

# ニューラルネットワークの構造設計への適用に関する基礎的研究

愛媛大学工学部 フェロー 大久保 賢二 (株) ヒロコン 正 ○三津山 慎也

## 1. まえがき

近代において、複雑化する工学的問題を解決するためにノイマン型コンピュータが果たしてきた貢献はまことに偉大なものがある。しかしながら、数理的表現になじみにくい問題や、明確に定義できない要素を含む問題などにおいては、ノイマン型コンピュータを用いて解くことが困難な場合がある。このような問題を解決する一つの方法としてニューラルネットワークによる工学的問題の解法が注目されている。本研究では、これまでに提案してきたニューラルネットワークモデルのうち階層型ニューラルネットワークモデルに着目し、構造物の美観関数のシミュレーションを行った結果について述べるものである。

## 2. ニューラルネットワークモデルの概要

生物の神経系は、多数のニューロンが複雑に結合されており、この結合部位をシナプス結合と呼ぶ。ニューロンにある入力が与えられ一定のしきい値を超えると次のニューロンへと信号を伝播する。このようなニューロンの動作をモデル化したものをモデルニューロンと呼び、次のように定義される。

$$O_j = f \left[ \sum_{i=1}^{n_j} \omega_{ij} I_i \right] \quad (1)$$

$O_j$  : ニューロン  $j$  の出力信号

$I_i$  : ニューロン  $i$  からの入力信号

$$f(x) = \frac{1}{1 + \exp(-x)}$$

$n_j$  : ニューロン  $j$  へ信号を伝播するニューロンの総数

$\omega_{ij}$  : ニューロン  $i$  からニューロン  $j$  へのシナプス結合強度

モデルニューロンを幾つか結合することによって、ニューラルネットワークモデルが構築される。本研究で用いた階層型ニューラルネットワークモデルは、ある入力信号に対する理想的な出力信号である教師信号を与え、学習を行うことにより、そこに内在する写像関係を獲得するものである。

## 3. 階層型ニューラルネットワークモデルの学習アルゴリズム

対象とするニューラルネットワークモデルの、第  $p$  番目の入力信号  $x_{ip}$  に対するニューラルネットワークの出力信号を  $y_{jp}$  とし教師信号を  $\bar{y}_{jp}$  とする。第  $p$  番目の入力信号に対する誤差関数  $E_p(\omega)$  および全ての入力信号に対する総誤差関数  $E(\omega)$  を次式で定義する。

$$E_p(\omega) = \frac{1}{2} \sum_{j=1}^{n_o} (y_{jp} - \bar{y}_{jp})^2 \quad (2)$$

$n_o$  : 出力層のニューロンの個数

$$E(\omega) = \sum_{p=1}^{n_p} E_p(\omega) \quad (3)$$

$n_p$  : 教師信号の個数

本研究では、総誤差関数  $E(\omega)$  を最小化するため勾配ベクトル  $\frac{\partial E(\omega)}{\partial \omega}$  を計算し、その逆方向に結合強度ベクトル  $\omega$  を修正する最急降下法を利用した逆誤差伝播法と、現在与えられている結合強度ベクトルに対する総誤差関数と結合強度ベクトルの各成分に対して正規乱数を発生させ、それを修正量とした結合強度ベクトルに対する総誤差関数とを比較し、小さい総誤差関数を与える結合強度ベクトルを新しい結合強度ベクトルとするランダム探索法とを交互に実行するハイブリッドアルゴリズムを用いている。その改良フロ

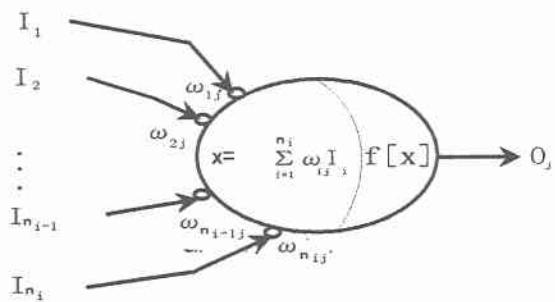


図 1 モデルニューロンの概略図

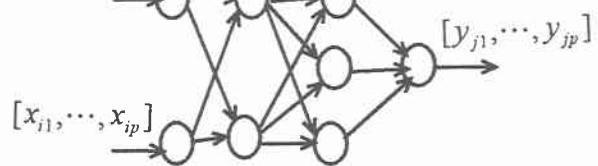


図 2 階層型ニューラルネットワークモデル

ーチャートを図3に示す。

#### 4. 構造物の美観関数のシミュレーションおよび考察

2.～3.でのべたニューラルネットワークを用いて図3に示す三径間連続プレストレストコンクリート箱桁橋の美観関数のシミュレーションを行った。本研究で取り扱った美観関数はスパン比 $S_r$ および桁高 $H$ を変数とし、これらの離散値の各組み合わせに対する三径間連続プレストレストコンクリート橋の美観の評価値は完成予想図を作成し相互に比較検討することにより決定し、これを教師信号として用いた。

隠れ層が2層で各隠れ層のニューロンの個数が7個および4個である場合(NN[2, 7, 4, 1])および7個および8個である場合(NN[2, 7, 8, 1])の教師信号の数と総誤差関数値の関係をそれぞれ図-5および図-6に示す。また、NN[2, 7, 4, 1]で教師信号36個を用いて学習を行った場合のニューラルネットワークによる美観関数と教師信号との比較を図7に示す。

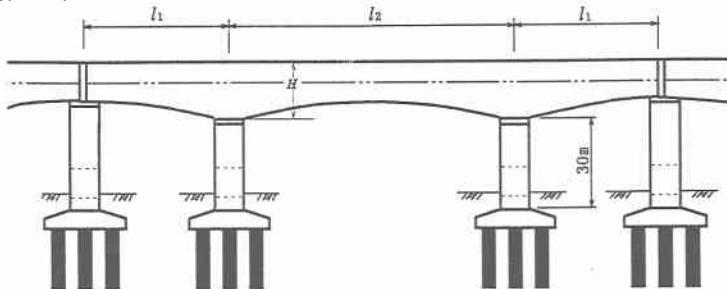


図4 三径間連続プレストレストコンクリート箱桁橋  
スパン比 :  $S_r = l_2/l_1$

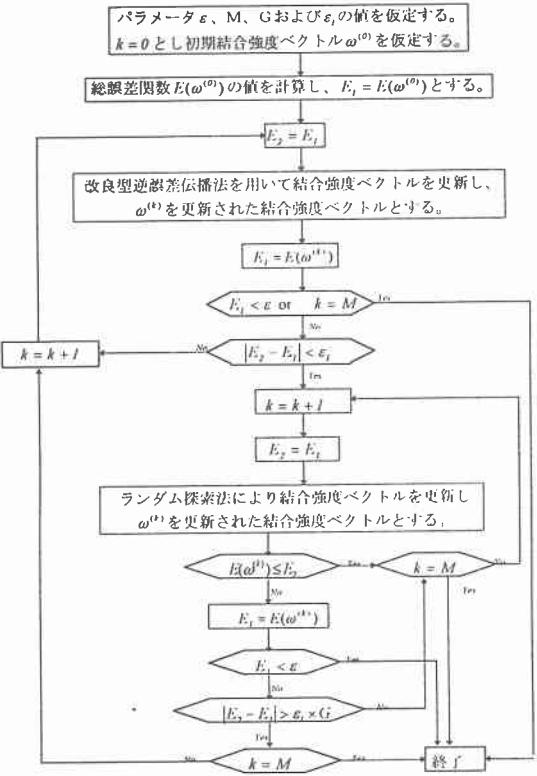


図3 ハイブリッドアルゴリズムによる結合強度ベクトル $w$ の改良フローチャート

● 学習に用いた教師信号による総誤差関数  
□ 全ての教師信号による総誤差関数

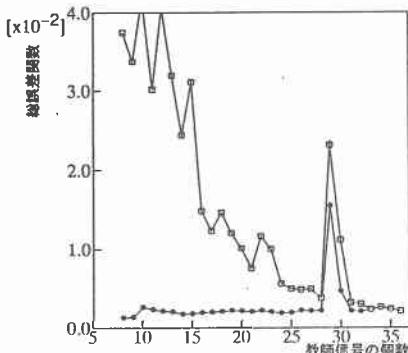


図5 NN[2,7,4,1]の総誤差関数と  
学習に用いた教師信号の個数の関係

● 学習に用いた教師信号による総誤差関数  
□ 全ての教師信号による総誤差関数

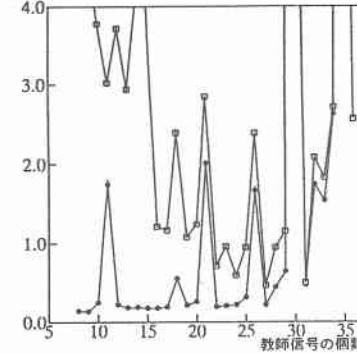


図6 NN[2,7,8,1]の総誤差関数と  
学習に用いた教師信号の個数の関係

これらのシミュレーション結果より次の事項が明らかとなった。

- 一般的にニューラルネットワークモデルの隠れ層におけるニューロンの個数を増やすことにより美観関数のシミュレーションの精度を向上させることができるが、8個以上になると精度が落ちはじめた。
- 学習に用いる教師信号の個数を増やすことにより美観関数のシミュレーションの精度を向上させることができるが、個数によっては不連続的に精度が落ちることがある。
- 隠れ層におけるニューロンの個数および学習に用いる教師信号の個数の種々の組み合わせについてニューラルネットワークを構築し、その中より教師信号の個数が或程度大きく、かつ総誤差関数の値が小さいニューラルネットワークモデルを選ぶことによって適当な精度で美観関数のシミュレーションを行うことができた。

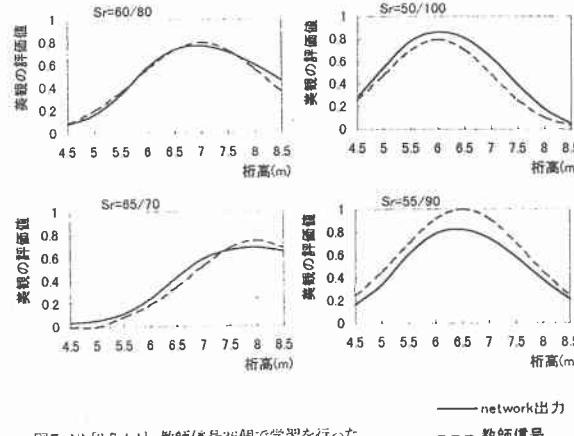


図7 NN[2,7,4,1]、教師信号36個で学習を行った  
ニューラルネットワークの美観関数と教師信号との比較