

# 第7章 パーセプトロン型学習規則

本：はじめてのパターン認識

著：平井 有三

茨城大学大学院理工学研究科情報工学専攻

菊池 裕紀

# 導入

## ■ パーセプトロンの学習規則

- 2クラスの線形識別関数を求める古典的な方法
- パーセプトロンの収束定理を利用
  - 識別関数のパラメータを逐次的に求めるアルゴリズムでは、2クラスの学習データが線形分離可能であれば収束

# パーセプトロン(1)


## ▶ パーセプトロンの学習規則

線形分離関数 :  $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$

$$\mathbf{w} = (w_0, w_1, \dots, w_d)^T, \quad \mathbf{x} = (x_0 = 1, x_1, \dots, x_d)^T$$

$f(\mathbf{x}) \geq 0$  のとき  $\mathbf{x} \in C_1$

$f(\mathbf{x}) < 0$  のとき  $\mathbf{x} \in C_2$



# パーセプトロン(2)

## ▶ 係数ベクトル $w$ の調整

$f(x_i) \geq 0$ であれば  $w_{i+1} = w_i$

$f(x_i) < 0$ であれば  $w_{i+1} = w_i + \eta x_i$

$\eta$  : 学習の収束速度を決めるパラメータ

$\eta = 1$ のとき、**固定増分誤り訂正**

# パーセプトロン(3)

## ▶ 学習の難しさの尺度

ノイズがある場合、誤差が生じやすくなる

識別超平面からある値  $h > 0$  より近い距離にあれば誤り

- ▶  $w$  を更新する
- ▶ この  $h$  をマージンという

# パーセプトロン(4)

- ▶ 係数ベクトル $w_i$ の変化量 $\Delta w_i$

$$\Delta w_i = \eta f_{step} \left( h - \frac{w_i x_i}{\|w_i\|} \right) x_i = \begin{cases} \eta x_i & ( h > \frac{w_i x_i}{\|w_i\|} \text{の場合} ) \\ 0 & ( \text{それ以外の場合} ) \end{cases}$$

# パーセプトロン(5)

## ▶ 取れるマージンの大きさ

$\rho$ : クラス間マージン

$$\rho = \min_{x \in C_1} \frac{w^T x}{\|w\|} - \max_{x \in C_2} \frac{w^T x}{\|w\|}$$

最大マージン  $D_{max}$


$$D_{max} = \frac{1}{2} \rho_{max}$$

# 誤差逆伝搬法(1)

## ▶ 多層パーセプトロン

例: 排他的論理和関数


$x_1$	$x_2$	出力	教師データ
0	0	0	-1
0	1	1	+1
0	1	1	+1
1	1	0	-1



多層パーセプトロンの誤差逆伝搬法

# 誤差逆伝搬法(2)

## ▶ 多層パーセプトロンの誤差逆伝搬法



- $V_j$ への入力

$$h_j^n = \sum_{i=0}^d w_{ji} x_i^n = \mathbf{w}_j^T \mathbf{x}^n$$

- $V_j$ からの出力

$$V_j^n = g(h_j^n)$$

# 誤差逆伝搬法(3)

## ▶ 非線形関数 $g(u)$

出力 $V_j^n$ が線形であれば、等価的に一層の回路で表現できてしまう

▶ 多層回路である必要がない

$g(u)$ を非線形とする

→ **非線形出力関数**

例: シグモイド関数  $g(u) = \frac{1}{1 + \exp(-\beta u)}$

# 誤差逆伝搬法(4)

## ▶ 出力 $o_k$

- $o_k (k = 1, \dots, K)$ への入力

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

- 出力

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

# 誤差逆伝搬法 (5)

## ▶ 誤差逆伝搬法の学習規則

隠れ素子から出力素子への結合係数の学習

▶ 教師信号を用いて、二乗誤差最小化法を最急降下法に従って行う

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

学習データ全体では、

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

# 誤差逆伝搬法(6)

## ▶ バッチアルゴリズム

$E(\boldsymbol{w})$ を評価関数として用いる

学習データ全体を用いて結合係数の修正量を計算する

→1エポック

$\tau$ エポック目の修正量を $\Delta w_{kj}(\tau)$ とすると、...

$$\Delta w_{kj}(\tau) = \sum_{n=1}^N \left( -\eta \frac{\partial E_n(\boldsymbol{w})}{\partial w_{kj}} \right) = -\eta \sum_{n=1}^N \left( \frac{\partial E_n(\boldsymbol{w})}{\partial o_k^n} \frac{\partial o_k^n}{\partial w_{kj}} \right)$$

# 誤差逆伝搬法(7)

## ▶ 修正量

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