

# ニューラルネットワークによる非線形履歴の推定手法を用いた地震応答評価の精度に関する研究

楊 元植<sup>1)</sup>・中埜 良昭<sup>2)</sup>・真田 靖士<sup>3)</sup>

- 1)学生会員 東京大学大学院 工学系研究科, wjyang@iis.u-tokyo.ac.jp
- 2)正会員 東京大学 生産技術研究所 人間・社会部門, iisnak@iis.u-tokyo.ac.jp
- 3)正会員 東京大学 生産技術研究所 人間・社会部門, sanada@iis.u-tokyo.ac.jp

## 1.はじめに

サブストラクチャ・オンライン実験では解析部分の部材の応答を適切な数式による履歴モデルにより推定するのが通例であるが、この場合オンライン実験の最大のメリット、即ち履歴特性をモデル化することなく、動的挙動を直接的にシミュレートできるという利点を最大限には生かせない。筆者らは、解析部分で用いる履歴特性をニューラルネットワーク(以下:NN)理論に基づき、実験で得られる部材特性を用いて推定することにより、オンライン実験のメリットを最大限に生かす実験手法の開発を試みている<sup>1)</sup>。本研究では、弾塑性地震応答解析を行い推定すべき部材数の多少が架構全体の応答評価精度に与える影響を検討すべく、低層および高層の建物を対象に、部材の復元力特性としてRamberg Osgoodモデルを用いた結果と、NNモデルを用いた結果とを比較し、NNモデルの解析精度を検討した。また、この結果に基づきNNによる履歴推定手法のサブストラクチャ・オンライン実験への適用性を検討した。

## 2.ニューラルネットワークの構造

### 2.1 階層型ニューラルネットワーク

本研究では、図1に示す階層型のニューラルネットワークを用いた<sup>2)</sup>。ネットワークの学習方法には一括学習アルゴリズム法(Whole Learning法)<sup>3)</sup>を用い、結合係数の初期値は  $-0.5 \sim 0.5$  の範囲の乱数によって作成した。なお、入力層と中間層の伝達関数には図2に示すシグモイド関数を、出力層の伝達関数には図3に示す線形関数をそれぞれ適用した。




図1 階層型ニューラルネットワーク




図3 線形関数

### 2.2 ネットワークの構築

本研究におけるネットワークの構造を表1に示す。入力層は表1に示す5つの成分を用いた。文献1)では入力層の成分を最大経験変位、最大経験復元力と設定したが、本研究では最大経験折返し変位、最大経験折返し復元力と設定した。中間層は1層としREAFアルゴリズム<sup>4)</sup>を導入して5個のノードから開始した。出力値は復元力である。

最大経験折返し変位、最大経験折返し復元力と設定した。中間層は1層としREAFアルゴリズム<sup>4)</sup>を導入して5個のノードから開始した。出力値は復元力である。

表1 ニューラルネットワークの構造

基準化	[-0.5 ~ 0.5]
入力層	最大経験折返し変位 最大経験折返し復元力 最新折返し変位 最新折返し復元力 現在の変位
中間層	5個から開始
出力層	現在の変位に対応する復元力
最大誤差	$E = 1/2(\text{教師値} - \text{出力値})^2 \leq 10^{-4}$ , $10^{-3}$ (ノード数 12 以上の場合)

### 2.3 入力データの基準化方法

階層型ニューラルネットワークは、一般に入力データ数が固定(既知)の場合に使用される方法であり、入力層の各データは成分ごとに各々最大値と最小値の範囲内で基準化されるのが通例である。しかしながら本研究で想定するサブストラクチャ・オンライン地震応答実験では、実験の進行とともにそれまでに経験した履歴特性、すなわち学習すべき入力データ数が増加するため、既往の基準化方法に代わり現在変位の最大経験値の絶対値とその変位(図4のX1)に対し OS(Operator Splitting)法によるサブストラクチャ・オンライン地震応答実験の際用いる既知の剛性(一般には初期剛性 K1)から得られる復元力(K1 × X1)により基準化する方法(図4)を設定した。




図4 基準化方法

## 3.ニューラルネットワークを用いた地震応答解析

### 3.1 解析方法

解析対象建物として図5(a)のようなプロトタイプ(4層建物, 8層建物, 12層建物)を想定し、これを同図(b), (c)に示すせん断系モデルに置換した。全層の復元力特性は同一と設定した(図5参照)。本研究で

は上記の解析対象を次に示す 2 通りにモデル化して解析を行った。一方は全層の復元力特性を予め Ramberg-Osgood(以下: R-O)モデルと仮定した RR 解析(図 5(b)), 他方は実験部分として想定する 1 階を R-O モデルと仮定し, 解析部分を NN に基づいてリアルタイムに履歴特性を評価するモデルに置換した RN 解析(図 5(c))である。以上の解析方法により 4 層建物, 8 層建物, 12 層建物を対象として RN 解析と正解である RR 解析を行い, 両者を比較・検討する。

### 3.2 数値演算方法および入力地震波

地震応答解析の数値積分法には OS(Operator Splitting)法を用い, 積分時間刻みは 0.01 秒とした。本解析では特定の建物の応答評価が主目的ではないため減衰は無視した。入力地震波は 1987 年千葉県東方沖地震の東京大学生産技術研究所千葉実験所内における加速度記録の NS 成分を用いた。本研究では主要動を含む 20 秒間(計 2000 ステップ)を使用した。




図 5 建物のモデル化

### 3.3 解析結果

図 6 ~ 図 8 に各解析対象建物における RN 解析の結果を正解である RR 解析の結果と比較して示す。また, 各々図の中に RR 解析による学習階(1 階)の学習範囲を分かるように包絡線で示した。図 6 ~ 図 8 の推定結果とそれぞれの学習階の包絡線との関係により推定精度は推定階が学習階の内挿になる 4 層建物と 12 層建物の場合が高いことが分かる。しかしながら, 外挿となる 8 層建物の最も推定が悪い階も最大変位で 15%, 最大復元力で 2%程度の誤差に留まっており, 本手法は内挿のみならず外挿となる場合にも有効な手法となり得る可能性を有していることがわかる。

### 4. まとめ

以上の検討により多層でも本研究で設定した入力層及び基準化方法を用いることにより NN による履歴推定は可能であることを確認した。また, 推定精度は推定する部材数の多少より推定データ(解析部分)が学習データ(実験部分)の範囲を超えるか超えないかにより推定精度が異なることが分かった。

今後は解析部分の応答が実験部分の応答を超える場合, すなわち, NN が外挿の部分を推定する場合の適用範囲に関する検討を行う。




図 6 4 層建物での推定状況




図 7 8 層建物での推定状況




図 8 12 層建物での推定状況

### 参考文献

- 楊元植, 中埜良昭, 真田靖士: ニューラルネットワークを利用した履歴推定手法のサブストラクチャ・オンライン実験への適用とその学習方法, コンクリート工学年次論文集, Vol.25, No.2, pp.1219-1224, 2003.7
- 市川 紘: 「階層型ニューラルネットワーク非線形問題解析への応用」1993 年 共立出版株式会社
- 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( )1998 年 3 月
- A. Joghataie, J. Ghaboussi and X. Wu, "Learning and Architecture Determination Through Automatic Node Generation", *Proceedings, International Conference on Artificial Neural Networks in Engineering*, St. Louis, November, 1995