

ニューラルネットワークを活用した 構造物の応答評価に関する一考察

松田 泰治¹・明渡 貴史²・玻座真 翼³・梶田 幸秀⁴

¹正会員 九州大学大学院 教授 工学研究院 社会基盤部門

(〒819-0395 福岡県福岡市西区元岡744)

E-mail:mazda@doc.kyushu-u.ac.jp

²学生会員 九州大学大学院 工学府 建設システム工学専攻 修士課程

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail:akedo@doc.kyushu-u.ac.jp

³学生会員 九州大学大学院 工学府 建設システム工学専攻 修士課程

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail:hazama@doc.kyushu-u.ac.jp

⁴正会員 九州大学大学院 準教授 工学研究院 社会基盤部門

(〒819-0395 福岡県福岡市西区元岡744)

E-mail:ykajita@doc.kyushu-u.ac.jp

本研究ではニューラルネットワークの有する関数近似能力に着目し、ニューラルネットワークが数学モデルと同等のモデル化能力を有することを、Ramberg-Osgoodモデル、バイリニアモデル、武田モデルの履歴曲線を再現することにより確認した。また、学習済みのニューラルネットワークが未学習の地震動を対象とした動的解析を行う際の数値演算サブルーチンとして利用可能であることを、実地震波を対象に数学モデルとの比較により検証した。また、学習に用いる波形を実地震動に近づけることにより推定精度の向上を図った。

Key Words : nural network, dynamic analysis, Ramberg-Osgood, Bilinear, Takeda

1. はじめに

ディープラーニングは、人間の脳神経系の仕組みを工学的に模したニューラルネットワークを多層に重ねたものにより構成される。このニューラルネットワークは学習能力と自己組織化能力を有する情報処理システムであり、その特徴は、あらかじめ与えられた多数の入出力データから任意の連続写像関数を自動的に作成できることにある。従って、それらの関係式の形が事前に明示できていなくても、簡易に近似関係を構築することができる。また、ディープラーニングは信頼性の高いデータを収集して学習させることで、人間が経験や知識、勘をもとに学習してさらに高度な推論や思考、判断等を行うように、

エキスパートの代役を実現可能にするものとして、様々な予測システムへの応用が試みられている。

本研究では、このディープラーニングの技術を用いて、履歴復元力特性のモデル化を行い、構築したネットワークの動的応答解析への適用性について検討した。一般に、新材料や新たに開発された免震・制震装置などの履歴復元力特性のモデル化は実験で得られた荷重-変位関係から、その新材料や装置の特徴をとらえた最適なモデルを数学モデルより選択し、パラメータを調整することで行われる。しかし、新材料や装置の特徴をとらえた最適なモデルが複雑となる場合や、実挙動をうまく再現できない場合もある。一方、ニューラルネットワークは高度な学習能力を有するため、実験等で得られた荷重-変位関

係を自動的に認識・記憶して数値演算サブルーチンとして非線形動的応答解析に活用できる可能性がある、本研究では、ディープラーニングを用いることで、荷重－変位関係のみから、正確な動的挙動を再現できるニューラルネットワークの構築を最終目的とし、まず、Ramberg-Osgoodモデル、バイリニアモデル、武田モデルの3つの履歴曲線を対象とし、モデルの定式化を行わずに、学習させたニューラルネットワークにより数値演算サブルーチンを代替して非線形動的応答解析を行う手法を検討する。

2. ニューラルネットワークの構築

(1)ニューロンモデル

ニューロンモデルとは生物の神経細胞における情報処理の仕組みを工学的にモデル化したものである。以下では単一のニューロンモデルの信号処理組織のことをノードと呼ぶ。このノードの特徴は図-1に示すような他入力1出力の構造にある。任意のユニットに対して図-1のように隣接する n 個のノードから $x_1, x_2, \dots, x_n$ の信号が出力される。 w は隣接するユニット間の結合の強さを表すもので結合荷重と呼ばれる。図中の黒く塗られたノードはバイアスと呼ばれるもので、ノードの出力を抑制したり促進したりするパラメータ（閾値）を与える。計算上バイアスは恒等的に1を出力するノードとして考慮するため、閾値は他の結合荷重と同様に扱われる。信号入力の流れは、隣接する n 個のノードからの出力信号が結合荷重により増幅または減衰された後、入力信号となる。入力された n 個の入力信号の総和が内部ポテンシャル x となり、活性化関数 f を通して出力信号 Y となる。本研究では、活性化関数としてRelu関数、最終層にのみ恒等関数を用いた。Relu関数は、入力値が0より小さいときは0を、そうでないときは入力値をそのまま出力する。本研究で用いた活性化関数を図-2に示す。

(2)階層型ニューラルネットワーク

多層ニューラルネットワークは、入力層、中間層、出力層からなる。一般的に、入力層、出力層は1層であり、中間層は複数層ある。このように層が重なった構造をしているものを階層型ニューラルネットワークと呼ぶ。本研究では、図-3のように中間層が n 層の階層型ニューラルネットワークのことを、 $n+2$ 層ニューラルネットワークと呼ぶこととする。また、各層に含まれる要素のことをノードと呼び、1層あたりに含まれるノードの個数をノード数と呼ぶ。本研究では、同一のネットワークにおいて中間層のノード数は同数とした。また、入力層のノードのことを入力要因、出力層のノードのことを出力要因と呼ぶ。




図-1 ニューロンモデル




図-2 活性化関数

(3) 入出力要因の選定

入出力要因はディープラーニングの結果に大きな影響を与える要素である。入力要因には対象とする数学モデルの非線形履歴挙動を特徴づけるパラメータを適切に選定する必要がある。本研究では既往の研究を参考にし、以下の入力要因を選択した。非線形の履歴は載荷方向が変化する際の変位や荷重の大小によりそれ以降の挙動が支配されることが知られている。したがって、まず最大経験変位、最大経験荷重、最小経験変位、最小経験荷重の4パラメータを選択した。また、非線形の履歴は最新折り返し点の影響を受ける場合もあるため、最新折り返し点変位および最新折り返し点荷重を加えた。剛性変化に関わる情報としては、1ステップ前の変位増分と、1ステップ前の荷重増分を加えた。履歴の連続性を考慮するために1ステップ前の変位、1ステップ前の荷重を加え、これらに現時点の変位を加えた11個を入力要因とした。出力層は動的応答解析へ適用を考慮し、現時点の接線剛性とした。




図-3 階層型ニューラルネットワーク




図-4 1質点系モデル

・入力要因

- $X_{\max}$: 最大経験変位
- $P_{\max}$: 最大経験荷重
- $X_{\min}$: 最小経験変位
- $P_{\min}$: 最小経験荷重
- X_0 : 最新折り返し点変位
- P_0 : 最新折り返し点荷重
- X_{n-1} : 1ステップ前の変位
- P_{n-1} : 1ステップ前の荷重
- $X_{n-1}-X_{n-2}$: 変位増分
- $P_{n-1}-P_{n-2}$: 荷重増分
- X_n : 現時点変位

・出力要因

- K_n : 接線剛性




図-5 漸増漸減正弦波

3. ニューラルネットワークの学習

本研究では誤差逆伝搬法を学習アルゴリズムとして用い、出力層の値と教師データの値の誤差を最小化するように出力層から入力層へ向かって勾配降下法を用いて結合荷重を修正した。ネットワーク構造は入力層のノード数が11、出力層のノード数が1、中間層のノード数はそれぞれ100とした。中間層の層数は試行錯誤的に求めた結果、6層が最適となった。

履歴復元力特性がそれぞれRamberg-Osgoodモデル、バイリニアモデル、武田モデルに従う図-4のような1質点系モデルに対し、図-5に示すような漸増漸減正弦波を強制変位として作用させた場合の応答履歴から教師データを作成し、これを用いてニューラルネットワークの学習を行った。学習回数は100万回とした。漸増漸減正弦波は、最大振幅の20%、40%、60%、80%をそれぞれ振幅

とする周期0.25秒の正弦波を1波長ずつ連続させることにより作成した。それぞれのモデルにおいて、学習済みのニューラルネットワークからの出力と正解である接線剛性の比較を図-6～図-8、ニューラルネットワークからの出力をもとに作成した荷重－変位関係と正解である荷重－変位関係の比較を図-9～図-11に示す。全てのモデルにおいて、ニューラルネットワークからの出力が教師データの接線剛性の値と一致していることが確認できる。また、Ramberg-Osgoodモデル、バイリニアモデルは非線形履歴曲線を高精度で模擬しており、武田モデルについても、非線形履歴曲線の特徴をとらえたモデル化ができていることが確認できる。

4. 非線形動的解析への適用

数学モデルに従う1質点系モデルを対象とし、学習済み




図-6 接線剛性時刻歴比較(R-Oモデル)




図-9 非線形履歴曲線の比較(R-Oモデル)




図-7 接線剛性時刻歴比較(バイリニアモデル)




図-10 非線形履歴曲線の比較(バイリニアモデル)




図-8 接線剛性時刻歴比較(武田モデル)




図-11 非線形履歴曲線の比較(武田モデル)

のニューラルネットワークを数値演算サブルーチンとして用い、実地震波に対する構造物の応答推定への応用についての検討を行った。学習済みのニューラルネットワークでは、入力層に与えられた変位等の信号に対して教師信号に基づき決定された結合荷重を用いた処理が一方方向に進行し、最終的に出力層から現時点における接線剛性が出力される。従って、動的解析を行う際には現時点において既知の情報である入力要因から現時点接線剛性を求める数値演算サブルーチンとして本ネットワークを用いる。計算には線形加速度法を用いた。履歴復元力特性がそれぞれRamberg-Osgoodモデル、バイリニアモデル、武田モデルに従う1質点系モデルに、図-12に示す振幅調整を行ったⅡ-Ⅱ-1設計地震動が40秒間作用した時の応答を検討対象とした。動的解析を行った結果と解析ソフト

による変位応答時刻歴比較を図-13～図-15に示す。それぞれのモデルにおいて、初めの約10秒間は比較的精度の高い推定ができていたが、それ以降、かなり大きな誤差が確認できる。

5. 推定精度の向上

図-16の波形は、図-5の漸増漸減正弦波に周期と振幅の小さい波を足し合わせ作成したものである。それぞれのモデルに従う1質点系モデルに、この波を強制変位として作用させ教師データを作成し、ニューラルネットワークに学習させることで学習精度の向上を図った。入力層、出力層、中間層、学習回数は変化させず、学習に用いる波形のみを変化さ、教師データに実地震動により近




図-12 振幅調整を行ったII-II-1 設計地震動




図-13 変位応答時刻歴比較(R-Oモデル)




図-14 変位応答時刻歴比較(バイリニアモデル)




図-15 変位応答時刻歴比較(武田モデル)




図-16 漸増漸減正弦波に小さい波を足した波形




図-17 変位応答時刻歴比較(R-Oモデル)




図-18 変位応答時刻歴比較(バイリニアモデル)




図-19 変位応答時刻歴比較(武田モデル)

いものを用いることにより推定精度の向上を図った。振幅調整を行ったII-II-1 設計地震動が40秒間作用した時の変位応答時刻歴比較を図-17～図-19に示す。全てのモデルにおいて全時間領域にわたって推定精度が向上していることが確認できる。

6. まとめ

本研究では、Ramberg-Osgoodモデル、バイリニアモデル、武田モデルを対象に、ニューラルネットワークの関数近似能力を非線形履歴曲線の認識に対して適用するこ

との有効性、及び教師データに基づき学習を行ったニューラルネットワークを動的応答解析時の数値演算サブルーチンとして利用することの妥当性について検討を行った。その結果、以下のようなことが明らかとなった。

(1)適切な入力要因を選定し、単純な規則波を学習させた階層型ニューラルネットワークはそれぞれの数学モデルの非線形履歴曲線を高精度で再現可能であり、その関数近似能力が非線形履歴曲線の認識に対して有効であることが確認された。

(2)実地震波を用いて動的解析を行い、正解と比較することによって、規則波を作用させて作成した教師データに基づき学習を行った階層型ニューラルネットワークでは動的応答解析に適用した場合、時間の経過に伴い誤差の累積で推定値が正解と乖離していくことが確認された。

(3)教師データに実地震動により近いものを用いることにより、実地震波に対する複雑な非線形履歴挙動の模擬精度が向上することを確認した。これによりニューラルネットワークが数学モデルと同等のモデル化能力を有することが示した。

今回検討を行ったものは、それぞれ3つの数学モデルに従う1質点系モデルのみであり、より汎用性の高いニューラルネットワークを構築するために、さらに多くの数学モデルに対しての検討が必要と考えられる。

参考文献

1) 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，

Vol.38A,pp85-94,1992.3.

- 2) 吉川和秀：ニューラルネットワークによる復元力モデルを用いた地震応答解析，日本建築学会関東支部研究報告集，pp.9-12，1992.
- 3) 野田茂，星谷勝，小淵康義：構造化学習による非線形履歴挙動系の道程，構造工学論文集，Vol.40A,pp.781-794,1994.3
- 4) 村瀬治比古，小山修平，石田良平：パソコンによるカルマンニューロコンピューティング，森北出版株式会社，1994.
- 5) 松田泰治，栂山義規，入江達雄，高山智宏：ニューラルネットワークの動的非線形問題への適用に関する研究，構造工学論文集，Vol.42A,pp.635-644,1996.3.
- 6) 矢葺亘，栂山義規，松田泰治：ニューラルネットワークによる高減衰ゴム履歴曲線の認識，構造工学論文集，Vol.43A,pp.843-848,1997.3.
- 7) T. Mazda, H. Otsuka and W. Yabuki, "Recognition of Hysteretic Behaviors of High Damping Rubber Bearing using Neural Network", ASME PVP-Vol.402-1, Seismic Engineering 2000, Vol.1, pp. 245-250, 2000.
- 8) W. Yabuki, T. Mazda, and H. Otsuka, "Study of the nonlinear behavior of prestressed concrete girders by a neural network," Earthquake Resistant Engineering Structures, WIT Press, pp.681-690, 2001.
- 9) T. Mazda, H. Otsuka, W. Yabuki, and M. Tsuruta, "A study on generalized neural network system for recognizing nonlinear behavior of structures," Proceedings of the third international conference on engineering computational technology, No.85, Sep. 2002.
- 10) T. Mazda, H. Otsuka, W. Yabuki, and K. Iwamoto, "Construction of Generalized Neural Network System for Recognizing Several Non-Linear Behaviors," ASME PVP-Vol.466, Seismic Engineering 2003, pp.143-151, 2003.

EVALUATION ON DYNAMIC RESPONSE OF STRUCTURES USING NEURAL NETWORK

Taiji MAZDA, Takashi AKEDO, Tubasa HAZANA and Yukihide KAJITA,

In this research, we consider a method of performing a dynamic analysis with not modeling by using hysteresis loops based on conventional formulation but a learned neural network. Learning data was prepared from the response history in the case where the progressive gradually decreasing sinusoid acted as forced displacement in the one mass system model in which the hysteresis loops are Ramberg - Osgood model, bilinear model, and Takeda model, respectively. The neural network learned using this learning data. It was confirmed that the neural network has the high versatility that it can recognize the nonlinear hysteresis loops. Moreover, the response estimation result by the neural network when the Waveforms with waves having short cycles and small amplitudes added to progressively gradually decreasing sinusoidal waves is learned was measured. When using that network for earthquake response analysis, the time history displacement almost matched. As a result of learning based on the displacement load relation with respect to the three hysteresis loops, the possibility of application as a numerical operation subroutine in nonlinear analysis of neural network after learning was shown.