


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

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

と仮定。 n 例 $D = \{\mathcal{D}_1, \mathcal{D}_2, \dots\}$, $X = \{x_1, x_2, \dots\}$, $y_{nk} = y_k(x_n, w)$ とおくと尤度は

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

対数尤度は

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

と仮定

(ベイズ- η の決定)

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 \mathcal{D} 分布 $p(\mathcal{D} | w)$

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

ここで対数事後分布は

D, X は観測値に固定されている
 $\therefore p(D | X)$ は定数である

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

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

と仮定

w の事前分布を等方ガウス分布 (5.162) とすると

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

とできる。

よって、対数事後分布 $\ln p(D|w, X)$ の最大化は、(5.182) の正則化ゴシック関数

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

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

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。

勾配降下法で必要となる $\frac{\partial E}{\partial w}$ の計算は 5.3 節の誤差逆伝播
で行うことができる。

(予測分布)

新しい x に対する y の予測分布は

$$\begin{aligned} p(y|x, D, X) &= \int p(y, w|x, D, X) dw = \int p(y|x, w) p(w|D, X) dw \\ &= \int \prod_{k=1}^K y_k^{t_k(x, w)} p(w|D, X) dw \end{aligned}$$

で与えられる。

ここに出てくる w の事前分布 $p(w|D, X)$ はラプラス近似 (5.167) である。

ラプラス近似に必要な $\ln p(w)$ の行列 H は (5.91) 若しくは (5.93), (5.94), (5.95)

で得られる。

(超パラメータの推定)

超パラメータ α はエビデンス最大化により (5.178) で与えられる。