

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応用した  
サブストラクチャ・オンライン実験手法の提案SUBSTRUCTURE ON-LINE TEST TECHNIQUE USING  
NON-LINEAR HYSTERESIS MODELLING WITH NEURAL NETWORK

楊 元 植\*, 中 埜 良 昭\*\*, 真 田 靖 士\*\*\*

Wonjik YANG, Yoshiaki NAKANO and Yasushi SANADA

In general, hysteresis models that are applied to a numerical analysis part of substructure on-line tests do not refer to an experimental behavior of members/subassemblage under loading tests on real-time basis. The objective of this study is to develop a new experimental technique for substructure on-line tests based on nonlinear hysteresis characteristics estimated with a neural network. New learning algorithms for the network applicable to substructure on-line tests are proposed focusing on input layer components and a normalization method for input data, and their validity is examined through several numerical analyses. The results show that the new algorithms proposed herein successfully reproduce the dynamic behavior of model structures.

**Keywords:** Neural Network, Substructure On-Line Test, Input Layer Component, Normalization Method, Hysteresis Characteristic

ニューラルネットワーク, サブストラクチャ・オンライン実験, 入力層成分, 基準化手法, 履歴特性

## 1. はじめに

建築物の地震応答を対象とする構造実験手法の一つとして、載荷実験と解析を併用することにより構造要素あるいは部分架構などの構造物の局所的な部分実験により構造物全体の地震応答を模擬するサブストラクチャ・オンライン実験手法が定着して久しい。本実験手法はおよそ30年前に伯野らの研究に端を発し<sup>1)</sup>、その後、高梨、岡田らによってデジタルコンピュータとアクチュエータを併用する現在の姿が形作られた<sup>2)</sup>。本手法を用いた構造実験が普及した背景には、振動台実験における諸問題（試験体の縮小に伴う諸問題や部分架構実験の困難さなど）を回避でき、実験の省力化が図れるなど、縮小模型のみならず実大の構造物の地震応答を合理的に扱うことが可能となること、また破壊過程を詳細に観察・追跡することが可能であるなどの利点が寄与したことが大きいと考えられる。

オンライン実験のもうひとつの重要な利点は、載荷実験で得られた履歴特性を解析部分にリアルタイムに反映し得る点にあるが、従来のサブストラクチャ・オンライン実験では載荷実験対象以外の履歴特性はあらかじめ数学モデルに置換するため、その履歴特性が明確である構造物や、弾性範囲に留まる構造物に対しては有効であるものの、履歴特性が明確ではない場合には、上記の利点を十分に活かしていないのが実情である。そのため、解析部分の履歴特性を何らかの手法で載荷実験部分からリアルタイムで推定できれば、オンライン実験の利点を最大限に活かせる

同時に実験精度の向上が期待できる。そこで筆者らはその履歴推定手法としてパターン認識手法の一つであるニューラルネットワーク（以下、NNと略記）に着目した。

構造物の挙動および履歴特性の同定に NN を応用した研究には、Ramberg Osgood 型の履歴特性を NN 内に構築し、NN によるモデリング手法が既存の数学モデルと対等に数値解析に導入し得る可能性を検討した山本の研究<sup>3)</sup>や、部材の予備載荷実験から得られた履歴特性を NN によりモデル化し、これをハイブリッド地震応答実験の数式モデルに代用することを試みた Zavala らの研究<sup>4)</sup>が挙げられる。また、Joghataie らは構造物の地震時の挙動を事前に NN によりモデル化し、構造物の地震応答を制御するアルゴリズムを提案している<sup>5)</sup>。これらの既往の研究では構造物の履歴推定手法として NN が有効であることを明らかにしているが、いずれの研究も解析またはオンライン実験の実施以前に NN を構築している共通点を有している。したがってこれらの手法では実験部分から得られた履歴特性を解析部分にリアルタイムに反映するという本研究での着目点の解決とはならない。またサブストラクチャ・オンライン実験への NN の応用を考えた場合、加力の進行に伴い NN が学習すべきデータ数が増加するが、このような場合にも従来の NN が適用可能か否かについては依然として未知である。

以上の背景の下、本論文では NN による履歴推定手法を応用したサブストラクチャ・オンライン実験手法の実現を目的として、本実験手

\* 東京大学大学院工学系研究科 大学院生  
\*\* 東京大学生産技術研究所 助教授・工博  
\*\*\* 東京大学地震研究所 助手・博士(工学)

Graduate Student, School of Engineering, The University of Tokyo  
Assoc. Prof., Institute of Industrial Science, The University of Tokyo, Dr. Eng.  
Research Assoc., Earthquake Research Institute, The University of Tokyo, Dr. Eng.

法に NN を適用するための新たな学習アルゴリズムを構築する。特に実験の進行に伴い増加するデータから履歴特性をリアルタイムで効率良く学習するための入力層成分およびその新たな基準化方法を提案し、仮想建物の数値解析を通じてその妥当性を検証した。すなわち、従来のサブストラクチャ・オンライン実験で通常用いられる数値解析モデルと本研究で提案する NN を用いた弾塑性地震応答解析をそれぞれ行い、両者を比較することで NN を用いた解析の精度を確認した。加えて、NN による推定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るため、建物の層数をパラメータとする同様の数値解析を行い、本研究が提案する NN による履歴推定手法を用いたサブストラクチャ・オンライン実験手法の適用範囲について議論した。

なお、本稿では NN のオンライン実験への適用アルゴリズムを解析的に検討した結果を報告するが、筆者らはここで提案する手法を用いた 2 層サブストラクチャ・オンライン実験をすでに実施しており、その詳細については稿を改めて報告したい。

## 2. ニューラルネットワークの構築

### 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<sup>6)</sup>を用いた。また、学習効率の向上に関する知見<sup>7)</sup>に基づき NN の学習方法には一括学習アルゴリズム法 (Whole Learning 法)<sup>8)</sup>を用いた。なお、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、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



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

図 2 シグモイド関数



$$f(x) = x$$

図 3 線形関数

### 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 NN の学習は、学習データ数を  $N$  (2.4 節で述べるとおり実験時にはその载荷進行に伴い増加する)、 $n$  番目の学習データの入力に対するネットワークの出力を  $O^{(n)}$ 、対応する教師データを  $T^{(n)}$  とした場合、式(1)の誤差関数  $f^{(n)}$  により構成される多目的関数  $\{f\}$  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  $\Delta W_j$  についてテーラー級数展開し、 $f^{(n)}$  を一次近似すると式(2)が得られる。

$$f^{(n)} = T^{(n)} - O^{(n)} \quad (n=1, \dots, N) \quad (1)$$

$$f^{(n)} = T^{(n)} - \left( O^{(n)} + \sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \Delta W_j \right) \quad (2)$$

式(2)を全学習データ ( $n=1 \sim N$ ) について示すと、式(3)となる。

$$\{f\} = \{b\} - [B]\{\Delta W\} \quad \text{ここで } \{b\} = \{T^{(n)} - O^{(n)}\}, [B] = \left[ \sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \right] \quad (3)$$

正しく出力値を推定できる NN が構築されると式(3)の  $\{f\}$  は 0 に近似できるので、 $\{\Delta W\}$  に対して式(4)が得られる。 $\{f\}$  が許容誤差以下となるまで収束計算を行えば、 $\{W\}$  が求められる。

$$\{\Delta W\} = [B]^{-1} \{b\} \quad \text{ここで } [B]^{-1} : \text{ムーアペンローズ一般逆行列} \quad (4)$$

上記のように、一括学習アルゴリズム法は全学習データセットに対して  $\{\Delta W\}$  を求める数値演算として定式化できる。

### 2.3 ネットワークの構造

本研究における階層型 NN の構造を表 1 に示す。本稿では入力層(ここでは現载荷ステップをステップ  $i$  と想定して記述)として表 1 に示す载荷ステップ  $i-1$  以前の①最大経験変位および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、载荷ステップ  $i$  での⑤現在変位、の 5 成分を用いた入力層 A<sup>9)</sup> と、入力層 A の最大経験変位および最大経験復元力の代わりに①最大経験折返し変位と②最大経験折返し復元力を用いた入力層 B の 2 通りを設定した。中間層のノード数については明確な設定基準がないため入力層と同数である 5 個から開始し、学習しながらノード数を自動的に増加させていく Joghataie らによるアルゴリズム<sup>9)</sup>を導入した。出力値は入力層 A, B いずれの設定においても载荷ステップ  $i$  での現在変位に対応する復元力である。

表 1 ニューラルネットワークの構造

入力層 A	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
入力層 B	①最大経験折返し変位, ②最大経験折返し復元力 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	1 層, ノード数 5 個から開始
出力層	現在の變位 (⑤) に対応する復元力

### 2.4 入力層成分の基準化方法

階層型 NN は、一般に入力データ数が固定 (既知) の場合に用いられ、入力層の各データは成分ごとに各々の最小値と最大値 (いずれも既知) 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学習すべき入力データ数  $N$  が増加し、これに伴い応答の最小値や最大値が変動する。よって、従来用いられてきた入力データの基準化方法が時々刻々増加するデータにも適用できるか否かを確認し、適用が困難な場合には新たな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の最小値と最大値である各成分の  $[X1', X2]$  および  $[P1', P2]$  をそれぞれ  $[-0.5, 0.5]$  に基準化する既往の方法 (図 4(a)) 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、グループごとにその最大経験絶対値の幅  $[-X2, X2]$  および  $[-P2, P2]$  をそれぞれ  $[-0.5, 0.5]$  に基準化する基準化方法 1<sup>9)</sup>

(図4(b)), 変位の最大経験絶対値 $[-X_2, X_2]$ とその変位に対しOS (Operator Splitting) 法<sup>10)</sup>によるオンライン地震応答実験の際に用いる初期剛性から得られる復元力 $[-P_2, P_2]$ をそれぞれ $[-0.5, 0.5]$ に基準化する基準化方法II (図4(c))を設定した。

なお, 本検討ではいずれの基準化方法においても最大経験変位の更新ごとに再基準化を行ったが, 上記の基準化方法I, IIは, 最大経験変位の更新時においても再学習をできるだけ回避し, それまでに構築したネットワークを直接利用する(即ち再学習が不要)ことで計算時間の短縮を意図したものである<sup>9)</sup>。さらに基準化方法IIはIに比べて復元力に関するデータ(表1の②と④)の再基準化が生じにくい点により計算時間の短縮が期待できる方法である。

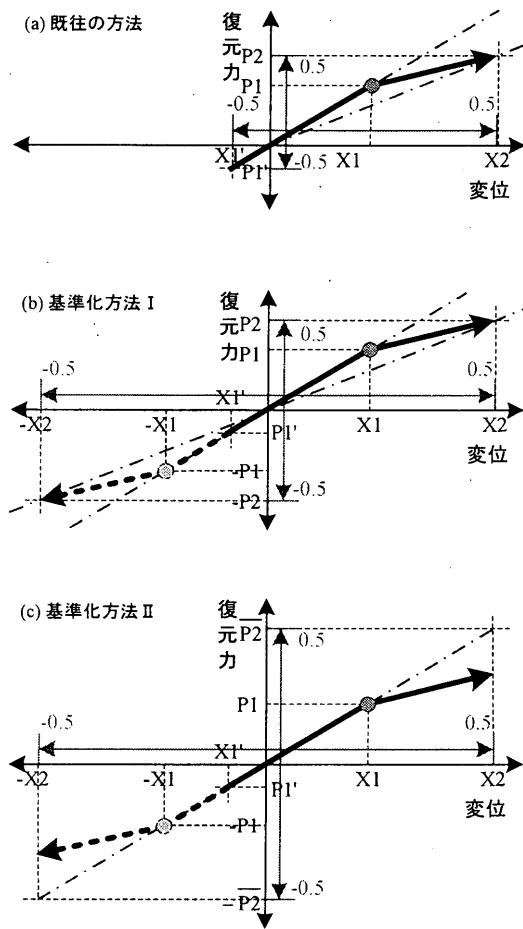


図4 基準化方法

### 3. サブストラクチャ・オンライン実験への適用方法

サブストラクチャ・オンライン地震応答実験(図5)は, 検討対象とする構造物の中で特にその応答性状に大きな影響を与えられられる部材あるいは架構を載荷実験対象として抜き出し, その他の部分は何らかの解析モデルで置換し, 構造実験とコンピュータによる数値解析を併用して構造物全体の地震応答を模擬する実験手法である。本実験手法では, 解析部材の復元力特性をあらかじめ確定的な数値解析モデルに設定するのが通例であるが, その履歴特性が明確ではない場合はオンライン実験特有の利点, 即ち, 載荷実験で得られた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。そこで, 本研究では実験

から得られる履歴特性をNNによりリアルタイムで解析モデルに反映する手法を提案する。本手法が実現すれば, 解析部分で用いる履歴特性を載荷実験結果に基づきリアルタイムに推定することが可能となるため, オンライン実験の利点を最大限に活かすことが可能になる。

図6にNNによる非線形履歴の推定手法を利用したサブストラクチャ・オンライン実験のフローを示す。同図に示すように, 本実験手法では毎ステップごとに得られる実験データを用いてNNの学習をリアルタイムで行い, その結果構築されたNNを解析部分の復元力推定に用いる。また解析部分で推定された復元力(出力値)は次ステップの入力データとしてフィードバックする。以上のように, 本研究で提案するNNのアルゴリズムは, 学習および推定を載荷実験とリアルタイムで行い, かつ得られた出力値をその後の入力データとしてフィードバックする点に従来のNNの応用技術とは一線を画する特徴を有する。




図5 サブストラクチャ・オンライン地震応答実験の概念

### 4. ニューラルネットワークを用いた地震応答解析

本研究ではNNを用いたサブストラクチャ・オンライン実験の実現可能性を検討するため, 実験を想定した数値解析(数値実験)を実施した。具体的には, 以下に示す2自由度を有する仮想建物について, 各層の復元力特性にRamberg-Osgoodモデルを用いた解析モデルの地震応答を正解と仮定し, オンライン実験を想定しNNを用いた解析モデルによりその応答の再現を試みた。ただし, 本研究で提案した入力層成分および基準化方法の従来手法に対する優位性を確認するため, これらをパラメータとして解析を行った。また,

本研究では本手法の実現可能性を検討するため, その第一歩として最も簡単な条件である, 学習対象となる実験部材と推定対象となる解析部分の部材の履歴特性が同一である架構を仮定した。これは, 例えば多層骨組において同一断面特性を有する梁部材への適用を想定したものに対応するが, 本提案に対する検証実験の容易さおよびその予備検討としての位置づけを考慮し, 本研究では図7のように各層の復元力が等しい2層せん断系モデルを設定している。

#### 4.1 解析対象

解析対象として図7(a)のようなプロトタイプ建物を想定し, これを同図

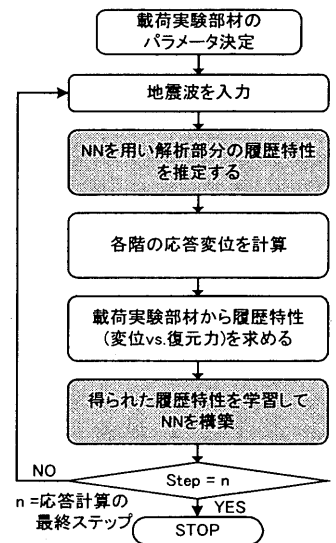


図6 NNを利用したサブストラクチャ・オンライン地震応答実験のフロー (■はNNによる推定ルーチン)

(b)に示す1階、2階ともに復元力特性を Ramberg-Osgood モデルと仮定した RR モデル（正解と仮定）と、同図(c)に示す1階を Ramberg-Osgood モデルと仮定し、2階を 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 モデル（NN を用いたサブストラクチャ・オンライン実験を想定）の2通りの2質点系モデルに置換した。本研究では将来 NN をオンライン実験に適用するための予備的検討であるため、Bi-Linear モデルや Takeda モデル等の折線近似した履歴モデルではなく、漸次剛性低下が生じる部材あるいは部分架構の非線形特性をより直接的に反映し得る Ramberg-Osgood モデルを実挙動の代用として選択した。RN モデルでは、2階の履歴特性（復元力）は1階のそれを学習した NN 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、表1に示す出力層の「現在の変位に対応する復元力」は次のステップ以降において入力層 A では「②最大経験復元力」、「④最新折返し復元力」を、入力層 B では「②最大経験折返し復元力」、「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する。RN モデルでは、入力層の成分として2.3節の2種、基準化方法として2.4節の3種を設定した。解析パラメータの一覧を表2に示す。




図7 建物のモデル化

表2 入力層成分に対する解析および学習パラメータ

解析種類	入力層成分	基準化方法
RR 解析 (正解とする)		
RN 解析	RNA (入力層A)	入力層の成分ごとの基準化 (既往の方法: 図4(a)参照)
	RNB (入力層B)	
RN I 解析	RN I A(入力層A)	最大経験変位および最大経験復元力を用いた基準化 (基準化方法 I: 図4(b)参照)
	RN I B(入力層B)	
RN II 解析	RN II A(入力層A)	最大変位及初期剛性に対するその復元力を用いた基準化 (基準化方法 II: 図4(c)参照)
	RN II B(入力層B)	

#### 4.2 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)<sup>10)</sup>法を用い、積分時刻は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。入力地震波には将来実施予定である NN を用いたサブストラクチャ・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。

#### 4.3 学習方法と収束条件

NNによる履歴推定手法を用いた弾塑性地震応答解析では推定誤差を  $[T^m - O^m]^2 / 2$  とし、これに対してまず許容誤差を  $10^{-4}$  に設定し100回の学習を行い、NNの解（結合係数  $W$ ）が収束しない場合は初期結合係数のパターンを乱数により再定義後、再度学習を行った。この作業を最大20回繰り返し、それでも解が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。本研究ではNNをサブストラクチャ・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になる。また、文献6)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、それでも解が収束しない場合は解の算定が困難であると判断し許容誤差を  $10^{-4}$  から  $10^{-3}$  に緩和した。また、学習範囲内での内挿推定を念頭に、NNの学習時間短縮を図るべく入力加速度の最大値生起時刻まで学習を行い、その後は最大応答変位の更新時に再学習を行うこととした。すなわち、本検討では大振幅までの学習結果に基づき大振幅後の小振幅履歴を推定している点に留意されたい。しかし、本検討では大振幅後の小振幅での最大推定誤差は  $10^{-3}$  を超えなかった。

#### 4.4 解析結果


提案した入力層成分および基準化方法と既往の方法による推定精度を検討するため、NNを用いた地震応答解析より得られた2階の荷重-変位関係について検討した。図8に各入力層成分について既往の基準化方法を用いた場合の推定状況を、図9、図10に各入力層成分について本研究が提案した基準化方法 I、IIを用いた場合の推定状況をそれぞれ示した。また、応答計算に要した時間及び中間層の最終ノード数を表3にまとめて示した。ただし、同表の数値はCPUが Xeon、クロック数が 1.4GHz、3659Mflops 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あり、その殆どが NN の学習に要した時間である。図8(a)および表3より、既往の基準化方法による入力層 A の成分を用いた RN 解析では推定精度が悪く、ステップごとの学習にも長時間を要したため、約8時間かけ900ステップで解析を終了した。しかし、図8(b)より、入力層 B の成分を用いた RN 解析では約11時間を要したものの最終ステップまで精度良く推定できていることがわかる。また、図9と図10の結果より、入力層成分、基準化方法に関わらず、それぞれの推定精度は同程度であったが、表3より、基準化方法 II の学習時間は入力層 A 成分では基準化方法 I の 1/5、入力層 B 成分では従来方法の 1/10、基準化方法 I の 1/3 程度にまで短縮されており、基準化方法 II による計算時間は実験実施を想定した場合にも現実的な値であることがわかる。

以上の結果より、NNにより構造物の非線形履歴を精度よく推定でき、NNを用いたサブストラクチャ・オンライン実験手法の実現可能性が示された。また、入力データの基準化方法については、基準化方法 II が最も学習時間が短く推定精度も良好であることが明らかとなった。しかし、RN II A と RN II B の結果を比較すると、入力層成分の違いによる推定精度の優位性は明確ではなかったため、以下で行う多自由度系の解析では入力層成分をパラメータとして検討する。


表3 解析時間と最大ノード数の比較 (CPU: Xeon 1.4G, 3659Mflops)

解析種類	中間層の最大ノード数	計算所要時間	最終誤差	終了 Step	
RN 解析	RNA (入力層A)	12 個	約 8 時間	-	900 Step
	RNB (入力層B)	12 個	約 11 時間	0.968	2000 Step
RN I 解析	RN I A(入力層A)	12 個	4 時間 9 分	0.968	2000 Step
	RN I B(入力層B)	12 個	3 時間 3 分	0.968	2000 Step
RN II 解析	RN II A(入力層A)	6 個	46 分 1 秒	0.450	2000 Step
	RN II B(入力層B)	8 個	59 分 26 秒	0.545	2000 Step

\* 最終ステップでの  $[教師値 - 出力値]^2 / 2 (x 10^{-3})$




(a) 入力層 A による RN 解析の 2 階の推定状況




(b) 入力層 B による RN 解析の 2 階の推定状況

図 8 既往の基準化方法による NN を用いた地震応答の推定




(a) 入力層 A による RN I 解析の 2 階の推定状況




(b) 入力層 B による RN I 解析の 2 階の推定状況

図 9 基準化方法 I による NN を用いた地震応答の推定



(a) 入力層 A による RN II 解析の 2 階の推定状況



(b) 入力層 B による RN II 解析の 2 階の推定状況

図 10 基準化方法 II による NN を用いた地震応答の推定

## 5. 推定部材数の多少が応答評価精度に与える影響

前章より NN を用いた地震応答解析の実現可能性が示されたことを受け、最後に、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、解析対象建物の層数をパラメータとして前章と同様の解析を行った。

### 5.1 解析対象および解析方法

対象建物の規模は図 11 に示すように 4, 8, 12 層建物を想定した。ただし、以下の解析は NN 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ており、特定の構造物の地震応答を評価するものではないため、各層の重量や復元力特性などの詳細は図 7 の 2 層建物の値をそのまま用い、全層において同一であると仮定した。また、前節の知見により、入力層成分には入力層 A と入力層 B の両者を、入力データの基準化方法には基準化方法 II を用いた。入力地震動や学習パラメータ等の解析方法については前章と同じである。なお、いずれの建物においても履歴特性の学習階は 1 階を対象とした。

### 5.2 解析結果

入力層 A、入力層 B による各建物の応答推定結果について、推定精度が最も良い階と悪い階の荷重-変位関係を図 12 と図 13 に示す。また、入力層 B による結果のうち最も推定精度が悪い 8 層建物の 3 階の復元

力と変位の時刻歴を図 14 と図 15 に示す。これらの図中には RN 解析による学習階 (1 階) の学習範囲として学習階の応答を包絡線で示した。

図 12、図 13 の推定結果と学習範囲を示す包絡線から、入力層 A より入力層 B の方が、また推定階 (1 階以外) の応答が学習階 (1 階) の内挿となる 4 層建物と 12 層建物の場合に推定精度が高いことがわかる。一方、8 層建物については、入力層 A による最も推定精度が悪い階での外挿部分では推定値が発散し不安定な履歴を示すのに対し、入力層 B でははるかに安定して応答が推定されており、応答変位最大時で 15%、復元力最大時で 10% 程度の誤差に留まっていることから (図 14、図 15)、本手法は内挿推定のみならず外挿推定となる場合にも有効な手法となる可能性を有していることがわかる。以下では簡単な解析例を通じて推定精度に関する検討を試みる。







図 11 建物規模およびモデル化




(a) 4層建物での推定状況




(a) 4層建物での推定状況




(b) 8層建物での推定状況



(b) 8層建物での推定状況



(c) 12層建物での推定状況



(c) 12層建物での推定状況

図12 入力層Aによる推定状況 (基準化方法IIによる)

図13 入力層Bによる推定状況 (基準化方法IIによる)




図 14 推定精度が最も悪い 8 層建物の 3 階の復元力推定状況 (基準化方法 II および入力層 B を用いた場合)




図 15 推定精度が最も悪い 8 層建物の 3 階の変位推定状況 (基準化方法 II および入力層 B を用いた場合)

### 5.3 入力層成分の違いが推定精度に与える影響

既往の入力層成分である入力層 A と本研究で提案した入力層 B の履歴推定精度を, Ramberg-Osgood モデルの履歴を学習した NN を例に検討した。教師データは変位 (5) の刻みを 0.5mm とし折返し変位を 10mm および -10mm に設定した非線形履歴であり, 推定データは教師データから抜き出した変位刻み 2mm の非線形履歴である。

それぞれの教師データと推定結果を図 16 および表 4 に示す。表 4 の(a)より, 入力層成分 A を用いた場合では同一の履歴特性であっても推定データの刻みが変化することで, 最大経験変位①が逐次更新される範囲 (図 16 の 0 → 10mm と 10 → 14mm の範囲) では入力層データに大きな差異が生じていることがわかる。すなわち, 同一の⑤現在変位に対して, 本来は等しくあるべき①~④のデータが, 学習データと推定データで一部異なっており, そのため精度良く学習した NN であるにもかかわらず精度良い推定結果が得られていない。一方入力層 B を用いた場合は上記の差異が①~④に見られず (表 4(b)参照), したがって精度良い推定結果が得られている。すなわち, NN による推定精度の向上を図るためには, 入力層データの安定性を考慮しその成分を慎重に設定することが重要である。





図 16 Ramberg-Osgood モデルの非線形履歴の推定

表4 入力層Aと入力層Bのデータの比較

(a) 入力層Aの学習時と推定時のデータ [単位: mm, kN]

学習データ						推定データ					
入力層 (入力層成分A)					出力層	入力層 (入力層成分A)					出力層
①	②	③	④	⑤	復元力	①	②	③	④	⑤	復元力
07.5	46.4	0.0	0.0	8.0	47.7	6.0	42.1	0.0	0.0	8.0	49.4
08.0	47.7	0.0	0.0	8.5	48.9						
08.5	48.9	0.0	0.0	9.0	50.0						
09.0	50.0	0.0	0.0	9.5	51.1						
09.5	51.0	0.0	0.0	10.0	52.0	8.0	47.7	0.0	0.0	10.0	56.0
10.0	52.0	10.0	52.0	9.5	46.7						
10.0	52.0	10.0	52.0	9.0	41.3						
10.0	52.0	10.0	52.0	8.5	36.0						
10.0	52.0	10.0	52.0	8.0	30.7	10.0	52.0	10.0	52.0	8.0	35.8
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
11.5	54.7	-10.0	-52.0	12.0	55.6	10.0	52.0	-10.0	-52.0	12.0	56.6
12.0	55.5	-10.0	-52.0	12.5	56.3						
12.5	56.3	-10.0	-52.0	13.0	57.1						
13.0	57.1	-10.0	-52.0	13.5	57.8						
13.5	57.8	-10.0	-52.0	14.0	58.5	12.0	55.5	-10.0	-52.0	14.0	59.6

(b) 入力層Bの学習時と推定時のデータ

学習データ						推定データ					
入力層 (入力層成分B)					出力層	入力層 (入力層成分B)					出力層
①	②	③	④	⑤	復元力	①	②	③	④	⑤	復元力
0.0	0.0	0.0	0.0	8.0	47.7	0.0	0.0	0.0	0.0	8.0	48.5
0.0	0.0	0.0	0.0	8.5	48.9						
0.0	0.0	0.0	0.0	9.0	50.0						
0.0	0.0	0.0	0.0	9.5	51.1						
0.0	0.0	0.0	0.0	10.0	52.0	0.0	0.0	0.0	0.0	10.0	52.6
10.0	52.0	10.0	52.0	9.5	46.7						
10.0	52.0	10.0	52.0	9.0	41.3						
10.0	52.0	10.0	52.0	8.5	36.0						
10.0	52.0	10.0	52.0	8.0	30.7	10.0	52.0	10.0	52.0	8.0	31.6
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
10.0	52.0	-10.0	-52.0	12.0	55.6	10.0	52.0	-10.0	-52.0	12.0	55.9
10.0	52.0	-10.0	-52.0	12.5	56.3						
10.0	52.0	-10.0	-52.0	13.0	57.1						
10.0	52.0	-10.0	-52.0	13.5	57.8						
10.0	52.0	-10.0	-52.0	14.0	58.5	10.0	52.0	-10.0	-52.0	14.0	58.5

5.4 外挿推定が推定精度に与える影響

階層型 NN では中間層の値が図2のシグモイド関数で規定されるため、NN による推定値の出力範囲を以下のように評価することができる。まず、出力値は式(5)のように中間層の値に出力層の結合係数を掛けた各値の和として算出される。本研究ではシグモイド関数の出力範囲を[-0.5~0.5]と定義しているため、出力値  $O^{(n)}$  の推定可能範囲は文献11)により式(6)のように評価される。例として、入力層成分 B を用いた地震応答解析結果(図13)の最終ステップまでの学習結果を用いて、NN による推定値の出力範囲(出力値の上・下限値)を算定すると4層建物では[-89.9~89.9kN]、8層建物では[-88.6~88.6kN]、12層建物では[-120.6~120.6kN]となる。すなわち、本研究で検討した NN による履歴推定は必ずしも内挿推定が必要条件ではなく、外挿となる場合においても推定が可能となる余地があることを示しており、図15に示すとおり本稿での検討例では基準化方法IIおよび入力層 B を用いた場合、応答変位の誤差は最大15%であった。

$$\text{出力値}(O^{(n)}) = \sum W_{i,j}^{k-1,k} O_i^{k-1} \quad (5)$$

$$\text{ここで、} O_i^{k-1} = f_i^k \left( \frac{x_i^{k-1}}{\sigma_i^{k-1}} \right) = 1 / (1 + e^{-x_i^{k-1}}), \quad [x_i^{k-1} = \sum W_{i,j}^{k-2,k-1} O_j^{k-2}]$$

$$-\sum |W_{i,j}^{k-1,k}| / 2 \leq O^{(n)} \leq \sum |W_{i,j}^{k-1,k}| / 2 \quad (6)$$

6. まとめ

NN による非線形履歴の推定手法をサブストラクチャ・オンライン実験に適用することを目的に、増加する学習データを NN でリアルタイムに効率良く学習するための入力層データの成分およびその基準化方法を提案し、その有効性を多層の弾塑性地震応答解析を通じて検

討した。本研究により得られた成果を以下にまとめる。

- ① 載荷実験の進行に伴い増加する学習データに対して NN の入力層データの基準化方法を本稿で新たに提案した基準化方法IIとすることにより、NN の学習時間の著しい短縮および推定精度の向上を実現した。
- ② 本稿で提案した入力層 B を用いることにより、安定した推定結果が得られ、NN による推定精度の向上を図るためには入力層データの安定性を考慮しその成分を慎重に設定することが重要であることがわかった。
- ③ NN を用いた多層建物の弾塑性地震応答解析により、推定すべき部材数が多数の場合でも、応答を精度良く推定できることを確認した。特に推定階の応答が学習階の内挿推定となる場合には、極めて精度良い推定結果が得られた。
- ④ 一方、外挿推定となる場合においては、精度は低下するものの応答推定が可能となる余地があることを、NN の推定可能範囲(上・下限値)の理論解を検討することにより示した。
- ⑤ 以上より、本稿で提案した入力層成分および基準化方法は、NN による履歴推定手法を応用したサブストラクチャ・オンライン実験の実用的アルゴリズムとして利用できると考えられる。

謝辞

本研究の実施にあたって、東京大学生産技術研究所・吉川暢宏助教授および元技官・佐藤佳代氏の助言を、また一部文部省科学研究費補助金・萌芽的研究(代表者:中埜良昭, 課題番号:08875101)の補助を得た。ここに謝意を表す。

参考文献

- 1) 伯野元彦, 四俣正俊, 原司: 計算機により制御された, はりの動的破壊実験, 土木学会論文報告集, No.171, pp.1-9, 1969.11
- 2) 高梨晃一, 宇田川邦明, 関松太郎, 岡田恒男, 田中尚: 電算機・試験機オンラインシステムによる構造物の非線形地震応答解析(その1: システムの内容), 日本建築学会論文報告集, No.229, pp.77-83, 1975.3
- 3) 山本広祐: ニューラルネットワークによる履歴挙動のモデリングと数値解析への応用, 構造工学論文集, Vol.38A, pp.85-94, 1992.3
- 4) C. Zavala, K. Ohi K. Takanashi, "Neural Network Predictor in Hybrid Earthquake Response: Performance and Applicability", *Journal of Structural Engineering*, Vol.40B, Architectural Institute of Japan, March 1994
- 5) A. Joghataie, J. Ghaboussi and X. Wu, "Learning and Architecture Determination Through Automatic Node Generation", *Proceedings of International Conference on Artificial Neural Networks in Engineering*, St Louis, November, 1995
- 6) 市川統: 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, 共立出版株式会社, pp.29-30, 1993
- 7) 楊元植, 中埜良昭, 楠浩一: 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, 一その2 BP法とWL法の比較および入力層が推定精度に与える影響一, 日本建築学会大会学術講演梗概集, 構造I, pp.411-412, 1999
- 8) 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
- 9) 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
- 10) 中島正愛, 石田雅利, 安藤和博: サブストラクチャ仮動的実験のための数値積分法, 一サブストラクチャ法を用いた仮動的実験の開発一, 日本建築学会論文報告集, No.417, pp.107-117, 1990.11
- 11) 楊元植, 中埜良昭, 楠浩一: 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, 日本建築学会大会学術講演梗概集, 構造II, pp.1053-1054, 1998

(2003年12月8日原稿受理, 2004年5月6日採用決定)