

回帰 (regression)

データをもとに、ある変数（**従属変数**または**目的変数**）を別の変数（**独立変数**または**説明変数**）で予測する式を作るための統計的手法を、「**回帰分析**」（regression analysis）といいます。

とくに、独立変数が1つだけの場合を**単回帰分析**といいます。複数の独立変数で1つの従属変数を予測する場合は**重回帰分析**といいます。

回帰直線 (regression line)

回帰直線

- 散布図の各点 (x_i, y_i) が近くに分布するような直線を回帰直線という。

$$y = ax + b$$

- 回帰係数 (回帰直線の傾き) : a
 - 回帰直線のy切片 ($x=0$ のときのyの値) : b
 - 独立変数 (説明変数: 予測に使う変数) : x
 - 従属変数 (目的変数、基準変数: 予測したい変数) : y
- なお、回帰式は必ず $(\bar{x}, \bar{y})$ を通る

最小二乗法 (least squares method)

- 観測値 (または実測値) y_i と推定値 (または予測値) $\hat{y}$ との差 (残差 ϵ) の二乗が最小になるような a と b を求める。
 - 次の値が最小となるような a と b を求める。

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

- 残差の二乗 ϵ^2 を足したものを、残差平方和 S_ϵ という

$$S_\epsilon = \sum \epsilon^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

回帰式の計算

- x を独立変数 (横軸)、 y を従属変数 (縦軸) としたときの回帰式 (y への x からの回帰式) は次のようになる。

$$y = r \cdot \frac{s_y}{s_x} x + \left(\bar{y} - \frac{s_{xy}}{s_x^2} \cdot \bar{x} \right)$$

- なお、回帰式を $y = ax + b$ とすると、 a と b は次のようになる。

$$a = r \cdot \frac{s_y}{s_x}$$
$$b = \bar{y} - \frac{s_{xy}}{s_x^2} \cdot \bar{x} = \bar{y} - \bar{x}a$$

- 相関係数: r
- 2変数の標準偏差: s_x, s_y
- 2変数の共分散 (偏差積和の平均)

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

- 回帰式を変形すると、次のようになる。

$$\begin{aligned} y - \bar{y} &= \frac{s_{xy}}{s_x^2} (x - \bar{x}) \\ &= \frac{S_{xy}}{S_{xx}} (x - \bar{x}) \end{aligned}$$

- 2変数の平均値: $\bar{x}$, $\bar{y}$
- 2変数の偏差積和: S_{xy}

$$S_{xy} = \sum_{i=1}^n d_x \cdot d_y = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- 偏差平方和: S_{xx}

$$S_{xx} = \sum_{i=1}^n d_x^2 = \sum_{i=1}^n (x_i - \bar{x})^2$$

標準誤差 (standard error)

- 予測値と実測値のずれ(予測値の誤差; 残差 ϵ)にちて考える

$$\hat{y} = ax_i + b + \epsilon$$

- 残差の標準偏差を、標準誤差 s_ϵ という

$$\begin{aligned} s_\epsilon &= \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n-2}} \\ &= \sqrt{\frac{S_\epsilon}{n-2}} \end{aligned}$$

- $n-2$ で割っているのは、2つの係数を推定したことによる自由度(後日説明)の修正のため

決定係数 (coefficient of determination)

- 相関係数の二乗を決定係数(または寄与率) R^2 という。

$$\begin{aligned} R^2 &= \left(\frac{1}{n s_x s_y} S_{xy} \right)^2 \\ &= \frac{S_{xy}^2}{n^2 \cdot s_x^2 s_y^2} \\ &= \frac{S_{xy}^2}{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2} \\ &= \frac{S_{xy}^2}{S_{xx} S_{yy}} \end{aligned}$$

- 偏差平方和と残差平方和を使うと、次のように書くこともできる

$$\begin{aligned}
 R^2 &= \frac{S_{\hat{y}y}}{S_{yy}} \\
 &= \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} \\
 &= 1 - \frac{S_e}{S_{yy}}
 \end{aligned}$$

- 決定係数は、0から1の値をとる。

$$0 \leq R^2 \leq 1$$

- 推定(回帰式)の精度を表す指標である

- 「従属変数 y の分散の何%を予測値 $\hat{y}$ の分散が説明しているか」を示す
 - 別の言い方をすると、「説明変数が従属変数の何%にあたる部分に影響を与えているか(寄与しているか)」を示す
- だいたい、0.5以上であれば精度が高いといえる

回帰の概念

- 予測値 $\hat{y}$ と従属変数の平均 $\bar{y}$ との差は、一般に独立変数 x とその平均 $\bar{x}$ との差より小さくなる
 - → 予測値と平均の差 $(\hat{y} - \bar{y})$ との差は、独立変数と平均の差 $(x - \bar{x})$ との差より小さくなる
 - → 予測値は独立変数に比べて平均に近づく
- 統計学的な現象で、「回帰効果」や「平均への回帰」ともいう
 - (例) 1回目の試験の結果が偏っていた(とくに良い、悪いなど)人について、2回目の試験結果を調べると、その平均値は1回目の結果よりも1回目の全体の平均値に近くなる(時間的には逆で考えてもよい)
 - (例) 父親と子どもの身長を比較して、とくに身長の高い父親でも、とくに身長の低い父親からでも、子どもたちの身長は父親たちの身長より平均に近くなる
 - (例) とくに身長の高い人たちの父親の身長は、子どもたちの身長よりも平均に近い(全体の身長の分布は、父親たちも子どもたちも同じ)