


■ 基本的な統計量 III (二つの変数の 相関)

【目的】 x 軸と y 軸の関連性の方向と大きさを測る指標を作りたい。



(1) 共分散

これは、平均と各点との間の二次の距離(面積)の平均。

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

※共分散には最大値と最小値が存在する。

$$-s_x s_y \leq s_{xy} \leq s_x s_y$$

(2) 相関係数 (ピアソンの積率相関係数)

これは、共分散が最大値と比較したときに占める割合。

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

今回とった共分散

関連度がMAXのときの共分散

※相関係数には最大値と最小値が存在する。

$$-1 \leq r_{xy} \leq 1$$

↑ -100%

↑ 100%

① 最大値が割ること

Aさん: 90点 (990点満点)
Bさん: 90点 (200点満点)



$$\frac{90}{990} \doteq 0.09 (9\%)$$

$$\frac{90}{200} = 0.45 (45\%)$$

最大値を分母

① 共分散の弱点

単位に依存してしまう。



① 共分散の上限と下限

共分散 s_{xy} は、関連性が最大化するときに、次の値をとる

$$s_{xy} = s_x s_y$$

(右肩あがり)

$$s_{xy} = -s_x s_y$$

(右肩下がり)


① 相関係数の良いところ

- ① 正負: 関連の方向
- ② 値: 関連度の強さ
 - 1: 相関が(正の方向)MAX
 - 0: 相関がない
 - 1: 相関が(負の方向)MAX
- ③ 場合分け不用
- ④ サンプルサイズに依存しない
- ⑤ データの単位に依存しない




(準備) 軸を取り払う


もともとの x 軸、 y 軸の位置は関連度合いには無関係なので、取っ払ってしまいたい。



しかし、座標自体は維持したいので、新しく、横軸を \bar{y} 、縦軸を \bar{x} の位置に据えた新しい座標を考える。これはもともとの座標を平行移動したことに相当する。



① 象限



① 第1案の良いとこ3

① 正負：関連の方向


- 正：↗
- 0：↔
- 負：↘

② 値の大きさ：関連の強さ



(第一案) 球の個数の差を考える

(式1) 「第一／三象限の球の数」 - 「第二／四象限の球の数」




問題点：ケース B とケース C の違いを捉えられない。




(第二案) 中心からの離れ具合を「足し算」で捉える



C



B



(式2) 「灰色の領域の数字の和」 - 「白色の領域の数字の和」



問題点：数式に場合分けが存在してしまう。

① 第2案の良いとこ

- ① 正負：関連性の方向
- ② 値：関連性の強さ
- ③ BとCを区別できる

② 数式で表現 (第2案)

① 出席番号1の人の中心からの長さ

$$2.1 + 2.2 = |x_1 - \bar{x}| + |y_1 - \bar{y}|$$



② 全2の人をまとめて、中心からの長さ

$$\begin{aligned} & 4.3 + 4.9 + 4.9 + 5.7 - 2.4 - 2 - 0.6 - 3.8 \\ & + |x_1 - \bar{x}| + |y_1 - \bar{y}| + |x_2 - \bar{x}| + |y_2 - \bar{y}| + |x_3 - \bar{x}| + |y_3 - \bar{y}| + |x_4 - \bar{x}| + |y_4 - \bar{y}| - (|x_5 - \bar{x}| + |y_5 - \bar{y}|) - (|x_6 - \bar{x}| + |y_6 - \bar{y}|) - (|x_7 - \bar{x}| + |y_7 - \bar{y}|) - (|x_8 - \bar{x}| + |y_8 - \bar{y}|) \end{aligned}$$



= 11.1



(第三案) 中心からの離れ具合を「掛け算」で捉える



(式2) 「灰色の領域の数字の和」 - 「白色の領域の数字の和」



問題点：サンプルサイズに依存してしまう。

③ 数式で表現 (第3案)

① 出席番号1の人

$$2.1 \times 2.2 = (x_1 - \bar{x})(y_1 - \bar{y})$$

② 全2の人をまとめて


$$\begin{aligned} & 6 + 4.62 + 6 + 8.12 + (-0.44) + (-0.64) + (-0.08) + (-3.57) \\ & + (x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + (x_3 - \bar{x})(y_3 - \bar{y}) + (x_4 - \bar{x})(y_4 - \bar{y}) + (x_5 - \bar{x})(y_5 - \bar{y}) + (x_6 - \bar{x})(y_6 - \bar{y}) + (x_7 - \bar{x})(y_7 - \bar{y}) + (x_8 - \bar{x})(y_8 - \bar{y}) \end{aligned}$$

$$= \sum_{i=1}^8 (x_i - \bar{x})(y_i - \bar{y})$$



(第四案) サンプルサイズの影響を無くす

採用!



(式3) $\frac{1}{n} \times (\text{「奇数象限の数字の和」} - \text{「偶数象限の数字の和」})$

共分散

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

準備:
平行移動を
する

第4案
サンプルサイズの
影響を取りのぞく

第2案
中心からの遠さを
考慮する


第3案
都合のいい回避

1つのデータではなく
データ全体を見よう



共分散の特殊なケースとしての分散

x と y という二変数の間ではなく、 x と x という自分自身との間の共分散を考えてみたものが分散である。



この値が大きいということは、その変数のばらつきが大きいということ。そこで、分散はばらつきの指標として使われる。