

逐次最小二乘法

Recursive Least Squares

大阪府立大学 工学研究科
清水 悠生

(復習)最小二乗法で扱う誤差関数


- ✓ 誤差関数を誤差の2乗の和とし, 誤差関数が最小となるような係数 a , b を計算する方法が最小二乗法

最小二乗法で扱う誤差関数 $E(a,b)$

$$E(a,b) = \sum_{i=1}^n \frac{1}{2} \left(y^{(i)} - (ax^{(i)} + b) \right)^2$$


a と b の
2変数関数

誤差の2乗



時系列データの場合は？

- ✓ 例えば, ある時刻 t において
モータに電圧 $v(t)$ をかけたとき電流 $i(t)$ が流れたとする
- ✓ ある一定時間(e.g. $t=0, \dots, n$)の電圧と電流の関係から
モータの抵抗値やインダクタンスなどを同定したい!
⇒**逐次最小二乗法**が有効!




時系列データの場合の問題設定

- ✓ 時刻 $t=i$ ($i=0,1,\dots$)における入出力データ $(x^{(i)}, y^{(i)})$ が得られた場合を仮定する
- ✓ x と y の関係は比例係数 θ の比例関係であると仮定 (ただし出力データ y にはノイズがのっている)
- ✓ この θ を最小二乗法で同定する！

時刻 $t=i$ における回帰誤差 $e^{(i)}$

$$e^{(i)} = y^{(i)} - \theta x^{(i)}$$



時系列データの場合の2つ問題点

✓ 時系列データを扱う際には下記の2つの問題に注意


① 求めたい回帰係数（パラメータ）の時刻による変動

② メモリ（記憶領域）の限界

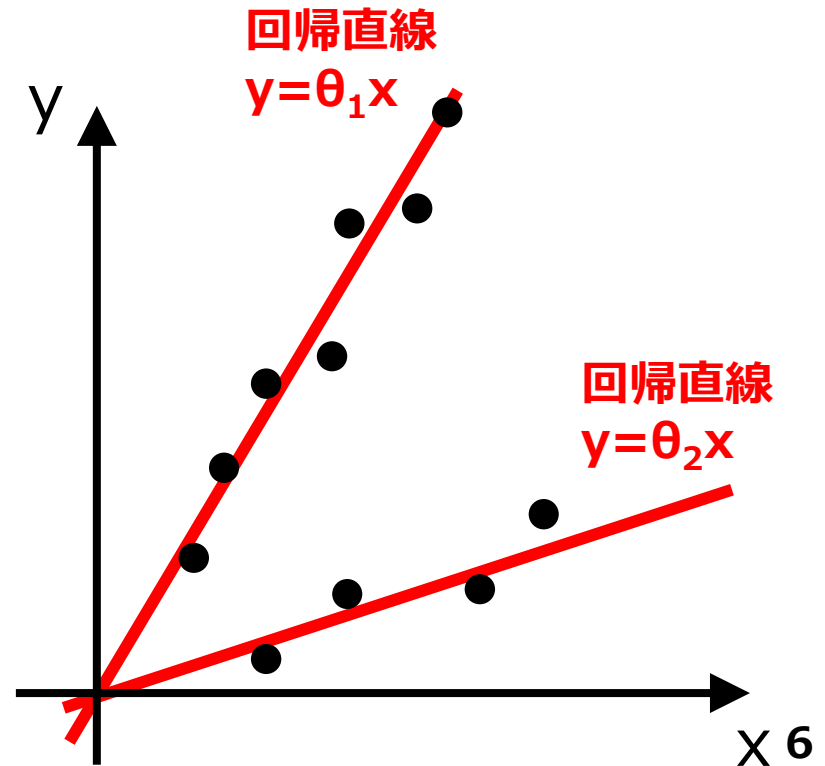
問題①：パラメータの変動

- ✓ 求めたい回帰係数（パラメータ）は変動する場合がある
ex) 抵抗値の温度変化, インダクタンスの磁気飽和etc
- ✓ パラメータの時間変動にすばやく追従する必要がある！

回帰誤差が大きい…？



係数が変化したと考えると自然！



過去のデータをどんどん忘れるように工夫！

- ✓ 忘却係数 λ を誤差関数に導入し、過去のデータの影響を小さくしていく⇒**逐次最小二乗法**

時刻 $t=i$ における回帰誤差 $e^{(i)}$

$$e^{(i)} = y^{(i)} - \theta x^{(i)}$$

通常の最小二乗法で扱う時刻 $t=n$ での誤差関数 $E[n]$

$$E[n] = \sum_{i=0}^n \frac{1}{2} (e^{(i)})^2 = \frac{1}{2} (e^{(n)})^2 + \frac{1}{2} (e^{(n-1)})^2 + \dots + \frac{1}{2} (e^{(0)})^2$$

逐次最小二乗法で扱う時刻 $t=n$ での誤差関数 $E[n]$

$$E[n] = \sum_{i=0}^n \frac{1}{2} \lambda^{n-i} (e^{(i)})^2 = \frac{1}{2} \lambda^0 (e^{(n)})^2 + \frac{1}{2} \lambda^1 (e^{(n-1)})^2 + \dots + \frac{1}{2} \lambda^n (e^{(0)})^2$$

λ : 忘却係数 ($0 < \lambda < 1$)

過去のデータになればなるほど
忘却係数の次数が大きくなる
(値が小さくなる)

問題②：メモリの限界

- ✓ 時系列データはシステムが動作している間はずっと増え続けるため、その全てを記憶することは不可能

時刻 $t=n$ での誤差関数 $E[n]$

$$E[n] = \sum_{i=0}^n \frac{1}{2} \lambda^{n-i} (e^{(i)})^2$$

**nが大きくなればなるほど
記憶しておくデータ数が膨大に！**

- ✓ 直近のデータのみを使用してパラメータを計算できることが理想

まとめると…

- ✓ 誤差関数 $E[n]$ から求まるパラメータ $\theta[n]$ に関して漸化式を作ればよい！

$$E[n] = \sum_{i=0}^n \frac{1}{2} \lambda^{n-i} (e^{(i)})^2 \text{ の最小化}$$

⇒ $\theta[n]$ が求められるが、

メモリの限界があるためこれは計算できない

⇒ $\theta[n]$ と $\theta[n-1]$ の関係を数式化できれば（漸化式を作れば）
直近のデータの計算だけでパラメータが求まる！

- ✓ この漸化式を導出していきます

まずは普通に誤差関数を解いてみる

✓ 誤差関数の最小化により

時刻 $t=n$ におけるパラメータの最適解 $\theta[n]$ を求める

$$\min_{\theta} E[n] = \sum_{i=0}^n \frac{1}{2} \lambda^{n-i} (e^{(i)})^2 = \sum_{i=0}^n \frac{1}{2} \lambda^{n-i} (y^{(i)} - \theta x^{(i)})^2$$

$$\Rightarrow \frac{\partial}{\partial \theta} E[n] = \sum_{i=0}^n (y^{(i)} - \theta[n] x^{(i)}) \lambda^{n-i} (-x^{(i)})$$

微分して0

$$= (Y[n] - \theta[n] X[n])^T \Lambda[n] (-X[n])$$

行列で表現

$$= -Y[n]^T \Lambda[n] X[n] + \theta[n] X[n]^T \Lambda[n] X[n] = 0$$

展開

$$\Leftrightarrow \theta[n] = (X[n]^T \Lambda[n] X[n])^{-1} Y[n]^T \Lambda[n] X[n]$$

逆行列を左から
かける(正則と仮定)


ただし, 時刻 $t=n$ における各ベクトル・行列は次式のように定義

$$Y[n] = \begin{bmatrix} y^{(0)} \\ \vdots \\ y^{(n)} \end{bmatrix}, X[n] = \begin{bmatrix} x^{(0)} \\ \vdots \\ x^{(n)} \end{bmatrix}, \Lambda[n] = \begin{bmatrix} \lambda^0 & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & \lambda^n \end{bmatrix} (n \times n \text{ 行列})$$

目標の再確認

- ✓ 時刻 $t=n$ におけるパラメータの最適解 $\theta[n]$ と時刻 $t=n-1$ におけるパラメータの最適解 $\theta[n-1]$ との関係を表す漸化式を導出することが最終目標

$$\theta[n] = (X[n]^T \Lambda[n] X[n])^{-1} Y[n]^T \Lambda[n] X[n]$$



両者の関係を数式化する！

$$\theta[n-1] = (X[n-1]^T \Lambda[n-1] X[n-1])^{-1} Y[n-1]^T \Lambda[n-1] X[n-1]$$

漸化式の導出(1/3)

✓ $\theta[n]$ を変形する

$$\theta[n] = \frac{(X[n]^T \Lambda[n] X[n])^{-1} Y[n]^T \Lambda[n] X[n]}{= p[n] \text{ (スカラ) とおく}}$$

$$p[n] = (X[n]^T \Lambda[n] X[n])^{-1} \\ = \left(\sum_{i=0}^n \lambda^{n-i} (x^{(i)})^2 \right)^{-1}$$

要素の和に変形

$$= \left(\sum_{i=0}^{n-1} \lambda^{n-i} (x^{(i)})^2 + \lambda^0 (x^{(n)})^2 \right)^{-1}$$

t=nの要素を
外に出す

$$= \left(\lambda \sum_{i=0}^{n-1} \lambda^{(n-1)-i} (x^{(i)})^2 + (x^{(n)})^2 \right)^{-1}$$

第1項目を
n-1で表現

$$= \left(\lambda (p[n-1])^{-1} + (x^{(n)})^2 \right)^{-1} = \frac{p[n-1]}{\lambda + p[n-1] (x^{(n)})^2}$$

漸化式の導出(3/3)

✓ ついに漸化式が求まる！

$$\begin{aligned}\theta[n] &= (\mathbf{X}[n]^T \Lambda[n] \mathbf{X}[n])^{-1} \mathbf{Y}[n]^T \Lambda[n] \mathbf{X}[n] \\ &= \underline{p[n]} \underline{q[n]} \\ &= \frac{p[n-1]}{\lambda + p[n-1](x^{(n)})^2} \underline{(\lambda q[n-1] + y^{(n)} x^{(n)})}\end{aligned}$$

前ページの
結果を代入

$$= \frac{\lambda p[n-1] q[n-1] + p[n-1] y^{(n)} x^{(n)}}{\lambda + p[n-1](x^{(n)})^2}$$

展開

$$= \frac{\lambda \theta[n-1] + p[n-1] y^{(n)} x^{(n)}}{\lambda + p[n-1](x^{(n)})^2}$$

$\theta[n-1]$ を作る

$$= \theta[n-1] + \frac{p[n-1] x^{(n)}}{\lambda + p[n-1](x^{(n)})^2} (y^{(n)} - \theta[n-1] x^{(n)})$$

一つ前のパラメータ $\theta[n-1]$ と $t=n$ のデータだけで
 $\theta[n]$ が導出可能に！


ただし、 $p[n-1]$ も漸化式から計算しておく必要あり

導出した漸化式の解釈

- ✓ 完成した漸化式はフィードバック制御のように解釈可能

$$\theta[n] = \underbrace{\theta[n-1]}_{\substack{\text{1つ前の} \\ \text{パラメータ}}} + \frac{p[n-1]x^{(n)}}{\lambda + p[n-1](x^{(n)})^2} \underbrace{(y^{(n)} - \theta[n-1]x^{(n)})}_{\substack{\text{1つ前のパラメータ} \\ \text{による予測誤差}}}$$

λ で決まるゲイン
(誤差をどれだけ反映するか)




単回帰から重回帰への拡張

- ✓ 複数パラメータ θ_1, θ_2 を同時に同定する場合を考える
- ✓ 回帰誤差は下記の通り

時刻 $t=i$ における回帰誤差 $e^{(i)}$

$$e^{(i)} = y^{(i)} - \theta_1 x_1^{(i)} - \theta_2 x_2^{(i)}$$



まずは誤差関数の最小化

- ✓ パラメータ最適解 $\theta_1[n], \theta_2[n]$ を求めると
単回帰の時と同じ解が得られる

$$\min_{\boldsymbol{\theta}} E[n] = \frac{1}{2} (\mathbf{Y}[n] - \mathbf{X}[n]\boldsymbol{\theta}[n])^T \boldsymbol{\Lambda}[n] (\mathbf{Y}[n] - \mathbf{X}[n]\boldsymbol{\theta}[n])$$

$$\Rightarrow \frac{\partial}{\partial \boldsymbol{\theta}} E[n] = (-\mathbf{X}[n])^T \boldsymbol{\Lambda}[n] (\mathbf{Y}[n] - \mathbf{X}[n]\boldsymbol{\theta}[n])$$

微分して0

$$= -\mathbf{X}[n]^T \boldsymbol{\Lambda}[n] \mathbf{Y}[n] + \mathbf{X}[n]^T \boldsymbol{\Lambda}[n] \mathbf{X}[n] \boldsymbol{\theta}[n] = \mathbf{0}$$

展開

$$\Leftrightarrow \boldsymbol{\theta}[n] = (\mathbf{X}[n]^T \boldsymbol{\Lambda}[n] \mathbf{X}[n])^{-1} \mathbf{X}[n]^T \boldsymbol{\Lambda}[n] \mathbf{Y}[n]$$

逆行列を左から
かける(正則と仮定)

ただし, 時刻 $t=n$ における各行列は次式のように定義

$$\mathbf{Y}[n] = \begin{bmatrix} y^{(0)} \\ \vdots \\ y^{(n)} \end{bmatrix} (\mathbf{n} \times \mathbf{1}), \mathbf{X}[n] = \begin{bmatrix} x_1^{(0)} & x_2^{(0)} \\ \vdots & \vdots \\ x_1^{(n)} & x_2^{(n)} \end{bmatrix} (\mathbf{n} \times \mathbf{2})$$

$$\boldsymbol{\theta}[n] = \begin{bmatrix} \theta_1[n] \\ \theta_2[n] \end{bmatrix} (\mathbf{2} \times \mathbf{1}), \boldsymbol{\Lambda}[n] = \begin{bmatrix} \lambda^0 & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & \lambda^n \end{bmatrix} (\mathbf{n} \times \mathbf{n})$$

漸化式の導出(1/4)

✓ $\Theta[n]$ を変形する

$$\begin{aligned}\Theta[n] &= \frac{(X[n]^T \Lambda[n] X[n])^{-1} X[n]^T \Lambda[n] Y[n]}{=} P[n](2 \times 2) \text{とおく}\end{aligned}$$

$$\begin{aligned}P[n] &= (X[n]^T \Lambda[n] X[n])^{-1} \\ &= \left(\sum_{i=0}^n \lambda^{n-i} \mathbf{x}^{(i)T} \mathbf{x}^{(i)} \right)^{-1} \quad (\mathbf{x}^{(i)} = [x_1^{(i)} \quad x_2^{(i)}]) \\ &= \left(\lambda \sum_{i=0}^{n-1} \lambda^{(n-1)-i} \mathbf{x}^{(i)T} \mathbf{x}^{(i)} + \lambda^0 \mathbf{x}^{(n)T} \mathbf{x}^{(n)} \right)^{-1} \\ &= \left(\lambda (P[n-1])^{-1} + \mathbf{x}^{(n)T} \mathbf{x}^{(n)} \right)^{-1}\end{aligned}$$

要素の和に変形

t=nの要素を
外に出す

第1項目を
n-1で表現

漸化式の導出(2/4)

✓ $P[n]$ のつづき

下記の公式を用いる（ひたすら要素計算すると証明できます）

$$(A^{-1} + BB^T)^{-1} = A - \frac{ABB^T A}{1 + B^T A B}$$

A : $M \times M$ の正定値行列

B : $M \times 1$ 行列

公式に代入して

$$\begin{aligned} P[n] &= \left(\lambda(P[n-1])^{-1} + \mathbf{x}^{(n)T} \mathbf{x}^{(n)} \right)^{-1} \\ &= \frac{1}{\lambda} P[n-1] - \frac{\frac{1}{\lambda} P[n-1] \mathbf{x}^{(n)T} \mathbf{x}^{(n)} \frac{1}{\lambda} P[n-1]}{1 + \mathbf{x}^{(n)} \frac{1}{\lambda} P[n-1] \mathbf{x}^{(n)T}} \\ &= \frac{1}{\lambda} \left(P[n-1] - \frac{P[n-1] \mathbf{x}^{(n)T} \mathbf{x}^{(n)} P[n-1]}{\lambda + \mathbf{x}^{(n)} P[n-1] \mathbf{x}^{(n)T}} \right) \\ &= \frac{P[n-1]}{\lambda + \mathbf{x}^{(n)} P[n-1] \mathbf{x}^{(n)T}} \end{aligned}$$

公式を適用

$1/\lambda$ でくくる

一つにまとめる

最後の変形では下記の関係を用いた（これもひたすら計算です）

$$P[n-1] \mathbf{x}^{(n)} P[n-1] \mathbf{x}^{(n)T} = P[n-1] \mathbf{x}^{(n)T} \mathbf{x}^{(n)} P[n-1]$$

漸化式の導出(3/4)

✓ つづき

$$\theta[n] = (X[n]^T \Lambda[n] X[n])^{-1} X[n]^T \Lambda[n] Y[n]$$

$= Q[n](2 \times 1 \text{ 行列})$ とおく

$$Q[n] = X[n]^T \Lambda[n] Y[n]$$

$$= \sum_{i=0}^n \lambda^{n-i} \mathbf{x}^{(i)T} \mathbf{y}^{(i)}$$

$$= \lambda \sum_{i=0}^{n-1} \lambda^{(n-1)-i} \mathbf{x}^{(i)T} \mathbf{y}^{(i)} + \lambda^0 \mathbf{x}^{(n)T} \mathbf{y}^{(n)}$$

$$= \lambda Q[n-1] + \mathbf{x}^{(n)T} \mathbf{y}^{(n)}$$

要素の和に変形

t=nの要素を
外に出す

第1項目をn-1で表現

漸化式の導出(4/4)

✓ 単回帰と同じ形式の漸化式が導出できる

$$\begin{aligned}\Theta[n] &= (\mathbf{X}[n]^T \Lambda[n] \mathbf{X}[n])^{-1} \mathbf{X}[n]^T \Lambda[n] \mathbf{Y}[n] \\ &= \underline{\mathbf{P}[n]} \underline{\mathbf{Q}[n]}\end{aligned}$$

$$= \frac{\mathbf{P}[n-1]}{\lambda + \mathbf{x}^{(n)} \mathbf{P}[n-1] \mathbf{x}^{(n)T}} \left(\underline{\lambda \mathbf{Q}[n-1] + \mathbf{x}^{(n)T} y^{(n)}} \right)$$

前ページの
結果を代入

$$= \frac{\lambda \mathbf{P}[n-1] \mathbf{Q}[n-1] + \mathbf{P}[n-1] \mathbf{x}^{(n)T} y^{(n)}}{\lambda + \mathbf{x}^{(n)} \mathbf{P}[n-1] \mathbf{x}^{(n)T}}$$

展開

$$= \frac{\lambda \Theta[n-1] + \mathbf{P}[n-1] \mathbf{x}^{(n)T} y^{(n)}}{\lambda + \mathbf{x}^{(n)} \mathbf{P}[n-1] \mathbf{x}^{(n)T}}$$

$\Theta[n-1]$ を作る

$$= \underline{\Theta[n-1]} + \frac{\mathbf{P}[n-1] \mathbf{x}^{(n)T}}{\lambda + \mathbf{x}^{(n)} \mathbf{P}[n-1] \mathbf{x}^{(n)T}} \left(\underline{y^{(n)} - \mathbf{x}^{(n)} \Theta[n-1]} \right)$$

1つ前の
パラメータ

λ で決まるゲイン

1つ前のパラメータ
による予測誤差

逐次最小二乗法の活用例

- ✓ 電圧方程式からIPMSMのインダクタンス等のパラメータをオンラインで同定することが可能

定常状態の電圧方程式(d軸)

$$\underbrace{v_d}_{Y} = R_a i_d + -\omega L_q i_q = \underbrace{[R_a \quad L_q]}_{\text{パラメータ}\theta} \underbrace{\begin{bmatrix} i_d \\ -\omega i_q \end{bmatrix}}_X$$

[1] Morimoto et al., "Mechanical Sensorless Drives of IPMSM With Online Parameter Identification," IEEE Trans. Ind. Appl., vol. 42, no. 5, pp. 1241-1248, 2006