

2.3.5 逐次推定

茨城大学工学部情報工学科

05T4072R

相原 功昌

逐次推定

- 逐次：
順を追って次々に物事がなされるさま
 - 逐次推定：
データ点を1つずつ処理し、処理したデータは
廃棄して推定する方法
- 全てのデータ点を一度に処理できない大規模なデータ集合、オンラインな応用分野
で重要

平均の最尤推定量について

- 平均の最尤推定量 μ_{ML} の場合
N個の観測値に基づいて推定した結果: $\mu_{ML}^{(N)}$
最後のデータ点 X_N がどれくらい影響したかを調べる
→式(2.126)

平均の最尤推定量について(2)

$$\mu_{ML}^{(N)} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n$$

$$= \frac{1}{N} \mathbf{x}_N + \frac{1}{N} \sum_{n=1}^{N-1} \mathbf{x}_n$$

$$= \frac{1}{N} \mathbf{x}_N + \frac{N-1}{N} \mu_{ML}^{(N-1)}$$

$$= \frac{1}{N} \mathbf{x}_N + \frac{N}{N} \mu_{ML}^{(N-1)} - \frac{1}{N} \mu_{ML}^{(N-1)}$$

$$= \mu_{ML}^{(N-1)} + \frac{1}{N} \left(\mathbf{x}_N - \mu_{ML}^{(N-1)} \right) \quad \dots(2.126)$$

$$\mu_{ML}^{(N-1)} = \frac{1}{N-1} \sum_{n=1}^{N-1} \mathbf{x}_n$$

$$(N-1) \mu_{ML}^{(N-1)} = \sum_{n=1}^{N-1} \mathbf{x}_n$$


$$\frac{(N-1)}{N} \mu_{ML}^{(N-1)} = \frac{1}{N} \sum_{n=1}^{N-1} \mathbf{x}_n$$

平均の最尤推定量について(3)

- N-1個のデータ点を観測した時点での μ の推定値: $\mu_{ML}^{(N-1)}$
- 誤差信号: $(x_N - \mu_{ML}^{(N-1)})$
- データ点 x_N を観測すると、 $1/N$ に比例する小さな量だけ、誤差信号の方へ $\mu_{ML}^{(N-1)}$ を移動させて修正した値を $\mu_{ML}^{(N)}$ としている
- Nが増えるにつれて、後続のデータ点からの影響は小さくなる

汎用的な逐次学習の定式化

- この方法で逐次アルゴリズムを導出する
→いつもできるとは限らない



- 汎用的な逐次学習の定式化が必要となる
→Robbins-Monroアルゴリズム

Robbins-Monroアルゴリズム(1)

- 確率変数のパラメータ: θ
- θ に依存した確率変数: z
- 回帰関数 $f(\theta) = E[z | \theta]$ を定義




図2.10

$$\begin{aligned}
 f(\theta) &\equiv E[z | \theta] \\
 &= \int zp(z | \theta)dz \quad \dots(2.127)
 \end{aligned}$$

- このとき、 $f(\theta) = 0$ の根 θ^* を逐次的に求めるためのアルゴリズム

Robbins-Monroアルゴリズム(2)

- 仮定

- z の条件付分散は有限である

$$E[(z - f)^2 | \theta] < \infty$$

- $\theta > \theta^*$ では $f(\theta) > 0$

- $\theta < \theta^*$ では $f(\theta) < 0$

- 定義

- N-1個のデータを観測した後の推定値: $\theta^{(N-1)}$

- このパラメータの下でのN個目の z の観測値: $z(\theta^{(N-1)})$

- このときのN回目のパラメータ:

$$\theta^N = \theta^{N-1} - a_{N-1} z(\theta^{(N-1)}) \quad \dots(2.129)$$

Robbins-Monroアルゴリズム(3)

- 係数 a_N が

- $\lim_{N \rightarrow \infty} a_N = 0$ $\cdots(2.130)$

- $\sum_{N=1}^{\infty} a_N = \infty$ $\cdots(2.131)$

- $\sum_{N=1}^{\infty} a_N^2 < \infty$ $\cdots(2.132)$

を満たすなら、式(2.129)で与えられる θ^N は目標の根に確率1で収束する

Robbins-Monroアルゴリズム(4)

- 式(2.130)
→この過程が極限值に収束できるように、解の逐次的な修正量を減らすことを保証
- 式(2.131)
→アルゴリズムが根以外に速すぎる収束をしないことを保証
- 式(2.131)
→蓄積されたノイズの分散を有限に抑え、収束を阻害しないことを保証

一般的な最尤推定問題(1)

- Robbins-Monroアルゴリズムを用いて、一般的な最尤推定問題を逐次的に解く
- 最尤推定解: θ_{ML}
 - 負の対数尤度関数の停留点(誤差の最小)
 - 式(2.133)を満たす

$$-\frac{\partial}{\partial \theta} \left\{ \frac{1}{N} \sum_{n=1}^N \ln p(x_n | \theta) \right\} \Bigg|_{\theta_{ML}} = 0 \quad \dots (2.133)$$

一般的な最尤推定問題(2)

$$-\frac{\partial}{\partial \theta} \left\{ \frac{1}{N} \sum_{n=1}^N \ln p(x_n | \theta) \right\} \Big|_{\theta_{ML}} = 0$$

微分と総和の演算を交換すると

$$-\frac{1}{N} \sum_{n=1}^N \frac{\partial}{\partial \theta} \ln p(x_n | \theta) \Big|_{\theta_{ML}} = 0$$

期待値の近似を厳密にするために

$N \rightarrow \infty$ の極限を考えると

$$-\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N \frac{\partial}{\partial \theta} \ln p(x_n | \theta) = E_x \left[-\frac{\partial}{\partial \theta} \ln p(x | \theta) \right] \dots (2.134)$$

一般的な最尤推定問題(3)

- 最尤推定解を求める
= 回帰関数の根を求める
- Robbins-Monroアルゴリズムを適用
→ 式(2.135)

$$\theta^{(N)} = \theta^{(N-1)} - a_{N-1} \frac{\partial}{\partial \theta^{(N-1)}} \left[-\ln p(x_N | \theta^{(N-1)}) \right] \quad \dots (2.135)$$

ガウス分布の平均の逐次推定(1)

- パラメータ: $\theta^{(N)}$

→ガウス分布の平均の推定量: $\mu_{ML}^{(N)}$

- 確率変数: z

$$z = - \frac{\partial}{\partial \mu_{ML}} \ln p(x | \mu_{ML}, \sigma^2)$$

$$= - \frac{1}{\sigma^2} (x - \mu_{ML}) \quad \dots (2.136)$$

ガウス分布の平均の逐次推定(2)

- 式(2.136)を式(2.135)に代入

$$\mu_{ML}^{(N)} = \mu_{ML}^{(N-1)} - a_{N-1} \left\{ -\frac{1}{\sigma^2} (x - \mu_{ML}) \right\}$$

- 係数 a_N を $a_N = \sigma^2/N$ とすると
式(2.126)の形式になる
- 多変量の場合も同様に、同じ手法が適用できる