

データサイエンス・シリーズ 6
データ学習アルゴリズム

(渡辺澄夫著, 共立出版 2001)

発表日: 平成 15 年 6 月 25 日
担当者: 岩崎 唯史
担当箇所: 3.1 関数近似モデル
 3.1.4 球形基底関数, RBF

3.1.4 球形基底関数, RBF

球形基底関数 (Radial Basis Function)

$R^M \rightarrow R^N$ への関数 $f(x, w) = \{f_i(x, w)\}$ ($1 \leq i \leq N$)
($x \in R^M$ は入力, $w = \{w_{ij}\}$ はパラメータ, H は中間ユニット数)

$$f_i(x, w) = \sum_{j=1}^H w_{ij} o_j,$$

$$o_j = \exp\left(-\frac{\|x - \xi_j\|^2}{2\sigma_j^2}\right),$$

$$\|x - \xi_j\|^2 = \sum_{k=1}^M (x^{(k)} - \xi_j^{(k)})^2.$$

球形基底関数中のパラメータ

$$W = \{(\xi_j, \sigma_j, w_{ij}); \xi_j \in R^M, \sigma_j > 0, w_{ij} \in R\}.$$

3層パーセプトロンとの対比

- 中間層の応答が「球形」である。

cf. 3層パーセプトロンの中間層 (p.50)

$$o_j = \sigma \left(\sum_k w_{jk} x^{(k)} + \theta_j \right), \quad \sigma(x) = \frac{1}{1 + \exp(-x)}.$$

- 3層パーセプトロンより多くのパラメータが必要 (短所)
- 3層パーセプトロンより学習データの無いところでの振舞が分かりやすい (長所)

球形基底関数を用いた学習アルゴリズム

1組のサンプル (x, y) の学習誤差: $\mathcal{E}(x, y, w) \stackrel{\text{def}}{=} \frac{1}{2} \|y - f(x, w)\|^2$.

$$\frac{\partial \mathcal{E}(x, y, w)}{\partial w_{ij}} = (f_i(x, w) - y^{(i)}) \exp\left(-\frac{\|x - \xi_j\|^2}{2\sigma_j^2}\right),$$

$$\frac{\partial \mathcal{E}(x, y, w)}{\partial \xi_j} = \sum_{i=1}^N (f_i(x, w) - y^{(i)}) w_{ij} \frac{(x - \xi_j)}{\sigma_j^2} \exp\left(-\frac{\|x - \xi_j\|^2}{2\sigma_j^2}\right),$$

$$\frac{\partial \mathcal{E}(x, y, w)}{\partial \sigma_j} = \sum_{i=1}^N (f_i(x, w) - y^{(i)}) w_{ij} \frac{\|x - \xi_j\|^2}{\sigma_j^3} \exp\left(-\frac{\|x - \xi_j\|^2}{2\sigma_j^2}\right).$$



最急降下法 (3層パーセプトロンと同じ手続き)

$$w(t+1) = w(t) - \eta(t) \nabla_w \mathcal{E}(x, y, w) + \alpha(t) (w(t) - w(t-1)),$$

$$\nabla_w \mathcal{E}(x, y, w) \stackrel{\text{def}}{=} \left(\frac{\partial \mathcal{E}(x, y, w)}{\partial \xi_j}, \frac{\partial \mathcal{E}(x, y, w)}{\partial \sigma_j}, \frac{\partial \mathcal{E}(x, y, w)}{\partial w_{ij}} \right) \text{ at } w = w(t).$$

各パラメータの初期設定

- (1) ξ_j はサンプル $\{x_i\}$ の周辺に設定 (必要ならクラスタリング).
- (2) σ_j はサンプルのばらつきより大きめに設定 (各クラスの分散より大きめ).
- (3) w_{ij} の絶対値は y の絶対値より十分小さな乱数で設定.

うまく機能させるには, サンプル $\{x_i\}$ についての事前知識が必要.

Green 関数 ([注 23] の準備)

変数 x , 関数 $u(x)$ に対する微分演算子 L_x, B_x ,

$$\text{微分方程式: } L_x u(x) = f(x), \quad \text{境界条件: } B_x u(x) = 0 \quad (1)$$



微分方程式 (1) の解

$$L_x G(x, y) = \delta(x - y), \quad B_x G(x, y) = 0, \quad (2)$$

を満たす関数 (Green 関数) $G(x, y)$ を導入すると,

$$u(x) = \int G(x, y) f(y) dy. \quad (3)$$

- $G(x, y)$ は L_x^{-1} の積分核.
- 「微分方程式 (1) を解く」 \equiv 「Green 関数 (式 (2)) を求める」
- $G(x, y)$ は, y に外力 $f(y)$ を加えたときの x での応答を表す.
(式 (3) は重ね合わせの原理)

[注 23] 球形基底関数が提案された背景

n 個の入出力の組 $\{(x_i, y_i); n = 1, 2, \dots, n\}$ ($x_i, y_i \in R^M$) が与えられたとき, $R^M \rightarrow R$ への関数 f に関する正則化された誤差

$$L(f) = \frac{1}{2} \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda \int (Pf)^2(x) dx,$$

を定義する. ただし, $\lambda > 0$ は定数, P はある微分作用素である. 以下, 誤差 $L(f)$ を最小にする関数 f を変分法により求める.

$f(x)$ の変分を $f(x) + (Df)(x)$, P の共役作用素を P^* とすると, $\delta L(f) = 0$ より

$$(P^*Pf)(x) = \frac{1}{\lambda} \sum_{i=1}^n (y_i - f(x)) \delta(x - x_i).$$

ここで, P^*P に対する Green 関数 $G(x, y)$ を導入する.

$$P^*PG(x, y) = \delta(x - y).$$

$$f(x) = \sum_{i=1}^n c_i G(x - x_i),$$

$$\sum_{j=1}^n (G(x_i, x_j) + \lambda) c_j = y_i \quad (i = 1, 2, \dots, n).$$

特に微分作用素が

$$(P^* P f)(x) = \sum_{k=0}^{\infty} \frac{(-1)^k \sigma^{2k}}{k! 2^k} (\nabla^{2k} f)(x),$$

のとき, $G(x, y) \propto \exp(-(x - y)^2 / (2\sigma^2))$ となるので (補足資料参照), 誤差 $L(f)$ を最小にする関数は,

$$f(x) = \sum_{i=1}^n c_i \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right).$$

これは全データに関する和になっているが, いくつかのデータ毎の代表に置き換えると球形基底関数になる.