

インサイト・ファクトリー 社内セミナー
2020年4月

マーケティング・ミックス・モデリング

III. 回帰分析の基礎

小野 滋

統計学・データ解析	マーケティング・ミックス・モデリングへの適用
I. イントロダクション	
	II. 市場反応モデルとは
III. 回帰分析の基礎	
	IV. 静学的市場反応モデル
V. 時系列分析の基礎	
	VI. 動学的市場反応モデル(1)
VII. 状態空間モデルの基礎	
	VIII. 動学的市場反応モデル(2)

目次

この章の内容

サンプルデータ

1. 基本的な統計量
2. 単回帰モデル
3. 単回帰モデルのパラメータ推定
4. 単回帰モデルのパラメータ推定量の分散
5. 単回帰モデルの推定量の性質
6. 重回帰モデル
7. 重回帰モデルのパラメータ推定
8. 重回帰モデルのパラメータ推定量の分散
9. 重回帰モデルの推定量の性質
10. 回帰モデルの説明力
11. 市場反応モデリングと回帰モデル

この章の引用文献

この章に登場したRの関数


回帰分析についておさらいします

この章の内容は、以降のすべての議論の基礎になります

本資料作成に用いたすべてのRコードを、以下で公開しています:
https://rpubs.com/shig_ono/MMM_3

ある不動産業者は、ある町の中古マンションの価格と、その特徴との関係を知りたいと考えている。

そこで、この町にある中古マンションから10件をランダムに抜き出し、価格・広さ・築年数を調べた。



1. 基本的な統計量

1. 基本的な統計量

■ 期待値 (平均) $\mu_X = E(X_i)$

■ 分散 $\text{Var}(X_i) = E[(X_i - \mu_X)^2]$

■ 共分散 $\text{Cov}(X_i, Y_i) = E[(X_i - \mu_X)(Y_i - \mu_Y)]$

■ 相関 $\text{Corr}(X_i, Y_i) = \frac{\text{Cov}(X_i, Y_i)}{\sqrt{\text{Var}(X_i)\text{Var}(Y_i)}}$

(確率変数)



X_1 Y_1



X_2 Y_2

⋮

⋮

⋮

標本統計量

■ 平均

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

■ 分散

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

変動

■ 共分散

$$\text{COV}_{x,y} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

共変動

■ 相関

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

(観測値)



x_1 y_1



x_2 y_2




⋮

⋮

⋮



x_n y_n



参考：基本的な式変形 (あとで使います)

- 変動の変形

$$\begin{aligned}
 \sum (x_i - \bar{x})^2 &= \sum x_i^2 - 2\bar{x} \sum x_i + n\bar{x}^2 \\
 &= \sum x_i^2 - 2n\bar{x}^2 + n\bar{x}^2 \\
 &= \sum x_i^2 - n\bar{x}^2
 \end{aligned}
 \quad \left. \begin{array}{l} \\ \\ \end{array} \right\} \sum x_i = n\bar{x}$$

- 共変動の変形

$$\begin{aligned}
 \sum (x_i - \bar{x})(y_i - \bar{y}) &= \sum x_i y_i - \bar{y} \sum x_i - \bar{x} \sum y_i + n\bar{x}\bar{y} \\
 &= \sum x_i y_i - n\bar{x}\bar{y} - n\bar{x}\bar{y} + n\bar{x}\bar{y} \\
 &= \sum x_i y_i - n\bar{x}\bar{y}
 \end{aligned}
 \quad \left. \begin{array}{l} \\ \\ \end{array} \right\} \begin{array}{l} \sum x_i = n\bar{x} \\ \sum y_i = n\bar{y} \end{array}$$


2. 単回帰モデル

2. 単回帰モデル

説明変数がひとつしかない線形回帰モデル

$$Y_i = \alpha + \beta X_i + U_i, \quad i = 1, \dots, n$$

目的変数 Y_i 、説明変数 X_i 、切片 α 、回帰係数 β 、誤差項 U_i 、パラメータ α, β




■ 攪乱項とは？

$$Y_i = \alpha + \beta X_i + U_i, \quad i = 1, \dots, n$$

↙ 攪乱項

- Y の変動のうち、説明変数 X で説明できないすべての変動を表す項
 - 価格の測定誤差, マンションの築年数の効果, 駅からの距離の効果, ... etc.
- それ自体は観測できない
 - パラメータ α, β を推定できれば、その推定を使って推定できる
 - 攪乱項の推定値を残差と呼ぶ
- 誤差項とも呼ばれる

■ 単回帰モデルは、私たちになにを与えてくれるのか？



1) パラメータ推定量

設計したモデル

$$Y_i = \alpha + \beta X_i + U_i$$

 \uparrow 推定 \uparrow 推定

推定したモデル

$$Y_i = \hat{\alpha} + \hat{\beta} X_i + E_i$$

回帰係数 β の意味 :

- 「説明変数 X が1変化すると、目的変数 Y はどれだけ変化するか」
- β は「因果的効果」か？
 - すなわち、 β は X の変化が引き起こす Y の変化の大きさを表しているのか？
 - とても大きな問題。このセミナーでは十分に扱えません

2) 所与の X_i のもとでの Y_i の予測

$$E(Y_i | X_i)$$

↑ 推定


推定したモデル

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$$

\hat{Y}_i の意味:


- 説明変数 X が所与であるときの、目的変数 Y の条件つき期待値の推定値
 - 「説明変数の値がコレコレであるとき、目的変数の値はコレコレになるはずです」という意味ではない
 - 「説明変数の値がコレコレであるとき、目的変数の値は平均するとコレコレになるはずです」という意味

中古マンション



3. 単回帰モデルのパラメータ推定

3. 単回帰モデルのパラメータ推定



パラメータ推定の主な方法 (=推定量のタイプ)

1. **最小二乗法**

2. **最尤法**


3. モーメント法

4. ベイズ法


} このセミナーでは扱わない

■ 考え方

- Y_i の予測値を $\hat{Y}_i = a + bX_i$ とする
- 残差 (攪乱項の推定値) は $Y_i - \hat{Y}_i$
- 残差二乗和 $\sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ を最小にする a, b を \hat{a}, \hat{b} としよう!




2通りの(a, b)について試してみると...



No	広さ	価格	パラメータ案1		パラメータ案2	
			予測値	残差の二乗	予測値	残差の二乗
1	51	30	36.1	36.6	38.8	77.4
2	38	32	28.9	9.6	28.4	13.0
3	57	33	39.4	40.3	43.6	112.4
4	51	39	36.1	8.7	38.8	0.0
5	53	44	37.2	46.9	40.4	13.0
6	77	45	50.4	28.6	59.6	213.2
7	63	45	42.7	5.5	48.4	11.6
8	69	54	46.0	64.8	53.2	0.6
9	72	54	47.6	41.0	55.6	2.6
10	73	60	48.2	140.4	56.4	13.0
合計				422.5		456.6

さまざまな(a, b)について計算してみると...



■ 推定量の導出 (蓑谷, pp.10-13)

a, b を変数と考え、関数 $Q(a, b) = \sum_{i=1}^n (Y_i - (a + bX_i))^2$ を最小化する。

a, b に関する偏導関数を0とおく。

$$\frac{\partial}{\partial a} Q(a, b) = \frac{\partial}{\partial a} \sum (Y_i - a - bX_i)^2 = \sum [2(Y_i - a - bX_i)(-1)] = 0$$

$$\frac{\partial}{\partial b} Q(a, b) = \frac{\partial}{\partial b} \sum (Y_i - a - bX_i)^2 = \sum [2(Y_i - a - bX_i)(-X_i)] = 0$$



合成関数の偏導関数は

$$\frac{\partial}{\partial a} f(g(a, b)) = f'(g(a, b)) \frac{\partial}{\partial a} g(a, b)$$

両辺を2で割って

$$\sum -(Y_i - a - bX_i) = 0$$

$$\sum -X_i(Y_i - a - bX_i) = 0$$

移項して

$$\left. \begin{aligned} an + b \sum X_i &= \sum Y_i \\ a \sum X_i + b \sum X_i^2 &= \sum X_i Y_i \end{aligned} \right\} \text{正規方程式}$$

$\bar{X} = \frac{1}{n} \sum X_i, \bar{Y} = \frac{1}{n} \sum Y_i$ とする。第1式の両辺を n で割って

$$a = \bar{Y} - b\bar{X}$$

$Y = a + bX$ は (\bar{X}, \bar{Y}) を通る直線

第2式に代入して

$$(\bar{Y} - b\bar{X}) \sum X_i + b \sum X_i^2 = \sum X_i Y_i$$

$$b \left(\sum X_i^2 - \bar{X} \sum X_i \right) = \sum X_i Y_i - \bar{Y} \sum X_i$$

$$b = \frac{\sum X_i Y_i - \bar{Y} \sum X_i}{\sum X_i^2 - \bar{X} \sum X_i} = \frac{\sum X_i Y_i - n\bar{X}\bar{Y}}{\sum X_i^2 - n\bar{X}^2} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2}$$

\longrightarrow
 変動・共変動の変形

直線の傾きは
(XとYの共変動) / (Xの変動)

中古マンション

Rで実行してみると...

```
> dfMansion <- read_csv("./Mansion.csv")  
  
> x <- dfMansion$Hirosa  
> y <- dfMansion$Price  
  
> b <- sum( (x - mean(x))*(y - mean(y))) / sum( (x - mean(x))^2 )  
> a <- mean(y) - b * mean(x)  
  
> print(a)  
[1] 4.286288  
  
> print(b)  
[1] 0.6508893
```

lm()関数を使うと...


```
> summary(lm(Price ~ Hirosa, data = dfMansion))

Call:
lm(formula = Price ~ Hirosa, data = dfMansion)


Residuals:
    Min       1Q   Median       3Q      Max
-9.405 -5.684  2.184  4.347  8.199

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   4.2863     10.9270   0.392  0.70511
Hirosa         0.6509      0.1775   3.666  0.00635 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 6.63 on 8 degrees of freedom
Multiple R-squared:  0.6269,    Adjusted R-squared:  0.5802
F-statistic: 13.44 on 1 and 8 DF,  p-value: 0.006346
```



■ 準備1. 正規分布



Quiz:

ある確率変数が平均10, 分散4の正規分布に従うとき、実現値12の確率密度は？

Rで求めてみると...

```
> 1/( sqrt(2*pi) * 2) * exp(-(12-10)^2 / (2*4) )  
[1] 0.1209854  
  
> dnorm(12, 10, 2)  
[1] 0.1209854
```

Quiz: ある確率変数が平均10, 分散4の正規分布に従うとしよう。互いに独立な実現値を3つ得たとき、それらが(12, 8, 9)となる確率密度 (同時確率密度) は？

互いに独立な出来事が同時に起きる確率は、個々の出来事の時確率の積だから、


```
> dnorm(12, 10, 2) * dnorm(8, 10, 2) * dnorm(9, 10, 2)
[1] 0.002576671
```

■ 準備2. 尤度とは

- B であるとき A となる条件つき確率を $P(A|B)$ とする
- これを A の関数とみなすこともできる。このときこれを**尤度** $L(B|A)$ と呼ぶ

例) ある国では、1万人当たり40人が、ある病気にかかっている。

- この病気にかかっている人が検診を受けると、確率0.8で陽性となる。
 - この病気にかかっていない人が検診を受けると、確率0.1で陽性となる。
- ある人が陽性であるとき、その人が病気にかかっている条件つき確率は？




$$P(\text{病気}|\text{陽性}) = \frac{0.0032}{0.0032+0.0996} = 0.031$$

これを陽性の下での病気の**条件つき確率**、ないし病気の下での陽性の**尤度**という

なぜわざわざ「尤度」というの？「条件つき確率」といえばいいじゃない？

- 「確率」というからには、すべての出来事を通じた合計は1になるべきだ
- $P(A|B)$ をBの関数とみなしたとき(=Bが所与だとみなしたとき)
 - すべてのAを通じたその合計は1になる。「確率」と呼ぶにふさわしい
- $P(A|B)$ をAの関数とみなしたとき(=Aが所与だとみなしたとき)
 - すべてのBを通じたその合計は1にならない。「確率」と呼ぶわけにはいかない



$$P(\text{病気}|\text{陽性}) = \frac{0.0032}{0.0032+0.0996} = 0.031$$

$$P(\text{健康}|\text{陽性}) = \frac{0.0996}{0.0032+0.0996} = 0.969$$

合計は1

$$L(\text{陽性}|\text{病気}) = \frac{0.0032}{0.0032+0.0996} = 0.031$$

$$L(\text{陰性}|\text{病気}) = \frac{0.0008}{0.0008+0.8964} = 0.0009$$

合計は1にならない


Quiz:

正規分布に従うことはわかっているが、平均と分散は未知の確率変数がある。その平均を μ 、分散を σ^2 とする。


- この確率変数の実現値をひとつ得たところ、12であった。 $\mu = 10$ かつ $\sigma^2 = 4$ である尤度は？
- この確率変数の実現値を3つ得たところ、(12, 8, 9)であった。 $\mu = 10$ かつ $\sigma^2 = 4$ である尤度は？

■ 最尤法の考え方

- 攪乱項 U_i は、互いに独立に $N(0, s^2)$ に従うと仮定しよう
このとき、 Y_i は互いに独立に $N(a + bX_i, s^2)$ に従う
- (Y_1, Y_2, \dots, Y_n) の尤度が最大になる a, b, s^2 を $\hat{\alpha}, \hat{\beta}, \hat{\sigma}^2$ としよう
直観的にいうと: データ (Y_1, Y_2, \dots, Y_n) が生まれる”確率”が一番大きくなるパラメータを求めよう!



さまざまな(a, b)について計算してみると...



$s^2 = 25$ とする

■ 推定量の導出 (蓑谷, pp.21-24)

Y_i の確率密度関数は、正規分布の定義より

$$f(Y_i) = \frac{1}{\sqrt{2\pi}s} \exp\left(-\frac{(Y_i - a - bX_i)^2}{2s^2}\right)$$

(Y_1, Y_2, \dots, Y_n) の同時確率密度関数は

$$f(Y_1, Y_2, \dots, Y_n) = (2\pi s^2)^{-\frac{n}{2}} \exp\left(-\frac{\sum_{i=1}^n (Y_i - a - bX_i)^2}{2s^2}\right)$$

$X_1, \dots, X_n, Y_1, \dots, Y_n$ を所与、 a, b, s^2 を変数と捉えたとき、これを**尤度関数**
 $L(a, b, s^2)$ という

話を簡単にするために、尤度関数の対数について考えよう

$$\log L(a, b, s^2) = -\frac{n}{2} \log(2\pi s^2) - \frac{1}{2s^2} \sum_{i=1}^n (Y_i - a - bX_i)^2$$

対数尤度関数 $\log L(a, b, s^2)$ の、 a, b に関する偏導関数を0と置く。

$$\frac{\partial \log L(a, b, s^2)}{\partial a} = \frac{1}{s^2} \sum_{i=1}^n (Y_i - a - bX_i) = 0$$

$$\frac{\partial \log L(a, b, s^2)}{\partial b} = \frac{1}{s^2} \sum_{i=1}^n (Y_i - a - bX_i)X_i = 0$$

これを解いて

$$\left. \begin{aligned} a &= \bar{Y} - b\bar{X} \\ b &= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \end{aligned} \right\} \begin{array}{l} \text{結局、} \\ \text{最小二乗推定量と同じ} \end{array}$$

4. 単回帰モデルのパラメータ推定量の分散

4. 単回帰モデルのパラメータ推定量の分散

■ おさらい：パラメータ推定量の分散とは？

- 推定したいパラメータを θ 、その推定量を $\hat{\theta}$ とする
- どれだけ優れた推定量であるとしても、推定量 $\hat{\theta}$ は推定対象 θ と同一ではない。 $\hat{\theta}$ は θ のまわりをばらつく
- そのばらつきの大きさを、分散 $Var(\hat{\theta})$ として表現する
 - $\sqrt{Var(\hat{\theta})}$ の推定値を**標準誤差** (SE) と呼ぶ

■ Quiz

- 推定したいパラメータを平均 μ とする
- サイズ n の無作為標本を得た。平均は \bar{x} 、標準偏差は s であった
- \bar{x} を μ の推定量として捉えよう。その標準誤差は？

■ 単回帰分析のパラメータ推定量の分散・共分散 (蓑谷, pp.28-30)

撓乱項 U_i の分散を σ^2 として、

$$\text{Var}(\hat{\alpha}) = \left(\frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right) \sigma^2$$

$$\text{Var}(\hat{\beta}) = \frac{\sigma^2}{\sum (X_i - \bar{X})^2}$$

- 単回帰係数の推定精度は、
- 撓乱項の分散が大きいとき低く、
 - 説明変数の変動が大きいとき高い

$$\text{Cov}(\hat{\alpha}, \hat{\beta}) = -\frac{\bar{X}\sigma^2}{\sum (X_i - \bar{X})^2}$$

中古マンション

パラメータ推定量の標準誤差

```
> summary(lm(Price ~ Hirosa, data = dfMansion))

Call:
lm(formula = Price ~ Hirosa, data = dfMansion)

Residuals:
    Min       1Q   Median       3Q      Max
-9.405 -5.684  2.184  4.347  8.199

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   4.2863     10.9270   0.392  0.70511
Hirosa         0.6509     0.1775   3.666  0.00635 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 6.63 on 8 degrees of freedom
Multiple R-squared:  0.6269,    Adjusted R-squared:  0.5802
F-statistic: 13.44 on 1 and 8 DF,  p-value: 0.006346
```

5. 単回帰モデルの推定量の性質

5. 単回帰モデルの推定量の性質

■ 推定量に期待される性質とは？

推定したいパラメータを θ , その推定量を $\hat{\theta}$ とする

• 不偏性

$$E(\hat{\theta}) = \theta$$

推定量 $\hat{\theta}$ の期待値(長い目でみた平均)は θ である

• 一致性

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}) = 0$$

推定量 $\hat{\theta}$ は、標本サイズが無限大に大きければ θ に一致する

• 有効性

推定量 $\hat{\theta}$ は、すべての不偏推定量のなかで分散が最小である

■ 単回帰モデルの古典的な仮定 (蓑谷, pp.3-7)

[1] X_i は確率変数でないか、 U_i と統計的に独立
「**外生性**」 「内生性がない」 「交絡がない」などと表現する

[2] $E(U_i) = 0$
期待値は0

[3] $\text{Var}(U_i) = \sigma^2$
分散均一性 homoscedasticity. 攪乱項の分散は一定

[4] $\text{Cov}(U_i, U_j) = 0, i \neq j$
独立性。異なる観測点の間での相関(自己相関)がない

[5] U_i は正規分布に従う
正規性

■ 最小二乗推定量 $\hat{\alpha}, \hat{\beta}$ の性質 (蓑谷, pp.27-37)

- Y_i の**線形関数**である (=データ Y_i の重みつき合計として表現できる)

$$v_i = \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}w_i \right), \quad w_i = \frac{(X_i - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2},$$

として

$$\hat{\alpha} = \sum_{i=1}^n v_i Y_i, \quad \hat{\beta} = \sum_{i=1}^n w_i Y_i$$

- 仮定[1][2]のもとで、 α, β の**不偏推定量**である
 - 推定量 $\hat{\alpha}, \hat{\beta}$ の期待値は α, β である
- 仮定[1][2] (と X に関するある仮定) の下で、 α, β の**一致推定量**である
 - 推定量 $\hat{\alpha}, \hat{\beta}$ は、観測点の数が無限に大きければ、 α, β に一致する

- 仮定[1][2][3][4]のもとで、 α, β の**最良線形不偏推定量 (BLUE)** である
 - 推定量 $\hat{\alpha}, \hat{\beta}$ は、線形関数の形をとる不偏推定量の中で分散が最小である
- 仮定[1][2][3][4][5]のもとで、 α, β の**有効推定量** である
 - 推定量 $\hat{\alpha}, \hat{\beta}$ は、不偏推定量の中で分散が最小である
- 仮定[1][2][3][4][5]のもとで、 α, β の**最尤推定量** である
 - 推定量 $\hat{\alpha}, \hat{\beta}$ は、ざっくりいうと「データが得られる”確率”がもっとも高くなるような推定量」である

← これをガウス・マルコフ定理という

6. 重回帰モデル

6. 重回帰モデル

説明変数が複数個ある線形回帰モデルのこと。

説明変数を X_{2i}, \dots, X_{Ki} として

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + U_i, \quad i = 1, \dots, n$$

↑
切片
↔
偏回帰係数

行列で表現すると

$$Y = X\beta + U$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{n-1} \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & \cdots & X_{K1} \\ 1 & X_{22} & \cdots & X_{K2} \\ \vdots & \vdots & & \vdots \\ 1 & X_{2,n-1} & \cdots & X_{K,n-1} \\ 1 & X_{2n} & \cdots & X_{Kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + \begin{bmatrix} U_1 \\ U_2 \\ \vdots \\ U_{n-1} \\ U_n \end{bmatrix}$$

■ 単回帰係数 β の意味

$$Y_i = \alpha + \beta X_i + U_i, \quad i = 1, \dots, n$$

説明変数 X が1変化すると、目的変数 Y はどれだけ変化するか

■ 偏回帰係数 β_2 の意味

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + U_i, \quad i = 1, \dots, n$$

説明変数 X_3, \dots, X_K が変化せず、説明変数 X_2 **だけ**が1変化すると、目的変数 Y はどれだけ変化するか

■ 偏回帰係数の解釈


往々にして困難。問題についての深い理解が必要

例)

- コンパクトカメラのユーザから、属性評価と満足度評価を得た
- 以下の回帰モデルを構築した:

$$(\text{満足度}) = 1.24 + 0.73 \times (\text{持ち運びしやすさ評価}) - 0.32 \times (\text{小型軽量さ評価})$$

- 小型軽量なほうが満足度が高いはずなのに、なぜ偏回帰係数は負なのか？
- 「持ち運びしやすさが一定であれば、小型軽量でないほうが満足度が高い」と解釈できるのでは？



7. 重回帰モデルのパラメータ推定

パラメータ推定量 (最小二乗推定量, 最尤推定量) は下式となる (蓑谷, pp.86-87)

$$\hat{\beta} = (X'X)^{-1}X'Y$$

上式の導出は省略するが、説明変数が1つ(X_i)の場合について確認しておこう :

$$X'X = \begin{bmatrix} 1 & \cdots & 1 \\ X_1 & \cdots & X_n \end{bmatrix} \begin{bmatrix} 1 \\ \vdots \\ 1 \\ X_1 \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

$$(X'X)^{-1} = \frac{1}{n \sum X_i^2 - (\sum X_i)^2} \begin{bmatrix} \sum X_i^2 & -\sum X_i \\ -\sum X_i & n \end{bmatrix}$$

 $X'X$ の行列式

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} 1 & \cdots & 1 \\ X_1 & \cdots & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \frac{1}{n \sum X_i^2 - (\sum X_i)^2} \begin{bmatrix} \sum X_i^2 & -\sum X_i \\ -\sum X_i & n \end{bmatrix} \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

$$= \frac{1}{n \sum X_i^2 - (\sum X_i)^2} \begin{bmatrix} \sum X_i^2 \sum Y_i - \sum X_i \sum X_i Y_i \\ n \sum X_i Y_i - \sum X_i \sum Y_i \end{bmatrix}$$

$$= \begin{bmatrix} \frac{n\bar{Y} \sum X_i^2 - n\bar{X} \sum X_i Y_i}{n \sum X_i^2 - n^2 \bar{X}^2} \\ \frac{n \sum X_i Y_i - n^2 \bar{X} \bar{Y}}{n \sum X_i^2 - n^2 \bar{X}^2} \end{bmatrix} = \begin{bmatrix} \bar{Y} - \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \bar{X} \\ \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \end{bmatrix}$$

たしかに、
3節と一致している

中古マンション

Rで実行してみると...

```
X <- dfMansion %>%  
  mutate(Intercept = 1) %>%  
  dplyr::select(Intercept, Hirosa, Nensu) %>%  
  as.matrix(.)  
Y <- dfMansion %>%  
  dplyr::select(Price) %>%  
  as.matrix(.)  
betahat <- solve(t(X) %**% X) %**% t(X) %**% Y  
print(betahat)
```

```
              Price  
Intercept 10.2012955  
Hirosa     0.6680477  
Nensu     -0.8082993
```

lm()関数を使うと...

```
> summary(lm(Price ~ Hirosa + Nensu, data = dfMansion))
```

```
Call:
```

```
lm(formula = Price ~ Hirosa + Nensu, data = dfMansion)
```

```
Residuals:
```

```
      Min       1Q   Median       3Q      Max
-3.2468 -2.0952  0.3939  1.7150  3.6196
```

```
Coefficients:
```

```
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 10.20130    4.43624   2.300 0.055029 .
Hirosa       0.66805    0.07065   9.456 3.09e-05 ***
Nensu      -0.80830    0.12241  -6.603 0.000303 ***
```



```
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 2.636 on 7 degrees of freedom
```

```
Multiple R-squared:  0.9484,    Adjusted R-squared:  0.9336
```

```
F-statistic: 64.3 on 2 and 7 DF,  p-value: 3.126e-05
```



8. 重回帰モデルのパラメータ推定量の共分散

8. 重回帰モデルのパラメータ推定量の共分散

パラメータ推定量の共分散は下式となる (蓑谷, pp.91-92)

攪乱項 U_i の分散を σ^2 として、

$$\text{Var}(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

- 説明変数が2つ (X_{2i}, X_{3i}) の場合は以下となる (蓑谷, p.135)
攪乱項 U_i の分散を σ^2 として、

$$\text{Var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum (X_{2i} - \bar{X}_2)^2} \times \frac{1}{1 - \text{Corr}(X_{2i}, X_{3i})}$$

- 偏回帰係数の推定精度は
- 攪乱項の分散が大きいとき低く、
 - 説明変数の変動が大きいとき高く、
 - 他の説明変数との相関が高いとき低い

- 一般に、 X_{ji} を目的変数、他のすべての説明変数を説明変数とした回帰モデルの決定係数(後述) を R_j^2 として、以下が成り立つ (蓑谷, p.136)

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum (X_{ji} - \bar{X}_j)^2} \times \frac{1}{1 - R_j^2}$$

- 第二項 $1/(1 - R_j^2)$ を
VIF (variance inflation factor) という

9. 重回帰モデルの推定量の性質

9. 重回帰モデルの推定量の性質

■ 重回帰モデルの古典的な仮定

(行列で書くと)

[1] X_i は確率変数でないか
 U_i と統計的に独立

[2] $E(U_i) = 0$

$$E(\mathbf{U}) = 0$$

[3] $\text{Var}(U_i) = \sigma^2$

[4] $\text{Cov}(U_i, U_j) = 0, i \neq j$

$$E(\mathbf{U}\mathbf{U}') = \sigma^2 \mathbf{I}$$

[5] U_i は正規分布に従う

[6] \mathbf{X} の列ベクトルは**一次独立**で、
列数は行数より小さい

$$\text{rank}(\mathbf{X}) = K < n$$

← 新登場!

[6]が満たされていれば、推定量 $\hat{\beta}$ は単回帰の場合と同様の性質を持つ。つまり、

- 仮定[1][2][6]のもとで、 β の**不偏推定量**である
- 仮定[1][2][6] (と X に関するある仮定) の下で、 β の**一致推定量**である
- 仮定[1][2][3][4][6]のもとで、 β の**最良線形不偏推定量** (BLUE) である
- 仮定[1][2][3][4][5][6]のもとで、 β の**有効推定量** である
- 仮定[1][2][3][4][5][6]のもとで、 β の**最尤推定量**である

■ 一次独立とは？

- ある列が、他の列の重みづけ和になっていないこと

■ なぜ「 X の列は一次独立で、列数は行数より小さい」必要があるのか？

- $X'X$ が逆行列を持たなくなるから (7節を参照)

直観的にいうと...

- 説明変数が X_2, X_3, X_4 の3つで、実は $X_4 = 2X_2 + 3X_3$ だとしよう
- このとき、以下の式はいずれも等価である

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4$$

$$Y = \beta_1 + (\beta_2 + 2\beta_4)X_2 + (\beta_3 + 3\beta_4)X_3 + 0X_4$$

$$Y = \beta_1 + (\beta_2 + \beta_4)X_2 + (\beta_3 + 1.5\beta_4)X_3 + 0.5\beta_4 X_4$$

- 推定しようとしているパラメータそのものが同定できない

10. 回帰モデルの説明力

10. 回帰モデルの説明力

1. 決定係数
2. 自由度修正済み決定係数
3. AIC

$Y_i = \hat{Y}_i + E_i$ とすると、以下が成り立つ：

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n E_i^2$$

①観測値の変動 ②予測値の変動 ③残差の二乗和

そこで

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad \text{①に占める②の割合}$$

を**決定係数**と呼ぶ。

単回帰の場合、決定係数は相関係数 $\text{Corr}(X_i, Y_i)$ の二乗に等しい。

①観測値の変動

$$\sum_{i=1}^n (Y_i - \bar{Y})^2$$

=


②予測値の変動

$$\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$


+

③残差の二乗和


$$\sum_{i=1}^n E_i^2$$



942.4



590.7



351.7

決定係数 = ②/① = 0.63

中古マンション

```
> summary(lm(Price ~ Hirosa + Nensu, data = dfMansion))
```

```
Call:
```

```
lm(formula = Price ~ Hirosa + Nensu, data = dfMansion)
```

```
Residuals:
```

Min	1Q	Median	3Q	Max
-3.2468	-2.0952	0.3939	1.7150	3.6196

```
Coefficients:
```

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	10.20130	4.43624	2.300	0.055029	.
Hirosa	0.66805	0.07065	9.456	3.09e-05	***
Nensu	-0.80830	0.12241	-6.603	0.000303	***

```
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 2.636 on 7 degrees of freedom
```

```
Multiple R-squared:  0.9484,      Adjusted R-squared:  0.9336
```

```
F-statistic: 64.3 on 2 and 7 DF, p-value: 3.126e-05
```

決定係数

決定係数は、説明変数の数を増やすと大きくなる

- モデルの説明力をモデル間で比較する際には、説明変数の数も考慮する必要がある

説明変数の数の影響を修正した決定係数

$$\bar{R}^2 = 1 - \frac{n-1}{n-K} (1 - R^2)$$

を自由度修正済み決定係数という

注意: ここでKは(説明変数の数)+1

中古マンション

```
> summary(lm(Price ~ Hirosa + Nensu, data = dfMansion))

Call:
lm(formula = Price ~ Hirosa + Nensu, data = dfMansion)

Residuals:
    Min       1Q   Median       3Q      Max
-3.2468 -2.0952  0.3939  1.7150  3.6196

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  10.20130    4.43624   2.300 0.055029 .
Hirosa        0.66805    0.07065   9.456 3.09e-05 ***
Nensu       -0.80830    0.12241  -6.603 0.000303 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.636 on 7 degrees of freedom
Multiple R-squared:  0.9484,    Adjusted R-squared:  0.9336
F-statistic: 64.3 on 2 and 7 DF,  p-value: 3.126e-05
```

自由度修正済決定係数

最尤法では、対数尤度関数を最大化する $\hat{\beta}$ を求める。最大化された対数尤度は、

$$\hat{\sigma}^2 = \frac{1}{n} (Y - X\hat{\beta})'(Y - X\hat{\beta})$$

として

$$\log L^* = -\frac{n}{2} (\log 2\pi + 1 + \log \hat{\sigma}^2)$$

となる。この値が大きいモデルは、データをよく説明している。

しかし、説明変数の数を増やすと、 $\hat{\sigma}^2$ は小さくなり、 $\log L^*$ は大きくなる。

そこで、モデルのパラメータ ($\beta_1, \dots, \beta_K, \sigma^2$) の数を p とし、**AIC (赤池情報量規準)**

$$AIC = -2 \log L^* + 2p$$

をモデル選択の基とすることがある。

この値が小さいモデルは、データをよく説明している。

中古マンション

```
X <- dfMansion %>%
  mutate(Intercept = 1) %>%
  dplyr::select(Intercept, Hirosa, Nensu) %>%
  as.matrix(.)
Y <- dfMansion %>%
  dplyr::select(Price) %>%
  as.matrix(.)
betahat <- solve(t(X) %**% X) %**% t(X) %**% Y
ehat <- Y - X %**% betahat
sshat <- as.vector((1/length(Y)) * t(ehat) %**% ehat)
LL <- -(length(Y)/2) * (log(sshat) + 1 + log(2 * pi))
AIC <- -2 * LL + 2 * 4
print(LL)
print(AIC)
```

```
> print(LL)
[1] -22.09959

> print(AIC)
[1] 52.19917
```

logLik()関数, AIC()関数を使うと..

```
oModel <- lm(Price ~ Hirosa + Nensu, data = dfMansion)
logLik(oModel)
AIC(oModel)
```

```
> logLik(oModel)
'log Lik.' -22.09959 (df=4)

> AIC(oModel)
[1] 52.19917
```

11. 市場反応モデリングと回帰モデル

11. 市場反応モデリングと回帰モデル

回帰モデルは、市場反応モデルの基盤を提供する。

いっぽう、市場反応の持つ特性は、回帰モデルの前提と多くの点で対立している。

次章からは、この対立を乗り越えるためのさまざまな方法について議論する。

回帰モデル

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + U_i$$

[1] X_i は確率変数でないか
 U_i と統計的に独立

[2] $E(U_i) = 0$

[3] $\text{Var}(U_i) = \sigma^2$

[4] $\text{Cov}(U_i, U_j) = 0, i \neq j$

[5] U_i は正規分布に従う

[6] X の列ベクトルは一次独立。
列数は行数より小さい



市場反応の特性

- A) マーケティング活動と市場反応との関係は、直線的ではないかもしれない
- B) 市場反応変数として、売上を用いる場合とシェアを用いる場合がある
- C) 市場反応に影響する変数は多様であり、データを入手できない変数も多い
- D) 広告・プロモーションの効果は、その内容や媒体によっても異なるかもしれない
- E) 異なるマーケティング活動を同時に行うことにより、シナジーが生まれるかもしれない
- F) マーケティング活動における消費者の反応には、異質性があるかもしれない
- G) 市場反応データは時系列データの形を取ることが多い
- H) マーケティング活動が与える効果は、即時的に現れることもあれば、時間的遅延とともに現れることもある
- I) マーケティング活動の効率は、時間とともに増大・減衰することがある
- J) マーケティング活動は、それまでの市場反応に基づいて計画されることがある

永田靖・棟近雅彦(2001)「多変量解析法入門」,サイエンス社.

小島隆矢(2003)「Excelで学ぶ共分散構造分析とグラフィカルモデリング」,オーム社.

- `lm(フォーミュラ, data=データフレーム)`
 - 回帰モデルを最小二乗推定し、`lm`オブジェクトとして返す
 - フォーミュラの書き方
回帰モデルを指定する。データフレームに含まれている変数の名前をそのまま使うことができる。

(以下ではデータフレームに変数 Y , $X1$, $X2$ が含まれているものとする)

- 例1) 重回帰モデル, 目的変数は Y , 説明変数は $X1$ と $X2$

$$Y \sim X1 + X2$$

- 例2) 切片を0に固定する

$$Y \sim 0 + X1 + X2$$

- 例3) 交互作用項を追加する

$$Y \sim X1 + X2 + X1:X2$$

- `summary(lmオブジェクト)`
パラメータ推定値などを返す
- `plot(lmオブジェクト)`
残差プロットを表示する
- `coef(lmオブジェクト)`
パラメータ推定値をベクトルとして返す
- `logLik(lmオブジェクト)`
モデルの最大対数尤度を返す
- `AIC(lmオブジェクト)`
モデルのAICを返す
- `predict(lmオブジェクト, newdata=データフレーム)`
推定したモデルをデータフレームにあてはめ、予測値を返す
- `car::vif(lmオブジェクト)`
VIFを返す
- `broom::tidy(lmオブジェクト)`
パラメータ推定値をデータフレームとして返す

注：Rでは、
「hogeパッケージが提供しているfuga関数」を
`hoge::fuga(...)`
と書くことがあります。
以下この書き方に従います

- `dnorm(値, mean=平均, sd=標準偏差)`
正規確率密度を返す
- `solve(数値行列)`
逆行列を返す
- `outer(ベクトル, ベクトル, 関数)`
2つのベクトルの外積を返す。関数を指定すると積ではなくてその関数が適用される (※説明しにくい...)