2017/6/16 Fri.

# 問題解決技法入門

# 3. Data Analysis

# 1. Cross Tabulation

堀田 敬介

# クロス集計とは

- クロス集計(表) cross tabulation
  - 2つ以上の属性間の関係を知りたい時に使う集計方法のひとつ．分割表ともよぶ

元データ

| id | 性別 | 年齢 | 嗜好1 | 嗜好2 |
|---|---|---|---|---|
| 1 | 女性 | 34 | 猫 | 紅茶 |
| 2 | 女性 | 21 | 犬 | 紅茶 |
| 3 | 男性 | 29 | 猫 | 紅茶 |
| 4 | 男性 | 69 | 猫 | 珈琲 |
| 5 | 女性 | 38 | 猫 | 紅茶 |
| 6 | 男性 | 64 | 猫 | 紅茶 |
| 7 | 男性 | 38 | 犬 | 珈琲 |
| 8 | 女性 | 37 | 猫 | 珈琲 |
| 9 | 男性 | 16 | 犬 | 珈琲 |
| 10 | 女性 | 25 | 犬 | 珈琲 |
| 11 | 女性 | 21 | 犬 | 紅茶 |
| 12 | 女性 | 17 | 猫 | 紅茶 |
| 13 | 男性 | 20 | 猫 | 珈琲 |
| 14 | 男性 | 16 | 犬 | 珈琲 |
| 15 | 女性 | 18 | 犬 | 紅茶 |
| ⋮ | | | | |

加工データ

ここを加工した

| id | 性別 | 年代 | 嗜好1 | 嗜好2 |
|---|---|---|---|---|
| 1 | 女性 | 30 | 猫 | 紅茶 |
| 2 | 女性 | 20 | 犬 | 紅茶 |
| 3 | 男性 | 20 | 猫 | 紅茶 |
| 4 | 男性 | 60 | 猫 | 珈琲 |
| 5 | 女性 | 30 | 猫 | 紅茶 |
| 6 | 男性 | 60 | 猫 | 紅茶 |
| 7 | 男性 | 30 | 犬 | 珈琲 |
| 8 | 女性 | 30 | 猫 | 珈琲 |
| 9 | 男性 | 10 | 犬 | 珈琲 |
| 10 | 女性 | 20 | 犬 | 珈琲 |
| 11 | 女性 | 20 | 犬 | 紅茶 |
| 12 | 女性 | 10 | 猫 | 紅茶 |
| 13 | 男性 | 20 | 猫 | 珈琲 |
| 14 | 男性 | 10 | 犬 | 珈琲 |
| 15 | 女性 | 10 | 犬 | 紅茶 |
| ⋮ | | | | |

クロス集計（例1）

「年代」と「嗜好1」の人数をクロス集計

| | 列ラベル | | |
|---|---|---|---|
| 行ラベル | 犬 | 猫 | 総計 |
| 10 | 13 | 7 | 20 |
| 20 | 16 | 16 | 32 |
| 30 | 16 | 23 | 39 |
| 40 | 16 | 25 | 41 |
| 50 | 13 | 16 | 29 |
| 60 | 19 | 17 | 36 |
| 70 | 3 | | 3 |
| 総計 | 96 | 104 | 200 |

クロス集計（例2）

「性別」と「嗜好2」の人数をクロス集計

| | 列ラベル | | |
|---|---|---|---|
| 行ラベル | 紅茶 | 珈琲 | 総計 |
| 女性 | 53 | 41 | 94 |
| 男性 | 57 | 49 | 106 |
| 総計 | 110 | 90 | 200 |

# クロス集計の前に：フィルタを使おう

- 集計したいデータ項目を選択①し [データ②]-[フィルタ③]

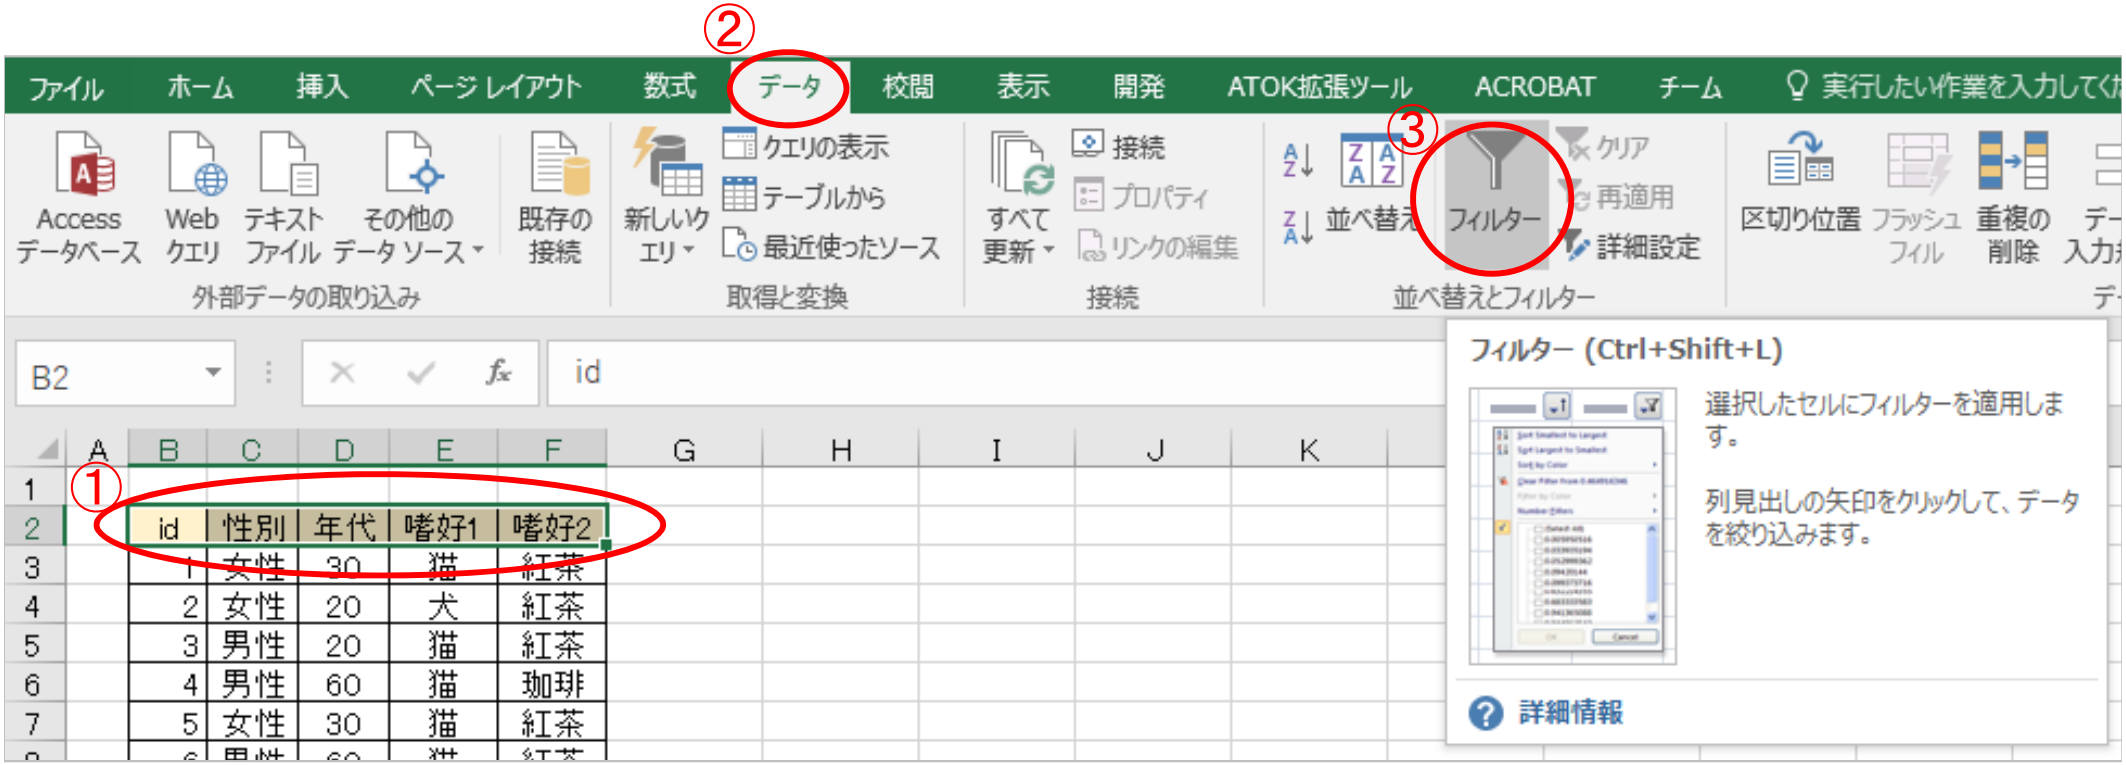

# クロス集計の前に：フィルタを使おう

- フィルタをかけ，欲しいデータだけを抽出
  - 例：「犬」好きで「紅茶」が好きな「女性」を抽出

フィルタで選択

| | A | B | C | D | E | F |
|---|---|---|---|---|---|---|
| 1 | | | | | | |
| 2 | | id | 性別 | 年代 | 嗜好1 | 嗜好2 |
| 4 | | 2 | 女性 | 20 | 犬 | 紅茶 |
| 13 | | 11 | 女性 | 20 | 犬 | 紅茶 |
| 17 | | 15 | 女性 | 10 | 犬 | 紅茶 |
| 28 | | 26 | 女性 | 40 | 犬 | 紅茶 |
| 29 | | 27 | 女性 | 30 | 犬 | 紅茶 |
| 31 | | 29 | 女性 | 60 | 犬 | 紅茶 |
| 32 | | 30 | 女性 | 60 | 犬 | 紅茶 |
| 38 | | 36 | 女性 | 50 | 犬 | 紅茶 |
| 41 | | 39 | 女性 | 20 | 犬 | 紅茶 |
| 53 | | 51 | 女性 | 40 | 犬 | 紅茶 |
| 54 | | 52 | 女性 | 50 | 犬 | 紅茶 |
| 55 | | 53 | 女性 | 40 | 犬 | 紅茶 |
| 61 | | 59 | 女性 | 60 | 犬 | 紅茶 |
| 66 | | 64 | 女性 | 60 | 犬 | 紅茶 |
| 74 | | 72 | 女性 | 60 | 犬 | 紅茶 |
| 82 | | 80 | 女性 | 20 | 犬 | 紅茶 |
| 83 | | 81 | 女性 | 10 | 犬 | 紅茶 |
| 92 | | 90 | 女性 | 60 | 犬 | 紅茶 |
| 106 | | 104 | 女性 | 30 | 犬 | 紅茶 |
| 112 | | 110 | 女性 | 40 | 犬 | 紅茶 |
| 113 | | 111 | 女性 | 10 | 犬 | 紅茶 |
| 117 | | 115 | 女性 | 50 | 犬 | 紅茶 |
| 118 | | 116 | 女性 | 10 | 犬 | 紅茶 |
| 119 | | 117 | 女性 | 50 | 犬 | 紅茶 |
| 162 | | 160 | 女性 | 20 | 犬 | 紅茶 |
| 171 | | 169 | 女性 | 20 | 犬 | 紅茶 |
| 186 | | 184 | 女性 | 30 | 犬 | 紅茶 |
| 197 | | 195 | 女性 | 10 | 犬 | 紅茶 |
| 203 | | | | | | |

データが選択（抽出）されたものだけだとわかるように，行番号が「青色」になっている

# Excelでクロス集計

- 集計したい範囲を選択①し [挿入②]-[ピボットテーブル③]

[OK④]

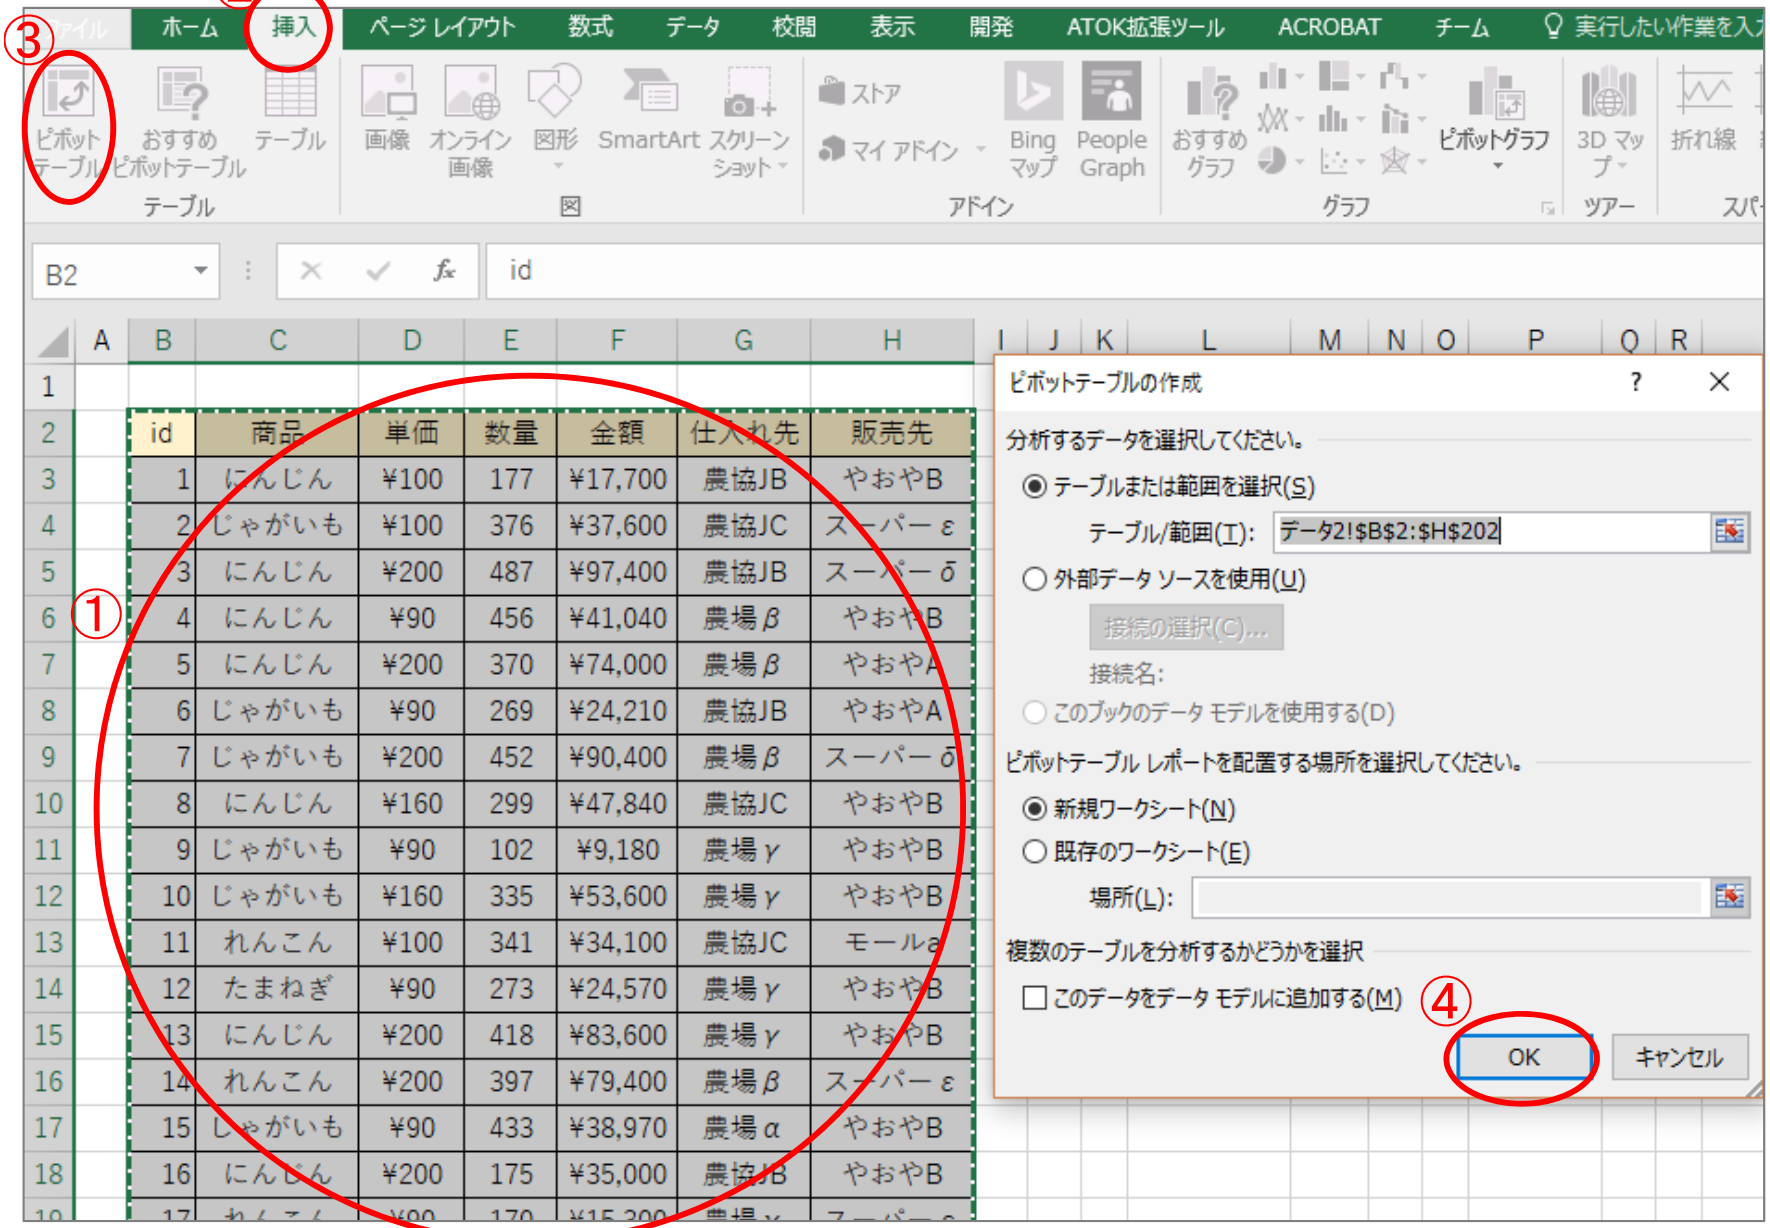

# Excelでクロス集計

- [ピボットテーブルのフィールド]

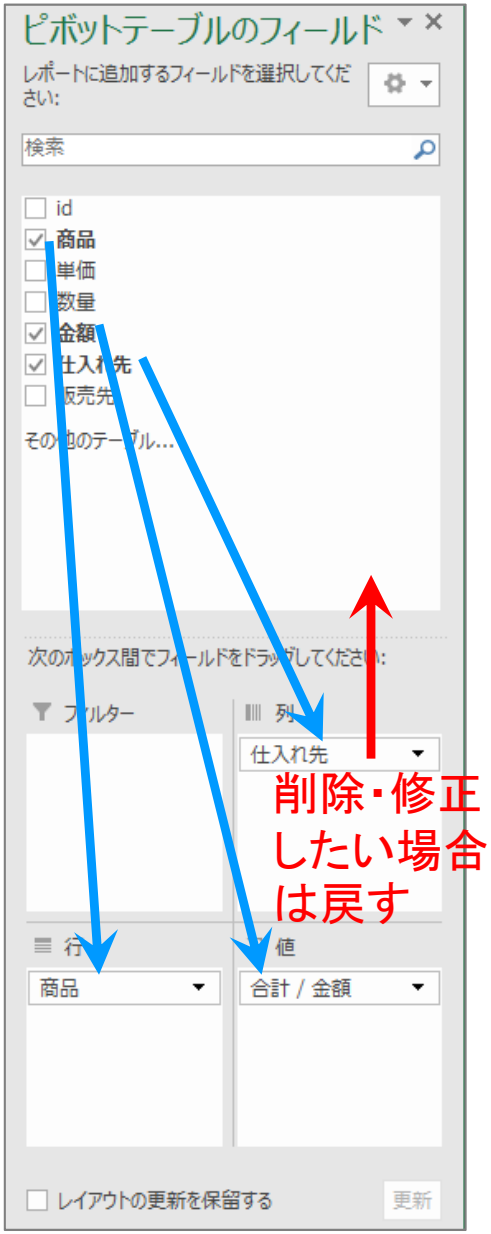


- 上半分にデータの「項目（属性，フィールド）」名が並んでいる
- 下半分の「行」「列」「値」の（最低）3つを指定する
- 「行」「列」にクロスさせたい項目を，「値」に集計したい項目を，それぞれ該当の場所にドラッグ&ドロップ　→クロス集計表がExcelシート内に完成
- 修正・編集も同様（ドラッグ&ドロップ）

例）左の設定でできたクロス集計表
「行」＝「商品」，「列」＝「仕入れ先」，「値」＝「金額」合計

| 合計 / 金額 | 列ラベル | | | | | |
|---|---|---|---|---|---|---|
| 行ラベル | 農協JB | 農協JC | 農場α | 農場β | 農場γ | 総計 |
| じゃがいも | ¥227,990 | ¥209,870 | ¥416,070 | ¥181,680 | ¥301,090 | ¥1,336,700 |
| たまねぎ | ¥632,040 | ¥209,560 | ¥223,420 | ¥208,200 | ¥316,740 | ¥1,589,960 |
| にんじん | ¥455,810 | ¥291,930 | ¥492,780 | ¥443,520 | ¥208,200 | ¥1,892,240 |
| はくさい | ¥359,360 | ¥435,900 | ¥61,860 | ¥398,340 | ¥172,360 | ¥1,427,820 |
| れんこん | ¥425,520 | ¥88,400 | ¥285,020 | ¥437,740 | ¥617,690 | ¥1,854,370 |
| 総計 | ¥2,100,720 | ¥1,235,660 | ¥1,479,150 | ¥1,669,480 | ¥1,616,080 | ¥8,101,090 |

【参考】

# 2変数間の分析法

尺度によって分析法が変わることに注意

- 2変数$x,y$の相関関係を調べる方法（図表と式）
  - 例1

| | A | B | C | D | E | F | G | H | I | J | 尺度 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| 性別 $x$ | 男 | 男 | 女 | 男 | 男 | 男 | 女 | 女 | 男 | 女 | 質的 |
| 嗜好 $y$ | 紅茶 | 緑茶 | 珈琲 | 珈琲 | 緑茶 | 珈琲 | 紅茶 | 珈琲 | 珈琲 | 紅茶 | 質的 |

クロス集計　連関係数

  - 例2

| | A | B | C | D | E | F | G | H | I | J | |
|---|---|---|---|---|---|---|---|---|---|---|---|
| 飲量 $x$ | 15 | 32 | 16 | 30 | 50 | 12 | 14 | 24 | 18 | 19 | 量的 |
| 嗜好 $y$ | 紅茶 | 緑茶 | 珈琲 | 珈琲 | 緑茶 | 珈琲 | 紅茶 | 珈琲 | 珈琲 | 紅茶 | 質的 |

点グラフ　相関比

  - 例3

| | A | B | C | D | E | F | G | H | I | J | |
|---|---|---|---|---|---|---|---|---|---|---|---|
| 身長 $x$ | 176 | 170 | 163 | 173 | 170 | 171 | 165 | 170 | 176 | 156 | 量的 |
| 体重 $y$ | 61 | 73 | 54 | 65 | 67 | 62 | 51 | 57 | 77 | 43 | 量的 |

散布図　相関係数

# 2変数の関係

## 2変数の関係1：$x$(質的)×$y$(質的)図

| | A | B | C | D | E | F | G | H | I | J |
|---|---|---|---|---|---|---|---|---|---|---|
| 性別 $x$ | 男 | 男 | 女 | 男 | 男 | 男 | 女 | 女 | 男 | 女 |
| 嗜好 $y$ | 紅茶 | 緑茶 | 珈琲 | 珈琲 | 緑茶 | 珈琲 | 紅茶 | 珈琲 | 珈琲 | 紅茶 |

質的

質的

クロス集計

| | 紅茶 | 緑茶 | 珈琲 | 計 |
|---|---|---|---|---|
| 男 | 1 | 2 | 3 | 6 |
| 女 | 2 | 0 | 2 | 4 |
| 計 | 3 | 2 | 5 | 10 |

周辺度数

総度数

周辺度数

# 2変数の関係

- 2変数の関係1：$x$(質的)×$y$(質的)式

連関係数

| | 紅茶 | 緑茶 | 珈琲 | 計 |
|---|---|---|---|---|
| 男 | 1 | 2 | 3 | 6 |
| 女 | 2 | 0 | 2 | 4 |
| 計 | 3 | 2 | 5 | 10 |

クロス集計から理論度数を求める

$$1.8=\frac{3\cdot 6}{10} \qquad 2.0=\frac{5\cdot 4}{10}$$

| | 紅茶 | 緑茶 | 珈琲 | 計 |
|---|---|---|---|---|
| 男 | 1.8 | 1.2 | 3.0 | 6 |
| 女 | 1.2 | 0.8 | 2.0 | 4 |
| 計 | 3 | 2 | 5 | 10 |

- クラメルの連関係数 ***Cramer's coefficient of association***

$$V=\sqrt{\frac{\chi^2}{n\cdot m}} \qquad (0\le V\le 1)$$

$$\begin{cases} \chi^2=\dfrac{(1-1.8)^2}{1.8}+\dfrac{(2-1.2)^2}{1.2}+\cdots+\dfrac{(0-0.8)^2}{0.8}+\dfrac{(2-2.0)^2}{2.0} \\ n=10 \\ m=\min\{2-1,3-1\} \end{cases}$$

ピアソンの$\chi^2$統計量

(行数-1)と(列数-1)の小さい方

# 2変数の関係

- 2変数の関係1：$x$(質的)×$y$(質的)式
  - クラメルの連関係数 *Cramer's coefficient of association*

| | 紅 | 緑 | 珈 | 計 |
|---|---|---|---|---|
| 男 | 0 | 3 | 9 | 12 |
| 女 | 6 | 0 | 0 | 6 |
| 計 | 6 | 3 | 9 | 18 |

$$\begin{cases} \chi^2 = \dfrac{(0-4)^2}{4} + \dfrac{(3-2)^2}{2} + \dfrac{(9-6)^2}{6} + \dfrac{(6-2)^2}{2} + \dfrac{(0-1)^2}{1} + \dfrac{(0-3)^2}{3} \\ \quad = 18 \\ n = 18 \\ m = \min\{2-1, 3-1\} = 1 \end{cases}$$

$$\rightarrow V = \sqrt{\frac{18}{18 \cdot 1}} = 1$$ 嗜好と性別は**完全相関**

| | 紅 | 緑 | 珈 | 計 |
|---|---|---|---|---|
| 男 | 3 | 1 | 8 | 12 |
| 女 | 3 | 2 | 1 | 6 |
| 計 | 6 | 3 | 9 | 18 |

$$\begin{cases} \chi^2 = \dfrac{(3-4)^2}{4} + \dfrac{(1-2)^2}{2} + \dfrac{(8-6)^2}{6} + \dfrac{(3-2)^2}{2} + \dfrac{(2-1)^2}{1} + \dfrac{(1-3)^2}{3} \\ \quad = 17/4 \\ n = 18 \\ m = \min\{2-1, 3-1\} = 1 \end{cases}$$

$$\rightarrow V = \sqrt{\frac{17/4}{18 \cdot 1}} \approx 0.49$$ 嗜好と性別は**多少相関**

| | 紅 | 緑 | 珈 | 計 |
|---|---|---|---|---|
| 男 | 4 | 2 | 6 | 12 |
| 女 | 2 | 1 | 3 | 6 |
| 計 | 6 | 3 | 9 | 18 |

$$\begin{cases} \chi^2 = \dfrac{(4-4)^2}{4} + \dfrac{(2-2)^2}{2} + \dfrac{(6-6)^2}{6} + \dfrac{(2-2)^2}{2} + \dfrac{(1-1)^2}{1} + \dfrac{(3-3)^2}{3} \\ \quad = 0 \\ n = 18 \\ m = \min\{2-1, 3-1\} = 1 \end{cases}$$

$$\rightarrow V = \sqrt{\frac{0}{18 \cdot 1}} = 0$$ 嗜好と性別は**無相関**

# 2変数の関係

- 2変数の関係2：$x$(量的)×$y$ (質的)図

| | A | B | C | D | E | F | G | H | I | J |
|---|---|---|---|---|---|---|---|---|---|---|
| 飲量 $x$ | 15 | 32 | 16 | 30 | 50 | 12 | 14 | 24 | 18 | 19 |
| 嗜好 $y$ | 紅茶 | 緑茶 | 珈琲 | 珈琲 | 緑茶 | 珈琲 | 紅茶 | 珈琲 | 珈琲 | 紅茶 |

量的

質的

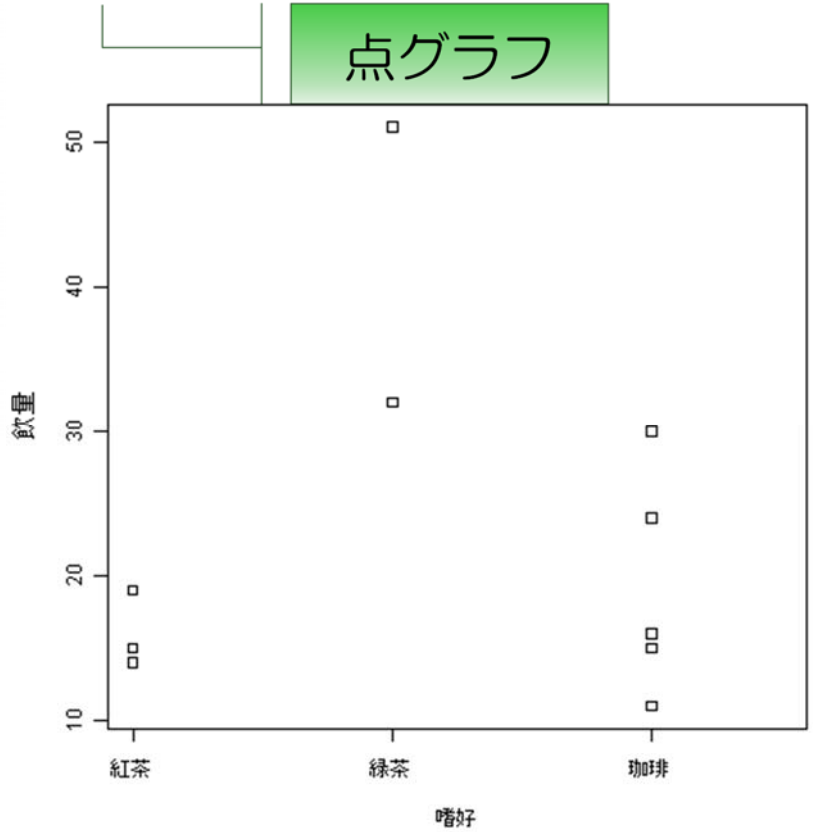

# 2変数の関係

- 2変数の関係2：$x$(量的)×$y$ (質的)式

| | A | B | C | D | E | F | G | H | I | J |
|---|---|---|---|---|---|---|---|---|---|---|
| 飲量 $x$ | 15 | 32 | 16 | 30 | 50 | 12 | 14 | 24 | 18 | 19 |
| 嗜好 $y$ | 紅茶 | 緑茶 | 珈琲 | 珈琲 | 緑茶 | 珈琲 | 紅茶 | 珈琲 | 珈琲 | 紅茶 |

量的

質的

相関比

- 相関比　***correlation ratio***

$$\eta^2 = \frac{S_T}{S_B + S_T}$$

$$\left(0 \le \eta^2 \le 1\right)$$

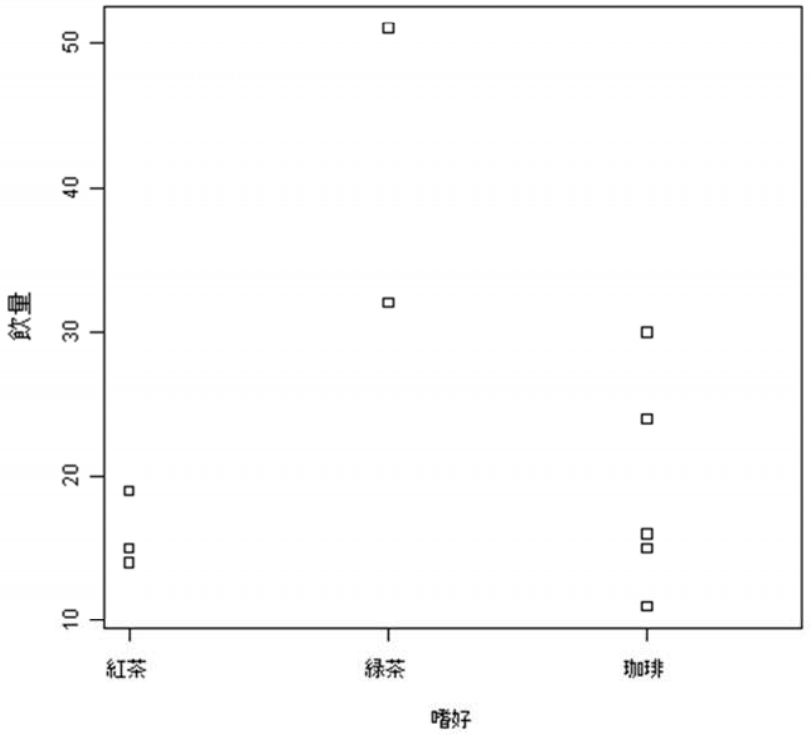

# 2変数の関係

- 2変数の関係2：$x$(量的)×$y$(質的)式
  - 相関比　***correlation ratio***

$$\eta^2 = \frac{S_T}{S_B + S_T} \quad (0 \le \eta^2 \le 1) \qquad \eta^2 = \frac{840}{376+840} \approx 0.691$$

| | 紅茶 | 緑茶 | 珈琲 | |
|---|---|---|---|---|
| | 14 | 32 | 12 | |
| | 15 | 50 | 16 | |
| | 19 | | 18 | |
| | | | 24 | |
| | | | 30 | |
| 個数 | 3 | 2 | 5 | 全平均 |
| 平均 | 16 | 41 | 20 | 23 |
| 偏差平方 | 49 | 324 | 9 | 840= $S_T$ |

級間変動

$49 = (16-23)^2$

$324 = (41-23)^2$

$9 = (20-23)^2$

$S_T = \underline{840} = 49 \times 3 + 324 \times 2 + 9 \times 5$

級間変動
＝級平均と全平均との偏差平方の加重和

| | | | | |
|---|---|---|---|---|
| 偏差平方 | 4 | 81 | 64 | |
| | 1 | 81 | 16 | |
| | 9 | | 4 | |
| | | | 16 | |
| | | | 100 | 合計 |
| 計 | 14 | 162 | 200 | 376= $S_B$ |

級内変動

$14 = (14-16)^2 + (15-16)^2 + (19-16)^2$

$162 = (32-41)^2 + (50-41)^2$

$200 = (12-20)^2 + (16-20)^2 + \ldots + (30-20)^2$

$S_B = \underline{376} = 14 + 162 + 200$

級内変動
＝級内データと級平均との偏差平方の和

# 2変数の関係

- 2変数の関係2：$x$(量的)×$y$(質的)式
  - 相関比　*correlation ratio*

$$\eta^2 = \frac{840}{0+840} = 1$$

嗜好と飲量は**完全相関**

| | 紅茶 | 緑茶 | 珈琲 | |
|---|---|---|---|---|
| | 16 | 41 | 20 | |
| | 16 | 41 | 20 | |
| | 16 | | 20 | |
| | | | 20 | |
| | | | 20 | |
| 個数 | 3 | 2 | 5 | 全平均 |
| 平均 | 16 | 41 | 20 | 23 |
| 偏差平方和 | 49 | 324 | 9 | 840 |
| | | | | 級間変動 |
| 偏差平方和 | 0 | 0 | 0 | |
| | 0 | 0 | 0 | |
| | 0 | | 0 | |
| | | | 0 | |
| | | | 0 | 合計 |
| 計 | 0 | 0 | 0 | 0 |
| | | | | 級内変動 |

$$\eta^2 = \frac{840}{376+840} \approx 0.691$$

嗜好と飲量は**多少相関**

| | 紅茶 | 緑茶 | 珈琲 | |
|---|---|---|---|---|
| | 14 | 32 | 12 | |
| | 15 | 50 | 16 | |
| | 19 | | 18 | |
| | | | 24 | |
| | | | 30 | |
| 個数 | 3 | 2 | 5 | 全平均 |
| 平均 | 16 | 41 | 20 | 23 |
| 偏差平方和 | 49 | 324 | 9 | 840 |
| | | | | 級間変動 |
| 偏差平方和 | 4 | 81 | 64 | |
| | 1 | 81 | 16 | |
| | 9 | | 4 | |
| | | | 16 | |
| | | | 100 | 合計 |
| 計 | 14 | 162 | 200 | 376 |
| | | | | 級内変動 |

$$\eta^2 = \frac{0}{314+0} = 0$$

嗜好と飲量は**無相関**

| | 紅茶 | 緑茶 | 珈琲 | |
|---|---|---|---|---|
| | 19 | 15 | 15 | |
| | 21 | 31 | 20 | |
| | 29 | | 25 | |
| | | | 25 | |
| | | | 30 | |
| 個数 | 3 | 2 | 5 | 全平均 |
| 平均 | 23 | 23 | 23 | 23 |
| 偏差平方和 | 0 | 0 | 0 | 0 |
| | | | | 級間変動 |
| 偏差平方和 | 16 | 64 | 64 | |
| | 4 | 64 | 9 | |
| | 36 | | 4 | |
| | | | 4 | |
| | | | 49 | 合計 |
| 計 | 56 | 128 | 130 | 314 |
| | | | | 級内変動 |

# 2変数の関係

- 2変数の関係3：$x$(量的)×$y$ (量的)図

| | A | B | C | D | E | F | G | H | I | J |
|---|---|---|---|---|---|---|---|---|---|---|
| 身長 $x$ | 176 | 170 | 163 | 173 | 170 | 171 | 165 | 170 | 176 | 156 |
| 体重 $y$ | 61 | 73 | 54 | 65 | 67 | 62 | 51 | 57 | 77 | 43 |

量的

量的

散布図

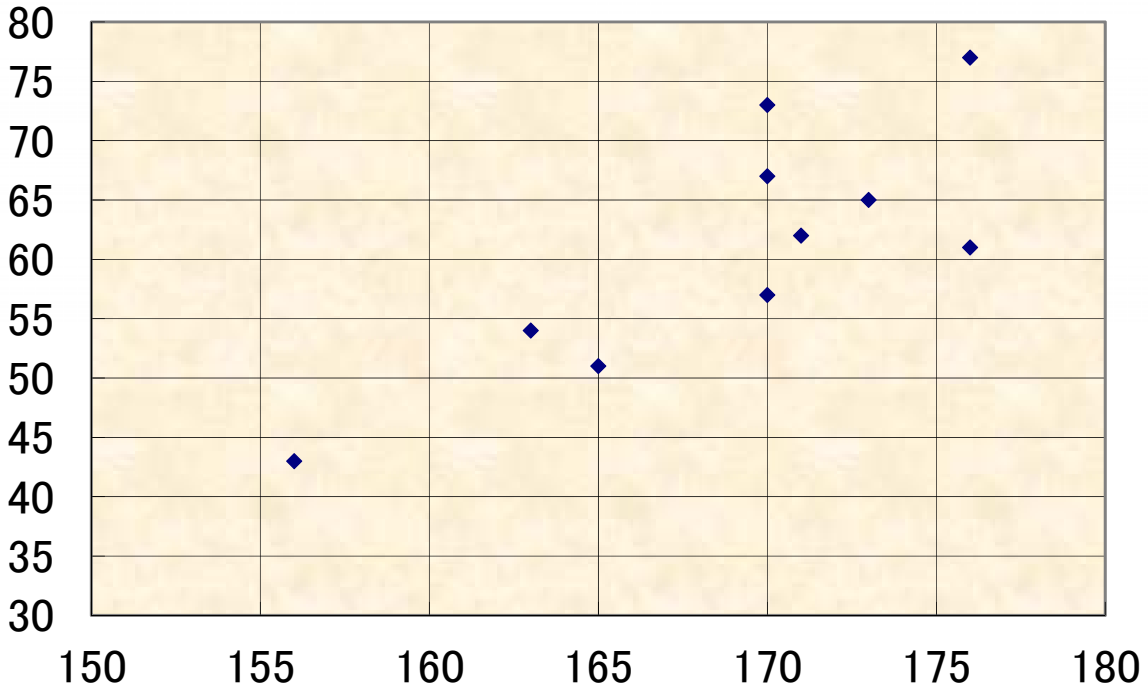

# 2変数の関係

- 2変数の関係3：$x$(量的)×$y$(量的)式

| | A | B | C | D | E | F | G | H | I | J | 平均 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| 身長 $x$ | 176 | 170 | 163 | 173 | 170 | 171 | 165 | 170 | 176 | 156 | 169 |
| 体重 $y$ | 61 | 73 | 54 | 65 | 67 | 62 | 51 | 57 | 77 | 43 | 61 |

相関係数

- ピアソンの積率相関係数 ***Pearson's product-moment correlation coefficient***

$$r_{xy}=\frac{\mathrm{cov}_{xy}}{S_x\cdot S_y}$$

$$\approx\frac{46}{5.848\cdot 9.706}$$

$$\approx 0.81$$

$$\left(-1\le r_{xy}\le 1\right)$$

$$\mathrm{cov}_{xy}=\frac{(176-169)(61-61)+\cdots+(156-169)(43-61)}{10}=46$$

($x$,$y$の共分散)

$$S_x=\sqrt{\frac{(176-169)^2+\cdots+(156-169)^2}{10}}\approx 5.848$$

($x$の標準偏差)

$$S_y=\sqrt{\frac{(61-61)^2+\cdots+(43-61)^2}{10}}\approx 9.706$$

($y$の標準偏差)

# 2変数の関係

- 2変数の関係3：$x$(量的)×$y$ (量的)式
  - ピアソンの積率相関係数 *Pearson's product-moment correlation coefficient*

$$r_{xy} = \frac{\mathrm{cov}_{xy}}{S_x \cdot S_y} \quad (-1 \le r_{xy} \le 1)$$

$$r_{xy} = \frac{\mathrm{cov}_{xy}}{S_x \cdot S_y} = 1$$

身長と体重は**正の相関**

$$r_{xy} = \frac{\mathrm{cov}_{xy}}{S_x \cdot S_y} = 0$$

身長と体重は**無相関**

$$r_{xy} = \frac{\mathrm{cov}_{xy}}{S_x \cdot S_y} = -1$$

身長と体重は**負の相関**