

第11回 平均値の比較と相関比

独立変数 x が質的変数で、従属変数 y が量的変数の場合、 x のカテゴリーごとに y の平均値を比較して、違いがあるかどうかを検討することができる。

x のカテゴリーごとの y の平均値を \bar{y}_i と表す。 i はカテゴリー番号。

質的変数と量的変数との関連を見るのに、**相関比**が用いられる。

相関比 η^2 の定義（まず、平方を考える）。

$$\eta_{yx}^2 = \frac{x \text{ を与えたときの } y \text{ の平均値の重みつき分散}}{y \text{ の全分散}} = \frac{S_{y_i}^2}{S_y^2}$$

$$\begin{aligned} &= \frac{\frac{1}{n} \sum_{i=1}^k n_i (\bar{y}_i - \bar{y})^2}{\frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2} \quad \dots \textcircled{1} \end{aligned}$$

ところで、 η^2_{yx} は $1 - \frac{x \text{ を与えたときの } y \text{ の分散}}{y \text{ の全分散}}$ に等しい。

$$1 - \frac{\frac{1}{n} \sum_i^k \sum_j^{n_i} (y_{ij} - \bar{y}_i)^2}{\frac{1}{n} \sum_i^k \sum_j (y_{ij} - \bar{y})^2}$$

$$\begin{aligned} &= \frac{\frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2 - \frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y}_i)^2}{\frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2} \end{aligned}$$

分母を S_y^2 と表記し、 $\Sigma \Sigma$ までを括り出す。

$$= \frac{1}{S_y^2} \cdot \frac{1}{n} \sum_i \sum_j \{(y_{ij} - \bar{y})^2 - (y_{ij} - \bar{y}_i)^2\}$$

{ }内を展開する。

$$= \frac{1}{S_y^2} \cdot \frac{1}{n} \sum_i \sum_j (y_{ij}^2 - 2y_{ij}\bar{y} + \bar{y}^2 - y_{ij}^2 + 2y_{ij}\bar{y}_i - \bar{y}_i^2)$$

()内の項を整理して

$$= \frac{1}{S_y^2} \cdot \frac{1}{n} \sum_i \sum_j^{n_i} (\bar{y}^2 - 2y_{ij}\bar{y} + 2y_{ij}\bar{y}_i - \bar{y}_i^2)$$

ここで、

$$\sum_j^{n_i} y_{ij} = n_i \bar{y}_i \quad (\text{級内の総和}) \quad \text{であることを利用して、} \sum_j \text{をカッコ内に入れる。}$$

$$= \frac{1}{S_y^2} \cdot \frac{1}{n} \sum_i (n_i \bar{y}^2 - 2n_i \bar{y}_i \bar{y} + 2n_i \bar{y}_i \bar{y}_i - n_i \bar{y}_i^2)$$

$$= \frac{1}{S_y^2} \cdot \frac{1}{n} \sum_i n_i (\bar{y}^2 - 2\bar{y}_i \bar{y} + \bar{y}_i^2)$$

$$\begin{aligned} & \frac{1}{n} \sum_i n_i (\bar{y}_i - \bar{y})^2 \\ = & \frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2 \end{aligned}$$

つまり、

$$\frac{x \text{を与えたときの} y \text{の平均値の重みつき分散}}{y \text{の全分散}} = 1 - \frac{x \text{を与えたときの} y \text{の分散}}{y \text{の全分散}}$$

よって、つぎのような関係が成り立つ。

$$\begin{aligned} & \frac{\frac{1}{n} \sum_i n_i (\bar{y}_i - \bar{y})^2}{\frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2} + \frac{\frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y}_i)^2}{\frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2} = 1 \end{aligned}$$

分母を払うと、

$$\frac{1}{n} \sum_i n_i (\bar{y}_i - \bar{y})^2 + \frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y}_i)^2 = \frac{1}{n} \sum_i \sum_j (y_{ij} - \bar{y})^2$$

つまり、級間分散+級内分散=全分散

n 倍した式では、級間変動+級内変動=全変動

$$SSB + SSW = SST$$

結局、相関比とは、

$$\sqrt{\frac{SSB}{SST}} = \sqrt{1 - \frac{SSW}{SST}}$$

- ・この平方が、全分散にたいする級間分散の説明率を示す（決定係数）。
- ・級内変動 SSW が小さければ、相関比は 1 に近づき、大きければ 0 に近づく。

【例題】学歴 q43 と仕事による収入 income2 の平均値および学歴と収入の相関比を計算する。(学歴は質的変数、収入は量的変数であることに注意)。

spss のコマンドは、

means tables income2 by q43 /statistics anova.

報告書

income2				
q43	学歴	平均値	度数	標準偏差
1	中学卒	277.8689	61	221.26993
2	高校卒	354.6099	282	307.37673
3	短大卒	306.2992	127	249.92000
4	大学卒	576.5781	301	402.21211
	合計	427.2374	771	355.49127

分散分析表

						平方和	自由度	平均平方	F値	有意確率
income2 x q43	学歴	グループ間	(結合)			11419049.476	3	3806349.825	33.991	.000
		グループ内				8588966.088	767	111980.399		
		合計				97308015.564	770			

連関の測定方法

			イータ	イータの2乗
income2 x q43	学歴		.343	.117