


回帰と相関

イギリスの遺伝学者ガルトンの調査 「人類遺伝の典型的法則」

- 親の身長とその子供の身長を調査
- 平均より背の高い人のグループ
 - 子供の平均身長は、親の平均身長ほどには高くない
- 逆に平均より低い人のグループ
 - 子供の平均身長も、親ほどには低くない
- 親の代で平均からはずれた分のうちのいくらかは子の代で戻る ⇒ 平均への回帰 (regression)
- 回帰現象の効果で、人類の身長はいつの時代もほぼ一定に保たれる
- 親の身長から子供の身長を予測する式 ⇒ 回帰式

一方の変数からもう一方の変数を予測



- 30歳以上では年齢が増せば、血圧も直線的に増加の傾向
- 女性:
血圧=140.5+1.07(年齢-50)
- 平均年齢50,
平均血圧140.5を通る傾き1.07の直線

回帰直線

- $b = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}$ 傾き
- $a = \bar{y} - b\bar{x}$ 切片
- $y = a + bx$
 $= \bar{y} + b(x - \bar{x})$ 回帰直線
- x: 独立変数(説明変数)
y: 従属変数(目的変数)

内挿と外挿

- 内挿
 - 回帰直線を求めるのに使用したデータの範囲内での推測
 - 例: データはないが、45歳の血圧を推測する
- 外挿
 - 回帰直線を求めるのに使用したデータの範囲外へ直線を伸ばす
 - 例: 25歳未満や75歳以上の血圧の推測
 - 範囲外の傾向が異なると適用できない

相関係数と回帰係数の検定

- 母相関係数 $\rho=0$ の検定
 - データ数 n と 相関係数 r から有意水準を求める ⇒ 表5.1 (210ページ)
 - 自由度: $n-2$
- 母回帰係数=0 の検定
 - 母相関係数=0 の検定と同じ計算

相関係数との関係【p.87 問2】

$$\begin{aligned}
 r &= \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{\sqrt{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2} \cdot \sqrt{(y_1 - \bar{y})^2 + \dots + (y_n - \bar{y})^2}} \\
 &= \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{\sqrt{n}S_x \cdot \sqrt{n}S_y} \\
 &= \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{nS_x S_y} \\
 &= \frac{S_y}{S_x} \cdot \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{nS_x^2} \\
 &= \frac{S_y}{S_x} \cdot \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2} \\
 &= \frac{S_y}{S_x} \cdot b
 \end{aligned}$$

順位相関

- 相関係数は、データ (x, y) の直線関係の強さを示す尺度
- 二次関数的, 指数関数的, 不規則な増加(減少)をする場合
⇒ x の順位と y の順位の相関係数を用いる
- スペアマンの順位相関(同順位がないとき)
■ x_i の順位を R_i , y_i の順位を S_i として

$$D = (R_1 - S_1)^2 + \dots + (R_n - S_n)^2$$

$$r = 1 - \frac{6D}{n(n^2 - 1)}$$