

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

RECOGNITION OF EXPERIMENTAL HYSTERETIC BEHAVIOR WITH NEURAL NETWORK
AND DEVELOPMENT PROCESS OF THE NETWORK

山本 広祐* 酒井理哉*

By Kohsuke YAMAMOTO and Michiya SAKAI

This paper describes an application of the neural network to realistic hysteretic modeling. The recognition targets with neural network are load-displacement relations obtained from bending tests of thin-walled pipe beams (two specimens).

By using neural network that is a new modeling strategy, the experimental hysteretic behavior was trained. Training cases were selected from typical hysteretic paths, and a transient path was prepared as untrained case. After training, untrained path was recognized, and close agreement between the result of the neural network and the experimental data was obtained.

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有限要素解析事例が蓄積されており、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、従来手法の近似精度が改善され、非線形構造解析の精度や効率の大幅な向上に役立つものと期待できる。

近年、パターン認識（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（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、構造解析分野においても幾つかの応用事例が蓄積されつつある。例えば、1質点系の線形振動方程式をニューラルネットワークに認識させ、応答解析を行ったRehakらの研究¹⁾、鋼材試験片の経時的な弾塑性応力-ひずみ関係から疲労寿命を算出したTroudetらの研究²⁾、あるいはプレーンコンクリートの非線形の応力-ひずみ関係（経路）のモデリングに活用したGhaboussiらの研究³⁾などが先駆的なものと言える。

著者の一人は、ニューラルネットワークの表現能力に着目し、履歴挙動のモデリングに用いられる既存の数学モデルの認識を通して本モデリング手法の有効性と構造解析への応用性を示した⁴⁾。文献4)では、多

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

数の学習データが容易に取得できることを前提に、試行錯誤的にネットワークを構築したものであった。本論文では、この検討結果を踏まえて、更に現実的な一端固定中空円筒梁の曲げ実験で得られた履歴挙動のモデリングにニューラルネットワークを適用した。適用にあたり、従来、ほとんど明確に示されなかった中間層ユニット数やネットワークの初期値設定などに関して決定根拠を明らかにし、限られた最少限の学習データから収束精度及び学習効率の高いネットワークを構築する方法を考察した。

2. ニューラルネットワークの認識対象とする実験履歴挙動

(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5)に示す一端固定梁の曲げ実験結果を引用する。図-1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。供試体の材料物性値を表-1に示す。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てある。

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強制変位を加えることにより行った。供試体への曲げ加力はスクリュー式ジャッキ（変位速度±1.5mm/min以下）により行われる。ニューラルネットワークによる認識対象は、以下に示す2つの供試体を用いた3種類の実験結果であり、履歴特性実験としては最少限のものである。

表-1 供試体に使用したステンレスSUS304の材料物性（平均値）

材料試験片の切り出し方向	0.2%耐力(kgf/cm ²)	引張強度(kgf/cm ²)	綫弾性係数(kgf/cm ²)	ポアソン比
供試体の高さ方向	2750	6740	1.99×10 ⁶	0.281
供試体の円周方向	2750	7020	1.87×10 ⁶	0.267

(2) 漸増繰り返し曲げ実験（供試体No.1）

供試体上下の相対水平変位（以降、供試体変位と略称）を2.2mmから8.25mmまで0.55mm間隔で、各変位振幅につき10回の繰り返し曲げを行った。得られた曲げ荷重と供試体変位の関係を図-2に示す。各変位振幅において、繰り返しによる曲げ荷重の低下を伴わない安定した履歴挙動を示した。なお、この紡錘型の履歴ループは、繰り返し曲げに伴って供試体の付け根部にバルジ変形が発生したことによるものであった。

(3) 定常繰り返し曲げ実験（供試体No.2）

漸増繰り返し曲げ実験の再現性と繰り返しによる荷重-変位関係の安定性を確認するため、別の供試体を用いて8.0mmの変位振幅で60回の繰り返し曲げを行った。得られた曲げ荷重と供試体変位の関係を図-3に示す。繰り返し曲げに伴い僅かに荷重低下が認められたものの、供試体間の仕上がり誤差等を念頭に入れれば図-2と基本的に大差のない結果であった。

(4) 過渡的な変位経路に関する実験（供試体No.2）

一定の変位振幅による履歴挙動以外の経路データとして、最大経験変位未満（最外郭ループの内側）で載荷、除荷を繰り返す実験を行った。図-4は最外郭ループ上の点から最大経験変位点を指向する経路で、ニューラルネットワークの学習データに用いるため、図-5は不規則な経路として未学習データの認識に用い、構築したネットワークを検証するための実験結果である。なお、この実験は定常繰り返し曲げ実験に引き続いて行った。

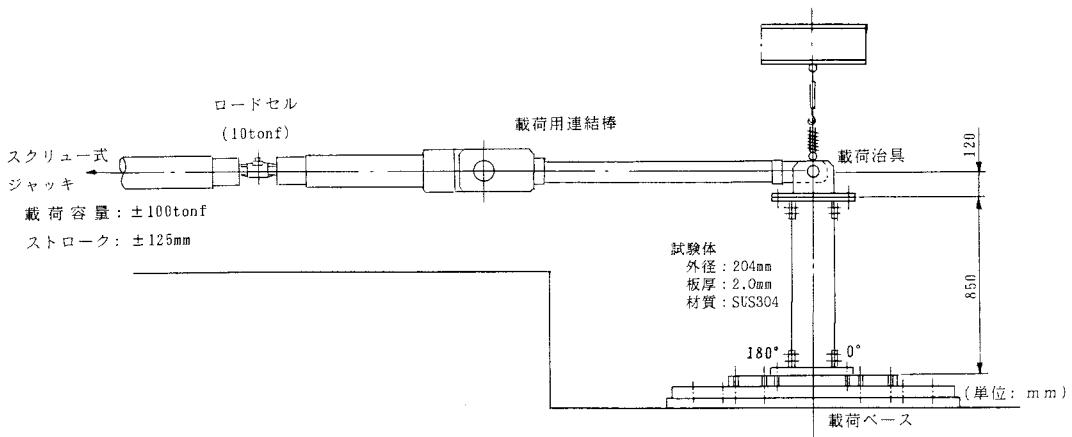


図-1 実験装置と供試体の概要

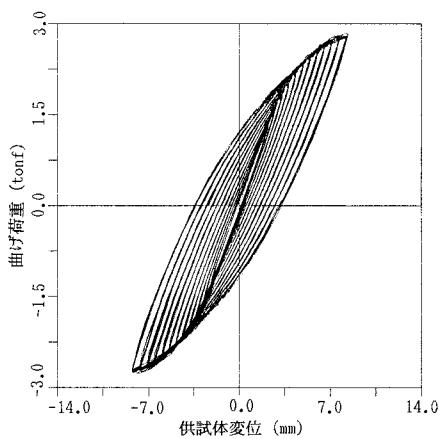


図-2 漸増繰り返し曲げ実験結果（供試体No.1）

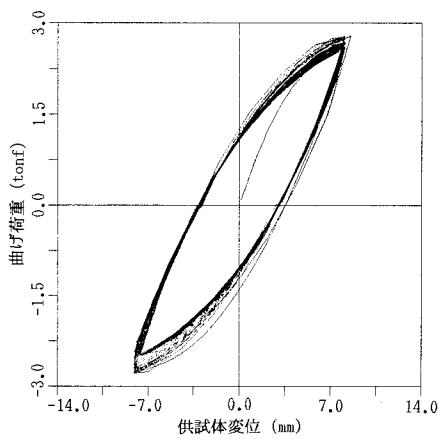


図-3 定常繰り返し曲げ実験結果（供試体No.2）

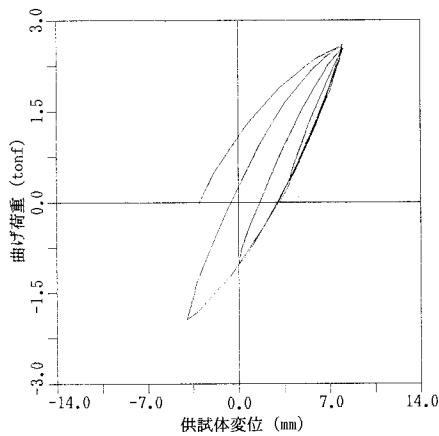


図-4 過渡的な変位経路に関する実験結果
(学習データ用；供試体No.2)

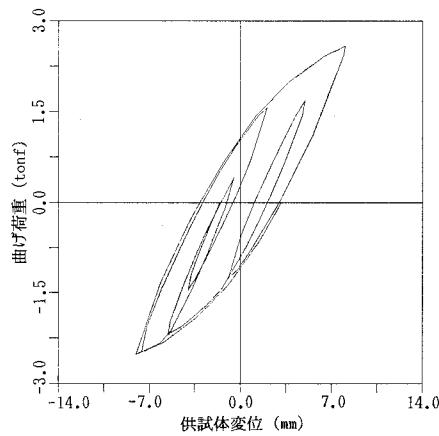


図-5 過渡的な変位経路に関する実験結果
(未学習データの認識用；供試体No.2)

3. ニューラルネットワークの構築

(1) 使用したニューラルネットワークの基本概念⁴⁾

誤差逆伝播 (back-propagation) 学習による階層型ニューラルネットワークを用いるものとし、定式化を行った^{6), 7)}。基本的な構造は、入力層、複数の中間層、出力層からなり、各層は人間の脳神経細胞を理想化したユニット (processing unit) から構成される (図-6)。ニューラルネットワークにより任意の連続写像関数を構築するためには、中間層を 1 層 (入・出力層を含めて 3 層) 以上とし、各中間層に適切なユニット数を設ければよい (但し、出力層の応答関数は線形関数とする) ことが既に知られている⁸⁾が、本論文では中間層ユニット数の最適化を図る便宜上、中間 1 層の 3 層構造を用いることにした。

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、出力層と信号が伝達される。入力層 i ユニット ($i = 1 \sim n_i$) から中間層 j ユニットへの信号を x_i とすると、信号の伝達により j ユニットには以下に示す内部ポテンシャル r_j が蓄積される。

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

ここに、 w_{ji} : i ユニットと j ユニット間の結合の重み (結合係数)

$-\theta_j$: j ユニットのしきい値

この r_j は、以下に示すシグモイド関数 (図-7) と呼ばれる応答関数 $f(r_j)$ の出力として、更に次層への信号 y_j として伝達される。

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

ここに、 T : シグモイド関数の形状パラメータ

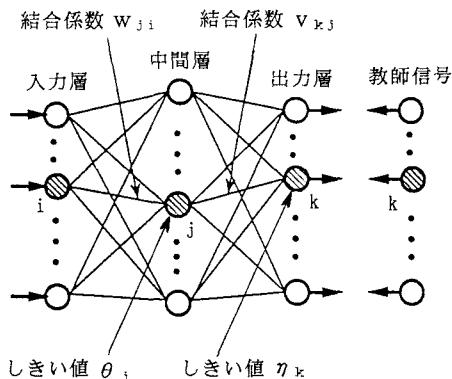


図-6 階層型ニューラルネットワークの概要

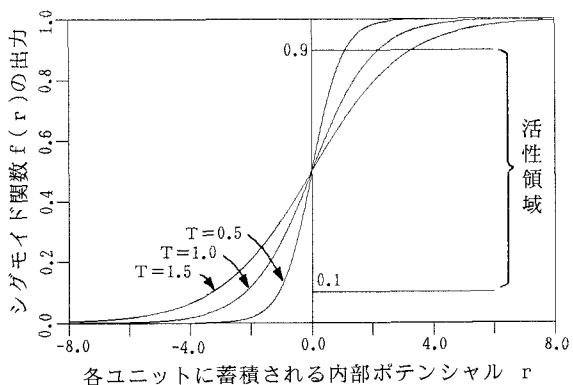


図-7 中間層ユニットの応答関数 (シグモイド関数)

一方、最終的に出力される出力信号と正しい解 (教師信号)との間に誤差が生じるが、この誤差を減らすために各層間の結合係数、及び、各ユニットのしきい値が修正される。この修正過程がニューラルネットワークの学習に相当する。まず、学習データ p に対する誤差関数 E_p を定義する。

$$E_p = \sum_{k=1}^{n_3} (T_{pk} - O_{pk})^2 / 2 \quad \dots \dots \dots \dots \dots \dots \dots \quad (3)$$

ここに、 n_3 : 出力層のユニット数

T_{pk} : 学習データ p に関する k ユニットの教師信号

O_{pk} : 学習データ p に関する k ユニットの出力信号

$$O_{pk} = g(q_k) = q_k/T \quad \dots \dots \dots \dots \dots \dots \dots \dots \quad (4)$$

$$q_s = \sum_{j=1}^{n_s} (v_{kj} + y_j) + \eta_s \quad \dots \dots \dots \dots \dots \dots \dots \quad (5)$$

ここに、 g : 出力層ユニットの線形応答関数

q_k : k ユニットの内部ポテンシャル

n_2 : 中間層のユニット数

v_{kj} : j ユニットと k ユニット間の結合の重み（結合係数）

— η_k : k ユニットのしきい値

この E_p を最急降下法を用いて極小化するためには、結合係数 v_{kj} を Δv_{kj} だけ修正すればよい。

$$\Delta V_{kj} = \mu \cdot (T_{pk} - O_{pk}) \cdot g'(q_k) \cdot y_j \quad \dots \dots \dots \dots \dots \dots \dots \quad (6)$$

ここに、 μ : 学習制御パラメータ ($\mu > 0$, μ は定数)

g' : 応答関数 g の 1 次偏分

同様にして、しきい値 η_k の修正量 $\Delta\eta_k$ も得ることができる。

$$\Delta \eta_k = \nu \cdot (T_{pk} - O_{pk}) + g' (q_k) \quad \dots \dots \dots \dots \dots \dots \dots \quad (7)$$

ここに、 γ : 学習制御パラメータ ($\gamma > 0$, γ は定数)

更に、出力層だけではなく、中間層についても同様の修正が加えられる。

以上の過程を全学習データに対して繰り返すことにより、最小2乗誤差の総和Eの極小化が図られる。

$$E = \sum_{p=1}^{n_g} E_p \quad \dots \dots \dots \dots \dots \dots \dots \quad (8)$$

ここに、 n_4 : 学習データ総数

(2) ネットワークの初期値設定法

学習開始時には、結合係数 w_{ij} 、 v_{kj} 、しきい値 θ_j 、 η_k の初期値を決定する必要がある。通常、シグモイド関数ユニットの初期値は小さな一様乱数により設定されることが多いが、この場合、ネットワーク各層のユニット数が少なければ結果的に適度な初期値になりやすい反面、ネットワークが大規模化して各層のユニット数が多くなると初期値設定の重要性が増し、ネットワークの収束可否や収束精度を左右することになる。この問題に関して、賈らはユニットの情報伝達構造を定量的に表現できるパラメータを導入して従来の初期値設定法の性質を調べ、新しい設定法を提案した⁸⁾。以下にその概要を示す。

式(2)に示した中間層ユニットの応答関数は0~1の値をとる。各ユニットへの入力空間は、前層のユニット数nにより決定され、 $(0, 1)^n$ の単位超キューブになる。ところで、各ユニットへの入力空間は、出力値が0または1付近で飽和する領域と出力値の変化の大きい領域(活性領域; 図-7参照)に分けて考えることができる。本論文では、ユニットの出力が0.1~0.9までの範囲をとる入力集合を活性領域と仮定する。ここで、前述の単位超キューブのサイズDを定義する。

貴らは、従来の初期値設定法では、ユニットに結合する前層のユニット数を考慮していないため活性領域の幅とユニットの入力空間サイズに不整合が生じていること指摘し、この改善策として結合係数としきい値の初期値に制約条件を導入した。本論文では、この貴らの方法にシグモイド関数の形状パラメータ T を考慮できる拡張を施して用いることにした。以下に中間層の j ユニットの結合係数としきい値の制約条件を示す。

$$\frac{|f^{-1}(0.9) - f^{-1}(0.1)|}{\left\{ \sum_{i=1}^{n_1} (w_{ji})^2 \right\}^{1/2}} = a (n_1)^{1/2} \quad \dots \dots \dots \dots \dots \dots \quad (10)$$

$$\theta_j = -0.5 \times \sum_{i=1}^{n_1} w_{ji} \quad \dots \dots \dots \dots \dots \dots \quad (11)$$

ここに、 a は活性領域の幅 d と D の比であり、 $a = 1 \sim 3$ 程度が適值と考えられている。なお、線形応答閾数ユニットの出力領域についても同様の値(0.1~0.9)を設定し、結合係数としきい値の初期値に制約条件を導入した。

(3) 中間層ユニット数の決定法

入・出力層のユニット数は取り扱う問題に応じて一意に決定されるが、中間層のユニット数は従来から試行錯誤的な方法で決定されることが多かった。中間層は、ネットワークが任意の連続写像関数を表すための重要な役割を果たしており、ネットワークの数値出力を直接扱う定量的問題においては層数とユニット数の組み合わせによるネットワーク結合の必要最小値があると考えられている。例えば、必要最小値に満たないネットワークを定義して学習を行わせてもネットワークは収束しないであろうし、逆に必要最小値を大幅に上回るネットワークを定義したなら実際の関数より高次の複雑な疑似関数を構築するであろう。

近年、中間層ユニット数の良否を評価する2種類の有効性指数(Goodness Factor : Good_j¹⁰⁾と Badness Factor : Bad_j¹¹⁾)が提案されている。ここで、Good_jは中間層の j ユニットが伝搬する活性の総和量を表し、Bad_jは j ユニットが伝搬する誤差の総和量を表す。

$$Good_j = \sum_{p=1}^{n_4} \left\{ \sum_{k=1}^{n_3} (v_{kj} \cdot y_p)^2 \right\} \quad \dots \dots \dots \dots \dots \quad (12)$$

$$Bad_j = \sum_{p=1}^{n_4} \left\{ \sum_{k=1}^{n_3} (v_{kj} \cdot (T_{pk} - O_{pk}))^2 \right\} \quad \dots \dots \dots \dots \dots \quad (13)$$

有効性指数を用いた中間層ユニット数の自動調整アルゴリズムは統一的な方法が確立されていないが、本論文では表-2に示すアルゴリズムを用いる。ここで、Good_jを用いる場合には値が最小となるユニットを不良ユニットとして、Bad_jを用いる場合には最大のユニットを不良ユニットとして抽出する。表-2のアルゴリズムを所定回数(N_4)繰り返すことによってネットワークに十分な揺らぎを与え、誤差総和Eを最小にする中間層ユニット数を最適値として選定する。いずれの有効性指数も中間層ユニット数の理論的な最小値を保証するものではないが、局所解からの脱出と学習回数の低減に関しては有効であると考えられている。本論文ではニューラルネットワークの本質上、活性の高いユニットを残す(活性の低いユニットを削除する)方が適切と考え、有効性指数Good_jを用いることにした。

(4) 入・出力層ユニット項目の選定

履歴挙動には経路依存性があるため、実験履歴挙動

表-2 中間層ユニット数の自動調整アルゴリズム

ユニット数を1つ削減する場合(1ルール)	
① 収束基準を設定し、その成立を確認する。	
② 収束基準が成立すれば有効性指数を計算し、不良ユニットを抽出する。	
③ 抽出されたユニットを削減する。	
ユニット数を1つ追加する場合(3ルール)	
① 誤差総和Eをモニタリングする。	
② Eが増加傾向にある場合、所定回数N ₁ をもって全ての結合係数としきい値を乱数でリセットする。	
③ リセット後もEの増加傾向が解消されない場合、ユニットを追加する。	
① 誤差総和Eをモニタリングする。	
② 所定回数N ₂ 以内で収束基準が成立しない場合、全ての結合係数としきい値を乱数でリセットする。	
③ リセット後も収束基準が成立しない場合、ユニットを追加する。	
① 誤差総和Eをモニタリングする。	
② 不良ユニットを削減した時の誤差総和E _s を記憶する。	
③ 削減後、所定回数N ₃ をもってE _s を回復できない場合、全ての結合係数としきい値を乱数でリセットする。	
④ リセット後もE _s を回復できない場合、ユニットを追加する。	

を特徴付けるパラメータをニューラルネットワークの入力層ユニットに割り当てる必要がある。変位制御による履歴推定問題を対象とする場合、出力層ユニットは与えられた変位経路に関する応答復元力であり、容易に1ユニットに決定できる。

図-2～図-5に示したニューラルネットワークの認識対象（但し、図-5はネットワークの学習に用いない）を念頭に、図-8に示す2種類の履歴則を考える。一般に、鋼構造物は塑性化が最も進行した状態の影響を強く受けるため、いずれの履歴則とも経路が最終的に最大経験変位点(X_{max} , Y_{max})を指向するように配慮した。図-8(a)は、経路が骨格曲線から除荷し、最外郭ループ上あるいはその内側で除荷、載荷を繰り返した際、経路が常に最大経験変位点を目指す、いわゆるRamberg-Osgood型の履歴則^{12), 13)}である。一方、図-8(b)は、図-8(a)の改良型であり、最外郭ループ上で変位方向を折り返した場合には最大経験変位点を目指し、最外郭ループ内で変位方向を折り返した場合には先に最大経験変位点を目指していた経路に戻るモデルである。すなわち、図-8(b)は、A→B→C→DのCD間で必ずBを経由し、その後、AD間を連続して移動する経路に復帰するものである。実験で不規則な履歴経路を取得した図-5は、図-8(b)に近い挙動を示している。しかしながら、

- ① 履歴特性実験として図-2～図-4が一般的であるが、この場合、結果的に図-8(a)の履歴則を想定したことになる。
- ② 図-8(a)の方が応答復元力を小さめに予測することから、実用上、安全側のモデル化になる。
- ③ 履歴ループの紡錘形状が極端に膨らんでいない場合、結果的に大きな違いを生じない。
- ④ 本論文では、最少限の学習データを想定した。

ことなどから、図-8(a)の履歴則を想定することにした。従って、入・出力層のユニット項目を以下のように決定した。なお、図-2～図-4に示した経路は、いずれも図-8のC点で変位方向を折り返す経路を含んでいないため、図-8(b)の履歴則を想定する場合には、更に多くの履歴経路データを取得する必要がある。

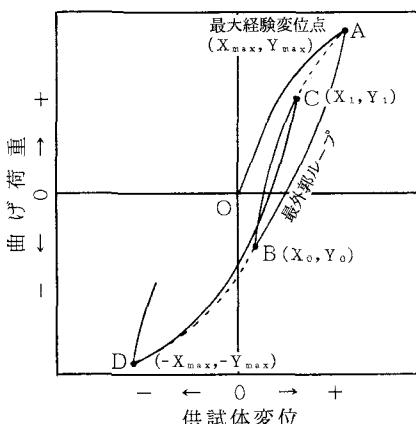
・入力層5ユニット：最大経験変位点(X_{max} , Y_{max})

最新の変位方向折り返し点

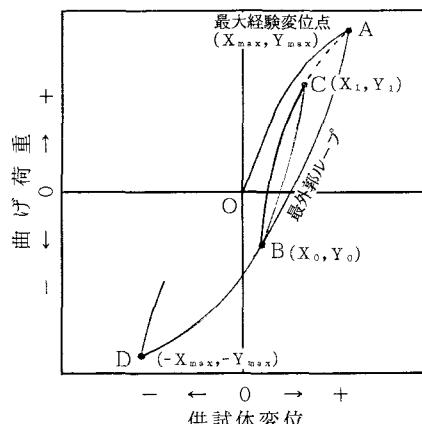
次の変位状態 X_n

・出力層1ユニット：次の変位状態 X_n に対する復元力 Y_n

ここで、最新の変位方向折り返し点は、図-8(a)でAD(AB)間を移動中にはA(X_{max} , Y_{max})、BA(BC)間を移動中にはB(X_0 , Y_0)、CD間を移動中にはC(X_1 , Y_1)になる。



(a) 常に最大経験変位点を指向する場合



(b) 最外郭ループ上の除荷点を経由する場合

図-8 実験履歴挙動のモデル化

4. 実験履歴挙動の学習と認識

(1) 学習データの選定

実験で取得した典型的な履歴経路を選定し、学習データを作成した。学習データの総数は79組で、その内訳は以下に示す通りである。

- ① 図-2から、変位振幅 $\pm 6.05\text{mm}$ 、 $\pm 7.15\text{mm}$ 、 $\pm 8.25\text{mm}$ の経路上で学習データを選定した(21組)。
- ② 図-3から、最終繰り返し時の経路上で学習データを選定した(9組)。
- ③ 図-4から、正方向に変位する経路上で学習データを選定した(49組)。

なお、各経路上では $1.0\sim2.0\text{mm}$ 程度の変位間隔でデータをサンプリングした。

(2) 学習とネットワークの収束状況

学習を開始する際、種々のパラメータ値を設定する必要がある。まず、学習速度を支配するシグモイド関数の形状パラメータ T 、及び学習制御パラメータ μ 、 ν の設定が重要である。一般に、 T の値が小さい時、ユニットの内部ポテンシャルの変化に対するシグモイド関数の応答が敏感になるため、 μ 及び ν を小さく設定することが多い。逆に、 T の値が大きい時は μ 及び ν を大きく設定することが多い。従って、(T , μ , ν)の組み合わせの最適値を求めるることは容易ではないが、ネットワークからの数値出力を直接扱う問題であれば、極端に小さくない値に T を固定し、 μ 及び ν の値に幅をもってパラメタスタディを行うのが有効である。本論文では、 $T=0.5$ に固定し、 $\mu=0.075\sim0.225$ (0.025間隔)、 $\nu=0.025\sim0.175$ (0.025間隔)の範囲内で49のパラメタスタディを行った。中間層ユニット数の自動調整に関連しては、収束基準 $\pm 5\%$ 以内、 $N_1=50$ 回、 $N_2=1,000$ 回、 $N_3=500$ 回、 $N_4=6,000$ 回とし、ネットワークの修正がほぼ収束するまで8,000回の学習を行った。ここで、全学習データに関する1通りの学習を1回の学習回と定義した。

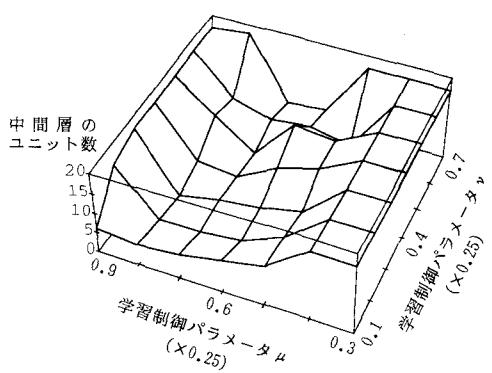
図-9に8,000回の学習が終了した時のネットワークの収束状況を示す。この図-9から、誤差が小さく、かつ、中間層ユニット数が少なくなるのは、 $T=0.5$ 、 $\mu=0.20$ 、 $\nu=0.05$ の時であることがわかる。このネットワークでは中間層が最終的に4ユニットになっており、平均的な誤差(誤差総和E)、局所的な誤差($(T_{pk}-O_{pk})$ の最大値)とも全49ケース中でほぼ最小になっている。図-10は、図-5の経路上から任意に3ケースのデータ(未学習データI~III)を選定し、学習終了時のネットワークに認識させた結果である。ここで、未学習データの認識率とは以下の定義に従う。

$$\text{未学習データの認識率} = \frac{\text{ニューラルネットワークの推定荷重値}}{\text{教師信号となる実験荷重値}} \quad \dots \dots \quad (14)$$

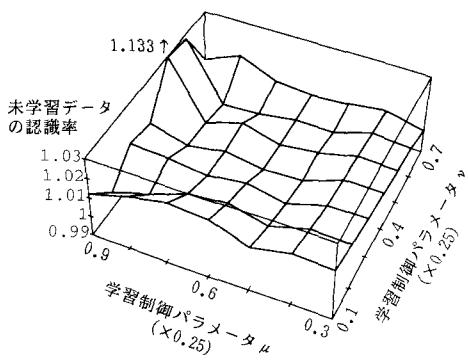
未学習データの認識率を示した図-10(a)~(c)とネットワークの誤差を示した図-9(b)及び(c)は分布形状がよく対応おり、収束精度及び学習効率の高いネットワークの方が一般化能力の面でもまさっていることが推察できる。先に述べた最も学習効率が高いネットワークに関して、図-11に学習回数とネットワークの収束状況の関係を示す。中間層ユニット数の自動調整アルゴリズムによってネットワークに適度な揺らぎが与えられ、6,000回の学習以降は、それまでで誤差を最小にした中間層ユニット数4を用いて学習を継続し、誤差総和Eの変化が小さくなるのを待って学習を終了している。本アルゴリズムは、中間層ユニット数を最適化する絶対的な方法ではないが、少なくとも試行錯誤を繰り返して中間層ユニット数を一定値に決定するよりは省力化の観点から有効であると考えられる。

(3) 学習経路の認識

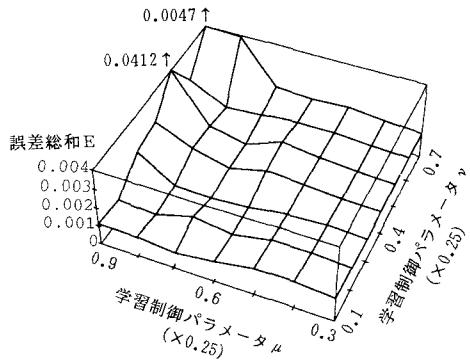
8,000回の学習後、最も学習効率が高いネットワーク($T=0.5$ 、 $\mu=0.20$ 、 $\nu=0.05$)を用いて図-4に示した経路を連続的に認識させ、荷重履歴の推定を行った。推定結果を図-12に示す。なお、以降の認識



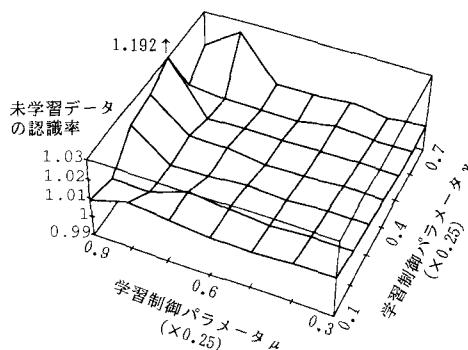
(a) 中間層のユニット数



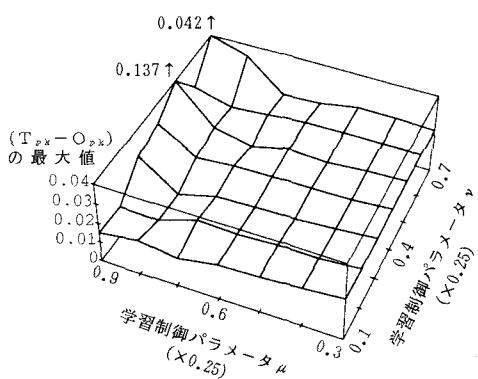
(a) 学習データ I



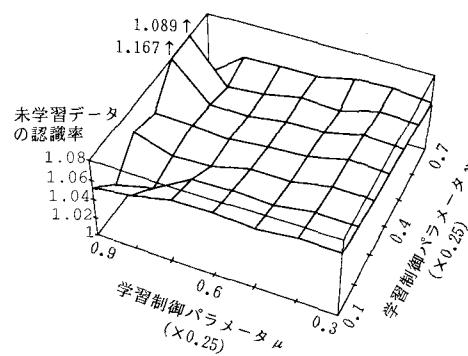
(b) 誤差総和 E



(b) 学習データ II



(c) $(T_{pk} - O_{pk})$ の最大値



(c) 学習データ III

図-9 8,000回の学習が終了した時のネットワークの収束状況

図-10 8,000回の学習が終了したネットワークによる未学習データの認識結果

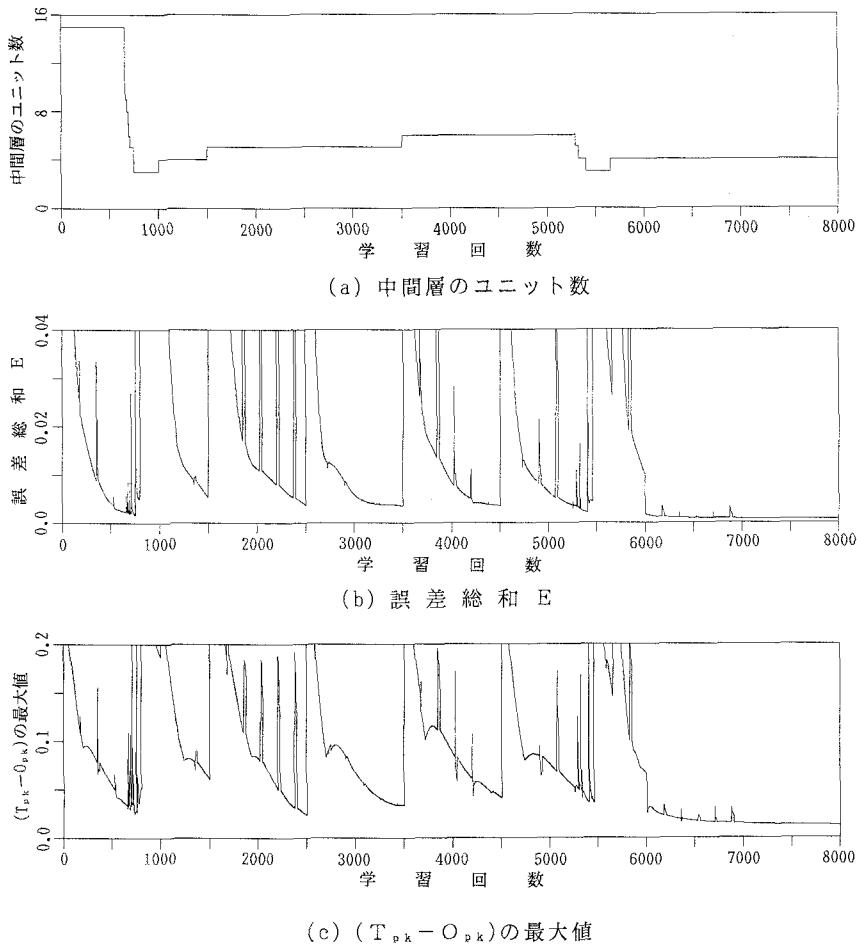


図-1-1 学習回数とネットワークの収束状況 ($T = 0.5$, $\mu = 0.20$, $\nu = 0.05$)

では、このネットワークを統一的に用いる。図-1-2は、荷重の予測値を更に先の予測に用いて認識を進めている。従って、ニューラルネットワークの入力データとして、変位は意図的に与えた変位履歴を、荷重は初期値を除いてニューラルネットワークで推定した値を用いている。学習データに関する認識結果より以下に示すことが確認された。

- ① ニューラルネットワークによる認識（推定）結果は、学習させた経路にはほぼ一致した。
- ② 荷重の予測値を更に先の予測に使用しても、認識（推定）結果に発散的な挙動が生じなかった。

(4) 未学習経路の認識

図-5に示した経路を連続的に認識させ、荷重履歴

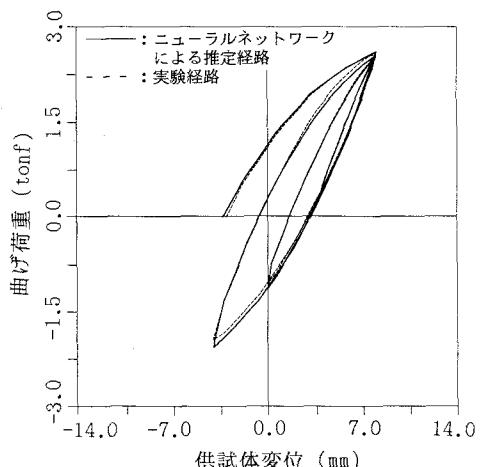


図-1-2 学習経路の認識結果

の推定を行った。推定結果を図-13に示す。最外郭ループ、及び、最外郭ループ上で変位方向を折り返した経路に関しては、ニューラルネットワークの推定値と実験値がよく対応している。一方、最外郭ループ内で変位方向を折り返した経路に関しては、ニューラルネットワークの推定値と実験値が明らかに異なっている。これは、学習させた経路（データ）のみでは支配的な履歴挙動を網羅できず、学習データに不足が生じた結果、推定経路の指向点に誤りがあったことに起因するものである。すなわち、最少限のデータを想定したため、学習データの中に最外郭ループ内で変位方向を折り返す経路が存在せず、従って、最外郭ループ上からの経路同様、推定経路が常に最大経験変位点を指向したために生じたものである。この事実は、構築したネットワークが学習データとして与えられた経路を高い精度で再現したことを如実に示すものであり、最外郭ループ内で変位方向を折り返す経路を学習データに追加すれば、ネットワークの推定精度を改善できるものと考えられる。なお、推定経路と実験経路の不一致箇所についてその差異に言及すれば、変位が図-8(b)に示すC点からB点にたどり着くまで、推定値と実験値がほぼ同一荷重のずれを生じている（推定経路が、実験経路にほぼ平行になっている）。このことは、ネットワークの出力値にこの差を解消する統一的な修正（補正）を加えることができれば、構築したネットワークの出力精度を改善できる可能性を示唆するものである。

（5）ニューラルネットワークの出力値の補正

学習データの不足による再現精度の低下は、データの追加によって容易に改善することができるが、ここでは、今回構築したネットワークを利用する方法を考える。すなわち、図-13の検討結果から、最外郭ループ内で変位方向を折り返した場合にのみ、推定荷重値に補正を加える方法を考える（図-14）。

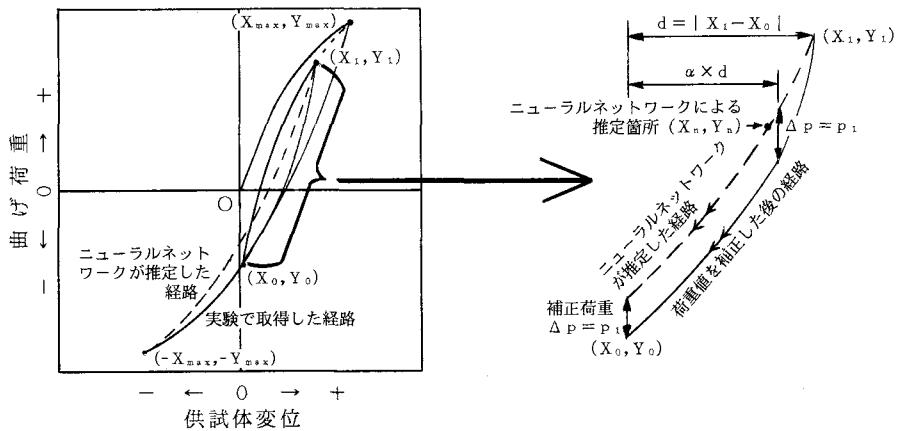


図-14 ニューラルネットワークが推定した荷重値の補正方法

ここで、次式に示す補正荷重値 Δp を定義する。

$$\Delta p = p_1 \times \frac{X_n}{(1-\alpha) d} ; \quad 0 < X_n < (1-\alpha) d \quad \dots \dots \dots \dots \quad (15)$$

$$\Delta p = p_1 \quad \dots \quad (1 - \alpha) d \leq x_n \leq d \quad \dots \dots \dots \dots \quad (16)$$

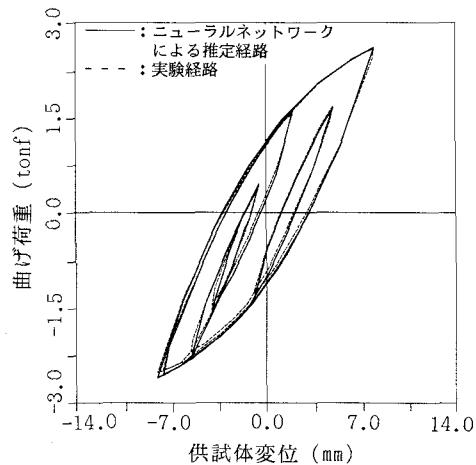


図-15 荷重補正を施したネットワークによる未学習経路の認識結果

5.まとめ

本論文では、一端固定中空円筒梁の繰り返し曲げ実験を例に、実験履歴挙動のモデリングにニューラルネットワークを適用し、未学習経路の認識に活用するとともに、ネットワークの構築過程を考察した。得られた成果を以下に要約する。

- ① 中間層のユニット数やネットワークの初期値設定に関して決定根拠を明らかにし、収束精度と学習効率の高いネットワークを構築する一般的手法を示した。
 - ② 履歴特性実験で取得できる最少限のデータを想定し、最適化された中間層ユニット数で最外郭ループ上からの経路データを学習させたところ、大多数の場合において学習後のネットワークは高い精度で実験経路を再現することができた。
 - ③ 再現精度の低下は、最外郭ループ内で変位方向を折り返した場合のみに見られ、小さめの荷重値を推定した。これは、学習させたデータのみでは支配的な履歴挙動を網羅できず、学習データの不足が生じたことに起因するものである。対応策としては、学習データを追加することが最も簡易であるが、今回構築したネットワークを用いても最外郭ループ内で変位方向を折り返す際の統一的な補正方法を導入すれば、再現精度を保持できることを確認した。

今回の実験履歴挙動は、繰り返し曲げに伴う荷重低下が生じない安定した履歴ループを描くもので、確認した履歴モデリングの有効性はその範囲内に限られる。しかしながら、数少ない実験結果（学習データ）から再現性の高いネットワークが構築できたことは、モデリングの省力化と精度向上に有効であり、今後、より複雑な履歴モデリングを開発する基礎になるものと考えられる。

6. あとがき

ニューラルネットワークは、学際的研究として種々の学問分野で応用が進められている。しかしながら、概してネットワークの構築過程が示されないため、ネットワークが開発者以外にはブラックボックスとなり、信頼性が懸念されることが多かった。内挿型問題に関して有効性が論じられる今日、ネットワークの学習データ及び未学習データの認識を通して妥当性の検証を行うのみではなく、ネットワークの開発過程を明らかにすることが更に信頼性を向上させる手段になるものと考えられる。構造解析分野における適用問題は、ネットワークが出力する数値を直接用いるため、ネットワークの構築過程をガラスボックスにして、その根拠を示すことが特に重要である。

なお、本論文は、エンジニアリング・ワークステーション（公称処理性能：28.5MIPS、4.2MFLOPS）上で構築したニューロ・シミュレータを用いて100時間以上に及ぶ計算を行った結果に基づくことを付記する。

参考文献

- 1) Rehak, D. R., Thewalt, C. R. and Doo, L. B. : " Neural Network Approaches in Structural Mechanics Computations ", Proc. of Structures Congress, pp. 168-176, San Francisco, 1989
- 2) Troudet, T. and Merrill, W. : " A Real Time Neural Net Estimator of Fatigue Life ", Proc. of International Joint Conference on Neural Networks, IEEE and INNS, Vol. 2, pp. 59-64, San Diego, 1990
- 3) Ghaboussi, J., Garrett Jr., J. H. and Wu, X. : " Knowledge-Based Modeling of Material Behavior with Neural Networks ", Jour. of Eng. Mech. Div., ASCE, Vol. 117, No. 1, pp. 132-153, 1991. 1
- 4) 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
- 5) 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り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U92020, 1992. 9
- 6) Rumelhart, D. E., McClelland, J. L. and the PDP Research Group : " Parallel Distributed Processing, Volume 1: Foundations ", MIT Press, pp. 318-362, 1986
- 7) Rumelhart, D. E., Hinton, G. E. and Williams, R. J. : " Learning Representations by Back-Propagating Errors ", Nature, Vol. 323, No. 9, pp. 533-536, 1986. 9
- 8) 舟橋賢一：“ニューラル・ネットワークのcapabilityについて”，電子情報通信学会技術研究報告，MBE88-52, 1988. 7
- 9) 貢 棋, 戸田尚宏, 白井支朗：“ニューラルネットワークにおける逆伝搬学習アルゴリズムの初期値設定に関する考察”，電子情報通信学会論文誌 D-II, Vol. J73-D-II, No. 8, pp. 1179-1185, 1990. 8
- 10) 松永 豊, 中出美彰, 山川 修, 村瀬一之：“階層型ニューラルネットワークの中間層素子を自動削減する誤差逆伝搬学習アルゴリズム”，電子情報通信学会論文誌 D-II, Vol. J74-D-II, No. 8, pp. 1118-1121, 1991. 8
- 11) 萩原将文：“淘汰機能を有するバックプロパゲーション，学習回数の低減と中間層ユニットの削減法”，電子情報通信学会論文誌 D-II, Vol. J74-D-II, No. 6, pp. 812-818, 1991. 6
- 12) Ramberg, W. and Osgood, W. R. : " Description of Stress-Strain Curves by Three Parameters ", NACA, Technical Note, No. 902, 1943. 7

- 13) Jennings, P. C. : " Periodic Response of a General Yielding Structure" , Jour. of Eng. Mech. Div., ASCE, Vol. 90, EM2, pp. 131-166, 1964. 4

(1992年9月21日受付)