

超平面からの距離による評価

- 2クラス識別器

$$g(x) = w^T x$$

- 重みベクトル w と識別線 $g(x) = w^T x = 0$ との距離


$$r = \frac{\|w^T x\|}{\|x\|}$$

- 評価関数 $J = \|w^T x\|$ として逐次修正を行う。ただし、正しく識別されたときには $J = 0$ とする。

$$J(w) = \begin{cases} -w^T x & (x \in \omega_1 \text{ かつ } w^T x < 0) \\ w^T x & (x \in \omega_2 \text{ かつ } w^T x > 0) \\ 0 & (\text{その他のとき}) \end{cases}$$

- 最急降下法はパーセプトロンと等価

$$\begin{aligned} w' &= w - \rho \frac{\partial J}{\partial w} \\ &= \begin{cases} w + \rho x & (x \in \omega_1 \text{ かつ } w^T x < 0) \\ w - \rho x & (x \in \omega_2 \text{ かつ } w^T x > 0) \\ w & (\text{その他のとき}) \end{cases} \end{aligned} \quad (1)$$



ニューラルネットワーク

- 多層パーセプトロン (非線形写像)
- ユニット j への入力 (ユニット i の出力の重みつき線形和)

$$h_{jp} = \sum_i w_{ij} g_{ip}$$

- ユニット j の出力 (非線形写像)

$$g_{jp} = f_j(h_{jp})$$


- 出力層: ℓ , 出力: $g_{\ell p}$, 教師信号 $b_{\ell p}$

- 誤差:

$$J_p = \frac{1}{2} \sum_{\ell} (g_{\ell p} - b_{\ell p})^2$$

- 全パターンに対する誤差:

$$J = \sum_p J_p$$



誤差最小化

- J の最小化

$$\frac{\partial J_p}{\partial w_{ij}} = \frac{\partial J_p}{\partial h_{jp}} \frac{\partial h_{jp}}{\partial w_{ij}} = \varepsilon_{jp} g_{jp}$$

ただし $\varepsilon_{jp} = \partial J_p / \partial h_{jp}$.

- 最急降下法

$$w'_{ij} = w_{ij} - \rho \varepsilon_{jp} g_{jp}$$

- ε_{jp} の決め方 .

$$\varepsilon_{jp} = \frac{\partial J_p}{\partial h_{jp}} = \frac{\partial J_p}{\partial g_{jp}} \frac{\partial g_{jp}}{\partial h_{jp}} = \frac{\partial J_p}{\partial g_{jp}} f'_j(h_{jp})$$


- $\partial J_p / \partial g_{jp}$ の決め方 .

– ユニット j が出力層にあるとき ($J_p = \frac{1}{2} \sum_j (g_{jp} - b_{jp})^2$)


$$\frac{\partial J_p}{\partial g_{jp}} = g_{jp} - b_{jp}$$

– ユニット j が中間層にあるとき ($h_{kp} = \sum_j w_{jk} g_{jp}$)

$$\frac{\partial J_p}{\partial g_{jp}} = \sum_k \frac{\partial J_p}{\partial h_{kp}} \frac{\partial h_{kp}}{\partial g_{jp}} = \sum_k \varepsilon_{kp} w_{jk}$$



誤差逆伝播法 (Back Propagation Method)



- しきい値関数の近似 (シグモイド関数: Sigmoid Function)

$$S(u) = \frac{1}{1 + \exp -u}, S'(u) = S(u)(1 - S(u))$$

- f_j をシグモイド関数にすると ($g_{jp} = f_j(h_{jp})$)

$$f'_j = g_{jp}(1 - g_{jp})$$

- 重み更新

$$w'_{ij} = w_{ij} - \rho \varepsilon_{jp} g_{jp}$$
$$\varepsilon_{jp} = \begin{cases} (g_{jp} - b_{jp}) g_{jp} (1 - g_{jp}) & \text{(ユニット } j \text{ が出力層にあるとき)} \\ (\sum_k \varepsilon_{kp} w_{jk}) g_{jp} (1 - g_{jp}) & \text{(ユニット } j \text{ が中間層にあるとき)} \end{cases}$$

汎化 (generalization)

- 一般的には: 個別の事例から背後に潜む一般法則を抽出すること
- 学習理論では: 未知パターンに対してどの程度正しい出力を示せるか(予測能力)であり, 一般法則の抽出とは関係ない.
- 教師つき学習では, 学習は入出力間関数のパラメータ推定問題
- パーセプトロンでは線形重みの推定(重回帰分析と等価)
- ニューラルネットワークでは非線形近似
- 非線形関数を用いれば複雑な関数を高精度で近似可能
- 少数の学習パターンを多数のパラメータを用いて近似すれば学習誤差は減少するが, 未知学習パターンには対応できなくなる.
- パラメータの数が多くなれば十分な学習パターンを準備することは困難(次元の呪い)
- パラメータの数に対して学習パターンが少ない場合, 過学習(言葉が適切ではない)が発生する.
- 過学習は関数のオーバーフィッティングであり, 少数のデータに対して多数のパラメータを用いた複雑な関数で誤差ゼロ近似をしてしまうこと.