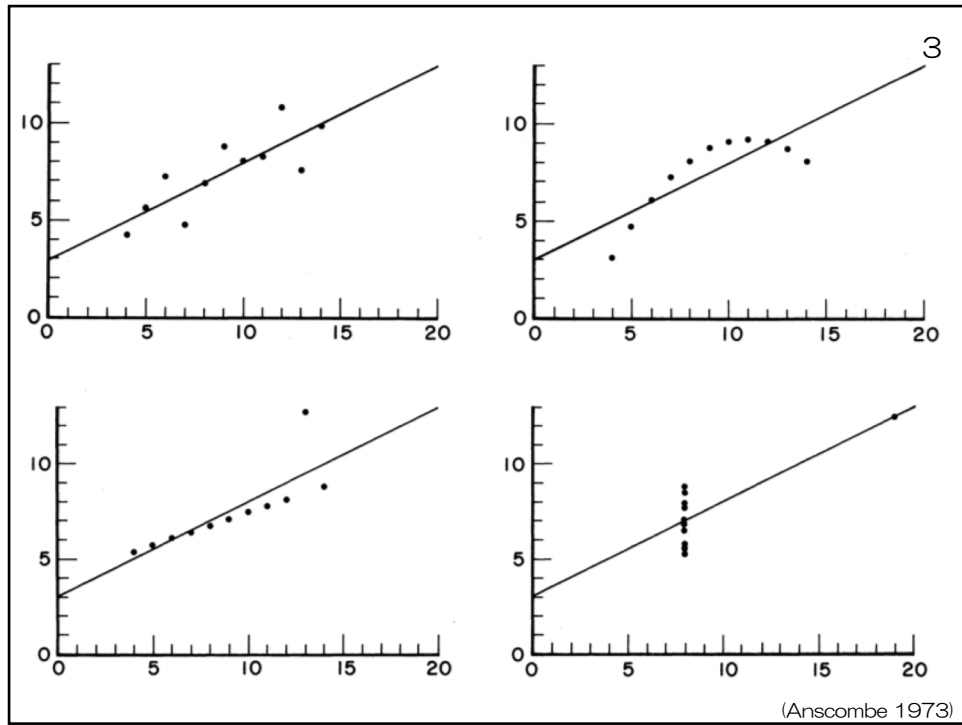


1 1. 2変数の関係の分析  
(相関分析)  
(連関分析)

内 容

2

1. 相関係数
2. 連関係数
3. 順位相関係数



## 1. 相関係数


4

5

## 散布図、共分散

$$(x_i - \bar{x})(y_i - \bar{y})$$

平均を原点として、  
右上と左下は正  
右下と左上は負



共分散

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

6

(Pearsonの積率) 相関係数  $r$ 

完全な正の相関があるような場合

$$s_{xy} = s_x s_y$$

完全な負の相関があるような場合

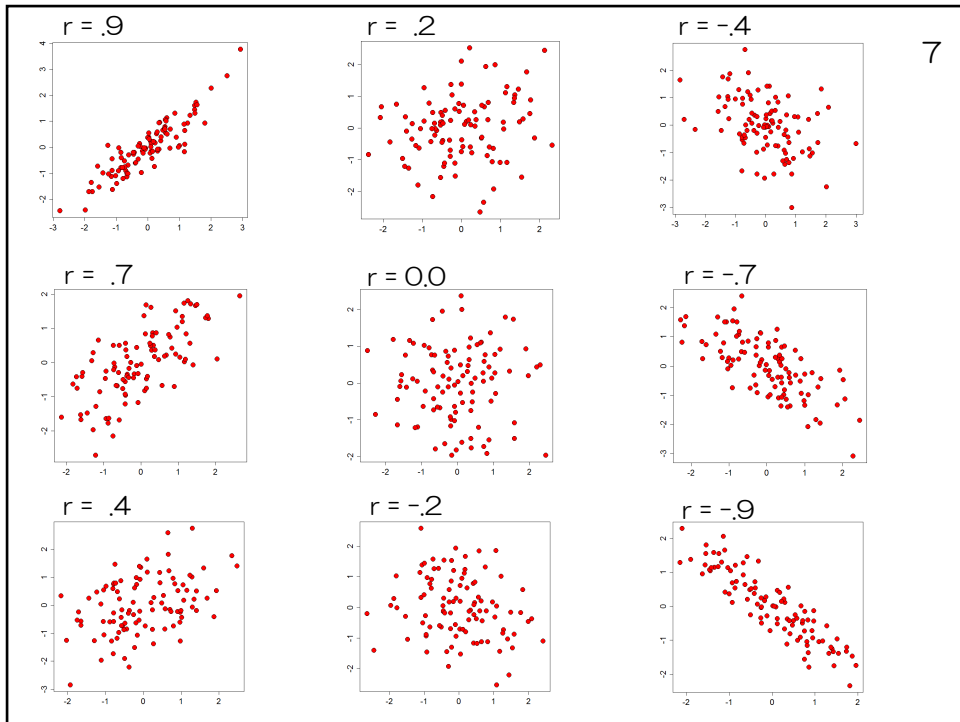
$$s_{xy} = -s_x s_y$$

共分散の取りうる範囲

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

 $s_x s_y$  で割ると

$$-1 \leq \frac{s_{xy}}{s_x s_y} \leq 1$$



8

関連の強さに関する、おおよその目安

$.7 <  r  \leq 1.$	強い相関あり
$.4 <  r  \leq .7$	比較的強い相関あり
$.2 <  r  \leq .4$	弱い相関あり
$0 \leq  r  \leq .2$	ほとんど相関なし


### 相関係数の留意点

9


- 外れ値の影響
- 切断効果
- 分割相関（層別相関）
- 曲線相関
- 疑似相関

外れ値の影響

$r = -.232$




$r = .844$



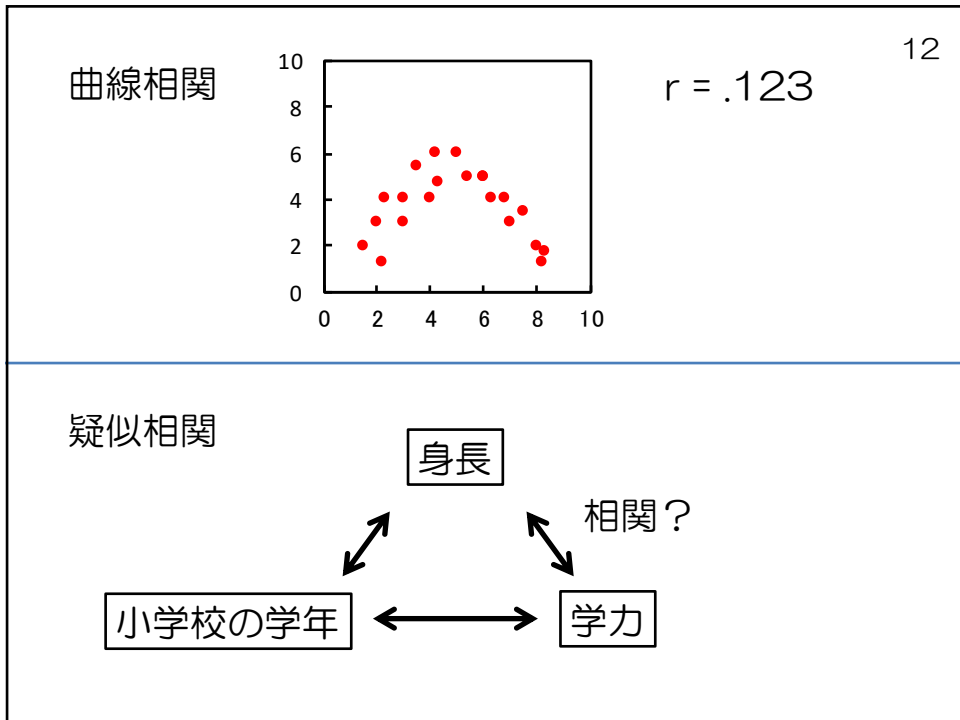
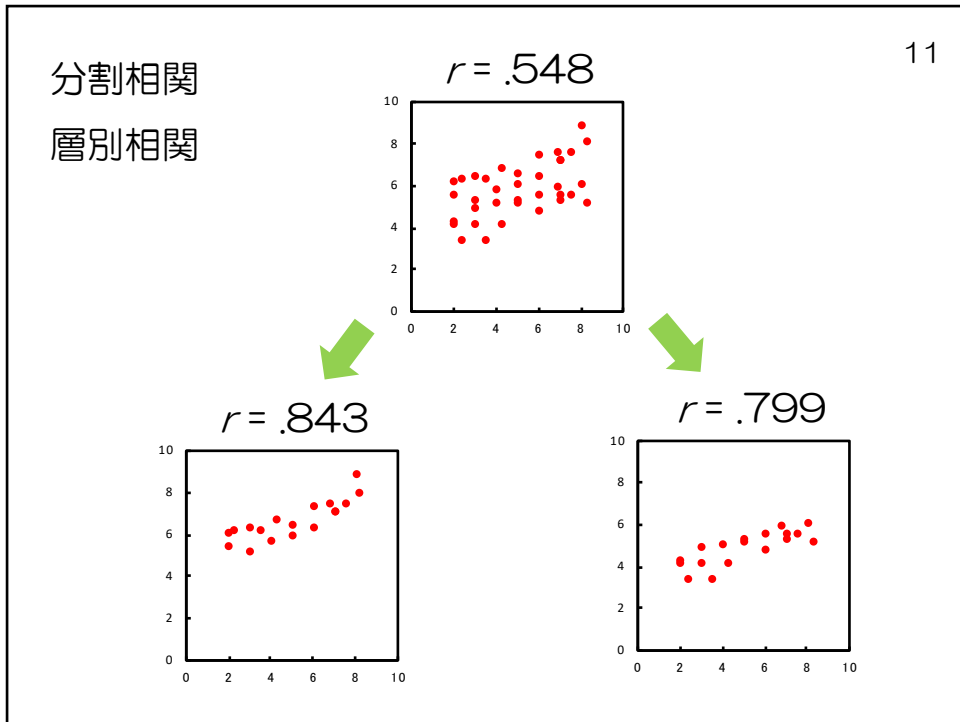
10

切断効果  
選抜効果



$r = .765$

$r = .329$  (横軸6以上)




13

x	6	4	4	2	6	5	4	7	4	3
y	5	4	3	3	6	3	5	5	6	2

```
x <- c(6, 4, 4, 2, 6, 5, 4, 7, 4, 3)
y <- c(5, 4, 3, 3, 6, 3, 5, 5, 6, 2)
cor(x, y)
```

```
[1] 0.5791078
```



14

### 無相関検定

$H_0$  : 母相関係数 = 0

$H_1$  : 母相関係数  $\neq$  0

$$t_0 = \frac{|r|\sqrt{n-2}}{\sqrt{1-r^2}} \sim t_{n-2} \text{分布}$$

15

x	6	4	4	2	6	5	4	7	4	3
y	5	4	3	3	6	3	5	5	6	2

```
x <- c(6, 4, 4, 2, 6, 5, 4, 7, 4, 3)
```

```
y <- c(5, 4, 3, 3, 6, 3, 5, 5, 6, 2)
```

```
cor.test(x, y)
```

ピアソンの積率相関係数

データ: x と y

t値 = 2.0092, 自由度 = 8, P値 = 0.07938

対立仮説: 母相関は, 0ではない

95 パーセント信頼区間: -0.07950929

0.88576510

標本推定値:

相関係数

0.5791078

16

## 相関の差の検定

$H_0$  : 母相関係数の間に差がない

$H_1$  : いずれかの母相関係数の間に差がある

互いに独立な  $k$  個の標本の相関係数の有意差検定

$$z' = \frac{1}{2} \log_e \frac{1+r}{1-r} \quad \text{フィッシャーの } z' \text{ 変換}$$

$$\chi^2 = \sum_i^k z_i'^2 (N_i - 3) - \left\{ \sum_i^k z_i' (N_i - 3) \right\}^2 / \sum_i^k (N_i - 3)$$

$\sim \chi^2 (k-1)$  分布



17

group	1	2	3	4
n	25	20	30	25
r	0.543	0.458	0.632	0.521

```
n <- c(25, 20, 30, 25)
r <- c(0.543, 0.458, 0.632, 0.521)
eq.cor(n, r)
```

標本相関係数の同等性の検定

```
data: n and r
chi sq. = 0.729, df = 3, p-value = 0.8664
sample estimates:
Estimated rho
0.5515522
```

18

## 2. 連関係数

カテゴリカルなデータの相関

2×2分割表

- 四分点相関係数
- $\phi$  係数
- Yuleの連関係数 (Q)

$l \times m$  分割表

- Cramé r の連関係数 (V)
- Goodman-Kruskalの順序連関係数 ( $\gamma$ )

## 四分点相関係数

各カテゴリーを0と1に置き換えて、相関係数を求めたもの

	はい	いいえ
男子	2	3
女子	1	2

ケース	1	2	3	4	5	6	7	8
性別	1	1	0	1	1	1	0	0
意見	1	1	1	0	0	0	0	0

 $\phi$ 係数

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

$$0 \leq \phi \leq 1$$

	はい	いいえ
男子	23	26
女子	12	19

```
dat <- matrix(c(23, 26, 12, 19), ncol=2, byrow=T)
x <- chisq.test(dat, correct=F)
(a <- sqrt(x$statistic/sum(dat)))
```

```
[1] 0.08081479
```

## Cramé r の連関係数 (V)

 $l \times m$  分割表 (クロス集計表)

	a <sub>1</sub>	a <sub>2</sub>	a <sub>3</sub>	Σ
b <sub>1</sub>				
b <sub>2</sub>				
Σ				

$$V = \sqrt{\frac{\chi^2}{(\min(l, m) - 1) \times n}}$$

$$0 \leq V \leq 1$$

名義尺度の例題)

	優	良	可	不可
A	7	12	18	13
B	11	15	15	9
C	20	12	13	5

```
dat <-
matrix(c(7, 12, 18, 13, 11, 15, 15, 9, 20, 12, 13, 5), ncol=4, byrow=T)
x <- chisq.test(dat, correct=F)
(v <- sqrt(x$statistic/((min(ncol(dat), nrow(dat))-
1)*sum(dat))))
```

```
[1] 0.1986889
```

関連の強さに関する、おおよその目安

$.8 < r_c$	非常に強い相関あり
$.5 \leq r_c < 0.8$	やや強い相関あり
$.25 \leq r_c < 0.5$	やや弱い相関あり
$r_c < 0.25$	ほとんど相関なし

### 3. 順位相関係数

順位相関係数

Spearman

Kendall

一致性係数

Spearmanの順位相関係数  $r_s$ 

順位をデータ値としてスピアマンの積率相関係数を計算したもの

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$$

関連の強さの目安は積率相関係数と同じ

例題)

A、Bの2名で8つのサンプルに順位を付けた。  
2名の順位の付け方について、スピアマン順位相関係数を求め、関連性について検討せよ。

	1	2	3	4	5	6	7	8	9	10
A	8	9	2	10	1	4	5	3	7	6
B	6	10	2	9	4	5	3	1	7	8

```
dataA <- c(8, 9, 2, 10, 1, 4, 5, 3, 7, 6)
```

```
dataB <- c(6, 10, 2, 9, 4, 5, 3, 1, 7, 8)
```

```
cor.test(dataA, dataB, method="spearman")
```

27

```
dataA <- c(8, 9, 2, 10, 1, 4, 5, 3, 7, 6)
dataB <- c(6, 10, 2, 9, 4, 5, 3, 1, 7, 8)
cor.test(dataA, dataB, method="spearman")
```

スピアマンの順位相関係数

データ: dataA と dataB

S = 28, P値 = 0.005557

対立仮説: 母相関 ( $\rho$ ) は, 0ではない

標本推定値:

$\rho$   
0.830303

28

Kendallの順位相関係数  $\tau$

$$\tau = \frac{2P}{\frac{1}{2}n(n-1)} = \frac{4P}{n(n-1)} - 1$$

Pは大小関係が一致する組の数

例題)

29

A、Bの2名で8つのサンプルに順位を付けた。  
2名の順位の付け方について、ケンドール順位相  
関係数を求め、関連性について検討せよ。

	1	2	3	4	5	6	7	8	9	10
A	8	9	2	10	1	4	5	3	7	6
B	6	10	2	9	4	5	3	1	7	8

```
dataA <- c(8, 9, 2, 10, 1, 4, 5, 3, 7, 6)
dataB <- c(6, 10, 2, 9, 4, 5, 3, 1, 7, 8)
cor.test(dataA, dataB, method="kendall")
```

30

```
dataA <- c(8, 9, 2, 10, 1, 4, 5, 3, 7, 6)
dataB <- c(6, 10, 2, 9, 4, 5, 3, 1, 7, 8)
cor.test(dataA, dataB, method="kendall")
```

ケンドールの順位相関係数

データ: dataA と dataB

T = 36, P値 = 0.01667

対立仮説: 母相関 ( $\tau$ ) は、0ではない

標本推定値:

 $\tau$ 

0.6

Kendallの一致性係数  $W$ 

$k$ 組、 $n$ 個の資料

$$S = \sum_{j=1}^n \left\{ S_j - \frac{1}{2} k(n+1) \right\}^2$$

$$W = \frac{12S}{k^2(n^3 - n)}$$

例題)

A、B、Cの2名で8つのサンプルに順位を付けた。2名の順位の付け方について、ケンドールの一致性係数を求め、関連性について検討せよ。

	1	2	3	4	5	6	7	8	9	10
A	8	9	2	10	1	4	5	3	7	6
B	6	10	2	9	4	5	3	1	7	8
C	7	10	3	9	2	4	6	1	8	5



```
source("all.R", encoding="euc-jp")
dat <- matrix ( c (
                8, 9, 2, 10, 1, 4, 5, 3, 7, 6,
                6, 10, 2, 9, 4, 5, 3, 1, 7, 8,
                7, 10, 3, 9, 2, 4, 6, 1, 8, 5
            ), byrow=FALSE, ncol=3)
kendall.w(dat)
```

33

ケンドールの一致度係数

データ: dat

Kendall W = 0.9111, chi sq. = 24.6000, 自由度 = 9,  
P値 = 0.003447

## ポリコリック相関係数

34

順序尺度と順序尺度の相関係数

```
install.packages("polycor")
```

```
library(polycor)
```

```
polychor(x,y)
```

35

## ポリシアル相関係数

連続尺度と順序尺度の相関係数

```
install.packages("polycor")
```

```
library(polycor)
```

```
polyserial(x,y)
```

xが連続変数、yが順序変数

36

## 尺度が混在する場合

事前に順序尺度をfactorで指定

```
install.packages("polycor")
```

```
library(polycor)
```

```
hetcor(x,y)
```