

京都大学防災研究所 正員 佐藤忠信
 京都大学工学部 正員 土岐憲三
 京都大学大学院 学生員 ○佐藤 誠

1 概説

本研究ではニューラルネットワークを利用し、観測データをもとに構造物の応答特性を同定する手法を展開する。これまでは主に誤差逆伝播法を利用してネットワークの重みを同定しているが、数々の問題点が指摘されており、これを克服するため拡張カルマンフィルターを利用して重みを決定する手法を開発した。

2 ニューラルネットワーク

ニューラルネットワークは神経回路網での信号のやり取りを簡単にモデル化したもので、最も簡単なものにPerceptron型と呼ばれる階層型ネットワークがあり、図1に示されるような構造を有する。図は3層構造の例であり、ある層のノードへの入力が入力層の各ノードからの信号の重み付きの和として表現され、それが非線形入出力関数を通して出力され、次の層へ入力されるといったシステムで、例えば最終層において

$$y_k = \alpha(\bar{y}_k) \quad \bar{y}_k = \sum_{i=1}^n w_{ki}^3 z_i \quad (1)$$

となり、このような信号の流れが各層において繰り返されて y_k は重み係数 $w_{ki}^1, w_{ij}^2, w_{ki}^3$ の非線形関数となる。そしてこれらノード間の結合の重みは一定ではなく、入力と出力の観測値に基づいて、ネットワークからの出力を観測値に近づけるように徐々に学習されるという特徴がある。この観測値を教師信号と呼ぶ。




図1 Perceptron型ニューラルネットワーク

3 誤差逆伝播法を用いた学習 (Back propagation; 以下BP)

BPでは、(2)式で与えられる観測値と計算値との2乗誤差を最小にするように、最大傾斜法を用いて(3)式に従いネットワークの重み係数 w_{ij} が更新される。ここに y_k は観測値、 y_{kd} はネットワークからの出力値、 ϵ は学習率と呼ばれる値である。問題点として観測データにノイズが含まれていると学習過程が不安定になることや、学習の出発点により解が局所解に陥る危険性があることなどがある。

$$E = \frac{1}{2} \sum_{k=1}^n e_k^2 \quad e_k = y_k - y_{kd} \quad (2)$$

$$w_{ij}^{(new)} = w_{ij}^{(old)} - \epsilon \cdot \frac{\partial E}{\partial w_{ij}^{(old)}} \quad (3)$$

4 拡張カルマンフィルタを用いた学習 (以下KF)

拡張カルマンフィルタを用いて重み係数の学習が行なえるよう定式化を行なう。図1のモデルでは出力 y_k は各層の重み係数の非線形関数であるため、その代表値 $\hat{w}_{ij}^1, \hat{w}_{ij}^2$ と \hat{w}_{ij}^3 のまわりで線形化する必要がある。即ち y_k を $(\hat{w}_{ki}^3 - w_{ki}^3), (\hat{w}_{st}^2 - w_{st}^2)$ ならびに $(\hat{w}_{hi}^1 - w_{hi}^1)$ の関数にテーラー展開する。この線形展開の作業を最終層から逆に辿りながら行ない、拡張カルマンフィルタを適用できるようにベクトル及びマトリクスを定義したうえで重み係数の学習を行う。

5 解析

まず、図2に示す2自由度モデルの地震波に対する応答計算結果を観測されるデータ、即ち教師信号としてネットワーク中の重み係数の学習を行う。使用するネットワークモデルは図3に示す2層構造とし、設定する入出力関数は全て線形関数とする。そして時刻kでの変位、速度の応答と地動加速度を入力し、時刻k+1の変位、速度の応答を出力するネットワークを構築する。この場合重み係数は4×5のマトリクスとなる。また時間刻みは0.01秒とした。最大振幅が応答の最大値の5%になるように設定した周波数帯域0~25Hzのピンクノイズを観測ノイズとし、それが混入する観測データを教師信号として重み係




図2 解析モデル

Tadanobu Sato, Kenzo Toki, Makoto Sato

数の学習を行う。この時の学習過程の例として、重み係数マトリクスの(2,3)成分の時刻歴を図4に示す。比較のため厳密解を図中の破線で示した。この図よりBPでは学習が不安定になっているが、KFではノイズの影響をうまく削除し、安定した学習を行っている。

次に観測値にノイズが混入しない条件下で、厳密解の0%から110%の値を重み係数の初期値として与え、重み係数の時間変動を比較したものが図5である。BPでは重み係数が初期値の影響を大きく受け厳密解とは大きく隔たった値に収束しているがKFでは初期値に関わらず重み係数は厳密解に収束することが分かる。10秒間の学習を1ステップの学習とし、グローバルな繰り返しを行って、各ステップが終わるごとに得られる重み係数に固定して

応答計算を行った。この結果を図6に示す。これはノイズがなく、重み係数の初期値を0として学習を行った場合である。KFでは重み係数が厳密解に収束するため、厳密な応答を再現できているが、BPによる学習では、重み係数が厳密解と異なった値に収束するにも関わらず、学習を重ねることで厳密な応答を再現することができた。これはBPでは局所解が得られたことを意味する。また得られた重み係数マトリクスを基に固有振動数及び減衰定数を算出した結果を表1に示す。これによるとBPでは同定される値は厳密値と大きく異なるが、KFではノイズが混入していても高次の固有振動数、減衰定数まで精度よく同定できることが分かる。




図3 2層のネットワークモデル




図4 ノイズ混入時の重み係数の時刻歴





図6 再現された応答の時刻歴




図5 重み係数の時刻歴 (重み係数の初期値の影響)

6 結論

提案したカルマンフィルタを用いた学習法の有効性を実証した。これは、観測値にノイズの混入が避けられない構造物の同定には極めて有効な手法であると言える。またニューラルネットワークでは同定の対象をモデル化する必要がなく、面倒な定式化が不要であるため、実際の同定問題への適用が容易に行える。

		ω (rad/s)	h
strict	1st	8.63	0.00863
	2nd	22.6	0.0226

B.P. Algorithm (With Noise)				K.F. Algorithm (With Noise)			
Initial weight	1st	ω (rad/s)	h	Initial weight	1st	ω (rad/s)	h
0%	1st	---	---	0%	1st	7.98	0.1530
	2nd	---	---	2nd	21.0	0.1050	
50%	1st	7.14	0.0839	50%	1st	8.04	0.1300
	2nd	39.7	0.9250	2nd	22.7	0.0694	
80%	1st	7.24	0.0928	80%	1st	8.09	0.1020
	2nd	24.0	0.3640	2nd	23.7	0.0469	
90%	1st	7.85	0.1480	90%	1st	8.11	0.1060
	2nd	21.7	0.0203	2nd	24.1	0.0407	
110%	1st	8.90	0.1360	110%	1st	8.13	0.1140
	2nd	21.7	0.5180	2nd	24.7	0.0275	

表1 同定されたパラメータ