

# 経済と社会 補助資料


## ～マーケティング・リサーチと回帰分析～

2022年度1学期: 火曜2限  
 担当教員: 石垣 司

## 回帰分析って？

- 変数  $y$  の動きを、別の変数  $x$  と関数  $f$  で予測や説明
  - 最もポピュラーなデータ分析手法の一つ

- 線形回帰分析
  - 関数  $f$  : 直線(1次式)
 
$$y = f(x) = a + bx$$
    - 散布図のデータの散らばりに適合する直線(切片  $a$ , 傾き  $b$ )を推定
    - $x$  と  $y$  に因果関係がある場合は,  $x$  が原因,  $y$  が結果の表現



- これ以降の講義の目的:  
 線形重回帰分析の結果の意味を理解する

## マーケティング・リサーチと回帰分析

- 需要の予測(小売業での例)
  - 曜日, 天気, チラシ広告の有無などから来店人数を予測。過去の購買履歴データから算出されるPI値(Purchase Index: 来店レジを通過した顧客1000人当たりの各商品の購買指数)から商品の需要量を予測
- 市場反応分析(メーカーでの例)
  - 販売価格, プロモーションの有無などから売上数量を予測。交差価格弾力性などの経済学的指標を算出することで, ブランド間の競合関係を測定する



## 回帰分析の用語の整理


- 変数に関する用語
  - 説明変数 変数  $x$
  - 従属変数 変数  $y$  (目的変数、被説明変数)
  - 回帰係数 係数  $b$  (パラメータ)
- 回帰に関する用語
  - 回帰 ある変数を他の変数の関数で表現すること
  - 回帰式  $y = a + bx$  (単回帰式)
  - 回帰直線 回帰式が表現する直線
  - 単回帰分析 1つの説明変数を用いた回帰による分析
  - 重回帰分析 複数の説明変数を用いた回帰による分析

## 回帰式の推定

- データから回帰係数  $b$  と切片  $a$  を決定する
  - 合理的な基準と手続きに基づいた推定が必要
- 基準 残差平方和(RSS: Residual sum of squares)の最小化
  - 残差  $e_i$   $e_i = y_i - \hat{y}_i = y_i - (a + bx_i)$
  - 残差平方和  $RSS = \sum_{i=1}^n e_i^2$
- 手続き 最小2乗法

### 最小2乗推定量


$$\hat{b} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}, \quad \hat{a} = \bar{y} - \hat{b} \bar{x}$$



5

## 回帰分析と予測

- 回帰式  $y = \hat{a} + \hat{b}x$  を利用した予測
  - $\hat{a}$  と  $\hat{b}$  はデータ  $\{(x_1, y_1), \dots, (x_n, y_n)\}$  から推定された係数
  - $\hat{y}_{n+1}$ :  $x_{n+1}$  に対する変数  $y$  の予測値
 
$$\hat{y}_{n+1} = \hat{a} + \hat{b}x_{n+1}$$



### 問題

左図の回帰係数は  $\hat{a} \cong 0$ ,  $\hat{b} \cong 0.7$  である。国民可処分所得が500兆円するとき、民間最終消費支出の予測値は？

1955年度～1998年度(1968SNA)  
(内閣府 国民経済計算年次推計)

6

## 重回帰分析

- 複数の説明変数による回帰分析
  - 目的変数, 従属変数: 変数  $y$
  - 説明変数, 独立変数: 変数  $x_1, x_2, \dots, x_p$
  - データ:  $\{y_i, x_{i1}, x_{i2}, \dots, x_{ip}\} (i = 1, \dots, N)$
  - 偏回帰係数: 係数  $b_1, b_2, \dots, b_p$  (パラメータ)
  - 切片: 係数  $b_0$  (パラメータ)

### 重回帰式

$$y = b_0 + b_1x_1 + \dots + b_px_p$$

### 重回帰モデル(データによる記述)

$$y_i = b_0 + b_1x_{i1} + \dots + b_px_{ip} + e_i \quad (i = 1, \dots, N)$$


7

## 重回帰分析のイメージ

- 2つの説明変数による重回帰式のイメージ

- 重回帰モデル(データによる記述)

$$y_i = b_0 + b_1x_{i1} + \dots + b_px_{ip} + e_i \quad (i = 1, \dots, N)$$



8

# 偏回帰係数の推定

## 最小2乗法による残差平方和の最小化

– 残差  $e_i = y_i - \hat{y}_i = y_i - (b_0 + b_1x_{i1} + \dots + b_px_{iP})$

## 最小2乗推定量

$$\begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \\ \vdots \\ \hat{b}_p \end{bmatrix} = (X^T X)^{-1} X^T \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1P} \\ 1 & x_{21} & \dots & x_{2P} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{N1} & \dots & x_{NP} \end{bmatrix}$$

※上式の意味を理解するには線形代数の知識が必要。よって、線形代数を未学習の学生は、数学的な手続きによって回帰係数  $b_0, b_1, \dots, b_p$  が推定可能ということを理解できれば十分

※現代では回帰分析はコンピューターを利用し、手作業で計算することはほぼ無い。後述のように、結果の意味を理解できることに授業の重点を置く

# 重回帰分析をしてみよう～問題設定

## 背景

– マーケッターとして、あるスーパーマーケットチェーンの販売促進に関する戦略立案を担うことになった

## 利用できるデータ

- ID-POSデータ: レジ通過時にポイントカードを提示した顧客の購買履歴データ。「誰が、いつ、何を、何個、いくらで」購入したのかが記録されているデータ(1年分を利用)
- 顧客属性データ: ポイントカード登録顧客の年齢、家族人数、世帯内の高齢者の有無、世帯内の子供の有無、自宅から店舗までの所要時間

## 目的

– 顧客属性と購買金額の関係を定量的に把握するための因果型リサーチ

# 重回帰分析をしてみよう～データ#1

## ID-POSデータ

購買日	購買時間	顧客ID	商品カテゴリコード	商品コード	価格	購買個数
2020.05.15	11.15.01	100001	12321	490000000012	198	3
2020.05.15	11.15.01	100001	10089	490111234020	258	1
2020.05.15	11.16.11	123456	10105	490000675962	154	2
...	...	...	...	...	...	...

## 顧客属性データ

顧客ID	年齢	家族人数	高齢者の有無	子供の有無	家からの距離
00001	61	3	0	0	15分
00002	40	4	0	1	10分
00003	59	2	0	0	25分
...	...	...	...	...	...

## 重回帰分析用に加工した購買金額データ

顧客ID	購買金額	年齢	家族人数	高齢者の有無	子供の有無	家からの距離
00001	¥267,120	61	3	0	0	15分
00002	¥156,990	40	4	0	1	10分
00003	¥143,428	59	2	0	0	25分
...	...	...	...	...	...	...
01000	¥84,143	71	2	1	0	5分

# 重回帰分析をしてみよう～データ#2

## 重回帰分析用に加工した購買金額データ

– このデータがあれば目的的回帰分析が可能

顧客ID	購買金額	年齢	家族人数	高齢者の有無	子供の有無	家からの距離
00001	¥267,120	61	3	0	0	15分
00002	¥156,990	40	4	0	1	10分
00003	¥143,428	59	2	0	0	25分
...	...	...	...	...	...	...
01000	¥84,143	71	2	1	0	5分

～データと数式の対応表～

顧客ID	購買金額	年齢	家族人数	高齢者の有無	子供の有無	家からの距離
$i = 1$	$y_1$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	$x_{15}$
$i = 2$	$y_2$	$x_{21}$	$x_{22}$	$x_{23}$	$x_{24}$	$x_{25}$
$i = 3$	$y_3$	$x_{31}$	$x_{32}$	$x_{33}$	$x_{34}$	$x_{35}$
...	...	...	...	...	...	...
$i = 1000$	$y_N$	$x_{N1}$	$x_{N2}$	$x_{N3}$	$x_{N4}$	$x_{N5}$

※本講義で利用するデータは実データを元に授業用に作成したダミーデータである。しかし、その分析結果は実際のデータの傾向が反映されている

# 重回帰分析を試みよう～結果

## • 重回帰分析の結果

	Estimate (推定値)	Std.Error (標準誤差)	t value (t値)	Pr(> t ) (p値)
切片 ( $b_0$ )	106146	24196	4.39	0.000***
年齢 ( $b_1$ )	841	382	2.21	0.028*
家族人数 ( $b_2$ )	23170	2602	8.91	0.000***
高齢者の有無 ( $b_3$ )	-1063	8202	-0.13	0.897
子供の有無 ( $b_4$ )	7941	7633	1.04	0.299
家からの時間 ( $b_5$ )	-3208	598	-5.37	0.000**
Adjusted R-squared (自由度調整済み決定係数)	0.11			

– ソフトウェアを利用することで、このような結果が出力される

## • これ以降の本授業の目標

⇒ この表の数値の意味を正しく解釈できる