

データの分析と知識発見

Introduction to Data Analysis

今回の構成


0101010101010101010101010101010101

重回帰分析の係数の導入過程について学ぶ

重回帰分析における決定係数とその役割を学ぶ

Rを用いての回帰分析
その結果をグラフに表す方法を学ぶ

係数の導出



$$E = (y^{(1)} - (ax^{(1)} + b))^2 + (y^{(2)} - (ax^{(2)} + b))^2$$

回帰係数の導出

最小2乗法

$$\begin{aligned} E &= (y^{(1)} - (ax^{(1)} + b))^2 \\ &\quad + (y^{(2)} - (ax^{(2)} + b))^2 \\ &\quad + \dots + (y^{(N)} - (ax^{(N)} + b))^2 \\ &= \sum_{p=1}^N (y^{(p)} - (ax^{(p)} + b))^2 \end{aligned}$$

E が最小となる a, b を求める

a, b で偏微分すると

$$\begin{aligned} \sum_{p=1}^N (y^{(p)} - (ax^{(p)} + b))x^{(p)} &= 0 \\ \sum_{p=1}^N (y^{(p)} - (ax^{(p)} + b)) &= 0 \end{aligned}$$


回帰係数の導出

$$\sum_{p=1}^N (y^{(p)} - (ax^{(p)} + b)) = 0$$

$$\frac{1}{N} \sum_{p=1}^N y^{(p)} = a \cdot \frac{1}{N} \sum_{p=1}^N x^{(p)} + \frac{1}{N} \sum_{p=1}^N b$$

$$\rightarrow \mu_y = a\mu_x + b$$

回帰直線 $y = ax + b$ は
それぞれの中心(平均)の点を通る



回帰係数の導出

$$y - \mu_y = a(x - \mu_x)$$

回帰直線はそれぞれの中心を通る

$$(x^{(1)}, y^{(1)}), \dots, (x^{(p)}, y^{(p)}), \\ \dots, (x^{(N)}, y^{(N)})$$

中心化

$$x^{(p)} \leftarrow (x^{(p)} - \mu_x)$$

$$y^{(p)} \leftarrow (y^{(p)} - \mu_y)$$

$$E = (y^{(1)} - ax^{(1)})^2 + (y^{(2)} - ax^{(2)})^2 \\ + \dots + (y^{(N)} - ax^{(N)})^2 \\ = \sum_{p=1}^N (y^{(p)} - ax^{(p)})^2$$

$$\sum_{p=1}^N (y^{(p)} - ax^{(p)})x^{(p)} = 0$$

N (または $N-1$)で割ると
分散共分散を用いて

$$s_{xy} - as_{xx} = 0$$

回帰係数の計算

最小2乗法にて導出

b に関して

2次元の場合

$$y = ax + b$$

$$\mu_y = a\mu_x + b$$

$$y - \mu_y = a(x - \mu_x)$$

r 次元の場合

$$y = a_1x_1 + \cdots + a_rx_r + b$$

$$\mu_y = a_1\mu_1 + \cdots + a_r\mu_r + b$$

$$y - \mu_y = a_1(x_1 - \mu_1) + \cdots + a_r(x_r - \mu_r)$$

回帰係数の計算

最小2乗法にて導出

b に関して

2次元の場合

$$y = ax + b$$

$$\mu_y = a\mu_x + b$$

$$y - \mu_y = a(x - \mu_x)$$

r 次元の場合

$$y = a_1x_1 + \cdots + a_rx_r + b$$

$$\mu_y = a_1\mu_1 + \cdots + a_r\mu_r + b$$

$$y - \mu_y = a_1(x_1 - \mu_1) + \cdots + a_r(x_r - \mu_r)$$

a_i に関して

2次元の場合

$$s_{xy} = as_{xx}$$

r 次元の場合

$$\begin{pmatrix} s_{1y} \\ \vdots \\ s_{ry} \end{pmatrix} = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1r} \\ s_{21} & s_{22} & \cdots & s_{2r} \\ \vdots & \ddots & & \vdots \\ s_{r1} & s_{r2} & \cdots & s_{rr} \end{pmatrix} \begin{pmatrix} a_1 \\ \vdots \\ a_r \end{pmatrix}$$

回帰係数の計算

最小2乗法にて導出

b に関して

2次元の場合

$$y = ax + b$$
$$\mu_y = a\mu_x + b$$

$$y - \mu_y = a(x - \mu_x)$$

r 次元の場合

$$y = a_1x_1 + \cdots + a_rx_r + b$$
$$\mu_y = a_1\mu_1 + \cdots + a_r\mu_r + b$$

$$y - \mu_y = a_1(x_1 - \mu_1) + \cdots + a_r(x_r - \mu_r)$$

回帰直線は中心を通る

a_i に関して

2次元の場合

$$s_{xy} = as_{xx}$$

r 次元の場合


$$\begin{pmatrix} s_{1y} \\ \vdots \\ s_{ry} \end{pmatrix} = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1r} \\ s_{21} & s_{22} & \cdots & s_{2r} \\ \vdots & \ddots & & \vdots \\ s_{r1} & s_{r2} & \cdots & s_{rr} \end{pmatrix} \begin{pmatrix} a_1 \\ \vdots \\ a_r \end{pmatrix}$$

逆行列があれば係数が導出できる

データの分析と知識発見


Introduction to Data Analysis

予測の精度




予測の精度

01







予測の精度

01



予測の精度



$$y = 0.2x + \xi$$


(ξ : 正規乱数)

$s_{xx} \neq 0$ であれば
係数を求めることは
できる

値が求まるからといって
特徴をよく表している
というわけではない

決定係数

01010101010101010101010101010101




$$\frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \mu_y)^2$$

測定値
の分散

決定係数

01010101010101010101010101010101

$$y^{(p)} = \hat{a}_1 x_1^{(p)} + \hat{a}_2 x_2^{(p)} + \cdots + \hat{a}_r x_r^{(p)} + \hat{b}$$




$$\frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \hat{y}^{(p)})^2$$

残差
の分散

決定係数

01010101010101010101010101010101



予測値
の分散

偏相関係数

見かけの相関

x_i と x_j の直接の関係だけでなく
 $x_1, x_2, \dots, x_r$ を通して相関係数に影響を与えることもある

$$x_i = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{ir}x_r + b_i + e_i$$

$$x_j = a_{j1}x_1 + a_{j2}x_2 + \dots + a_{jr}x_r + b_j + e_j$$

e_i と e_j との相関 $\rightarrow$ 偏相関係数

Rによる計算

www.kci.go.kr

```
> h1 <- read.table("ch071.dat", header=T, row.names=1)
```

 $\geq h_1$

```
> h2 <- lm(weight ~ height, data=h1)
```

> h2

```
> plot(h1, pch=16)
```

```
> abline(h2)
```



決定係数

01010101010101010101010101010101

$$y^{(p)} = \hat{y}^{(p)} + e^{(p)} = \hat{a}x^{(p)} + \hat{b} + e^{(p)}$$

$$\hat{y}^{(p)} = \hat{a}x^{(p)} + \hat{b}$$

として、誤差の2乗を計算すると

$$S_{yy} = \frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \mu_y)^2$$

$$= \frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \hat{y}^{(p)})^2 + \frac{1}{N-1} \sum_{p=1}^N (\hat{y}^{(p)} - \mu_y)^2$$

$$\left(\begin{array}{c} \text{測定値} \\ \text{の分散} \end{array} \right) = \left(\begin{array}{c} \text{残差} \\ \text{の分散} \end{array} \right) + \left(\begin{array}{c} \text{予測値} \\ \text{の分散} \end{array} \right)$$

決定係数

01010101010101010101010101010101

$$y^{(p)} = \hat{y}^{(p)} + e^{(p)} = \hat{a}x^{(p)} + \hat{b} + e^{(p)}$$

$$\hat{y}^{(p)} = \hat{a}x^{(p)} + \hat{b}$$

として、誤差の2乗を計算すると

$$S_{yy} = \frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \mu_y)^2$$

$$= \frac{1}{N-1} \sum_{p=1}^N (y^{(p)} - \hat{y}^{(p)})^2 + \frac{1}{N-1} \sum_{p=1}^N (\hat{y}^{(p)} - \mu_y)^2$$

$$\left(\begin{array}{c} \text{測定値} \\ \text{の分散} \end{array} \right) = \left(\begin{array}{c} \text{残差} \\ \text{の分散} \end{array} \right) + \left(\begin{array}{c} \text{予測値} \\ \text{の分散} \end{array} \right)$$

決定係数

$$S_T = S_E + S_R$$

T : トータル (Total)

E : 残差 (Error)

R : 回帰 (Regression)

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_E}{S_T}$$