

第1章

補足資料

記号の用意

\mathbb{R} 実数全体の集合

\mathbb{N} 自然数全体の集合

x スカラー

\mathbf{x} ベクトル (デフォルトは縦ベクトル)

X 確率変数

\mathbf{X} 行列

$\text{diag}(a_1, \dots, a_n)$ 対角成分が a_1, \dots, a_n であるような $n \times n$ 行列

\mathcal{X} 集合

$\mathbf{x}^\top, \mathbf{X}^\top$ ベクトル \mathbf{x} や行列 \mathbf{X} の転置

\mathbf{X}^{-1} 行列 \mathbf{X} の逆行列

$|\mathbf{X}|$ 行列 \mathbf{X} の行列式

$\text{tr}(\mathbf{X})$ 行列 \mathbf{X} の跡 (トレース)

$\|\mathbf{x}\|$ ベクトル \mathbf{x} のユークリッドノルム

$\hat{\pi}$ 推定値または近似値

$\mathbf{1}_A(\mathbf{x})$ 事象 A の指示関数

$X \sim P$ 確率変数 X が確率分布 P に従う

$\mathbb{P}(A)$ 事象 A が成り立つ確率

$\mathbb{E}[X]$ 確率変数 X の期待値

$\text{Cov}[X, Y]$ 確率変数 X と Y の共分散

$H(X)$ 確率変数 X の微分エントロピー

$\text{KL}(X\|Y)$ 確率変数 X の確率変数 Y に対するカルバック・ライブラー情報量

$x \propto y$ x が y に比例する

$\mathcal{N}(\boldsymbol{\mu}, \Sigma)$ 平均ベクトル $\boldsymbol{\mu}$, 共分散行列 Σ の多変量正規分布

$\mathcal{GP}(\boldsymbol{\mu}, k)$ 平均関数 $\boldsymbol{\mu}$, カーネル関数 k のガウス過程

D_n n 回の目的関数の観測の結果得られた入力と出力のペアのデータ
 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$

1.1 線形代数の種々の結果

ここでは本文で用いる種々の結果のうち、線形代数の分野でよく知られているものを列挙します。

定理 1.1.1 (逆行列の微分). 行列 \mathbf{A} は正則であって、かつ $|\mathbf{A}| > 0$ であるような $n \times n$ 行列とします。このとき、以下が成り立ちます。

- $\frac{\partial}{\partial t} \log |\mathbf{A}| = \text{tr} \left(\frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1} \right)$
- $\frac{\partial}{\partial t} \mathbf{A}^{-1} = -\mathbf{A}^{-1} \frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1}$

Proof. 第一式は以下のように示すことができます。まず、

$$\begin{aligned} \frac{\partial}{\partial t} \log |\mathbf{A}| &= \frac{1}{|\mathbf{A}|} \frac{\partial}{\partial t} |\mathbf{A}| \\ &= \frac{1}{|\mathbf{A}|} \sum_{i=1}^n \sum_{j=1}^n \frac{\partial |\mathbf{A}|}{\partial A_{ij}} \frac{\partial A_{ij}}{\partial t} \end{aligned} \quad (1.1)$$

です。 $\frac{\partial |\mathbf{A}|}{\partial A_{ij}}$ について考えるために、余因子展開を考えます。

$$|\mathbf{A}| = \sum_{k=1}^n A_{ik} \tilde{A}_{ik} \quad (1.2)$$

ただし \tilde{A}_{ik} は \mathbf{A} の (i, j) 余因子で、 \mathbf{A} の i 行目と k 列目削除して得られる行列の行列式に $(-1)^{i+k}$ をかけたものです。式 (1.2) の両辺を A_{ij} で微分して以下を得ます。

$$\begin{aligned} \frac{\partial |\mathbf{A}|}{\partial A_{ij}} &= \sum_{k=1}^n \left(\frac{\partial A_{ik}}{\partial A_{ij}} \tilde{A}_{ik} + A_{ik} \frac{\partial \tilde{A}_{ik}}{\partial A_{ij}} \right) \\ &= \sum_{k=1}^n \left(\delta_{kj} \tilde{A}_{ik} + A_{ik} \frac{\partial \tilde{A}_{ik}}{\partial A_{ij}} \right) \\ &= \tilde{A}_{ij} \end{aligned} \quad (1.3)$$

ここで、 δ_{kj} は $k = j$ のときにのみ 1 をとりそれ以外では 0 をとる値であり、 (i, k) 余因子は A_{ij} に依存し得ないことを用いました。ここで、 (j, i) 余因子を ij 成分とする余因子行列 $\tilde{\mathbf{A}}$ は、 $\mathbf{A}^{-1} = \frac{1}{|\mathbf{A}|} \tilde{\mathbf{A}}$ を満たしますか

ら、式 (1.3) は

$$\begin{aligned}\frac{\partial |\mathbf{A}|}{\partial \mathbf{A}_{ij}} &= \tilde{\mathbf{A}}_{ij} \\ &= |\mathbf{A}|(\mathbf{A}^{-1})_{ji}\end{aligned}\tag{1.4}$$

これを式 (1.1) に代入して、

$$\begin{aligned}\frac{\partial}{\partial t} \log |\mathbf{A}| &= \frac{1}{|\mathbf{A}|} \sum_{i=1}^n \sum_{j=1}^n \frac{\partial |\mathbf{A}|}{\partial \mathbf{A}_{ij}} \frac{\partial \mathbf{A}_{ij}}{\partial t} \\ &= \frac{1}{|\mathbf{A}|} \sum_{i=1}^n \sum_{j=1}^n |\mathbf{A}|(\mathbf{A}^{-1})_{ji} \frac{\partial \mathbf{A}_{ij}}{\partial t} \\ &= \sum_{i=1}^n \sum_{j=1}^n \frac{\partial \mathbf{A}_{ij}}{\partial t} (\mathbf{A}^{-1})_{ji} \\ &= \sum_{i=1}^n \left(\frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1} \right)_{ii} \\ &= \text{tr} \left(\frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1} \right)\end{aligned}\tag{1.5}$$

よって示されました。

第二式を示すには、 $\mathbf{A}\mathbf{A}^{-1} = \mathbf{I}_n$ の両辺を微分します。

$$\frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1} + \mathbf{A} \frac{\partial \mathbf{A}^{-1}}{\partial t} = \mathbf{O}\tag{1.6}$$

すなわち

$$\mathbf{A} \frac{\partial \mathbf{A}^{-1}}{\partial t} = -\frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1}\tag{1.7}$$

左から \mathbf{A}^{-1} をかけて、所望の等式を得ます。

$$\frac{\partial \mathbf{A}^{-1}}{\partial t} = -\mathbf{A}^{-1} \frac{\partial \mathbf{A}}{\partial t} \mathbf{A}^{-1}\tag{1.8}$$

□

1.2 確率論の種々の結果

ここでは本文で用いる種々の結果のうち、確率論の分野でよく知られて

いるものを列挙します。

定理 1.2.1 (正規分布の積). 確率密度関数 $p(\mathbf{z})$ が二つの正規分布 $\mathcal{N}(\mathbf{z} \mid \boldsymbol{\mu}_1, \Sigma_1), \mathcal{N}(\mathbf{z} \mid \boldsymbol{\mu}_2, \Sigma_2)$ の積に比例することが分かっているならば、 $p(\mathbf{z})$ 自体も正規分布 $\mathcal{N}(\mathbf{z} \mid \bar{\boldsymbol{\mu}}, \bar{\Sigma})$ となります。ただし、

$$\begin{aligned}\bar{\boldsymbol{\mu}} &= \bar{\Sigma} (\Sigma_1^{-1} \boldsymbol{\mu}_1 + \Sigma_2^{-1} \boldsymbol{\mu}_2) \\ \bar{\Sigma} &= (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1}\end{aligned}\tag{1.9}$$

です。

Proof. 単純に、 \mathbf{z} に関係のない定数倍を無視して計算していくと得られます。

$$\begin{aligned}p(\mathbf{z}) &\propto \mathcal{N}(\mathbf{z} \mid \boldsymbol{\mu}_1, \Sigma_1) \mathcal{N}(\mathbf{z} \mid \boldsymbol{\mu}_2, \Sigma_2) \\ &\propto \exp\left(-\frac{1}{2}(\mathbf{z} - \boldsymbol{\mu}_1)^T \Sigma_1^{-1} (\mathbf{z} - \boldsymbol{\mu}_1)\right) \times \\ &\quad \exp\left(-\frac{1}{2}(\mathbf{z} - \boldsymbol{\mu}_2)^T \Sigma_2^{-1} (\mathbf{z} - \boldsymbol{\mu}_2)\right) \\ &\propto \exp\left(-\frac{1}{2}\left((\mathbf{z} - \boldsymbol{\mu}_1)^T \Sigma_1^{-1} (\mathbf{z} - \boldsymbol{\mu}_1) + (\mathbf{z} - \boldsymbol{\mu}_2)^T \Sigma_2^{-1} (\mathbf{z} - \boldsymbol{\mu}_2)\right)\right) \\ &\propto \exp\left(-\frac{1}{2}\left(\mathbf{z}^T (\Sigma_1^{-1} + \Sigma_2^{-1}) \mathbf{z} - 2\mathbf{z}^T (\Sigma_1^{-1} \boldsymbol{\mu}_1 + \Sigma_2^{-1} \boldsymbol{\mu}_2)\right)\right) \\ &\propto \exp\left(-\frac{1}{2}\left(\mathbf{z} - (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} (\Sigma_1^{-1} \boldsymbol{\mu}_1 + \Sigma_2^{-1} \boldsymbol{\mu}_2)\right)^T \right. \\ &\quad \left. (\Sigma_1^{-1} + \Sigma_2^{-1}) \right. \\ &\quad \left. \left(\mathbf{z} - (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} (\Sigma_1^{-1} \boldsymbol{\mu}_1 + \Sigma_2^{-1} \boldsymbol{\mu}_2)\right)\right) \\ &= \exp\left(-\frac{1}{2}(\mathbf{z} - \bar{\boldsymbol{\mu}})^T \bar{\Sigma}^{-1} (\mathbf{z} - \bar{\boldsymbol{\mu}})\right)\end{aligned}\tag{1.10}$$

最左辺は \mathbf{z} について確率密度関数であると分かっているので、 $p(\mathbf{z}) = \mathcal{N}(\mathbf{z} \mid \bar{\boldsymbol{\mu}}, \bar{\Sigma})$ です。□

定理 1.2.2 (正規分布の比). 確率密度関数 $p(z)$ が二つの正規分布 $\mathcal{N}(z | \mu_1, \Sigma_1), \mathcal{N}(z | \mu_2, \Sigma_2)$ の比に比例することが分かっているならば、 $p(z)$ 自体も正規分布 $\mathcal{N}(z | \bar{\mu}, \bar{\Sigma})$ となります。ただし、

$$\begin{aligned}\bar{\mu} &= \bar{\Sigma} (\Sigma_1^{-1} \mu_1 - \Sigma_2^{-1} \mu_2) \\ \bar{\Sigma} &= (\Sigma_1^{-1} - \Sigma_2^{-1})^{-1}\end{aligned}\tag{1.11}$$

です。

Proof. $p(z) \propto \mathcal{N}(z | \mu_1, \Sigma_1) / \mathcal{N}(z | \mu_2, \Sigma_2)$ であるとき、 $p(z)$ も正規分布になることは、指数部分が z の二次式であって、かつこれ以外に z への依存がないことから明らかです。そこで $p(z) = \mathcal{N}(z | \bar{\mu}, \bar{\Sigma})$ とおいて、 $\bar{\mu}, \bar{\Sigma}$ を求めます。

$$\begin{aligned}\mathcal{N}(z | \bar{\mu}, \bar{\Sigma}) &\propto \mathcal{N}(z | \mu_1, \Sigma_1) / \mathcal{N}(z | \mu_2, \Sigma_2) \\ \Leftrightarrow \mathcal{N}(z | \mu_1, \Sigma_1) &\propto \mathcal{N}(z | \bar{\mu}, \bar{\Sigma}) \mathcal{N}(z | \mu_2, \Sigma_2)\end{aligned}\tag{1.12}$$

定理 1.2.1 より、以下が成り立ちます。

$$\begin{aligned}\mu_1 &= \Sigma_1 (\bar{\Sigma}^{-1} \bar{\mu} + \Sigma_2^{-1} \mu_2) \\ \Sigma_1 &= (\bar{\Sigma}^{-1} + \Sigma_2^{-1})^{-1}\end{aligned}\tag{1.13}$$

これを整理して、以下を得ます。

$$\begin{aligned}\bar{\mu} &= \bar{\Sigma} (\Sigma_1^{-1} \mu_1 - \Sigma_2^{-1} \mu_2) \\ \bar{\Sigma} &= (\Sigma_1^{-1} - \Sigma_2^{-1})^{-1}\end{aligned}\tag{1.14}$$

□

定理 1.2.3 (正規分布に対するカルバック・ライブラー情報量の最小化). \mathbb{R} 上の確率分布 $p(x)$ が与えられており、平均と分散が有限であるとします。 \mathbb{R} 上の正規分布 $q(x)$ の中で、 $p(x)$ の $q(x)$ に対するカルバック・ライブラー情報量 $\text{KL}(p(x) \| q(x))$ を最小化するものは、 $p(x)$ と平均と分散が一致するものです。^a

a 証明は省略しますが、この定理はより高次元でも成立します。

Proof. $p(x)$ の平均を m , 分散を v^2 とします。また $q(x) = \mathcal{N}(x | \mu, \sigma^2)$ と置きます。我々が最小化したい式は以下のように変形できます。

$$\begin{aligned} \text{KL}(p(x)||q(x)) &= \int p(x) \log \left(\frac{p(x)}{q(x)} \right) dx \\ &= \int p(x) \log \left(p(x) \sqrt{2\pi\sigma^2} \exp \left(\frac{(x-\mu)^2}{2\sigma^2} \right) \right) dx \\ &= \frac{1}{2} \log(2\pi\sigma^2) \\ &\quad + \int \frac{(x-\mu)^2}{2\sigma^2} p(x) dx + \int p(x) \log p(x) dx \end{aligned} \quad (1.15)$$

最右辺を μ, σ^2 でそれぞれ微分して以下を得ます。

$$\begin{cases} \int \frac{x-\mu}{\sigma^2} p(x) dx = \frac{1}{\sigma^2} (m - \mu) \\ \frac{1}{2\sigma^2} - \int \frac{(x-\mu)^2}{2\sigma^4} p(x) dx = \frac{1}{2\sigma^4} (\sigma^2 - v^2) \end{cases} \quad (1.16)$$

よってそれぞれ $\mu = m, \sigma^2 = v^2$ で 0 となり、これらを境に上式は負から正に符号変化するので、このとき最小値が達成されます。□

定理 1.2.4 (正規分布と標準正規分布の累積分布関数の積の積分).

$\sigma \neq 0, v \neq 0$ の時、以下の式が成り立ちます。

$$\int_{-\infty}^{\infty} \mathcal{N}(x | \mu, \sigma^2) \Phi \left(\frac{x-m}{v} \right) dx = \Phi \left(\frac{\mu-m}{v\sqrt{1+\frac{\sigma^2}{v^2}}} \right) \quad (1.17)$$

Proof. まず $v > 0$ とします。計算すべき左辺は以下のように変形されます。

$$\begin{aligned}
& \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
&= \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \int_{-\infty}^{\frac{x-m}{v}} \mathcal{N}(y \mid 0, 1) dy dx \\
&= \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \int_{-\infty}^x \mathcal{N}(y \mid m, v^2) dy dx \\
&= \int_{-\infty}^{\infty} \int_{-\infty}^x \frac{1}{2\pi\sigma v} \exp\left(-\frac{(y-m)^2}{2v^2} - \frac{(x-\mu)^2}{2\sigma^2}\right) dy dx
\end{aligned} \tag{1.18}$$

$z = y - x + \mu - m, w = x - \mu$ と変数変換します。

$$\begin{pmatrix} w \\ z \end{pmatrix} = \begin{pmatrix} x - \mu \\ y - x + \mu - m \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} + \begin{pmatrix} -\mu \\ \mu - m \end{pmatrix} \tag{1.19}$$

より、この変換のヤコビアンは

$$\begin{vmatrix} 1 & 0 \\ -1 & 1 \end{vmatrix} = 1 \tag{1.20}$$

です。また、積分領域は $\{(x, y) \mid y \leq x\}$ であるので、

$$\begin{aligned}
\begin{pmatrix} x \\ y \end{pmatrix} &= \begin{pmatrix} 1 & 0 \\ -1 & 1 \end{pmatrix}^{-1} \left(\begin{pmatrix} w \\ z \end{pmatrix} - \begin{pmatrix} -\mu \\ \mu - m \end{pmatrix} \right) \\
&= \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} w + \mu \\ z - \mu + m \end{pmatrix} \\
&= \begin{pmatrix} w + \mu \\ w + z + m \end{pmatrix}
\end{aligned} \tag{1.21}$$

より、 $\{(w, z) \mid \infty \leq w \leq \infty, -\infty \leq z \leq \mu - m\}$ と変換されます。よって、以下を得ます。

$$\begin{aligned}
 & \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
 &= \int_{-\infty}^{\infty} \int_{-\infty}^x \frac{1}{2\pi\sigma v} \exp\left(-\frac{(y-m)^2}{2v^2} - \frac{(x-\mu)^2}{2\sigma^2}\right) dy dx \\
 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\mu-m} \frac{1}{2\pi\sigma v} \exp\left(-\frac{(w+z)^2}{2v^2} - \frac{w^2}{2\sigma^2}\right) dz dw \\
 &= \int_{-\infty}^{\mu-m} \int_{-\infty}^{\infty} \frac{1}{2\pi\sigma v} \exp\left(-\frac{(w+z)^2}{2v^2} - \frac{w^2}{2\sigma^2}\right) dw dz \\
 &= \int_{-\infty}^{\mu-m} \int_{-\infty}^{\infty} \frac{1}{2\pi\sigma v} \exp\left(-\frac{1}{2} \begin{pmatrix} w \\ z \end{pmatrix}^T \begin{pmatrix} \frac{1}{v^2} + \frac{1}{\sigma^2} & \frac{1}{v^2} \\ \frac{1}{v^2} & \frac{1}{v^2} \end{pmatrix} \begin{pmatrix} w \\ z \end{pmatrix}\right) dw dz
 \end{aligned} \tag{1.22}$$

ここで、

$$\left| \begin{array}{cc} \frac{1}{v^2} + \frac{1}{\sigma^2} & \frac{1}{v^2} \\ \frac{1}{v^2} & \frac{1}{v^2} \end{array} \right| = \left(\frac{1}{v^2} + \frac{1}{\sigma^2}\right) \frac{1}{v^2} - \frac{1}{v^2} \frac{1}{v^2} = \frac{1}{v^2\sigma^2} \tag{1.23}$$

であるため、

$$\begin{pmatrix} \frac{1}{v^2} + \frac{1}{\sigma^2} & \frac{1}{v^2} \\ \frac{1}{v^2} & \frac{1}{v^2} \end{pmatrix}^{-1} = v^2\sigma^2 \begin{pmatrix} \frac{1}{v^2} & -\frac{1}{v^2} \\ -\frac{1}{v^2} & \frac{1}{v^2} + \frac{1}{\sigma^2} \end{pmatrix} = \begin{pmatrix} \sigma^2 & -\sigma^2 \\ -\sigma^2 & v^2 + \sigma^2 \end{pmatrix} \tag{1.24}$$

よって、式 (1.22) は以下のように変形されます。

$$\begin{aligned}
& \int_{-\infty}^{\mu-m} \int_{-\infty}^{\infty} \frac{1}{2\pi\sigma v} \exp\left(-\frac{1}{2} \begin{pmatrix} w \\ z \end{pmatrix}^T \begin{pmatrix} \frac{1}{v^2} + \frac{1}{\sigma^2} & \frac{1}{v^2} \\ \frac{1}{v^2} & \frac{1}{v^2} \end{pmatrix} \begin{pmatrix} w \\ z \end{pmatrix}\right) dw dz \\
&= \int_{-\infty}^{\mu-m} \int_{-\infty}^{\infty} \mathcal{N}\left(\begin{pmatrix} w \\ z \end{pmatrix} \mid \mathbf{0}, \begin{pmatrix} \sigma^2 & -\sigma^2 \\ -\sigma^2 & v^2 + \sigma^2 \end{pmatrix}\right) dw dz \\
&= \int_{-\infty}^{\mu-m} \mathcal{N}(z \mid 0, v^2 + \sigma^2) dz \\
&= \int_{-\infty}^{\frac{\mu-m}{\sqrt{v^2+\sigma^2}}} \mathcal{N}(z \mid 0, 1) dz \\
&= \Phi\left(\frac{\mu-m}{\sqrt{v^2+\sigma^2}}\right) \\
&= \Phi\left(\frac{\mu-m}{v\sqrt{1+\frac{\sigma^2}{v^2}}}\right)
\end{aligned} \tag{1.25}$$

以上から、 $v > 0$ の時に等式が示されました。 $v < 0$ の時は、 $\Phi(-z) = 1 - \Phi(z)$ を用いると以下のように計算できます。

$$\begin{aligned}
& \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
&= \int_{-\infty}^{\infty} \mathcal{N}(x \mid \mu, \sigma^2) \left(1 - \Phi\left(\frac{x-m}{-v}\right)\right) dx \\
&= 1 - \Phi\left(\frac{\mu-m}{-v\sqrt{1+\frac{\sigma^2}{v^2}}}\right) \\
&= \Phi\left(\frac{\mu-m}{v\sqrt{1+\frac{\sigma^2}{v^2}}}\right)
\end{aligned} \tag{1.26}$$

□

定理 1.2.5 (正規分布と標準正規分布の累積分布関数の積の一次モーメント). $\sigma \neq 0, v \neq 0$ とします。また

$$z^* = \frac{\mu - m}{v\sqrt{1 + \frac{\sigma^2}{v^2}}} \quad (1.27)$$

と置きます。このとき、以下の式が成り立ちます。

$$\int_{-\infty}^{\infty} x \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx = \mu \Phi(z^*) + \frac{\sigma^2 \phi(z^*)}{v\sqrt{1 + \frac{\sigma^2}{v^2}}} \quad (1.28)$$

ただし、 $\phi(z)$ は標準正規分布の確率密度関数です。

Proof. 示すべき等式の右辺を I_1 と置きます。定理 1.2.4 より、以下の式が成り立ちます。

$$\int_{-\infty}^{\infty} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx = \Phi(z^*) \quad (1.29)$$

両辺を μ で微分します。被積分関数は連続関数なので微分と積分は交換できて以下が成り立ちます。

$$\int_{-\infty}^{\infty} \frac{\partial}{\partial \mu} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx = \frac{\partial \Phi(z^*)}{\partial \mu} \quad (1.30)$$

式 (1.30) の左辺は

$$\begin{aligned} & \int_{-\infty}^{\infty} \frac{\partial}{\partial \mu} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx \\ &= \int_{-\infty}^{\infty} \frac{x - \mu}{\sigma^2} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx \\ &= \frac{1}{\sigma^2} \left(I_1 - \mu \int_{-\infty}^{\infty} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx \right) \\ &= \frac{1}{\sigma^2} (I_1 - \mu \Phi(z^*)) \end{aligned} \quad (1.31)$$

となります。式 (1.30) の右辺は

$$\begin{aligned}
\frac{\partial \Phi(z^*)}{\partial \mu} &= \phi(z^*) \frac{\partial z^*}{\partial \mu} \\
&= \phi(z^*) \frac{1}{v\sqrt{1 + \frac{\sigma^2}{v^2}}} \\
&= \frac{\phi(z^*)}{v\sqrt{1 + \frac{\sigma^2}{v^2}}}
\end{aligned} \tag{1.32}$$

よって式 (1.31) と式 (1.32) を合わせて以下を得ます。

$$\begin{aligned}
\frac{1}{\sigma^2} (I_1 - \mu\Phi(z^*)) &= \frac{\phi(z^*)}{v\sqrt{1 + \frac{\sigma^2}{v^2}}} \\
\Leftrightarrow I_1 &= \mu\Phi(z^*) + \frac{\sigma^2\phi(z^*)}{v\sqrt{1 + \frac{\sigma^2}{v^2}}}
\end{aligned} \tag{1.33}$$

よって示されました。 \square

定理 1.2.6 (正規分布と標準正規分布の累積分布関数の積の二次モーメント). $\sigma \neq 0, v \neq 0$ とします。また

$$z^* = \frac{\mu - m}{v\sqrt{1 + \frac{\sigma^2}{v^2}}} \tag{1.34}$$

と置きます。また定理 1.2.5 の左辺を I_1 と置きます。このとき、以下の式が成り立ちます。

$$\begin{aligned}
&\int_{-\infty}^{\infty} x^2 \mathcal{N}(x \mid \mu, \sigma^2) \Phi\left(\frac{x - m}{v}\right) dx \\
&= 2\mu I_1 + (\sigma^2 - \mu^2)\Phi(z^*) - \frac{\sigma^4 z^* \phi(z^*)}{v^2 + \sigma^2}
\end{aligned} \tag{1.35}$$

Proof. 示したい等式の左辺を I_2 と置きます。定理 1.2.5 の証明中の式 (1.30) より、

$$\begin{aligned}
 \int_{-\infty}^{\infty} \frac{\partial}{\partial \mu} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx &= \frac{\partial \Phi(z^*)}{\partial \mu} \\
 \Leftrightarrow \int_{-\infty}^{\infty} \frac{x-\mu}{\sigma^2} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx &= \frac{\phi(z^*)}{v\sqrt{1+\frac{\sigma^2}{v^2}}} \quad (1.36)
 \end{aligned}$$

両辺をさらに μ で微分します。

$$\begin{aligned}
 \int_{-\infty}^{\infty} \frac{\partial}{\partial \mu} \frac{x-\mu}{\sigma^2} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx &= \frac{\partial}{\partial \mu} \frac{\phi(z^*)}{v\sqrt{1+\frac{\sigma^2}{v^2}}} \\
 \Leftrightarrow \int_{-\infty}^{\infty} \left(-\frac{1}{\sigma^2} + \frac{(x-\mu)^2}{\sigma^4}\right) \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
 &= \frac{\phi'(z^*)}{\left(v\sqrt{1+\frac{\sigma^2}{v^2}}\right)^2} \\
 \Leftrightarrow \frac{1}{\sigma^4} \int_{-\infty}^{\infty} x^2 \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
 &\quad - \frac{2\mu}{\sigma^4} \int_{-\infty}^{\infty} x \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
 &\quad + \left(\frac{\mu^2}{\sigma^4} - \frac{1}{\sigma^2}\right) \int_{-\infty}^{\infty} \mathcal{N}(x | \mu, \sigma^2) \Phi\left(\frac{x-m}{v}\right) dx \\
 &= \frac{-z^* \phi(z^*)}{v^2 + \sigma^2} \\
 \Leftrightarrow \frac{1}{\sigma^4} I_2 - \frac{2\mu}{\sigma^4} I_1 + \left(\frac{\mu^2}{\sigma^4} - \frac{1}{\sigma^2}\right) \Phi(z^*) &= \frac{-z^* \phi(z^*)}{v^2 + \sigma^2} \\
 \Leftrightarrow I_2 = 2\mu I_1 + (\sigma^2 - \mu^2) \Phi(z^*) - \frac{\sigma^4 z^* \phi(z^*)}{v^2 + \sigma^2}
 \end{aligned}$$

よって示されました。 \square

1.3 書籍 3.6 節の詳細

本章では、書籍の 3.6 節にて扱ったエントロピー探索関数の計算の詳細を説明します。

さて、我々が計算したかったエントロピー探索獲得関数の値は以下でし

た。

$$\begin{aligned} & \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} [\text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*))] \\ &= \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} \left[\int p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \log \frac{p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y))}{u_{\mathcal{X}}(\mathbf{x}_*)} d\mathbf{x}_* \right] \end{aligned} \quad (1.37)$$

式 (1.37) の期待値の中身 $\text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*))$ を Monte Carlo 法により近似することを考えましょう。我々は、目的関数の定義域を Δ 個の点 $\mathbf{x}_1, \dots, \mathbf{x}_\Delta$ で近似しました。それらを用いて以下のように積分を近似します。

$$\begin{aligned} & \text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*)) \\ &= \int p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \log \frac{p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y))}{u_{\mathcal{X}}(\mathbf{x}_*)} d\mathbf{x}_* \\ &\simeq \frac{1}{\Delta} \sum_{i=1}^{\Delta} p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \log \frac{p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))}{u_{\mathcal{X}}(\mathbf{x}_i)} \end{aligned} \quad (1.38)$$

$u_{\mathcal{X}}$ は \mathcal{X} 上の一様分布なので、 $u_{\mathcal{X}}(\mathbf{x}_i) = 1/|\mathcal{X}|$ を代入して

$$\begin{aligned} & \text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*)) \\ &\simeq \frac{1}{\Delta} \sum_{i=1}^{\Delta} p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \log (|\mathcal{X}| p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))) \end{aligned} \quad (1.39)$$

これを式 (1.37) に代入すると以下を得ます。

$$\begin{aligned}
 & \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} [\text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*))] \\
 & \simeq \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} \left[\frac{1}{\Delta} \sum_{i=1}^{\Delta} p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \right. \\
 & \quad \left. \log(|\mathcal{X}| p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))) \right] \\
 & = \frac{1}{\Delta} \sum_{i=1}^{\Delta} \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} [p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \\
 & \quad \times \log(|\mathcal{X}| p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)))] \tag{1.40} \\
 & = \frac{1}{\Delta} \sum_{i=1}^{\Delta} \int_{-\infty}^{\infty} p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \\
 & \quad \times \log(|\mathcal{X}| p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))) p(y|\mathbf{x}, \mathcal{D}_n) dy
 \end{aligned}$$

我々は、 $p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))$ を期待値伝播法を用いて $q(\mathbf{x}_i | \boldsymbol{\mu}'_n, \boldsymbol{\kappa}'_n)$ として近似したのでした。この近似を用いると、さらに以下のように変形できます。

$$\begin{aligned}
 & \mathbb{E}_{p(y|\mathbf{x}, \mathcal{D}_n)} [\text{KL}(p_{\min}(\mathbf{x}_* | \mathcal{D}_n \cup (\mathbf{x}, y)) \| u_{\mathcal{X}}(\mathbf{x}_*))] \\
 & \simeq \frac{1}{\Delta} \sum_{i=1}^{\Delta} \int_{-\infty}^{\infty} p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y)) \\
 & \quad \times \log(|\mathcal{X}| p_{\min}(\mathbf{x}_i | \mathcal{D}_n \cup (\mathbf{x}, y))) p(y|\mathbf{x}, \mathcal{D}_n) dy \tag{1.41}
 \end{aligned}$$

また、期待値伝播法を用いることで、 q のパラメータ $\boldsymbol{\mu}'_n, \boldsymbol{\kappa}'_n$ による微分を計算することができました。すなわち、以下の値が計算できていることになりました。

1. $\frac{\partial q}{\partial \boldsymbol{\mu}'_n}$: 第 i 成分が $\frac{\partial q}{\partial \mu'_n(\mathbf{x}_i)}$ であるような Δ 次元ベクトル
2. $\frac{\partial^2 q}{\partial \boldsymbol{\mu}'_n^2}$: ij 成分が $\frac{\partial^2 q}{\partial \mu'_n(\mathbf{x}_i) \partial \mu'_n(\mathbf{x}_j)}$ であるような $\Delta \times \Delta$ 行列
3. $\frac{\partial q}{\partial \boldsymbol{\kappa}'_n}$: ij 成分が $\frac{\partial q}{\partial \kappa'_n(\mathbf{x}_i, \mathbf{x}_j)}$ であるような $\Delta \times \Delta$ 行列

エントロピー探索の元論文 [1] では、 y の関数として $q(\mathbf{x}_i | \boldsymbol{\mu}'_n, \boldsymbol{\kappa}'_n)$ を一次

近似¹ し、これを上式に代入することで積分を近似しています。以降の計算は省きますが、上記の q のパラメータ μ'_n, κ'_n による微分だけでなく、パラメータ μ'_n, κ'_n の y による微分などを計算する必要があり、非常に煩雑です。計算量としては $\Delta \times \Delta$ 行列の積計算が支配的で、 $O(\Delta^3)$ です。

以上のように、エントロピー探索獲得関数の関数値の計算は、各点 \mathbf{x} に対して、期待値伝播法による近似の部分が支配的で $O(\Delta^4)$ かかります。獲得関数の勾配の計算をしようと思えば、さらに近似計算が必要となり重い計算が必要となります。

1.4 書籍 3.7 節の詳細

1.4.1 書籍の式 (3.136) の計算

書籍の 3.7 節の 3.7.4 項における $p(\mathbf{f} | \mathcal{D}_n, C_1, C_2)$ を近似した式 (3.136) が \mathbf{f} についての正規分布であることを計算によって示します。まず、 $\mu_{\mathbf{f}|w=0,y,z}$ は z について線形であるため $\mu_{\mathbf{f}|w=0,y,z} = A\mathbf{z} + \mathbf{b}$ と置けます。さらに $\Sigma_{\mathbf{f}|w=0,y,z}$ は z に依存しないので、簡単のため $\Sigma_{\mathbf{f}|w=0,y,z} = C$ と置きます。

1 この近似計算には伊藤の補題 [2] が用いられていますが、著者の確認した限りでは、添字空間が多次元のガウス過程に対して適用することは一般には不可能であるため、その正当性には疑念が残ります。

$$\begin{aligned}
 & \int \mathcal{N}(\mathbf{f} \mid \boldsymbol{\mu}_f | w=0, \mathbf{y}, \mathbf{z}, \Sigma_{\mathbf{f} | w=0, \mathbf{y}, \mathbf{z}}) \mathcal{N}(\mathbf{z} \mid \bar{\boldsymbol{\mu}}, \bar{\Sigma}) d\mathbf{z} \\
 & \propto \int \exp\left(-\frac{1}{2}((\mathbf{f} - A\mathbf{z} - \mathbf{b})^T C^{-1}(\mathbf{f} - A\mathbf{z} - \mathbf{b}) + (\mathbf{z} - \bar{\boldsymbol{\mu}})^T \bar{\Sigma}^{-1}(\mathbf{z} - \bar{\boldsymbol{\mu}}))\right) d\mathbf{z} \\
 & \propto \int \exp\left(-\frac{1}{2}(\mathbf{z}^T (A^T C^{-1} A + \bar{\Sigma}^{-1}) \mathbf{z} \right. \\
 & \quad \left. - 2((\mathbf{f} - \mathbf{b})^T C^{-1} A + \bar{\boldsymbol{\mu}}^T \bar{\Sigma}^{-1}) \mathbf{z} + (\mathbf{f} - \mathbf{b})^T C^{-1}(\mathbf{f} - \mathbf{b}))\right) d\mathbf{z} \\
 & \propto \left[\int \exp\left(-\frac{1}{2}\left((\mathbf{z} - (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}}))^T \right. \right. \\
 & \quad \left. \left. (A^T C^{-1} A + \bar{\Sigma}^{-1}) (\mathbf{z} - (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}}))\right)\right) \right] \\
 & \times \exp\left(-\frac{1}{2}(\mathbf{f} - \mathbf{b})^T C^{-1}(\mathbf{f} - \mathbf{b}) \right. \\
 & \quad \left. + \frac{1}{2} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}})^T (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}})\right) \\
 & \propto \exp\left(-\frac{1}{2}(\mathbf{f} - \mathbf{b})^T C^{-1}(\mathbf{f} - \mathbf{b}) \right. \\
 & \quad \left. + \frac{1}{2} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}})^T (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} (A^T C^{-1}(\mathbf{f} - \mathbf{b}) + \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}})\right) \\
 & \propto \exp\left(-\frac{1}{2}(\mathbf{f}^T (C^{-1} - C^{-1} A (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} A^T C^{-1}) \mathbf{f} \right. \\
 & \quad \left. - 2(C^{-1} \mathbf{b} - C^{-1} A (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} (A^T C^{-1} \mathbf{b} - \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}}))^T \mathbf{f})\right) \\
 & = \exp\left(-\frac{1}{2}(\mathbf{f}^T (C + A \bar{\Sigma} A^T)^{-1} \mathbf{f} \right. \\
 & \quad \left. - 2((C + A \bar{\Sigma} A^T)^{-1} \mathbf{b} + C^{-1} A (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}})^T \mathbf{f})\right) \\
 & \propto \exp\left(-\frac{1}{2}\left((\mathbf{f} - (C + A \bar{\Sigma} A^T)^{-1} ((C + A \bar{\Sigma} A^T)^{-1} \mathbf{b} + C^{-1} A (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}}))^T \right. \right. \\
 & \quad \left. \left. (C + A \bar{\Sigma} A^T)^{-1} (\mathbf{f} - (C + A \bar{\Sigma} A^T)^{-1} ((C + A \bar{\Sigma} A^T)^{-1} \mathbf{b} + C^{-1} A (A^T C^{-1} A + \bar{\Sigma}^{-1})^{-1} \bar{\Sigma}^{-1} \bar{\boldsymbol{\mu}}))\right)\right)
 \end{aligned}$$

よって、書籍の式 (3.136) は \mathbf{f} について確率分布なので、その分布は正規分布であり、平均ベクトルと共分散行列はそれぞれ

$$\begin{aligned}
\boldsymbol{\mu}_f &= (C + A\bar{\Sigma}A^T) \\
&\quad \times ((C + A\bar{\Sigma}A^T)^{-1}\mathbf{b} + C^{-1}A(A^TC^{-1}A + \bar{\Sigma}^{-1})^{-1}\bar{\Sigma}^{-1}\bar{\boldsymbol{\mu}}) \\
\Sigma_f &= C + A\bar{\Sigma}A^T
\end{aligned} \tag{1.42}$$

です。平均ベクトルは計算を行うとより簡単にできて以下のようになりません。

$$\begin{aligned}
\boldsymbol{\mu}_f &= (C + A\bar{\Sigma}A^T) ((C + A\bar{\Sigma}A^T)^{-1}\mathbf{b} + C^{-1}A(A^TC^{-1}A + \bar{\Sigma}^{-1})^{-1}\bar{\Sigma}^{-1}\bar{\boldsymbol{\mu}}) \\
&= \mathbf{b} + (C + A\bar{\Sigma}A^T)C^{-1}A(A^TC^{-1}A + \bar{\Sigma}^{-1})^{-1}\bar{\Sigma}^{-1}\bar{\boldsymbol{\mu}} \\
&= \mathbf{b} + (A + A\bar{\Sigma}A^TC^{-1}A)(A^TC^{-1}A + \bar{\Sigma}^{-1})^{-1}\bar{\Sigma}^{-1}\bar{\boldsymbol{\mu}} \\
&= \mathbf{b} + A\bar{\Sigma}(\bar{\Sigma}^{-1} + A^TC^{-1}A)(A^TC^{-1}A + \bar{\Sigma}^{-1})^{-1}\bar{\Sigma}^{-1}\bar{\boldsymbol{\mu}} \\
&= \mathbf{b} + A\bar{\boldsymbol{\mu}}
\end{aligned} \tag{1.43}$$

したがって、

$$\begin{aligned}
\boldsymbol{\mu}_f &= A\bar{\boldsymbol{\mu}} + \mathbf{b} \\
\Sigma_f &= C + A\bar{\Sigma}A^T
\end{aligned} \tag{1.44}$$

として、書籍の式 (3.136) は正規分布 $\mathcal{N}(\mathbf{f} \mid \boldsymbol{\mu}_f, \Sigma_f)$ と近似されます。

1.4.2 書籍の式 (3.138) の計算

書籍の式 (3.138) が

$$\frac{1}{Z} \Phi\left(\frac{f(\mathbf{x}) - m}{v}\right) \mathcal{N}(f(\mathbf{x}) \mid \mu, \sigma^2) \tag{1.45}$$

の形の確率分布となることは、以下のような計算によって確かめることができます。簡単のため $\mathbf{f} = (f(\mathbf{x}), f(\mathbf{x}_*)) = (f_1, f_2)^T$, $\boldsymbol{\mu}_f = (\mu_{f1}, \mu_{f2})^T$, $\Sigma_f = \begin{pmatrix} \Sigma_{f11} & \Sigma_{f12} \\ \Sigma_{f21} & \Sigma_{f22} \end{pmatrix}$ と置きます。すると

$$\begin{aligned}
& \int_{f(\mathbf{x}_*) \leq f(\mathbf{x})} \mathcal{N}(\mathbf{f} \mid \boldsymbol{\mu}_f, \Sigma_f) d\mathbf{f}(\mathbf{x}_*) \\
&= \int_{f_2 \leq f_1} \mathcal{N}(\mathbf{f} \mid \boldsymbol{\mu}_f, \Sigma_f) df_2 \\
&= \int_{f_2 \leq f_1} \mathcal{N}\left(\begin{pmatrix} f_1 \\ f_2 \end{pmatrix} \middle| \begin{pmatrix} \mu_{f1} \\ \mu_{f2} \end{pmatrix}, \begin{pmatrix} \Sigma_{f11} & \Sigma_{f12} \\ \Sigma_{f21} & \Sigma_{f22} \end{pmatrix}\right) df_2 \quad (1.46) \\
&\propto \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2}(\mathbf{f} - \boldsymbol{\mu}_f)^T \Sigma_f^{-1}(\mathbf{f} - \boldsymbol{\mu}_f)\right) df_2 \\
&\propto \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2}\left(\mathbf{f}^T \Sigma_f^{-1} \mathbf{f} - 2\boldsymbol{\mu}_f^T \Sigma_f^{-1} \mathbf{f}\right)\right) df_2
\end{aligned}$$

簡単のため $A = \Sigma_f^{-1} = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$, $\mathbf{b} = \Sigma_f^{-1} \boldsymbol{\mu}_f = (b_1, b_2)^T$ と置きます。共分散行列の対称性より $A_{12} = A_{21}$ です。すると

$$\begin{aligned}
& d \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2} \left(\mathbf{f}^T \Sigma_{\mathbf{f}}^{-1} \mathbf{f} - 2\boldsymbol{\mu}_{\mathbf{f}}^T \Sigma_{\mathbf{f}}^{-1} \mathbf{f}\right)\right) df_2 \\
&= \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2} \left(\mathbf{f}^T \mathbf{A} \mathbf{f} - 2\mathbf{b}^T \mathbf{f}\right)\right) df_2 \\
&= \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2} \left(A_{22} f_2^2 + 2A_{12} f_1 f_2 + A_{11} f_1^2 - 2b_1 f_1 - 2b_2 f_2\right)\right) df_2 \\
&= \int_{-\infty}^{f_1} \exp\left(-\frac{1}{2} \left(A_{22} f_2^2 - 2(b_2 - A_{12} f_1) f_2 + A_{11} f_1^2 - 2b_1 f_1\right)\right) df_2 \\
&= \left[\int_{-\infty}^{f_1} \exp\left(-\frac{1}{2} \left(A_{22} (f_2 - A_{22}^{-1}(b_2 - A_{12} f_1))^2\right)\right) df_2 \right] \\
&\times \exp\left(-\frac{1}{2} (A_{11} f_1^2 - 2b_1 f_1) + \frac{1}{2} A_{22}^{-1} (b_2 - A_{12} f_1)^2\right) \\
&\propto \left[\int_{-\infty}^{f_1} \mathcal{N}(f_2 \mid A_{22}^{-1}(b_2 - A_{12} f_1), A_{22}^{-1}) df_2 \right] \\
&\times \exp\left(-\frac{1}{2} \left((A_{11} - A_{22} A_{12}^2) f_1^2 - 2(b_1 - A_{22} A_{12} b_2) f_1\right)\right) \\
&\propto \left[\int_{-\infty}^{\sqrt{A_{22}}(f_1 - A_{22}^{-1}(b_2 - A_{12} f_1))} \mathcal{N}(x \mid 0, 1) dx \right] \\
&\times \mathcal{N}(f_1 \mid (A_{11} - A_{22}^{-1} A_{12}^2)^{-1} (b_1 - A_{22}^{-1} A_{12} b_2), (A_{11} - A_{22}^{-1} A_{12}^2)^{-1}) \\
&= \Phi\left(\sqrt{A_{22}}(f_1 - A_{22}^{-1}(b_2 - A_{12} f_1))\right) \\
&\quad \times \mathcal{N}(f_1 \mid (A_{11} - A_{22}^{-1} A_{12}^2)^{-1} (b_1 - A_{22}^{-1} A_{12} b_2), \\
&\quad \quad \quad (A_{11} - A_{22}^{-1} A_{12}^2)^{-1})
\end{aligned}$$

よって、以下のように μ, σ, m, v を取れば、これは $\Phi\left(\frac{f_1 - m}{v}\right) \mathcal{N}(f_1 \mid \mu, \sigma^2)$ です。

$$\begin{cases} \mu &= (A_{11} - A_{22}^{-1} A_{12}^2)^{-1} (b_1 - A_{22}^{-1} A_{12} b_2) \\ \sigma &= \sqrt{(A_{11} - A_{22}^{-1} A_{12}^2)^{-1}} \\ m &= \frac{A_{22}^{-1}}{1 + A_{22}^{-1} A_{12}} b_2 \\ v &= \frac{1}{\sqrt{A_{22} (1 + A_{22}^{-1} A_{12})}} \end{cases} \quad (1.47)$$

A, \mathbf{b} はそれぞれ

$$\begin{aligned} A &= \Sigma_f^{-1} \\ &= \frac{1}{|\Sigma_f|} \begin{pmatrix} \Sigma_{f22} & -\Sigma_{f12} \\ -\Sigma_{f21} & \Sigma_{f11} \end{pmatrix} \\ \mathbf{b} &= \Sigma_f^{-1} \boldsymbol{\mu}_f \\ &= \frac{1}{|\Sigma_f|} \begin{pmatrix} \Sigma_{f22} & -\Sigma_{f12} \\ -\Sigma_{f21} & \Sigma_{f11} \end{pmatrix} \begin{pmatrix} \mu_{f1} \\ \mu_{f2} \end{pmatrix} \\ &= \frac{1}{|\Sigma_f|} \begin{pmatrix} \Sigma_{f22}\mu_{f1} - \Sigma_{f12}\mu_{f2} \\ -\Sigma_{f21}\mu_{f1} + \Sigma_{f11}\mu_{f2} \end{pmatrix} \end{aligned} \tag{1.48}$$

であるため、 μ, σ, m, v は以下のように計算されます。

$$\begin{aligned}
\mu &= (A_{11} - A_{22}^{-1}A_{12}^2)^{-1}(b_1 - A_{22}^{-1}A_{12}b_2) \\
&= |A|^{-1}(A_{22}b_1 - A_{12}b_2) \\
&= |\Sigma_f| \left(\frac{\Sigma_{f11}}{|\Sigma_f|}b_1 + \frac{\Sigma_{f12}}{|\Sigma_f|}b_2 \right) \\
&= \Sigma_{f11}b_1 + \Sigma_{f12}b_2 \\
&= \frac{1}{|\Sigma_f|} (\Sigma_{f11}(\Sigma_{f22}\mu_{f1} - \Sigma_{f12}\mu_{f2}) + \Sigma_{f12}(-\Sigma_{f12}\mu_{f1} + \Sigma_{f11}\mu_{f2})) \\
&= \frac{1}{|\Sigma_f|} (\Sigma_{f11}\Sigma_{f22} - \Sigma_{f12}\Sigma_{f21})\mu_{f1} \\
&= \frac{1}{|\Sigma_f|} |\Sigma_f| \mu_{f1} \\
&= \mu_{f1} \\
\sigma^2 &= (A_{11} - A_{22}^{-1}A_{12}^2)^{-1} \\
&= A_{22}(A_{11}A_{22} - A_{12}^2)^{-1} \\
&= A_{22}|A|^{-1} \\
&= \frac{1}{|\Sigma_f|} \Sigma_{f11} |\Sigma_f| \\
&= \Sigma_{f11} \\
m &= \frac{A_{22}^{-1}}{1 + A_{22}^{-1}A_{12}} b_2 \\
&= \frac{1}{A_{22} + A_{12}} b_2 \\
&= \frac{|\Sigma_f|}{\Sigma_{f11} - \Sigma_{f12}|\Sigma_f|} \frac{1}{|\Sigma_f|} (-\Sigma_{f12}\mu_{f1} + \Sigma_{f11}\mu_{f2}) \\
&= \frac{\Sigma_{f11}\mu_{f2} - \Sigma_{f12}\mu_{f1}}{\Sigma_{f11} - \Sigma_{f12}} \\
v^2 &= \frac{1}{A_{22}(1 + A_{22}^{-1}A_{12})^2} \\
&= \frac{A_{22}}{(A_{22} + A_{12})^2} \\
&= \frac{\frac{\Sigma_{f11}}{|\Sigma_f|}}{\left(\frac{\Sigma_{f11}}{|\Sigma_f|} - \frac{\Sigma_{f12}}{|\Sigma_f|} \right)^2} \\
&= \frac{|\Sigma_f| \Sigma_{f11}}{(\Sigma_{f11} - \Sigma_{f12})^2}
\end{aligned}$$

$$(1.49)$$

よって、定理 1.2.4 を用いると正規化定数 Z も計算できて、以下を得ます。

$$p(f(x) | \mathcal{D}_n, C_1, C_2, C_3) \simeq \frac{1}{Z} \Phi\left(\frac{f_1 - m}{v}\right) \mathcal{N}(f_1 | \mu_{f_1}, \Sigma_{f_{11}}) \quad (1.50)$$

ただし、

$$\begin{cases} m &= \frac{\Sigma_{f_{11}}\mu_{f_2} - \Sigma_{f_{12}}\mu_{f_1}}{\Sigma_{f_{11}} - \Sigma_{f_{12}}} \\ v &= \frac{\sqrt{|\Sigma_f| \Sigma_{f_{11}}}}{\Sigma_{f_{11}} - \Sigma_{f_{12}}} \\ Z &= \Phi\left(\frac{\mu_{f_1} - m}{v\sqrt{1 + \frac{\Sigma_{f_{11}}}{v^2}}}\right) \end{cases} \quad (1.51)$$

です。

1.4.3 書籍の式 (3.142) の計算

書籍の式 (3.142) を定める $\mu_n(\mathbf{x} | \mathbf{x}_*), \sigma_n^2(\mathbf{x} | \mathbf{x}_*)$ はそれぞれ以下のようにして計算することができます。簡単のため $z_* = \frac{\mu_{f_1} - m}{v\sqrt{1 + \frac{\Sigma_{f_{11}}}{v^2}}}$ と置きます。書籍の式 (3.141) より $Z = \Phi(z_*)$ です。定理 1.2.5 より、

$$\begin{aligned} \mu_n(\mathbf{x} | \mathbf{x}_*) &= \frac{1}{Z} \int f_1 \Phi\left(\frac{f_1 - m}{v}\right) \mathcal{N}(f_1 | \mu_{f_1}, \Sigma_{f_{11}}) df_1 \\ &= \frac{1}{\Phi(z_*)} \left(\mu_{f_1} + \Phi(z_*) + \frac{\Sigma_{f_{11}}\phi(z_*)}{v\sqrt{1 + \frac{\Sigma_{f_{11}}}{v^2}}} \right) \\ &= \mu_{f_1} + \frac{\Sigma_{f_{11}}\phi(z_*)}{\Phi(z_*)v\sqrt{1 + \frac{\Sigma_{f_{11}}}{v^2}}} \end{aligned} \quad (1.52)$$

また、定理 1.2.6 より

$$\begin{aligned}
& \sigma_n^2(\mathbf{x} \mid \mathbf{x}_*) \\
&= \frac{1}{Z} \int f_1^2 \Phi\left(\frac{f_1 - m}{v}\right) \mathcal{N}(f_1 \mid \mu_{f1}, \Sigma_{f11}) df_1 - \mu_n(\mathbf{x} \mid \mathbf{x}_*)^2 \\
&= \frac{1}{\Phi(z_*)} \left(2\mu_{f1} \Phi(z_*) \mu_n(\mathbf{x} \mid \mathbf{x}_*) + (\Sigma_{f11} - \mu_{f1}^2) \Phi(z_*) \right. \\
&\quad \left. - \frac{\Sigma_{f11}^2 z_* \phi(z_*)}{v^2 + \Sigma_{f11}} \right) - \mu_n(\mathbf{x} \mid \mathbf{x}_*)^2 \\
&= 2\mu_{f1} \left(\mu_{f1} + \frac{\Sigma_{f11} \phi(z_*)}{\Phi(z_*) v \sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \right) + \Sigma_{f11} - \mu_{f1}^2 \\
&\quad - \frac{\Sigma_{f11}^2 z_* \phi(z_*)}{\Phi(z_*) (v^2 + \Sigma_{f11})} - \left(\mu_{f1} + \frac{\Sigma_{f11} \phi(z_*)}{\Phi(z_*) v \sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \right)^2 \\
&= \left(\mu_{f11} + \frac{\Sigma_{f11} \phi(z_*)}{\Phi(z_*) v \sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \right) \left(\mu_{f11} - \frac{\Sigma_{f11} \phi(z_*)}{\Phi(z_*) v \sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \right) \\
&\quad + \Sigma_{f11} - \mu_{f1}^2 - \frac{\Sigma_{f11}^2 z_* \phi(z_*)}{\Phi(z_*) (v^2 + \Sigma_{f11})} \\
&= \Sigma_{f11} - \frac{\Sigma_{f11}^2 \phi(z_*)^2}{\Phi(z_*)^2 (v^2 + \Sigma_{f11})} - \frac{\Sigma_{f11}^2 z_* \phi(z_*)}{\Phi(z_*) (v^2 + \Sigma_{f11})} \\
&= \Sigma_{f11} - \frac{\Sigma_{f11}^2}{v^2 + \Sigma_{f11}} \frac{\phi(z_*)}{\Phi(z_*)} \left(\frac{\phi(z_*)}{\Phi(z_*)} + z_* \right)
\end{aligned}$$

ここで書籍の式 (3.141) を用いると

$$\begin{aligned}
 \frac{\Sigma_{f11}^2}{v^2 + \Sigma_{f11}} &= \frac{\Sigma_{f11}^2}{\frac{\sqrt{|\Sigma_f|^2 \Sigma_{f11}^2}}{(\Sigma_{f11} - \Sigma_{f12})^2} + \Sigma_{f11}} \\
 &= \frac{\Sigma_{f11}(\Sigma_{f11} - \Sigma_{f12})^2}{|\Sigma_f| + (\Sigma_{f11} - \Sigma_{f12})^2} \\
 &= \frac{\Sigma_{f11}(\Sigma_{f11} - \Sigma_{f12})^2}{\Sigma_{f11}\Sigma_{f22} - \Sigma_{f12}^2 + (\Sigma_{f11} - \Sigma_{f12})^2} \\
 &= \frac{\Sigma_{f11}(\Sigma_{f11} - \Sigma_{f12})^2}{\Sigma_{f11}\Sigma_{f22} + \Sigma_{f11}^2 - 2\Sigma_{f11}\Sigma_{f12}} \\
 &= \frac{(\Sigma_{f11} - \Sigma_{f12})^2}{\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12}} \\
 z_* &= \frac{\mu_{f1} - m}{v\sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \\
 &= \text{sign}(\Sigma_{f11} - \Sigma_{f12}) \frac{\mu_{f1} - m}{v^2 + \Sigma_{f11}} \\
 &= \text{sign}(\Sigma_{f11} - \Sigma_{f12}) \frac{\mu_{f1} - \frac{\Sigma_{f11}\mu_{f2} - \Sigma_{f12}\mu_{f1}}{\Sigma_{f11} - \Sigma_{f12}}}{\sqrt{\frac{\Sigma_{f11}^2(\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12})}{(\Sigma_{f11} - \Sigma_{f12})^2}}} \\
 &= \frac{\Sigma_{f11} - \Sigma_{f12}}{\Sigma_{f11}\sqrt{\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12}}} \frac{\Sigma_{f11}(\mu_{f1} - \mu_{f2})}{\Sigma_{f11} - \Sigma_{f12}} \\
 &= \frac{\mu_{f1} - \mu_{f2}}{\sqrt{\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12}}}
 \end{aligned} \tag{1.53}$$

よって、 $\mu_n(\mathbf{x} | \mathbf{x}_*)$ および $\sigma_n^2(\mathbf{x} | \mathbf{x}_*)$ に代入して以下を得ます。

$$\begin{aligned}
\mu_n(\mathbf{x} \mid \mathbf{x}_*) &= \mu_{f1} + \frac{\Sigma_{f11}\phi(z_*)}{\Phi(z_*)v\sqrt{1 + \frac{\Sigma_{f11}}{v^2}}} \\
&= \mu_{f1} + \text{sign}(\Sigma_{f11} - \Sigma_{f12})\sqrt{\frac{\Sigma_{f11}^2}{v^2 + \Sigma_{f11}}}\frac{\phi(z_*)}{\Phi(z_*)} \\
&= \mu_{f1} + \frac{\Sigma_{f11} - \Sigma_{f12}}{\sqrt{\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12}}}\frac{\phi(z_*)}{\Phi(z_*)} \\
\sigma_n^2(\mathbf{x} \mid \mathbf{x}_*) &= \Sigma_{f11} - \frac{\Sigma_{f11}^2}{v^2 + \Sigma_{f11}}\frac{\phi(z_*)}{\Phi(z_*)}\left(\frac{\phi(z_*)}{\Phi(z_*)} + z_*\right) \\
&= \Sigma_{f11} - \frac{(\Sigma_{f11} - \Sigma_{f12})^2}{\Sigma_{f11} + \Sigma_{f22} - 2\Sigma_{f12}}\frac{\phi(z_*)}{\Phi(z_*)}\left(\frac{\phi(z_*)}{\Phi(z_*)} + z_*\right)
\end{aligned} \tag{1.54}$$

参考文献

- [1] Philipp Hennig and Christian Schuler. Entropy search for information-efficient global optimization. *Journal of Machine Learning Research*, 13, 12 2011.
- [2] 伊藤 清. 確率論. 岩波書店, 1991.