

ニューラルネットワークによる高減衰積層ゴム履歴曲線の認識

Recognition of Hysteretic Behaviors of High Damping Rubber Bearing using Neural Network

矢眞 亘*、桝山 義規**、松田 泰治***

Wataru YABUKI, Yosinori KABAYAMA and Taiji MAZDA

* 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)

** 新日本製鐵(株) 技術開発本部 設備技術センター 土木建築技術部 土木技術室
(〒293 千葉県富津市新富20-1)

***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)

Generally, in formulating a spring-mass model for hysteretic behavior of materials and members with inelastic characteristic, a mathematical model based on load-deformation experimental results is considered. The model must approximate the inelastic hysteresis of the material. However, assumption of material's behavior using mathematical models is crucial, since it may cause serious errors if inappropriate model is applied for a particular situation. On the other hand, by applying Neural Network, a technical method similar to human brain's operation, tests for inelastic behavior of the material becomes unnecessary and highly precise model can be obtained. Therefore, in this paper, the applicability of Neural Network is examined by direct modeling of high damping rubber bearing's hysteretic behavior without any mathematical assumption. Moreover, dynamic loading test is carried out to determine the load-deformation relationship of the high damping rubber bearing.

Key Words : Neural Network, inelastic behavior, High Damping Rubber Bearing, direct modeling

1 はじめに

一般に、非線形性の強い材料や部材の挙動をばね等でモデル化する際には、実験などにより得られた荷重一変位関係から、非線形履歴現象を近似できるある数学モデルを選択する。これらのモデルは、非常に単純なものから複雑なものまで数多く提案されている。どのモデルにおいても荷重および変位の最大点、最小点、剛性、減衰などを考慮し復元力特性の履歴ルールを決定して解析を行っていく。しかしその場合、現象を何らかの数学モデルで置き換えるという仮定が存在するため、数学モデルの選択が適切でない場合には、解析において大きな誤差が生じるおそれがある。例えば高減衰積層ゴムのように十分にその特性が解明されていない比較的新しい材料から構成される部材では、ソフトニング、ハードニング、降伏といった現象に対し、既存の履歴モデルの適用が困難な場合もあり、より精度の高い新しい履歴モデルの開発を待つものも存在する。従って、こうした非線形現象の適かつ簡易なモデリング手法の開発は、数値解析における能率、計算精度の向上の一助となると考えられる。

一方、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、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。

本研究では、こうしたニューラルネットワークの優れたパターン認識能力に着目し、非線形履歴曲線を、ニューラルネットワークを用いた疑似関数を構築することにより、従来提案されているモデルで置き換えることなく直接モデリングし、その有効性と数値解析への適用性の評価を行った。その際、教師データ採取のため、高減衰積層ゴムを対象とした動的載荷実験を行った。

2 既往の研究

ニューラルネットワークを振動解析の分野に用いた既往の研究では、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、学習済み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¹⁾。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²⁾。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理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³⁾。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⁴⁾。さらにZAVALAらは、疑似動的実験の供試体の復元力の予測子にニューラルネットワークを用いることで、不平衡モーメントを除去し、計測に基づく予測手法と同等の精度を得ている⁵⁾。著者らもニューラルネットワークをRamberg-Osgood型履歴の認識問題、実地震波に対する応答解析、さらに杭のStanamic載荷試験へ適用する事で、ニューラルネットワークを種々の動的非線形問題に対して利用することの可能性を示した⁶⁾。さらに、鉄筋コンクリートの挙動を精度よく近似できる武田モデル⁷⁾に従う複雑な履歴挙動に対してもニューラルネットワークが有効であることを示した⁸⁾。しかしながら、ニューラルネットワークを、履歴挙動の直接モデリングや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。

3 高減衰積層ゴムの動的載荷実験

ここでは、ニューラルネットワークの教師データを取得するための正弦波載荷実験と、正弦波載荷実験から得られた教師データにより学習を行ったニューラルネットワークの未学習データに対する適用性の検討を行うためのランダム波載荷実験を行った。

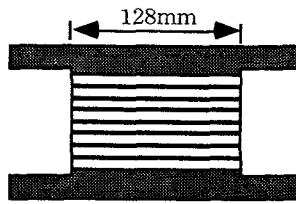
3.1 供試体概要

高減衰ゴムは、天然ゴムをベースにカーボン等の充填剤オイルや樹脂等の可塑剤あるいは軟化剤を特殊配合して、材料の減衰性能を高めたものである。また合成ゴムを新たにブレンドする場合もある。高減衰ゴムの場合、人為的に天然ゴムの配合に手を加えるため、カーボン等の効果により減衰性能は向上しても、他の機械的性質が天然ゴムに比べ低下する場合もあり得る。免震用に開発された高減衰ゴムはこのようなことがないよう、補強剤等が適切に配合しており、減衰性能以外は天然ゴムと同等の性能を有している。高減衰ゴムの減衰性能は基本的には天然ゴムの減衰性能発生機構の延長線上にあると考えられる。このため高減衰ゴムは、天然ゴム特有の超弾性挙動と減衰性能の向上による粘性挙動を合わせた複雑な履歴挙動を呈する。

高減衰積層ゴムの構造は、フランジ、内部ゴム、被覆ゴム、鋼板からなり、ゴムシートと鋼板を互層にして加硫接着した積層構造である。断面形状は、建築用は円形、橋梁用は矩形のものが一般に使用されており、外周部には内部の保護を目的とした被覆ゴムがある。

本実験で用いた矩形高減衰積層ゴム(HDR401)を、

図-3.1に示す。供試体の形状は、断面94×128mm、ゴム層厚は3.5mmで8層、鋼板厚1.0mmである。供試体で使用された高減衰ゴム材料の物理特性を表-3.1に示す。



ゴム 3.5mm×8層=28.0mm
内部鋼板 1.0mm×7枚=7.0mm

図-3.1 矩形高減衰積層ゴム（8層、HDR401）

表-3.1 ゴム材料物性値

硬度 IRHD	綫弹性係数 $E_0(\text{kgf}/\text{cm}^2)$	せん断弹性率 $G(\text{kgf}/\text{cm}^2)$	硬度補正係数 κ	体積弹性率 $E_\infty(\text{kgf}/\text{cm}^2)$
60	54.5	10	0.57	1.17

3.2 実験方法

図-3.2に供試体の取付状況を示す。本実験では、同一形状、同一物性の供試体A,Bを図のように配置することで、水平変位を加えた際のフランジの回転の発生を防ぐ構造を用いている。

載荷実験では、不動点より荷重計を介して供試体Aの下フランジ、供試体Bの上フランジを固定した状態で、振動台上に固定された供試体Aの上フランジ、供試体Bの下フランジに強制変位を与えることにより載荷を行った。このように間接的に強制変位を与える方法を採用したのは取付スペースの都合によるものである。載荷方向は正弦波載荷実験、ランダム波載荷実験とともに、長辺の128mmに固定して行った。

計測はひずみタイプの荷重計 (LUK-5TBS、定格負荷5tf、許容モーメント1.5tfcm)により水平方向の荷重を、インダクタンス式の変位計 (DLT-100BS、±100mm)により支承の水平変位(振動台水平変位)を測定した。振動台は電気油圧式振動実験機(HYDRACT、水平変位±30mm、加速度1G、最大負荷10ton)を使用した。計測時の時間刻みは、正弦波載荷試験時では0.017秒、ランダム波載荷試験時では0.02秒である。

なお、得られた復元力はA,B両供試体の合計であり、これを平均して単体の復元力として用いた。

(1) 正弦波載荷実験

学習用の教師データ採取の目的で上述の矩形高減衰積層ゴムに対して、図-3.3に示す漸増漸減正弦波変位を強制入力した。最大振幅は振動台の性能およびゴムに発生するせん断ひずみを考慮して28mm(ゴム総厚に対して±100%程度)を目安とした。この試験で得られた履歴曲線を図-3.4に示す。

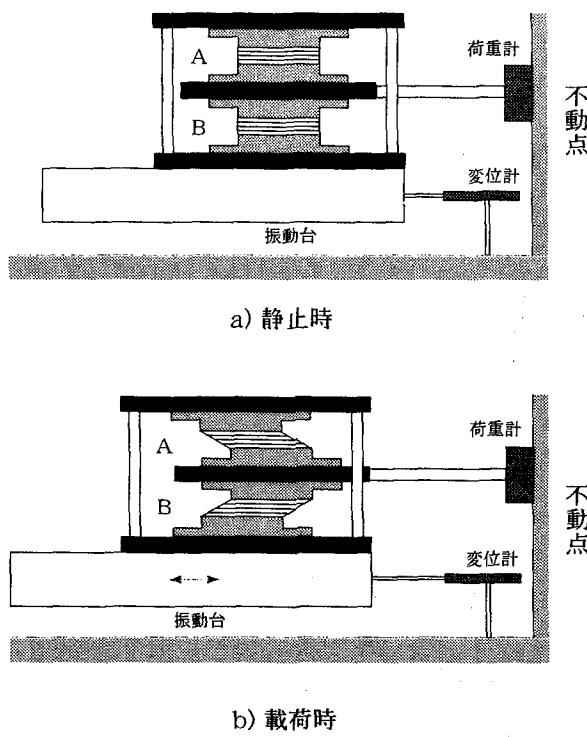


図-3.2 供試体の取付状況

(2) ランダム波載荷試験

学習済みニューラルネットワークの未学習データに対する適用性の検討を行う目的で、ランダム波載荷試験を行った。上述の正弦波載荷試験で得られた履歴曲線(図-3.4)をRamberg-Osgood型モデルで近似し、矩形高減衰積層ゴムを図-3.5に示すモデルと仮定して上で、入力加速度をEl Centro NSの主要動(5秒間)としたときの非線形時刻歴解析を行い、時刻歴応答変位を計算する。そして、計算より得られた時刻歴応答変位(図-3.6)を試験体に強制変位入力し、それより得られる履歴曲線を(図-3.7)矩形高減衰積層ゴムの地震時の履歴曲線とこれをニューラルネットワークの表現能力を評価する際の正解とする。

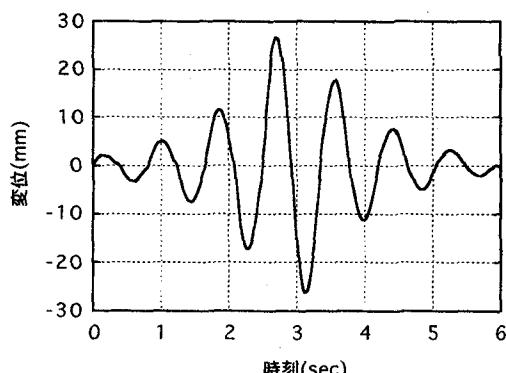


図-3.3 漸増漸減正弦波変位

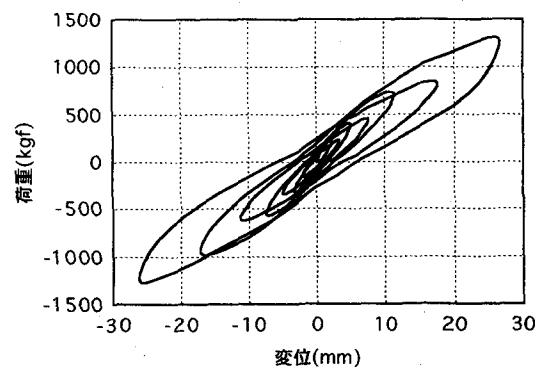


図-3.4 漸増漸減正弦波変位入力に対し
実験より得られた履歴曲線



断面積 : 120.32cm^2
重 量 : 7219.2kgf
降伏荷重 : 550kgf
初期剛性 : 650kgf/cm
減衰定数 : 0%

図-3.5 1質点系モデル

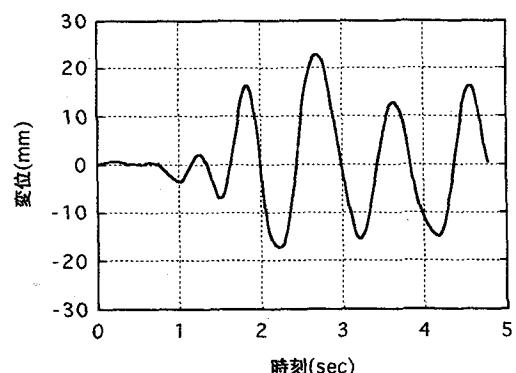


図-3.6 時刻歴応答変位

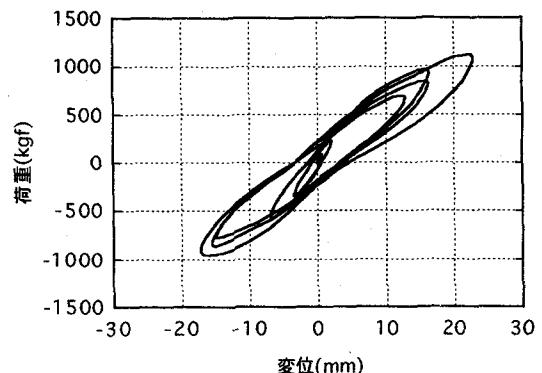


図-3.7 時刻歴応答変位入力に対し
実験より得られた履歴曲線

4 ニューラルネットワークの構築

4.1 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（図-4.1）と呼ばれる構造のニューラルネットワークを使用した。階層型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、処理が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する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。

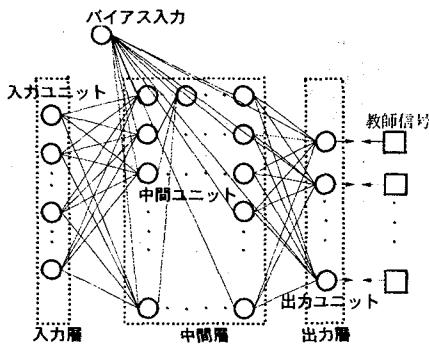


図-4.1 階層型ニューラルネットワーク

4.2 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（図-4.2）である。以下、この情報処理組織のことをユニットと呼ぶ。

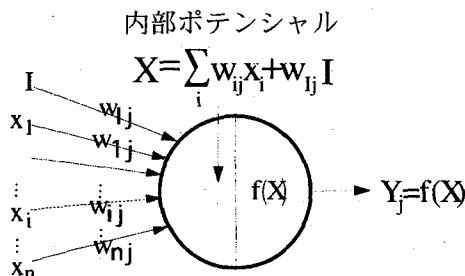


図-4.2 ニューロンモデル

このユニットの特徴は多入力1出力である点である。図4.2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、結合荷重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-4.3）。

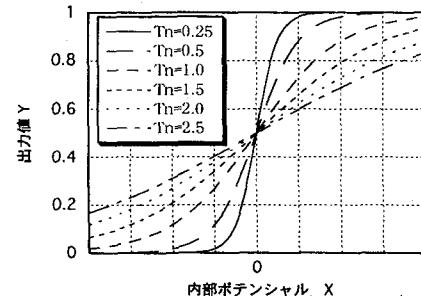


図-4.3 温度定数によるシグモイド関数の形状

4.3 誤差逆伝播法 (Error Back Propagation Method)

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。

本研究では、平滑化係数 α により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、調整量の決定を行った。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。

4.4 ニューラルネットワークの入出力項の選定および構造

ニューラルネットワークの入力層には対象とする履歴挙動を特徴づけるとされる各種のパラメータが、数、項目ともに適切に選定される必要がある。

本研究では、ニューラルネットワークによる Ramberg-Osgood型履歴則のモデリングに関する研究⁶⁾を参考に、高減衰積層ゴムの実験的履歴曲線のモデリングに際し、以下のように入力層を選定した。

得られた高減衰積層ゴムの履歴曲線は、載荷サイクルにおいて、最大経験点を更新しながら、最外郭ループを形成する。さらに最大変位が更新されないで、最外郭

ループ内で変位を折り返す場合、最新の折り返し点から最大経験点を指向する。よって入力層には最大経験点、最新の折り返し点の情報が入力される必要があると考えられる。また高減衰積層ゴムそのものが持つ減衰成分のため、最大変位点=最大荷重点が成り立たない。そのため、最大経験点、最新の折り返し点はそれぞれ変位項、荷重項を個々に入力した。加えて動的挙動の速度の成分を加味する上で、1ステップ前の変位増分および荷重増分を入力した。以上の6ユニットに、現時点での変位を加えた7ユニットを入力層とした。

出力層は、入力された現在の変位等の情報より、荷重を推定することから、荷重の1ユニットとした。

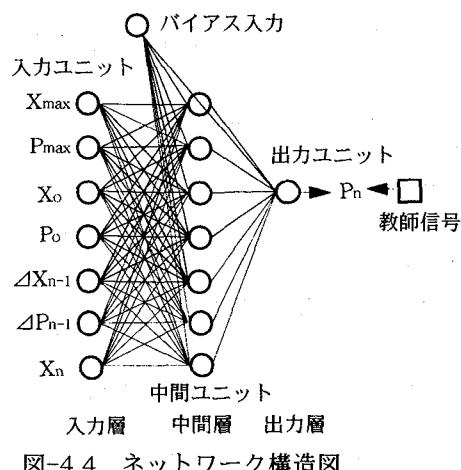
ネットワークの構造は、中間層1層の3層階層型ネットワークとした。中間層のユニット数、温度定数は表-4.1に示す総計25ケースのパラメータスタディを行い、最良の7ユニット、温度定数1.5を用いた。本研究で採用したネットワーク構造を図-4.4に示す。

・入力層7ユニット：

- 最大経験変位(X_{max})
- 最大経験荷重(P_{max})
- 最新の変位折り返し点(X_o)
- 最新の荷重折り返し点(P_o)
- Δt 秒間の変位増分($\Delta X_{n-1} = X_{n-1} - X_{n-2}$)
- Δt 秒間の荷重増分($\Delta P_{n-1} = P_{n-1} - P_{n-2}$)
- 現時点での変位(X_n)

・出力層1ユニット：

- 現時点での荷重(P_n)



なお、学習回数、平滑化係数 α 、学習速度係数 η に関してはそれぞれ5000回、0.9、0.5を採用したが、学習回数については500回、1000回、2000回、5000回、10000回、平滑化係数 α は0.3、0.6、0.9、学習速度係数 η は0.25、0.50、0.75の総計45通りのパラメータスタディを行い誤差収束性が良好であったものを用いたことをここに記す。なお学習データは、図-3.4に示す履歴曲線より350組すべてを選定した。

表-4.1 解析ケース

	ケース1	ケース2	ケース3	ケース4	ケース5
中間ユニット数	5	6	7	8	9
温度定数	0.5	0.5	0.5	0.5	0.5
	ケース6	ケース7	ケース8	ケース9	ケース10
中間ユニット数	5	6	7	8	9
温度定数	1.0	1.0	1.0	1.0	1.0
	ケース11	ケース12	ケース13	ケース14	ケース15
中間ユニット数	5	6	7	8	9
温度定数	1.5	1.5	1.5	1.5	1.5
	ケース16	ケース17	ケース18	ケース19	ケース20
中間ユニット数	5	6	7	8	9
温度定数	2.0	2.0	2.0	2.0	2.0
	ケース21	ケース22	ケース23	ケース24	ケース25
中間ユニット数	5	6	7	8	9
温度定数	2.5	2.5	2.5	2.5	2.5

5 解析結果

総計25ケースの誤差の収束性を図-5.1に示す。

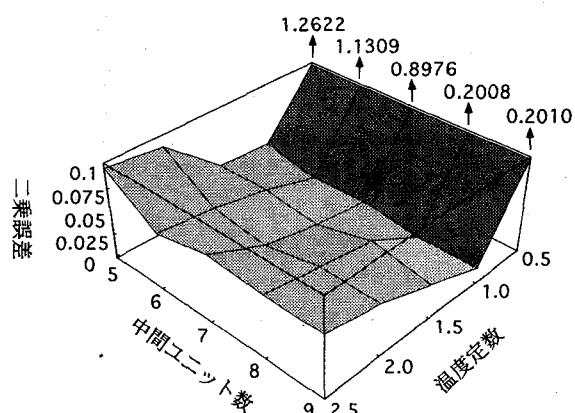


図-5.1 中間ユニット数と温度定数の影響による学習結果

図-5.1より本適用対象においては、中間ユニット数7、温度定数1.5が最良と判断され、そのネットワークの出力と正解である学習データの時刻歴荷重の比較を図-5.2に、履歴曲線の比較を図-5.3に示す。

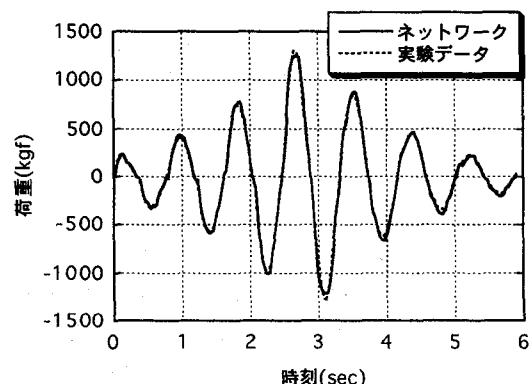


図-5.2 ニューラルネットワークの認識結果
(時刻歴荷重比較)

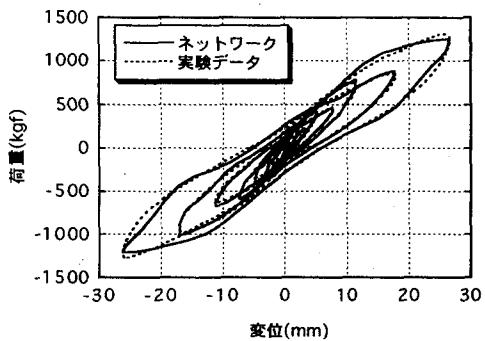


図-5.3 ニューラルネットワークの認識結果
(履歴曲線比較)

次に、未学習データであるEl Centro NS波形に対する応答変位を与えた実験データとネットワークの出力の時刻歴復元力比較を図-5.4に、履歴曲線の比較を図-5.5に示す。

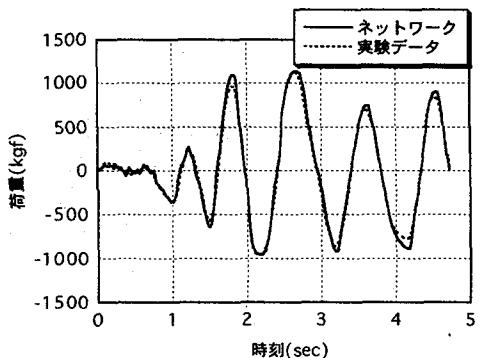


図-5.4 ニューラルネットワークの未学習データの
再現性（時刻歴荷重比較）

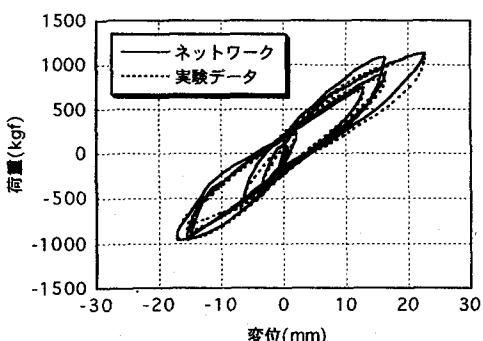


図-5.5 ニューラルネットワークの未学習データの
再現性（履歴曲線比較）

正解の実験データと本適用事例で最良なニューラルネットワークを用いた解析結果では、履歴曲線の荷重において、載荷方向が変化する際に若干の誤差が生じているが、両者は定性的かつ定量的によく一致している。

以上のことより、実験的履歴曲線をニューラルネットワークを用いた疑似関数を構築することにより直接モデリングする方法は、若干の誤差は含まれるが、その現象

を定性的に表現可能であり、実際にモデル化が困難な現象の場合の解析においては有効な一手法といえる。

6 まとめ

ニューラルネットワークを、実験的履歴挙動のモデリングに適用し、ネットワークの構築および表現能力評価を行い、その結果以下のようことが明らかになった。

a) 漸増漸減正弦波入力による通常の載荷実験結果を教師データとし、その荷重-変位関係をニューラルネットワークを用いた疑似関数を構築することで直接モデリングした結果、教師データとは異なるランダム波（未学習データ）に対する応答を高精度で推定可能であることが確認された。

b) ニューラルネットワークの誤差収束性の判断として中間層のユニット数と温度定数の関係について検討を行った。その結果温度定数の変化は、中間ユニット数の変化よりも誤差収束性に大きく影響を及ぼすことが確認された。

今後は、本供試体による振動台実験を実施して、ニューラルネットワークの数値演算サブルーチンとしての適用性を検証する。本研究を行うに当たって貴重なご助言をいただいた(財)電力中央研究所 山本広祐博士に厚く御礼申し上げます。

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，構造工学論文集 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 pp9-12,1992
- 3) 野田茂,星谷勝,小淵康義：構造化学習による非線形履歴振動系の同定,構造工学論文集 Vol.40A,pp781-794,1994.3
- 4) 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
- 5) C.ZAVALA,K.Ohi,K.Takanashi : Neuro-Hybrid Substructuring On-Line Test on Moment Resistant Frames, 11th World Conference Earthquake Engineering,Paper No.1387
- 6) 松田泰治,樋山義規,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,pp635-644,1996.3
- 7) T.Takeda,M.A.Sozen,N.N.Nielsen : Reinforced Concrete Response to Simulated Earthquakes, 第3回日本地震工学シンポジウム講演集,pp357-364,1970.12
- 8) 樋山義規,矢葺亘,松田泰治：ニューラルネットワークによる繰り返し劣化型履歴の認識,土木学会第51回年次学術講演会 CS-149,1996.9

(1996年9月6日受付)