


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 \mathcal{D} 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この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 とすると

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

目標変数 \mathcal{D} (1 of K 表記) の条件付分布は

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

と仮定。このとき $\mathcal{D} = \{t_1, t_2, \dots\}$, $\mathcal{X} = \{x_1, x_2, \dots\}$, $y_{nk} = y_k(x_n, w)$ とおくと尤度は

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

対数尤度は

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

と仮定。

(注) 教科書では条件付確率の \mathcal{D}, \mathcal{X} の表記は省略されている。

(ベイズ- w の推定)

ベイズモデルにて w の推定値は 最大事後確率推定 (MAP推定) で与えられる。 ^{w の} 事後分布は

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

にて 対数事後分布は

D, X は観測値に固定されている
にて $p(D|X)$ は定数である

$$\ln p(w|D, X) = \ln p(D|w, X) + \ln p(w) + C, \quad (C \text{ は } w \in \mathbb{R}^n \text{ の定数})$$

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

とすると

w の事前分布を 等方ガウス分布 (5.162) とすると

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

とすると

よって、対数事後分布 $\ln p(w|D, X)$ の最大化は、(5.182) の正則化ガウス関数

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

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

の最小化と等価であることが分かる。

$E(w)$ を最小にする w_{MAP} は $0 = \frac{\partial E}{\partial w}$ 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。

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

を行うことができる。

(予測分布)

新しい α に対する世の予測分布は

$$p(\mathbf{t}|\alpha, D, X) = \int p(\mathbf{t}, \mathbf{w}|\alpha, D, X) d\mathbf{w} = \int p(\mathbf{t}|\alpha, \mathbf{w}) p(\mathbf{w}|D, X) d\mathbf{w}$$
$$= \int \prod_{k=1}^K y_k^{\mathbf{t}_k}(\alpha, \mathbf{w}) p(\mathbf{w}|D, X) d\mathbf{w}$$

と与えられる。

この積分可算性は難しいが、 δ で近似可算。

(近似1)

(5.185)と同様に事後分布 $p(\mathbf{w}|D, X) \approx \delta(\mathbf{w} - \mathbf{w}_{\text{MAP}})$ と近似して

$$p(\mathbf{t}|\alpha, D, X) = \int \prod_{k=1}^K y_k^{\mathbf{t}_k}(\alpha, \mathbf{w}) p(\mathbf{w}|D, X) d\mathbf{w}$$
$$\approx \int \prod_{k=1}^K y_k^{\mathbf{t}_k}(\alpha, \mathbf{w}) \delta(\mathbf{w} - \mathbf{w}_{\text{MAP}}) d\mathbf{w} = \prod_{k=1}^K y_k^{\mathbf{t}_k}(\alpha, \mathbf{w}_{\text{MAP}})$$

を得る。

(近似2)

5.7.3節の(5.190)と同様の近似は出来るがこの説明

(5.186)と同様にネットワークの出力 y_k の活性化 a_k を線形近似可算

$$a_k(\alpha, \mathbf{w}) \approx a_k^{\text{MAP}}(\alpha) + b_k^T(\mathbf{w} - \mathbf{w}_{\text{MAP}})$$

ただし $a_k^{\text{MAP}}(\alpha) = a_k(\alpha, \mathbf{w}_{\text{MAP}})$, $b_k = \nabla a_k(\alpha, \mathbf{w})|_{\mathbf{w}=\mathbf{w}_{\text{MAP}}}$ とする。

このときネットワークの出力 y_k は

$$y_k(\alpha, \mathbf{w}) \approx \frac{\exp(a_k^{\text{MAP}}(\alpha) + b_k^T(\mathbf{w} - \mathbf{w}_{\text{MAP}}))}{\sum_j \exp(a_j^{\text{MAP}}(\alpha) + b_j^T(\mathbf{w} - \mathbf{w}_{\text{MAP}}))}$$

と与えられる。

ここで α の代わりに $\theta = (0 \dots 1 \dots 0)$ とする。ただし θ_k は

$$p(\theta = (0 \dots 1 \dots 0) | \alpha, D, X) = \int g_k(\alpha, w) p(w | D, X) dw$$

$$\approx \int \frac{\exp(a_k^{\text{MAP}}(\alpha) + b_k^T(w - w_{\text{MAP}}))}{\sum_j \exp(a_j^{\text{MAP}}(\alpha) + b_j^T(w - w_{\text{MAP}}))} p(w | D, X) dw$$

a_k は線形近似

$$\approx \int \underbrace{\frac{\exp(a_k^{\text{MAP}}(\alpha) + b_k^T(w - w_{\text{MAP}}))}{\sum_j \exp(a_j^{\text{MAP}}(\alpha) + b_j^T(w - w_{\text{MAP}}))}}_{\textcircled{3}} g(w | D, X) dw$$

$p(w | D, X)$ の近似

と近似。

③ が $w^T b_k$ を変数とするソフト関数になっているので、(4.145)と同じ形と見做すことができる。

よって4.5.2節の結果を利用して積分を得ることができる。

5.7.3節では、③の部分から $\sigma(a_k^{\text{MAP}}(\alpha) + b_k^T(w - w_{\text{MAP}}))$ と仮定して

4.5.2節の(4.145)の積分と同じ形と見做すことができる。

(4.148)、(4.150)、(4.153) を用いて (5.190) の積分を得ることができる。

(超次元空間での推定)

α の Evidential 関数は

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

である。右辺の $f(w) = p(D|w, X) p(w|\alpha)$ は W 次元関数。

・超次元空間では W が大きくなるにつれて $f(w)$ の値は W 次元空間で 0 に近づく。

ここで、 $(4, 135)$ より

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

である。ここで W は w の次元で、 $A = -W \ln f(w) \Big|_{w=w_{MAP}}$ $(4, 132)$ である。

より

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

ここで

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

$$= -E(w_{MAP}) + \frac{\alpha}{2} w_{MAP}^T w_{MAP} + \ln N(w_{MAP} | 0, \alpha^{-1} I)$$

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

$$= -E(w_{MAP}) - \frac{W}{2} \ln(2\pi) + \frac{W}{2} \ln \alpha \leftarrow |\alpha^{-1} I| = \alpha^{-W}$$

より

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

を得る。

二重正則化可能な α は

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

$$= -\frac{1}{2} w_{MAP}^T w_{MAP} - \frac{1}{2} \frac{\partial}{\partial \alpha} \ln |A| + \frac{W}{2\alpha}$$

上記 $E(w) = -\sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk} + \frac{\alpha}{2} w^T w$
 $\frac{\partial E(w_{MAP})}{\partial \alpha} = \frac{1}{2} w_{MAP}^T w_{MAP}$

2" 及び 3" あり。 二重正則化

$$A = -\nabla \nabla \ln f(w) \Big|_{w=w_{MAP}} = -\nabla \nabla \ln P(D|w, X) \Big|_{w=w_{MAP}} - \nabla \nabla \ln P(w|\alpha) \Big|_{w=w_{MAP}}$$

$$= H + \alpha I \quad \leftarrow \begin{aligned} -\nabla \nabla \ln P(w|\alpha) &= -\nabla \nabla \ln N(w|0, \alpha^{-1} I) \\ &= -\nabla \nabla \left(-\frac{\alpha}{2} w^T w \right) = \alpha I \end{aligned}$$

$$\frac{\partial w^T w}{\partial w} = \frac{\partial (w^T I w)}{\partial w} \quad (L.1.17)$$

$$= \left(\frac{\partial (w^T I w)}{\partial w^T} \right)^T = (w^T (I + I))^T$$

$$= 2w$$

2" あり。 $T \in \mathbb{R}^d$, $H = -\nabla \nabla \ln P(D|w, X) \Big|_{w=w_{MAP}}$ あり

H の固有値は λ_i ($i=1 \sim W$) あり

固有値 (2重正則化) 固有値の性質?

$$H u_i = \lambda_i u_i$$

$$(\alpha I) u_i = \alpha u_i$$

$$\therefore (H + \alpha I) u_i = (\lambda_i + \alpha) u_i$$

A の固有値は $\lambda_i + \alpha$ ($i=1 \sim W$) あり

$$\therefore \frac{\partial}{\partial w} \frac{\partial}{\partial w} w^T w = \frac{\partial}{\partial w} 2w$$

$$= 2 \begin{pmatrix} \frac{\partial w_1}{\partial w_1} & \frac{\partial w_1}{\partial w_2} \\ \frac{\partial w_2}{\partial w_1} & \frac{\partial w_2}{\partial w_2} \end{pmatrix} = 2 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = 2I$$

5.7

$$\frac{\partial}{\partial \alpha} \ln |A| = \frac{\partial}{\partial \alpha} \ln \prod_{i=1}^W (\lambda_i + \alpha) \quad (L.47)$$

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

二重正則化式 α は

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

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

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

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

2" あり。 $T \in \mathbb{R}^d$

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

2" あり。

(確率モデル)


参考までに8章の確率モデルで、この問題のモデルを表現してある。

つまり、このように初めは8章の確率モデルとは別のものである。


このように初めは7章の確率変数は連続変数ではない。未知はトド向の確率的依存関係を表現している。各ノードに条件付分布を割り当てられる。同時分布を与える。確率モデルのトドは確率変数である。未知はトド向の確率的依存関係を表現する。各ノードに条件付分布を割り当てると各トドの分布の積が同時分布を与える。

この問題モデルに於いて確率変数は t, α, w, z, y である。 α の分布は考えられ、 α は定数と見做す。

t, α, y, a, z, w の確率モデル図は




とある。① $p(t|\alpha, w)$ のモデル図は




とある。

$t_n, \alpha_n, y, a, z, w$ の確率モデル図は



とある。② $p(D|w, X)$ のモデル図は



とある。

確率的依存の仕方はいろいろあり (wiki あり)

- 確率変数変換 $y = ax + b$ による Transform of variable

- 確率変数の関数 $z = x + y$ による Function of variable


- 混合(合成)分布 Compound distribution

分布の1つ $x \sim N$ 確率変数 z になること

$$p(y|x) = N(y|f(x), \sigma^2) \geq 0$$


混合分布 z と $p(z) = \sum_k \pi_k p_k(z)$ となること

予測分布を求めようとするのディープ図は




である。

失敗したが、 α と線形近似して予測分布を求めようとするのディープ図は



である。訓練時の α_n も含むディープ図は



である。