

研 究 速 報

ニューラルネットワークを利用した履歴推定手法をサブストラクチャ・オンライン実験へ適用するためのアルゴリズムとその学習方法

The Algorithm and Learning Method to apply a Neural Network to the Substructure On-Line Test

楊 元 植*・中 埜 良 昭*・真 田 靖 士*

Wonjik YANG, Yoshiaki NAKANO and Yasushi SANADA

1. は じ め に

サブストラクチャ・オンライン実験では、実験部分以外の構造要素を数値モデルに置換するのが通例であるが、この方法ではオンライン実験特有の利点、即ち実験部分から得られた構造特性を解析部分にリアルタイムに反映し得る特徴を十分に活かさない。筆者らは、解析部分の履歴特性をニューラルネットワークに基づき実験部分から推定することで、オンライン実験の利点を最大に活かす実験手法の開発を試みている¹⁾。

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ための新たな学習アルゴリズムを構築し、とくに新しい学習方法の有効性について検討する。また、ニューラルネットワークで用いる基準化方法を提案し既往の基準化方法と本研究での提案方法を用いて数値解析モデルの地震応答を推定し、それらを比較することにより、本提案手法の妥当性および実験への適用可否を確認する。

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²⁾。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)³⁾を用い、結合係数の初期値は-0.5~0.5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。

2.2 一括学習アルゴリズム法

一括学習アルゴリズム法によるニューラルネットワークの学習は教師データ(T⁽ⁿ⁾)と出力値(O⁽ⁿ⁾)の誤差(f⁽ⁿ⁾)

を結合係数(W)に関して最小化する最適化問題である。そこで(O⁽ⁿ⁾)を(ΔW_j)についてテーラー級数展開し、(f⁽ⁿ⁾)を一次近似すると式(1)が得られる。

$$f^{(n)} = T^{(n)} - \left(O^{(n)} + \sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \Delta W_j \right) \dots \dots \dots (1)$$

式(1)を全学習データについて示すと式(2)となる。

$$\{f\} = \{b\} - [A]\{\Delta W\} \quad \text{ここに} \quad \{b\} = \{T^{(n)} - O^{(n)}\} \\ [A] = \left[\sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \right] \dots \dots \dots (2)$$

式(2)の{f}は0に近似できるので、{ΔW}に対して定義すると式(3)が得られる。

$$\{\Delta W\} = [A]^{-1} \{b\} \dots \dots \dots (3)$$

ここに[A]⁻¹:ムーアペンローズ一般逆行列

上記のようにWL法は全学習データセットに対して(ΔW)を求める数値演算である。

2.3 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。中間層は1層としREAFアルゴリズム^{4,5)}を導入して5個のノ

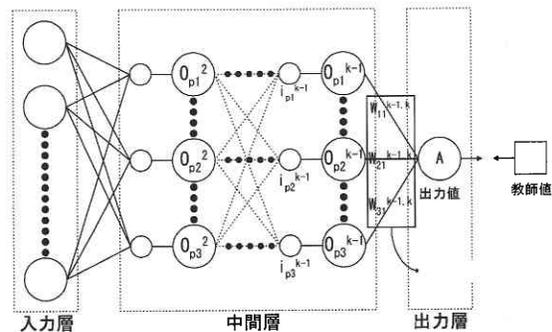
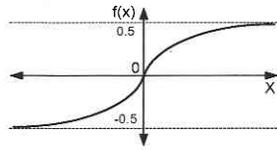


図1 階層型ニューラルネットワーク

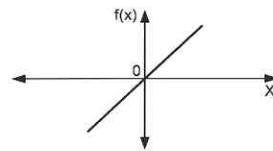
*東京大学生産技術研究所 人間・社会部門

研究 速 報



$$f(x) = \frac{1}{1 + \exp(-x)} - 0.5$$

図2 シグモイド関数



$$f(x) = X$$

図3 線形関数

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	①最大経験変位, ②最大経験復元力 ③最新折返し変位, ④最新折返し復元力 ⑤現在の変位
中間層	5個から開始
出力層	現在の復元力
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の場合)

ードから開始した。出力値は復元力である。

2.4 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の場合に使用される方法であり、入力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、試験の進行とともに入力データ数が増加するため、既往の基準化方法の適用可否を確認し、適用が困難な場合には新しい基準化方法を構築する必要がある。

そこで、本研究では入力データを各成分の最大値と最小値で基準化する既往の方法(図4)に加え、入力データを変位(表1の①, ③, ⑤)と復元力(表1の②, ④)の2グループに分類し、それぞれのグループにおける最大経験(絶対)値を最大値(正側:+0.5)と最小値(負側:-0.5)に設定し、同グループ内の各成分を共通の範囲内で基準化する(-0.5~+0.5)提案I方法(図5)と、変位の最大経験(絶対)値とその変位に対しOS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(普通は初期剛性)から得られる復元力により基準化する提案II方法(図6)を設定した。以上の3つの基準化方法を用い弾塑性地震応答解析を行い3つの基準化手法の精度を比較・検討した。

3. 解 析 方 法

3.1 解析対象

解析対象建物として図7(a)のようなプロトタイプを想定し、これを同図(b),(c)に示す2質点系のモデルに置

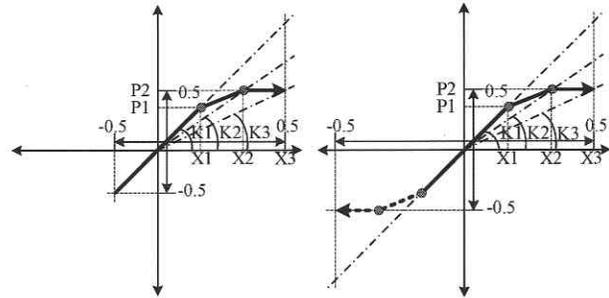


図4 既往の方法

図5 提案Iの方法

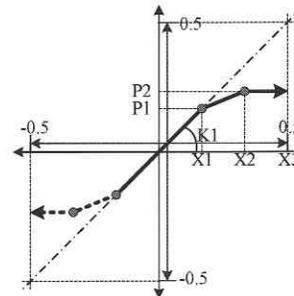


図6 提案IIの方法

換した。なお、以下の解析はニューラルネットワークを利用したサブストラクチャ・オンライン地震応答実験の可能性および精度を検討することを目的とし、特定の構造物の地震応答を評価するものではないため、各層の復元力特性は将来実験を計画している試験体の性能を反映させた(表2)。また、同様の理由から、各層質量を196 kNと仮定した。以上の仮定に基づき算定される解析対象の1次周期は0.443 sec, 2次周期は0.169 secである。

本研究では上記の解析対象を次に示す2通りにモデル化した。一つは1階, 2階ともに復元力特性を予め Ramberg-Osgood モデルと仮定した RR モデル(図7(b)), もう一つは1階を Ramberg-Osgood モデルと仮定し, 2階を Neural Network 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 モデル(図7(c))である。本研究は将来ニューラルネットワークをオンライン実験に適用するための予備検討であるため、折線近似した Takeda モデルではなく、漸次剛性低下が生じ RC 部材の実性状を反映し得る Ramberg-Osgood モデルを選択した。RN モデルでは2階の履歴特性(復元力)は1階の解析結果を学習したニューラルネットワークに基づいて2階の各入力値に対する出力値として評価される。また、出力層の「現在の復元力」は次のステップにおいて入力層の「②最大経験復元力」, 「④最新折返し復元力」を決定するためのデータとしてフィードバックされる。RN モデルの解析では基準化方法として2.4

節の3種を設定した。表2に解析パラメーター一覧を示す。

3.2 数値演算方法

地震応答解析の数値積分法にはOS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。

3.3 入力地震波

入力地震波には将来実施予定であるサブストラクチャ・オンライン実験の入力として計画している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。

3.4 学習パラメータ

ニューラルネットワークによる解析では100回の学習で解が収束しない場合、初期結合係数のパタンを乱数で変え再度学習を行わせた。この作業を20回まで繰り返し、さらに収束しない場合は中間層のノード数を1個増加させることとした。文献2)の知見に基づき、上記の過程をノード数が12個に達するまで繰り返し、12個のノードで収束しない場合は解の算定が困難であると判断した。本研究ではニューラルネットワークをオンライン実験に適用することを想定しているため、解の算定に極端に時間をかけるのは避けることが望ましく、中間層のノード数の上限を12個に設定した。よって、中間層のノード数は5~12個の範囲をとることとなるが、ノード数が多いと学習時間が長くなることを考慮し、ノード数が12個に達した後は学習に許容する誤差を 10^{-3} に緩和した(表1)。また、ニュー

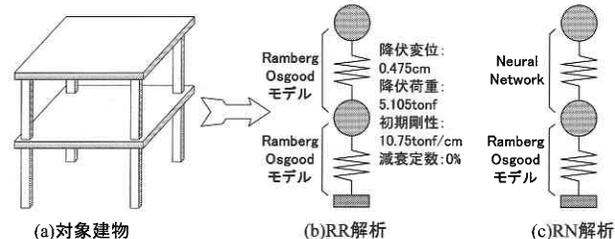


図7 建物のモデル化

表2 解析および学習パラメータ

解析種類	最大誤差	基準化方法
RR 解析 (正解)		1階と2階をRamberg Osgoodモデルで解析 (Qy = 50.1 kN, Dy = 0.476 cm)
RN 解析	10^{-4}	入力層の成分ごとに基準化する (既往)
RN I 解析	10^{-4}	最大経験変位と復元力を用い正側と負側を同じ幅で基準化(提案 I)
RN II 解析	10^{-4}	最大経験変位と初期剛性に対する復元力を用い正側と負側を同じ幅で基準化(提案 II)

ラルネットワークによる地震応答解析では学習階(1階)が最大変位と復元力を超えるとその後の学習は推定階(2階)の変位が1階より小さい場合は推定するのに必要ないところを学習することになり推定精度に悪影響を与えるので、入力加速度の最大値を超えた後から2秒まで学習を行いその結果を用い最後まで解析を行った。

4. ニューラルネットワークによる地震応答の推定

本章では2.4節で提案した2つの基準化方法と既往の方法を使用しニューラルネットワークによる地震応答解析を行い提案した2つの手法の精度を既往の方法と比較・検討した。

まず表3より、既往の方法によるRN解析では8時間かけて900ステップまで達したが、推定精度が悪く(図8)、ステップごとの学習にも長時間を要したため、900ステップで解析を終了した。

RN I解析(提案 I)、RN II解析(提案 II)では最終のステップまで達しているが、学習に要する時間はRN I解析(提案 I)よりRN II解析(提案 II)の方が5倍程度短かった。しかしながら図9により推定精度はほぼ同程度得られていることが分かる。

以上の解析結果の比較により推定精度は既往の方法より提案 Iと提案 IIの方が良いことが分かる。また、学習時間は提案 Iより提案 IIの方法で短縮できた。以下では3つの基準化方法により推定精度及び学習時間が異なる原因を検討する。推定精度に関しては参考文献1)で述べてあるためここでは提案 Iと提案 IIの方法により学習時間が異なった原因を検討した。まず、図5の提案 Iの方法によると現在変位がX1からX2に進行する際変位と復元力関係が変わることが分かる。その時ニューラルネットワークはX2での変位と復元力関係である剛性K2で現在までのデータ全てを再基準化することになる。すなわち前ステップX1までの変位と復元力関係がX2のステップで再評価されるのでX1までの学習結果が使えなくなると考えられる。しかし、提案 IIの方法(図6)では最初の剛性K1を用いるのでX2のステップでもX1での変位と復元力関係は変わらないので前ステップでの学習結果を生かせることが可能になり提案 Iより短い学習時間を要したと考えられる。最

表3 解析結果の比較 (CPUの性能: Xeon 1.4 G, 3659 Mflops)

解析種類	中間層のノード数	学習所要時間	終了Step
RN 解析(既往)	12個	8時間程度	900Step
RN I 解析(提案 I)	12個	4時間9分	2000Step
RN II 解析(提案 II)	6個	46分1秒	2000Step

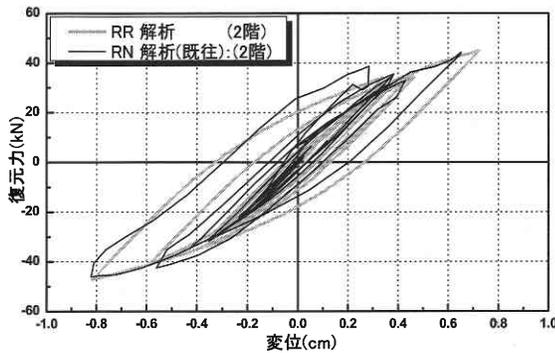


図8 RN 解析による2階の推定状況

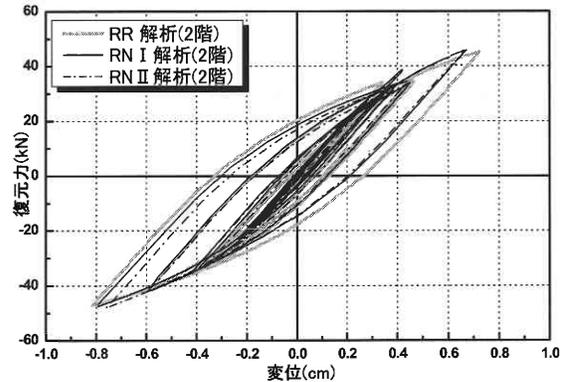


図9 RN I 解析と RN II 解析による2階の推定状況

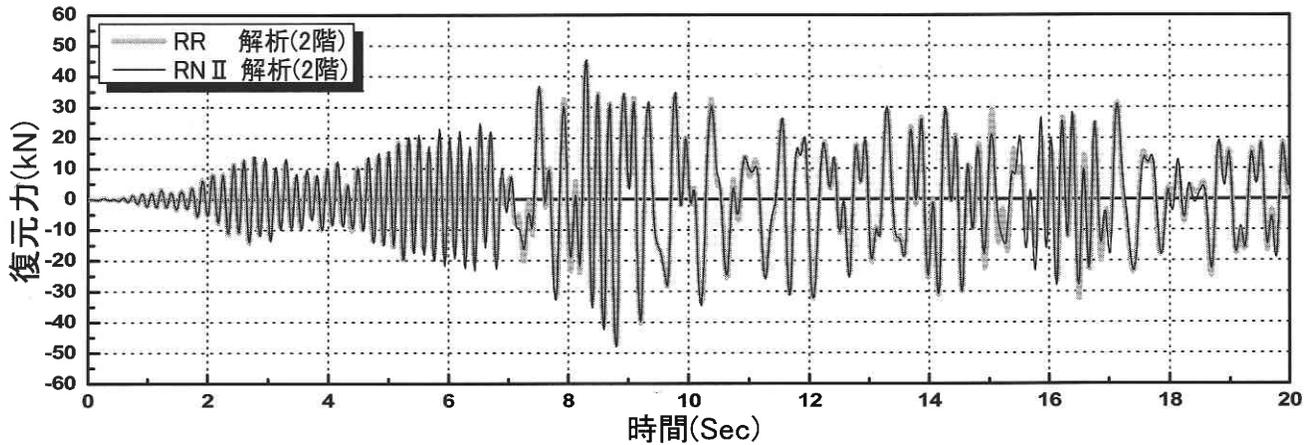


図10 提案Ⅱの方法による2階の復元力状況

後に提案Ⅱの方法による推定状況を図10に時刻歴で示した。提案Ⅱの方法により2階の復元力を極めて精度良く推定出来ていることが分かる。

5. ま と め

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し、解析部分を予め数値解析モデルに置換することなく、その履歴特性を推定する手法について検討した。

階層型ニューラルネットワークでは入力データの基準化方法により学習時間及び推定精度を大きく改善できることがわかった。また、本研究で提案した学習アルゴリズムおよび基準化方法により、推定階(2階)を予め数値解析モデルに置換することなく、その地震応答をニューラルネットワークに基づいて評価できることが明らかとなった。すなわち、サブストラクチャ・オンライン地震応答実験では試験部分の実験データを時々刻々モデリング(学習)しながら解析部分の復元力を推定することが可能であると考えられる。

(2003年9月10日受理)

参 考 文 献

- 1) 楊 元種, 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」2003年コンクリート工学年次論文集 第25巻, pp. 1219-1224
- 2) 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
- 3) Kayo Satho, Nobuhiro Yoshikawa, Yoshiaki Nakano, Wonjik Yang, "Whole learning algorithm of the neural network for modeling nonlinear and dynamic behavior of RC members, *Structural Engineering and Mechanics An International Journal*, Vol. 12, No. 5 (2001) pp. 527-540
- 4) A. Joghataie, J. Ghohoussi and X. Wu, "Learning and Architecture Determination Through Automatic Node Generation", *Proceedings, International Conference on Artificial Neural Networks in Engineering*, St Louis, November, 1995
- 5) J. Ghaboussi, and A. Joghataie, "Active Control of Structures Using Neural Networks", *Journal of Engineering mechanics Division*, ASCE, Vol. 121, No. 4, April 1995, pp. 555-567