

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

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

ここを加工した

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]

Excelの「データ」タブと「フィルタ」機能の使用方法を示すスクリーンショット。図中の①はデータ項目の選択、②は「データ」タブ、③は「フィルタ」ボタンを示しています。

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

	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					

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

※ 論理積 (かつ, AND) でフィルタがかかる

フィルタで選択

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


< 論理演算の例 >

- ✓ 論理積 AND/intersection/logical conjunction/logical product
- ✓ 論理和 OR/union/logical disjunction/logical add/logical sum
- ✓ 論理否定 not
- ✓ 排他的論理和 XOR/exclusive or

	A	B	C	D	E	F
1						
2		id	性別	年	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						

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]



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
- 「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」=「年代」
「列」=「嗜好1」
「値」=「id」

これだと集計値がおかしい。「値」が[合計/id]なので修正する

	A	B	C	D
1				
2				
3	合計 / id	列ラベル		
4	行ラベル	犬	猫	総計
5	10	1284	727	2011
6	20	1330	1120	2450
7	30	1312	2367	3679
8	40	1780	2930	4710
9	50	1040	2065	3105
10	60	1908	1837	3745
11	70	400		400
12	総計	9054	11046	20100
13				
14				


Excelでクロス集計

- [ピボットテーブルのフィールド]の修正



① [合計/id]を右クリックし, 「値フィールドの設定(N)」を選択

② [個数]を選択し, [OK]クリック



正しい(欲しい)
集計表になった

	A	B	C	D
1				
2				
3	個数 / id	列ラベル		
4	行ラベル	犬	猫	総計
5	10	13	7	20
6	20	16	16	32
7	30	16	23	39
8	40	16	25	41
9	50	13	16	29
10	60	19	17	36
11	70	3		3
12	総計	96	104	200

Excelでクロス集計

- [ピボットテーブルのフィールド]の**操作1**

ピボットテーブルのフィールド

レポートに追加するフィールドを選択してください:

検索

☒ id
☒ 性別
☐ 年代
☐ 嗜好1
☒ 嗜好2

その他のテーブル...

①

次のボックス間でフィールドをドラッグしてください:

フィルター

列
嗜好2

行
性別

値
個数 / id

① [年代]→[性別]に変更

※[年代]を下から上(①のあたり)へdrag&drop
or [年代]の☑を外す(どちらでもよい)

※[性別]を上から下([行]の中)へdrag&drop

② [嗜好1]→[嗜好2]に変更

※[嗜好1]を下から上(①のあたり)へdrag&drop
or [嗜好1]の☑を外す(どちらでもよい)

※[嗜好2]を上から下([列]の中)へdrag&drop



	A	B	C	D
1				
2				
3	個数 / id	列ラベル		
4	行ラベル	紅茶	珈琲	総計
5	女性	53	41	94
6	男性	57	49	106
7	総計	110	90	200
8				

新しい(欲しい)集計表に変わった

Excelでクロス集計

• [ピボットテーブルのフィールド]の操作2

☒ id
☒ 性別
☐ 年代
☒ 嗜好1
☒ 嗜好2
その他のテーブル...

次のボックス間でフィールドをドラッグしてください:

▼ フィルター

≡ 行

性別 ▼

≡ 列

嗜好1 ▼

嗜好2 ▼

Σ 値

個数 / id ▼



	A	B	C	D	E	F	G	H
1								
2								
3	個数 / id	列ラベル ▼						
4		犬		犬 集計	猫		猫 集計	総計
5	行ラベル ▼	紅茶	珈琲		紅茶	珈琲		
6	女性	28	18	46	25	23	48	94
7	男性	30	20	50	27	29	56	106
8	総計	58	38	96	52	52	104	200

「行」=「性別」
「列」=「嗜好1」「嗜好2」
「値」=「id(個数)」

☒ id
☒ 性別
☒ 年代
☒ 嗜好1
☐ 嗜好2
その他のテーブル...

次のボックス間でフィールドをドラッグしてください:

▼ フィルター

≡ 行

性別 ▼

年代 ▼

≡ 列

嗜好1 ▼

Σ 値

個数 / id ▼


「行」=「性別」「年代」
「列」=「嗜好1」
「値」=「id(個数)」




	A	B	C	D
1				
2				
3	個数 / id	列ラベル ▼		
4	行ラベル ▼	犬	猫	総計
5	女性	46	48	94
6	10	7	6	13
7	20	9	6	15
8	30	4	10	14
9	40	10	12	22
10	50	6	9	15
11	60	10	5	15
12	男性	50	56	106
13	10	6	1	7
14	20	7	10	17
15	30	12	13	25
16	40	6	13	19
17	50	7	7	14
18	60	9	12	21
19	70	3		3
20	総計	96	104	200

- 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

クロス集計

連関係数

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

点グラフ

相関比

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

散布図

相関係数

2変数の関係

□ 2変数の関係1 : x (質的) $\times y$ (質的) ㊦

	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
男	1	2	3	6
女	2	0	2	4
計	3	2	5	10

連関係数

クロス集計から理論度数を求める

	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

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

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

□ クラメル の 連関係数 *Cramer's coefficient of association*

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

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

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

$$n = 10$$

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

ピアソンの
 χ^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

$$\left\{ \begin{aligned} \chi^2 &= \frac{(0-4)^2}{4} + \frac{(3-2)^2}{2} + \frac{(9-6)^2}{6} \\ &\quad + \frac{(6-2)^2}{2} + \frac{(0-1)^2}{1} + \frac{(0-3)^2}{3} \\ &= 18 \\ n &= 18 \\ m &= \min\{2-1, 3-1\} = 1 \end{aligned} \right.$$

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

$$\left\{ \begin{aligned} \chi^2 &= \frac{(3-4)^2}{4} + \frac{(1-2)^2}{2} + \frac{(8-6)^2}{6} \\ &\quad + \frac{(3-2)^2}{2} + \frac{(2-1)^2}{1} + \frac{(1-3)^2}{3} \\ &= 17/4 \\ n &= 18 \\ m &= \min\{2-1, 3-1\} = 1 \end{aligned} \right.$$

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

$$\left\{ \begin{aligned} \chi^2 &= \frac{(4-4)^2}{4} + \frac{(2-2)^2}{2} + \frac{(6-6)^2}{6} \\ &\quad + \frac{(2-2)^2}{2} + \frac{(1-1)^2}{1} + \frac{(3-3)^2}{3} \\ &= 0 \\ n &= 18 \\ m &= \min\{2-1, 3-1\} = 1 \end{aligned} \right.$$

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


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	緑茶	珈琲	珈琲	緑茶	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
平均	16	41	20
偏差平方	49	324	9

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

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

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

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

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

級間変動

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

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

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

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

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	840

級間変動

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

級内変動

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

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) $\times y$ (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)×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)×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

