

クレジット:

Mathematics and Informatics Center 文科系のための線形代数・解析Ⅱ
2020 藤堂 眞治・松尾 泰・藤原 毅夫

ライセンス:

利用者は、本講義資料を、教育的な目的に限ってページ単位で利用することができます。特に記載のない限り、本講義資料はページ単位でクリエイティブ・コモンズ 表示-非営利-改変禁止 ライセンスの下に提供されています。

<http://creativecommons.org/licenses/by-nc-nd/4.0/>

本講義資料内には、東京大学が第三者より許諾を得て利用している画像等や、各種ライセンスによって提供されている画像等が含まれています。個々の画像等を本講義資料から切り離して利用することはできません。個々の画像等の利用については、それぞれの権利者の定めるところに従ってください。



最小二乗近似 2

最小二乗法の概要

実変数 x_k に対してデータの値が y_k ($k = 1, 1, 2, \dots, N$) であるとする.

この事象が, 関数 $y = f(x)$ で表現できるとする (近似関数).

データ (x_k, y_k) とその理論値 (近似値) $y = f(x)$ が与えられるとき,

標本数 (サンプル数) を N として, その誤差の分散は

$$J = \sum_{j=1}^N |f(x_j) - y_j|^2$$

と定義される.

J/N を二乗平均誤差という.

最小二乗法 (最小誤差近似) は, 二乗平均誤差 (データの分散) を最小にする近似である.

近似関数を1次式とする場合 (連立方程式を解く)

近似関数として1次式 $f(x) = ax + b$ を仮定すれば, $J = \sum_{j=1}^N |(ax_j + b) - y_j|^2$.

J を a, b でそれぞれ偏微分して0と置き $\left(\frac{\partial J}{\partial a} = 0, \frac{\partial J}{\partial b} = 0\right)$

$$\begin{pmatrix} {}^t\mathbf{xx} & {}^t\mathbf{xu} \\ {}^t\mathbf{xu} & {}^t\mathbf{uu} \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} {}^t\mathbf{xy} \\ {}^t\mathbf{uy} \end{pmatrix}$$

$$\mathbf{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_N \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}, \quad \mathbf{u} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

を得る. ただし とする.

これから a, b が定まる.

具体的に書けば

$${}^t\mathbf{ux} = {}^t\mathbf{xu} = \sum x_i \equiv N\bar{x}, \quad {}^t\mathbf{uy} = {}^t\mathbf{yu} = \sum y_i \equiv N\bar{y}$$

$${}^t\mathbf{xx} = \sum x_i^2 \equiv N(V(x) + \bar{x}^2) = N(\sigma_{xx} + \bar{x}^2)$$

$${}^t\mathbf{xy} = \sum x_i y_i \equiv N(\sigma_{xy} + \bar{x} \bar{y}) = N(\sigma_{yx} + \bar{x} \bar{y})$$

$${}^t\mathbf{uu} = N.$$

ただし $\sigma_{xx} = \frac{1}{N} \sum (x_i - \bar{x})^2$, $\sigma_{xy} = \frac{1}{N} \sum (x_i - \bar{x})(y_i - \bar{y})$ と定義する.

ここで ${}^t\mathbf{xx} \cdot {}^t\mathbf{uu} - ({}^t\mathbf{xu})^2 = N^2 \sigma_{xx}$ であるから,

$$\begin{pmatrix} a \\ b \end{pmatrix} = \frac{1}{N^2\sigma_{xx}} \begin{pmatrix} N & -N\bar{x} \\ -N\bar{x} & N(\sigma_{xx} + \bar{x}^2) \end{pmatrix} \begin{pmatrix} N(\sigma_{yx} + \bar{x}\bar{y}) \\ N\bar{y} \end{pmatrix} = \begin{pmatrix} \sigma_{yx}/\sigma_{xx} \\ \bar{y} - a\bar{x} \end{pmatrix}$$

を得る.

「 $(x_i, y_i) \quad (i = 1, 2, \dots, N)$ 全てを通る直線を決めたい」

$$x_1 a + b = y_1$$

⋮

$$x_N a + b = y_N$$

N 個の条件で2つの定数 a, b を決めるのであるから、一般に解は無い.

しかしひとまずこの式を行列形式で書けば

$$M\mathbf{a} = \mathbf{y}$$

$$M = (\mathbf{x} \ \mathbf{u}) = \begin{pmatrix} x_1 & 1 \\ \vdots & \vdots \\ x_N & 1 \end{pmatrix}, \quad \mathbf{a} = \begin{pmatrix} a \\ b \end{pmatrix}$$

となる. ただし

と定義する.

行列形式の立場からいっても, M は正方行列ではないので, この式には一般に解は無い.

この式に左から tM をかければ, それぞれ

$${}^tMM = {}^t(\mathbf{x} \ \mathbf{u})(\mathbf{x} \ \mathbf{u}) = \begin{pmatrix} {}^t\mathbf{x} \\ {}^t\mathbf{u} \end{pmatrix} (\mathbf{x} \ \mathbf{u}) = \begin{pmatrix} {}^t\mathbf{xx} & {}^t\mathbf{xu} \\ {}^t\mathbf{ux} & {}^t\mathbf{uu} \end{pmatrix}$$

$${}^tM\mathbf{y} = {}^t(\mathbf{x} \ \mathbf{u})\mathbf{y} = \begin{pmatrix} {}^t\mathbf{x} \\ {}^t\mathbf{u} \end{pmatrix} \mathbf{y} = \begin{pmatrix} {}^t\mathbf{xy} \\ {}^t\mathbf{uy} \end{pmatrix}$$

を得る. これで前式 $\begin{pmatrix} {}^t\mathbf{xx} & {}^t\mathbf{xu} \\ {}^t\mathbf{xu} & {}^t\mathbf{uu} \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} {}^t\mathbf{xy} \\ {}^t\mathbf{uy} \end{pmatrix}$ は

$${}^tMM\mathbf{a} = {}^tM\mathbf{y}$$

であることが分かる. tMM は正方行列であり, この方程式は必ず解をもつ.

簡単な例題

$x-y$ 平面の3点 $(1, 1.5)$, $(2, 2.5)$, $(3, 3)$ を結ぶ最良の直線の方程式を求めよう.


```
x=[1;2;3];
y=[1.5;2.5;3.0];
u=[1;1;1];
M=[x u];
```

```
a=(M'*M)\(M'*y)
```

```
a = 2x1  
    0.7500  
    0.8333
```

解に対して3点と，得られた直線を図示せよ.

```
f = @(x,y) y-a(1,1)*x-a(2,1);  
fimplicit(f,[0 4 0 4])  
hold on  
px=[1 2 3];  
py=[1.5 2.5 3];  
plot(px,py,'o')  
daspect([1 1 1])  
hold off
```



一般の場合

与えられたデータ点 (x_1, x_2, \dots, x_n) におけるデータ y_i ($i = 1, 2, \dots, n$) が与えられている.

このときデータを多項式 $y = a_0 + a_1x + a_2x^2 + \dots + a_mx^m$ と表すことを考える.

評価関数

$$L = \sum_{i=1}^n \{y_i - (a_0 + a_1x_i + \dots + a_mx_i^m)\}^2$$

を最小にするように a_0, a_1, \dots を決めよう.

$$\mathbf{x}^{(k)} = \begin{pmatrix} (x_1)^k \\ (x_2)^k \\ \vdots \\ (x_n)^k \end{pmatrix}, \quad k = 0, 1, \dots, m, \quad M = [\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}]$$

$$\mathbf{a} = \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_m \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

とおけば,

$$M \cdot \mathbf{a} = \mathbf{x}^{(0)} a_0 + \mathbf{x}^{(1)} a_1 + \mathbf{x}^{(2)} a_2 + \dots + \mathbf{x}^{(m)} a_m$$

であることに注意すれば,

$$L = {}^t(\mathbf{y} - M \cdot \mathbf{a}) \cdot (\mathbf{y} - M \cdot \mathbf{a})$$

を得る. これから \mathbf{a} の各成分で微分して

$${}^t M M \mathbf{a} = {}^t M \mathbf{y}$$

を得る.

$${}^t M M = \begin{pmatrix} \mathbf{x}^{(0)} \\ \mathbf{x}^{(1)} \\ \vdots \\ \mathbf{x}^{(m)} \end{pmatrix} (\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}) = \begin{pmatrix} {}^t \mathbf{x}^{(0)} \mathbf{x}^{(0)} & {}^t \mathbf{x}^{(0)} \mathbf{x}^{(1)} & \dots & {}^t \mathbf{x}^{(0)} \mathbf{x}^{(m)} \\ {}^t \mathbf{x}^{(1)} \mathbf{x}^{(0)} & {}^t \mathbf{x}^{(1)} \mathbf{x}^{(1)} & \dots & {}^t \mathbf{x}^{(1)} \mathbf{x}^{(m)} \\ \vdots & \vdots & \ddots & \vdots \\ {}^t \mathbf{x}^{(m)} \mathbf{x}^{(0)} & {}^t \mathbf{x}^{(m)} \mathbf{x}^{(1)} & \dots & {}^t \mathbf{x}^{(m)} \mathbf{x}^{(m)} \end{pmatrix}$$

ただし

$${}^t M \mathbf{y} = \begin{pmatrix} \mathbf{x}^{(0)} \\ \mathbf{x}^{(1)} \\ \vdots \\ \mathbf{x}^{(m)} \end{pmatrix} (y_1 \ y_2 \ \dots \ y_n) = (\mathbf{x}^{(0)} y_1 \ \mathbf{x}^{(0)} y_2 \ \dots \ \mathbf{x}^{(0)} y_n)$$

に注意.

これにより

$$\mathbf{a} = ({}^t M M)^{-1} {}^t M \mathbf{y}$$

が得られる. ${}^t M M$ をグラム行列という.

上のような方法を, 勿論直接用いても良いが, MATLABでは `polyfit` というルーチンが

用意されている:

```
p = polyfit(x,y,n)
```

は、 y のデータに対して (最小二乗的に) 最適な近似となる n 次の多項式 $p(x)$ の係数を返す。

p の係数は降べきの順で、 p の長さは $n+1$ になる。


$$p(x) = p_1x^n + p_2x^{n-1} + \dots + p_nx + p_{n+1}$$

上で与えた a_k のノーテーションと異なるので注意を要する。

例 1

等間隔10点で与えられているsin関数を5次および7次多項式で近似する：


```
x = linspace(0,4*pi,10);  
y = sin(x);  
p = polyfit(x,y,5);  
q = polyfit(x,y,7);  
x1 = linspace(-0.5*pi,4.3*pi);  
yp = polyval(p,x1);  
yq = polyval(q,x1);  
y1 = sin(x1);  
%figure  
plot(x,y,'o');hold on  
plot(x1,yp,'--*');hold on  
plot(x1,yq,'-.*');hold on  
plot(x1,y1);hold off
```



例 2

同じく不等間隔10点で与えられたsin関数を7次多項式で近似する：

```
x=[0 0.5 1.2 2.2 4 6.5 10 11 12 12.5];  
y = sin(x);  
p = polyfit(x,y,7);  
x1 = linspace(-0.2*pi,4.2*pi);  
yp = polyval(p,x1);  
y1 = sin(x1);  
%figure  
plot(x,y,'o');hold on  
plot(x1,yp,'--*');hold on  
plot(x1,y1);hold off
```



課題

- (1) 「簡単な例題」の問題で2次式のフィッティングを行え。
- (2) 上の例で、多項式の点の数に比べてずっと小さな次数に変えて、同じことを実行してみよ。また点の数に比べて大きな次数に変えたらどうか。
- (3) 上の例で、例示された領域の外ではどうなっているか。xの広い範囲でプロットしてみよ。
- (4) 様々な初等関数（多項式、三角関数、指数関数）について同様なことをやってみよ。
- (5) polyfit を使わず、 MM を計算して解を求めるプログラムを書いてみよ。