


# 第7章 パーセプトロン型学習規則

12T4069L

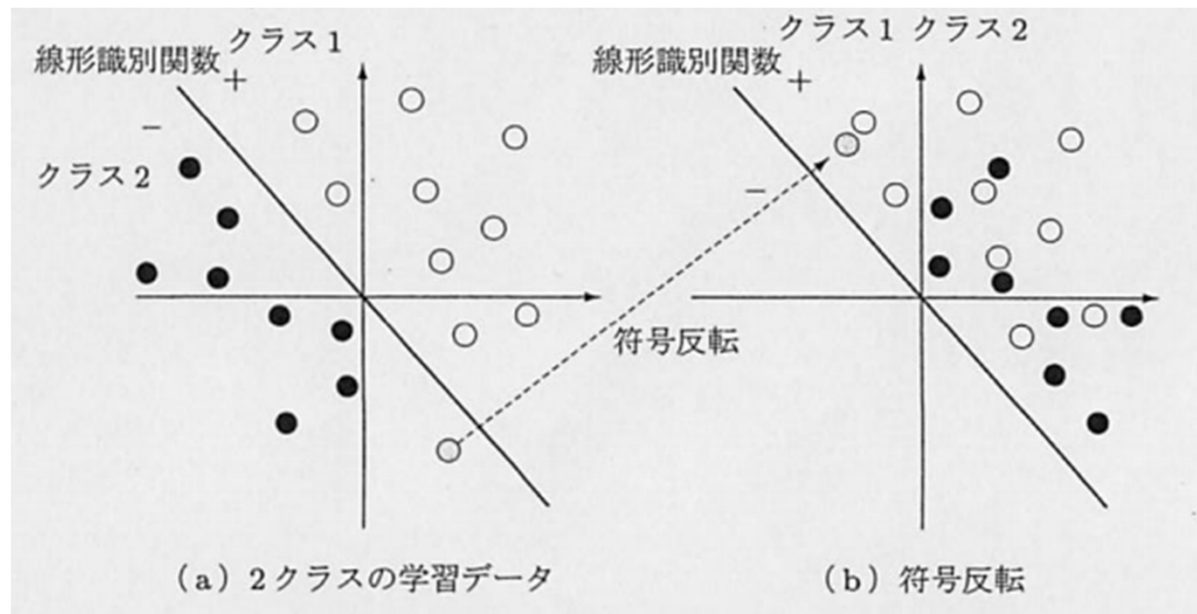
佐鳥 恭太郎

# パーセプトロン



# パーセプトロンの学習規則

- データは線形分離可能であるとする。
- 以下の様にデータの符号を反転させると、全てのデータが同じ側の超平面に存在するようになる。



# 学習規則の収束

- 学習データ $x$ が入力されたとき、 $f(x)$ の正負によって $w$ を更新する。

$$\begin{cases} w_{new} = w_{old} & (f(x) \geq 0) & \text{判断が正しい} \Rightarrow \text{何もしない} \\ w_{new} = w_{old} + \eta x & (f(x) < 0) & \text{判断が誤っている} \Rightarrow \text{修正する} \end{cases}$$

$\eta$ : 学習の収束速度

特に $\eta=1$ のとき、固定増分誤り訂正法という。

# 学習の難しさの尺度

- ノイズのない学習データで学習した識別関数は、ノイズありのテストデータで誤りやすくなる。
- 学習データが識別超平面に値 $h(> 0, \text{マージンという})$ より近い距離にあれば誤りとして、 $w$ を更新する。
- $i$ 番目の学習における $w_i$ の変更量  
 $\Delta w_i$ は、符号反転を行った学習データについて

$$\Delta w_i = \begin{cases} \eta x_i (h > w_i^T x_i / \|w_i\|) & \text{近いので修正} \\ 0 & \text{(それ以外の場合) 遠いのでそのまま} \end{cases}$$

と書ける。

# 最大マージン

- 符号反転を行った学習データを超平面の法線ベクトル上へ射影した長さの最小値がマージンとなり、 $w$ が最大(クラスが分けられた)のとき、最大マージンとなる。

最大マージン  $D_{max}$

$$D_{max} = \max_w D(w) = \max_w \min_{x \in C_1, C_2} \frac{w^T x}{\|w\|}$$


# パーセプトロンの収束定理

- パーセプトロンの収束定理
  - 2クラス間の学習データが線形分離可能ならば、パーセプトロンの学習規則は有限の学習回数で収束する。

# 多層回路

- 線形識別関数では正しく識別できない例(排他的論理和関数など)もある。

=>入力を用いて、第三の入力を定義すると線形分離可能になる。



# 誤差逆伝搬法

- 学習データ:  $x^n (n = 1, \dots, N)$
- 学習データの次元:  $d$  (図では  $d=5$ )
- よって入力は、 $x^n = (1, x_1^n, \dots, x_d^n)^T$  となる。

隠れ素子  $V_j (j = 1, \dots, M)$

$$\text{入力: } h_j^n = \sum_{i=0}^d w_{ji} x_i^n = w_j^T x^n$$

$$\text{出力: } V_j^n = g(h_j^n)$$

出力素子  $o_k (k = 1, \dots, K)$

$$\text{入力: } h_k^n = \sum_{j=0}^M w_{kj} V_j^n = \sum_{j=0}^M w_{kj} g(\sum_{i=0}^d w_{ji} x_i^n)$$

$$\text{出力: } o_k^n = \tilde{g}(h_k^n) = \tilde{g}(\sum_{j=0}^M w_{kj} V_j^n) = \tilde{g}(\sum_{j=0}^M w_{kj} g(\sum_{i=0}^d w_{ji} x_i^n))$$

$g(u)$ : 非線形出力関数


良く使用されるのはシグモイド関数

$$g(u) = \frac{1}{1 + \exp(-\beta u)}$$

出力素子用非線形出力関数

$$\tilde{g}(o_k^n) = \exp o_k^n / \sum_{l=1}^k \exp o_l^n$$

または、 $\tilde{g}(o_k^n) = p(t_k^n = 1 | x^n)$



# 誤差逆伝搬法の学習規則

n番目の学習データによる誤差の評価関数は、

$$E_n(w) = \frac{1}{2} \sum_{k=1}^K (t_k^n - o_k^n)^2 = \frac{1}{2} \sum_{k=1}^K \left( t_k^n - \tilde{g} \left( \sum_{j=0}^M w_{kj} g \left( \sum_{i=0}^d w_{ji} x_i^n \right) \right) \right)^2$$

となる。学習データ全体では、

$$E(w) = \sum_{n=1}^N E_n(w)$$

# 出力素子係数の更新

$$w_{kj}(\tau + 1) = w_{kj}(\tau) + \Delta w_{kj}(\tau)$$

$$\begin{aligned} \Delta w_{kj}(\tau) &= \sum_{n=1}^N \left( -\eta \frac{\partial E_n(w)}{\partial w_{kj}} \right) = \\ &= -\eta \sum_{n=1}^N \left( \frac{\partial E_n(w)}{\partial o_k^n} \frac{\partial o_k^n}{\partial w_{kj}} \right) = \eta \sum_{n=1}^N (t_k^n - o_k^n) \tilde{g}'(h_k^n) V_j^n = \eta \sum_{n=1}^N \delta_k^n V_j^n \end{aligned}$$

$$\delta_k^n = (t_k^n - o_k^n) \tilde{g}'(h_k^n) : \text{誤差信号}$$

確率降下法(オンライン学習):  $w_{kj}$  の修正量を次式で与える方法。

$$\Delta w_{kj}(\tau) = \eta \delta_k^n(\tau) V_j^n(\tau)$$

# 隠れ素子係数の更新

出力素子と同様に、

$$\begin{aligned}\Delta w_{ji}(\tau) &= \sum_{n=1}^N \left( -\eta \frac{\partial E_n(w)}{\partial w_{ji}} \right) = -\eta \sum_{n=1}^N \left( \frac{\partial E_n(w)}{\partial V_j^n} \frac{\partial V_j^n}{\partial w_{ji}} \right) \\ &= -\eta \sum_{n=1}^N \left( \sum_{k=1}^K \left( \frac{\partial E_n(w)}{\partial o_k^n} \frac{\partial o_k^n}{\partial V_j^n} \right) \frac{\partial V_j^n}{\partial w_{ji}} \right) \\ &= \eta \sum_{n=1}^N \sum_{k=1}^K (t_k^n - o_k^n) \tilde{g}'(h_k^n) w_{kj} g'(h_j^n) x_i^n \\ &= \eta \sum_{n=1}^N \sum_{k=1}^K \delta_k^n w_{kj} g'(h_j^n) x_i^n\end{aligned}$$

隠れ素子jの誤差信号： $\delta_j^n = g'(h_j^n) \sum_{k=1}^K \delta_k^n w_{kj}$

確率降下法では、 $\Delta w_{ji}^n(\tau) = \eta \delta_j^n(\tau) x_i^n(\tau)$

# 誤差逆伝搬法の学習特性

- 初期依存性がある
  - 誤差評価関数に局所最小値がたくさんあるため、局所最適解が結合係数の初期値により決まる。
- 隠れ素子の数
  - 増やしすぎると汎化誤差が増加する。  
=>過学習
  - ホールドアウト法,交差確認法で最適な数を求める。

# 過学習と正則化

- 隠れ素子の数が膨大=>過学習 ではない。
- 学習が進む=>結合係数が大きくなる=>シグモイド関数が非線形動作し始める=>ノイズ成分が混じる=>学習がうまくいかない(過学習)
- 結合係数の大きさを抑えるのに正則化を用いる。
- 正則化
  - 荷重減衰ペナルティ:誤差の評価関数にペナルティ項を加える。

$$\tilde{E}(w) = E(w) + \lambda R(w)$$

$$R(w) = \sum_{i=0}^d \sum_{j=0}^M w_{ji}^2 + \sum_{j=0}^M \sum_{k=0}^K w_{kj}^2$$

$\lambda$ :正則化の大きさを決める正則化パラメータ

学習規則は、 $\Delta w_{kj}(\tau) = \eta \sum_{n=1}^N \delta_k^n V_j^n - 2\lambda w_{kj}$  となる。

# 学習回路の尤度(1)

- 誤差逆伝搬法の評価関数を確率で表す。

$$E(w) = - \sum_{n=1}^N \sum_{k=1}^K t_k^n \log o_k^n$$

- 最尤度推定法により結合係数の更新式は、
- 出力 $o_k$ をK個の無関係な確率とみなす場合は、ベルヌーイ試行

$$p(t|x, w) = \prod_{k=1}^K o_k^{t_k} (1 - o_k)^{1-t_k}$$

と解釈できる。負の対数尤度は交差エントロピー型誤差関数

$$E(w) = - \sum_{n=1}^N \sum_{k=1}^K (t_k^n \ln o_k^n + (1 - t_k^n) \ln(1 - o_k^n))$$

となる。

# 学習回路の尤度(2)

- 出力端子の学習は、

$$\Delta w_{kj} = -\eta \frac{\partial E(w)}{\partial w_{kj}} = \eta \sum_{n=1}^N \frac{t_k^n - o_k^n}{o_k^n (1 - o_k^n)} g' \left( \sum_{j=0}^M w_{kj} V_j^n \right) V_j^n$$

となる。出力関数がシグモイド関数の場合は、

$$g' \left( \sum_{j=0}^M w_{kj} V_j^n \right) = \beta o_k^n (1 - o_k^n)$$

なので、

$$\Delta w_{kj} = \eta \sum_{n=1}^N \delta_k^n V_j^n, \quad \delta_k^n = \beta (t_k^n - o_k^n)$$

となり、出力関数の微分が消えたので非線形部分でも学習できる。