

鈴木讓「ベイジアンネットワーク入門」(培風館)

3. 統計的学習

3.2 データ圧縮 (2) 確率が未知の場合

鈴木讓

大阪大学

2009年12月10日

あらまし

問題の定式化

$\min_W \max_{\theta} D^n(P_{\theta} || Q_W)$ の上界

$\min_W \max_{\theta} D^n(P_{\theta} || Q_W)$ の下界

Jeffreys の事前確率

問題の定式化: $\min_W \max_{\theta} D^n(P_{\theta} || Q_W)$ とそれに到達する W

c_j : $z^n \in Z^n(\Omega)$ における $j \in Z(\Omega) := \{0, 1, \dots, m-1\}$ の頻度

$$\theta \in \Theta(\Omega) := \left\{ (\theta_0 \cdots, \theta_{m-1}) \mid \theta_j \geq 0, j = 0, 1, \dots, m-1, \sum_{j=0}^{m-1} \theta_j = 1 \right\}$$

$$P_{\theta}(z^n) := \prod_{j=0}^{m-1} \theta_j^{c_j} \quad (5)$$

W : Θ の測度 ($W(\Theta(\Omega)) = 1$)

$$Q_W(z^n) := \int_{\Theta(\Omega)} P_{\theta}(z^n) W(d\theta) \quad (6)$$

$$I_{\varphi}(z^n) := -\log Q_W(z^n)$$

$$D^n(P_{\theta} || Q_W) := E I_{\varphi}(Z^n) - H(Z^n) = \sum_{z^n \in Z^n(\Omega)} P_{\theta}(z^n) \log \frac{P_{\theta}(z^n)}{Q_W(z^n)}$$

上界

$W(d\theta) = w(\theta)d\theta$ 、Dirichlet 分布 $(a_0, a_1, \dots, a_{m-1} = \frac{1}{2})$ を仮定

$$w_{a_0, \dots, a_{m-1}}(\theta) = \frac{\Gamma\left(\sum_{j=0}^{m-1} a_j\right)}{\prod_{j=0}^{m-1} \Gamma(a_j)} \prod_{j=0}^{m-1} \theta_j^{a_j-1} \quad (7)$$

$$\begin{aligned} Q_W(z^n) &= \int_{\Theta(\Omega)} w_{1/2, \dots, 1/2}(\theta) P_\theta(z^n) d\theta \\ &= \int_{\Theta(\Omega)} \frac{\Gamma(m/2)}{\Gamma(1/2)^m} \prod_{j=0}^{m-1} \theta_j^{c_j-1/2} d\theta \\ &= \frac{\Gamma(m/2) \prod_{j=0}^{m-1} \Gamma(c_j + 1/2)}{\Gamma(1/2)^m \Gamma(n + m/2)} \int_{\Theta(\Omega)} w_{c_0+1/2, \dots, c_{m-1}+1/2}(\theta) d\theta \\ &= \frac{\Gamma(m/2) \prod_{j=0}^{m-1} \Gamma(c_j + 1/2)}{\Gamma(1/2)^m \Gamma(n + m/2)}. \end{aligned} \quad (8)$$

上界 (続)

$z_*^n := 0 \cdots 0$ (0 が n 回続く系列)

$$Q_W(z_*^n) = \frac{\Gamma(m/2)\Gamma(n+1/2)}{\Gamma(1/2)\Gamma(n+m/2)}, \quad (9)$$

$$\frac{Q_W(z^n)}{Q_W(z_*^n)} = \frac{\prod_{j=0}^{m-1} \Gamma(c_j + 1/2)}{\Gamma(1/2)^{m-1} \Gamma(n+1/2)} \quad (10)$$

$$= \frac{\prod_{j=0}^{m-1} (c_j + 1)(c_j + 2) \cdots (2c_j)}{(n+1)(n+2) \cdots (2n)} \quad (11)$$

$$\geq \prod_{j=0}^{m-1} \left(\frac{c_j}{n} \right)^{c_j} \quad (12)$$

$$\geq \prod_{j=0}^{m-1} \theta_j^{c_j} \quad (13)$$

(10) \Rightarrow (11)

$$\begin{aligned}\Gamma(n + 1/2) &= (n - 1/2)(n - 3/2) \cdots (1/2) \cdot \Gamma(1/2) \\ &= \frac{(2n - 1)(2n - 3) \cdots 1}{2^n} \Gamma(1/2) \\ &= \frac{2n \cdot (2n - 1) \cdot (2n - 2) \cdot (2n - 3) \cdots 2 \cdot 1}{n \cdot (n - 1) \cdots 1 \cdot 2^{2n}} \Gamma(1/2) \\ &= \frac{(n + 1)(n + 2) \cdots 2n}{2^{2n}} \Gamma(1/2),\end{aligned}$$

$$\begin{aligned}\prod_{j=0}^{m-1} \Gamma(c_j + 1/2) &= \prod_{j=0}^{m-1} \left\{ \frac{(c_j + 1)(c_j + 2) \cdots 2c_j}{2^{2c_j}} \Gamma(1/2) \right\} \\ &= \frac{\prod_{j=0}^{m-1} [(c_j + 1)(c_j + 2) \cdots 2c_j]}{2^{2n}} \Gamma(1/2)^m\end{aligned}$$

(11)⇒(12)

$$\left(1 + \frac{1}{n}\right) \left(1 + \frac{2}{n}\right) \cdots 2 \leq \prod_{j=0}^{m-1} \left(1 + \frac{1}{c_j}\right) \left(1 + \frac{2}{c_j}\right) \cdots 2 \text{ と同値}$$

$$1 + \frac{i}{n} \leq 1 + \frac{k}{c_j} \iff k \geq \frac{c_j}{n} i,$$

$$x_j \geq 0 \implies \sum_{j=0}^{m-1} [x_j] \leq \left[\sum_{j=0}^{m-1} x_j \right] + m - 1$$

S_i : $1 + i/n \leq 1 + k/c_j$, $1 \leq k \leq c_j$ なる (j, k) の個数

$$\sum_{j=0}^{m-1} \left[\frac{c_j}{n} i \right] \leq \left[i \sum_{j=0}^{m-1} \frac{c_j}{n} \right] + m - 1 = m - 1 + i$$

$$S_i = \sum_{j=0}^{m-1} \left(c_j - \left[\frac{c_j}{n} i \right] + 1 \right) \geq \sum_{j=0}^{m-1} c_j + 1 - i = n + 1 - i.$$

$1 + \frac{i}{n} \leq 1 + \frac{k}{c_j}$, $1 \leq k \leq c_j$ なる i と 1 対 1 対応の (j, k) が存在

(12) \Rightarrow (13)

$$\sum_{j=0}^{m-1} \frac{c_j}{n} \log \left(\frac{c_j}{n} / n \right) \geq 0$$

と同値

上界 (続)

(5), (9), (13) より ,

$$\begin{aligned}
 D^n(P_\theta \| Q_W) &= E_\theta \log \frac{P_\theta(Z^n)}{Q_W(Z^n)} \\
 &\leq E_\theta[-\log Q_W(z_*^n)] = \log \frac{\Gamma(1/2)\Gamma(n+m/2)}{\Gamma(m/2)\Gamma(n+1/2)} \\
 &\leq \frac{1}{2}(m-1) \log n - \log \frac{\Gamma(m/2)}{\Gamma(1/2)} + O(1/n) \quad (14)
 \end{aligned}$$

最後の变形: m が奇数のとき、

$$\begin{aligned}
 \log \frac{\Gamma(n+m/2)}{n^{(m-1)/2}\Gamma(n+1/2)} &= \log \left\{ \left(1 + \frac{m/2-1}{n}\right) \cdots \left(1 + \frac{1/2}{n}\right) \right\} \\
 &\leq \sum_{k=0}^{\frac{m-1}{2}} \frac{k+1/2}{n} = \frac{(m+1)^2}{8n} \\
 \frac{\Gamma(n+m/2)}{n^{\frac{m-1}{2}}\Gamma(n+1/2)} &\leq \frac{\Gamma(n+(m+1)/2)}{n^{\frac{m}{2}}\Gamma(n+1/2)}
 \end{aligned}$$

より (m の帰納法) , m が偶数でも成立。

下界

U : Θ の測度 ($U(\Theta(\Omega)) = 1$, W とは別もの)

$$I(\Theta, Z^n) := \int_{\Theta(\Omega)} D^n(P_\theta \| Q_U) U(d\theta),$$

$$Q_U(z^n) := \int_{\Theta(\Omega)} P_\theta(z^n) U(d\theta)$$

$$\begin{aligned} \max_U I(\Theta, Z^n) &= \max_U \min_W \int D^n(P_\theta \| Q_W) U(d\theta) \\ &\leq \min_W \max_U \int D^n(P_\theta \| Q_W) U(d\theta) = \min_W \max_\theta D^n(P_\theta \| Q_W). \end{aligned}$$

下界 (続)

最初の等式:

$$\begin{aligned} & \int_{\Theta(\Omega)} D^n(P_\theta \| Q_W) U(d\theta) - \int_{\Theta(\Omega)} D^n(P_\theta \| Q_U) U(d\theta) \\ &= \int_{\Theta(\Omega)} \sum_{z^n \in Z^n(\Omega)} P_\theta(z^n) \log \frac{P_\theta(z^n)}{Q_W(z^n)} U(d\theta) \\ & \quad - \int_{\Theta(\Omega)} \sum_{z^n \in Z^n(\Omega)} P_\theta(z^n) \log \frac{P_\theta(z^n)}{Q_U(z^n)} U(d\theta) \\ &= \sum_{z^n \in Z^n(\Omega)} Q_U(z^n) \log \frac{Q_U(z^n)}{Q_W(z^n)} \geq 0 \end{aligned}$$

微分エントロピー

確率変数 X の確率密度関数 f_X が存在するとき

X の微分エントロピー

$$h(X) := \int_{x \in X(\Omega)} -f_X(x) \log f_X(x) dx$$

確率変数 Y は離散 (確率分布: P_Y) で条件付密度関数 $f_{X|Y}$ が存在するとき

Y のもとでの X の条件付微分エントロピー

$$h(X|Y) := \sum_{y \in Y(\Omega)} \int_{x \in X(\Omega)} -f_{X|Y}(x|y) P_Y(y) \log \frac{f_{X|Y}(x|y) P_Y(y)}{P_Y(y)} dx$$

$h(x) \geq 0$, $h(X|Y) \geq 0$ は成立しない

$g : Y(\Omega) \rightarrow \mathbb{R}$ で、 $g(Y)$ が確率変数のとき、 $I(X, Y) \geq I(X, g(Y))$

$$I(X, Y) := h(X) - h(X|Y)$$

$$= \int_{x \in X(\Omega)} \sum_{y \in Y(\Omega)} f_{X|Y}(x|y) P_Y(y) \log \frac{f_{X|Y}(x|y) P_Y(y)}{f_X(x) P_Y(y)} dx \geq 0$$

$$\sum_{y \in Y(\Omega)} \int_{x \in X(\Omega)} f_{X|Y}(x|y) P_Y(y) \log \frac{f_{X|Y}(x|y) P_Y(y)}{f_{X|g(Y)}(x|g(y)) P_Y(y)} dx \geq 0$$

$$I(X, Y) = h(X) - h(X|Y) \geq h(X) - h(X|g(Y)) = I(X, g(Y)) \quad (15)$$

下界 (続)

推定量 $\hat{\theta}_j(Z^n) := c_j(Z^n)/n$, $\hat{\theta}(Z^n) = (\hat{\theta}_0(Z^n), \dots, \hat{\theta}_{m-1}(Z^n))$ は, 確率変数 Z^n の関数であるので,

$$\begin{aligned} I(\Theta, Z^n) &\geq I(\Theta, \hat{\theta}(Z^n)) \\ &= h(\Theta) - h(\Theta | \hat{\theta}(Z^n)) \\ &= h(\Theta) - h(\Theta - \hat{\theta}(Z^n) | \hat{\theta}(Z^n)) \\ &\geq h(\Theta) - h(\Theta - \hat{\theta}(Z^n)). \end{aligned} \tag{16}$$

$\Theta = \theta$ を任意に固定すると、

$(\Theta_1 - \hat{\theta}_1(Z^n), \dots, \Theta_{m-1} - \hat{\theta}_{m-1}(Z^n))$ は, 平均 0,

$$\sigma_{i,j}^2 := E[(\Theta_i - \hat{\theta}_i(Z^n))(\Theta_j - \hat{\theta}_j(Z^n))]$$

を成分とする共分散行列 $\Sigma = (\sigma_{ij}^2)_{1 \leq i,j \leq m-1}$ をもつ。

正規分布: 同じ分散で微分エントロピー最大の分布

f_X : 平均 0, 共分散行列 Σ の正規分布の確率密度関数

g_X : 平均 0, 共分散行列 Σ の任意の確率密度関数

$\log f_X(x)$ の平均が確率変数 X の分散のみに依存するので,

$$\begin{aligned} 0 &\leq \int g_X(x) \log \left(\frac{g_X(x)}{f_X(x)} \right) dx \\ &= \int g_X(x) \log g_X(x) dx - \int g_X(x) \log f_X(x) dx \\ &= \int g_X(x) \log g_X(x) dx - \int f_X(x) \log f_X(x) dx \end{aligned}$$

f_X の微分エントロピー:

$$\begin{aligned} &\int -f_X(\mathbf{x}) \log f_X(\mathbf{x}) d\mathbf{x} \\ &= \int f_X(\mathbf{x}) \cdot \frac{1}{2} {}^t \mathbf{x} \Sigma^{-1} \mathbf{x} d\mathbf{x} + \int f_X(\mathbf{x}) \log(\sqrt{2\pi \det(\Sigma)}) d\mathbf{x} \\ &= \frac{1}{2} \log(2\pi e \det(\Sigma)) \end{aligned}$$

下界 (続)

D : $\sigma_{jj}^{-1/2}$ を対角成分にもつ対角行列

$D\Sigma D$ の対角成分が 1 で, Σ は正定値対称行列なので, その固有値を $\lambda_1, \dots, \lambda_{m-1}$ とおくと, それらは正で

$$\begin{aligned} \{\det(D\Sigma D)\}^{1/(m-1)} &= \left(\prod_{j=1}^{m-1} \lambda_j \right)^{1/(m-1)} \\ &\leq \frac{1}{m-1} \sum_{j=1}^{m-1} \lambda_j = \frac{1}{m-1} \text{trace}(D\Sigma D) = 1 \end{aligned}$$

$$\det \Sigma \leq \prod_{j=1}^{m-1} \sigma_{jj}$$

同じ共分散行列をもつ分布で、正規分布が $h(\Theta - \hat{\theta}(Z^n))$ を最大。

$$h(\Theta - \hat{\theta}(Z^n)) \leq \frac{1}{2} \log[(2\pi e)^{m-1} \det(\Sigma)] \leq \sum_{j=1}^{m-1} \frac{1}{2} \log(2\pi e \sigma_{jj}^2).$$

下界 (続)

$$\Lambda := \{(\theta_1, \dots, \theta_{m-1}) \mid 0 \leq \theta_j \leq 1, j = 1, \dots, m-1, \theta_1 + \dots + \theta_{m-1} \leq 1\}$$

$$\int_{\Lambda} d\theta_1 \cdots d\theta_{m-1} = \frac{1}{(m-1)!}$$

$$u(\theta) := (m-1)!$$

$$\sigma_{jj}^2 = \int_{\Lambda} E_{\theta} \left(\frac{c_j(Z^n)}{n} - \theta_j \right)^2 U(d\theta) = \int_{\Lambda} \frac{\theta_j(1-\theta_j)}{n} U(d\theta) = \frac{1}{6n},$$

$$h(\Theta - \hat{\theta}(Z^n)) \leq \frac{1}{2}(m-1) \log \frac{\pi e}{3n}, \quad (17)$$

$$h(\Theta) = -\log(m-1)!. \quad (18)$$

(17), (18) を (16) に代入すると,

$$\begin{aligned} & \min_W \max_{\theta} D^n(P_{\theta} \| Q_W) \\ & \geq \frac{1}{2}(m-1) \log n - \log(m-1)! - \frac{1}{2}(m-1) \log \frac{\pi e}{3} \quad (19) \end{aligned}$$

$\min_W \max_{\theta} D^n(P_{\theta} || Q_W)$ の上界下界

(14), (19) より、

定理 3.5 (Davisson, 1981)

$$\begin{aligned} & \frac{1}{2}(m-1) \log n - \log(m-1)! - \frac{1}{2}(m-1) \log \frac{\pi e}{3} \\ & \leq \min_W \max_{\theta} D^n(P_{\theta} || Q_W) \\ & \leq \frac{1}{2}(m-1) \log n - \log \frac{\Gamma(m/2)}{\Gamma(1/2)} + O(1/n) \end{aligned} \quad (20)$$

$w = w_{a_0, \dots, a_{m-1}}$ で $a_j = 1$ とおいた場合, w が一様分布になるが, 定理 18 より精密な上界は得られていない。

Jeffreys の事前確率

各 $\theta \in \Theta(\Omega)$ の近傍にある θ' について, その確率測度 μ_θ が θ の近傍にある各 θ' で $\mu_\theta \ll \mu_{\theta'}$ のとき,

確率変数 Θ に関する Fisher 情報行列

$$I_{i,j} := \left[\frac{\partial D(\mu_\theta || \mu_{\theta'})}{\partial \theta'_i \partial \theta'_j} \Big|_{\theta'=\theta} \right] \text{ を成分とする行列 } I = (I_{i,j})$$

$c^* := \int_{\Lambda} \sqrt{\det I(\theta)} d\theta < \infty$ のとき、

Jeffreys の事前確率

$$w^*(\theta) = \frac{\sqrt{\det I(\theta)}}{c^*} \quad (21)$$

Jeffreys の事前確率 (続)

例: $X(\Omega) = \{0, 1\}$, $\mu_X\{1\} = \theta$, $\mu_X\{0\} = 1 - \theta$ について,

$$D(\mu_\theta || \mu_{\theta'}) = \theta \log \frac{\theta}{\theta'} + (1 - \theta) \log \frac{1 - \theta}{1 - \theta'},$$

$$\frac{\partial^2}{\partial(\theta')^2} D(\mu_\theta || \mu_{\theta'}) = \frac{\theta}{\theta'^2} + \frac{1 - \theta}{(1 - \theta')^2}.$$

$\theta' = \theta$ を代入すると, Fisher 情報量行列はスカラーとなり,

$$I(\theta) = \frac{1}{\theta(1 - \theta)}$$

$$c^* = \int_0^1 \frac{d\theta}{\sqrt{\theta(1 - \theta)}} = \pi$$

$$w^*(\theta) = \frac{1}{\pi \sqrt{\theta(1 - \theta)}}$$

Clarke-Barron, 1994

- ▶ Jeffreys の事前確率が最適となるための十分条件



$$\lim_{n \rightarrow \infty} \left[\min_W \max_{\theta} D^n(P_{\theta} || Q_W) - \frac{d(\Theta(\Omega))}{2} \log \frac{n}{2\pi e} \right]$$
$$= \log \int_{\Lambda} \sqrt{\det I(\theta)} d\theta$$

- ▶ 確率変数 Z の値域が有限集合となる場合には ,
 $a_j = 1/2$ の場合が Jeffreys の事前確率。
- ▶ $w_{1/2, \dots, 1/2}$ は Clarke-Barron の十分条件を満足しない
- ▶ 最適な W は絶対連続ではない (Xie-Barron, 1997)。

定理 3.5 の意味で十分最適に近いことから , Θ の事前確率 Q_W が未知である場合に , $w_{1/2, \dots, 1/2}$ が準最適な事前確率として用いられている。