

相関係数の定義

2変量のデータ $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ に対し、2変量 x と y の相関係数 r を次のように定義する。

$$r = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \dots + (x_N - \bar{x})(y_N - \bar{y})}{\sqrt{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2} \sqrt{(y_1 - \bar{y})^2 + \dots + (y_n - \bar{y})^2}}$$

また、2変量のデータ $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ に対し、次の統計量 S_{xy} を2変量 x と y の共分散と呼び、

$$S_{xy} = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \dots + (x_N - \bar{x})(y_N - \bar{y})}{N - 1}$$

データ $\{x_1, x_2, \dots, x_N\}$ に対し、次の統計量 s^2 を x の分散（分母が $N - 1$ のものを不偏分散、 N のものを標本分散）と呼ぶので、

$$s^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{N - 1}$$

相関係数の定義式は次のように変形できる。

$$r = \frac{x \text{ と } y \text{ の共分散}}{\sqrt{x \text{ の分散}} \sqrt{y \text{ の分散}}}$$

さらに、相関係数 r は $-1 \leq r \leq 1$ の値をとります。1に近いほど正の相関が、 -1 に近いほど負の相関が強く、0に近いほど相関が弱いこととなります。