

インタラクティブシステム論 第10回

梶本裕之

Twitter ID kajimoto

ハッシュタグ #ninshiki

日程

- 4/13 第1回 イントロダクション
- 4/20 第2回 フーリエ変換
- 4/27 第3回フーリエ変換と線形システム
- 5/4 みどりの日**
- 5/11 出張により休講**
- 5/18 第4回 信号処理の基礎
- 5/25 第5回 信号処理応用1(相関)
- 6/1 第6回 信号処理応用2(画像処理)
- 6/08 インタラクティブシステムの実際(小泉先生)**
- 6/15 第7回 ラプラス変換
- 6/22 第8回 古典制御の基礎
- 6/29 中間確認テスト(出張予定)**
- 7/6 第9回 行列
- 7/13 第10回 行列と最小二乗法
- 7/20 第11回 インタラクティブシステムと機械学習
- 7/27 第12回 ロボティクス
- 8/3 期末テスト(**出張中**)

行列復習

(センシングに現れる行列・逆行列)

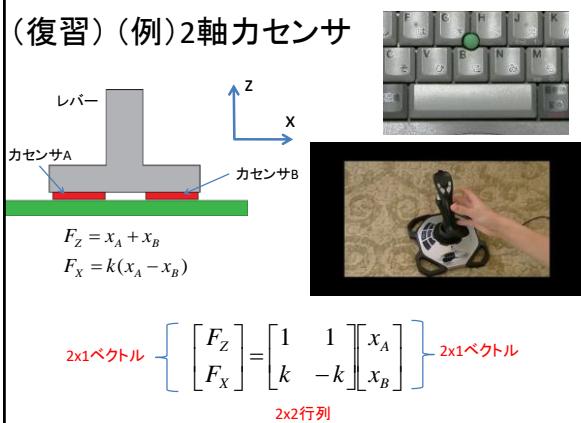
(復習) 行列: データ列を変換するもの

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

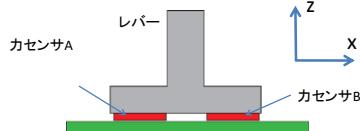
$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

(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



(復習) 力センサのキャリブレーション(較正)

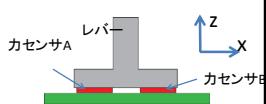


$$\begin{aligned} F_Z &= k_1 x_A + k_2 x_B \\ F_X &= k_3 x_A + k_4 x_B \end{aligned} \quad \begin{bmatrix} F_Z \\ F_X \end{bmatrix} = \begin{bmatrix} k_1 & k_2 \\ k_3 & k_4 \end{bmatrix} \begin{bmatrix} x_A \\ x_B \end{bmatrix}$$

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 $\mathbf{f} = \mathbf{Ax}$ 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。

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{f} = \mathbf{Gf}$$

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

(復習) 逆行列の測定

$$\mathbf{x} = \mathbf{Gf} = \mathbf{A}^{-1}\mathbf{f}$$

\downarrow
 $\mathbf{G} = \mathbf{A}^{-1}$ 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、

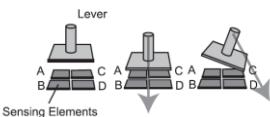
$$\begin{bmatrix} x_A \\ x_B \end{bmatrix} = \begin{bmatrix} g_1 & g_2 \\ g_3 & g_4 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} g_1 \\ g_3 \end{bmatrix}$$

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

行列に単位行列をかけたことに相当



(復習) 逆行列が使えない場合



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

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

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

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

3×4行列

一般には正方行列ではない！！
(例) 6軸力センサには8つ以上のセンサエレメント内蔵

(復習) 逆行列の測定

$$\mathbf{x} = \mathbf{Gf}$$

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

(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) 単位力でなくて良い

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

1回目の入力

1回目の出力

$$\begin{bmatrix} f_{z2} \\ f_{x2} \end{bmatrix} = \begin{bmatrix} m_2 \\ m_2 \end{bmatrix}$$

2回目の入力

2回目の出力

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

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



1. 2回既知の力ベクトルを加えて、各センサの出力を得る

2. 力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

3. 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。

4. \mathbf{G} の逆行列が望んだ較正行列 \mathbf{A}

行列と最小二乗法

本日の疑問

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

3x4行列

・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

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

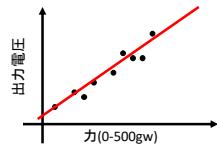
3x4行列

・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。

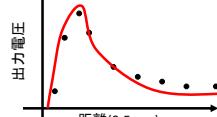
・またこれは最小二乗法という、
工学全体を支える基礎的な考え方である。

色々なセンサ

フィルム状力センサ

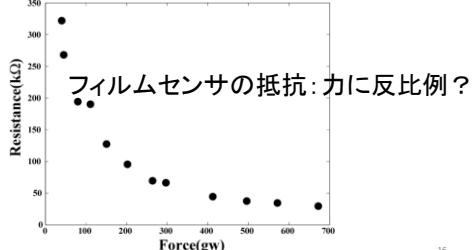
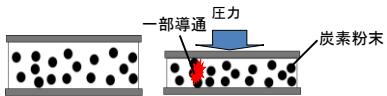


フォトリフレクタを用いた近接距離センサ



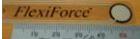
いかにして較正曲線を求め、センサとして使えるようにするか？

フィルムセンサの定式化(1)

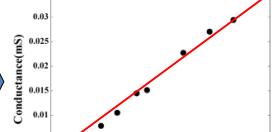
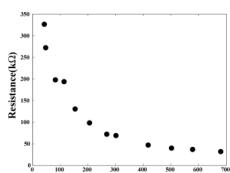


16

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



$$y = ax + b \quad \left\{ \begin{array}{l} x: \\ y: \\ a, b: \end{array} \right.$$

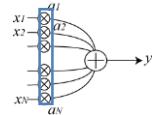
実験でなじみ深い「直線フィッティング」

17

一般化

$y = a_1x_1 + a_2$ 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。

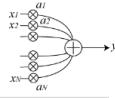
目的: N個の未知パラメータ $[a_1, a_2, \dots, a_N]$ の同定 (identification)

取れる手段: 入力の操作と出力の計測

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

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



入力を変化させ、M回の出力を得る

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

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

⋮

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

結局

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

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

19

二乗誤差を最小化する(最小二乗法)

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

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。

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

20

誤差の「大きさ」

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

$$\mathbf{e} =$$

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

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

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

$$=$$

$$=$$

$$=$$

$$=$$

21

誤差の「大きさ」を最小化する

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

誤差の大きさが最小となる \mathbf{a} を見つける

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

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

$$=$$

$$=$$

$$=$$

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

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

$$\mathbf{a} =$$

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

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

22

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)

23

擬似逆行列は逆行列の拡張である

行列 \mathbf{X} が正則な場合

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

$$=$$

$$=$$

24

(再考) フィルムセンサの場合

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

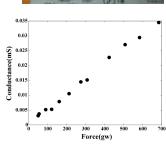
これは

$$y = a_1 x_1 + a_2 x_2 \quad \text{where } x_2 = 1$$

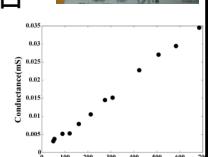
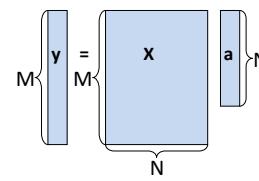
とみなせる。

加える力を変え、M回測定する(2回以上)

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



(再考) フィルムセンサの場合



よって、
 $\mathbf{a} = \mathbf{X}^T \mathbf{y}$ 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出来る。

26

手作業で求めてみる

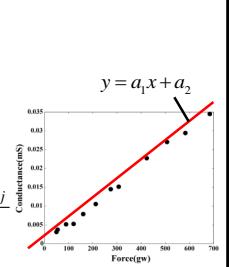
$$\begin{aligned} \mathbf{a} &= \mathbf{X}^T \mathbf{y} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \\ &= \left(\begin{bmatrix} x_1 & x_2 & \cdots & x_M \\ 1 & 1 & \cdots & 1 \end{bmatrix} \begin{bmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_M & 1 \end{bmatrix} \right)^{-1} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} \\ &= \begin{bmatrix} & & & \\ & & & \\ & & & \\ & & & \end{bmatrix} \end{aligned}$$



27

手作業で求めてみる

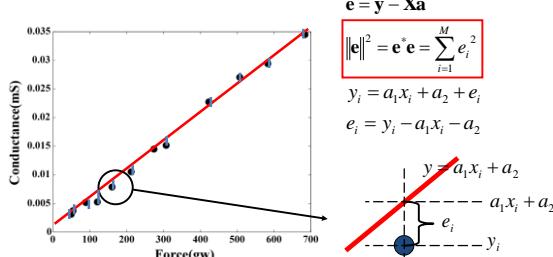
$$\begin{aligned} a_1 &= \frac{M \sum x_i y_i - \sum x_i \sum y_j}{M \sum x_i^2 - (\sum x_i)^2} \\ a_2 &= \frac{-\sum x_i \sum x_j y_j + \sum x_i^2 \sum y_j}{M \sum x_i^2 - (\sum x_i)^2} \end{aligned}$$



これは、直線によるフィッティングの公式に他ならない

28

何を最小化したか



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

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

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

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

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

$$y = a_1 x + a_2$$

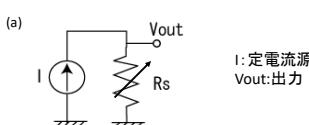
$$e_i = y_i - (a_1 x_i + a_2)$$

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。

29

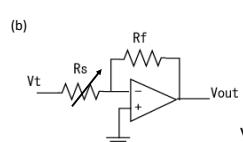
(参考) 実際の測定回路

- 「抵抗」を測定するなら



出力電圧は抵抗に比例

- 「コンダクタンス(抵抗の逆数)」を測定するなら



Vt: 定電圧源
 R_s: フィルムセンサの抵抗
 R_f: 調整用固定抵抗

これは「反転増幅回路」
 $Vout = R_f / (R_s + R_f) * Vt$

Vtが一定なら出力電圧は抵抗に反比例

「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。

(a)出力は抵抗に比例

(b)出力はコンダクタンスに比例

ADボードによる量子化

• 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。

31

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。

32

多項式近似

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

何度も測定する

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

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

$$\vdots$$

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

33

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
 $y_M = a_1x_M^2 + a_2x_M + a_3$

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

$\mathbf{y} = \mathbf{X}\mathbf{a}$ の形に出来たので,
 $\mathbf{a} = \mathbf{X}^\# \mathbf{y}$ where $\mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$

により3つの未知パラメータを求めることが出来る。(計算機のじごと)

34

元に戻って... 何をしたかったか

(1) $y = a_1x + a_2$
(2) $y = a_1x^2 + a_2x + a_3$
(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: 测定した出力
 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。

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

35

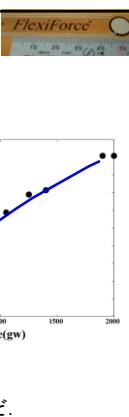
デモ: Excelでのフィッティング

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次多項式だと完全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
 $y_M = a_1 x_M^{1/2} + a_M$

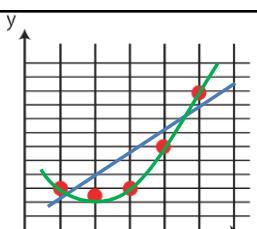
$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} x_1^{1/2} & 1 \\ x_2^{1/2} & 1 \\ \vdots & \vdots \\ x_M^{1/2} & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}$$


関数であっても良い。たとえば $\log(x)$ など。

37

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



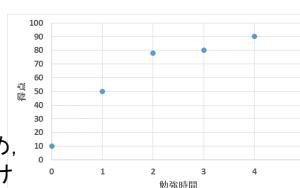
X	1.0	2.0	3.0	4.0	5.0
Y	3.0	2.5	3.0	6.0	10.0

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。

38

レポート課題(2)(余裕のある人)

次のデータ系列に対して、
 $y=a1 * \log(x+1) + a2$
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



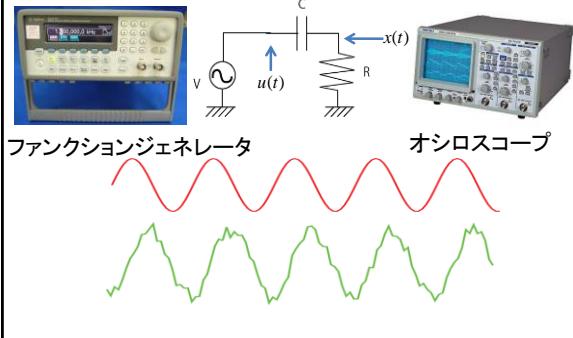
問題を定式化
信号 $f(t)$ が、

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

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 ϕ を求めるには？

応用事例(1)



応用事例(2)



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。

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

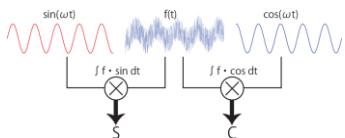
直交(同期)検波:数式(復習)

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。

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

直交(同期)検波:数式(復習)

$$\begin{aligned} S &= \frac{A}{2} \cos(\phi) \\ C &= \frac{A}{2} \sin(\phi) \end{aligned}$$



位相差

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

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

振幅

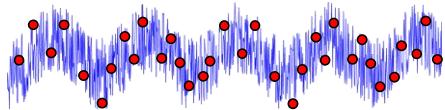
$$S^2 + C^2 = \frac{A^2}{4} (\cos^2(\phi) + \sin^2(\phi))$$

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

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

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

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

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

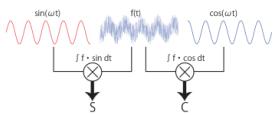
$$\begin{aligned} \begin{bmatrix} A\cos(\phi) \\ A\sin(\phi) \end{bmatrix} &= \mathbf{a} = \mathbf{X}^{\#} \mathbf{y} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \\ &= \left[\begin{bmatrix} \sin(\omega t_1) & \dots & \sin(\omega t_N) \\ \cos(\omega t_1) & \dots & \cos(\omega t_N) \\ \vdots & & \vdots \\ \sin(\omega t_N) & \dots & \cos(\omega t_N) \end{bmatrix} \begin{bmatrix} \sin(\omega t_1) & \cos(\omega t_1) \\ \vdots & \vdots \\ \sin(\omega t_N) & \cos(\omega t_N) \end{bmatrix} \right]^{-1} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \\ &= \begin{bmatrix} \text{ } \\ \text{ } \\ \text{ } \\ \text{ } \end{bmatrix} \\ &\quad \text{--- 残る} \\ &\quad \text{--- ほぼ消える} \\ &\quad \text{(適切なNで完全に0)} \end{aligned}$$

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
 • $\cos(\omega t)$ をかけて積分したものと、
 • $\sin(\omega t)$ をかけて積分したもの
 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

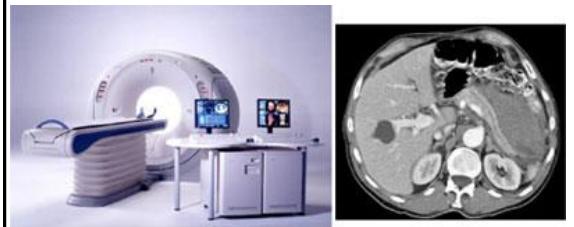
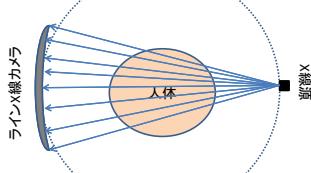


図1. X線CTと画像例

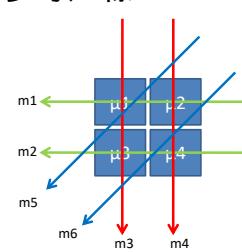
CT:Computational Tomography: 計算による断層撮影
 周囲からの計測により、断面／3D形状を再構成

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

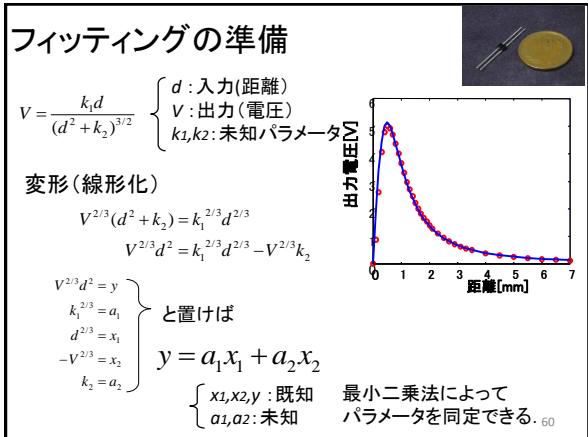
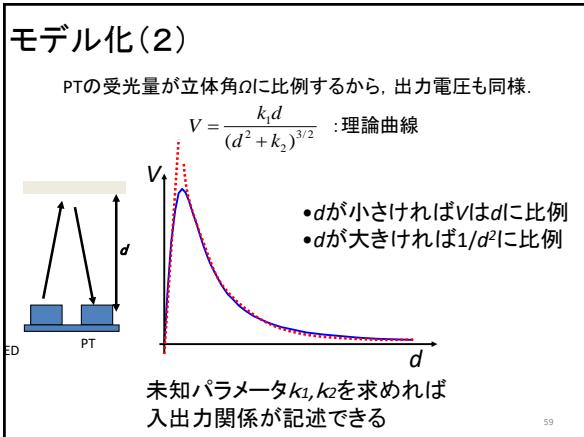
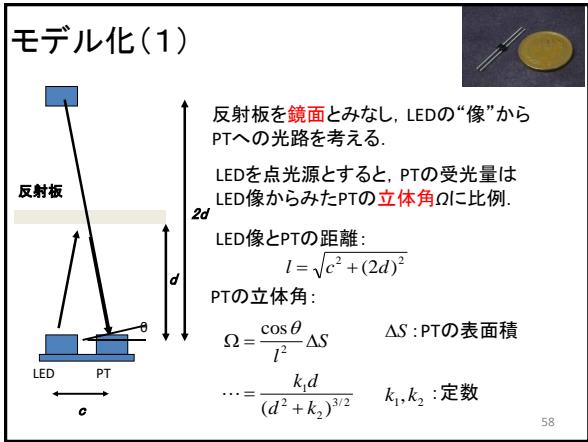
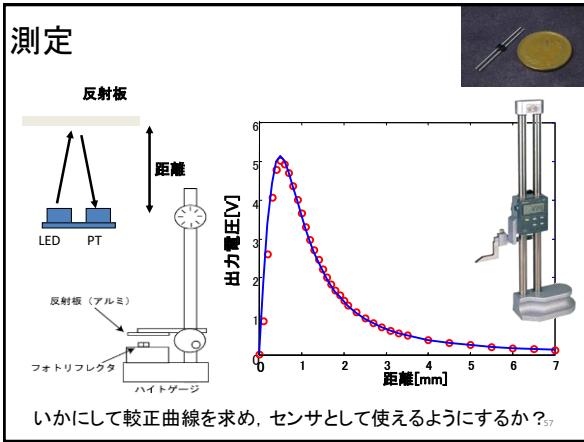
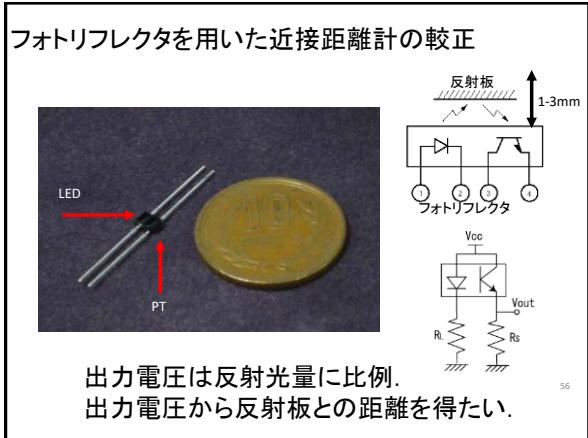
(参考)X線CT

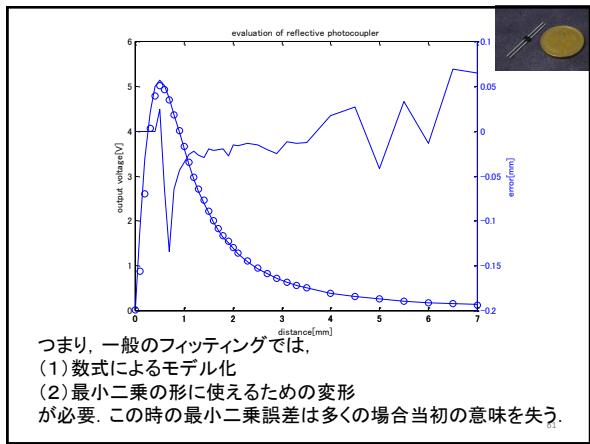


- $m_1 = \mu_1 + \mu_2$
- $m_2 = \mu_3 + \mu_4$
- $m_3 = \mu_1 + \mu_3$
- $m_4 = \mu_2 + \mu_4$
- $m_5 = \mu_1 + (\mu_2 + \mu_3)/2$
- $m_6 = \mu_4 + (\mu_2 + \mu_3)/2$

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

- 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 \Rightarrow 行列 \Rightarrow 擬似逆行列 $\Rightarrow \mu_1 \sim 4$ を取得





つまり、一般的なフィッティングでは、
(1)数式によるモデル化
(2)最小二乗の形に使えるための変形
が必要。この時の最小二乗誤差は多くの場合当初の意味を失う。