


【線形回帰の注意点】

- 線形回帰では、2変数の間に「直線的な」関係があることが前提となる
- データ間の(直線的な)関係性の向きや程度を調べておく必要がある→相関分析

【相関分析】

- 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、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


【相関係数の値と相関の度合い】

- 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


※相関の度合いの判定にはいくつかの基準があるが、いずれにしても絶対値が 1 に近いほど相関が強い(高い)

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

完全な正の相関
($R = 1$)



完全な負の相関
($R = -1$)



【練習: 相関係数の計算】

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。

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

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

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

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

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

【相関係数の注意点】

- 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
-

【どうすれば適切な方法でデータの分類と整理ができるか？】

- 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

【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。

※無相関検定は R の絶対値で判定してよい

※電卓のない人は右の表も参考にしてください

参考： $\sqrt{\quad}$ の値

気温(°C)	売り上げ(個)
18	
15	
10	
5	

$$\sqrt{111} = 10.535653$$

$$\sqrt{130} = 11.401753$$

$$\sqrt{1175} = 34.278273$$

$$\sqrt{7280} = 85.322916$$

$$\sqrt{12740} = 112.8716$$

$$\sqrt{13965} = 118.1736$$