

ニューラルネットワークによる
繰り返し劣化型履歴則のモデリング

MODELING OF HYSTERETIC DEGRADING BEHAVIORS WITH NEURAL NETWORKS

山本広祐* 酒井理哉* 萩原 豊*

By Kohsuke YAMAMOTO, Michiya SAKAI and Yutaka HAGIWARA

This paper describes a realistic hysteretic modeling with neural networks. The recognition targets with the neural networks are load-displacement relations obtained from bending tests of thin-walled pipe beams (two specimens). By using two kinds of neural networks, the hysteretic degrading behaviors were trained. One network was used for predicting the restoring force degradation, and the other was used for recognizing the hysteretic paths including the stiffness degradation. After training, some hysteretic paths were recognized, and well agreement between the results of the neural networks and the experimental data was obtained.

Key Words: neural network, hysteretic modeling, degrading system, load-displacement relation

1. はじめに

構造物の荷重-変位関係に現れる非線形の履歴挙動は、構造物の終局状態を把握し、予測する上で重要であり、限界状態を考慮した耐震設計への移行期にある今日、簡易で精度の高いモデリング手法の開発が望まれている。現在までに、各種の非線形挙動に関して多くの実験データや解析事例が蓄積されており¹⁾、これらを適切にモデリングする手法が開発され、数値解析に活用できれば、近似精度の改善やモデリングの省力化が図られ、解析・設計検討に役立つものと期待できる。

近年、パターン認識(数値モデリング)の一手法として人間の脳神経細胞網を模倣したニューラルネットワークが注目を集めている。このニューラルネットワークの特徴は、あらかじめ与えられた多数の入出力関係(学習データ)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り、関係式の形が事前に明示できなくても簡易に近似関数を作成できる手法として構造解析分野においても応用事例が蓄積されつつある。構造あるいは材料強度特性のモデリングについていえば、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²⁾をはじめ、Alanらによる合金材料モデルに関する研究³⁾、吉川による免震要素に関する研究⁴⁾、吉村らによるChaboche粘弾性モデルに関する研究⁵⁾などがある。また、動的システムの同定も構造システム挙動の定式化を目指したものであるが、例えば、線形システムを対象にしたRehakらの研究⁶⁾、非線形システムを対象にしたMasriらの研究⁷⁾、及び、Palらの研究⁸⁾などもこの範疇に含めることができる。

* 工修 (財)電力中央研究所 我孫子研究所 構造部 (〒270-11 千葉県我孫子市我孫子1646)

著者らも、ニューラルネットワークの高い内挿能力に着目し、これを用いた履歴モデリングの有効性と数値解析への応用性を示している^{9) - 11)}。しかしながら、著者らの研究も含め、既往研究の大半は繰り返し載荷に伴う、履歴復元力の低下を伴わない安定した挙動を対象にしたものであった。本論文では、ニューラルネットワークによる履歴モデリングの実用性を更に高めるために繰り返し劣化型履歴則のモデリングを検討した。一端固定中空円筒梁の繰り返し曲げ実験で、梁の固定部に累積変形が生じることによって履歴復元力の低下が生じ、一定振幅下である荷重値に収束する現象を例に、復元力の低下を推定するネットワークと剛性の低下を含んだ履歴経路を推定するネットワークを直列的に組み合わせた履歴モデルを作成し、近似精度の考察を行った。

2. ニューラルネットワークを数値モデリングに活用する意義

本来、数値モデリングは線形・非線形現象を問わず、現象の物理的な洞察に基づいて支配的なパラメータが抽出され、それらパラメータ間の因果関係を数式化することによりなされるのが原則である。この意味からは、作成した近似式がブラックボックスとなるニューラルネットワークの利用はモデリングの本質に反することになる。しかしながら、多数のデータ（ニューラルネットワークでいう入出力関係；学習データ）が得られているが、現象の解明が難しく、事前に関係式を明示することが容易でない場合が多いのも事実である。図-1は履歴モデルの作成に関して従来法と本論文で提案する方法を比較したものである。非線形関係の定式化が容易でない時、既存の簡易な数学モデルに代用させるか、近似精度を重視するかは作成したモデルの用途に依存するものであるが、少なくとも精度の確保は重要な問題であり、また、結果的に構築したニューラルネットワークから物理的な因果関係を見出すことも究極の目標と位置付けられる。




図-1 履歴復元力特性のモデリング手法

本論文で対象とする繰り返し劣化型履歴則の代表的な数学モデルとしては、Wenらが提案した多曲面型のモデル^{12), 13)}が有名である。例えば、星谷らは拡張カルマンフィルタアルゴリズムの状態方程式をWenらのモデルを用いて定式化し、構造系の地震時非線形挙動を同定する一手法を提案し、十分な精度が確保できたことを示している（例えば、文献14）、15）。本論文とこれら既往の方法との根本的な違いは、既述の通り、履歴復元力特性をモデリングする際、事前に関係式を必要とするか、しないかである。この違いには、単にモデリングの簡便化のみならず、実挙動に酷似した近似式を作成するために式の形になんらの制約も設けないという本質的な意義を含んでいる。

3. ニューラルネットワークの認識対象とする履歴復元力特性

(1) 実験の概要

ニューラルネットワークによる認識対象として、著者らが行った文献16)に示す一端固定梁の曲げ実験結果を引用する。図-2に実験装置と供試体の概要を示す。供試体はステンレスSUS304製の中空円筒梁で、長さ850mm、外径204mm、板厚2.0mmである。供試体の上下端には、中空円筒梁に比べて極端に剛性の高いフラン

ジが取り付けられている。

この曲げ実験は、供試体下部を剛に固定し、供試体上部のピン支持点に水平方向の強制変位を加えることにより行われる。供試体への曲げ加力はスクリー式ジャッキ（変位速度 $\pm 1.5\text{mm/min}$ 以下）により行われる。実験計測項目は、供試体への曲げ荷重（供試体の復元力）及び図-3に示す21箇所の変位である。ニューラルネットワークによる認識対象は2つの供試体を用いた実験結果（図-4）であり、前報^{10), 11)}でニューラルネットワークの認識対象とした実験と方法、供試体とも同様であるが、繰り返し変位の振幅を増大させている。ここで、図-4に示した供試体変位及び曲げ荷重は、供試体の初期状態から最初に強制変位を与えた方向（スクリー式ジャッキ方向）で生じたものを正とおいた。各供試体には以下に示す変位経路を強制外力として作用させた。

- ・ 供試体No. 1 : $\pm 9.5\text{mm}$ の変位振幅を45回、その後、 $\pm 11.0\text{mm}$ の変位振幅を15回
- ・ 供試体No. 2 : $\pm 11.0\text{mm}$ の変位振幅を30回

各変位振幅（以降、 $\pm$ の表記を省略する）における繰り返し回数は、その変位振幅で履歴復元力の低下がほぼ収束した時点とした。なお、供試体の初期剛性 k_0 、最大曲げ荷重 P_{cr} などは以下に示す通りである。

- ・ 初期剛性 : $k_0 = 604\text{kgf/mm}$
- ・ 最大曲げ荷重 : $P_{cr} = 2,710\text{kgf}$
- ・ P_{cr} における供試体変位 : $\delta_{cr} = 10.8\text{mm}$
- ・ 初期剛性で P_{cr} に到達する変位 : $\delta_e = 4.5\text{mm}$
- ・ P_{cr} における塑性率 : $\mu = \delta_{cr} / \delta_e = 2.4$




図-2 実験装置と供試体の概要





図-3 変位計測箇所



(a) 供試体No. 1 : 変位振幅 9.5mm (b) 供試体No. 1 : 変位振幅 11.0mm (c) 供試体No. 2 : 変位振幅 11.0mm

図-4 一端固定中空円筒梁の繰り返し曲げ実験結果

(2) 履歴復元力の低下と供試体の損傷

図-4に示した荷重-変位関係では、繰り返し载荷に伴い履歴復元力の低下が生じ、ある値に収束しているが、これが何に起因するものかを考察する。一例として、供試体No. 2の繰り返し回数と供試体下部の面外変形との関係(図-5)、及び、実験終了時の変形モード図(図-6)を示す。図-5では中空円筒梁の中心に向かう変位を正とおいた。いずれの供試体でも、繰り返し载荷の過程で供試体下部の曲げ圧縮縁に局部的な面外変形が発生し、それが周方向に徐々に広がりをもせ、最終的にはエレファント・フット・バルジに類似した残留変形を残した。従って、履歴復元力の低下は供試体下部の累積的なバルジ変形によるものである。なお、終局的な損傷はこの局部変形(過大ひずみ)箇所における低サイクル疲労になるものと予想される。






図-5 供試体下部の面外変形の成長過程
(供試体No. 2)



(a) 管軸方向変形モード図



(b) 供試体下部の周方向変形モード図

図-6 実験終了時の変形モード図
(供試体No. 2)

(3) 繰り返し回数及び履歴吸収エネルギーと履歴復元力の低下傾向

図-7に繰り返し载荷に伴う履歴復元力の低下傾向を示す。図中で縦軸は、各繰り返し時に得られた荷重を第1回目の载荷で得られた荷重で除した値として示している。なお、供試体No. 1における11.0mmの変位振幅過程については供試体No. 2の第1回の载荷で得られた荷重で基準化している。いずれの供試体でも滑らかに履歴復元力の低下が収束に至っているが、供試体No. 1の変位振幅11.0mmにおける低下曲線がNo. 2のその後半に類似していることは注目に値する。即ち、ある変位振幅 δa で履歴復元力の低下が生じた後、その変位振幅を超過して最大経験変位が δb に増大した時、履歴復元力の低下曲線は最初から δb の変位振幅を受けた場合の低下曲線上のある点に移動することを意味している。このことは工学的にみて理にかなっており、 δa から δb に増大した時どの状態に移るかの判断が重要であることを示唆している。ここで、 δa から δb への変位増分が小さい時、履歴復元力の低下率の変化量が小さいであろうことは容易に類推することができる。

図-8は、図-7の横軸を累積吸収エネルギーに置き換えたものである。両図とも同様の傾向を示しているが、繰り返し過程で履歴形態(あるいは、損傷モード)に極端な変化が生じないなら、繰り返し回数から履歴復元力の低下を推定する方が簡易である。

実験終了時の各供試体の状況を比較すると、復元力の収束値にはほとんど違いがみられなかったが、履歴曲線が囲む面積はNo. 2の方が10%程度大きかった。その原因としては、供試体の製作精度、据え付け条件、局部変形の発生位置・モード、変位履歴の違いなどが考えられる。




図-7 繰返し回数と履歴復元力の低下傾向




図-8 累積吸収エネルギーと履歴復元力の低下傾向

(4) 繰返し回数と剛性の低下傾向

図-4より、除荷時の剛性には若干の低下しか認められないが、載荷時の剛性には履歴復元力の低下に伴う顕著な剛性低下が認められる。履歴曲線全体として見た時、除荷から載荷に滑らかな履歴経路として移行していることから、繰返しに伴う剛性の変化（低下）は、単に履歴経路の目指す点（指向点）が変化したものとしてモデル化できる可能性がある。

4. 階層型ニューラルネットワークの構築

(1) 階層型ニューラルネットワークの基本概念

本論文では、Rumelhartらが開発した誤差逆伝搬学習に基づく階層型ニューラルネットワーク¹⁷⁾を採用し、3層構造のネットワークを用いる。以下にその基本概念をまとめる。まず、順方向の信号の伝搬は次の2つの式で示す、中間層ユニットjの内部ポテンシャル r_j と応答関数 g によって与えられる。

$$r_j = \sum_{i=1}^{n_i} (w_{ji} \cdot x_i) + \theta_j \quad \dots \dots \dots (1)$$

$$y_j = g(r_j) = 1 / \{1 + \exp(-r_j/T)\} \quad \dots \dots \dots (2)$$

ここで、 n_1 ：前層のユニット数

w_{ji} ： i ユニットと j ユニット間の結合係数

x_i ： i ユニットの出力信号

$-\theta_j$ ： j ユニットのしきい値

y_j ： j ユニットの出力信号

T ：応答関数 g の勾配を決定するパラメータ

一方、逆方向の処理、即ち誤差逆伝搬学習では、出力層ユニット k の出力信号 O_k と正しい解（教師信号） A_k との間に生じた誤差 E を減らすために最急降下法を用いて結合係数としきい値を修正する。

$$E = \sum_{k=1}^{n_3} (A_k - O_k)^2 / 2 \quad \dots \dots \dots (3)$$


ここで、 n_3 ：出力層のユニット数

（２）繰り返し劣化型履歴則のモデリングに関する基本方針

履歴則を設定する際、最も重要なのは履歴経路が現在の位置からどの点を指向するのを見極めることである。前報^{9)~11)}では変位制御による履歴推定問題を対象とし、履歴経路の出発点、指向点、及び、両点間の任意の変位をニューラルネットワークの入力に与え、その変位に対する荷重を出力（推定）したが、本論文でも同様の方法を用いる。ここで、履歴経路の指向点は以下の方法で統一的に選択する。

- ① 骨格曲線上から除荷し、履歴曲線を描く時、その除荷点（結果的に最大経験変位となる）と正負の符号を入れ換えた点（原点对称点）を履歴経路が指向する点とする。
- ② 最大経験変位未満で除荷・載荷を繰り返す時、同一の変位方向で最も間近に変位方向を折り返した点（最も近傍の折れ点）を指向点とする。

図－９はこの概念を示したものである。供試体が原点 O から正方向に強制変位を受け、点 A （ δ_1, f_1 ）で変位方向を折り返した時、指向点は A' （ $-\delta_1, -f_1$ ）となる。履歴曲線 AA' 上の点 B で変位方向を折り返した時の指向点は A であり、更に BA 間の点 C で変位方向を折り返した時は点 B にたどりつくまでの指向点は B であり、それ以降は A' となる。以上の考え方は、鋼構造要素としてはごく一般的なものである。



図－９ 典型的な履歴経路

次に、繰り返し載荷に伴う履歴復元力低下の考え方を付加する。

- ③ 指向点の変位が最大経験変位を大きく下回る場合、即ち、変位振幅が小さい場合、供試体下部に生じた累積変形を増大させ、履歴復元力を低下させる効果が小さいと考えられるため、指向点の復元力の低下を考えない。
- ④ 指向点が最大経験変位にほぼ等しく、かつ、指向点のごく近傍で変位方向を折り返した際には、次回、その領域で指向点を設定する時に復元力の低下を考慮する。
- ⑤ 最大経験変位を越えた場合にも変位方向を折り返すまでは復元力の低下率に変化が生じないものと仮定し、その後、変位方向を折り返した際には、次回、その領域で指向点を設定する時に復元力の低下を考慮する。

③及び④の境界をどこで与えるのかは、モデリングの適用対象に依存する。

以上に基づいて、履歴復元力の低下率を推定するネットワークと剛性低下を含む履歴経路の推定を行うネットワークの２種類を作成する。なお、実験で得られた履歴挙動には正負で若干の非対称性が認められることから、正負それぞれに分けてネットワークを作成する。従って、総計４つのネットワークを作成する。

(3) 履歴復元力の低下曲線の学習

基本的には、変位振幅と繰り返し回数から、その変位振幅に対する履歴復元力の低下率を推定できればよい。但し、ある程度、復元力が低下した後で変位振幅が変化する場合にも対応できる必要があるため、入出力ユニットとして以下の項目を設定した。

・入力層（3ユニット）：現在の復元力の低下率（ Deg_{i-1} ）

現在の変位振幅（ Amp ）

現在の変位振幅 Amp における繰り返し回数の増分（ Δm ）

・出力層（1ユニット）：変位振幅 Amp を Δm 回繰り返した時の復元力の低下率（変化量； ΔDeg_i ）

ここで、 Deg の添え字 i （ $=1, 2, \dots$ ）は、ニューラルネットワークを用いた履歴復元力の低下率の推定回数を示す。最初の推定を行う場合、過去にいかなる変位履歴も受けていないため初期値 $\text{Deg}_0=1.0$ となる。 i 回目の推定における履歴復元力の低下率は $\text{Deg}_i=\text{Deg}_{i-1}+\Delta \text{Deg}_i$ で表される。変位振幅 Amp の変化に対しては、前節の考察に基づき、最大経験変位より小さくなる方向では復元力の低下率に変化なし、最大経験変位近傍及びそれより大きくなる方向では変位方向を折り返すまでは Deg_i を変化させず、次回、その領域で指向点を設定する時に Deg_i の値を更新（ $\text{Deg}_{i+1}=\text{Deg}_i+\Delta \text{Deg}_{i+1}$ を計算）した。なお、変位振幅の変化を直接ニューラルネットワークに組み込むなら、入出力ユニットを以下のように設定し直せば容易に拡張することができる。

・入力層（4ユニット）：現在の復元力の低下率（ Deg_{i-1} ）

現在の変位振幅（ Amp ）

次の変位振幅（ Amp' ）

次の変位振幅 Amp' における繰り返し回数の増分（ $\Delta m'$ ）

・出力層（1ユニット）：変位振幅 Amp' を $\Delta m'$ 回繰り返した時の復元力の低下率（変化量； $\Delta \text{Deg}_i'$ ）

i 回目の推定における履歴復元力の低下率は $\text{Deg}_i=\text{Deg}_{i-1}+\Delta \text{Deg}_i'$ で表される。

ネットワークは文献10) に示した簡単な構造学習を経て、入力層3ユニット、中間層6ユニット、出力層1ユニットの構成とした。学習データは、供試体No. 1の変位振幅9.5mmの実験結果、及び、供試体No. 2の実験結果から約400組（ $\times 2$ ネットワーク分）を選択した。このデータ組数は、実験結果から作成し得る最大値の約1/4に相当する。なお、供試体No. 1の変位振幅11.0mmの実験結果は完全にブラインドデータ（学習の対象外）とした。全学習データに対して1通りの学習を1回の学習と定義すると、約5,000回の逐次修正学習でネットワークが適度な精度に収束した。図-10に学習結果を示す。供試体No. 2の繰り返しの初期の段階（負の荷重側）で、若干、推定精度の乱れがみられるが、全般に平均的な傾向をとらえている。また、全く学習の対象としていなかった、供試体No. 1の変位振幅11.0mmの実験結果に対しても十分な精度を保持できていることが確認できた。

本ネットワークの特徴は、増分的な扱いを用い、既に何らかの履歴経路を経て復元力の低下が生じ




図-10 ニューラルネットワークを用いた
復元力低下曲線の推定結果

た段階から更にその先の状態を予測できることにある。この意味から、供試体No.1で変位振幅を9.5mmから11.0mmに増大させた過程が精度よく推定できたことは有意義である。なお、現状では、十分な検証データを有していないため主として定常変位振幅に対する履歴復元力の低下しか扱っていないが、より複雑な履歴経路の学習・推定に適用した時、更に有効性が発揮できるものと考えられる。

(4) 履歴曲線の学習

変位制御による荷重推定問題を想定し、入出力ユニットとして以下の項目を設定した。

- ・入力層（5ユニット）：最新の变位方向折り返し点；履歴経路の出発点（ X_i, P_i ）
履歴経路の指向点（ $X_o, P_o' = \text{Deg}_i \times P_o$ ）
履歴経路の出発点と指向点の間の任意の変位 X_n
- ・出力層（1ユニット）：変位 X_n における復元力 P_n

ここで、指向点の設定において、 P_o は骨格曲線上の変位 X_o における荷重、即ち、過去にいかなる変位履歴も受けていない状態での荷重を意味する。 Deg_i は前節で示したニューラルネットワークの出力であり、このユニットを介して2種類のニューラルネットワークが直列的に組み合わせられている。図-11にネットワーク相互の位置関係を示す。 Deg_i

は変位経路を折り返した時に計算するもので、履歴経路の認識における各変位ステップごとに随時計算するものではない。なお、学習データの作成時においては、履歴経路がどの位置で折り返したかがわかるため、経路の指向点 P_o' を直接提示することができる。





図-11 2種類のネットワークの相互関係

ネットワークは、前節同様、文献10)に示した簡単な構造学習を経て、入力層5ユニット、中間層5ユニット、出力層1ユニットの構成とした。学習データは、供試体No.1の変位振幅9.5mmの実験結果、及び、供試体No.2の実験結果から約300組（×2ネットワーク分）を選択し、供試体No.1の変位振幅11.0mmの実験結果は前節同様、学習の対象外とした。このデータ組数は、実験結果から作成し得る最大値の約1/3.5に相当する。ネットワークは、約2,000回の逐次修正学習で適度な精度に収束した。図-12に図-4に示した実験結果



(a) 供試体No.1: 変位振幅9.5mm (b) 供試体No.1: 変位振幅11.0mm (c) 供試体No.2: 変位振幅11.0mm

図-12 ニューラルネットワークを用いた履歴推定結果

における変位経路を連続的に認識させた結果を示す。また、履歴モデリングの精度評価に重要と考えられる、繰り返し回数と履歴吸収エネルギーの関係を図-13に示す。図-13の縦軸は、該当する実験結果の初回の履歴面積で基準化を行っている。履歴復元力の低下傾向が十分な精度で推定できたことは前節で論じたが、図-12から履歴曲線の形状にも大きな逸脱のないことが容易に判断できる。また、図-13から履歴曲線の囲む面積を考察すると、供試体No. 1の変位振幅9.5mm及び供試体No. 2については実験結果とほぼ一致する。これに対し、供試体No. 1の変位振幅11.0mmの推定結果は、例えば、最終回の繰り返しにおいてNo. 1の実験結果に対しては約10%程度大き

めの値、No. 2の実験結果に対してはほぼ等しい値となった。このことは、ネットワーク内部に作成された履歴モデルが学習データである供試体No. 2の挙動を忠実に再現したことを如実に示すものであり、妥当な結果といえる。もしネットワークの学習データにNo. 1の変位振幅11.0mmのデータを付け加えれば、供試体No. 1とNo. 2の平均的な挙動を再現できるものと考えられる。




図-13 履歴吸収エネルギーの比較

5. まとめ

本論文では一端固定中空円筒梁の曲げ実験を例に、ニューラルネットワークを用いた劣化型履歴則のモデリング手法を検討した。得られた成果を以下に要約する。

- ① 履歴モデリングにニューラルネットワークを利用する意義と有効性を論じた。
- ② ニューラルネットワークは自動的にパターン認識する手法であるが、入出力項目に何を割り当てるかの判断が特に重要であり、対象とする現象の詳細な分析を経てなされることの一例を示した。
- ③ 履歴復元力の低下曲線の学習・推定では、既に何らかの履歴経路を経て復元力の低下が生じた段階から更にその先の復元力低下を予測する手法を示した。
- ④ 剛性低下を含む、履歴経路の学習・推定では、履歴経路の出発点と指向点、及び、それら两点間の任意の変位を入力データとして応答荷重を予測する手法を示した。
- ⑤ 履歴復元力の低下を推定するネットワークと剛性低下を含んだ履歴経路を推定するネットワークを直列的に組み合わせ、変位振幅が変化する経路の荷重履歴推定に活用し、精度の高い解を得た。

なお、本論文では履歴挙動の非対称性を考慮して変位方向別にネットワークを使い分ける手法を用いたが、この方法は顕著な非対称履歴則をモデリングする際に特に有効性を発揮するものと考えられる。

6. あとがき

本論文ではニューラルネットワークを用いて劣化型履歴則をモデリングする一例を示したが、提案した手法そのものは個別の対象に特化されるものではない。その基本的な流れは、履歴復元力の低下とそれに基づ

く履歴経路の指向点の変化を適切に判断しながらニューラルネットワークに経路認識させることに他ならない。ニューラルネットワークによるモデリングでは、どこまで人間が介入すべきか（即ち、どこまでニューラルネットワークの入力項目にすべきか）、どこまでニューラルネットワークの学習対象とすべきか（即ち、出力項目にすべきか）は、今なお、議論の余地が残されているが、少なくとも本論文で示した程度の入出力項目は、作成した履歴モデルを評価し、推定経路を検証するためのチェック項目としても有効であり、また、データ作成上の大きな負担にはならないであろうことを付記する。

参考文献

- 1) 土木学会鋼構造委員会, 鋼構造動的極限性状研究小委員会: "鋼構造物の弾塑性性状と耐震設計法", 1993.8
- 2) Ghaboussi, J., Garrett Jr., J.H. and Wu, X.: "Knowledge-based Modeling of Material Behavior with Neural Networks", Jour. of Eng. Mech., ASCE, Vol.117, No.1, pp.132-153, 1991.1
- 3) Alam, J., Berke, L. and Murthy, P.L.N.: "Use of Artificial Neural Networks in Non-linear Material Modeling", Intelligent Engineering Systems through Artificial Neural Networks (Proc. of the ANNIE'91, Edited by Dagli, C.H. et al.), ASME Press, pp.607-612, 1991.11
- 4) 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, 1992年度研究発表会研究報告集<構造編>, pp.9-12, 1993.2
- 5) 吉村 忍, 菱田博俊, 矢川元基: "ニューラルネットワークによる非弾性構成方程式のパラメータ決定法", 日本機械学会論文集 (A編), Vol.59, No.559, pp.518-525, 1993.3
- 6) Rehak, D.R., Thewalt, C.R. and Doo, L.B.: "Neural Network Approaches in Structural Mechanics Computations", Computer Utilization in Structural Engineering (Proc. of the Structures Congress'89, Edited by Nelson Jr., J.K.), ASCE, pp.168-176, 1989.5
- 7) Masri, S.F., Chassiakos, A.G. and Caughey, T.K.: "Identification of Nonlinear Dynamic Systems Using Neural Networks", Jour. of App. Mech., ASME, Vol.60, No.1, pp.123-133, 1993.3
- 8) Pal, C., 榎場直樹, 森下 信, 萩原一郎: "ニューラルネットワークによる動的システムの時系列同定 (第1報, 誤差逆伝ば法に基づく高速学習法)", 日本機械学会論文集 (C編), Vol.59, No.561, pp.1436-1442, 1993.5
- 9) 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
- 10) 山本広祐, 酒井理哉: "ニューラルネットワークによる実験履歴挙動の認識とネットワーク構築過程の考察", 構造工学論文集, Vol.39A, pp.71-84, 1993.3
- 11) Yamamoto, K. and Sakai, M.: "An Application of Neural Networks to Hysteretic Modeling of Steel Structures", Computing in Civil and Building Engineering (Proc. of the 5th ICCCB, Edited by Cohn, L.F.), ASCE, Vol.2, pp.961-964, 1993.6
- 12) Wen, Y.K.: "Method for Random Vibration of Hysteretic Systems", Jour. of Eng. Mech., ASCE, Vol.102, No.EM2, pp.249-263, 1976.4
- 13) Baber, T.T. and Wen, Y.K.: "Random Vibration of Hysteretic, Degrading Systems", Jour. of Eng. Mech., ASCE, Vol.107, No.EM6, pp.1069-1087, 1981.12
- 14) Hoshiya, M. and Saito, E.: "Structural Identification by Extended Kalman Filter", Jour. of Eng. Mech., ASCE, Vol.110, No.12, pp.1757-1770, 1984.12
- 15) 星谷 勝, 丸山 収: "非線形構造系の地震時挙動特性の同定", 土木学会論文集, No.386/I-8, pp.397-405, 1987.10
- 16) 山本広祐, 酒井理哉, 萩原 豊, 松浦真一, 豊田幸宏: "高速炉薄肉直管の繰返し曲げ特性に関する実験的検討", 電力中央研究所報告, 研究報告U92022, 1992.9
- 17) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: "Learning Representations by Back-propagating Errors", Nature, Vol.323, No.6088, pp.533-536, 1986.10

(1993年9月16日受付)