

# シミュレーション論 II

## 第13回

データの分類と数値処理(2)

## 第12回のレポート

- 4つの駅で、一日の乗降人数と売店の売上を調べたところ、以下の表のようになった。乗降人数と売上の関係を最小二乗法を用いて線形回帰せよ。
- あらたに乗降人数が5千人の駅に売店を出すことにした。いくらの売上が見込まれるか推定せよ。

駅	乗降人数(千人)	売上(万円)
A駅	1	19
B駅	2	23
C駅	3	35
D駅	4	37

# 第12回のレポート解答(1)

- データ数  $n = 4$  で、データの組はそれぞれ

$$(x_1, y_1) = (1, 19), \quad (x_2, y_2) = (2, 23), \quad (x_3, y_3) = (3, 35), \quad (x_4, y_4) = (4, 37)$$

a, b は以下の式で求められる

$$\begin{cases} a = \frac{nD - CE}{nB - E^2} \\ b = \frac{BC - DE}{nB - E^2} \end{cases}$$

- ただし

$$B = \sum_{i=1}^n x_i^2, \quad C = \sum_{i=1}^n y_i$$

$$D = \sum_{i=1}^n x_i y_i, \quad E = \sum_{i=1}^n x_i$$

## 第12回のレポート解答(2)

- B~Eを求めると

$$B = \sum_{i=1}^n x_i^2 = 1^2 + 2^2 + 3^2 + 4^2 = 30$$

$$C = \sum_{i=1}^n y_i = 19 + 23 + 35 + 37 = 114$$

$$D = \sum_{i=1}^n x_i y_i = 1 \times 19 + 2 \times 23 + 3 \times 35 + 4 \times 37 = 318$$

$$E = \sum_{i=1}^n x_i = 1 + 2 + 3 + 4 = 10$$

## 第12回のレポート解答(3)

- a, b の式に代入して

$$a = \frac{nD - CE}{nB - E^2} = \frac{4 \times 318 - 114 \times 10}{4 \times 30 - 10^2} = 6.6$$

$$b = \frac{BC - DE}{nB - E^2} = \frac{30 \times 114 - 318 \times 10}{4 \times 30 - 10^2} = 12$$

- よって売上の推定値(回帰直線)は

$$Y = 6.6X + 12$$

- 5000人の乗降客がある駅に新たに店を出した場合の売り上げ予想は

$$6.6 \times 5 + 12 = 45 \text{ (万円)}$$

# 今回の内容


- 2つの変数間に線形の関係がある場合→線形回帰
- 線形回帰をおこなうにあたって、気になること  
変数間の関係性はどのようなものか？  
そもそも本当に線形の関係があるのか？
- 変数の間の関係性(相関)を分析する

# データの相互関係

- 実験やシミュレーション結果、実際の観察データ、種々の統計データなどからデータ間の関係を推定・整理する
- 原因-結果の相互関係が明確になり、モデルの作成や将来の予測が可能となる  
→ 回帰分析・**相関分析**など

経済理論や実データから  
シミュレーションのモデルを作成

$$\log(C) = 0.27261 + 0.26787 * \log(Y) - 0.00542 * R + 0.71102 * \log(C-1)$$



# 線形回帰の注意点

- なんでもかんでも線形回帰をおこなえばいいというわけではない
- 線形回帰は2種類のデータ(2変数)間に「直線的な関係がある」ことが前提になる
- データによって関係性が強いもの、弱いものがある  
→2変数の関係(相関)の強さを調べてやる必要がある
- 相関係数の導出




# 相関係数

- 2変数に関連性がある(片方が大きくなると、もう一方も大きくなる、など)場合、2変数に「相関」があるという
- 相関係数: 相関の度合いを表す数値で、 $R$ で表す
- 相関係数は $-1 \sim +1$ の数値をとる
  - 片方が増えればもう片方も増える → 相関係数は $+$ 、正の相関
  - 片方が増えればもう片方が減る → 相関係数は $-$ 、負の相関
- 絶対値が大きいほど、相関が強い(2変数の間に強い関連性がある)

# 相関係数(正の相関)


- 2変数に「片方が増えれば、もう片方も増える」という関係がある場合を「正の相関」という



相関係数  $R > 0$

# 相関係数(負の相関)


- 2変数に「片方が増えれば、もう片方が減る」という関係がある場合を「負の相関」という



相関係数  $R < 0$

# 相関係数(無相関)

- 2変数に(線形の)関係が(ほとんど)見られない場合、データは円に近い形で分布する。このような場合を無相関という
- このとき相関係数は0に(近く)なる



相関係数  $R \doteq 0$

# 相関係数の式

- $n$  組のデータ  $(x_1, y_1), (x_2, y_2), (x_3, y_3) \wedge (x_n, y_n)$  があるとき、 $x, y$  の相関係数  $R$  は

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

- ただし  $\bar{x}, \bar{y}$  はそれぞれ  $x, y$  の平均  $\frac{1}{n} \sum_{i=1}^n x_i, \frac{1}{n} \sum_{i=1}^n y_i$

## 相関係数の値と関係性の度合い

- 相関係数の絶対値が 1 に近いほど相関の度合いは強くなる
- 一般的には以下のような分類になる
- 相関係数の絶対値が1の場合を「完全な相関」といい、データが一直線上に並ぶ場合に相当する


Rの値	相関の度合い
0	無相関
$0 <  R  \leq 0.2$	ほとんど相関なし
$0.2 <  R  \leq 0.4$	低い相関あり
$0.4 <  R  \leq 0.7$	相関あり
$0.7 <  R  < 1.0$	高い相関あり
1.0 または -1.0	完全な相関

注:これ以外の分類方法もある


# 相関係数の値とデータの並び

- 相関係数  $R$  の絶対値が1のときは以下のようにデータが一直線上に並ぶ

完全な正の相関  
( $R = 1$ )



完全な負の相関  
( $R = -1$ )



# 相関係数の計算(1)

- 以下のようなデータがあるとき、相関係数を計算してみよう

$$(x_1, y_1) = (1, 19)$$

$$(x_2, y_2) = (2, 23)$$

$$(x_3, y_3) = (3, 35)$$

$$(x_4, y_4) = (4, 37)$$

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

$$x \text{ の平均値} : \bar{x} = \frac{1 + 2 + 3 + 4}{4} = 2.5$$

$$y \text{ の平均値} : \bar{y} = \frac{19 + 23 + 35 + 37}{4} = 28.5$$



## 相関係数の計算(2)

- $R$ の分子を計算する

$$\begin{aligned}\text{分子} &: \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n (x_i - 2.5)(y_i - 28.5) \\ &= (1 - 2.5)(19 - 28.5) + (2 - 2.5)(23 - 28.5) \\ &\quad + (3 - 2.5)(35 - 28.5) + (4 - 2.5)(37 - 28.5) \\ &= 14.25 + 2.75 + 3.25 + 12.75 \\ &= 33\end{aligned}$$

# 相関係数の計算(3)

- $R$ の分母を計算する

$$\begin{aligned} \text{分母} &: \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2} \\ &= \sqrt{\{(1-2.5)^2 + (2-2.5)^2 + (3-2.5)^2 + (4-2.5)^2\}} \\ &\quad \times \sqrt{\{(19-28.5)^2 + (23-28.5)^2 + (35-28.5)^2 + (37-28.5)^2\}} \\ &= \sqrt{(2.25 + 0.25 + 0.25 + 2.25) \times (90.25 + 30.25 + 42.25 + 72.25)} \\ &= \sqrt{5 \times 235} \\ &= 34.278... \end{aligned}$$

# 相関係数の計算(4)

- $R$ の値を計算する

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{33}{34.278} = 0.962\dots$$

- 参考: Excelでは関数 CORREL(xの範囲, yの範囲)で計算できる

	A	B
1	x	y
2	1	19
3	2	23
4	3	35
5	4	37
6		
7	相関係数R	0.96270894
8		

=CORREL(A2:A5,B2:B5)

# 相関係数の検定(無相関検定)

- $R = 0.962$  だから、一般的には「 $x, y$  の間に高い相関がある」と言える
- しかし、相関係数の値はデータの個数やバラツキに大きく左右される  
→「たまたま」そうだったのか、関係性があるからそうだったのか
- 2変数の間にちゃんと「相関があるかどうか」を調べてやる必要がある  
→ **無相関検定**

# 無相関検定

- 2変数の間に「相関がない」と仮定して(帰無仮説)、有意性の検定をおこなう
- 相関係数に意味があるかどうか(相関があるかどうか)
- 以下の表で、5%有意水準の値より相関係数  $R$  が大きければ「有意」、つまり相関があるといえる(1%水準はさらに厳しい検定)  
(実際には帰無仮説の棄却なので「無相関であるとはいえない」ということ)

データ数 (n)	5%有意水準	1%有意水準
3	0.997	1.000
4	0.950	0.990
5	0.878	0.959
6	0.811	0.917
7	0.754	0.875
8	0.707	0.834
9	0.666	0.798
10	0.632	0.765
100	0.197	0.256
1000	0.062	0.081



## 無相関検定(2)

- 先ほどの練習問題だと  $n = 4$  だったから、  
 $R > 0.950$  で 5% 有意、 $R > 0.990$  で 1% 有意となる。
- $R = 0.962$  だったので 5% 有意となり「2変数  $x, y$  に相関がある」といえる

データ数 (n)	5%有意水準	1%有意水準
3	0.997	1.000
4	0.950	0.990
5	0.878	0.959
6	0.811	0.917
7	0.754	0.875
8	0.707	0.834
9	0.666	0.798
10	0.632	0.765
100	0.197	0.256
1000	0.062	0.081

# 相関分析の注意点

- 相関係数の絶対値が1に近くても必ずしも相関があるとはいえない(無相関検定)
- 相関分析はあくまで「相関がありそう」という判定  
→まったく無関係のデータ間に強い相関が見られることもある
- ここまで述べてきた相関係数は実は「ピアソンの積率相関係数」というもので、2変数間に線形の関係があることを前提にしたもの
- データが曲線に沿う場合や、他の関係がある場合には意味をなさない



例:どちらも相関係数(ピアソンの積率相関係数)は0だが、果たして変数間に関係性がないといえるだろうか？

## 相関分析の注意点(2)

- 変数間の関係性を調べたいときには、まず散布図を描いてみる
- データの散らばりからある程度の仮説を立て、それに応じた分析方法を使う
- 線形の関係性が見られる場合→**相関分析、線形回帰分析**
- 適切なデータの分析法を使用して
  - ・ 実験データ、統計データからシミュレーションモデルの構築
  - ・ シミュレーション結果の整理と分類などに使用することができる



# 第13回のレポート

- 気温とおでんの売り上げが以下の表のようになった。
  - (1) 相関分析をおこない、気温とおでんの売り上げに相関があるかどうか、あるならばどのような相関か調べよ
    - 相関係数を計算し、無相関検定により有意性を判定する
    - 相関係数の値から相関の正負、強弱を調べる
  - (2) 線形回帰をおこない、回帰直線の式を求めよ

注：無相関検定は  $R$  の絶対値で判定してよい

気温(°C)	売り上げ(個)
18	
15	
10	
5	