

ニューラルネットワークによる複数の非線形履歴挙動認識のための基礎的研究

九州大学工学部 学生会員 岩本 憲亮 九州大学大学院 正会員 松田 泰治
九州大学大学院 フェロー 大塚 久哲 九州大学大学院 正会員 矢葺 亘

1. はじめに

ニューラルネットワーク(以下, NN)による構造物の非線形履歴挙動のモデリングを行い, これを動的応答解析に利用した場合, 従来の数学履歴モデルと同等の表現能力を有する可能性が知られており, 現在までに様々な履歴曲線のモデリングが行われている。しかし, ネットワーク構造を決定する入出力要因は, 履歴モデルごとに設定されており, 汎用性の高いものは存在していない。本研究では, Ramberg-Osgood モデル, 高減衰積層ゴムモデル, 武田モデル, 3つの履歴曲線を対象とし, 複数の履歴モデルの認識に対応可能なNNの提案を行い, 動的応答解析への適用の前段階として学習の改善を目的とした。その際の学習に最適な教師データの取得について検討した。

2. ニューラルネットワークの概要

NNとは, 人間の神経細胞(ニューロン)をモデル化したユニットを複数結合させることにより構成された学習能力と自己組織化能力を有する情報処理システムである。このユニットは前層からの重み付け入力 x を計算し, 入出力関数 f を通して出力する。入出力関数としてシグモイド関数を用いた。本研究で用いた誤差逆伝播法は種々の入力データの組に対して, ネットワークから出力される出力値と正解値との差が最小となるようにユニット間の結合係数 W を修正する学習方法である。

3. ニューラルネットワークの構築

入力情報は表-1に示す12項目を選択し, 出力は現在の接線剛性とした。そのため入力は12, 出力は1ユニットとなり中間層は学習効率の良い14ユニットとした。

データは履歴復元力特性がそれぞれR-0モデル, 高減衰積層ゴムモデル, 武田モデルに従う1質点系モデルに, 強制変位として漸増漸減正弦波を作用させた場合の応答履歴から作成した。

4. ニューラルネットワークの学習

本研究では学習データ数が学習へ与える影響を分析した。ここで表-2に示すデータは学習データ2251個(CASE. 1)を基本としてデータ数を増減したものである。このうち, 図-2はcase. 1, 3, 5の縦軸をNNによる推定値を正解で割ったもの, 横軸を時間で表したグラフである。表-2の結果から, 学習回数1万回一定とした場合には226から2251個の間はデータの増加に伴い学習精度の向上が認められるが22501個以降は逆に精度が低下

している。また, 図-2ではデータ数が少ないcase. 1とcase. 3は1から1.5秒間の局所的な誤差が大きい。case. 5は全時刻に周期的な誤差の増減が認められる。




図-1 ニューラルネットワーク

表-1 入出力情報

入力要因			
最大経験変位	$X_{\max}$	1ステップ前の変位	X_{n-1}
最大経験荷重	$P_{\max}$	1ステップ前の荷重	P_{n-1}
最小経験変位	$X_{\min}$	1ステップ前の接線剛性	K_{n-1}
最小経験荷重	$P_{\min}$	変位増分	dX_{n-1}
最新折返し点変位	X_0	荷重増分	dP_{n-1}
最新折返し点荷重	P_0	現時点変位	X_n
出力要因			
現時点の接線剛性		K_n	

表-2 データ数による学習への影響

ケース	データ数	誤差/データ数
case.1	226	1.683E-04
case.2	1126	1.361E-04
case.3	2251	5.491E-06
case.4	22501	6.231E-06
case.5	45001	2.465E-05

5. 学習データの正規化

学習データは各入力因子毎に[0, 1]区間に収まるように正規化する。この際、これまでの研究では各因子の最大、最小を各々1, 0として正規化していたが、NNはシグモイド関数の性質上0, 1に近い値を出力し難い。このため最大、最小値の差を5, 10, 15, 20, 25, 40, 50%ずつ割り増して正規化を行い学習データを作成した。また、ここの学習データ数は2251個とした。表-3に出力と正解の二乗誤差及び、誤差累積により精度の落ちる正解と推定の最大荷重の誤差を示す。R0モデルは20%を、高減衰積層ゴムモデルは15%を、武田モデルは10%の例を示した。各ケースとも0%に比べ二乗誤差は少なくなっている。また、全モデルとも最大荷重の誤差より、正規化で

割り増す割合は10~20%が妥当と考えられる。図-3に時刻歴接線剛性の比較を示す。R0モデルは正解と推定値がよく一致している。しかし、どのモデルについても剛性が急激に変化する点が一致しにくい傾向にある。

6. まとめ

Ramberg-Osgoodモデル、高減衰積層ゴムモデル、武田モデル3つの復元力特性を対象に、入出力要因を一般化し、規則的なパターンの変位-復元関係により学習を行った。また、正規化する幅を割り増すことにより学習精度は向上することが確認できた。

今後は学習後のネットワークを非線形解析の数値演算サブルーチンとして適用するため、数式モデルの解析結果と同程度で一致するようなネットワークを得るための学習、計算メカニズムの総合的な検討が必要である。




図-2 時刻歴接線剛性の推定

表-3 二乗誤差と最大荷重の誤差

R0モデル			高減衰積層ゴムモデル			武田モデル		
割合	2乗誤差	最大荷重の誤差	割合	2乗誤差	最大荷重の誤差	割合	2乗誤差	最大荷重の誤差
0%	0.008076276	0.07	0%	3.393683514	2.47	0%	2.81550	1.90
5%	0.004576402	0.15	5%	0.775404953	2.03	5%	2.19815	0.80
10%	0.003439496	0.31	10%	0.688515332	1.59	10%	1.79269	0.14
15%	0.004684747	0.32	15%	0.599813535	0.41	15%	1.72570	2.69
20%	0.006145319	0.05	20%	0.791931396	7.75	20%	1.40562	1.16
25%	0.017542605	0.44	25%	0.42931741	2.68	25%	1.37597	1.16
40%	0.013396495	0.97	40%	0.451033929	9.54	40%	1.02296	1.16
50%	0.009347664	0.31	50%	0.494067953	9.81	50%	0.83837	1.18




図-3 学習結果（接線剛性）