2M(m+n)M - 2M^2(m+n)$$

$$= (\bar{x} - M)^2 m + (\bar{y} - M)^2 n$$

となるから、

$$(m+n)\sigma^2 = \sigma_X^2 m + \sigma_Y^2 n + (\bar{x} - M)^2 m + (\bar{y} - M)^2 n$$

となって、

$$\sigma^2 = \frac{1}{m+n} \{ \sigma_X^2 m + \sigma_Y^2 n + (\bar{x} - M)^2 m + (\bar{y} - M)^2 n \}$$

が示された。

■ ニーズがないとは言えないが、こんな「公式」は覚えてくれないなあ。

■ 書棚を探していたら『現代の総合数学Ⅲ』(安藤洋美, 現代数学社, 1973)のp.192-193, 例3.17にこの内容が扱われているのを見つけた。ただ、結果の式にミスプリントがある。

ここでの記号にしたがって記せば

$$\sigma^2 = \frac{1}{m+n} \left\{ \sigma_X^2 m + \sigma_Y^2 n + \frac{mn}{m+n} (\bar{x} - \bar{y})^2 \right\}$$

である。

ミスプリントは、 $\{ \}$ 内の $\frac{mn}{m+n} (\bar{x} - \bar{y})^2$ の前の符号が-

になってしまっている点である。

このように見ると、

$$\{(\bar{x})^2 - M^2\}m + \{(\bar{y})^2 - M^2\}n = (\bar{x} - M)^2 m + (\bar{y} - M)^2 n$$

$$= \frac{mn}{m+n} (\bar{x} - \bar{y})^2$$

が成り立つことになる。

さまざまな顔を持つ、妖怪みいたな式である。