

# 回歸直線



# 回帰直線

- 相関係数：変量間の直線的関連性の強さを測る尺度
- 2つの変量間の関係を直線で表現する方法を考える
  - 測定の難しい変量を，測定が容易な変量を用いて推測する
  - ある変量を，他の変量から予測する


- 基本的な考え方

- 2つの変量に直線的な関係を仮定し，直線の傾きと切片を推定する

- 右図

- データ：年齢（横軸）と血圧値（縦軸）
- 赤い直線： $y = 63 + 1.4x$

回帰直線




# 回帰モデル

---

- 2つの変量の間に関係を仮定することが妥当な場合、次のような回帰モデルを考えられる
- 回帰モデル
  - $y = \alpha + \beta x + \varepsilon$
  - $\varepsilon$ : 誤差項
  - $\alpha + \beta x$  を平均として、 $y$  はその近くの値をとる
- 問題点
  - $\alpha$  と  $\beta$  の決め方

# 回帰モデルの構成



# 誤差項について

---

## □ 誤差項 $\varepsilon$



- モデルに取り込んだ変数のみでは説明しきれない情報
  - 測定誤差
- 等

## □ 誤差に関する3つの条件

- $\varepsilon_i$  と  $\varepsilon_j$  とは独立である ( $i \neq j, i, j = 1, 2, \dots, n$ )
- $\varepsilon_i$  の平均は0である ( $i = 1, 2, \dots, n$ )
- $\varepsilon_i$  の分散は全て等しい ( $i = 1, 2, \dots, n$ )

# 誤差項の条件について

- $\varepsilon_i$ の平均は0である ( $i = 1, 2, \dots, n$ )
  - 目的変数の平均が回帰直線上にある
- $\varepsilon_i$ の分散は全て等しい ( $i = 1, 2, \dots, n$ )
  - 左下の図：条件を満たす場合
  - 右下の図：条件を満たさない場合




# 回帰係数の推定



# 基本的な考え方


$\varepsilon_i$  の二乗和が最小となるように  $\alpha$  と  $\beta$  を定める





# 誤差の大きさ

$\varepsilon_i$  の二乗和が最小となるように  $\alpha$  と  $\beta$  を定める



$$S^2 = \varepsilon_1^2 + \varepsilon_2^2 + \cdots + \varepsilon_n^2$$

誤差の大きさの総合的な指標  
(残差平方和)

# 回帰係数の推定量

---

## □ $\varepsilon_i$ の二乗和

$$\begin{aligned} S^2 &= \varepsilon_1^2 + \varepsilon_2^2 + \cdots + \varepsilon_n^2 \\ &= \{y_1 - (\alpha + \beta x_1)\}^2 + \{y_2 - (\alpha + \beta x_2)\}^2 + \cdots + \{y_n - (\alpha + \beta x_n)\}^2 \end{aligned}$$

## □ $S^2$ を最小にするような回帰モデルは次のように表される

- $\hat{y} = \hat{\alpha} + \hat{\beta}x$

- $\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}$

- $$\hat{\beta} = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \cdots + (x_n - \bar{x})(y_n - \bar{y})}{(x_1 - \bar{x})^2 + \cdots + (x_n - \bar{x})^2}$$

# 例：回帰係数の推定

---

## □ 目的

- 年齢から血圧を推測するための回帰モデルを構成する

## □ データ

- 7名の女性の年齢を調査し、心臓収縮血圧を測定

被験者	1	2	3	4	5	6	7
年齢 $x$	37	45	48	55	58	67	75
血圧 $y$	112	132	120	154	136	162	164

## □ 回帰モデル

- $y_i = \alpha + \beta x_i + \varepsilon_i, \quad i = 1, 2, \dots, 7$

# 回帰係数の推定

---

## □ 各変数の平均値

- $\bar{x} = \frac{37 + 45 + \dots + 75}{7} = 55$

- $\bar{y} = \frac{112 + 132 + \dots + 164}{7} = 140$

## □ 回帰係数の推定量

- $$\hat{\beta} = \frac{(37 - 55)(112 - 140) + \dots + (75 - 55)(164 - 140)}{(37 - 55)^2 + \dots + (75 - 55)^2}$$
$$= \frac{(-18)(-28) + \dots + 20 \cdot 24}{18^2 + \dots + 20^2} = 1.4$$

- $\hat{\alpha} = 140 - 1.4 \times 55 = 63$

# 推定された回帰モデル

## □ 推定された回帰モデル

- $\hat{y} = 63 + 1.4x$

## □ 実現値・予測値・残差

被験者	年齢	血圧値	予測値	残差
1	37	112	114.5	-2.47
2	45	132	125.8	6.19
3	48	120	130.1	-10.07
4	55	154	140.0	14.00
5	58	136	144.3	-8.26
6	67	162	157.0	4.97
7	75	164	168.4	-4.38

