

論文 ニューラルネットワークを用いた非線形履歴推定手法のサブストラクチャ法への適用と精度に関する研究

朴 珍和^{*1}・中埜 良昭^{*2}・高橋 典之^{*3}

要旨：計算機による数値計算と準静的加力による実験を組み合わせたオンライン地震応答実験において、ニューラルネットワークを用いた履歴推定手法の適用が検討されている。この手法は構造物全体の応答性状を直接実験的に評価する事の困難な構造物に対して極めて有効な実験手法の一つである。本論文では、サブストラクチャ・オンライン実験にニューラルネットワークを適用するのが難しいとされていた RC 部材を対象に、新たな履歴推定アルゴリズムの構築を試み、その精度について検討を行った。

キーワード：ニューラルネットワーク、非線形履歴、サブストラクチャ法

1. はじめに

建築物の地震応答構造実験手法のひとつとして、載荷実験により得られた履歴特性を解析部分にリアルタイムに反映させて、構造物全体の擬似動的挙動を推定するニューラルネットワークオンライン実験が挙げられる。この手法の利点は、解析部分の履歴特性を既存の数学モデルに置換することなく、載荷実験の進行に伴い累積されるデータに基づいて推定できる点にある。これまでに、簡易な鉄骨部材に対するニューラルネットワークオンライン実験の実施例はある¹⁾が、RC 部材のように非線形性の強い複雑な履歴を示す部材の場合、履歴パターンの認識における近似関数の生成が難しくなり、履歴特性を良好に学習することができないため、RC 部材のニューラルネットワークオンライン実験は実現していない。筆者らは文献 2)において、RC 部材を対象としたニューラルネットワークオンライン実験の実現にむけて、ニューラルネットワークの学習アルゴリズムに用いる要素およびパラメータを、

- (1) 復元力推定に関する許容誤差を定数から指数項 1 次関数に変更

- (2) ユニット間の結合強さを表す結合係数 W の修正係数 η ³⁾ (以下、結合係数再定義増分量と呼ぶ) を 1.0 以下に変更

して、ファイバーモデルによる仮想 RC 部材を対象に履歴推定手法の高速化・高精度化に関する検討を行った。

本論文では、地震応答観測記録を用いて、文献 2)で提案したパラメータを参考に、学習した非線形履歴に従って推定されるサブストラクチャ・オンライン実験の解析部分に相当する応答が、実際の応答を再現できるか検討を行なった。

2. 教師値の決定

2.1 対象とした実地震記録

本論文で対象とする実地震応答記録は、1987 年千葉県東方沖地震において東京大学生産技術研究所千葉実験所の梁崩壊型弱小モデルから観測された記録⁴⁾である。図-1 に梁崩壊型弱小モデルの形状および部材断面の寸法を示す。

図-1 の弱小モデルは、実建物を 1/3~1/4 に縮小した 5 層建物である。


2.2 学習データと推定対象

弱小モデルの地震応答記録から学習データと

*1 東京大学生産技術研究所 修士課程 (正会員)


*2 東京大学生産技術研究所 教授 工博 (正会員)

*3 東京大学生産技術研究所 助手 博 (工) (正会員)



a) 平面

b) 立面



c) 断面および配筋

図-1 建物の形状および部材断面（単位：mm）

推定対象を選定するにあたり、弾性区間の剛性がほぼ同じである2層および3層の復元力特性を用いることとした。ただし、学習データは推定対象よりも大きな応答を経験していることが望ましいため、学習データを2層、推定対象を3層とした。

2.3 実観測記録データの平滑化処理

本研究では、準静的なサブストラクチャ・オンライン地震応答実験への適応を目的としていることから、ランダムネスの大きい微小振動域のデータを除外し、主要動のみの5秒～55秒（2000ステップ、時間刻み0.025秒）間のデータを検討対象データとした。更に、データの局所的な変動を除去したスムーズなデータを学習対象とすべく、 i ステップのデータはそれ以前の5ステップ（即ち $i \sim i-4$ ）における変位と復元力の平均を用いた（図-2中(a)）。ただし、履歴特性の折り返し点はその再現上の重要な特性点であるため、折り返し点およびその前後を




図-2 平滑化手法




図-3 2層の学習階履歴ループの形状




図-4 3層の推定階履歴ループの形状

含む合計3点については実記録を直接用いた（図-2中(b)）。学習データに選んだ2層の履歴形状を図-3に、推定対象に選んだ3層の履歴形状を図-4に示す。

3. 学習アルゴリズム構成要素およびパラメータ

3.1 学習アルゴリズム構成要素およびパラメータの概略


履歴パターンの学習に用いるニューラルネッ

トワークの形態は階層型ニューラルネットワークとし、学習方法は一括学習アルゴリズム法（Whole Learning 法⁵⁾）を用いることとした。ここで、学習アルゴリズムを構成する要素およびパラメータの設定を表－1、表－2に示す。

表－1 の学習アルゴリズム構成要素のうち、入力成分の基準化方法について詳細を図－5 に示す。変位の基準化方法は、変位の最大経験絶対値 $[-X2, X2]$ 区間を $[-0.5, 0.5]$ として基準化した。また、復元力の基準化方法は、変位の最大経験絶対値 $[-X2, X2]$ 区間に対して初期剛性から得られる復元力 $[-P2, P2]$ 区間を $[-0.5, 0.5]$ として基準化した。

表－1 学習アルゴリズム構成要素の概略⁶⁾

要素	設定
入力成分の基準化	入力成分区間 $[-0.5 \sim 0.5]$
入力層成分	(1) 最大経験折返し点変位 (2) 最大経験折返し点復元力 (3) 最新折返し点変位 (4) 最新折返し点復元力 (5) 現在の変位 5 素子
中間層数	5 層～12 層
出力層成分	現在の変位に対応する復元力…1 素子
最大誤差	$E_{\max} = \frac{(\text{教師値} - \text{出力値})^2}{2}$ の最大値



図－5 入力データの基準化方法⁶⁾

表－2 学習アルゴリズムパラメータの概略⁶⁾

パラメータ内容	変数
許容誤差の与え方	E_{allow}
結合係数再定義増分量 (η)	$\eta = \frac{(W_i - W_{i-1})}{\Delta W} *$

* W_i : 修正後の結合係数, W_{i-1} : 前ステップの結合係数,
 $\eta \Delta W$: 修正量³⁾

3.2 学習アルゴリズムのパラメータ

前節の表－2 に示した学習アルゴリズムのパ

ラメータ（許容誤差 E_{allow} および結合係数再定義増分量 η ）について、文献 1) で用いた設定は、

[設定 1-1] 許容誤差 $E_{\text{allow}} = 10^{-3.5}$ (定数)

[設定 1-2] 結合係数再定義増分量 $\eta = 1.0$


である。しかし、この設定に関してはファイバーモデルによる仮想 RC 部材を対象にした非線形性の強い履歴などは学習できないことが多く²⁾、これを

[設定 2-1] 許容誤差 $E_{\text{allow}} = 10^{(P1-\alpha)}$ (指数項 1 次関数)

[設定 2-2] 結合係数再定義増分量 $\eta = 1.0$ 以下に変更すると学習できる場合があることが示されている²⁾。ここで、 $|P1| : [-0.5, 0.5]$ に基準化した復元力の絶対値、 α : 正の定数である。このとき、文献 2) で示唆された学習アルゴリズムのパラメータが学習結果に及ぼす影響については、概ね次のような説明が考えられる。

表－1 の最大誤差の定義は教師値と出力値の差分から求めているが、差分から求めた誤差が教師値に対して示す比率は、原点付近と最大値付近とでは大きく異なり、原点付近における値は相対的に大きな誤差を許容していることになる（図－6）。

以上のような最大誤差の問題を修正するため、許容誤差 E_{allow} を原点付近において厳しく設定すると、このような不具合を回避することができると考えられる。



図－6 学習過程に関する概念図

なお、図－6 のように i ステップから $i+1$ ステップにかけて剛性が大きく変化する非線形性の強い履歴が教師値になる場合、文献 1) で設定した結合係数再定義増分量 $\eta = 1.0$ では、近似

関数の生成が難しくなる。仮に、近似関数が生成されても、図-6 点線のような全体的な履歴パターンを外れる近似関数が構築される可能性が高い。本来のニューラルネットワーク学習システムは、履歴パターンの全体的な傾向の認識を得意とするものである。そこで、結合係数再定義増分量 η を 1.0 以下に設定すると、履歴パターンの全体的な傾向をなだらかに追従する図-6 実線 (η = 微小増分) のようなシステムが構築できると考えられる。

本論文では、上記の考察に基づき、実際の地震応答観測記録に対する最善（少なくとも学習および推定が実行可能な）の学習アルゴリズム構成パラメータ（表-2）を検討する。

3.3 検討用パラメータの設定

最善の学習アルゴリズム構成パラメータの検討にあたり、パラメータを次のように設定した。

(1) 許容誤差 E_{allow}

$E_{\text{allow}} = 10^{-3.5}$ （一定）および $E_{\text{allow}} = 10^{(Pl-\alpha)}$ （指数項 1 次関数）の $\alpha = 4.0, 4.1, 4.2$ 。ただし、弾性域である 0~200 ステップについては一様に E_{allow} を $10^{-3.5}$ で固定することとした。

(2) 結合係数再定義増分量 η

$\eta = 0.2, 0.25, 0.3, 0.4, 0.5, 0.6, 0.7$ および 1.0。

4. 非線形履歴の学習および推定結果

実際の地震応答観測記録に基づく非線形履歴の学習および推定の解析結果を、復元力時刻歴として図-7、図-8 および図-9 に示す。文献 1) で用いられた学習アルゴリズム構成パラメータ：許容誤差 $E_{\text{allow}} = 10^{-3.5}$ 、結合係数再定義増分量 $\eta = 1.0$ の場合、図-7 のように学習が収束せずに計算が続行不可能となった。一方、文献 2) でファイバーモデルによる仮想 RC 部材を対象に検討した学習アルゴリズム構成パラメータ：許容誤差 E_{allow} の $\alpha = 4.0$ 、結合係数再定義増分量 $\eta = 0.25$ を用いた場合、図-8 のように学習は終了するものの、推定値は大きく外れる結果を得ることとなった。

そこで、少なくとも学習および推定が実行可能なパラメータの中から、さらに推定精度が高く、推定時間の短い、最善の学習アルゴリズム構成パラメータを検討した結果を表-3 に示す。その際、学習および推定精度を比較するために精度検討指数 V_{check} を、

$$V_{\text{check}} = \left(\frac{\sum_{t=5}^{t=10} |T - O_{pi}|}{\sum_{t=5}^{t=10} |T - O_p|_{\min}} \right) \quad (1)$$

と定義した。ここに、 T ：教師値、 O_{pi} ：学習ア

表-3 各学習アルゴリズム構成パラメータにおける学習精度、推定精度および計算時間

η	$E_{\text{allow}}=10^{-3.5}$			$E_{\text{allow}}=10^{(Pl-\alpha)}$ (但し 0~200 ステップにおいては $E_{\text{allow}}=10^{-3.5}$)								
	学習 精度 V_{check}	推定 精度 V_{check}	計算時間	$\alpha=4.0$			$\alpha=4.1$			$\alpha=4.2$		
				学習 精度 V_{check}	推定 精度 V_{check}	計算時間	学習 精度 V_{check}	推定 精度 V_{check}	計算時間	学習 精度 V_{check}	推定 精度 V_{check}	計算時間
1.0	×	×	×	×	×	×	×	×	×	×	×	×
0.7	×	×	×	×	×	×	×	×	×	×	×	×
0.6	1.28	1	7 分 01 秒	1.42	1.48	24 分 40 秒	1	1.20	5 分 13 秒	×	×	×
0.5	2.33	4.29	3 分 07 秒	1.43	1.92	4 分 00 秒	1.29	1.95	14 分 00 秒	1.12	1.22	17 分 40 秒
0.4	1.93	1.49	4 分 31 秒	1.69	2.55	7 分 36 秒	1.33	3.67	16 分 03 秒	1.43	10.37	7 分 53 秒
0.3	2.36	1.66	3 分 08 秒	1.54	1.89	4 分 51 秒	1.39	31.22	11 分 17 秒	1.39	1.61	10 分 38 秒
0.25	2.36	6.48	1 分 28 秒	1.48	4.15	3 分 20 秒	1.52	4.26	4 分 55 秒	1.34	9.41	12 分 04 秒
0.2	2.18	6.00	1 分 40 秒	1.69	3.18	5 分 31 秒	1.57	43.58	4 分 52 秒	1.21	5.07	8 分 00 秒

×：学習が終了せず途中でプログラムを強制終了




図-7 復元力時刻歴の学習および推定結果 (学習および推定不良の例 : $E_{\text{allow}} = 10^{-3.5}$, $\eta = 1.0$)




図-8 復元力時刻歴の学習および推定結果 (学習良好・推定不良の例 : $E_{\text{allow}} = 10^{(|P|-4.0)}$, $\eta = 0.25$)




図-9 復元力時刻歴の学習および推定結果 (学習および推定良好の例 : $E_{\text{allow}} = 10^{(|P|-4.1)}$, $\eta = 0.6$)

ルゴリズム構成パラメータが i のときの推定値、 $|T-O_p|_{\min}$ ：復元力の最大値が含まれる 5～10 秒間のデータに対して教師値と推定値の差の絶対値を累積した値で最小のものである。すなわち、精度検討指数 V_{check} が 1.0 に近いほど精度が良いことを意味している。また、プログラム終了までの計算時間は、CPU が Intel(R) Pentium 4 プロセッサでクロック数 2.40GHz、RAM メモリが 256MB の演算性能を有するコンピュータを使用した場合の結果で表した。

表-3 より、プログラム終了までの計算時間は、 η が 0.2～0.5 のいずれの場合でも大きな差は見られなかったが、結合係数再定義増分量 η については、許容誤差 E_{allow} の設定に関わらず、0.5、0.6 の場合の推定精度が概ね高かった。また、 η が 0.7 より大きなパラメータについては、学習が収束せず、強制的にプログラムを終了した。一方、許容誤差 E_{allow} については、与え方を厳しくすると (α を大きくすると) 学習および推定精度が良好になる傾向があるが、 E_{allow} の与え方を厳しくし過ぎると学習ができなくなるので注意が必要である。本論文では、 E_{allow} の設定が $\alpha=4.3$ より厳しい与え方の場合、学習が収束せず、強制的にプログラムを終了した。

また、本論文の結果から、学習精度に関しては許容誤差 E_{allow} の設定が大きく影響し、推定精度に関しては結合係数再定義増分量 η の影響が大きく表れる傾向が認められた。

本論文に用いた実観測データに対しては、学習および推定結果を総合的に判断して、 E_{allow} の α が 4.1、 η が 0.6 の場合に、最善の学習アルゴリズム構成パラメータとなるものと考えられる。

5. まとめ

本論文では、1987 年千葉県東方沖地震において東京大学生産技術研究所千葉実験所の梁崩壊型弱小モデルで観測された実観測データを用い、学習アルゴリズムに新たなパラメータを適用したニューラルネットワークによる非線形履歴推定手法のサブストラクチャ法への適用と精度に

関する検討を行なった。本研究により得られた知見を以下に示す。

(1)本論文で検討したニューラルネットワーク学習アルゴリズム構成パラメータ（許容誤差 E_{allow} および結合係数再定義増分量 η ）は学習精度、推定精度および計算終了までの計算時間に大きな影響を与える。

(2)学習精度に関しては許容誤差 E_{allow} 設定の影響が大きく、推定精度に関しては結合係数再定義増分量 η の影響が大きい。

(3)ニューラルネットワークの学習アルゴリズムに新たなパラメータを適用した結果、RC 建物のような非線形性の強い履歴を対象にしても推定できる場合があることを確認した。具体的には、本論文に用いた実観測データに対して、 E_{allow} が $\alpha=4.1$ 、 η が 0.6 の場合に、最も精度良く履歴を推定することができた。

ただし、今回検討したパラメータが恒常的に RC 建物の履歴特性を推定できるパラメータとなりうる保証はなく、今後、より汎用性の高いサブストラクチャオンラインニューラルネットワーク実験手法を構築するためには、多くの実地震応答履歴に対し、許容誤差 E_{allow} および結合係数再定義増分量 η の影響を検討する必要があると考えられる。

参考文献

- 1)楊元植：ニューラルネットワークによる履歴推定手法を利用したサブストラクチャオンライン地震応答実験手法の開発に関する研究，東京大学博士論文，2004 年 5 月
- 2)朴珍和，中埜良昭，高橋典之：ニューラルネットワークを用いた RC 部材の地震応答履歴推定手法の高精度化・高速化の検討，日本地震工学大会梗概集，pp.472-473，2005 年 11 月
- 3)矢川元基：計算力学と CAE シリーズ 12「ニューラルネットワーク（計算力学・応用力学への応用）」，培風館，1992 年
- 4)岡田恒男：鉄筋コンクリート弱小モデル建物の実地震応答観測結果の評価に関する研究(科学研究費補助金(一般研究 B)研究成果報告書)，東京大学生産技術研究所，1988 年 3 月
- 5)Kayo Satoh, Nobuhiro Yoshikawa, Yoshiaki Nakano and Wonjik Yang : Whole learning algorithm of the neural network for modeling nonlinear and dynamic behavior of RC members, Structural Engineering and Mechanics, Vol.12, No.5, pp.527-540, 2001.
- 6)楊元植，中埜良昭，真田靖士，山内成人：ニューラルネットワークを利用したサブストラクチャ・オンライン実験，日本建築学会学術講演梗概集 B-1，pp.331-332，2004 年 8 月