

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

A STUDY ON APPLICATION OF NEURAL NETWORK TO NON-LINEAR DYNAMIC ANALYSIS

松田 泰治*, 桃山 義規**, 入江 達雄***, 高山 智宏**

Taiji MAZDA, Yoshinori KABAYAMA, Tatsuo IRIE, and Tomohiro TAKAYAMA

*工博 九州大学助教授 工学部建設都市工学科 (〒812 福岡市東区箱崎6-10-1)

** 九州大学大学院 工学研究科土木工学専攻 (〒812 福岡市東区箱崎6-10-1)

***工修 (株)建設技術研究所 (〒810 福岡市中央区渡辺通2-1-10、十八福岡ビル)
九州大学大学院 工学研究科土木工学専攻博士課程

Formulation of nonlinear-model for reinforced concretes, grounds, isolation device, etc. is usually based on selection of mathematical models and establishment of parameters. However, with the use of Neural Network, a technical imitation of the human brain's operation, consideration of nonlinear behaviour becomes unnecessary and formulation of highly precised model is believed to be possible. Therefore, in this paper, the applicability of Neural Network to dynamic problems is examined. Moreover, its applicability to dynamic response analysis of a single-degree-of-freedom system and to Statnamic loading test of pile are studied. Results show that both cases give values which approximately matches with that of the analysis using mathematical model. Thus, it is made clear that the application of Neural Network to dynamic response analysis is effective.

Key Words: Neural Network, nonlinear-model, dynamic response analysis

1. はじめに

近年、ニューラルネットワークの工学的問題への応用に関する研究が盛んに行われるようになってきた。

ニューラルネットワークとは、人間の脳神経系の仕組みを工学的に実現しようとしたもので、具体的には、人間の脳神経細胞を理想化したユニットとユニット間の重み付き結合からなるネットワークのことを指し、この高度並列性を持ったシステムが人間的な能力を発揮するものと考えられている。

ニューラルネットワークに関する基本的な概念は今から50数年ほど前に提案されたものである。しかし、当時は現在のような高速演算処理を行うことのできるコンピュータは存在せず、また、学習アルゴリズムの限界のため一時的にこの理論は停滞した。しかし、1986年 Rumelhart などによって提案された学習アルゴリズム、誤差逆伝播法 (Error Back Propagation Method) により再び脚光を浴びるようになってきた。

この新しいアルゴリズムが提案された後、様々な工学的問題に応用されるようになってきた。土木分野では、Ghaboussi らによるブレンコンクリートを対象にした先駆的な研究¹⁾をはじめとし、振動解析の分野では、山本が Ramberg-Osgood 型モデルの履歴曲線の認識問題を例にニューラルネットワークの表現能力が数学モデルと同程

度であることを明らかにし、学習済のニューラルネットワークを非線形時刻歴応答解析の数値演算サブルーチンとして利用している²⁾。同様に、吉川は積層ゴムの非線形履歴曲線の認識問題に対してニューラルネットワークを適用し、数値演算サブルーチンとしての利用の可能性を指摘している³⁾。野田らはニューラルネットワークの自己組織化機能を利用して非線形履歴挙動を表す数式やそのパラメータを自動的に同定する手法を提案している⁴⁾。村瀬らは誤差逆伝播法に基づくニューラルネットワークの学習に限界を感じ、拡張カルマンフィルタを用いることにより高速で精度の高い学習が可能であることを示している⁵⁾。同様に、佐藤らはニューラルネットワークを用いた線形および非線形の時刻歴応答解析の際に、ノイズを含む観測データでは、拡張カルマンフィルタを利用した学習が、誤差逆伝播法に比べて優れていることを指摘している。その際ニューラルネットワークを直接利用して非線形の時刻歴応答解析を行っている⁶⁾。しかしながら、ニューラルネットワークを動的非線形問題に応用した例はまだ少なく、今後ニューラルネットワークの有効性を立証するためにも、学習方法の一般化や適用事例の蓄積が必要と考えられる。

本研究では、山本の行った、学習済のニューラルネットワークを非線形時刻歴応答解析の際の数値演算サブ

ルーチンとして利用する点に着目した。既往の数学モデルでは個別の実験データに対するパラメータの設定は同定手法などを用いることにより可能であるが、複数の実験データに対してパラメータの設定を行うと、個別の実験データに対する近似精度は、一般に低下する。また、現象が複雑になればなるほど数学モデルの設定はより一層困難となる。このような問題に対してニューラルネットワークによる数値演算サブルーチンの構築は一助となると考えられる。ここでは教師データとして、通常、構造部材の静的あるいは動的な載荷試験等より得られる漸増漸減の荷重-変位データを選択した。このような教師データに基づき、ニューラルネットワークの学習を行い、地震荷重のようなランダムな荷重に対し、ニューラルネットワークが数値演算サブルーチンとして利用できることを明らかにした。また、具体的な応用例を挙げてニューラルネットワークを実際に動的非線形問題に適用した際の有効性を検討した。

2. ニューラルネットワーク

2.1 ニューロンモデル

ニューロンとは、生物の神経細胞のことである。この神経細胞の情報処理の仕組みを工学的に模倣したモデルがニューロンモデルである（図-1）。以下、この情報処理組織のことをユニットと呼ぶ。

このユニットの特徴は多入力1出力である点である。図-1のjユニットはn個のユニットから入力信号を受け取る。これらの入力値をそれぞれ、 $x_1, x_2, \dots, x_i, \dots, x_n$ とする。 W_{ij} はユニットij間の結合の強さを示すもので、結合荷重または荷重、結合係数（生物の神経細胞ではシナプス結合の役割）と呼ばれている。Iはバイアス入力でユニットの出力を抑制したり促進したりするパラメータ（閾値）を与える入力である。計算上Iは、恒等的に1を出力するユニットと考えるので、閾値は、他の結合荷重と同じjユニットとバイアス入力を出力するユニットとの結合荷重 W_{ij} として扱う。

処理の流れは、jユニットへの入力信号 $x_1 \sim x_n$ は、結合係数によって強弱をつけられ入力され、入力された $x_1 \sim x_n$ は、内部ポテンシャルXとして合計された後、応答関数を介して出力値 Y_j となる。

ここで関数 $f(X)$ は、応答関数あるいは入出力関数と呼ばれ、ユニットへの入力を $[0,1]$ の値に正規化する役割を果たす単調増加関数であり、本研究においては式(1)のシグモイド関数を用いた。

$$f(X) = \frac{1}{1 + \exp(-X/T_n)} \quad (1)$$

ここで T_n は温度定数と呼ばれる正の数でニューロンの発火しやすさを表す定数である。 $f(X)$ は T_n が小さいほど、閾値関数（2値関数）に近づく（図-2）。




図-1 ニューロンモデル




図-2 温度定数によるシグモイド関数の形状

2.2 ニューラルネットワークの構造

本研究では、一般に階層型ニューラルネットワークと呼ばれる構造のニューラルネットワークを使用した（図-3）。階層型ニューラルネットワーク（以下、単にニューラルネットワーク）は、処理が入力層から出力層に向かうという方向性を持っているため、単純で比較的容易に応用が可能である。

ニューラルネットワークは、入力信号を受け取ると入力層、中間層、出力層と信号が伝わり、最終的に出力信号を出力する。この出力信号と教師信号との間に誤差が生じたとき、この誤差を減らすために各層間の結合荷重およびバイアス入力の結合荷重を修正する。この修正過程がニューラルネットワークによる学習に相当する。学習アルゴリズムで誤差を最小化しよう出力層から入力層へ向かって最急降下法により修正を進める方法が、誤差逆伝播法である。次節においてこの誤差逆伝播法について述べる。




図-3 階層型ニューラルネットワーク

2.3 誤差逆伝播法

本研究では、Rumelhartらにより開発された誤差逆伝播法 (Error Back Propagation Method、以下BP法) を学習アルゴリズムとして用いた。BP法は、ニューラルネットワークの学習アルゴリズムの中で最も一般的なものである。

入力層と出力層の間に任意の個数の中間層を設けることにより、任意の入力パターンを任意の出力パターンに変換することができる。これは標準デルタルールを一般化したルールとみなせ、一般化デルタルールとも呼ばれている。出力層の各ニューロンが入力パターンに対して有効な値を出力するには、結合荷重を正しく調整することが必要である。結合荷重の調整には上述したBP法を用いる。出力層 r における k 番目のニューロンからの出力を Y_{rk} とし、入力パターンに対して期待される教師信号を r_k とすると、式(2)に示すような誤差 R を最小にするように結合荷重の調整を行う。

$$R = \sum_{n=1}^N \sum_{k=1}^K (Y_{rk} - r_k)^2 \quad (2)$$

ここで、 N はデータ個数である。

BP法による学習は、出力層から入力層へと進んでいくものであり、まず最初に出力層における学習信号 δ を求める。学習信号とは、BP法で学習する際に、結合荷重の調整を決定する定数である。

ここでは学習信号 δ について述べる。入力パターンにおける出力層からの二乗誤差として、次式を定義する。

$$E_p = \frac{1}{2} \sum_{k=1}^K (r_k - Y_{rk})^2 \quad (3)$$

ここでパターン全体の誤差は $E = \sum E_p$ で表される。標準デルタルールは、結合荷重 W をさまざまに変化させて全体の誤差 E の最小値を求める最急降下法である。そして標準デルタルールの一般式を式(4)に示す。

$$\frac{\partial E_p}{\partial W} = \frac{\partial E_p}{\partial X} \frac{\partial X}{\partial W} \quad (4)$$

ここで式(4)の右辺のが、学習信号 δ と仮定する。

$$\delta = -\frac{\partial E_p}{\partial X}$$

そしてこの学習信号を計算するために、合成関数の微分公式を用いて、この微分を、誤差の出力に関する微分と出力の入力総和に関する微分の積に分解する。

$$\delta = -\frac{\partial E_p}{\partial X} = -\frac{\partial E_p}{\partial Y} \frac{\partial Y}{\partial X} \quad (5)$$

まず出力層における学習信号 δ_{rk} について展開する。 r 層 k 番目ユニットへの入力総和 X_{rk} は

$$X_{rk} = \sum_{j=1}^u W_{qjk} \cdot Y_{qj} \quad (6)$$

となる。式(5)の2番目の微分はシグモイド関数から

$$\frac{\partial Y_{rk}}{\partial X_{rk}} = f'(X_{rk}) = Y_{rk} \cdot (1 - Y_{rk}) \quad (7)$$

となり、式(5)の1番目の微分は、

$$\begin{aligned} \frac{\partial E_p}{\partial Y_{rk}} &= \frac{1}{2} \frac{\partial}{\partial Y_{rk}} (r_k - Y_{rk})^2 \\ &= -(r_k - Y_{rk}) \end{aligned} \quad (8)$$

となる。以上のことから、 r 層 k 番目ユニットにおける学習信号 δ_{rk} は、式(7)と(8)を式(5)に代入することにより、次式で表される。

$$\begin{aligned} \delta_{rk} &= -\frac{\partial E_p}{\partial X_{rk}} = \{r_k - Y_{rk}\} \cdot f'(X_{rk}) \\ &= Y_{rk} \cdot (1 - Y_{rk}) \cdot \{r_k - Y_{rk}\} / T_n \end{aligned} \quad (9)$$

ここで、 δ_{rk} は r 層 k 番目ユニットにおける学習信号であり、 Y_{rk} は r 層 k 番目ユニットからの出力値である。

次に中間層における学習信号について述べる。中間層の学習信号は、前層の学習信号を用いて求める。 q 層 j 番目ユニットの入力総和 X_{qj} は式(6)を

$$X_{qj} = \sum_{i=1}^n W_{pij} \cdot Y_{pi} \quad (10)$$

と変更する。出力層と同様に式(5)の2番目の微分は、シグモイド関数の式と式(10)から

$$\frac{\partial Y_{qj}}{\partial X_{qj}} = f'(X_{qj}) = Y_{qj} \cdot (1 - Y_{qj}) \quad (11)$$

となり、式(5)の1番目の微分は、

$$\begin{aligned}\frac{\partial E_p}{\partial Y_{qj}} &= \sum_{k=1}^n \frac{\partial E_p}{\partial W_{rk}} \frac{\partial}{\partial Y_{qj}} \sum_{i=1}^u W_{qik} \cdot Y_{qi} \\ &= \sum_{k=1}^n \frac{\partial E_p}{\partial X_{rk}} \cdot W_{qik}\end{aligned}\quad (12)$$

となる。以上のことからq層j番目ユニットにおける学習信号 δ_{rk} は式(11)と式(12)を式(5)に代入することにより、次式で表される。

$$\begin{aligned}\delta &= -\frac{\partial E_p}{\partial X} = -\frac{\partial E_p}{\partial Y} \frac{\partial Y}{\partial X} \\ &= \sum_{k=1}^n \delta_{rk} \cdot W_{qik} \cdot f'(X) \\ &= Y \cdot (1 - Y_{qj}) \\ &\quad \cdot \sum_{k=1}^n \delta_{rk} \cdot W_{qik} / T_n\end{aligned}\quad (13)$$

ここで、 δ_{qj} はq層j番目ユニットにおける学習信号であり、 Y_{qj} はq層j番目ユニットからの出力値、 W_{qik} はq層j番目ユニットと次層k番目ユニット間の結合荷重である。

本研究では調整量の決定に、前回の調整量の重みを任意に考慮できるモーメント法を用いた。また、結合荷重の調整量の重みを任意に考慮できる学習速度係数 η も導入した。 W_{qik} に対する調整量 $\Delta W_{qik}(K)$ およびK回目調整後の結合荷重は、次式で表される。

$$\begin{aligned}\Delta W_{qik}(K) &= \alpha \cdot \Delta W_{qik}(K-1) \\ &\quad + (1-\alpha) \cdot \delta_{rk} \cdot Y_{qj}\end{aligned}\quad (14)$$

$$W_{qik}(K) = W_{qik}(K-1) + \eta \cdot \Delta W_{qik}(K) \quad (15)$$

ここで、Kは繰り返し回数、 $\Delta W_{qik}(K)$ は W_{qik} に対する繰り返し回数K回目の調整量、 $W_{qik}(K)$ は繰り返し回数K回目の調整後の結合荷重 W_{qik} である。また、 α は平滑化係数で0.0~1.0の値をとる定数であり、 η は学習速度係数で一般的に0.01~1.0の値をとる定数である⁶⁾。バイアス入力に対する結合荷重および入力層とp層の間のそれぞれの結合荷重の調整も同様にして行うものとする。このようにして、出力層から入力層に向かって順次結合荷重の調整を行っていく。

た。教師データは漸増sin波変位に対する復元力とし、それを学習させたニューラルネットワークを用い、中間層と温度定数をパラメータとして応答評価を行った。

3. ニューラルネットワークの動的非線形問題への適用

3.1 ニューラルネットワークの構築

ここでは、ニューラルネットワークの非線形動的問題

への適用性を検討するため、検証が容易な数学的履歴モデルを用いた事例に対してネットワークの構築を行った。教師データは漸増sin波変位に対する復元力とし、それを学習させたニューラルネットワークを用い、中間層と温度定数をパラメータとして応答評価を行った。

(1) 履歴モデルの設定

構造物の荷重-変位関係のモデリングにはbi-linearモデルなどをはじめとし多くの履歴モデルが提案され活用されている。ここでは山本の研究²⁾でニューラルネットワークによる履歴認識が行われたRamberg-Osgood型モデル（以下R-Oモデル）を採用した。

このR-Oモデルは、Ramberg-Osgoodの骨格曲線を用い、Masingの法則に従って履歴曲線を表すもので図-4に示すような非線形挙動をとる。骨格曲線はR-Oモデルに従い以下に示す式に従う。

$$\frac{X}{X_y} = \frac{P}{P_y} + \beta \left(\frac{P}{P_y} \right)^\gamma$$

ここに

- X : 構造物の変位
- P : 構造物の変位xにおける復元力
- Xy : 構造物の降伏変位
- Py : 構造物の降伏荷重
- β, γ : 骨格曲線の形状パラメータ

なお、骨格曲線の形状パラメータは履歴曲線が適切な非線形性を表現するよう $\beta=0.35$ 、 $\gamma=5$ とした。履歴曲線は上記のようにMasingの法則を用い、以下に示す式に従う。

正の変位方向

$$\frac{X+X_{max}}{2X_y} = \frac{P+P_{max}}{2P_y} + \beta \left(\frac{P+P_{max}}{2P_y} \right)$$

負の変位方向

$$\frac{X-X_{max}}{2X_y} = \frac{P-P_{max}}{2P_y} + \beta \left(\frac{P-P_{max}}{2P_y} \right)$$

Xmax : 最大経験変位

Pmax : 最大経験変位に対応する荷重

骨格曲線

$$\left(\frac{X}{X_y} \right) = \frac{P}{P_y} + \beta \left(\frac{P}{P_y} \right)^\gamma$$




図-4 Ramberg-Osgood型モデル


(2) 入力層および出力層の設定

ニューラルネットワークを構築する際、出力層は求めたい物理量とするので容易に設定できるが、入力層への入力条件は、対象とするものに対して重要かつ不可欠なものを選択する必要がある。ここで、入力層への入力は、山本の研究²⁾と同様に最大経歴変位点座標値 (X_{max}, P_{max})、最新の変位折り返し点座標値 (X_0, P_0)、現時点での変位 (X_n) の5ユニットとした。出力層は数値演算サブルーチンとしての利用を考慮して次ステップの変位 X_{n+1} を求めるためのバネ定数 k (X_n における接線剛性) の1ユニットとした。つまり、通常は仮定した数学モデルに基づき定まるバネ定数をニューラルネットワークにより算出し、算出されたバネ定数を用いて線形加速度法により動的応答解析を行い次ステップの計算に活用する。なお、学習に用いる入力信号、および教師信号は正負の最大値を用いて $[0, 1]$ に正規化を行った。また、式(14)、式(15)のパラメータは $\alpha = 0.9$ 、 $\eta = 0.8$ とした。

(3) 中間層のユニット数および温度定数の決定⁷⁾

中間層のユニット数の決定は、最近ニューラルネットワークと遺伝的アルゴリズムを組み合わせることで自動的に中間層ユニット数を決定する方法などが提案されているが、本研究で用いるネットワークは大規模なものではなく3層構造を基本としているので、表-1のようにパラメータスタディを行い決定することとし、また、温度定数も同様にいくつかのパラメータスタディを行い決定することとした。

ここでは、図-5に示すように1質点系のバネのみで非線形、強制外力として周期が5Hzで最大加速度200galのsin波が作用したときの応答を解析対象とした。なお降伏変位は1cm、降伏荷重は1000kgf、初期剛性は1000kgf/cmとし、質点の質量は系の固有周期が5Hzになるように、また粘性減衰係数は減衰定数が1%となるように設定した。このような解析モデルの応答を解析するにあたり、ニューラルネットワークに学習させた履歴曲線が図-6である。その解析フローを図-7に、パラメータスタディのケースを表-1に示す。なお、この解析モデルを数学的モデルを用いて解いたものが図-8であり、これを正解とする。



降伏変位：1cm
降伏荷重：1000kgf
初期剛性：1000kgf/cm
固有周期：5Hz
減衰定数：1%

図-5 1質点系モデル

図-9～図-12は、ユニット数を変えてその影響を調べるために行った解析結果である。ケース1では中間ユニット数が2でも比較的良好な再現性が得られた。しかし、ケース2、ケース3では中間ユニット数がケース1より多いにも関わらずよりよい再現性は得られなかった。ケース4では、ケース1とほぼ同様の再現性が得られ、ケース5、ケース6は、ケース4とほぼ同様の再現精度となったので図は省略する。

図-13～15は、シグモイド関数の温度定数を変えたときその影響を調べるために行った解析結果である。シグモイド関数の性格上、同じ内部ポテンシャルでも温度定数が大きいとシグモイド関数の勾配は緩やかとなり、温度定数が小さいとシグモイド関数の勾配は急になる。したがって、温度定数が小さいと応答関数は0.1付近の値を取りやすくなり、逆に温度定数が大きいと0.1付近の値を取りにくくなる。したがって、温度定数大きいほうが幅広い内部ポテンシャルに対して対応可能となる。なお、ケース10からケース12は、ケース9と同様の再現精度となったので図は省略する。




図-6 学習履歴曲線




図-8 正解値




図-7 解析フロー

表-1 解析ケース

ケース	1	2	3	4	5	6	7	8	9	10	11	12
中間ユニット数	2	3	4	5	6	7	5	5	5	5	5	5
温度定数	1	1	1	1	1	1	0.25	0.5	1	1.5	2	2.5




図-9 中間ユニット 2




図-13 温度定数 0.25




図-10 中間ユニット 3




図-14 温度定数 0.5




図-11 中間ユニット 4




図-15 温度定数 1.0




図-12 中間ユニット 5

3.2 非線形時刻歴応答解析への適用⁹⁾

本適用事例では、実現象への適用を目的とし、前節で構築したニューラルネットワークを用いて、実験や解析などにより入手可能な漸増漸減sin波変位に対する復元力を教師データとし、ランダムな実地震波に対する応答の推定を行う。

(1) 解析方法

ここでは、載荷試験等により入手可能な学習データの

例として、漸増漸減のsin波変位（図-16）に対するRamberg-Osgood型モデルの復元力（図-17）より得られるバネ定数を教師データとして選択した。この教師データに基づきニューラルネットワークに対して十分な学習を行い、最終的に同定された結合荷重を用いてランダムな地震入力による動的応答解析を行った。なお、ここでは式(14)、式(15)のパラメータは $\alpha=0.9$ 、 $\eta=0.25$ とした。

(2) 解析結果

強制外力として最大加速度341.7galのEL Centro地震波が、1質点系に作用したときの応答を解析対象とした。1質点系モデルの重量は1000tonfとし、系の固有周期はEL

Centro地震波の卓越振動数を考慮して1.16Hzとした。この二つの条件より初期剛性は54.2062tonf/cmとなる。

降伏荷重は150tonf、また粘性減衰係数は減衰定数が1%となるように設定した。解析方法で述べた学習方法で2000回学習させたニューラルネットワークを用いてEL Centro地震波に対する相対加速度の時刻歴、相対速度の時刻歴、相対変位の時刻歴、復元力の時刻歴を再現したものが図-18～21である。再現された相対加速度の時刻歴、相対速度の時刻歴、相対変位の時刻歴、復元力の時刻歴、また相対加速度のフーリエスペクトル（図-22）は、全体としてはほぼ一致した。しかし、詳細に見ると、動的解析で一般に合いにくい加速度が良く一致しているにもかかわらず、変位の一致度が相対的に低い。検討対象としたRamberg-Osgood型のモデルは変位の増加に伴い剛性が低下する軟化型のモデルである。従って、加速度の算定の際に考慮する復元力の項では、変位が正解よりも大きな場合は剛性が低く評価され、逆に変位が正解よりも小さな場合は剛性が高く評価され、結果的に復元力の項の誤差が打ち消されて加速度が正解と良く一致したものと考えられる。

3.3 杭のStatnamic載荷試験結果の評価への適用¹⁰⁾

本適用事例では、Statnamic載荷試験より得られる動的応答結果に基づき静的応答の推定を試みる。




図-16 漸増漸減sin波変位




図-17 学習用履歴データ




図-18 応答加速度の時刻歴




図-19 応答速度の時刻歴




図-20 相対変位の時刻歴




図-21 復元力の時刻歴




図-22 フーリエスペクトルの比較

(1) 解析方法

鳥野らの研究¹¹⁾を参考に、直径1.0m、長さ19.1mの場所打ちコンクリート杭を対象に検討を行った。まず、杭を杭本体質量に杭の体積分の土の付加質量を考慮して1質点でモデル化した。ばね定数は静的載荷試験結果に基づき、荷重-変位関係をバイリニアでモデル化し、等価粘性減衰定数は第1剛性 k_1 に対して25%とした。解析モデルを図-23に示す。今回はこの解析モデルを用いて学習のための教師データを作成した。まず、Statnamic載荷試験時の動的荷重として、最大荷重4.9MNと5.88MN、載荷時間100msの正弦半波を仮定した。これらの荷重に対して上記解析モデルによる動的解析を行い、加速度、速度、変位を求めた。積分手法は線形加速度法を用い、時間刻みは2msとした。計算により得られた学習用の動的な荷重-変位関係を図-24に示す。推定に用いたニューラルネットワークは、前節同様に3層構造のもので、入力層は、計測等により取得可能と考えられる動的荷重、加速度、速度、変位の4ユニットとし、出力層は静的荷重の1

ユニットとした。出力層として静的荷重を選択した理由は、杭のStatnamic載荷試験では動的な荷重-変位関係より設計上必要な静的な支持力を評価する必要があるためである。中間層のユニット数は5ユニットとした。最終的に同定された結合荷重を用い、動的荷重レベルの異なる杭の静的な荷重-変位関係の推定を行った。今回の検討では学習回数を5000回とした。なお、学習に用いる入力信号、および、教師信号は正負の最大値を用いて[0,1]に正規化を行った。推定に用いた動的荷重は最大荷重5.39MN、載荷時間100msの正弦半波である。なお、ここでは平滑化係数 $\alpha=0.9$ 、学習速度係数 $\eta=0.8$ を用いた。

(2) 解析結果

図-25に結合荷重の同定を行った際の学習回数と誤差の関係を示す。今回の学習ではシステムの誤差が局所解に陥るようなBP法特有の現象は認められていない。図-26にニューラルネットワークにより推定した静的な荷重と、今回教師データ作成時に用いたバイリニアモデルから定まる静的な荷重との比較を示した。学習時の荷重レベルとは異なる入力に対して推定値と正解値は良い一致を示した。




図-23 解析モデル




図-24 学習用の動的な荷重-変位関係




図-25 学習回数と誤差の関係




図-26 静的な荷重の推定結果

4. まとめ

ニューラルネットワークを動的非線形問題に適用し、ニューラルネットワークの構築およびその数値演算サブルーチンとしての表現能力の評価を行った。その結果以下のようなことが明らかとなった。

(1) モーメント法と学習速度係数を考慮した誤差逆伝播法を用いて非線形履歴特性を表現可能なニューラルネットワークの構築を行った。その結果、中間ユニット数5以上のケースでは著しい表現精度の向上は認められず、計算時間は増大した。また温度定数についても同様に、1以上のケースでは精度の向上は認められなかった。

(2) 実験などにより入手可能な漸増漸減荷重時のデータを教師データとして学習させたニューラルネットワークを利用して、ランダムな実地震波に対する構造物の応答解析を行った。その結果、構造物の実地震波に対する応答に対してニューラルネットワークが数値演算サブルーチンとして利用可能であり、かつ数学的履歴モデルと同等の表現能力を有することが確認された。

(3) 杭のStatnamic載荷試験を対象に、計測等により入手可能な動的応答結果に基づく静的応答結果の推定に対してニューラルネットワークを適用性を検討した。その結果、動的な応答結果から静的な応答結果を推定可能であることが確認された。

今回検討を行ったものは評価が容易な1質点系モデルのみである、今後は多自由度の複合非線形の問題等への適用性を検討する必要があると考えられる。その際教師データの不足するものについては、3次元FEM等のパラメトリックスタディの解析結果等を教師データとして利用することが考えられる。

参考文献

- 1) Ghaboussi J., Garrett Jr. J.H., and Wu, X.: Knowledge-Based Modeling of Material Behavior with Neural Networks, J. Engrg. Mech. Div., ASCE, Vol. 177, No. 1, pp. 132-153, 1991.1
- 2) 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
- 3) 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
- 4) 野田茂、星谷勝、小淵康義：構造化学習による非線形履歴振動系の同定、構造工学論文集、Vol. 40A, pp. 781-794, 1994.3
- 5) 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、森木他出版株式会社、1994
- 6) 佐藤誠、佐藤忠信：自己学習アルゴリズムによる構造物の非線形地震応答シミュレーション、土木学会第49回年次学術講演会 I-771, 1994.9
- 7) Philip D. Wasserman: Theory and Practice Vannostrand Reinhold, Neural Computing, pp. 50-54, 1989
- 8) 柁山義規、松田泰治：ニューラルネットワークの履歴モデルへの適用に関する基礎的研究、土木学会西部支部研究発表会 I-42, 1995.3
- 9) 柁山義規、松田泰治：ニューラルネットワークの動的応答解析への適用に関する研究、土木学会第50回年次学術講演会 I-B819, 1995.9
- 10) 松田泰治、鳥野清、柁山義規、アランディアズマヤ：ニューラルネットワークを利用したStatnamic載荷試験結果の評価、第30回土質工学研究発表会 pp. 1419-1420, 1995.6
- 11) 鳥野清ほか：場所打ち杭の支持力推定に関する動的試験と解析法、土木学会論文報告集 No. 430/III-15, pp. 39-48, 1991年

(1995年9月18日受付)