

# 問題解決技法入門

## 4. 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]

The screenshot shows the Microsoft Excel interface. The 'Data' ribbon tab is highlighted with a red circle and the number 2. The 'Filter' button in the 'Data' ribbon is also circled in red with the number 3. In the data table below, the header row (B2:F2) is circled in red with the number 1. A 'Filter' dialog box is open on the right side of the table, showing the 'Filter' button and the 'Filter' dialog box.

	A	B	C	D	E	F	G	H	I	J	K
1											
2		id	性別	年代	嗜好1	嗜好2					
3		1	女性	30	猫	紅茶					
4		2	女性	20	犬	紅茶					
5		3	男性	20	猫	紅茶					
6		4	男性	60	猫	珈琲					
7		5	女性	30	猫	紅茶					
8		6	男性	60	猫	紅茶					

フィルタ (Ctrl+Shift+L)

選択したセルにフィルタを適用します。

列見出しの矢印をクリックして、データを絞り込みます。

詳細情報

# 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

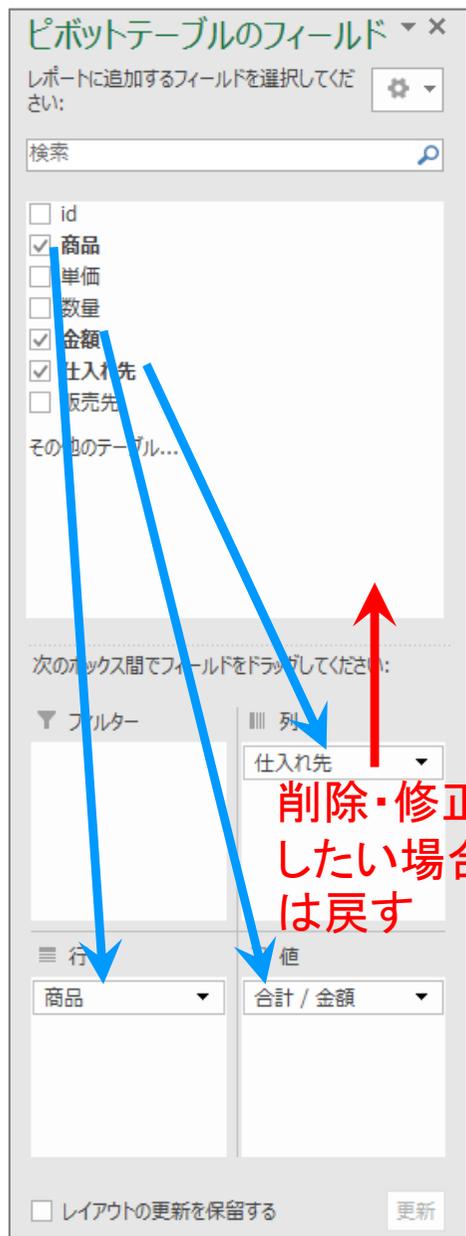
	A	B	C	D	E	F
1						
2		id	性別	年齢	嗜好	嗜好
4		2	女性	20	犬	紅茶
13		11	女性	20	犬	紅茶
17		15	女性	10	犬	紅茶
28		26	女性	40	犬	紅茶
29		27	女性	30	犬	紅茶
31		29	女性	60	犬	紅茶
32		30	女性	60	犬	紅茶
38		36	女性	50	犬	紅茶
41		39	女性	20	犬	紅茶
53		51	女性	40	犬	紅茶
54		52	女性	50	犬	紅茶
55		53	女性	40	犬	紅茶
61		59	女性	60	犬	紅茶
66		64	女性	60	犬	紅茶
74		72	女性	60	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

## • [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**)

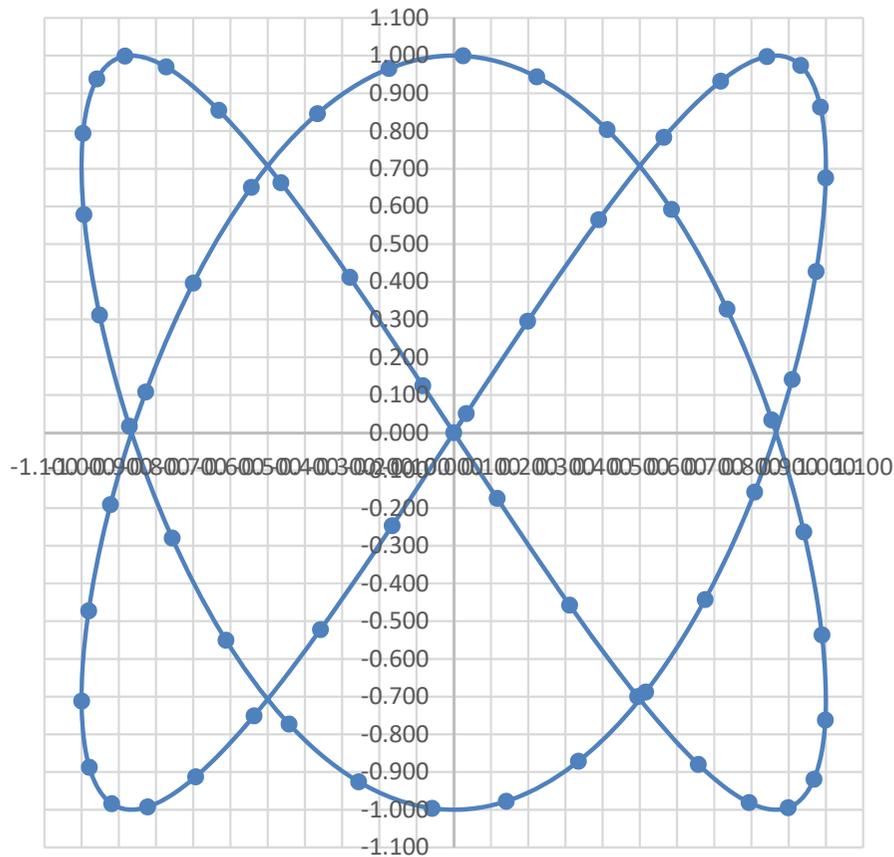
例) 左の設定でできたクロス集計表  
「行」=「商品」, 「列」=「仕入れ先」, 「値」=「金額」合計

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

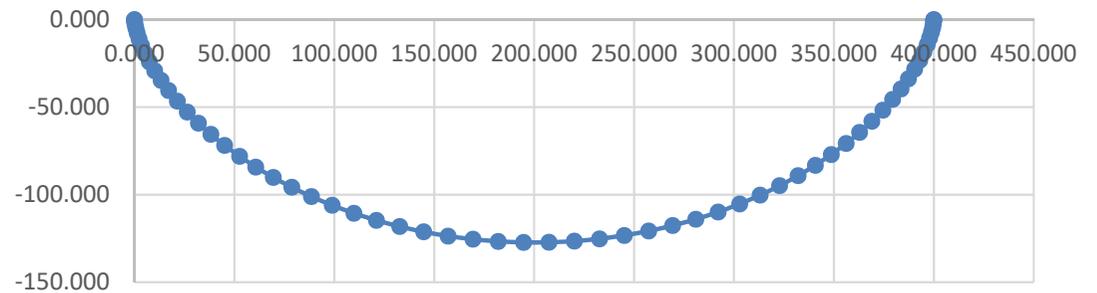
## • 媒介変数表記とExcel散布図(平滑線)による関数の描画

- リサージュ曲線
- サイクロイド曲線
- 2次曲線(円・楕円・双曲線)

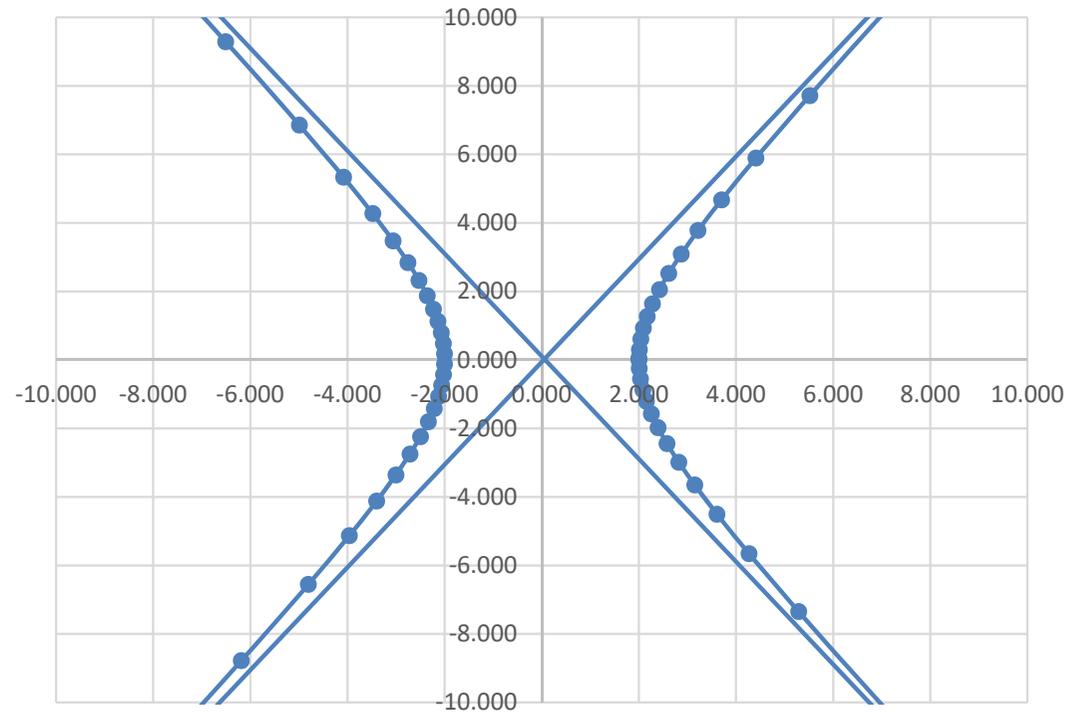
リサージュ曲線



サイクロイド曲線



2次曲線



# 【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



例2

	A	B	C	D	E	F	G	H	I	J	尺度
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



例3

	A	B	C	D	E	F	G	H	I	J	尺度
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



# 2変数の関係

□ 2変数の関係1:  $x$ (質的)  $\times$   $y$ (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	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

	紅茶	緑茶	珈琲	計	
男	1	2	3	6	} 周辺度数
女	2	0	2	4	
計	3	2	5	10	← 総度数

} 周辺度数

# 2変数の関係

## □ 2変数の関係1: $x$ (質的) $\times$ $y$ (質的)式

	紅茶	緑茶	珈琲	計	連関係数		紅茶	緑茶	珈琲	計
男	1	2	3	6	クロス集計から理論度数を求める	男	1.8	1.2	3.0	6
女	2	0	2	4		女	1.2	0.8	2.0	4
計	3	2	5	10		計	3	2	5	10

$$1.8 = \frac{3 \cdot 6}{10}$$

$$2.0 = \frac{5 \cdot 4}{10}$$

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

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

$$(0 \leq V \leq 1)$$

ピアソンの  
 $\chi^2$ 統計量

$$\chi^2 = \frac{(1-1.8)^2}{1.8} + \frac{(2-1.2)^2}{1.2} + \dots + \frac{(0-0.8)^2}{0.8} + \frac{(2-2.0)^2}{2.0}$$

$$n = 10$$

$$m = \min\{2-1, 3-1\}$$

(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) $\times$ $y$ (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

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

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

$$\chi^2 = \frac{(0-4)^2}{4} + \frac{(3-2)^2}{2} + \frac{(9-6)^2}{6} + \frac{(6-2)^2}{2} + \frac{(0-1)^2}{1} + \frac{(0-3)^2}{3}$$

$$= 18$$

$$n = 18$$

$$m = \min\{2-1, 3-1\} = 1$$

$$\rightarrow V = \sqrt{\frac{18}{18 \cdot 1}} = 1$$

嗜好と性別は **完全相関**

$$\chi^2 = \frac{(3-4)^2}{4} + \frac{(1-2)^2}{2} + \frac{(8-6)^2}{6} + \frac{(3-2)^2}{2} + \frac{(2-1)^2}{1} + \frac{(1-3)^2}{3}$$

$$= 17/4$$

$$n = 18$$

$$m = \min\{2-1, 3-1\} = 1$$

$$\rightarrow V = \sqrt{\frac{17/4}{18 \cdot 1}} \approx 0.49$$

嗜好と性別は **多少相関**

$$\chi^2 = \frac{(4-4)^2}{4} + \frac{(2-2)^2}{2} + \frac{(6-6)^2}{6} + \frac{(2-2)^2}{2} + \frac{(1-1)^2}{1} + \frac{(3-3)^2}{3}$$

$$= 0$$

$$n = 18$$

$$m = \min\{2-1, 3-1\} = 1$$

$$\rightarrow V = \sqrt{\frac{0}{18 \cdot 1}} = 0$$

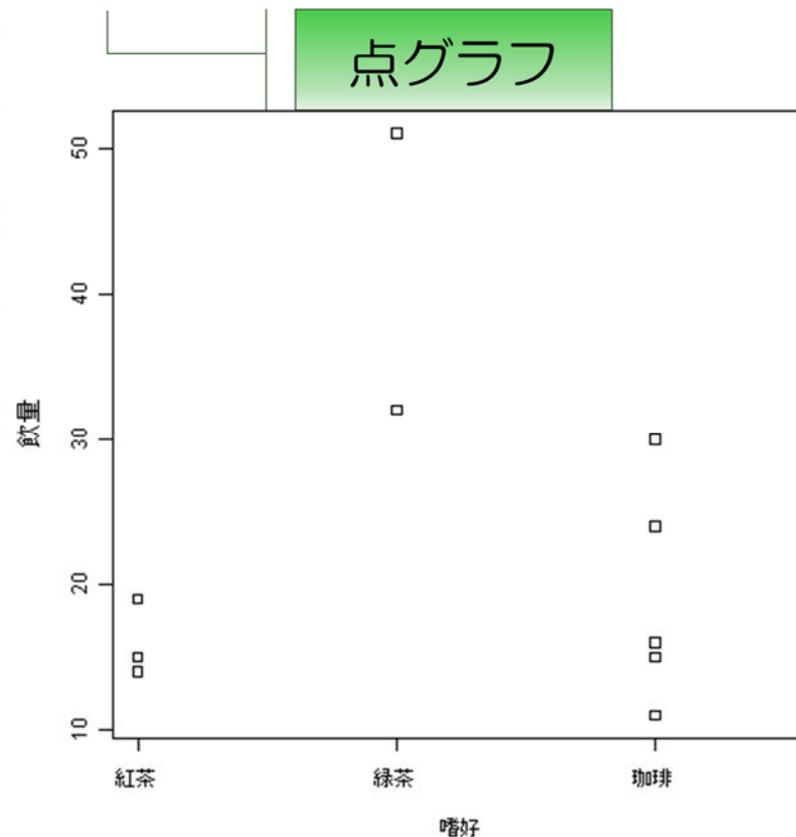
嗜好と性別は **無相関**

# 2変数の関係

□ 2変数の関係2:  $x$ (量的)  $\times$   $y$ (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) $\times$ $y$ (質的)式

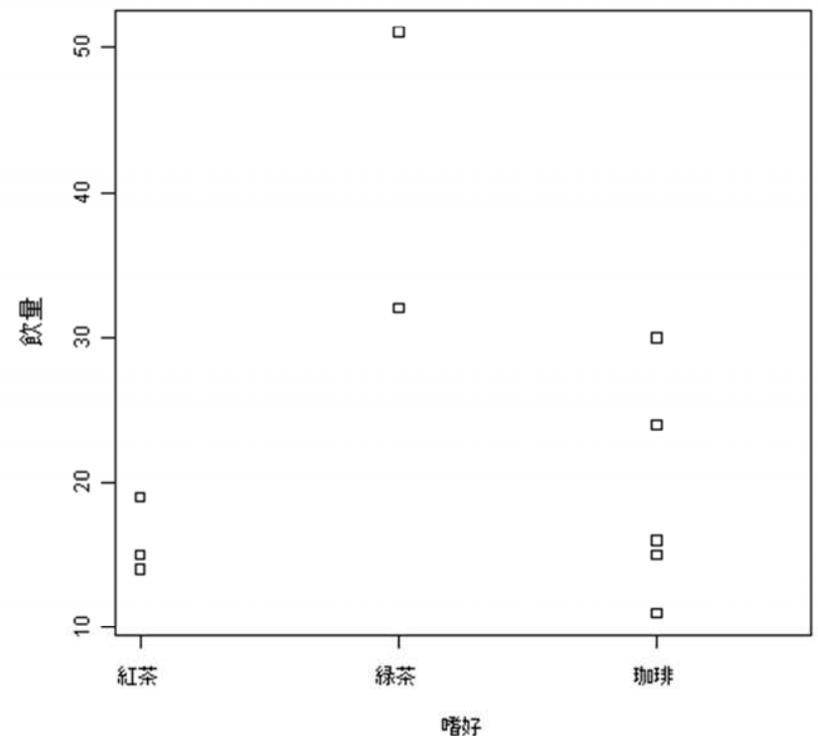
	A	B	C	D	E	F	G	H	I	J	
飲量 $x$	15	32	16	30	50	12	14	24	18	19	量的
嗜好 $y$	紅茶	綠茶	珈琲	珈琲	綠茶	珈琲	紅茶	珈琲	珈琲	紅茶	質的

相関比

## □ 相関比 *correlation ratio*

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

$$(0 \leq \eta^2 \leq 1)$$



# 2変数の関係

## □ 2変数の関係2: $x$ (量的) $\times$ $y$ (質的)式

### □ 相関比 *correlation ratio*

$$\eta^2 = \frac{S_T}{S_B + S_T} \quad (0 \leq \eta^2 \leq 1)$$

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

	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 = $S_T$

$$49 = (16 - 23)^2$$

$$324 = (41 - 23)^2$$

$$9 = (20 - 23)^2$$

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

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	
計	14	162	200	合計
			376 = $S_B$	

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

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

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

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

級内変動

= 級内データと級平均との偏差平方の和

級内変動

# 2変数の関係

## □ 2変数の関係2: $x$ (量的) $\times$ $y$ (質的)式

### □ 相関比 *correlation ratio*

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

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

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

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	<b>840</b>

級間変動

偏差平方和	0	0	0	
	0	0	0	
	0		0	
			0	
			0	
			0	合計

級内変動

計	0	0	0	<b>0</b>
---	---	---	---	----------

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	<b>840</b>

級間変動

偏差平方和	4	81	64	
	1	81	16	
	9		4	
			16	
			100	合計

級内変動

計	14	162	200	<b>376</b>
---	----	-----	-----	------------

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	<b>0</b>

級間変動

偏差平方和	16	64	64	
	4	64	9	
	36		4	
			4	
			49	合計

級内変動

計	56	128	130	<b>314</b>
---	----	-----	-----	------------

# 2変数の関係

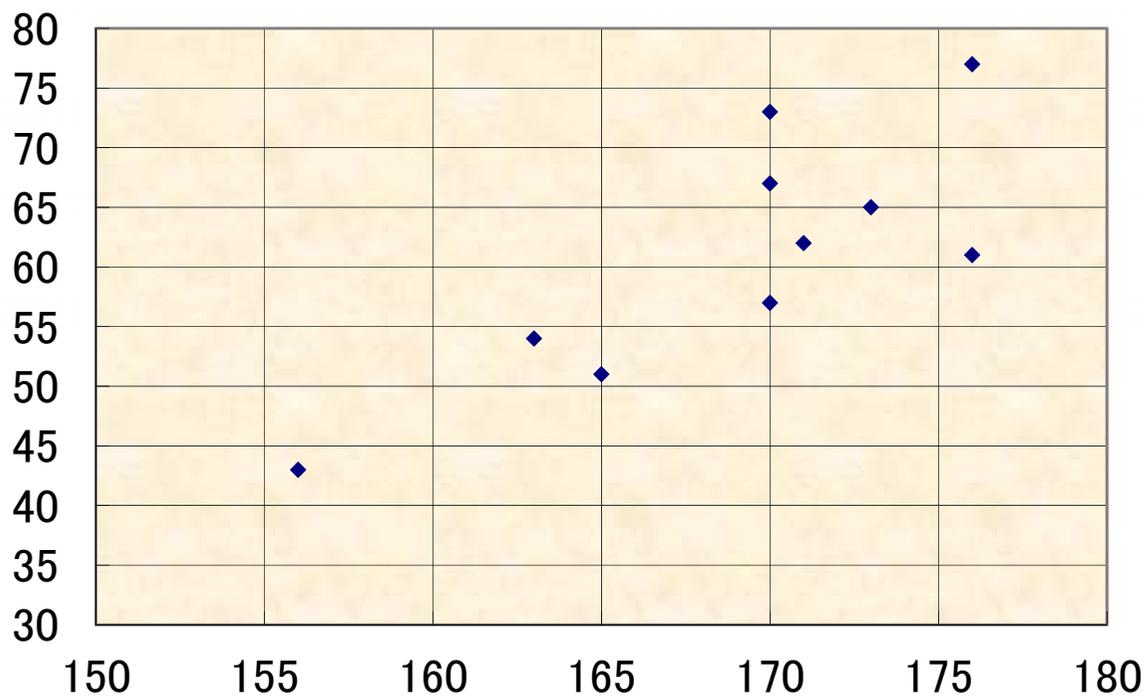
## □ 2変数の関係3: $x$ (量的) $\times$ $y$ (量的) 図

	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) $\times$ $y$ (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*

$$r_{xy} = \frac{\text{COV}_{xy}}{S_x \cdot S_y}$$

$$\approx \frac{46}{5.848 \cdot 9.706}$$
$$\approx 0.81$$

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

$$\left\{ \begin{array}{l} \text{COV}_{xy} = \frac{(176-169)(61-61) + \dots + (156-169)(43-61)}{10} = 46 \quad (x,y \text{の共分散}) \\ S_x = \sqrt{\frac{(176-169)^2 + \dots + (156-169)^2}{10}} \approx 5.848 \quad (x \text{の標準偏差}) \\ S_y = \sqrt{\frac{(61-61)^2 + \dots + (43-61)^2}{10}} \approx 9.706 \quad (y \text{の標準偏差}) \end{array} \right.$$

# 2変数の関係

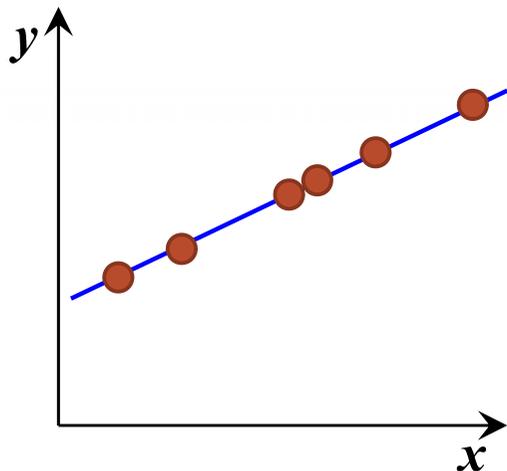
## □ 2変数の関係3: $x$ (量的) $\times$ $y$ (量的)式

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

$$r_{xy} = \frac{\text{COV}_{xy}}{S_x \cdot S_y} \quad (-1 \leq r_{xy} \leq 1)$$

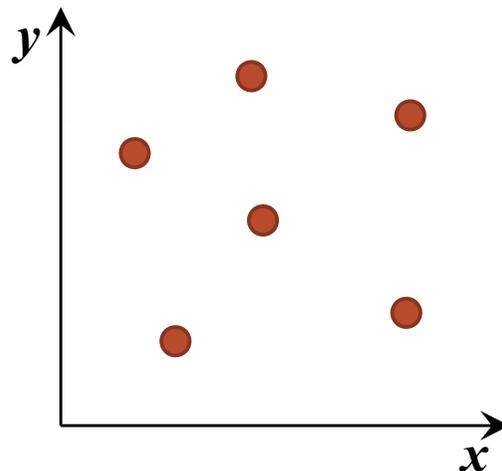
$$r_{xy} = \frac{\text{COV}_{xy}}{S_x \cdot S_y} = 1$$

身長と体重は正の相関



$$r_{xy} = \frac{\text{COV}_{xy}}{S_x \cdot S_y} = 0$$

身長と体重は無相関



$$r_{xy} = \frac{\text{COV}_{xy}}{S_x \cdot S_y} = -1$$

身長と体重は負の相関

