

教養科目／**B** 自然の摂理の探求

2026 年度 統計学（集中1期）

第5回

前回の内容

- ・ 2次元データ

- ・ 散布図 ・ 共分散 ・ 相関係数


- ・ 相関係数は直線的な関係の強さを表している。

相関係数の値が0に近い




x と y の直線的な関係がほとんどない

x と y の関係がないとは言っていないので注意



相関係数 : 0



相関係数 : 1

1. 8. クロス集計表

例 1.12

80 人のクラスで試験を行い、試験は 2 問あり、次の結果が得られた。

表 1.13 例 1.12 の試験結果

| | 問題 1 | 問題 2 |
|----|------|------|
| 1 | 正 | 正 |
| 2 | 誤 | 誤 |
| ⋮ | ⋮ | ⋮ |
| 80 | 正 | 誤 |

- 問題 1, 問題 2 が何人の学生に正しく解答されているか？
- 問題 1 の出来具合と問題 2 の出来具合の関係は？



クロス集計表が便利

1.8 クロス集計表

問題1も問題2も正しく解答した学生の人数

問題1は正しく解答し, 問題2は間違えた学生の人数

表 1.14 例 1.12 のクロス集計表

| 問題1 \ 問題2 | 正 | 誤 | 計 |
|-----------|----|----|----|
| 正 | 32 | 12 | 44 |
| 誤 | 8 | 28 | 36 |
| 計 | 40 | 40 | 80 |

問題1は間違え, 問題2は正しく解答した学生の人数

問題1も2も間違えた学生の人数

このような表をクロス集計表あるいは2×2の分割表という。

1. 8. クロス集計表

表 1.14 例 1.12 のクロス集計表

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 32 | 12 | 44 |
| 誤 | 8 | 28 | 36 |
| 計 | 40 | 40 | 80 |


問題 1 を正しく解答した学生の人数

問題 1 を間違えた学生の人数

問題 2 を正しく解答した学生の人数

問題 2 を間違えた学生の人数

・問題 1 を正しく解けることと問題 2 を正しく解けることには関係がありそうである。(主対角の数字に注目)



・それでは関係の強さを表す代表値はどう考えればよいのか?

1. 9. 独立性

一般的に話をするために、次のようなクロス集計表を考える。より詳しくは4章 (p.123~126) の検定で述べる。

表 1.15 一般のクロス集計表

| $A \setminus B$ | B_1 | B_2 | 計 |
|-----------------|---------------|---------------|--------------|
| A_1 | n_{11} | n_{12} | $n_{1\cdot}$ |
| A_2 | n_{21} | n_{22} | $n_{2\cdot}$ |
| 計 | $n_{\cdot 1}$ | $n_{\cdot 2}$ | n |

ただし,

$$n_{1\cdot} = n_{11} + n_{12}, \quad n_{2\cdot} = n_{21} + n_{22},$$

$$n_{\cdot 1} = n_{11} + n_{21}, \quad n_{\cdot 2} = n_{12} + n_{22}.$$

・ **Note** : $n_{1\cdot} + n_{2\cdot} = n_{\cdot 1} + n_{\cdot 2} = n$

1. 9. 独立性

・ A と B が独立である，つまり，A と B に関係がないときに期待される度数を**独立期待度数**という。

・ 独立期待度数

$$e_{11} = \frac{n_{1.} n_{.1}}{n}, \quad e_{12} = \frac{n_{1.} n_{.2}}{n}, \quad e_{21} = \frac{n_{2.} n_{.1}}{n}, \quad e_{22} = \frac{n_{2.} n_{.2}}{n}$$

表 1.16 一般の独立期待度数表

| $A \setminus B$ | B_1 | B_2 | 計 |
|-----------------|----------|----------|----------|
| A_1 | e_{11} | e_{12} | $n_{1.}$ |
| A_2 | e_{21} | e_{22} | $n_{2.}$ |
| 計 | $n_{.1}$ | $n_{.2}$ | n |

1. 9. 独立性

表 1.15 一般のクロス集計表

| $A \setminus B$ | B_1 | B_2 | 計 |
|-----------------|---------------|---------------|--------------|
| A_1 | n_{11} | n_{12} | $n_{1\cdot}$ |
| A_2 | n_{21} | n_{22} | $n_{2\cdot}$ |
| 計 | $n_{\cdot 1}$ | $n_{\cdot 2}$ | n |

・ 実際のデータ

・ χ^2 値

表 1.16 一般の独立期待度数表

| $A \setminus B$ | B_1 | B_2 | 計 |
|-----------------|---------------|---------------|--------------|
| A_1 | e_{11} | e_{12} | $n_{1\cdot}$ |
| A_2 | e_{21} | e_{22} | $n_{2\cdot}$ |
| 計 | $n_{\cdot 1}$ | $n_{\cdot 2}$ | n |

・ A と B が独立である
(A と B に関係がない)

$$\chi^2 = \frac{(n_{11} - e_{11})^2}{e_{11}} + \frac{(n_{12} - e_{12})^2}{e_{12}} + \frac{(n_{21} - e_{21})^2}{e_{21}} + \frac{(n_{22} - e_{22})^2}{e_{22}}$$


実際のデータがどの程度「独立である」ということから乖離（かいり）しているかを表している。


1. 9. 独立性


・ Note

$$\chi^2 = n \frac{(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1.}n_{2.}n_{.1}n_{.2}}$$

- ・ この値が**大きければ大きいほど独立でない傾向がある**.
つまり**関係がある**ということがわかる.

・ $\chi^2 \leq 3.841$  「独立であるといえないこともない」
あるいは
「関係があるとはいえない」

・ $\chi^2 > 3.841$  「独立ではない」あるいは「関係がある」

・ $\chi^2 > 6.635$  「関係が強い」

1.9 独立性 (例1.12の解析結果)

表 1.14 例 1.12 のクロス集計表

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 32 | 12 | 44 |
| 誤 | 8 | 28 | 36 |
| 計 | 40 | 40 | 80 |

表 1.17 例 1.12 の独立期待度数表

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 22 | 22 | 44 |
| 誤 | 18 | 18 | 36 |
| 計 | 40 | 40 | 80 |

- ・ 実際のデータ
- ・ χ^2 値
- ・ 問題 1 と 問題 2 が独立である (問題 1 と問題 2 に関係がない)

$$\chi^2 = 80 \times \frac{(32 \times 28 - 12 \times 8)^2}{44 \times 36 \times 40 \times 40} = \frac{2000}{99} \doteq 20.2 > 6.635$$

- ・ 問題 1 と問題 2 は関係が強いと判断される。



1. 9. 独立性（クラメールの連関係数）

質的データどうしの関係のことを連関ともいう。

- ・クラメールの連関係数

$$V = \sqrt{\frac{\chi^2}{n}}$$

- ・ Note : $0 \leq V \leq 1$ が成り立つ.
- ・ A と B の関係が強ければ強いほど 1 に近い値をとる.

- ・ A と B が独立  V の値は 0 に近い値を取る
- ・ A と B の関係が強い  V の値は 1 に近い値を取る

1. 9. 独立性（例 1. 12のクラメールの連関係数）

クラメールの連関係数は

$$V = \sqrt{\frac{\frac{2000}{99}}{80}} \doteq 0.50.$$

いくつ以上だと関係があるというような明確な基準はないが、0.50 という値はそれなりに大きく、問題 1 と問題 2 は関係が強いと言ってよい。

1.10. 回帰直線

例 1.10 最高気温とアイスクリームの売り上げ額

| | | | | | | | |
|---------------|------|------|------|------|------|------|------|
| 最高気温 (x) | 26.1 | 20.0 | 23.2 | 25.1 | 25.3 | 27.2 | 28.1 |
| 売り上げ額 (y) | 120 | 55 | 70 | 75 | 70 | 95 | 110 |




図 1.21 例 1.10 の散布図

およそ図中にあるような直線の関係があるように思える。直線の関係は暑ければ暑いほどアイスクリームの売り上げ額が大きくなることを意味している。

1. 10. 回帰直線

- ・ 図中で求めようとしている直線の方程式を $y = a + bx$ とする.
- ・ 図 1.22 の各点と直線 $y = a + bx$ との縦の線分の長さを考える.




図 1.22 例 1.10 の散布図と回帰直線

- ・ これらの線分の長さの2乗の総和

$$\{120 - (a + 26.1b)\}^2 + \{55 - (a + 20.0b)\}^2 + \cdots + \{110 - (a + 28.1b)\}^2$$

が最小になるような直線 $y = a + bx$ を y の x への回帰直線という.

公式 1.4


(1) y の x への回帰直線 $y = \hat{a} + \hat{b}x$ の係数 \hat{a} , \hat{b} は

$$\hat{a} = (y \text{ の標本平均}) - \hat{b} \times (x \text{ の標本平均}),$$

$$\hat{b} = \frac{x \text{ と } y \text{ の共分散}}{x \text{ の標本分散}}$$

として得られる。 (\hat{a} , \hat{b} はそれぞれ“エーハット”, “ビーハット” と読む)。

(2) 相関係数が 1 または -1 に近ければ近いほど回帰直線のデータへのあてはまりが良くなる。



公式 1.4

- ・ 公式 1.4 (1) の \hat{a} , \hat{b} を数式で書くと

$$\hat{a} = \bar{y} - \hat{b}\bar{x}, \quad \hat{b} = \frac{C_{xy}}{S_x^2}$$

となる. \hat{b} を**回帰係数**という.

- ・ このようにして直線を2次元データにあてはめる方法を**最小2乗法**という.

注意

- ・ 一般に “ y の x への回帰直線” と “ x の y への回帰直線” は異なることに注意する。

- ・ 2種類のデータがそれぞれ原因と結果と考えられるような場合

「最高気温」が原因であり, 「アイスクリームの売り上げ額」が結果



x 軸 (横軸) に原因を表すデータ, y 軸 (縦軸) に結果を表すデータをとり, y の x への回帰直線を考えるのが一般的である。

- ・ どちらが原因でも結果でもないと考えられる場合

どちらに x 軸, y 軸をとっても差し支えない。

例1. 10. における回帰直線

例 1.10 最高気温とアイスクリームの売り上げ額

| | | | | | | | |
|---------------|------|------|------|------|------|------|------|
| 最高気温 (x) | 26.1 | 20.0 | 23.2 | 25.1 | 25.3 | 27.2 | 28.1 |
| 売り上げ額 (y) | 120 | 55 | 70 | 75 | 70 | 95 | 110 |

・ \bar{x} , \bar{y} , s_x^2 , c_{xy} を計算する.

$$\bar{x} = \frac{1}{7}(26.1 + 20.0 + 23.2 + 25.1 + 25.3 + 27.2 + 28.1) = 25.0$$

$$\bar{y} = \frac{1}{7}(120 + 55 + 70 + 75 + 70 + 95 + 110) = 85$$

$$\begin{aligned} s_x^2 &= \frac{1}{7}\{1.1^2 + (-5.0)^2 + (-1.8)^2 + 0.1^2 + 0.3^2 + 2.2^2 + 3.1^2\} \\ &= \frac{44}{7} \end{aligned}$$

$$\begin{aligned} c_{xy} &= \frac{1}{7}\{1.1 \times 35.0 + (-5.0) \times (-30.0) + (-1.8) \times (-15.0) \\ &\quad + 0.1 \times (-10.0) + 0.3 \times (-15.0) + 2.2 \times 10.0 + 3.1 \times 25.0\} \\ &= \frac{309.5}{7} \end{aligned}$$

例1. 10. における回帰直線

- ・ s_x^2 , c_{xy} の値から回帰係数を計算する.

$$\hat{b} = \frac{c_{xy}}{s_x^2} = \frac{\frac{309.5}{7}}{\frac{44}{7}} = 7.03 \dots \doteq 7.0$$

- ・ \bar{x} , \bar{y} , \hat{b} の値を使い \hat{a} を計算する.

$$\hat{a} = \bar{y} - \hat{b}\bar{x} \doteq 85.0 - \frac{309.5}{44} \times 25.0 = -90.85 \dots \doteq -90.9$$

- ・ y の x への回帰直線

$$y = -90.9 + 7.0x$$

例 1. 10における回帰直線

- ・ y の x への回帰直線

$$y = -90.9 + 7.0x$$

たとえば最高気温が $x = 32$ °C のとき、売り上げ額はおよそ

$$-90.9 + 7.0 \times 32 = 133.1 \quad (\text{千円})$$

となると予想される。

まとめ

表 1.14 例 1.12 のクロス集計表

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 32 | 12 | 44 |
| 誤 | 8 | 28 | 36 |
| 計 | 40 | 40 | 80 |

・ クロス集計表

・ 独立性, 関係, χ^2 値, クラメールの連関係数

$$\chi^2 = n \frac{(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1.}n_{2.}n_{.1}n_{.2}}$$

表 1.15 一般のクロス集計表

| $A \setminus B$ | B_1 | B_2 | 計 |
|-----------------|----------|----------|----------|
| A_1 | n_{11} | n_{12} | $n_{1.}$ |
| A_2 | n_{21} | n_{22} | $n_{2.}$ |
| 計 | $n_{.1}$ | $n_{.2}$ | n |

・ $\chi^2 \leq 3.841$



「独立であるといえないこともない」
あるいは

「関係があるとはいえない」

・ $\chi^2 > 3.841$



「独立ではない」あるいは「関係がある」

・ $\chi^2 > 6.635$



「関係が強い」

注意

- ・ 関係の方向は2つある。
- ・ 最も関係がある場合 (計を固定した場合)

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 40 | 4 | 44 |
| 誤 | 0 | 36 | 36 |
| 計 | 40 | 40 | 80 |

- ・ もう一方の関係

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 4 | 40 | 44 |
| 誤 | 36 | 0 | 36 |
| 計 | 40 | 40 | 80 |

- ・ 最も関係がない場合 (計を固定した場合)

| 問題 1 \ 問題 2 | 正 | 誤 | 計 |
|-------------|----|----|----|
| 正 | 22 | 22 | 44 |
| 誤 | 18 | 18 | 36 |
| 計 | 40 | 40 | 80 |

まとめ

・ 回帰直線

(1) y の x への回帰直線 $y = \hat{a} + \hat{b}x$ の係数 \hat{a} , \hat{b} は

$$\hat{a} = (y \text{ の標本平均}) - \hat{b} \times (x \text{ の標本平均}),$$

$$\hat{b} = \frac{x \text{ と } y \text{ の共分散}}{x \text{ の標本分散}}$$

として得られる。 (\hat{a} , \hat{b} はそれぞれ“エーハット”, “ビーハット” と読む)。

(2) 相関係数が 1 または -1 に近ければ近いほど回帰直線のデータへのあてはまりが良くなる。

