

論文 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

楊 元植*¹ ・ 中埜 良昭*² ・ 真田 靖士*³

要旨: RC 部材の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という特徴を活かせない。本研究では, 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により, オンライン実験の利点を最大限に活かす新しい実験手法の開発を試みている。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学習アルゴリズムを中心に検討した。

キーワード: 鉄筋コンクリート, サブストラクチャ・オンライン実験, ニューラルネットワーク, 地震応答解析

1. はじめに

RC 部材の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せない。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。

本論文では, とくにサブストラクチャ・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, 新しい学習方法の有効性について検討する。既往の学習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¹⁾。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)²⁾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。

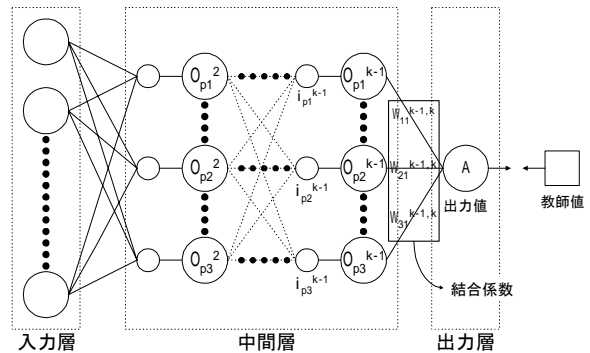


図-1 階層型ニューラルネットワーク




図-2 シグモイド関数

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。

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

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

式(1)を全学習データについて示すと式(2)となる。

$$\{f\} = \{b\} - [A]\{\Delta W\} \quad \text{ここに} \quad \{b\} = \{T^{(n)} - O^{(n)}\} \quad (2)$$

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

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

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

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^{3), 4)}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	①最大経験変位 ②最大経験復元力 ③最新折り返し点変位 ④最新折り返し点復元力 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以上の場合)

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では、入力データを成分ごとにそれぞれの最大値と最小値の範囲内で基準化して用いるのが通例であるが、一般に本手法は入力データ数が固定の場合に使用される方法である。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に加え、入力データを変位と復元力の2通りに分類し、それぞれの最大経験(絶対)値を最大値(正側)と最小値(負側)に設定し、各成分を共通の範囲内で基準化する新しい方法とした。(図-4)。




図-4 学習データの基準化方法

3. 解析方法

3.1 解析対象

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-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。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NNに基づき、この時、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せた。学習させたニューラルネットワークにより2階の各入力値に対する出力値(表-1)として評価した。逐次また、RNモデルの解析では基準化方法として2.4節の2種を設定した。表-2に解析パラメーター一覧を示す。




図-5 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
RN 解析 I	10^{-4}	入力層の成分ごとに基準化する (既往の方法)
RN 解析 II	10^{-4}	最大変位と復元力での基準化 (新しい方法)
RR 解析	1 階と 2 階を Ramberg Osgood モデルで 解析($Q_y = 50.1 \text{ kN}$, $D_y = 0.476 \text{ cm}$)	

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を評価することを目的としていないため、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(図-6)。




図-6 入力加速度

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ー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 1)の知見に基づき、上記の過程をノード数が 20 個に達するまで繰り返し、20 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 20 個に設定した。よって、中間層のノード数は 5~20 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)。

4. ニューラルネットワークによる地震応答の推定

4.1 RN 解析

はじめに、入力データの基準化を既往の方法により行い、RR 解析の応答の評価を試みた結果を示す。図-7 に RN 解析 I における再学習回数および中間層のノード数の経過を、図-8 に学習の最大誤差の経過を示す。ただし、図-7 では応答のピークを含む 600~900 ステップについて示している。図-7 によると、RN 解析 I では 824 ステップで中間層のノード数が 12 個にまで増加した。従って、図-8 より 824 ステップ以降の学習時の最大誤差が 10^{-3} まで増加し(3.4 節)、学習精度が低下していることがわかる。




図-7 RN 解析 の学習回数と中間層のノード数




図-8 RN 解析 の学習の最大誤差




図-9 RN 解析 による 1 階の履歴特性の学習結果

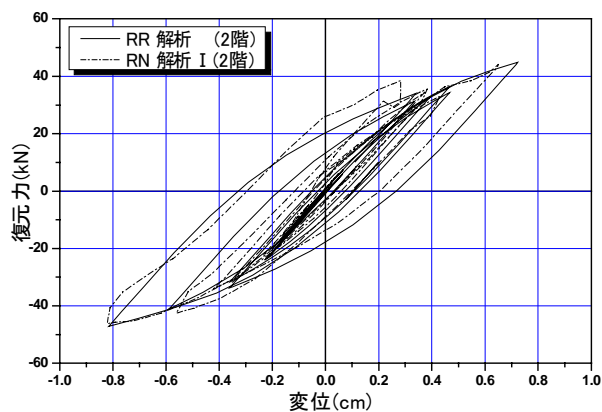


図-10 RN 解析 による 2 階の履歴特性の推定結果

また、図-9, 10 に既往の基準化方法に基づく RN 解析 I から得られた 1, 2 階の復元力と変位の関係 (1 階:学習結果, 2 階:推定結果)を正解である RR 解析の結果と比較して示した。ただし、両図では応答のピークを含む 7~9 秒について示した。RN 解析 I 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-10)、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-9 の 1 階の学習結果に比べ図-10 の 2 階の推定精度が非常に悪いことが確認できる。そこで、これらの原因を調べるため、例として 812, 813 ステップにおける 1 階の学習データを取り上げ、既往の基準化方法による学習データの操作、経過についてやや詳細に検討した。表-3 には 812, 813 ステップにおける学習時の入力データを示した。同表の基準化前のデータに着目すると、812 から 813 ステップにかけて現在変位成分のみが更新されている。本解析で用いた既往の基準化方法ではすべての入力成分に対して独立に基準化が行われるため、813 ステップで現在変

位が更新されると現在変位に対する再基準化が行われ、同時に 812 ステップ以前の変位も再基準化されることとなる (表-3 の(a), (b)から 812 ステップの現在変位が更新されているのがわかる)。すなわち、812 ステップまでの学習結果を 813 ステップ以降そのまま用いることができなくなるため、結果、再学習が必要となり、解析に非常に長い時間を費やすこととなる。ここでは 812, 813 ステップを例に解説を加えたが、これはすべての解析ステップに共通の現象であり、時々刻々と変化する入力データに対して既往の基準化方法を適用する場合の大きな障害の一つである。また、2 階の推定精度が悪い点についても、既往の基準化方法に内在する問題が原因であると考えられる。例えば 2 階の復元力を実際に推定する場合、1 階の学習データにより構築されたニューラルネットワークに 2 階の入力データを与えることにより解を算定することとなるが、仮に 2 階の入力データが同じであっても、1 階の入力データが部分的に更新されることにより、2 階の出力値がその影響を大きく受けて、出力結果が変化するという不具合が生じるなど、解を不安定にし得る要因が指摘できる。

表-3 既往の基準化による値

Step	最大経験変位 (cm)	最大経験復元力 (kN)	最新折り返し変位 (cm)	最新折り返し復元力 (Kn)	現在変位 (cm)	教師値 (kN)
基準化前のデータ						
811	0.478	36.858	0.215	21.070	-0.287	-27.362
812	0.478	36.858	0.215	21.070	-0.350	-31.203
813	0.478	36.858	0.215	21.070	-0.401	-33.585
(a)812 Step での基準化後のデータ						
811	0.499	0.500	0.500	0.264	-0.424	-0.444
812	0.499	0.500	0.500	0.264	-0.500	-0.500
Min	0.000	0.000	-0.318	-29.645	-0.350	-31.203
Max	0.478	36.858	0.478	36.858	0.478	36.858
(b)813 Step での基準化後のデータ						
811	0.499	0.500	0.500	0.264	-0.370	-0.412
812	0.499	0.500	0.500	0.264	-0.441	-0.466
813	0.499	0.500	0.500	0.264	-0.500	-0.500
Min	0.000	0.000	-0.318	-29.645	-0.401	-33.585
Max	0.478	36.858	0.478	36.858	0.478	36.858

4.2 RN 解析

RN 解析 I から得られた知見に基づいて、本論文ではより合理的な基準化の方法について検討する。新しく提案する基準化方法は過去の学習結果を以後の学習に反映することができ、解析時間を短縮し得る方法が望ましい。既往の基準化方法は各入力成分を

独立に基準化するのが通例であったが、本研究では入力データを変位と復元力の2通りに分類し、それぞれの最大経験(絶対)値を正側と負側の最大値と最小値に設定して他のすべての入力成分に適用する方法(図-4)を提案する。本手法を前節で取り上げたRN解析Iの812, 813ステップに適用した場合の結果を表-4に示し、既往の方法との違いを解説する。同表から813ステップの現在変位が更新されても、最大経験変位より定義される基準化の範囲内であるため、812ステップの値に変化がないことがわかる。よって、812ステップまでの学習結果を813ステップ以降に活かすことができ、且つ、2階の応答を推定するためのニューラルネットワークが1階の現在変位の更新のみによりパタンを崩す現象も回避される。本基準化方法によりRN解析IIの学習時間は最終の2000ステップまで4時間9分と大幅に短縮することができた。

表-4 新しい基準化による値

(a)812 Stepでの基準化後のデータ						
811	0.500	0.500	0.225	0.286	-0.300	-0.371
812	0.500	0.500	0.225	0.286	-0.366	-0.423

(b)813 Stepでの基準化後のデータ						
811	0.500	0.500	0.225	0.286	-0.300	-0.371
812	0.500	0.500	0.225	0.286	-0.366	-0.423
813	0.500	0.500	0.225	0.286	-0.420	-0.456
Min	-0.478	-36.858	-0.478	-36.858	-0.478	-36.858
Max	0.478	36.858	0.478	36.858	0.478	36.858

RN解析IIの中間層のノード数と学習回数の経過を図-11に示す。また、各ステップの最大誤差の経過を図-12に示す。図-11によると860ステップまで中間層のノード数が8個で収束していることがわかる。RN解析Iの同ステップにおけるノード数12個よりも大幅に小さく、RN解析IIの解の収束精度が優れていることを示している。RN解析IIでは951ステップ以前は設定誤差 10^{-4} で収束し、それ以降は 10^{-3} で収束する結果となった。




図-11 RN解析の学習回数及び中間層のノード数




図-12 RN解析の学習の最大誤差状況

最後に、図-13, 14にRN解析IIによる1, 2階の荷重-変位関係をRR解析Iと比較して示した。ただし、図-9, 10と同様に7~9秒について示した。図-9, 13より学習階(1階)の相関はほぼ同程度であるが、図-10, 14より推定階(2階)では新しい基準化方法によるRN解析IIがより精度良く推定できることがわかる。

また、RN解析IIによる復元力の時刻歴をRR解析の結果と比較して図-15, 16に示した。両図より全解析区間を通じて1階の学習結果, 2階の推定結果ともに極めて精度よく評価できていることがわかる。




図-13 1階の学習状況

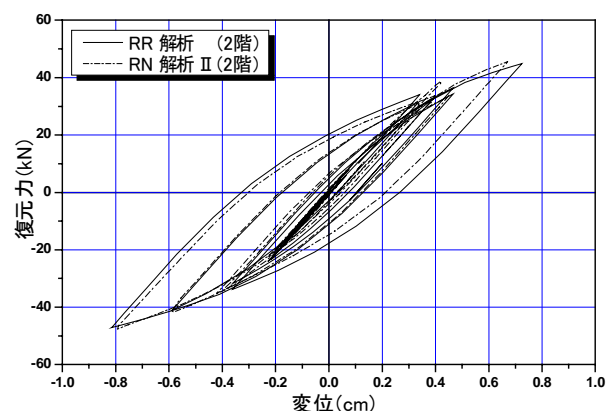


図-14 2階の推定状況




図-15 1階の復元力学習状況




図-16 2階の復元力推定状況

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、中間層のノード数を増やすことによって、より複雑な関数を近似できることがわかった。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。

参考文献

- 1) 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
- 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(I) 1998年3月
- 3) 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
- 4) J. Ghaboussi, and A. Joghataie, "Active Control of Structures Using Neural Networks", *Journal of Engineering mechanics Division*, ASCE, Vol. 121, No.4, April 1995, pp555 - 567