

# 階層型のネットワーク

浅川伸一 <asakawa@twcu.ac.jp>

パーセプトロンに代表されるフィードフォワード型の結合を持つ階層型のネットワークは、パターン認識 (pattern recognition)、情報圧縮 (data compression)、運動制御 (motion control)、雑音除去 (noise reduction)、および時系列予測 (time series prediction) などへの理論的、または応用的研究が試みられている。ここでは、パーセプトロンの学習について、幾何学的表現を用いて詳しく解説し、線形分離可能な問題について紹介する。続いてバックプロパゲーション法を導入し、階層型のネットワークについての幾つかの話題を解説する。

## 1 階層型ネットワークの行列表現

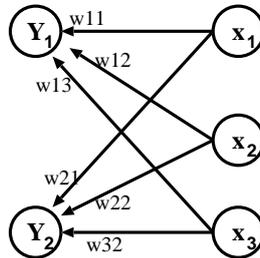


図 1: ネットワークの行列表現

図 1 には、3つの入力ユニットと2つの出力ユニットの活性値  $x_1, x_2, x_3$  と  $y_1, y_2$  および入力ユニットと出力ユニットの結合係数を表す  $w_{11}, w_{12}, \dots, w_{32}$  が示されている。これらの記号をベクトル  $x, y$  と行列  $W$  を使って表すと  $y = Wx$  となる。図 1 の場合、ベクトルと行列の各要素を書き下せば、

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} \quad (1)$$

のようになる。

行列の積は、左側の行列の  $i$  行目の各要素と右側の行列 (ベクトルは 1 列の行列でもある) の  $i$  列目の各要素とを掛け合わせて合計することなので、

以下のような、加算記号を用いた表記と同じことである。

$$\begin{aligned} y_1 &= w_{11}x_1 + w_{12}x_2 + w_{13}x_3 = \sum_i w_{1i}x_i \\ y_2 &= w_{21}x_1 + w_{22}x_2 + w_{23}x_3 = \sum_i w_{2i}x_i \end{aligned} \quad (2)$$

これを、 $m$  個の入力ユニットと  $n$  個の出力ユニットの場合に一般化すれば、

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} & \cdots & w_{1m} \\ w_{21} & w_{22} & \cdots & w_{2m} \\ \vdots & & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{nm} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{pmatrix} \quad (3)$$
$$\mathbf{y} = \mathbf{W}\mathbf{x} \quad (4)$$

と表現できる。しきい値の扱いについては、常に 1 を出力する仮想的なユニット  $x_0 = 1$  を考えて  $W$  に組み込むことが多い。

実際の出力は  $y$  の各要素に対して

$$f(y) = \frac{1}{1 + e^{-y}} \quad (5)$$

のような非線型変換を施すことが行なわれる。

階層型のネットワークにとっては、(5) 式の非線型変換が本質的な役割を果たす。なぜならば、こうした非線形変換がなされない場合には、ネットワークの構造が何層になったとしても、この単純なシナプス結合係数を表す行列を  $W_i$  ( $i = 1, \dots, p$ ) としたとき、 $W = \prod_{i=1}^p W_i$  と置くことによって本質的には 1 層のネットワークと等価になるからである。

$$\mathbf{y} = W_p W_{p-1} \cdots W_1 \mathbf{y} = \left( \prod_{i=1}^p W_i \right) \mathbf{y} \quad (6)$$