


5.40

- ニューラルネットワークの出力ユニットの活性化関数をソフトマックス関数とする。
- 目標変数 τ の条件付分布を多項分布とし、ニューラルネットの出力を多項分布の平均と解釈する。
というモデルを考える



出力ユニット y_k の活性を a_k とする

$$y_k(x, w) = \frac{\exp(a_k(x, w))}{\sum_j \exp(a_j(x, w))}$$

目標変数 τ (1 of K 記号) の条件付分布は

$$p(\tau | x, w) = \prod_{k=1}^K y_k^{t_k}(x, w) \quad \dots \textcircled{1}$$

τ の値を $D = \{t_1, t_2, \dots\}$, $X = \{x_1, x_2, \dots\}$, $y_{nk} = y_k(x_n, w)$ とおくと尤度は

$$p(D | w, X) = \prod_{n=1}^N p(t_n | x_n, w) = \prod_{n=1}^N \prod_{k=1}^K y_{nk}^{t_{nk}} \quad \dots \textcircled{2}$$

対数尤度は

$$\ln p(D | w, X) = \sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk}$$

となる。

(注) 教科書での条件付確率の x, w, X の表記は省略されている。

(MAP推定)

ベイズモデルで w の推定値は 最大事後確率推定 (MAP推定) で与えられる。事後分布

$$p(w|D, X) = \frac{p(D, w|X)}{p(D|X)} = \frac{p(D|w, X)p(w)}{p(D|X)} \propto p(D|w, X)p(w)$$

で、対数事後分布は

D, X は観測値 (固定) である
 $p(D|X)$ は定数である

$$\ln p(w|D, X) = \ln p(D|w, X) + \ln p(w) + C, \quad (C \text{ は } w = \emptyset \text{ の定数})$$

$$= \sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk} + \ln p(w) + C$$

となる。

w の事前分布を 等方共分散分布 (5.162) とすると

$$\ln p(w|D, X) = \sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk} - \frac{\alpha}{2} w^T w + C$$

となる。

ここで、対数事後分布 $\ln p(w|D, X)$ の最大化は、(5.182) の正則化コサイン数

$$E(w) = -\ln p(D|w, X) + \frac{\alpha}{2} w^T w$$

$$= -\sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk} + \frac{\alpha}{2} w^T w$$

の最小化を等価であることを示す。

$E(w)$ の最小化は w_{MAP} で $0 = \frac{\partial E}{\partial w}$ の解で与えられる。

この解は 5.2.4 節の勾配降下法で得ることができる。

勾配降下法で必要な $\frac{\partial E}{\partial w}$ の計算は 5.3 節の誤差逆伝播

で行なうことができる。

(予測分布)

新しい観測に対する予測分布は

$$p(t|x, D, \mathbf{x}) = \int p(t, w|x, D, \mathbf{x}) dw = \int p(t|x, w) p(w|D, \mathbf{x}) dw$$
$$= \int \prod_{k=1}^K y_k^{t_k}(x, w) p(w|D, \mathbf{x}) dw$$

この積分は複雑で近似する。

この積分を簡便化する近似法を

(近似 1)

(5.185)と同様に事後分布を $p(w|D, \mathbf{x}) \approx \delta(w - w_{MAP})$ と近似すると

$$p(t|x, D, \mathbf{x}) = \int \prod_{k=1}^K y_k^{t_k}(x, w) p(w|D, \mathbf{x}) dw$$
$$\approx \int \prod_{k=1}^K y_k^{t_k}(x, w) \delta(w - w_{MAP}) dw = \prod_{k=1}^K y_k^{t_k}(x, w_{MAP})$$

が得る。

(近似 2)

5.7.3節の(5.190)と同様の近似は出力 y_k の特性 a_k を線形近似する

(5.186)と同様にネットワークの出力 y_k の特性 a_k を線形近似する

$$a_k(x, w) \approx a_k^{MAP}(x) + b_k^T(w - w_{MAP})$$

$$a_k(x, w) \approx a_k^{MAP}(x) + b_k^T(w - w_{MAP}), b_k = \nabla a_k(x, w) \Big|_{w=w_{MAP}}$$

となるネットワークの出力 y_k は

$$y_k(x, w) \approx \frac{\exp(a_k^{MAP}(x) + b_k^T(w - w_{MAP}))}{\sum_j \exp(a_j^{MAP}(x) + b_j^T(w - w_{MAP}))}$$

となる。

この式の左側は $t=0 \dots 0$ と書かれてるが、
右側では α_k が α_k^{MAP} と書かれている。

$$\begin{aligned} p(t=0 \dots 0 | x, D, \alpha) &= \int_{\mathbb{R}^K} y_k(x, w) p(w | D, \alpha) dw \\ &\approx \int \frac{\exp(\alpha_k^{\text{MAP}}(x) + b_k^T(w - w_{\text{MAP}}))}{\sum_j \exp(\alpha_j^{\text{MAP}}(x) + b_j^T(w - w_{\text{MAP}}))} p(w | D, \alpha) dw \quad \text{← } \alpha_k \text{ が MAP で近似} \\ &\approx \int \frac{\exp(\alpha_k^{\text{MAP}}(x) + b_k^T(w - w_{\text{MAP}}))}{\sum_j \exp(\alpha_j^{\text{MAP}}(x) + b_j^T(w - w_{\text{MAP}}))} q(w | D, \alpha) dw \quad \text{← } p(w | D, \alpha) \text{ が } q(w | D, \alpha) \text{ で置換} \\ &\quad \text{③} \end{aligned}$$

とある。

③ の $w^T b_k$ を複数回引く形でモルヒューリックに $4,144$ と同じ形を見出せ。

5,7,4,5,2 節の結果を利用して積分を導き出せ。

5,7,3 節では、③の部分が $\delta(\alpha_k^{\text{MAP}}(x) + b_k^T(w - w_{\text{MAP}}))$ と書いてある。

4,5,2 節の $(4,145)$ の積分と同じ形と見えて手で導け。

$(4,148), (4,150), (4,153)$ を用いて $(5,190)$ の積分を導き出せ。

(超回帰分析の推進)

α の I 比 $\frac{w}{\alpha}$ による偏微分

$$p(D|\alpha, X) = \int p(D|w, X) p(w|\alpha) dw$$

ここで、 $f(w) = p(D|w, X) p(w|\alpha)$ は正規分布である。
証明 (4.135) 式

$$p(D|\alpha, X) = \int f(w) dw \approx f(w_{MAP}) \frac{(2\pi)^{\frac{W}{2}}}{(A)^{\frac{1}{2}}}$$

ここで、 w_{MAP} は w の最大値。 $A = -\nabla \ln f(w)|_{w=w_{MAP}}$ (4.132) とある。

F.7

$$\ln p(D|\alpha, X) = \ln f(w_{MAP}) + \frac{W}{2} \ln(2\pi) - \frac{1}{2} \ln |A|$$

ここで

$$\ln f(w_{MAP}) = \ln p(D|w_{MAP}, X) + \ln p(w_{MAP}|\alpha)$$

$$= -E(w_{MAP}) + \frac{\alpha}{2} w_{MAP}^T w_{MAP} + \ln N(w_{MAP} | 0, \alpha^T \Sigma)$$

$$= -E(w_{MAP}) + \frac{\alpha}{2} w_{MAP}^T w_{MAP} + \ln \frac{1}{(2\pi)^{\frac{W}{2}}} \frac{1}{(\alpha^T \Sigma)^{\frac{1}{2}}} \exp \left(-\frac{\alpha}{2} w_{MAP}^T w_{MAP} \right)$$

$$= -E(w_{MAP}) - \frac{W}{2} \ln(2\pi) + \frac{W}{2} \ln \alpha \quad \leftarrow |\alpha^T \Sigma| = \bar{\alpha}^W$$

ここで

$$\ln p(D|\alpha, X) = -E(w_{MAP}) - \frac{1}{2} \ln |A| + \frac{W}{2} \ln \alpha$$

を得る。

二回目最後化す α 17

$$0 = \frac{\partial}{\partial \alpha} \ln P(D | \alpha, \mathbf{X}) = \frac{\partial}{\partial \alpha} \left(-E(\mathbf{w}_{MAP}) - \frac{1}{2} \ln |\mathbf{A}| + \frac{W}{2} \ln \alpha \right)$$
$$= -\frac{1}{2} \mathbf{w}_{MAP}^T \mathbf{w}_{MAP} - \frac{1}{2} \frac{\partial}{\partial \alpha} \ln |\mathbf{A}| + \frac{W}{2} \alpha$$

で、 $\frac{\partial}{\partial \alpha} E(\mathbf{w}) = -\sum_{n=1}^N \sum_{k=1}^K t_n c_k \ln y_{nk} + \frac{1}{2} \mathbf{w}^T \mathbf{w} / \alpha$
 $\frac{\partial E(\mathbf{w}_{MAP})}{\partial \alpha} = \frac{1}{2} \mathbf{w}_{MAP}^T \mathbf{w}_{MAP}$

$$|\mathbf{A}| = -\nabla \nabla \ln f(\mathbf{w})|_{\mathbf{w}=\mathbf{w}_{MAP}} = -\nabla \nabla \ln P(D | \mathbf{w}, \mathbf{X})|_{\mathbf{w}=\mathbf{w}_{MAP}} = -\nabla \nabla \ln P(\mathbf{w} | \alpha)|_{\mathbf{w}=\mathbf{w}_{MAP}}$$
$$= \mathbb{H} + \alpha \mathbb{I}$$

で、 $\mathbb{H} = -\nabla \nabla \ln P(D | \mathbf{w}, \mathbf{X})|_{\mathbf{w}=\mathbf{w}_{MAP}}$ とすると
左の固有値 λ_i ($i=1 \sim W$) と右の $\lambda_i + \alpha$ の固有値 $\lambda_i + \alpha$ は、
左の固有値 λ_i ($i=1 \sim W$) と右の $\lambda_i + \alpha$ の固有値 $\lambda_i + \alpha$ は、

$$\frac{\partial \nabla \nabla \ln \mathbf{w}}{\partial \mathbf{w}} = \frac{\partial \text{Tr}(\mathbf{w}^T \mathbf{z} \mathbf{w})}{\partial \mathbf{w}} \quad (\text{L.17})$$
$$= \frac{\partial \text{Tr}((\mathbb{I} + \alpha \mathbb{I}) \mathbf{w})^T}{\partial \mathbf{w}} = \frac{\partial \text{Tr}((\mathbf{w}^T (\mathbb{I} + \alpha \mathbb{I}))^T)}{\partial \mathbf{w}} = 2\mathbf{w}$$
$$\therefore \frac{\partial}{\partial \mathbf{w}} \frac{\partial \nabla \nabla \ln \mathbf{w}}{\partial \mathbf{w}} = \frac{\partial}{\partial \mathbf{w}} 2\mathbf{w}$$
$$= 2 \left(\frac{\partial \mathbf{w}_1}{\partial \mathbf{w}_1} \frac{\partial \mathbf{w}_2}{\partial \mathbf{w}_2} \dots \frac{\partial \mathbf{w}_W}{\partial \mathbf{w}_W} \right) = 2 \begin{pmatrix} 1 & 0 & \dots & 0 \end{pmatrix} = 2 \mathbb{I}$$

5.7

$$\frac{\partial}{\partial \alpha} \ln |\mathbf{A}| = \frac{\partial}{\partial \alpha} \ln \prod_{i=1}^W (\lambda_i + \alpha) = \frac{\partial}{\partial \alpha} \sum_{i=1}^W \ln (\lambda_i + \alpha) = \sum_{i=1}^W \frac{1}{\lambda_i + \alpha}$$

二回目までを λ で表す

$$0 = -\frac{1}{2} \mathbf{w}_{MAP}^T \mathbf{w}_{MAP} - \frac{1}{2} \sum_{i=1}^W \frac{1}{\lambda_i + \alpha} + \frac{W}{2} \alpha$$

$$\therefore 0 = -\alpha \mathbf{w}_{MAP}^T \mathbf{w}_{MAP} - \sum_{i=1}^W \frac{\alpha}{\lambda_i + \alpha} + \sum_{i=1}^W 1$$

$$= -\alpha \mathbf{w}_{MAP}^T \mathbf{w}_{MAP} + \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha}$$

$$\therefore \alpha = \frac{\gamma}{\mathbf{w}_{MAP}^T \mathbf{w}_{MAP}} \quad \dots (5.178)$$

で、 γ は

$$\gamma = \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha} \quad \dots (5.179)$$

で、 γ は


(確率モデル(4回))

参考までに8章の確率モデルで、この問題のモデル図を書いてみる。


では、二つ並んで一つは8章の確率モデルで、もう一つはである。

二つ並んで一つは確率変数で、二つ並んで一つは確率的依存関係を表現したもの。
確率モデルの一つは確率変数で、二つ並んで一つは確率的依存関係を表現する。左の図は確率モデルで、右の図は確率的依存関係を表現する。右の図は確率モデルで、左の図は確率的依存関係を表現する。

$t, \alpha, \gamma, a, z, w$ の確率モデル図




とすると ① $p(t|x, w)$ の確率モデル図




とすると

$t, \alpha, \gamma, a, z, w$ の確率モデル図



とすると ② $p(D|w, x)$ の確率モデル図



とすると

確率的依存の仕方はいくつかある (wiki: F1)

・確率変数変換 $y = ax + b e^{-ax}$

Transform of variable

・確率変数の関数 $z = x + y e^{ax}$

Function of variables

・複合(合成)分布


Compound distribution

分布の構成 $x \rightarrow$ 確率変数 $y = f(x)$ が確率変数 $z = g(y)$

$$p(y|x) = N(y|f(x), \sigma^2) \approx 1$$


$$\text{複合分布} p(x) = \sum_k p_k p_k(x)$$

予測分布を求めるまでの手順図




である。

失敗LT=gt、aを線形近似して予測分布を求めるまでの手順図



である。訓練時のaも含めて手順図



である。