

相関と最小2乗法

静岡大学工学部機械工学科

岡本正芳

相関

標本は2対のペアー (x_i, y_i) で与えられる場合も頻繁にある。

例えば、人における身長と体重，時間と降水量，温度と金属の膨張率，位置と速度など様々なものが存在する。

x_i と y_i の間に関連性があるかどうかを議論する。

相関評価の手順

- I. データの収集
- II. データを散布図によりグラフ化
- III. 相関係数の算出
- IV. 最適関数の同定

評価データー

表 6.1 解析例データー

| x_i | $y_i^{(1)}$ | $y_i^{(2)}$ | $y_i^{(3)}$ | $y_i^{(4)}$ | $y_i^{(5)}$ |
|-------|-------------|-------------|-------------|-------------|-------------|
| 0.2 | 0.640 | 0.501 | 2.624 | 2.875 | 2.715 |
| 0.4 | 0.732 | 0.798 | 0.678 | 2.781 | 1.963 |
| 0.6 | 0.900 | 0.572 | 0.533 | 2.112 | 1.480 |
| 0.8 | 1.037 | 0.657 | 0.678 | 2.031 | 1.152 |
| 1.0 | 1.126 | 1.041 | 1.349 | 1.461 | 0.532 |
| 1.2 | 1.300 | 1.664 | 1.502 | 1.659 | 0.342 |
| 1.4 | 1.467 | 1.518 | 0.312 | 1.831 | 0.417 |
| 1.6 | 1.546 | 1.625 | 3.087 | 1.443 | 0.169 |
| 1.8 | 1.699 | 1.646 | 0.193 | 0.951 | 0.137 |
| 2.0 | 1.802 | 1.949 | 2.114 | 1.243 | 0.087 |
| 2.2 | 2.015 | 1.884 | 2.184 | 0.765 | 0.077 |
| 2.4 | 2.208 | 1.702 | 2.946 | 0.812 | 0.031 |
| 2.6 | 2.233 | 1.885 | 4.060 | 1.136 | 0.025 |
| 2.8 | 2.352 | 2.153 | 2.079 | 0.100 | 0.021 |

グラフによる可視化

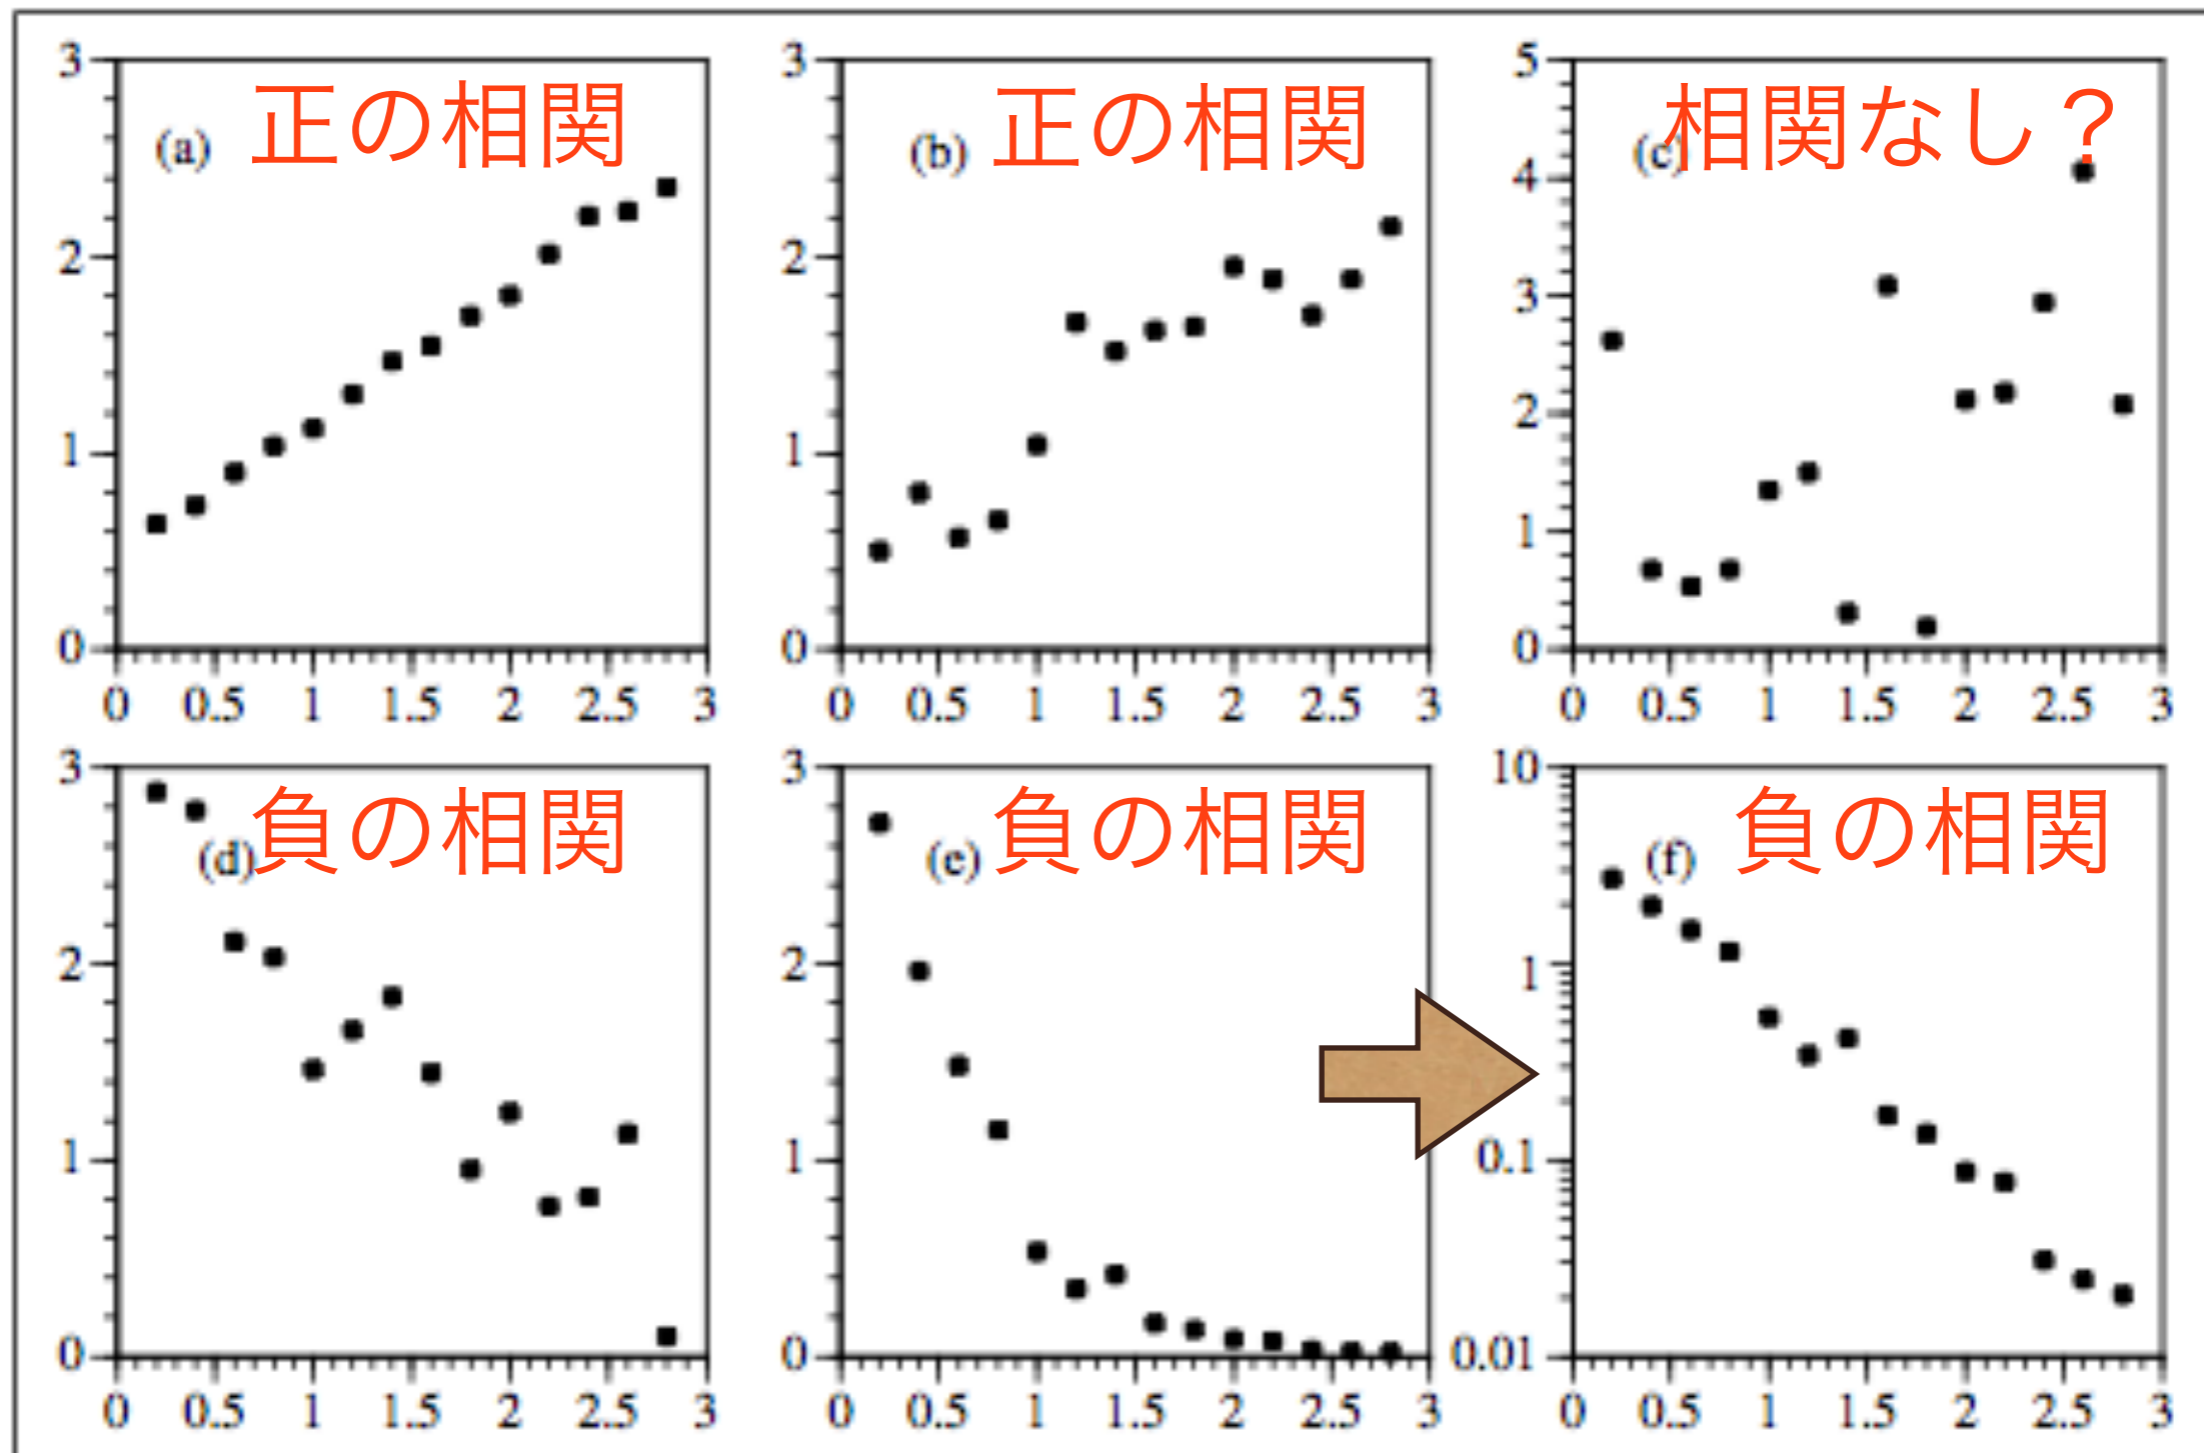



図 6.1 解析例データの散布図

相関係数


- ◆ 相関係数の定義式

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{S_{xy}}{\sqrt{S_{xx}S_{yy}}}$$

- ◆ r が $+1$ に近い：正の相関
- ◆ r が 0 付近：相関なし
- ◆ r が -1 に近い：負の相関



x と y の関係性を調べる



最小2乗法（一般形）

n 個の標本セット (x_i, y_i) があるとき、その関係性が $k+1$ 個のパラメーターセット (a_0, a_1, \dots, a_k) を用いた関数

$$y = G(x; a_0, a_1, \dots, a_k)$$

で近似できるとする。真値 y_i と推定値 $G(x_i)$ の差の2乗和 V を以下で与える。

$$V(a_0, a_1, \dots, a_k) = \sum_{i=1}^n (y_i - G(x_i; a_0, a_1, \dots, a_k))^2$$

最小2乗法（一般形）

V が最小となるようにパラメーターセット (a_0, a_1, \dots, a_k) を決定することで近似関数を決定する。

決定式

$$\frac{\partial V}{\partial a_j} = -2 \sum_{i=1}^n (y_i - G(x_i; a_0, a_1, \dots, a_k)) \frac{\partial G(x_i; a_0, a_1, \dots, a_k)}{\partial a_j} = 0$$

$$\begin{aligned} \frac{\partial^2 V}{\partial a_j^2} &= 2 \sum_{i=1}^n \frac{\partial G(x_i; a_0, a_1, \dots, a_k)}{\partial a_j} \frac{\partial G(x_i; a_0, a_1, \dots, a_k)}{\partial a_j} \\ &\quad - 2 \sum_{i=1}^n (y_i - G(x_i; a_0, a_1, \dots, a_k)) \frac{\partial^2 G(x_i; a_0, a_1, \dots, a_k)}{\partial a_j^2} > 0 \end{aligned}$$

最小2乗法（多項式）

n 個の標本セット (x_i, y_i) があるとき、その関係性が $k+1$ 個のパラメーターセット (a_0, a_1, \dots, a_k) を用いた関数

$$y = \sum_{j=0}^k a_j x^j$$

で近似できるとする。真値 y_i と推定値 $\sum_{j=0}^k a_j x_i^j$ の差の2乗和 V を以下で与える。

$$V(a_0, a_1, \dots, a_k) = \sum_{i=1}^n \left(y_i - \sum_{j=0}^k a_j x_i^j \right)^2$$

最小2乗法（多項式）

V が最小となるようにパラメーターセット
 (a_0, a_1, \dots, a_k) を決定することで近似関数を決定する。

決定式
$$\frac{\partial V}{\partial a_j} = -2 \sum_{i=1}^n x_i^j \left(y_i - \sum_{j=0}^k a_j x_i^j \right) = 0$$

$k+1$ 本の連立1次方程式

$$\frac{\partial^2 V}{\partial a_j^2} = 2 \sum_{i=1}^n x_i^{2j} > 0$$

最小値条件を満足

最小2乗法（線形近似）

n 個の標本セット (x_i, y_i) があるとき、その関係性が2個のパラメーターセット (a_0, a_1) を用いた線形関数

$$y = a_0 + a_1x$$

で近似できるとする。真値 y_i と推定値 $a_0 + a_1x_i$ の差の2乗和 V を以下で与える。

$$V(a_0, a_1) = \sum_{i=1}^n (y_i - a_0 - a_1x_i)^2$$

よく利用するので覚えておくように！！

最小2乗法（線形関数）

V が最小となるようにパラメーターセット (a_0, a_1) を決定することで近似関数を決定する。

$$\frac{\partial V(a_0, a_1)}{\partial a_0} = -2 \sum_{i=1}^n (y_i - a_0 - a_1 x_i) = 0$$

$$\frac{\partial V(a_0, a_1)}{\partial a_1} = -2 \sum_{i=1}^n x_i (y_i - a_0 - a_1 x_i) = 0$$

最小 2 乘法 (線形関数)

$$\begin{aligned} \text{第 1 式 } \sum_{i=1}^n (y_i - a_0 - a_1 x_i) &= \sum_{i=1}^n y_i - a_0 \sum_{i=1}^n 1 - a_1 \sum_{i=1}^n x_i \\ &= n\bar{y} - na_0 - na_1\bar{x} = 0 \end{aligned}$$

$$\Rightarrow a_0 = \bar{y} - a_1\bar{x}$$

$$\text{第 2 式 } \sum_{i=1}^n x_i (y_i - a_0 - a_1 x_i) = \sum_{i=1}^n x_i y_i - a_0 \sum_{i=1}^n x_i - a_1 \sum_{i=1}^n x_i^2$$

$$= \sum_{i=1}^n x_i y_i - n\bar{x} \cdot \bar{y} + na_1\bar{x}^2 - a_1 \sum_{i=1}^n x_i^2 = 0$$

$$\Rightarrow a_1 = \frac{S_{xy}}{S_{xx}}$$

$$\Rightarrow a_0 = \bar{y} - \bar{x} \frac{S_{xy}}{S_{xx}}$$

最小点の確認

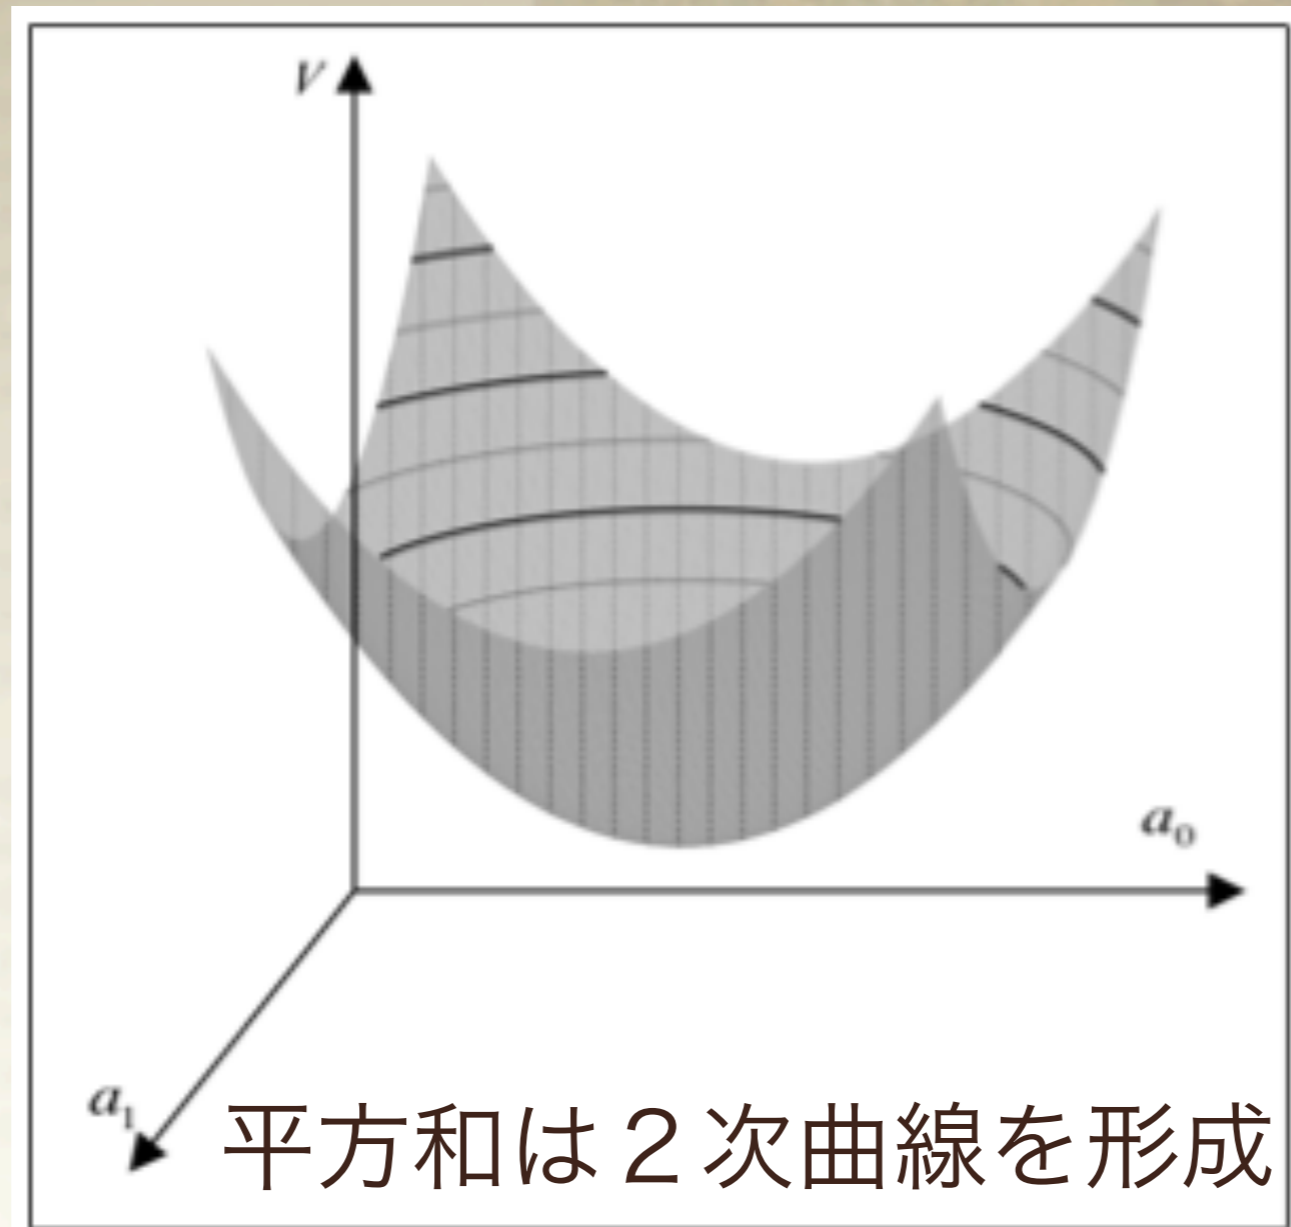


図 6.2 誤差の2乗和 V に関する概略図