

ニューラルネットワークによる 平等オフセットの学習

山口大学工学部 正 員 久井 守
山口大学大学院 学生員 ○高橋昌之

1. はじめに

本研究は、系統信号制御において交通流を円滑化するために最も重要な制御パラメータであるオフセットに着目し、ニューラルネットワークに系統制御の平等オフセットを学習させ、平等オフセットを求めるニューラルネットワークを構築するものである。

3信号、5信号、7信号路線の系統信号制御路線を対象とし、スルーバンド法(TB法)により平等オフセットをあらかじめ求め、TB法で得た制御パラメータをニューラルネットワークに学習させ、学習パターン数・繰り返し回数・諸定数値などの最適値および汎化能力の検討を行った。

2. ニューラルネットワークによる学習

学習に用いる対象路線は図1に示すように $(n+1)$ 交差点、 n リンクからなる路線とした。学習パターンは第 k 信号の現示率 $\pi(k)$ 、第 k リンクのリンク長の時間距離 $\tau(k)$ 、第 k リンクの相対オフセット γ_k (対周期比)とした。ここで入力パターンは π, τ であり、教師信号は γ である。 $\tau(k)$ は式(1)に示すように対周期比である。

$$\tau(k) = D(k) / V(k) \cdot T \quad \dots\dots\dots (1)$$

ここで、 $D(k)$ は第 k リンクのリンク長、 $V(k)$ は第 k リンクの速度、 T は信号周期である。

これら学習パターンに対して図2のような、ニューロンを層状に配列した階層型ニューラルネットワークを用いた。各ニューロンへの入力値 X を $[0, 1]$ の値に正規化する役割をはたす関数として式(2)に示すシグモイド関数を用いた。

$$f(X) = \frac{1}{1 + \exp(-X/T_N)} \quad \dots\dots\dots (2)$$

ここで T_N は温度定数と呼ばれる正の数であり、ニューロンの発火のしやすさを表す定数である。本研究では、この温度定数を変化させて学習を行った。

ニューラルネットワークにおける学習とは、入力パターンに対して望ましい出力、すなわち平等オフセットが得られるように荷重を調整することであり、荷重の調整は誤差逆伝搬法により行った。誤差逆伝搬法とは、式(3)に示すRMS(Root Mean Square)誤差 R を最小にするようにシナプス荷重 W を変化させる最急降下法である。

$$R = \sqrt{\frac{1}{n \cdot N_d} \sum_{n=1}^N \sum_{d=1}^d \{Y_{rk} - \gamma_k\}^2} \quad \dots\dots\dots (3)$$




図1 対象路線




図2 階層型ニューラルネットワーク




図3 誤差逆伝搬法

ここで、 n はリンク数、 n_d は教師信号であるオフセットパタンの組番号、 N_d はオフセットパタンの組数、 Y_{rk} は出力層 r における k 番目ニューロンからの出力、 γ_k は教師信号であり第 k リンクの相対オフセットである。次に出力層 r における k 番目ニューロンの学習信号 δ_{rk} を式(4)に、中間層 q における j 番目ニューロンの学習信号 δ_{qj} を式(5)に示す。出力層の学習信号は、相対オフセット γ_k と出力値 Y_{rk} によって求める。中間層の学習信号は、前の層の学習信号を用いて求める。

$$\delta_{rk} = Y_{rk} \cdot (1 - Y_{rk}) \cdot \{\gamma_k - Y_{rk}\} \quad \dots\dots\dots (4)$$

$$\delta_{qj} = Y_{qj} \cdot (1 - Y_{qj}) \cdot \sum_{k=1}^n \delta_{rk} W_{qjk} \quad \dots\dots\dots (5)$$

荷重の調整量の決定には、前回の荷重の調整量を考慮するモーメント法を用いる。 W_{qjk} に対する調整量 $\Delta W_{qjk}(K)$ および K 回目調整後のシナプス荷重 $W_{qjk}(K)$ は、次式で表される。

$$\Delta W_{qjk}(K) = \alpha \cdot \Delta W_{qjk}(K-1) + (1 - \alpha) \cdot \delta_{rk} \cdot Y_{qj} \quad \dots\dots\dots (6)$$

$$W_{qjk}(K) = W_{qjk}(K-1) + \eta \cdot \Delta W_{qjk}(K) \quad \dots\dots\dots (7)$$

ここで、 α は平滑化係数で0.0~1.0の値をとる定数であり、 η は学習速度係数で一般に0.01~1.0の値をとる定数である。本研究では、この両係数について変化させ学習を行った。このようにして、出力層から入力層に向かって順次シナプス荷重の調整を行っていく。

3. 平等オフセットの学習と再現性

7信号路線の平等オフセットの学習と再現性について述べる。図2に示したニューラルネットワークにより、リンク数 $n=6$ として解析を行った。ここで学習のネットワーク規模は中間層を2層とし、計算条件は $T_N=3.0$ 、 $\alpha=0.9$ 、 $\eta=0.8$ 、中間層第2層のユニット数を14、学習パターンを70組として学習を行った。図4はRMS誤差の変動を表したものである。これは繰り返し回数200回毎の最大RMS誤差(MAXRMS)と最小RMS誤差(MINRMS)をグラフ化したものであるが、他の計算条件の場合と比較してMINRMSが最小となった。また学習パターンと教師信号の相関係数も $r=0.953$ と非常に精度がよく、中間層のユニット数を出力層ユニット数の倍以上にした他のモデルも同様に0.9以上の精度であった。つまりユニット数を増やすことにより学習能力は向上すると考えられる。

次にモデルの再現性について述べる。再現性とは、未学習パターンに対するニューラルネットワークの出力値(平等オフセット)の精度である。このモデルの誤差の頻度分布を図5に示す。このモデルはリンク数 $n=6$ 、未学習パターン10組で、 $6 \times 10 = 60$ 個のオフセットがある。この60個のオフセットのうち35個のオフセットは、誤差が0.10以下となっている。このモデルは学習パターンを70組用いて学習を行ったが、学習パターン数を増やすことによりニューラルネットワークの汎化能力が向上することが分かった。

4. まとめ

本研究では、ニューラルネットワークで平等オフセットが学習できることが分かった。しかし、RMS誤差の振動を減少させる方法や、収束させる最適な方法を見いだすことができなかった。今後の課題は、再現精度の高いニューラルネットワークを構築することである。




図4 RMS誤差の収束




図5 誤差の頻度分布