


# 回帰分析・重回帰分析

今、何か①( $x_1$ ) および 何か②( $x_2$ ) から、  
その結果( $y$ ) が得られるとする。





例) 調味料①、②を入れる → 味が変わる  
エアコン①、②を入れる → 室温が変わる。

いま、 $x_1, x_2, y$  について、次のようなデータがある。

何か①( $x_1$ )	何か②( $x_2$ )	その結果( $y$ )
0	0	0
1	1	0
1	0	0.5
0	1	-0.5
2	2	0
1	2	-0.5
2	0	1
-1	-1	0
-2	0	-1
-2	-2	0

問1 このデータの散布図相関行列は次のようになる。 $x_1, x_2, y$  についての相関関係について考えてみよう。  
何か①と何か②のうち、結果に影響を及ぼしているものはどれだろう？



問2 実際、もう少しじっくりとデータを眺めてみると、 $x_1, x_2, y$  にはどのような関係があるだろう。

$y =$

結果にあたる変数  $y$  (変数という) が 複数の変数 (変数という) から影響を受ける場合、散布図相関行列で個別の変数の関係だけをながめてしまうと、実は相関がある変数同士を「相関なし」と判定してしまう可能性がある。

そこで、まずモデルとして例えば次のような式を仮定する。
$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2$$
 ※ $x_1$  と  $x_2$  がそれぞれ  $y$  に影響すると考えているところがポイント。

そして、実際の結果をうまく説明/予想できるような、 $x$  の係数  $\beta$  のセット ( $\beta_0, \beta_1, \beta_2, \dots$ ) を、 $\beta$  をあてでもない、こうでもない変化させ、あてはめながら決めていく。(実際には、残差(実際と理論の差)を小さくするような  $\beta$  の値のセットを、 $\beta$  を変えながら決めていく。) この分析手法を ( ) 回帰分析という。

以下、Excel ファイル (説明変数 6 つまでに対応) を開いて、実際にやってみましょう。

**【実習①】** サンプルデータ①が入力されていることを確認したら、ステップ幅 (ベータをどれくらい変化させて試すか) を 0.1、試行回数を 100 として、重回帰分析ボタンを押してみましょう。R<sup>2</sup> 値\*が 1 に近ければ近いほど、実際の値をよく説明する (誤差の少ない) モデルとなっています。データ①については、R<sup>2</sup> 値が 0.999 くらいになるまで繰り返してみましょう。

重回帰分析 係数を探索するボタン	設定可能です	
	ステップ幅	0.1
	試行回数	100
	R <sup>2</sup> 値	0.0678

### 【実習②】家賃のデータ

駅からの距離、築年数、部屋の広さなどによって、アパートの家賃は違いますよね。皆さんがアパートを建てるとしたら、どれくらいの家賃を設定しますか?あるいは、アパートを借りるときに、割安なアパートを見つけることはできるでしょうか…?

$\beta_1$ ○する	$\beta_2$ ○する	$\beta_3$ ○する	$\beta_4$ ○する	$\beta_5$ ×しない	$\beta_6$ ×しない	$\beta_0$ ×しない
0	0	0	0	0	0	0
変数 $x_1$	変数 $x_2$	変数 $x_3$	変数 $x_4$	変数 $x_5$	変数 $x_6$	目的変数 $y$
駅からの距離 (徒歩(分))	築年数(年)	部屋の広さ (m <sup>2</sup> )	立地エリアの 人気度			家賃(円)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

- データのクリア消去 → サンプルデータ②家賃ボタンを押して、データを読み込みましょう。
- 係数のセル (B3~H3) に、それぞれの説明変数の効果がどの程度か予想して、係数の初期値 (その値から、変化させてセットを決める種のようなもの) を決めます。この値がいい感じだと、少ない試行回数で R<sup>2</sup> 値が 1 に近づきます。データ②の場合はその値が 1 増えたとき、家賃がいくら上がるか、下がるかを想像してみるといいと思います。
- 重回帰分析をやってみる。このデータは、(R<sup>2</sup> 値 0.98 くらいまでは狙えるはず。) それぞれの係数はいくらになったか。表に書き入れましょう。

駅からの距離	築年数	部屋の広さ	立地エリアの人気	切片
$\beta_1$ :	$\beta_2$ :	$\beta_3$ :	$\beta_4$ :	$\beta_0$ :

R<sup>2</sup> 値\* … (1 - (残差<sup>2</sup>の合計) / ( $y^2$ の合計)) で計算できる。 $y$  の値に対し、残差が小さいと 1 に近づく。

### 【実習③】 テストの点数

テストでいい点を取りたい！と思ったら、まずは勉強する。そして、睡眠も大事な気がする。スマホは使いすぎるとよくない…さて、1日の生活をどうマネジメントしたらいいでしょう。それぞれの項目は、テストの点数をおよそ何点分押し上げるでしょうか。

データ番号	学習時間 (時間/日)	睡眠時間 (時間/日)	スマホ利用時間 (時間/日)	朝食習慣の有無	余暇の時間 (時間/日)	テストの点数
1	1.69	5.16	4.21	0	2.01	24
2	4.28	8.18	1.42	1	3.43	96
3	3.29	6.57	1.81	1	2.63	47
4	2.69	7.54	5.49	1	0.65	48
5	0.7	9.54	4.03	0	0.28	39
6	0.7	6.25	1.05	0	2.57	16
7	0.26	7.05	1.51	0	0.11	40
8	3.9	8.78	4.32	1	2.34	75
9	2.71	6.14	1.03	1	3.76	54
...	...	...	...	...	...	...

データのクリア消去 → サンプルデータ③テストの点数ボタンを押すところからやってみよう。

変数 $x_1$	変数 $x_2$	変数 $x_3$	変数 $x_4$	変数 $x_5$	目的変数 $y$
学習時間	睡眠時間	スマホ利用時間	朝食習慣の有無	余暇の時間	テストの点数
$\beta_1$ :	$\beta_2$ :	$\beta_3$ :	$\beta_4$ :	$\beta_5$ :	$\beta_0$ :

### 【実習④】 実際の探究で…

総合的な探究の時間や、大学での研究などでデータを分析する1つのツールとして、重回帰分析を活用してください。単回帰分析だけを使うよりも面白い発見がありそうです。今回は、 $x_1$ や $x_2$ は1乗であることを仮定しましたが、ひょっとすると2乗や3乗のものもあるかもしれませんよね。

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2^2 + \beta_3 x_3 + \beta_4 x_4^3$$


あるいは、何乗かわからないときは、それもランダムに変えながら調べる必要があるかもしれません。

$$y = \beta_0 + \beta_1 x_1^{\alpha_1} + \beta_2 x_2^{\alpha_2} + \beta_3 x_3^{\alpha_3} + \beta_4 x_4^{\alpha_4}$$

# 重回帰分析と Excel シートの仕組み

重回帰分析、というところこそ重々しく感じますが、原理はそんなに難しくありません。

例えば、次のグラフの四角いマークが実際の値、丸いマークがモデルから計算される予想値、黒い直線がその差分を表しています。



要するに、四角と丸ができるだけ重なるようになると、それだけそのモデルは、現実のデータをうまく言い当てている（つまり、素敵で優秀なモデル）ということになります。

つまり、黒い直線の長さを計算して、それを全部合計したものができるだけ短くなる「理想の $\beta$ のセット」を探ることが、重回帰分析の原理です。

$\beta_1$ ○する	$\beta_2$ ○する	$\beta_3$ ○する	$\beta_4$ ○する	$\beta_5$ ○する	$\beta_6$ ×しない	$\beta_0$ ○する		$y = \beta_0 + \beta_1$	
12	4	① -5	5	0	0	0	切片	とモデル化されると仮	
変数 X1	変数 X2	変数 X3	変数 X4	変数 X5	変数 X6	目的変数 y		⑤ 9770.4536	
学習時間	睡眠時間	スマホ利用時間	朝食習慣の有無	余暇の時間		テストの点数	モデルからの 予測値	残差	残差の2乗
1.69	5.16	4.21	0	2.01		24	19.87	4.13	17.0569
4.28	8.18	1.42	1	3.43		96	81.98	14.02	196.5604
3.29	6.57	1.81	1	2.63		47	② 61.71	③ 4.71	④ 16.3841

ワークシートのつくりも案外単純です。

重回帰分析のボタンを押すと、①の $\beta$ のセットの値をランダムで少しずつ変化させ、それに基づいて②の予想値を各データから計算します。③は実際の $y$ の値（今の場合はテストの点数）と、モデルから計算された予想値の差分です。このまま合計するとプラスマイナスを含むので、それを足し合わせても合計の長さにはなりません。そこで、③を2乗して、④を計算してから、④の全データの合計である⑤を計算しています。（だから、正確には黒い線の長さの2乗の和を計算しています。）例えば試行回数を1000回とすると、1000回 $\beta$ をさまざま変えた中で、最も⑤の値が小さくなった $\beta$ のセットを、最適なモデルとして記録します。