

情報認識

「パラメトリック法: ベイズ推定」

- 担当教員: 杉山 将 (計算工学専攻)
- 居室: W8E-505
- 電子メール: sugi@cs.titech.ac.jp

パラメータの確率的取り扱い

- 最尤推定の枠組みでは、モデル $q(x; \theta)$ のパラメータ θ を決定論的な変数として扱った。
- もし、パラメータも確率変数とみなせば、次のような確率が定義できる。
 - 事前確率 $p(\theta)$
 - 事後確率 $p(\theta | x_1, x_2, \dots, x_n)$
 - 尤度 $p(x_1, x_2, \dots, x_n | \theta)$

ベイズ推定法

- **ベイズ推定法(Bayes estimation method)**: モデルをパラメータの事後確率に関して平均することによって推定する方法

$$\hat{p}(x) = \int_{\Theta} q(x; \theta) p(\theta | x_1, x_2, \dots, x_n) d\theta$$

- **最尤推定**: 1つの代表パラメータで推定
- **ベイズ推定**: 無数の確率密度関数の平均で推定

ベイズ推定法の計算

■ 尤度は

$$p(x_1, x_2, \dots, x_n | \theta) = \prod_{i=1}^n q(x_i; \theta)$$

■ 事後確率は, ベイズの定理を用いれば

$$\begin{aligned} p(\theta | x_1, x_2, \dots, x_n) &= \frac{p(x_1, x_2, \dots, x_n | \theta) p(\theta)}{p(x_1, x_2, \dots, x_n)} \\ &= \frac{p(x_1, x_2, \dots, x_n | \theta) p(\theta)}{\int_{\Theta} p(x_1, x_2, \dots, x_n | \theta') p(\theta') d\theta'} \\ &= \frac{\prod_{i=1}^n q(x_i; \theta) p(\theta)}{\int_{\Theta} \prod_{i=1}^n q(x_i; \theta') p(\theta') d\theta'} \end{aligned}$$

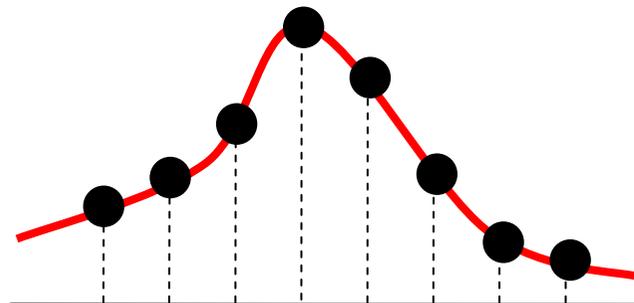
ベイズ推定法の計算(続き)

$$\hat{p}(x) = \int_{\Theta} q(x; \theta) \frac{\prod_{i=1}^n q(x_i; \theta) p(\theta)}{\int_{\Theta} \prod_{i=1}^n q(x_i; \theta') p(\theta') d\theta'} d\theta$$

- ベイズ推定法は、事前確率とモデルさえ与えられれば、原理的には計算できる。
- しかし、実際にはパラメータに関する積分を計算しなければならない。

ベイズ推定法の計算(続き)

- パラメータ空間 Θ の次元が低いとき, 格子上の値を使えば, (台形公式やシンプソンの公式により) 簡単に近似計算できる.
- しかし, 格子点の数はパラメータ空間の次元に指数的に比例するため, 次元が高いとき, 計算効率が非常に悪い.



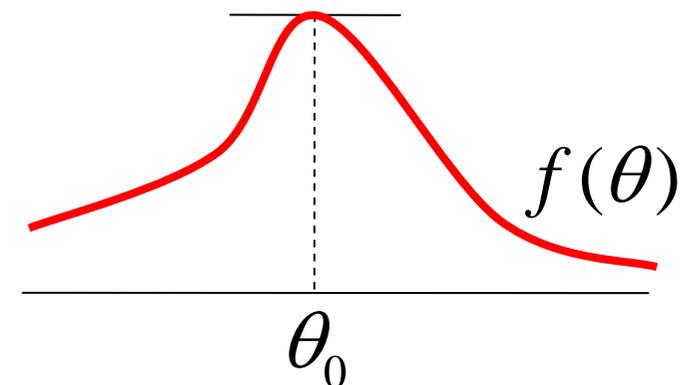
積分の近似

- 以下では, $f(\theta)$ の積分 $\int_{\Theta} f(\theta) d\theta$ を近似する問題を考える.
- $\theta_0 = \arg \max_{\theta \in \Theta} f(\theta)$ は最大値なので次式を満たす

$$\left. \frac{\partial}{\partial \theta_i} f(\theta) \right|_{\theta=\theta_0} = 0$$

- $\log f(\theta)$ に対しても同様に

$$\left. \frac{\partial}{\partial \theta_i} \log f(\theta) \right|_{\theta=\theta_0} = 0$$



テイラー展開

■ テイラー展開(Taylor expansion):

$$f(\theta) = f(\theta_0) + (\theta - \theta_0)f'(\theta_0) + \frac{1}{2}(\theta - \theta_0)^2 f''(\theta_0) + \dots$$

(θ の1次元のとき)

■ テイラー展開を適当な次数で打ち切れば、関数 $f(\theta)$ を多項式で近似できる。

■ θ が多次元のとき、

$$f(\theta) = f(\theta_0) + (\theta - \theta_0)^T h + \frac{1}{2}(\theta - \theta_0)^T H(\theta - \theta_0) + \dots$$

$$h_i = \left. \frac{\partial}{\partial \theta_i} f(\theta) \right|_{\theta=\theta_0} \quad H_{i,j} = \left. \frac{\partial^2}{\partial \theta_i \partial \theta_j} f(\theta) \right|_{\theta=\theta_0} \quad \text{:ヘシアン行列 (Hessian matrix)}$$

積分の近似(続き)

- $\log f(\theta)$ を θ_0 の周りで2次のテーラー展開

$$\log f(\theta) \approx \underbrace{\log f(\theta_0) + 0 + \frac{1}{2}(\theta - \theta_0)^T H(\theta - \theta_0)}_{\log \tilde{f}(\theta)}$$

$$H_{i,j} = \frac{\partial^2}{\partial \theta_i \partial \theta_j} \log f(\theta) \Big|_{\theta=\theta_0}$$

- 指数をとれば,

$$f(\theta) \approx \tilde{f}(\theta) = f(\theta_0) \exp\left(\frac{1}{2}(\theta - \theta_0)^T H(\theta - \theta_0)\right)$$

ラプラス近似

- 正規分布の確率密度関数の積分は1:

$$\int_D p(x) dx = 1$$

$$p(x) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu)\right)$$

- これより,

$$\int_{\Theta} \exp\left(-\frac{1}{2} (\theta - \theta_0)^T (-H) (\theta - \theta_0)\right) d\theta = \sqrt{\frac{(2\pi)^{\dim \theta}}{|-H|}}$$

- 積分のラプラス近似(Laplace approximation):

$$\int_{\Theta} f(\theta) d\theta \approx \int_{\Theta} \tilde{f}(\theta) d\theta = f(\theta_0) \sqrt{\frac{(2\pi)^{\dim \theta}}{|-H|}}$$

ラプラス近似 (続き)

- $\log f(\theta)$ を2次関数で近似することは、 $f(\theta)$ を (正規化されていない) ガウス関数で近似することに対応。
- そのため、ラプラス近似は**ガウス近似 (Gaussian approximation)** とも呼ばれる。
- $f(\theta)$ の形状がガウス分布の形状に近いとき、ラプラス近似は精度がよい。

小レポート

■ $f(\theta) = p(\theta;1) + p(\theta;2)$

$$p(\theta; \sigma) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{\theta^2}{2\sigma^2}\right)$$

■ $Z = \int_{-\infty}^{\infty} f(\theta)d\theta$ の値をラプラス近似で求めよ
(真の値は2である) .