

ニューラルネットワークの履歴推定手法を用いた
サブストラクチャ・オンライン実験の精度向上に関する研究
RESEARCH ON THE PRECISION IMPROVEMENT OF THE SUBSTRUCTURE ON-LINE TEST
BY HYSTERESIS ESTIMATION TECHNIQUE OF NEURAL NETWORK

楊 元植*, 中埜良昭**, 真田靖士***

Wonjik YANG, Yoshiaki NAKANO and Yasushi SANADA

In general, the substructure On-line test where the hysteresis model is applied for the numerical analysis part cannot simulate dynamic behavior of experiment in real time. The objective of this study is to develop the new experimental technique by estimating the characteristics of numerical part in the substructure On-line test through the neural network. The new learning algorithm to apply a neural network to the substructure On-line test was built, and the normalization method of the new learning data that experiment data to increase in real time can be learned efficiently was proposed and examined about that validity through the numerical analysis. In addition, the numerical experiment, which made the early data of an experiment a parameter was done as a spare analysis of the substructure On-line test by the neural network, and this research discussed the realization and precision of a substructure On-line test by the neural network.

Keywords : Neural Network, Substructure On-Line Test, Whole Learning Algorithm, 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, 一括学習アルゴリズム, 履歴特性

1. はじめに

建築・土木構造物を対象とする構造実験での利用が浸透したサブストラクチャ・オンライン実験^{1),2)}では、試験部分以外の構造要素を数値解析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、即ち試験部分から得られた復元力特性を解析部分の構造要素にリアルタイムに反映し得るという利点を活かさない。そこで、筆者らは解析部分の構造要素の履歴特性を、ニューラルネットワークに基づき実験から得られる結果を用いて推定し、これを逐次解析部分に反映することにより、オンライン実験の利点を最大限に活かす実験手法の開発を試みている³⁾。

筆者らは文献 3)においてニューラルネットワークの学習に用いる入力データの合理的な基準化方法を既に提案したが、本論文では、より学習時間を短縮できる新たな基準化方法を提案するとともに、その基準化手法の有効性を検証した。具体的には、ニューラルネットワークによる履歴推定手法を用いた地震応答解析を行い、学習に要する時間及び応答の推定精度について、文献 3)の方法を用いた場合と比較・検討を行った。また、上記の検討により得られた学習時間が短く推定精度もよい基準化方法を用い、将来実施予定であるニューラルネットワークによるサブストラクチャ・オンライン地震応答実験の予備解析として、実験初期のデータの処理方法をパラメータとする数値実験を行い、本研究が提案するニューラルネットワー

クの履歴推定手法を用いたサブストラクチャ・オンライン地震応答実験の実現性および従来の手法である数式モデルを用いたサブストラクチャ・オンライン実験に対する優位性を示した。

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⁴⁾を用いた。また、文献 5)の知見により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)⁶⁾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学習データ数を N で表し、 n 番目の学習データの入力に対するネットワーク出力を $O^{(n)}$ 、対応する教師データを $T^{(n)}$ と表すと、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 (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(2)が得られる。

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

*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

***東京大学生産技術研究所 助手・博(工)

Graduate Student, School of Engineering, The University of Tokyo

Associate Professor, Institute of Industrial Science, The University of Tokyo, Dr. Eng.

Research Associate, Institute of Industrial Science, The University of Tokyo, Dr. Eng.

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

式(2)を全学習データについて示すと式(3)となる。

$$\{f\} = \{b\} - [A]\{\Delta W\} \quad (3)$$

$$\text{ここで } \{b\} = \{T^{(n)} - O^{(n)}\}$$

$$[A] = \left[\sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \right]$$

式(3)の $\{f\}$ は 0 に近似できるので、 $\{\Delta W\}$ に対して定義すると式(4)が得られる。

$$\{\Delta W\} = [A]^{-1} \{b\} \quad (4)$$

ここで $[A]^{-1}$: 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。

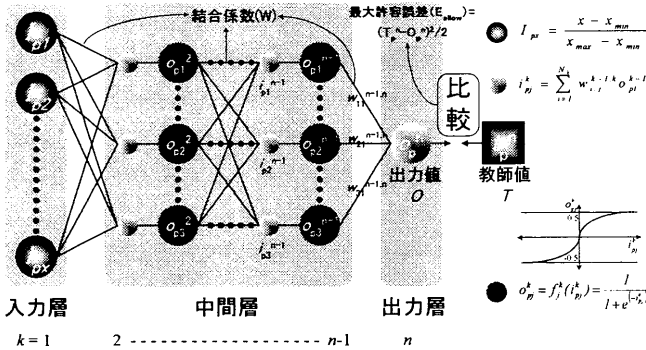




図1 階層型ニューラルネットワーク



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

図2 シグモイド関数



$$f(x) = X$$

図3 線形関数

2.3 ネットワークの構造

本研究における階層型ニューラルネットワークの構造を表1に示す。入力層は表1に示すように载荷ステップ $n-1$ 以前の最大経験変位点座標値(①最大経験変位および②最大経験復元力)および最新変位折り返し点座標値(③最新折返し変位および④最新折返し復元力)、载荷ステップ n での⑤現在変位の5つの成分⁷⁾、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個のノードから開始し、学習しながら中間層のノード数を自動的に増加させていく Ghaboussi らによるアルゴリズム⁸⁾を導入した。出力値は载荷ステップ n での現在変位に対応する復元力とした。最大誤差は表1に示すように最初は 10^{-4} に設定し、中間ノード数が12個に達すると解の算定に長時間要するため、本研究では最大許容誤差を 10^{-3} に緩和した。

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	1層, ノード数5個から開始
出力層	現在の変位に対応する復元力
最大許容誤差	$E = 1/2(\text{教師値}-\text{出力値})^2 \leq 10^{-4}$, 10^{-3} (ノード数12の場合)

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(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I³⁾(図4(b))、変位の最大経験絶対値 $[-X2, X2]$ とその変位に対し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 $[-\overline{P2}, \overline{P2}]$ 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。

3. ニューラルネットワークによる履歴推定を利用した地震応答の推定

本章では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地震応答解析のパラメータおよび手法を説明する。また、本研究で新たに提案した基準化方法と既往の方法の精度を比較検討するため、ニューラルネットワークを利用した地震応答解析を行い、学習時間がより短く、かつ推定精度がより高い基準化方法を検討する。

3.1 解析対象建物

解析対象建物として図5(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構造詳細を反映させ(図5)、各層重量を196kN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次固有周期は0.443s、2次固有周期は0.169s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。すなわち一つは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5(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5(c))である。また、図6にニューラルネットワークを利用した地震応答解析の流れ図を示す。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に解析パラメータ一覧を示す。




図5 建物のモデル化




図4 基準化方法

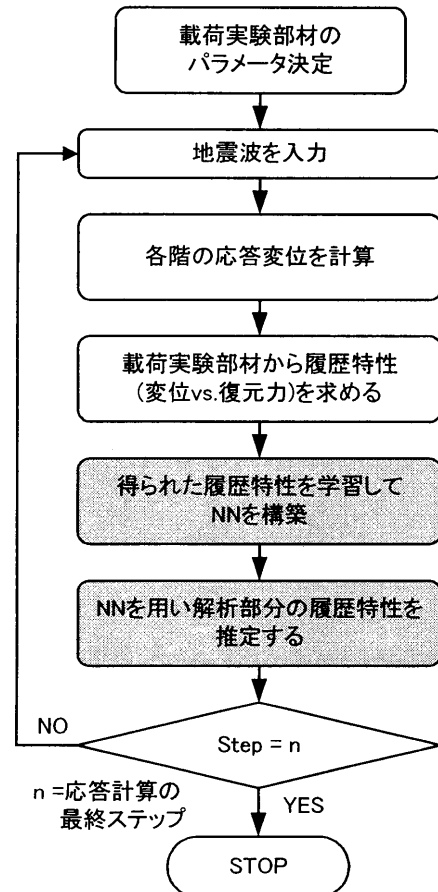


図6 ニューラルネットワークを利用した地震応答解析の流れ

表2 解析および学習パラメータ

解析種類	最大許容誤差*	基準化方法
RR 解析 (正解)		
RN 解析	10^{-4}	入力層の成分ごとに基準化する(従来一般的な手法)
RN I 解析	10^{-4}	最大経験変位と最大経験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してその変位に対応する復元力を用い正側と負側を同じ幅で基準化(提案 II)

* 中間ノード数が12個に達すると最大許容誤差を 10^{-3} に緩和

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。

3.3 学習パラメータ

弾塑性地震応答解析では100回の学習でニューラルネットワークの解が収束しない場合、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、収束しない場合は中間層のノード数をさらに1個増加させることとした。文献4)の知見に基づき、中間層のノード数が増加するほど学習に長時間を要するため、そのノード数は入力層のノード数の2倍程度までとした。従って、本研究ではニューラルネットワーク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個からスタートし最大許容誤差を満足しないステップでは1個ずつ追加され最終的には12個までの範囲をとるが、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個に達した後はノード数を追加せず学習に許容する誤差を 10^4 から 10^3 に緩和した(表1)。また、ニューラルネットワークの推定は学習結果に基づいて学習データの範囲の中で推定値を求めるので、学習時間を短縮するため、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ようにした。すなわち、本検討では最大振幅前の学習結果により最大振幅後の小振幅の履歴を推定している点に留意されたい。しかし、最大振幅後の小振幅の誤差は、最大許容誤差 10^3 を超えなかった。

3.4 基準化方法の違いによる推定精度の検討

提案した2つの基準化方法及び既存の方法の精度を検討するため、ニューラルネットワークによる弾塑性地震応答解析より得られた2階の復元力-変位関係の推定状況を図7に、また学習に要した時間及び中間層のノード数を表3に示した。表3より、既存の方法による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7(a))、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。


図7(b)より、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1/5倍程度であった。しかしながら推定精度はほぼ同程度得られていることが分かる。よって以下の解析ではRN IIの方法を用いることとした。

表3 解析結果の比較


(CPUの性能: Xeon 1.4G, 3659Mflops)

解析種類	中間層の最終ノード数	計算終了に要した時間	終了Step
RN 解析(既往)	12 個	8 時間程度	900 Step*
RN I 解析(提案 I)	12 個	4 時間 9 分	2000 Step*
RN II 解析(提案 II)	6 個	46 分 1 秒	2000 Step

*RN では 823 Step 以降、RN I では 951 Step 以降許容誤差を 10^3 に修正した。



(a) RN 解析による2階の推定状況



(b) RN I 解析と RN II 解析による2階の推定状況

図7 ニューラルネットワークによる地震応答の推定

4. サブストラクチャ・オンライン実験へのニューラルネットワークの適用性の検討

本章では、3章でのニューラルネットワークによる弾塑性地震応答解析手法と基準化方法(RN II 解析)を用い、本手法をサブストラクチャ・オンライン実験に応用することの有効性を示すとともに、その実用化を念頭に基礎的な検討を行う。具体的には、ニューラルネットワークを用いたサブストラクチャ・オンライン実験手法と従来の手法を用いて数値実験を行い、両者の比較を通じて従来の手法に内在する問題を指摘する。また、サブストラクチャ・オンライン実験の際、実験初期に必要なとするニューラルネットワークによるデータ処理方法が応答に与える影響をパラメータ解析により検討し、本研究が提案する手法が実用化に耐え得ることを確認する。


4.1 解析方法

解析対象建物およびモデル化は3章と同様である。既往のサブストラクチャ・オンライン地震応答実験では構造物の挙動に最も大きく影響を与える部材に対して実験を行い、他の解析部分に対しては数式モデルを使用するのが通例である。この場合、実験部分については実験結果から直接復元力特性を得るが、解析部分はあらかじめ仮定した数式モデルに基づき復元力特性を推定するため、その推定誤差により応答結果が影響を受ける。そこで以下では、OS法を用いてサブストラクチャ・オンライン実験を実施する場合を想定し上記の問題を解析的に検討することを目的に、想定する実験手法として以下の3通りを設定し(表4)、その結果を比較した。


- ① 1階、2階ともに実験を行う場合(建物全体を対象とする実験に相当し、これを正解値とみなす: OT(Online Test)解析)
- ② 1階は実験、2階が数式モデルの場合(通常のサブストラクチャ・オンライン実験に相当: SOT(Substructure Online Test)解析)

表4 解析パラメータ


解析種類	OT解析(正解)		SOT解析		NSOT解析	
解析部分(2階)						
実験部分(1階)						



(a) 既知の剛性 K^A が $1.2K^T$ の時の解析部分(2階)の推定状況



(b) 既知の剛性 K^A が $1.5K^T$ の時の解析部分(2階)の推定状況



(c) 既知の剛性 K^A が $3.0K^T$ の時の解析部分(2階)の推定状況

図8 3つの解析手法による解析部分(2階)の推定結果

- ③ 1階は実験, 2階がニューラルネットワークによるモデル化を用いた場合(ニューラルネットワークによるサブストラクチャ・オンライン実験に相当: NSOT(Neural network Substructure Online Test)解析)

ただし, 上記は数値実験であるため実験を想定する部分(以下, 実験部分と表記)と数式モデルによる解析を想定する部分(以下, 解析部分と表記)ともに復元力特性モデルとして Ramberg Osgood モデルを用いるが, 実験部分の降伏点割線剛性を K^T , 解析部分を K^A と仮定することによって両者の違いを表現した。数式モデルの剛性 K^A には真の剛性 K^T の 1.2 倍, 1.5 倍, 3.0 倍の 3 通りを設定した(1.0 倍の場合は上記の①OT 解析と②SOT 解析の結果は一致する。なお, 3.0 倍は解の安定性を検討することを目的に比較的大きな値をあえて設定したものである。)。また, ニューラルネットワークをサブストラクチャ・オンライン実験に適用する場合(上記の③NSOT 解析), 第 1 ステップでは学習データが存在せず, 加えて, 実験初期のデータは不安定な場合が多いため, はじめは何らかの剛性あるいは数式モデルを仮定してあるステップで実験データに基づいたニューラルネットワークにより推定した履歴特性へ移行する方法を採ることが想定される。そこで, 応答変位が降伏変位の 0.1 倍に達するまでは②と同様の数式モデルを用い, その後, ニューラルネットワークによるモデルに移行することとした。この場合, 数式モデルからニューラルネットワークモデルに移行するタイミングも問題となるが, 移行変位を降伏変位の 0.05 倍, 0.2 倍とした場合についても検討し, これらによる結果の差は生じないことを確認している⁹⁾。

4.2 解析結果

1階と2階とも実験を行うオンライン実験を想定した①OT 解析, 1階は実験を行い2階は数式モデルにより推定するサブストラクチャ・オンライン実験を想定した②SOT 解析, 2階の数式モデルの代わりに1階の実験データに基づいたニューラルネットワークにより推定を行う解析③NSOT 解析, 以上3つの解析を行いそれぞれの解析部分(2階)の推定結果を図8に示す(図8(a): 数式モデルに仮定する剛性 K^A が真の剛性 K^T の 1.2 倍, (b): 1.5 倍, (c): 3.0 倍)。図8の3つの解析結果(ここでは最大応答値, その生起時刻, 応答波形に着目する。)の比較により SOT 解析では, 仮定剛性 K^A と真の剛性 K^T との差が大きくなるほど解析部分の推定値と正解である OT 解析の応答との差が大きくなるのが分かる。しかし, NSOT 解析では仮定剛性 K^A と真の剛性 K^T の差に関わらず真の剛性に移行してからは精度良く正解である OT 解析に収束していることが分かる。すなわち, SOT 解析では仮定剛性 K^A の大小により解析部分(2階)の応答が大きく影響を受け, また, 実験部分(1階)の応答は解析部分の応答に依存するので結果として真の応答を得ることができなくなると考えられる。しかし, NSOT 解析では仮定剛性 K^A から真の剛性 K^T に移行した後は仮定剛性 K^A の影響は受けず正解である OT 解析を精度良く推定していることでニューラルネットワークを用いることによりサブストラクチャ・オンライン実験の精度を向上できると考えられる。

5. まとめ

ニューラルネットワークによる履歴推定手法をサブストラクチャ・オンライン実験手法に適用することを目的に, リアルタイムに増加する学習データを効率的に学習するためのデータ処理方法を提

案するとともに, 本手法の有効性を弾塑性地震応答解析を通じて確認した。また, 本手法を用いて構築したニューラルネットワークを将来実施予定であるサブストラクチャ・オンライン地震応答実験(以下: NSOT 実験)に応用することを想定した数値解析を行い, 従来用いられてきた手法に対する優位性を示した。本研究により得られた成果を以下にまとめる。

①ニューラルネットワークの入力データの基準化方法を本稿で新たに提案した手法とすることによりニューラルネットワークの学習時間の短縮および推定精度の向上を実現した。

②既往のサブストラクチャ・オンライン実験を想定した SOT 解析では, 解析部分の応答, さらには実験部分の応答が予め仮定する数式モデルによって大きく影響を受けた。しかし, ニューラルネットワークによるサブストラクチャ・オンライン実験を想定した NSOT 解析では実験部分のデータに基づいて解析部分の応答を推定するため, 同一の構造詳細を有する部材の応答を予めモデル化することなく精度よく推定することができた。

③ニューラルネットワークによるサブストラクチャ・オンライン実験では, 実験初期からニューラルネットワークによる履歴推定を行うことができないため, 実験初期では何らかの剛性あるいは数式モデルを仮定する必要があるが, この初期の操作はニューラルネットワークによるモデルに移行後の履歴推定精度に大きく影響しないことを確認した。

④以上より, 提案した基準化方法とリアルタイムで学習しながら推定するアルゴリズムを用い実験のデータを精度よくモデル化できれば, 本稿で提案する履歴推定手法を応用したサブストラクチャ・オンライン実験は十分実用に耐え得ると判断できる。また, 実験時間に対しては既往の基準化方法より 1/9 程度に短縮できた基準化方法 II と最大許容誤差の適切な設定により実験データに対するニューラルネットワークの計算時間を短縮できるので, ニューラルネットワークを用いたサブストラクチャ・オンライン実験が可能であると考えられる。

参考文献

- 1) 伯野元彦, 四俵正俊, 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, 第171号, 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建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, 第229号, pp.77-83, 1975.3
- 3) 楊元植, 中笠良昭, 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
- 4) 市川絃: 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
- 5) 楊元植, 中笠良昭, 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, ーその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, 日本建築学会大会学術講演梗概集, 構造I, pp.411-412, 1999
- 6) 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, pp.527-540, 2001
- 7) 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, 土木学会, pp.85-94, 1992.3
- 8) 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
- 9) 楊元植, 中笠良昭, 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をサブストラクチャ・オンライン実験へ適用するための検討, 日本建築学会大会学術講演梗概集, 構造II, pp.863-864, 2003