

インタラクティブシステム論 第11回

梶本裕之
Twitter ID kajimoto
ハッシュタグ #ninshiki

行列復習

(センシングに現れる行列・逆行列)

(復習) 行列: データ列を変換するもの

$$\mathbf{y} = \mathbf{A}\mathbf{x} \quad \mathbf{x} = \mathbf{A}^{-1}\mathbf{y}$$

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

(例1)


y: 観測データ, A: システムの性質, x: 媒介変数

(例2)

y: フーリエ空間での周波数成分, A: フーリエ変換行列,

x: 実空間でのデータ系列

(復習) (例) 2軸力センサ



$$F_Z = x_A + x_B$$


$$F_X = k(x_A - x_B)$$



$$2 \times 1 \text{ ベクトル } \left[\begin{bmatrix} F_Z \\ F_X \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ k & -k \end{bmatrix} \begin{bmatrix} x_A \\ x_B \end{bmatrix} \right] 2 \times 1 \text{ ベクトル}$$

2x2 行列

(復習) カセンサのキャリブレーション(校正)



$$F_Z = k_1 x_A + k_2 x_B \quad \begin{bmatrix} F_Z \\ F_X \end{bmatrix} = \begin{bmatrix} k_1 & k_2 \\ k_3 & k_4 \end{bmatrix} \begin{bmatrix} x_A \\ x_B \end{bmatrix}$$

$$F_X = k_3 x_A + k_4 x_B$$

k1~k4のパラメータは元々未知。
これを求めなければ使えない!!

(復習) 逆行列

$$\begin{bmatrix} F_Z \\ F_X \end{bmatrix} = \begin{bmatrix} k_1 & k_2 \\ k_3 & k_4 \end{bmatrix} \begin{bmatrix} x_A \\ x_B \end{bmatrix}$$


これを $\mathbf{f} = \mathbf{A}\mathbf{x}$ と書く。

ここで、
「ある力を加えたときの各センサ出力は？」
という逆の関係を考える。

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{f} = \mathbf{G}\mathbf{f} \quad \begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} F_Z \\ F_X \end{bmatrix}$$

(復習) 逆行列の測定

$$\mathbf{x} = \mathbf{Gf} \quad \begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} F_Z \\ F_X \end{bmatrix}$$



(1) $F_z=1, F_x=0$ の力を加え、各センサの出力を記録

$$\begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} g_1 \\ g_3 \end{bmatrix}$$

各センサの出力に、逆行列の成分 g_1, g_3 が現れる！

(2) $F_z=0, F_x=1$ の力を加え、各センサの出力を記録

$$\begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} g_2 \\ g_4 \end{bmatrix}$$

各センサの出力に、逆行列の成分 g_2, g_4 が現れる！



(復習) 逆行列の測定

$$\mathbf{x} = \mathbf{Gf} = \mathbf{A}^{-1}\mathbf{f} \quad \begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} F_Z \\ F_X \end{bmatrix}$$



$\mathbf{G}=\mathbf{A}^{-1}$ の成分、 $g_1 \sim g_4$ が得られたので、その逆行列を計算すれば \mathbf{A} が得られる。

$$\mathbf{f} = \mathbf{Ax}$$

まとめると、

$$\begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} g_1 \\ g_3 \end{bmatrix}$$

$$\begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} g_2 \\ g_4 \end{bmatrix}$$

行列に単位行列をかけたことに相当



(復習) 単位力だけでなく良い

$$\begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} f_{z1} \\ f_{x1} \end{bmatrix} = \begin{bmatrix} m_1 \\ m_2 \end{bmatrix}$$

$$\begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} f_{z2} \\ f_{x2} \end{bmatrix} = \begin{bmatrix} m_1 \\ m_2 \end{bmatrix}$$


$$\mathbf{GF} = \mathbf{M}$$

$$\mathbf{G} = \mathbf{MF}^{-1}$$

- 2回既知のカベクトルを加えて、各センサの出力を得る
- カベクトルを並べたものを力行列 \mathbf{F} 、センサ出力を並べたものを行列 \mathbf{M} とする
- 力行列の逆行列 \mathbf{F}^{-1} を \mathbf{M} にかければ、行列 \mathbf{G} が得られる。
- \mathbf{G} の逆行列が望んだ校正行列 \mathbf{A}



(復習) 逆行列が使えない場合



$$F_z = k_1(x_A + x_B + x_C + x_D)$$

$$F_x = k_2((x_A + x_B) - (x_C + x_D))$$

$$F_y = k_3((x_A + x_C) - (x_B + x_D))$$

$$\begin{bmatrix} F_z \\ F_x \\ F_y \end{bmatrix} = \begin{bmatrix} k_1 & k_1 & k_1 & k_1 \\ k_2 & k_2 & -k_2 & -k_2 \\ k_3 & -k_3 & k_3 & -k_3 \end{bmatrix} \begin{bmatrix} x_A \\ x_B \\ x_C \\ x_D \end{bmatrix}$$


一般には正方形ではない！！

(例)6軸カセンサには8つ以上のセンサエレメント内蔵



行列と最小二乗法

本日の疑問



- 一般には正方行列ではない
- 「逆行列」は定義できず、キャリブレーションもできないのでは

本日の解答


$$3 \begin{bmatrix} F_z \\ F_x \\ F_y \end{bmatrix} = \begin{bmatrix} k_1 & k_1 & k_1 & k_1 \\ k_2 & k_2 & -k_2 & -k_2 \\ k_3 & -k_3 & k_3 & -k_3 \end{bmatrix} \begin{bmatrix} x_A \\ x_B \\ x_C \\ x_D \end{bmatrix} \quad 4$$

3x4行列



- 逆行列は定義できなくても擬似逆行列(Pseudo Inverse Matrix)は定義できる.
- またこれは最小二乗法という、工学全体を支える基礎的な考えである.

色々なセンサ

フィルム状カセンサ



フォトリフレクタを用いた近接距離センサ





いかにして較正曲線を求め、センサとして使えるようにするか？

フィルム状カセンサ



<https://www.youtube.com/watch?v=Y12b7UQM5Ho>

フィルムセンサの定式化(1)




17

フィルムセンサの定式化(2)



抵抗ではなくコンダクタンス(抵抗の逆数)を見る



$$y = ax + b \quad \begin{cases} x: \\ y: \\ a, b: \end{cases}$$


実験でなじみ深い「直線フィッティング」

18

一般化

$y = a_1x + a_2$ から一般化

$$y = a_1x_1 + a_2x_2 + \dots + a_Nx_N$$




N個の既知入力 $[x_1, x_2, \dots, x_N]$ と
 N個の未知パラメータ $[a_1, a_2, \dots, a_N]$ の
 積和によって1個の出力 y が決定されるシステム。

目的: N個の未知パラメータ $[a_1, a_2, \dots, a_N]$ の同定 (identification)
 取れる手段: 入力操作と出力の計測

フィルムセンサの場合: $y = a_1x_1 + a_2x_2$ where $x_2 = 1$

行列の形にする

$$y = a_1x_1 + a_2x_2 + \dots + a_Nx_N$$



入力を変化させ、M回の出力を得る

$$y_1 = a_1x_{11} + a_2x_{12} + \dots + a_Nx_{1N}$$

$$y_2 = a_1x_{21} + a_2x_{22} + \dots + a_Nx_{2N}$$

⋮

$$y_M = a_1x_{M1} + a_2x_{M2} + \dots + a_Nx_{MN}$$

結局

$$\mathbf{y} = \mathbf{X}\mathbf{a} \begin{cases} \mathbf{X}: M \times N \text{ 行列. 入力. 既知} \\ \mathbf{y}: M \times 1 \text{ ベクトル. 出力. 観測可能} \\ \mathbf{a}: N \times 1 \text{ ベクトル. 未知.} \end{cases}$$

もし $M=N$ なら

$$\mathbf{a} = \mathbf{X}^{-1}\mathbf{y}$$

実際には $M \neq N$ で \mathbf{X}^{-1} は存在しないことがほとんど

二乗誤差を最小化する (最小二乗法)

いかにして $\mathbf{y} = \mathbf{X}\mathbf{a}$ を \mathbf{a} について解くか。
 $\begin{cases} \mathbf{X}: M \times N \text{ 行列. 入力. 既知} \\ \mathbf{y}: M \times 1 \text{ ベクトル. 出力. 観測可能} \\ \mathbf{a}: N \times 1 \text{ ベクトル. 未知.} \end{cases}$

解けない (未知数より方程式の数が多い)
 つまり、式を完全に満たすベクトル \mathbf{a} は、無い

(1) 測定された出力ベクトル \mathbf{y} が誤差を含んでいると仮定
 $\mathbf{y} = \mathbf{X}\mathbf{a} + \mathbf{e}$ where $\mathbf{e} = [e_1, e_2, \dots, e_M]^T$

(2) 誤差の大きさが最小となるような \mathbf{a} を
 もっともらしい \mathbf{a} として受け入れよう。

(3) 大きさとして二乗和 (二乗ノルム) を採用。

$$\sum_{i=1}^M e_i^2 = [e_1, e_2, \dots, e_M] [e_1, e_2, \dots, e_M]^T = \mathbf{e}^T \mathbf{e}$$

誤差の「大きさ」

$$\mathbf{y} = \mathbf{X}\mathbf{a} + \mathbf{e}$$

$$\mathbf{e} =$$

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_M \end{bmatrix}$$

$$\|\mathbf{e}\|^2 = \mathbf{e}^T \mathbf{e} \quad \text{Tは転置.}$$

$$\|\mathbf{e}\|^2 = \sum_{i=1}^M e_i^2 = [e_1, e_2, \dots, e_M] \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_M \end{bmatrix} = \mathbf{e}^T \mathbf{e}$$



誤差の「大きさ」を最小化する

$$\|\mathbf{e}\|^2 = \mathbf{y}^T \mathbf{y} - 2\mathbf{y}^T \mathbf{X}\mathbf{a} + \mathbf{a}^T \mathbf{X}^T \mathbf{X}\mathbf{a} \quad \|\mathbf{e}\|^2 = a^2x^2 - 2ayx + y^2$$

誤差の大きさが最小となる \mathbf{a} を見つける

$$\frac{\partial}{\partial \mathbf{a}} \|\mathbf{e}\|^2 = \left[\frac{\partial}{\partial a_1} \|\mathbf{e}\|^2 \quad \frac{\partial}{\partial a_2} \|\mathbf{e}\|^2 \quad \dots \quad \frac{\partial}{\partial a_N} \|\mathbf{e}\|^2 \right]$$

$$\frac{\partial}{\partial \mathbf{a}} \|\mathbf{e}\|^2 =$$

$$=$$

$$=$$

$$\mathbf{a}^T \mathbf{X}^T \mathbf{X} =$$

$$\mathbf{a}^T =$$

$$\mathbf{a} =$$

$$\|\mathbf{e}\|^2 = \frac{\partial}{\partial a} (a^2x^2 - 2ayx + y^2) = 2x^2a - 2yx = 0$$

$$x^2a = yx$$

$$a = y/x$$

$$\therefore (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{y} = ((x^T x)^T)^{-1} = (x^T x)^{-1}$$

擬似逆行列

結論: 未知パラメータのベクトル \mathbf{a} は次の式で求められる。

$$\mathbf{a} = \mathbf{X}^\# \mathbf{y}$$

ただし

$$\mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$$

$\mathbf{X}^\#$: 擬似逆行列 (Pseudo Inverse)

擬似逆行列は逆行列の拡張である

行列xが正則な場合


$$\mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$$

$$=$$

$$=$$

(再考)フィルムセンサの場合


$$y = a_1 x + a_2 \begin{cases} x: \text{力: 既知入力} \\ y: \text{コンダクタンス: 測定結果} \\ a_1, a_2: \text{未知パラメータ} \end{cases}$$





これは
 $y = a_1 x_1 + a_2 x_2$ where $x_2 = 1$
 とみなせる。

加える力を変え、M回測定する(2回以上)

$$\begin{matrix} y_1 = a_1 x_{11} + a_2 1 \\ y_2 = a_1 x_{21} + a_2 1 \\ \vdots \\ y_M = a_1 x_{M1} + a_2 1 \end{matrix} \quad \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} x_{11} & 1 \\ x_{21} & 1 \\ \vdots & \vdots \\ x_{M1} & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}$$



(再考)フィルムセンサの場合



よって、

$$\mathbf{a} = \mathbf{X}^\# \mathbf{y} \text{ where } \mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$$

により二つの未知パラメータを求めることができる。

手作業で求めている


$$\mathbf{a} = \mathbf{X}^\# \mathbf{y} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

$$= \begin{bmatrix} x_1 & x_2 & \dots & x_M \\ 1 & 1 & \dots & 1 \end{bmatrix}^{-1} \begin{bmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_M & 1 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix}$$

手作業で求めている


$$a_1 = \frac{M \sum x_i y_i - \sum x_i \sum y_j}{M \sum x_i^2 - (\sum x_i)^2}$$

$$a_2 = \frac{-\sum x_i \sum x_j y_j + \sum x_i^2 \sum y_j}{M \sum x_i^2 - (\sum x_i)^2}$$



これは、直線によるフィッティングの公式に他ならない

何を最小化したか



$$\mathbf{y} = \mathbf{Xa} + \mathbf{e}$$

$$\mathbf{e} = \mathbf{y} - \mathbf{Xa}$$

$$\|\mathbf{e}\|^2 = \mathbf{e}^T \mathbf{e} = \sum_{i=1}^M e_i^2$$

$$y_i = a_1 x_i + a_2 + e_i$$

$$e_i = y_i - a_1 x_i - a_2$$



データと直線の、「y軸に沿った距離」の二乗の和を最小化した。

(参考) 実際の測定回路

「抵抗」を測定するなら




「コンダクタンス (抵抗の逆数)」を測定するなら




「抵抗」を測定して逆数をとればよいのでは？

別にそれでもよい。しかし玄人な理由はある。



アナログ部による線形化の意義
= ADボードによる量子化の影響を低減
「ダイナミックレンジを広げる」とも言う。

フィルムセンサを限界性能まで使いきりたい。



直線近似 $y = a_1x + a_2$ ではフィッティングできない気が、...
(直線領域だけで使う、という方針も正しい)

多項式によるフィッティングを試みる。

$$y = a_1x + a_2 \Rightarrow y = a_1x^2 + a_2x + a_3$$

$$y = a_1x^3 + a_2x^2 + a_3x + a_4$$

もはや直線フィッティングの公式は使えない。

多項式近似

$$y = a_1x^2 + a_2x + a_3 \begin{cases} x: \text{力: 既知入力} \\ y: \text{コンダクタンス, 測定出力} \\ a_1, a_2, a_3: \text{未知パラメータ} \end{cases}$$


何度も測定する

$$y_1 = a_1x_1^2 + a_2x_1 + a_3$$

$$y_2 = a_1x_2^2 + a_2x_2 + a_3$$

$$\vdots$$

$$y_M = a_1x_M^2 + a_2x_M + a_3$$



多項式近似


$$y_1 = a_1x_1^2 + a_2x_1 + a_3$$

$$y_2 = a_1x_2^2 + a_2x_2 + a_3$$

$$\vdots$$

$$y_M = a_1x_M^2 + a_2x_M + a_3$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} x_1^2 & x_1 & 1 \\ x_2^2 & x_2 & 1 \\ \vdots & \vdots & \vdots \\ x_M^2 & x_M & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix}$$



$y = Xa$ の形に出来たので、

$$a = X^\#y \quad \text{where} \quad X^\# = (X^T X)^{-1} X^T$$

により3つの未知パラメータを求めることができる。(計算機のごと)

元に戻って... 何をしたかったか

- $y = a_1x + a_2$
 - $y = a_1x^2 + a_2x + a_3$
 - $y = a_1x^3 + a_2x^2 + a_3x + a_4$
- x: 力: 既知の入力
y: コンダクタンス, 測定した出力
 a_1, \dots, a_4 : 未知パラメータ

モデルの未知パラメータを求めるのがゴールではない。
測定出力yから力xを逆算することがゴール。

- $x = (y - a_2) / a_1$
- $a_1x^2 + a_2x + (a_3 - y) = 0$
$$x = \frac{-a_2 \pm \sqrt{a_2^2 - 4a_1(a_3 - y)}}{2a_1}$$
- $a_1x^3 + a_2x^2 + a_3x + (a_4 - y) = 0$
 $x = \dots$ (3次方程式の解の公式)

デモ: Excelでのフィッティング

X軸は等間隔でなくて良い
X軸は単調増加でなくて良い

N次多項式だと**完璧なフィッティング**ができてしまうのはなぜか？
(行列の形はどうなるか？)

整数次数の多項式でなくて良い


$$y_1 = a_1 x_1^{1/2} + a_2$$

$$y_2 = a_1 x_2^{1/2} + a_2$$

$$\vdots$$

$$y_M = a_1 x_M^{1/2} + a_2$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} x_1^{1/2} & 1 \\ x_2^{1/2} & 1 \\ \vdots & \vdots \\ x_M^{1/2} & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}$$




関数であっても良い. たとえば $\log(x)$ など.

38

レポート課題(1)

次のデータ系列に対して,
Scilabを用いて,

- (1) 直線による近似,
- (2) 2次曲線による近似を適用,
パラメータを求め,
曲線とデータをグラフに描け




X	1.0	2.0	3.0	4.0	5.0
Y	3.0	2.5	3.0	6.0	10.0

なおScilabでは行列Aの擬似逆行列は $\text{pinv}(A)$ で直接求めることができる.
当然自分で $\text{inv}(A^*A)A^*$ とやっても同じ.

39

レポート課題(2) (余裕のある人)

次のデータ系列に対して,
 $y = a_1 * \log(x+1) + a_2$
を仮定してパラメータを求め,
曲線とデータをグラフに描け




	Aさん	Bさん	Cさん	Dさん	Eさん
X(勉強時間)	3	4	2	0	1
Y(試験の点)	80	90	78	10	45

最小二乗法 事例紹介

最小二乗法事例紹介 (時間の許す限り)

- 直交(同期)検波の最小二乗法による理解
- X線CTの画像再構成
- フォトリフレクタのキャリブレーション

最小二乗法事例(1): 直交(同期)検波



問題を定式化

信号 $f(t)$ が,

$$f(t) = A \sin(\omega t + \phi) + \text{noise}(t)$$

と仮定できるとする。周波数 ω はわかっている。

計測データから、振幅 A と、位相ずれ ϕ を求めるには？

直交(同期)検波: 数式(復習)

信号に $\sin(\omega t)$ をかけ、積分する(=内積をとる)
積分時間 T は充分長い。

$$\begin{aligned} S &= \frac{1}{T} \int_0^T (A \sin(\omega t + \phi) + \text{noise}(t)) \sin(\omega t) dt \\ &= \frac{1}{T} \int_0^T A \sin(\omega t + \phi) \sin(\omega t) dt + \frac{1}{T} \int_0^T \text{noise}(t) \sin(\omega t) dt \\ &= \frac{1}{T} \int_0^T A (\sin(\omega t) \cos(\phi) + \cos(\omega t) \sin(\phi)) \sin(\omega t) dt \\ &= A \cos(\phi) \frac{1}{T} \int_0^T \sin^2(\omega t) dt + A \sin(\phi) \frac{1}{T} \int_0^T \sin(\omega t) \cos(\omega t) dt \\ &= A \cos(\phi) \frac{1}{T} \int_0^T \frac{1 - \cos(2\omega t)}{2} dt \\ &= \frac{A}{2} \cos(\phi) \end{aligned}$$

直交(同期)検波: 数式(復習)


信号に $\cos(\omega t)$ をかけ、積分する(=内積をとる)
積分時間 T は充分長い。

$$\begin{aligned} C &= \frac{1}{T} \int_0^T (A \sin(\omega t + \phi) + \text{noise}(t)) \cos(\omega t) dt \\ &= \frac{1}{T} \int_0^T A \sin(\omega t + \phi) \cos(\omega t) dt + \frac{1}{T} \int_0^T \text{noise}(t) \cos(\omega t) dt \\ &= \frac{1}{T} \int_0^T A (\sin(\omega t) \cos(\phi) + \cos(\omega t) \sin(\phi)) \cos(\omega t) dt \\ &= A \cos(\phi) \frac{1}{T} \int_0^T \sin(\omega t) \cos(\omega t) dt + A \sin(\phi) \frac{1}{T} \int_0^T \cos^2(\omega t) dt \\ &= A \sin(\phi) \frac{1}{T} \int_0^T \frac{1 + \cos(2\omega t)}{2} dt \\ &= \frac{A}{2} \sin(\phi) \end{aligned}$$

直交(同期)検波: 数式(復習)

$$S = \frac{A}{2} \cos(\phi)$$

$$C = \frac{A}{2} \sin(\phi)$$



位相差

$$\frac{C}{S} = \tan(\phi)$$

$$\phi = \arctan\left(\frac{C}{S}\right)$$

振幅

$$S^2 + C^2 = \frac{A^2}{4} (\cos^2(\phi) + \sin^2(\phi))$$


$$= \frac{A^2}{4}$$

$$A = 2\sqrt{S^2 + C^2}$$




ノイズに埋もれた信号から位相差と振幅が求まった

最小二乗法で理解する



離散的に取り込まれるデータは次の形をしていると仮定



ただし周波数 ω は既知。

得られたデータ $[y_1, y_2, \dots, y_N]$ から、振幅 A と位相 ϕ を求める。

最小二乗法で理解する

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} = \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$

$$= \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$

$$= \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$

これにより、行列の形、 $\mathbf{y} = \mathbf{X}\mathbf{a}$ に変形することが出来た。

最小二乗法で理解する

$$\begin{bmatrix} A \cos(\phi) \\ A \sin(\phi) \end{bmatrix} = \mathbf{a} = \mathbf{X}^T \mathbf{y} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

$$\begin{bmatrix} \sin(\omega t_1) & \dots & \sin(\omega t_N) \\ \cos(\omega t_1) & \dots & \cos(\omega t_N) \end{bmatrix} \begin{bmatrix} \sin(\omega t_1) & \cos(\omega t_1) \\ \vdots & \vdots \\ \sin(\omega t_N) & \cos(\omega t_N) \end{bmatrix}^{-1} \begin{bmatrix} \sin(\omega t_1) & \dots & \sin(\omega t_N) \\ \cos(\omega t_1) & \dots & \cos(\omega t_N) \end{bmatrix} \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}$$

残る
ほぼ消える (適切なNで完全に0)

最小二乗法で理解する


$$\begin{bmatrix} A \cos(\phi) \\ A \sin(\phi) \end{bmatrix} \propto \begin{bmatrix} \sum_{i=1}^N \sin(\omega t_i) y_i \\ \sum_{i=1}^N \cos(\omega t_i) y_i \end{bmatrix}$$

つまり、元信号y(t)に

- cos(ωt)をかけて積分したものと、
- sin(ωt)をかけて積分したものと

によって、振幅と位相を求めることができる。

これはこれまでの数式的理解と全く同一。



最小二乗法事例(2) : CT





図1. X線CTと画像例


CT:Computational Tomography: 計算による断層撮影
周囲からの計測により、断面/3D形状を再構成

X線CT



- 体内を貫通したX線をライン状カメラで検出=射影
- 装置自体を回転することで、射影データを一周分取得

(参考)X線CT




- $m_1 = \mu_1 + \mu_2$
- $m_2 = \mu_3 + \mu_4$
- $m_3 = \mu_1 + \mu_3$
- $m_4 = \mu_2 + \mu_4$
- $m_5 = \mu_1 + (\mu_2 + \mu_3)/2$
- $m_6 = \mu_4 + (\mu_2 + \mu_3)/2$

$$\begin{bmatrix} m_1 \\ m_2 \\ m_3 \\ m_4 \\ m_5 \\ m_6 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 1/2 & 1/2 & 0 \\ 0 & 1/2 & 1/2 & 1 \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \mu_3 \\ \mu_4 \end{bmatrix}$$


- 人体が4ブロックに分かれていたとする。
- それぞれX線を吸収する能力(線減衰係数)が異なる。 $\mu_1 \sim \mu_4$ とする(未知数)
- 多方向から観測、連立方程式⇒行列⇒擬似逆行列⇒ $\mu_1 \sim \mu_4$ を取得

最小二乗法事例(3) フォトリフレクタを用いた近接距離計の較正




<https://www.youtube.com/watch?v=hpYOIECqnH4>

フォトリフレクタを用いた近接距離計の較正



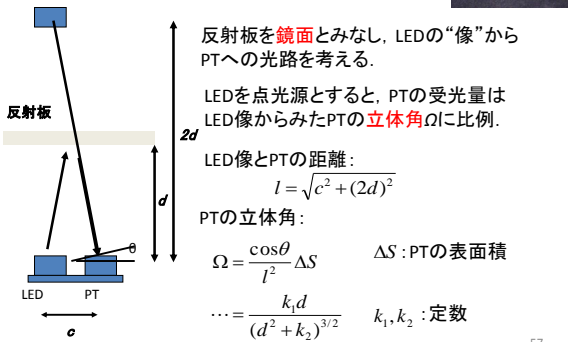
出力電圧は反射光量に比例。
出力電圧から反射板との距離を得たい。

測定




いかにして較正曲線を求め、センサとして使えるようにするか？

モデル化(1)



モデル化(2)



フィッティングの準備

$V = \frac{k_1 d}{(d^2 + k_2)^{3/2}}$ $\left\{ \begin{array}{l} d: \text{入力(距離)} \\ V: \text{出力(電圧)} \\ k_1, k_2: \text{未知パラメータ} \end{array} \right.$

変形(線形化)
 $V^{2/3}(d^2 + k_2) = k_1^{2/3} d^{2/3}$
 $V^{2/3} d^2 = k_1^{2/3} d^{2/3} - V^{2/3} k_2$

$V^{2/3} d^2 = y$
 $k_1^{2/3} = a_1$
 $d^{2/3} = x_1$
 $-V^{2/3} = x_2$
 $k_2 = a_2$ と置けば $y = a_1 x_1 + a_2 x_2$

$\left\{ \begin{array}{l} x_1, x_2, y: \text{既知} \\ a_1, a_2: \text{未知} \end{array} \right.$ 最小二乗法によってパラメータを同定できる。

