


# マルチメディア信号処理 前半のまとめ

## モールス符号



Message  
SOS

Morse Code  
← . . . - . . .

## 最も簡単な圧縮は、モールス信号

文字	モールス符号 $i$	発生確率 $P_i$	長さ $L_i$
A	· -	0.064	6
B	- · · ·	0.013	10
C	- · - ·	0.022	12
Space	← 符号長 →	0.186	1

- 【二値化】それぞれの文字を「·」か「-」で置換する
- 【圧縮】通報全体の符号長を出来るだけ短くしたい

頻出する文字には短い符号を、  
さまなければ長い符号を割り当てる。

## 圧縮の基本 ハフマン符号化

通報 = { ABC\_AAB\_AABA } の場合

文字	自然2進数	ハフマン符号	発生頻度
A	00 [2 bit]	1 [1 bit] (短い)	6 (頻出)
B	01 [2 bit]	00 [2 bit] ↑	3 ↑
-	11 [2 bit]	010 [3 bit] ↓	2 ↓
C	10 [2 bit]	011 [3 bit] (長い)	1 (希少)

それぞれの文字を0と1の符号で置き換える(二値化する)

## 圧縮後は...


通報 = { ABC\_AAB\_AABA } の場合

文字	ハフマン符号
A	1 [1 bit]
B	00 [2 bit]
-	010 [3 bit]
C	011 [3 bit]

→ 1BC\_AAB\_AABA  
 → 100C\_AAB\_AABA  
 → 10001101...AB\_AABA  
 → 100011010110001011001  
 【21 bit 圧縮後】 ← 圧縮  
 → 000110110000011100000100  
 【24 bit 圧縮前】

→ “符号長”を各自計算すること

## ハフマン符号を 作ってみよう



各文字の発生頻度が  
分かれれば、圧縮できる。

## 課題

【問題1】 一番圧縮できる通報を選べ。

- 通報① {ABC\_ABC\_ABC\_}
- 通報② {AABBBC\_AC\_C\_}
- 通報③ {ABA\_ABABCACA}

【問題2】 どのような場合に効率良く圧縮できるか？

【問題3】 通報①は、全く圧縮出来ないか？

## 自己情報量 とは何か？

発生確率	自己情報量	ハフマン符号	
$P(1) = 5/11$	$-\log_2 P(1) = 1.14$ bit	1	1 bit
$P(2) = 3/11$	$-\log_2 P(2) = 1.87$ bit	00	2 bit
$P(3) = 2/11$	$-\log_2 P(3) = 2.46$ bit	011	3 bit
$P(4) = 1/11$	$-\log_2 P(4) = 3.46$ bit	010	3 bit


発生確率 ⇒ 自己情報量 ⇒ 符号長の推定

## エントロピー とは何か？

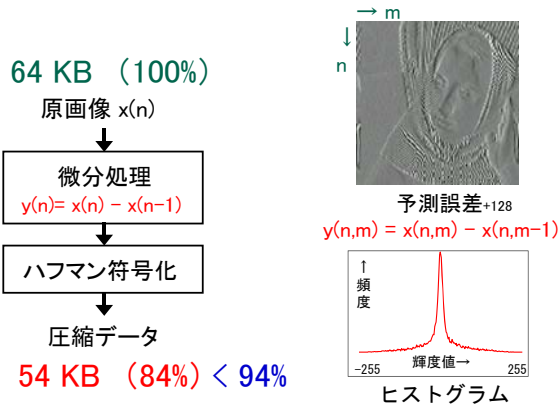
発生確率	重み × 自己情報量	ハフマン符号	
$P(1) = 5/11$	$-P(1)\log_2 P(1) = 0.52$	1	$1\text{bit} \times 5/11 = 0.45$
$P(2) = 3/11$	$-P(2)\log_2 P(2) = 0.51$	00	$2\text{bit} \times 3/11 = 0.55$
$P(3) = 2/11$	$-P(3)\log_2 P(3) = 0.45$	011	$3\text{bit} \times 2/11 = 0.55$
$P(4) = 1/11$	$-P(4)\log_2 P(4) = 0.31$	010	$3\text{bit} \times 1/11 = 0.27$
合計 1.79 bit/文字 エントロピー (平均情報量)		合計 1.82 bit/文字 平均符号長	

自己情報量の重みつき和 ⇒ エントロピー ⇒ 平均符号長の推定

## ハフマン符号化だけでは不十分



## 微分を併用して効果的に圧縮



## 予測の実例 微分と積分で元通り！

### 原信号

$$[x(0) \ x(1) \ x(2)] = [10 \ 12 \ 11]$$

### 予測処理 (微分)

$$y(0) = x(0) - x(-1) = 10 - 0 = 10$$

$$y(1) = x(1) - x(0) = 12 - 10 = 2 \text{ 予測誤差}$$

$$y(2) = x(2) - x(1) = 11 - 12 = -1$$

### 再生方法 (積分)

$$\underline{x}(0) = y(0) + \underline{x}(-1) = 10 + 0 = 10$$

$$\underline{x}(1) = y(1) + \underline{x}(0) = 2 + 10 = 12$$

$$\underline{x}(2) = y(2) + \underline{x}(1) = -1 + 12 = 11$$

## 課題


1. 以下の2つのうち、圧縮できる方を選び。

$$\begin{aligned} [x(0) \ x(1) \ \dots \ x(5)] &= [2 \ 2 \ 2 \ 1 \ 1 \ 1] \\ [x(0) \ x(1) \ \dots \ x(5)] &= [1 \ 0 \ 1 \ 0 \ 1 \ 0] \end{aligned}$$

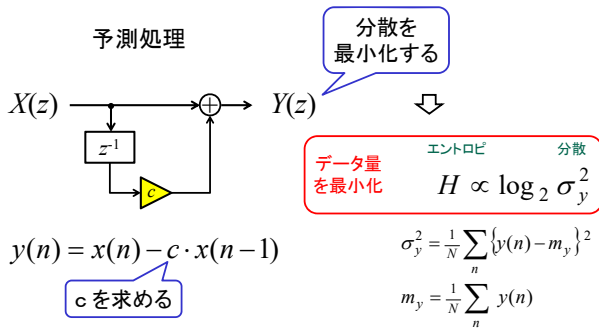
2. 予測処理  $y(n) = x(n) - x(n-1)$  を施せ。

3. 予測の結果を、ハフマン符号化せよ。

## 微分は予測 (0次の外挿)



## 最適な予測器 を設計しよう



## 最適な予測器 を設計しよう

以下の予測処理,

$$y(n) = x(n) + c \cdot x(n-1)$$

において、与えられた入力信号“ $x(n)$ ”に対する最適な“ $c$ ”の値を求めたい。

予測後のデータ量  $\propto \log(\text{予測誤差の分散})$   
 $\Rightarrow$  予測誤差の分散を最小化する

## 最適化の方法

1. 予測誤差“ $y(n)$ ”の分散値を“ $c$ ”で表す。  $m_y = \frac{1}{N} \sum_n y(n) = 0$

$$\begin{aligned} \sigma_y^2 &= \frac{1}{N} \sum_n \{y(n) - m_y\}^2, \text{ 以下、平均 } m_y = 0 \text{ のとき} \\ &= \frac{1}{N} \sum_n \{x(n) + c \cdot x(n-1)\}^2 \end{aligned}$$

2. 得られた分散値を最小とする“ $c$ ”は次式を満たす。

$$\frac{\partial \sigma_y^2}{\partial c} = 0$$

以上を解けば最適係数値が決定される。

3. 計算すると


$$\begin{aligned} \frac{\partial}{\partial c} \sigma_y^2 &= \frac{1}{N} \sum_n 2\{x(n) + c \cdot x(n-1)\} \cdot \frac{\partial}{\partial c} \{x(n) + c \cdot x(n-1)\} = 0 \\ \sum_n \{x(n) + c \cdot x(n-1)\} \cdot \frac{\partial}{\partial c} \{x(n) + c \cdot x(n-1)\} &= 0 \\ \sum_n \{x(n) + c \cdot x(n-1)\} \cdot x(n-1) &= 0 \\ \sum_n x(n)x(n-1) + c \cdot \sum_n x^2(n-1) &= 0 \end{aligned}$$

4. 以上より、

$$c = \frac{-R_1}{R_0} \quad \text{最適な予測係数は自己相関で決まる}$$

$$\begin{cases} R_0 = \sum_n x^2(n-1) \\ R_1 = \sum_n x(n)x(n-1) \end{cases}$$

## 最適な予測器を設計しよう (K=2次)



分散が最小となるよう  
a, b を最適化する



データ量を最小化  
 $H \propto \log_2 \sigma_y^2$   
エントロピー 分散

$$y(n) = x(n) + a \cdot x(n-1) + b \cdot x(n-2)$$

a, b を求める

$$\sigma_y^2 = \frac{1}{N} \sum_n \{y(n) - m_y\}^2$$

$$m_y = \frac{1}{N} \sum_n y(n)$$

## 最適な予測器 (パラメータ 2つ)

以下の予測処理,

$$y(n) = x(n) + a x(n-1) + b x(n-2)$$

において, 与えられた入力信号 “x(n)”

に対する最適な “a, b” の値を求めたい.



予測後のデータ量  $\propto \log(\text{予測誤差の分散})$

$\Rightarrow$  予測誤差の分散を最小化する

## 最適化の方法 (パラメータ2つ)

1. 予測誤差 “y(n)” の分散値を “a, b” で表す.  $m_y = \frac{1}{N} \sum_n y(n) = 0$

$$\sigma_y^2 = \frac{1}{N} \sum_n \{y(n) - m_y\}^2, \text{ 以下、平均 } m_y = 0 \text{ のとき}$$

$$= \frac{1}{N} \sum_n \{x(n) + a \cdot x(n-1) + b \cdot x(n-2)\}^2$$

2. 得られた分散値を最小とする “a, b” は次式を満たす.

$$\frac{\partial}{\partial a} \sigma_y^2 = 0, \quad \frac{\partial}{\partial b} \sigma_y^2 = 0$$

この方程式を解けば最適な係数が決まる

3. 最初の方程式は,

$$f = x(n) + a \cdot x(n-1) + b \cdot x(n-2) \quad (1)$$

とおくと、

$$\frac{\partial}{\partial a} \sigma_y^2 = \frac{\partial}{\partial a} \frac{1}{N} \sum_n f^2 = \frac{1}{N} \sum_n 2f \cdot \frac{\partial}{\partial a} f = 0$$

$$\therefore \sum_n f \cdot \frac{\partial}{\partial a} f = 0 \quad (2)$$

(1)  $\rightarrow$  (2)

$$\sum_n \{x(n) + a \cdot x(n-1) + b \cdot x(n-2)\} \cdot x(n-1) = 0$$

$$\sum_n x(n)x(n-1) + a \cdot \sum_n x^2(n-1) + b \cdot \sum_n x(n-1)x(n-2) = 0$$

以上より、

但し、

$$R_{01} + a \cdot R_{11} + b \cdot R_{12} = 0$$

$$R_{ji} = \frac{1}{N} \sum_{n=0}^{N-1} x(n-j)x(n-i)$$

4. もう一つの方程式より、

$$\frac{\partial}{\partial b} \sigma_y^2 = \frac{1}{N} \sum_n 2f \cdot \frac{\partial}{\partial b} f = 0 \rightarrow \sum_n f \cdot \frac{\partial}{\partial b} f = 0$$

に

$$f = x(n) + a \cdot x(n-1) + b \cdot x(n-2)$$

を代入して、

$$\sum_n \{x(n) + a \cdot x(n-1) + b \cdot x(n-2)\} \cdot x(n-2) = 0$$

$$\sum_n x(n)x(n-2) + a \cdot \sum_n x(n-1)x(n-2) + b \cdot \sum_n x^2(n-2) = 0$$

以上より、

但し、

$$R_{02} + a \cdot R_{12} + b \cdot R_{22} = 0$$

$$R_{ji} = \frac{1}{N} \sum_{n=0}^{N-1} x(n-j)x(n-i)$$

5. 得られた2つの方程式より

$$\begin{cases} R_{01} + a \cdot R_{11} + b \cdot R_{12} = 0 \\ R_{02} + a \cdot R_{12} + b \cdot R_{22} = 0 \end{cases}$$

自己相関が

$$\begin{cases} R_{11} = R_{22} = \Theta_0 \\ R_{01} = R_{12} = \Theta_1 \\ R_{02} = R_{13} = \Theta_2 \end{cases}$$

$$\leftarrow R_{ji} = \frac{1}{N} \sum_{n=0}^{N-1} x(n-j)x(n-i)$$

を満たす場合、方程式は、

$$\begin{pmatrix} \Theta_1 + a \cdot \Theta_0 + b \cdot \Theta_1 \\ \Theta_2 + a \cdot \Theta_1 + b \cdot \Theta_0 \end{pmatrix} = 0 \quad \Leftrightarrow \quad \begin{pmatrix} \Theta_1 \\ \Theta_2 \end{pmatrix} + \begin{pmatrix} \Theta_0 & \Theta_1 \\ \Theta_1 & \Theta_0 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

6. 以上より、

$$\begin{pmatrix} a \\ b \end{pmatrix} = - \begin{pmatrix} \Theta_0 & \Theta_1 \\ \Theta_1 & \Theta_0 \end{pmatrix}^{-1} \begin{pmatrix} \Theta_1 \\ \Theta_2 \end{pmatrix}$$

なので、

$$\begin{pmatrix} a \\ b \end{pmatrix} = \frac{-1}{\Theta_0^2 - \Theta_1^2} \begin{pmatrix} \Theta_0 & -\Theta_1 \\ -\Theta_1 & \Theta_0 \end{pmatrix} \begin{pmatrix} \Theta_1 \\ \Theta_2 \end{pmatrix}$$

$$= \frac{-1}{\Theta_0^2 - \Theta_1^2} \begin{pmatrix} \Theta_0\Theta_1 - \Theta_1\Theta_2 \\ -\Theta_1\Theta_1 + \Theta_0\Theta_2 \end{pmatrix}$$

最適な予測係数は自己相関で決まる

但し、

$$\Theta_k = \frac{1}{N} \sum_{n=0}^{N-1} x(n-j)x(n-i), \quad |j-i|=k$$

k次の自己相関

k次の相関係数を、

$$\Phi_k = \frac{\Theta_k}{\Theta_0}$$

但し、

$$\Theta_k = \frac{1}{N} \sum_{n=0}^{N-1} x(n-j)x(n-i), \quad |j-i|=k$$

と定義すると、

$$\begin{cases} a = \frac{\Theta_1\Theta_2 - \Theta_0\Theta_1}{\Theta_0^2 - \Theta_1^2} = \frac{-(1-\Phi_2)\Phi_1}{1-\Phi_1^2} \\ b = \frac{\Theta_1\Theta_1 - \Theta_0\Theta_2}{\Theta_0^2 - \Theta_1^2} = \frac{\Phi_1^2 - \Phi_2}{1-\Phi_1^2} \end{cases}$$

最適な予測係数は自己相関係数で決まる


### AR(1)モデル に対する 最適予測

AR(1) model の自己相関は、

$$\Phi_k = \rho^k$$


と表される。このとき、

$$\begin{cases} a = \frac{-(1-\Phi_2)\Phi_1}{1-\Phi_1^2} = \frac{-(1-\rho^2)\rho}{1-\rho^2} = -\rho \\ b = \frac{\Phi_1^2 - \Phi_2}{1-\Phi_1^2} = \frac{\rho^2 - \rho^2}{1-\rho^2} = 0 \end{cases}$$



### AR(1)モデルとは？



“ρ”は相関係数，“ρ=0.95”程度が良い近似



$$x(n) = w(n) + \rho \cdot x(n-1)$$

但しw(n)は平均値が零の白色信号

x(n)の周波数振幅特性と自己相関関数を求めよ



### AR(1)モデルの周波数振幅特性と自己相関

$$X(e^{j\omega}) = \frac{1}{1 - \rho e^{j\omega}}$$

$$|X(e^{j\omega})| = \frac{1}{\sqrt{(1 - \rho \cos \omega)^2 + (\rho \sin \omega)^2}}$$

$$= \frac{1}{\sqrt{1 + \rho^2 - 2\rho \cos \omega}}$$



$$R_1 = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x(n-1)$$

$$= \frac{1}{N} \sum_{n=0}^{N-1} \{\rho \cdot x(n-1) + w(n)\}x(n-1)$$


$$= \rho \cdot \frac{1}{N} \sum_{n=0}^{N-1} x^2(n-1) + \frac{1}{N} \sum_{n=0}^{N-1} w(n)x(n-1)$$

$$\approx \rho \cdot R_0$$

$$\therefore R_k = \rho^k \cdot R_0$$



### AR(1) モデルの最適予測



$$x(n) = w(n) + \rho \cdot x(n-1)$$

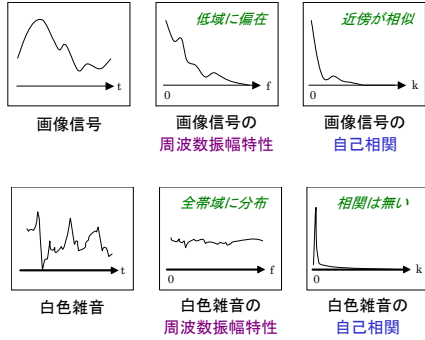
$$y(n) = x(n) - \rho \cdot x(n-1)$$

$$X(z) = \frac{1}{1 - \rho \cdot z^{-1}} W(z)$$

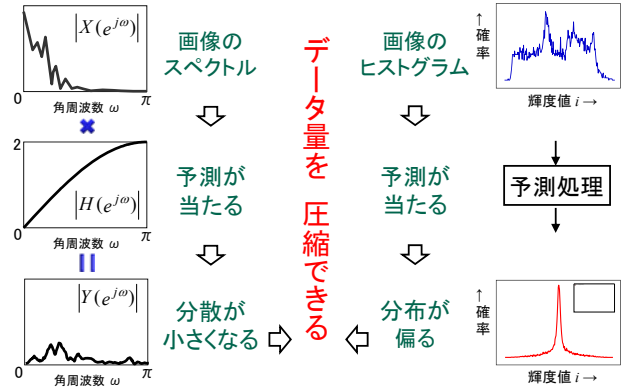
$$Y(z) = (1 - \rho \cdot z^{-1}) X(z)$$

$$Y(z) = W(z)$$

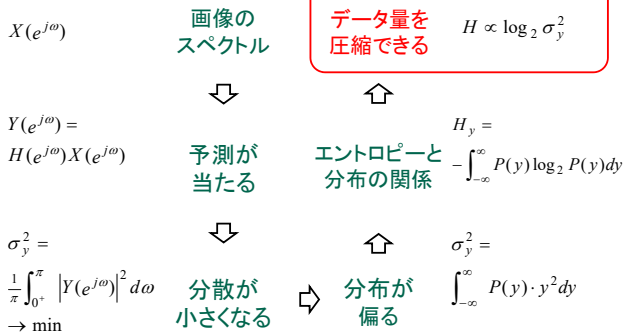
## 周波数振幅特性 と 自己相関



## 圧縮する = 分散を小さくする



## 圧縮する = 分散を小さくする



## 分散とエントロピー

確率密度関数  $P(x)$  が以下である信号  $x(n)$  について、エントロピー  $H$  と分散  $\sigma^2$  の関係を示せ。

$$P(x) = \begin{cases} 1/\Delta & \text{for } |x| \leq \Delta/2 \\ 0 & \text{for } |x| > \Delta/2 \end{cases}$$

ヒント

$$H = -\int_{-\infty}^{\infty} P(x) \log_2 P(x) dx$$

$$\sigma^2 = \int_{-\infty}^{\infty} P(x) x^2 dx$$

分散を小さく  
→ データ圧縮

$$H \propto \log_2 \sigma^2$$

## 分散とエントロピー


$$\begin{aligned} \sigma^2 &= \int_{-\infty}^{\infty} P(x) x^2 dx & H &= -\int_{-\infty}^{\infty} P(x) \log_2 P(x) dx \\ &= 2 \int_0^{\Delta/2} \frac{1}{\Delta} x^2 dx & &= -2 \int_0^{\Delta/2} \frac{1}{\Delta} \log_2 \frac{1}{\Delta} dx \\ &= \frac{2}{\Delta} \int_0^{\Delta/2} x^2 dx & &= \frac{2 \log_2 \Delta}{\Delta} \int_0^{\Delta/2} dx \\ &= \frac{2}{\Delta} \left[ \frac{x^3}{3} \right]_0^{\Delta/2} & &= \log_2 \Delta \\ &= \frac{\Delta^2}{12} \end{aligned}$$

$$H = \log_2 \Delta = \frac{1}{2} (\log_2 \sigma^2 + \log_2 12)$$

分散を小さく  
→ データ圧縮

$$H \propto \log_2 \sigma^2$$


## 前半の 話の流れ



## 関連事項

## 線形回帰

課題  $p_0, p_1$  を求よ



データ 直線上の点  
 $n \quad x_n \quad y_n \quad f(x)$

1	0	1	$p_0 + p_1 \cdot 0$
2	1	0	$p_0 + p_1 \cdot 1$
3	2	2	$p_0 + p_1 \cdot 2$

← 差 →

方法1 【最小二乗法】

$$I = \sum_n \{f(x_n) - y_n\}^2, \quad \frac{\partial I}{\partial p_k} = 0$$

発展 2次の場合は？

$$y = p_0 + p_1 x + p_2 x^2$$


$$P = [1.5 \quad -2.5 \quad 1.00]$$

方法2 【一般化逆行列】


$$(X^T \cdot X)^{-1} \cdot X^T$$

## 次数を増やすと...


直線  
(1次)




曲線  
(2次)



曲線  
(3次)



曲線  
(4次)



## 方法1 【最小二乗法】

誤差を定義する

$$I = \{1 - (p_0 + p_1 \cdot 0)\}^2 + \{0 - (p_0 + p_1 \cdot 1)\}^2 + \{2 - (p_0 + p_1 \cdot 2)\}^2$$

データ 直線上の点  
 $n \quad x_n \quad y_n \quad f(x)$

1	0	1	$p_0 + p_1 \cdot 0$
2	1	0	$p_0 + p_1 \cdot 1$
3	2	2	$p_0 + p_1 \cdot 2$

← 差 →

方程式を解く

$$\begin{cases} \frac{\partial I}{\partial p_0} = 0 \\ \frac{\partial I}{\partial p_1} = 0 \end{cases} \Rightarrow \begin{cases} 0 = 2\{1 - (p_0 + p_1 \cdot 0)\}(-1) \\ \quad + 2\{0 - (p_0 + p_1 \cdot 1)\}(-1) \\ \quad + 2\{2 - (p_0 + p_1 \cdot 2)\}(-1) \\ 0 = 2\{1 - (p_0 + p_1 \cdot 0)\} \cdot (-0) \\ \quad + 2\{0 - (p_0 + p_1 \cdot 1)\} \cdot (-1) \\ \quad + 2\{2 - (p_0 + p_1 \cdot 2)\} \cdot (-2) \end{cases} \Rightarrow \begin{cases} \begin{bmatrix} 3 & 3 \\ 3 & 5 \end{bmatrix} \begin{bmatrix} p_0 \\ p_1 \end{bmatrix} = \begin{bmatrix} 3 \\ 4 \end{bmatrix} \\ \therefore \begin{bmatrix} p_0 \\ p_1 \end{bmatrix} = \begin{bmatrix} 0.5 \\ 0.5 \end{bmatrix} \end{cases}$$

## 方法1 【最小二乗法】

1. 誤差を定義する

$$I = \sum_{n=1}^N \{f(x_n) - y_n\}^2 \quad \text{但し、} f(x) = \sum_{k=0}^K p_k x^k$$

2. 方程式を解く

$$\frac{\partial I}{\partial p_k} = 0, \quad k = 1, 2, \dots, K$$

$$\begin{cases} \frac{\partial I}{\partial p_0} = \sum_{n=1}^N 2 \cdot \{p_0 + p_1 \cdot x_n - y_n\} \cdot 1 = 0 \\ \frac{\partial I}{\partial p_1} = \sum_{n=1}^N 2 \cdot \{p_0 + p_1 \cdot x_n - y_n\} \cdot x_n = 0 \end{cases}$$

3.  $K=2$  の例

$$\begin{bmatrix} p_0 \\ p_1 \end{bmatrix} = \begin{bmatrix} N & \sum_{n=1}^N x_n \\ \sum_{n=1}^N x_n & \sum_{n=1}^N x_n^2 \end{bmatrix}^{-1} \cdot \begin{bmatrix} \sum_{n=1}^N y_n \\ \sum_{n=1}^N y_n x_n \end{bmatrix}$$

## 最小自乗法 (詳細)

$$I = \sum_{i=0}^{N-1} \{y(x_i) - y_i\}^2 = \sum_{i=0}^{N-1} \{a + b x_i - y_i\}^2 \quad \leftarrow y(x_i) = a + b x_i$$

より,

$$\frac{\partial I}{\partial a} = \frac{\partial}{\partial a} \sum_{i=0}^{N-1} \{a + b x_i - y_i\}^2 = 2 \sum_{i=0}^{N-1} \{a + b x_i - y_i\} = 0 \quad \leftarrow \frac{df(g(x))}{dx} = \frac{df}{dg} \frac{dg}{dx}$$

$$\frac{\partial I}{\partial b} = \frac{\partial}{\partial b} \sum_{i=0}^{N-1} \{a + b x_i - y_i\}^2 = 2 \sum_{i=0}^{N-1} \{a + b x_i - y_i\} x_i = 0$$

すなわち,

$$\begin{pmatrix} \sum_{i=0}^{N-1} 1 & \sum_{i=0}^{N-1} x_i \\ \sum_{i=0}^{N-1} x_i & \sum_{i=0}^{N-1} x_i^2 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \sum_{i=0}^{N-1} y_i \\ \sum_{i=0}^{N-1} x_i y_i \end{pmatrix}$$

以上より,

$$\begin{pmatrix} a \\ b \end{pmatrix} = \frac{1}{\sum_{i=0}^{N-1} x_i^2 \sum_{i=0}^{N-1} 1 - \sum_{i=0}^{N-1} x_i \sum_{i=0}^{N-1} x_i} \begin{pmatrix} \sum_{i=0}^{N-1} y_i^2 & -\sum_{i=0}^{N-1} x_i \\ -\sum_{i=0}^{N-1} x_i & \sum_{i=0}^{N-1} 1 \end{pmatrix} \begin{pmatrix} \sum_{i=0}^{N-1} y_i \\ \sum_{i=0}^{N-1} y_i x_i \end{pmatrix}$$

## 方法2 【一般化逆行列】

行列で表す

$$\begin{bmatrix} 1 \\ 0 \\ 2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} p_0 \\ p_1 \end{bmatrix}$$

データ 直線上の点  
 $n \quad x_n \quad y_n \quad f(x)$

$$\begin{array}{l} 1 \quad 0 \quad 1 = p_0 + p_1 \cdot 0 \\ 2 \quad 1 \quad 0 = p_0 + p_1 \cdot 1 \\ 3 \quad 2 \quad 2 = p_0 + p_1 \cdot 2 \end{array}$$

↑  
等しいとおく...

方程式を解く

$$P = X^{-1} Y \quad \dots \text{ではなくて}$$

$$P = X^+ Y \quad \dots \text{で求まる}$$

ここで、

$$X^+ = (X^T X)^{-1} X^T \quad \text{一般化逆行列}$$

$$X^+ = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 1 & 2 \end{bmatrix}^{-1} \cdot \begin{bmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 1 & 2 \end{bmatrix}$$

$$\begin{bmatrix} p_0 \\ p_1 \end{bmatrix} = X^+ \begin{bmatrix} 1 \\ 0 \\ 2 \end{bmatrix} = \begin{bmatrix} 0.5 \\ 0.5 \end{bmatrix}$$

## 一般化逆行列は 2種類


$$X^+ = (X^T \cdot X)^{-1} \cdot X^T$$

縦長な X に使う (方程式が変数より **多い**・優決定)  
 最小自乗の意味で最適


$$X^+ = X^T \cdot (X \cdot X^T)^{-1}$$

横長な X に使う (方程式が変数より **少ない**・劣決定)  
 $\|X\|_2$  が最小

## 誤差の測り方は 2通り



$$\min \sum_{n=1}^3 \{f(x_n) - y_n\}^2$$



$$\min \sum_{n=1}^3 \{(x - x_n)^2 + (y - y_n)^2\}$$

s.t.  $y = f(x)$

## ラグランジュの未定乗数法


$f(x) = p_0 + p_1 \cdot x$  については、

$$\frac{\partial J}{\partial p_0} = 0, \quad \frac{\partial J}{\partial p_1} = 0$$

に対して、

$$\frac{\partial J}{\partial \lambda} = 0$$

を加えて解けばよい、



$$J = \sum_{n=1}^3 \{(x - x_n)^2 + (y - y_n)^2\} + \lambda \{y - f(x)\}$$

$$\min \sum_{n=1}^3 \{(x - x_n)^2 + (y - y_n)^2\}$$

s.t.  $y - f(x) = 0$

## 拘束条件付きの 最小二乗法

$$f(x) = \sum_{k=1}^K p_k \cdot x^k \quad \text{については、}$$

$$\frac{\partial J}{\partial p_i} = 0, \quad i = 1, 2, \dots$$

に対して、

$$\frac{\partial J}{\partial \lambda} = 0$$

を加えて解けばよい、

$\lambda$ : ラグランジュの未定乗数

$$J = \sum_{n=1}^3 \{(x - x_n)^2 + (y - y_n)^2\} + \lambda \{y - f(x)\} \leftarrow \text{拘束条件}$$

$$\min \sum_{n=1}^3 \{(x - x_n)^2 + (y - y_n)^2\}$$

s.t.  $y - f(x) = 0 \leftarrow \text{拘束条件}$