

## ニューラルネットワークによる履歴推定手法を用いた オンライン地震応答実験に関する研究 —その3 ニューラルネットワークによる地震応答解析

正会員 ○ 楊 元植<sup>\*1)</sup> 同 中埜良昭<sup>\*2)</sup> 同 楠 浩一<sup>\*3)</sup>

### 1.序論

前報<sup>[1]</sup>の Back Propagation 法(以下 BP 法)と Whole Learning 法<sup>[2]</sup>(以下 WL 法)の比較に基づき、本研究では、WL 法を用い非線形モデル(Ramberg Osgood モデル)の履歴特性を学習および推定し、推定精度を検討した。また、同一の入力層の構成要素を用い実際のサブストラクチャ・オンライン実験と同一条件でニューラルネットワークによる地震応答解析を行い、実験の可能性を検討した。なお、使用したニューラルネットワークの構造は前報と同一である。

### 2.非線形データによる学習および推定

本節では前報<sup>[1]</sup>で紹介した WL 法を用いて学習を行い、Ramberg Osgood モデルを学習データとし、学習および推定を行った。入力層の構成要素は山本の研究<sup>[4]</sup>を用い、その入力層の構成要素による推定精度を検討し、地震応答解析への可能性を検討した。

#### 2.1 Ramberg Osgood モデルのパラメータ

骨格曲線の形状パラメータ<sup>[4]</sup>は履歴曲線が適切な非線形性を表現するよう  $\beta = 0.35$ ,  $\gamma = 5$ とした。履歴曲線は以下に示す式 1,2,3 に従う。また、降伏変位  $X_y$ 、降伏荷重  $P_y$  はそれぞれ 6 とした。

#### [骨格曲線]

$$\frac{X}{X_y} = \left( \frac{P}{P_y} \right)^{\beta} + \beta \cdot \left( \frac{P}{P_y} \right)^{\gamma} \quad (式 1)$$

#### [正の変位方向]

$$\frac{(X + X_{\max})}{2X_y} = \left[ \frac{(P + P_{\max})}{2P_y} \right]^{\beta} + \beta \cdot \left[ \frac{(P + P_{\max})}{2P_y} \right]^{\gamma} \quad (式 2)$$

#### [負の変位方向]

$$\frac{(X - X_{\max})}{2X_y} = \left[ \frac{(P - P_{\max})}{2P_y} \right]^{\beta} + \beta \cdot \left[ \frac{(P - P_{\max})}{2P_y} \right]^{\gamma} \quad (式 3)$$

### 2.2 入力層および出力層の設定

ニューラルネットワークを構築する際、出力層は要求される物理量とするので容易に設定できるが、入力層への構成要素は、推定量に対して重要なものを選択する必要がある。ここで、入力層の構成要素は、山本の研究と同様に最大経験変位点座標値(①最大経験変位、②最大経験荷重)、最新折り返し点座標値(③最新折り返し

点変位、④最新折り返し点荷重)、現時点での変位(⑤現在変位)の 5 ユニットとした。出力層は復元力を設定した。

### 2.3 学習および推定

2.1 節のパラメータを用い( $X_{\max} = 8, 10, 12, 14$ )における 4 ループを教師データとして学習させ、( $X_{\max} = 9, 11, 13, 15, 16, 17$ )に拡大したループを推定した。最大学習誤差は(教師値 - 出力値)=0.0202 である。学習および推定結果図 1 によると拡大したループでの推定値と目標値がほぼ一致しており、学習データ以外の範囲も精度良く推定できていることが分かる。

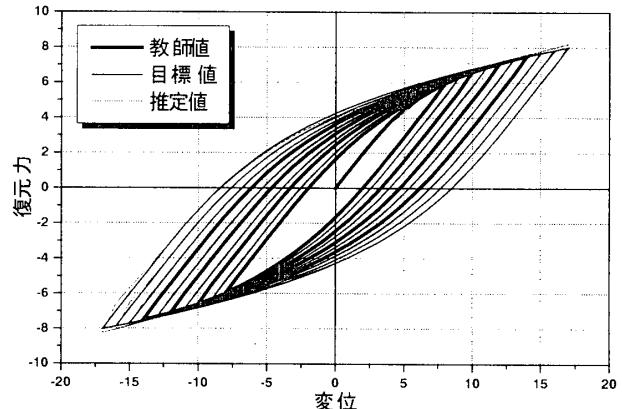


図 1 学習および推定状況

### 3.ニューラルネットワークによる地震応答解析

本節ではニューラルネットワークによるサブストラクチャ・オンライン実験の可能性を検討するため 2 節の検討結果に基づき同一の入力層構成要素を用い実際のオンライン実験と同一条件でニューラルネットワークによる地震応答シミュレーションを行った。図 2 に示すように 1 階は Ramberg Osgood モデルを設定し、2 階はニューラルネットワークによる 1 階の学習により 2 階を推定するアルゴリズムである。また、入力地震動として千葉東方沖地震波<sup>[3]</sup>(最大加速度:400gal)を用いた。

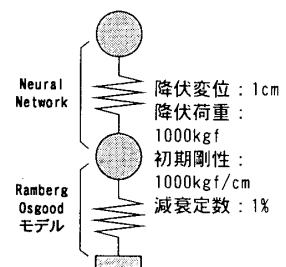


図 2 2 質点系モデル

### 3.1 モデル設定

構造物は図2に示すように2質点せん断系にモデル化した。層の降伏変位は1cm, 降伏荷重は1000kgf, 初期剛性は1000kgf/cmとし, 減衰係数は瞬間剛性比例型とし減衰定数は1%に設定した。

### 3.2 解析結果

最大学習誤差  $E_p [=1/2(\text{教師値} - \text{出力値})^2]$  は802ステップまでは  $10^{-6}$  と設定し, それ以降は  $10^{-4}$  と設定した。学習回数は30回とし, 30回を超えると  $10^{-3}$  を満足すれば終了とした。また, 剛性マトリクスの2階の剛性は現在の復元力の増分/現在の変位の増分を瞬間剛性とした。ニューラルネットワークを用いて学習させるためには入力データを基準化する必要がある。そこで, 今回は全データの最大値を用いて基準化(以下: 全 - 規準化)したのと, 現ステップまでの最大値を用いて基準化(以下: 現 - 規準化)したもの2種類で解析を行い基準化の方法が推定精度に与える影響を検討した。また, 1階と2階を Ramberg Osgood モデルを用いた解析(以下 RR 解析)と, 1階は Ramberg Osgood モデルで2階は Neural Network で推定する解析(以下 RN 解析)2種類で解析を行った。現 - 規準化を用いた解析の結果を図3および図4に示す。全 - 規準化を用いた解析の結果を図5および図6に示す。図3, 4および図5, 6からと現 - 規準化に比べて全 - 規準化を用いた解析の方が精度良く推定できることが分かる。その原因是, ニューラルネットワークの時間短縮のために入力データの基準則の変化を再学習の必要条件としなかったために, 次のような現象, すなわち①1階の学習データの変化によって最大 - 最小値の組み合わせが変化, ②ネットワークの入力データ作成のための基準化のルールが変化, ③2階の入力データも②の基準則に従うため同一データであっても基準化後の値は異なる, ④一方許容誤差範囲内であれば, 必ずしもネットワークの再学習はなされない(そのステップのネットワークが用いられる), ⑤同一データであっても異なる値が出力されるとなったためである。

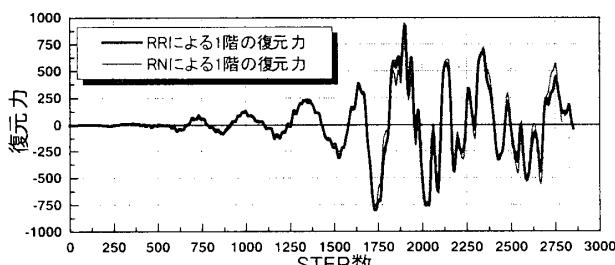


図3 現ステップで基準化した場合(1階の状況)

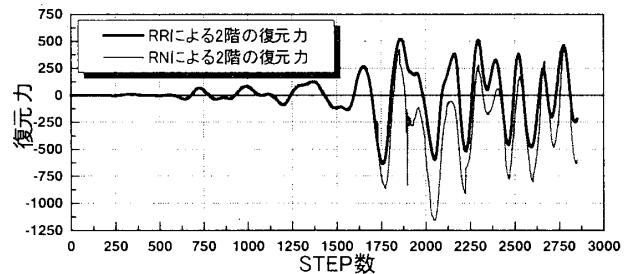


図4 現ステップで基準化した場合(2階の状況)

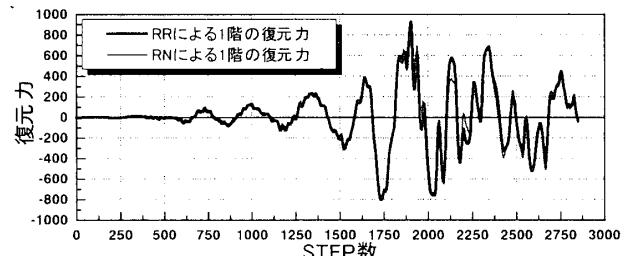


図5 全ステップで基準化した場合(1階の状況)

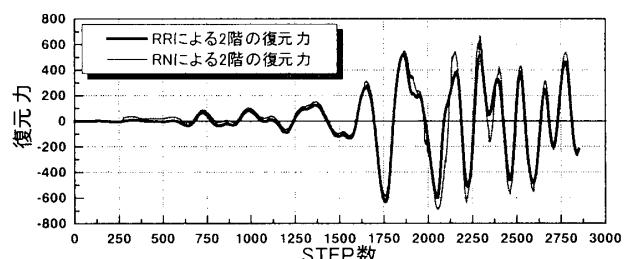


図6 全ステップで基準化した場合(2階の状況)

### 4.まとめ

本検討により地震応答解析における上層部の応答は現ステップでの最大値ではなく全ステップでの最大値でニューラルネットワークの入力値を基準化する事により精度良く推定が出来ることが分かった。

[参考文献] [1] ニューラルネットワークによる履歴推定手法を用いたオンライン地震応答実験に関する研究(その2)日本建築学会学術講演梗概集 1999年9月 [2] 左藤佳代「階層型ニューラルネットワークの一括学習アルゴリズム」日本機械学会第75期通常総会講演会講演論文集(1) 1998年3月 [3] 楠浩一「鉛直地震動が建物の動的応答性状に与える影響に関する研究」1997年東京大学博士論文 pp3-41 [4] 松田泰治, 横山義規, 入江達雄, 高山智宏「ニューラルネットワークの動的非線形問題への適用に関する研究」構造工学論文集 Vol.42A, pp635-644, 1996

1) 東京大学大学院院生  
2) 東京大学生産技術研究所 助教授・工博  
3) 東京大学生産技術研究所 助手・博(工)

Graduate Student : Univ. of Tokyo  
Associate Professor : Institute of Industrial Science, Univ. of Tokyo, Dr. Eng.  
Research Associate : Institute of Industrial Science, Univ. of Tokyo, Dr. Eng.