

付 録 A

第 5.5 節に対する補足説明

第 5.5 節では凸（凹）関数の性質を用いてスパースベイズ推定の更新式を導いた．この第 5.5 節の説明では，未知量 x を補助変数として取り扱うなどのため，導出は若干わかりにくいかもしれない．この補足資料では，凸（凹）関数の性質を用いて，更新式の少し異なった（望むべくは少々わかりやすい）導出を行う．

A.1 周辺尤度 (5.20) の自由エネルギーを用いた導出

ここでの説明は，式 (5.20) に示された周辺尤度から出発する．まず，ここでは式 (5.20) を自由エネルギーから導いてみよう．

評価関数 $\mathcal{F}[q, \alpha]$ ：

$$\mathcal{F}[q, \alpha] = \int dx q(x) [\log p(x, \mathbf{y} | \alpha) - \log q(x)] \quad (\text{A.1})$$

は自由エネルギーと呼ばれる．この $\mathcal{F}[q, \alpha]$ は 2 つの量，ハイパーパラメータ α と任意の確率分布 $q(x)$ の関数である．第 4.6 節の議論によれば，自由エネルギー $\mathcal{F}[q, \alpha]$ を最大にする確率分布は未知量 x の（ α をこの時点での値に固定した）事後分布 $p(x | \mathbf{y}, \alpha)$ であることを示している．すなわち，自由エネルギーを $q(x)$ について最大にすることは EM アルゴリズム

の E ステップに対応する．E ステップ終了時点での自由エネルギーは

$$\begin{aligned}
 \mathcal{F}[p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}), \boldsymbol{\alpha}] &= \int d\mathbf{x} p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) [\log p(\mathbf{x}, \mathbf{y}|\boldsymbol{\alpha}) - \log p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})] \\
 &= \int d\mathbf{x} p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) \log \frac{p(\mathbf{x}, \mathbf{y}|\boldsymbol{\alpha})}{p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})} = \int d\mathbf{x} p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) \log p(\mathbf{y}|\boldsymbol{\alpha}) \\
 &= \log p(\mathbf{y}|\boldsymbol{\alpha}) \int d\mathbf{x} p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) = \log p(\mathbf{y}|\boldsymbol{\alpha}) \quad (\text{A.2})
 \end{aligned}$$

となり，自由エネルギーの値は周辺尤度 $\log p(\mathbf{y}|\boldsymbol{\alpha})$ に等しい．したがって，

$$\begin{aligned}
 \log p(\mathbf{y}|\boldsymbol{\alpha}) &= \int d\mathbf{x} p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) [\log p(\mathbf{x}, \mathbf{y}|\boldsymbol{\alpha}) - \log p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})] \\
 &= E [\log p(\mathbf{x}, \mathbf{y}|\boldsymbol{\alpha}) - \log p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})] \\
 &= E [\log p(\mathbf{y}|\mathbf{x}) + \log p(\mathbf{x}|\boldsymbol{\alpha})] + \mathcal{H}[p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})] \quad (\text{A.3})
 \end{aligned}$$

が成立する．ここで， $E[\cdot]$ は事後分布 $p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})$ で平均を取ることを意味し， $\mathcal{H}[p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})]$ は事後分布のエントロピーである．

式 (A.3) に

$$\begin{aligned}
 p(\mathbf{x}|\boldsymbol{\alpha}) &= \mathcal{N}(\mathbf{x}|\mathbf{0}, \boldsymbol{\Phi}^{-1}) \\
 p(\mathbf{y}|\mathbf{x}) &= \mathcal{N}(\mathbf{y}|\mathbf{H}\mathbf{x}, \beta^{-1}\mathbf{I}) \\
 p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) &= \mathcal{N}(\mathbf{x}|\bar{\mathbf{x}}, \boldsymbol{\Gamma}^{-1})
 \end{aligned}$$

を代入して整理する．ただしここで，

$$\boldsymbol{\Phi} = \text{diag} [\alpha_1, \dots, \alpha_N]$$

である．すると，定数を見捨て， $\mathcal{H}[p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha})] = -\log |\boldsymbol{\Gamma}|$ を用いて，

$$\log p(\mathbf{y}|\boldsymbol{\alpha}) = \frac{1}{2} [|\boldsymbol{\Phi}| + |\beta\mathbf{I}| - |\boldsymbol{\Gamma}|] - \frac{1}{2} E [\beta \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2] - \frac{1}{2} E [\mathbf{x}^T \boldsymbol{\Phi} \mathbf{x}] \quad (\text{A.4})$$

を得る．さらに，

$$\begin{aligned} E \left[\beta \| \mathbf{y} - \mathbf{H} \mathbf{x} \|^2 \right] + E \left[\mathbf{x}^T \boldsymbol{\Phi} \mathbf{x} \right] \\ = \beta \left[\mathbf{y}^T \mathbf{y} - 2 \bar{\mathbf{x}}^T \mathbf{H}^T \mathbf{y} \right] + E \left[\mathbf{x}^T (\beta \mathbf{H}^T \mathbf{H} + \boldsymbol{\Phi}) \mathbf{x} \right] \quad (\text{A.5}) \end{aligned}$$

であり，ここで，

$$\begin{aligned} E \left[\mathbf{x}^T (\beta \mathbf{H}^T \mathbf{H} + \boldsymbol{\Phi}) \mathbf{x} \right] &= E \left[\mathbf{x}^T \boldsymbol{\Gamma} \mathbf{x} \right] = E \left[\text{tr} \left(\mathbf{x} \mathbf{x}^T \boldsymbol{\Gamma} \right) \right] \\ &= E \left[\text{tr} \left(\mathbf{x} \mathbf{x}^T \boldsymbol{\Gamma} \right) \right] = \text{tr} \left[E \left(\mathbf{x} \mathbf{x}^T \right) \boldsymbol{\Gamma} \right] \\ &= \text{tr} \left[\left(\bar{\mathbf{x}} \bar{\mathbf{x}}^T + \boldsymbol{\Gamma}^{-1} \right) \boldsymbol{\Gamma} \right] = \bar{\mathbf{x}}^T (\beta \mathbf{H}^T \mathbf{H} + \boldsymbol{\Phi}) \bar{\mathbf{x}} \quad (\text{A.6}) \end{aligned}$$

であるので，結局，

$$\begin{aligned} E \left[\beta \| \mathbf{y} - \mathbf{H} \mathbf{x} \|^2 \right] + E \left[\mathbf{x}^T \boldsymbol{\Phi} \mathbf{x} \right] \\ = \beta \left[\mathbf{y}^T \mathbf{y} - 2 \bar{\mathbf{x}}^T \mathbf{H}^T \mathbf{y} + \bar{\mathbf{x}}^T \mathbf{H}^T \mathbf{H} \bar{\mathbf{x}} \right] + \bar{\mathbf{x}}^T \boldsymbol{\Phi} \bar{\mathbf{x}} \\ = \beta \| \mathbf{y} - \mathbf{H} \bar{\mathbf{x}} \|^2 + \bar{\mathbf{x}}^T \boldsymbol{\Phi} \bar{\mathbf{x}} \quad (\text{A.7}) \end{aligned}$$

を得る．したがって，式 (5.26)：

$$\log |\boldsymbol{\Sigma}_y| = -(|\boldsymbol{\Phi}| + |\beta \mathbf{I}| - |\boldsymbol{\Gamma}|)$$

を用いれば結局，周辺尤度として式 (5.20)：

$$\log p(\mathbf{y} | \boldsymbol{\alpha}) = -\frac{1}{2} \log |\boldsymbol{\Sigma}_y| - \frac{1}{2} \left[\beta \| \mathbf{y} - \mathbf{H} \bar{\mathbf{x}} \|^2 + \bar{\mathbf{x}}^T \boldsymbol{\Phi} \bar{\mathbf{x}} \right]$$

を得る．ここで，

$$\boldsymbol{\Sigma}_y = \beta^{-1} \mathbf{I} + \mathbf{H} \boldsymbol{\Upsilon} \mathbf{H}^T$$

である．

A.2 凹関数の性質を用いたコスト関数の導出

周辺尤度の式 (5.20) からスタートするのであるが，精度 α_j に対応した分散を ν_j ($\nu_j = \alpha_j^{-1}$) とし，列ベクトル ν を $\nu = [\nu_1, \dots, \nu_N]$ と定義する．凹関数の性質を用いるため，精度ベクトル α の代わりに分散ベクトル ν を，精度行列 Φ の代わりに共分散行列 Υ ($\Upsilon = \Phi^{-1}$) を用いる．したがって，式 (5.20) の周辺尤度は

$$\log p(\mathbf{y}|\nu) = -\frac{1}{2} \log |\Sigma_y| - \frac{1}{2} [\beta \|\mathbf{y} - \mathbf{H}\bar{\mathbf{x}}\|^2 + \bar{\mathbf{x}}^T \Upsilon^{-1} \bar{\mathbf{x}}] \quad (\text{A.8})$$

と表される．

ここで， $\log |\Sigma_y|$ は ν に関して凹関数であり，補助変数 z を用いて，式 (5.41)，すなわち，

$$\mathbf{z}^T \nu - z_0 \geq \log |\Sigma_y|$$

が常に成立する．したがって，

$$\log p(\mathbf{y}|\nu) \geq -\frac{1}{2} (\mathbf{z}^T \nu - z_0) - \frac{1}{2} [\beta \|\mathbf{y} - \mathbf{H}\bar{\mathbf{x}}\|^2 + \bar{\mathbf{x}}^T \Upsilon^{-1} \bar{\mathbf{x}}] \quad (\text{A.9})$$

であり，補助的コスト関数 $\tilde{\mathcal{F}}(\nu, z)$ を

$$\tilde{\mathcal{F}}(\nu, z) = -\frac{1}{2} (\mathbf{z}^T \nu - z_0) - \frac{1}{2} [\beta \|\mathbf{y} - \mathbf{H}\bar{\mathbf{x}}\|^2 + \bar{\mathbf{x}}^T \Upsilon^{-1} \bar{\mathbf{x}}]$$

と定義すれば，必ず，

$$\log p(\mathbf{y}|\nu) \geq \tilde{\mathcal{F}}(\nu, z)$$

が成立するため， $\tilde{\mathcal{F}}(\nu, z)$ を増加させる ν は周辺尤度 $\log p(\mathbf{y}|\nu)$ を増加させる．したがって， ν の更新解は

$$\hat{\nu} = \underset{\nu}{\operatorname{argmax}} \tilde{\mathcal{F}}(\nu, z) \quad (\text{A.10})$$

として求めることができる．

A.3 更新式の導出

ここで，補助変数 z の更新値 \hat{z} は，式 (5.46) すなわち

$$\hat{z} = \frac{\partial}{\partial \boldsymbol{\nu}} \log |\boldsymbol{\Sigma}_y|$$

から求まり，5.5.2 項で示したように

$$\hat{z}_j = \mathbf{h}_j^T \boldsymbol{\Sigma}_y^{-1} \mathbf{h}_j \quad (\text{A.11})$$

となる．上式は式 (5.49) である． $\boldsymbol{\nu}$ の更新値 $\hat{\boldsymbol{\nu}}$ は

$$\begin{aligned} \operatorname{argmax}_{\boldsymbol{\nu}} \tilde{\mathcal{F}}(\boldsymbol{\nu}, \mathbf{z}) &= \operatorname{argmax}_{\boldsymbol{\nu}} [\bar{\mathbf{x}}^T \boldsymbol{\Upsilon}^{-1} \bar{\mathbf{x}} + \mathbf{z}^T \boldsymbol{\nu}] \\ &= \operatorname{argmax}_{\boldsymbol{\nu}} \sum_{j=1}^N \left[z_j \nu_j + \frac{\bar{x}_j^2}{\nu_j} \right] \quad (\text{A.12}) \end{aligned}$$

から求まる．ここで，

$$\frac{\partial}{\partial \nu_j} \sum_{j=1}^N \left[z_j \nu_j + \frac{\bar{x}_j^2}{\nu_j} \right] = z_j - \frac{\bar{x}_j^2}{\nu_j^2} = 0 \quad (\text{A.13})$$

とおいて，式 (A.11) を用いることにより

$$\hat{\nu}_j = \frac{|\bar{x}_j|}{\sqrt{z_j}} = \frac{|\bar{x}_j|}{\sqrt{\mathbf{h}_j^T \boldsymbol{\Sigma}_y^{-1} \mathbf{h}_j}} \quad (\text{A.14})$$

を得る．上式が式 (5.53) である． $\bar{\mathbf{x}}$ は事後分布の平均であり，式 (5.10)，(5.11) を用いて更新する．

A.4 L_2 ノルム正則化解に対する正則化パラメータ更新式の導出

以上の考え方をいれれば， L_2 正則化ミニマムノルム解の正則化パラメータに対する更新式を，凹関数の性質を用いて導くこともできる．確率モデ

ルは，全ボクセルに共通の分散 ν を用いて，

$$\begin{aligned} p(\mathbf{x}|\nu) &= \mathcal{N}(\mathbf{x}|\mathbf{0}, \nu\mathbf{I}) \\ p(\mathbf{y}|\mathbf{x}) &= \mathcal{N}(\mathbf{y}|\mathbf{H}\mathbf{x}, \beta^{-1}\mathbf{I}) \\ p(\mathbf{x}|\mathbf{y}, \boldsymbol{\alpha}) &= \mathcal{N}(\mathbf{x}|\bar{\mathbf{x}}, \boldsymbol{\Gamma}^{-1}) \end{aligned}$$

であるので，周辺尤度は

$$\log p(\mathbf{y}|\nu) = -\frac{1}{2} \log |\boldsymbol{\Sigma}_y| - \frac{1}{2} [\beta \|\mathbf{y} - \mathbf{H}\bar{\mathbf{x}}\|^2 + \nu^{-1} \|\bar{\mathbf{x}}\|^2] \quad (\text{A.15})$$

を得る．ここで，

$$\boldsymbol{\Sigma}_y = \beta^{-1}\mathbf{I} + \nu\mathbf{H}\mathbf{H}^T \quad (\text{A.16})$$

である．スカラー補助変数 z を用いて，

$$z\nu - z_0 \geq \log |\boldsymbol{\Sigma}_y| = \log |\beta^{-1}\mathbf{I} + \nu\mathbf{H}\mathbf{H}^T|$$

が成立するので，補助的コスト関数を

$$\tilde{\mathcal{F}}(\nu, z) = -\frac{1}{2}(z\nu - z_0) - \frac{1}{2} [\beta \|\mathbf{y} - \mathbf{H}\bar{\mathbf{x}}\|^2 + \nu^{-1} \|\bar{\mathbf{x}}\|^2]$$

と定義すれば，必ず，

$$\log p(\mathbf{y}|\nu) \geq \tilde{\mathcal{F}}(\nu, z)$$

が成立するため，ボクセル分散 ν の更新解は

$$\hat{\nu} = \underset{\nu}{\operatorname{argmax}} \tilde{\mathcal{F}}(\nu, z) \quad (\text{A.17})$$

から求めることができる．

補助変数 z の更新値 \hat{z} は式 (5.46) すなわち

$$\hat{z} = \frac{\partial}{\partial \nu} \log |\boldsymbol{\Sigma}_y|$$

から求まる．ここで，

$$\frac{\partial}{\partial \nu} \log |\boldsymbol{\Sigma}_y| = \operatorname{tr} \left[\boldsymbol{\Sigma}_y^{-1} \frac{\partial}{\partial \nu} \boldsymbol{\Sigma}_y \right] \quad (\text{A.18})$$

であり ,

$$\frac{\partial}{\partial \nu} \Sigma_y = \frac{\partial}{\partial \nu} \left[\beta^{-1} \mathbf{I} + \nu \mathbf{H} \mathbf{H}^T \right] = \mathbf{H} \mathbf{H}^T \quad (\text{A.19})$$

であるので , 結局 ,

$$\hat{z} = \text{tr} \left[\Sigma_y^{-1} \mathbf{H} \mathbf{H}^T \right] = \text{tr} \left(\mathbf{H}^T \Sigma_y^{-1} \mathbf{H} \right) \quad (\text{A.20})$$

を得る .

次に , ν の更新値 $\hat{\nu}$ は ,

$$\hat{\nu} = \underset{\nu}{\text{argmax}} \tilde{\mathcal{F}}(\nu, z) = \underset{\nu}{\text{argmin}} \left[z\nu + \nu^{-1} \|\bar{\mathbf{x}}\|^2 \right] \quad (\text{A.21})$$

から求めることができる .

$$\frac{\partial}{\partial \nu} \left[z\nu + \nu^{-1} \|\bar{\mathbf{x}}\|^2 \right] = z - \nu^{-2} \|\bar{\mathbf{x}}\|^2 = 0$$

より , 式 (A.20) を用い

$$\hat{\nu} = \sqrt{\frac{\|\bar{\mathbf{x}}\|^2}{z}} = \sqrt{\frac{\|\bar{\mathbf{x}}\|^2}{\text{tr} \left[\mathbf{H}^T \Sigma_y^{-1} \mathbf{H} \right]}} \quad (\text{A.22})$$

を得る . すなわち , ν を上式を用いて更新し , β は式 (4.33) を用いて更新することにより , L_2 ノルム正則化解を正則化パラメータを更新しながら求めることができる .