

(財)電力中央研究所 正会員 山本広祐

1. まえがき 近年、Rumelhartらにより開発された階層型ニューラルネットワーク¹⁾が、土木・建築・機械材料あるいは構造要素の履歴モデリングに活用されている。例えば、ニューラルネットワークに履歴経路を直接認識させた事例^{2)~4)}、既往の数学モデルを設定する際のパラメータ同定に活用した事例⁵⁾がその代表であり、また、動的システムの同定や材料設計への応用などもこの範疇に含めることができる。著者はこれまでに、鋼製の構造要素の履歴復元力特性をニューラルネットワークで直接モデリングし、数値解析に応用する手法を検討してきた⁶⁾。本報では、履歴復元力特性のモデル化に関するニューラルネットワークの適用対象を多様化させるため、過渡的な地震応答に耐えうる数学モデルの構築を目指した検討を行った。

2. ニューラルネットワークの認識対象 一端固定梁の曲げ実験から得られた履歴復元力特性を既往の数学モデルにフィッティングする際のパラメータ同定にニューラルネットワークを適用する。この実験では、ステンレスSUS304製の中空円筒供試体（高さ850mm、外径204mm、板厚2mm）を用いた。供試体の両端には、中空円筒に比べて極端に剛性の高いフランジを取り付け、下端を剛に固定し、上端のピン支持点に強制的な水平変位経路を負荷した。典型的な実験結果として、図-1に変位振幅を段階的に増大させた漸増載荷実験結果を、図-2に単調載荷実験結果を示す。ここで、供試体変位とは上下フランジ間の相対水平変位をさす。なお、別途、構築したネットワークを検証するため、過渡的な変位経路に関する実験を実施した。

3. 使用した階層型ニューラルネットワークの概要 誤差逆伝播学習¹⁾による階層型ニューラルネットワークを用いた。入・出力層を含めて3層以上の構造とし、中間層の出力にシグモイド関数を、出力層に線形関数を用いれば任意の連続写像関数を構築できることが既に知られているため、本報では3層構造を用い、中間層のユニット数は試行錯誤的な数値実験により決定した。学習には逐次型のモーメント法を用いた。

4. 同定数学モデルの設定と学習データの選定 実験結果が滑らかな筋錐型の履歴曲線を示したことから、Ramberg-Osgoodモデルでフィッティングすることにした。この履歴モデルでは、骨格曲線を式(1)で、履歴曲線を(2)で表わすことができ、一般には $x_0 = x_1$ 、 $p_0 = p_1$ 、 $\alpha_0 = \alpha_1$ 、 $\gamma_0 = \gamma_1$ として用いることが多い。

$$\frac{x}{x_0} = \frac{p}{p_0} \left(1 + \alpha_0 \left| \frac{p}{p_0} \right|^{-\gamma_0^{-1}} \right) \quad \dots (1) \quad \frac{x - x_1}{2x_1} = \frac{p - p_1}{2p_1} \left(1 + \alpha_1 \left| \frac{p - p_1}{2p_1} \right|^{\gamma_1^{-1}} \right) \quad \dots (2)$$

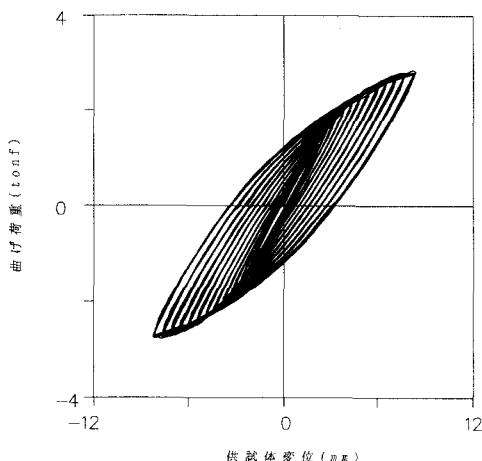


図-1 定常繰り返し曲げ実験結果

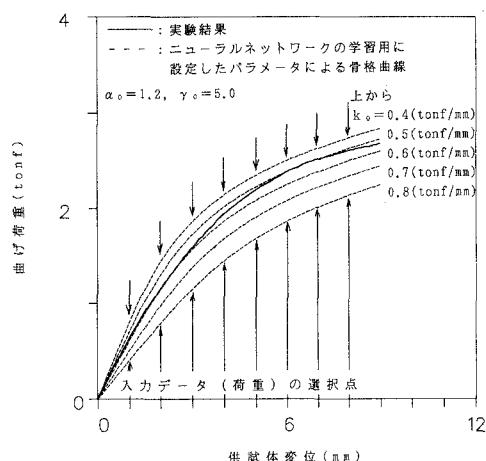


図-2 学習データの選択方法

ここで、 x は変位、 p は荷重、 (x_i, p_i) は履歴曲線の折り返し点、 $(x_0, p_0, \alpha_0, \gamma_0)$ と $(x_1, p_1, \alpha_1, \gamma_1)$ が式(1)及び式(2)を決定するパラメータとなる。 p_0/x_0 は式(1)の骨格曲線の初期剛性 k_0 を、 p_1/x_1 は式(2)の履歴曲線の除荷剛性 k_1 を表わす。なお、式(1)の p_0 と α_0 、式(2)の p_1 と α_1 の関係に着目すると、 k_0 と γ_0 または k_1 と γ_1 が一定の条件で外見は異なるが、結果的に等価な式になる(p_0, α_0)または(p_1, α_1)の組み合わせが多数存在する。従って、便宜上、どちらか一方の値を固定すればパラメータを3つに減じることができる。式(1)の同定では、図-2に示した単調載荷実験における最大荷重(=2.66tonf)を p_0 に設定し、 $(k_0, \alpha_0, \gamma_0)$ を同定パラメータとしてニューラルネットワークの出力層に割り当てた。入力層には、図-2に示す、 $x=1\text{~mm}$ で1mm間隔の荷重値 p を8ユニットに割り当てた。学習データは、 $k_0=0.4\sim0.8\text{tonf/mm}$ 、 $\alpha_0=0.4\sim2.0$ 、 $\gamma_0=3\sim7$ の範囲で各パラメータにつき5データの総計125組を選定した。一方、式(2)の同定では、① $k_1=k_0$ 、 $\alpha_1=\alpha_0$ 、 $\gamma_1=\gamma_0$ とする方法、② $\alpha_1=\alpha_0$ 、 $\gamma_1=\gamma_0$ とし、 k_1 のみ同定する方法、③骨格曲線と同様に $(k_1, \alpha_1, \gamma_1)$ をニューラルネットワークで同定する方法の3つが考えられる。なお、③の場合、同一の認識対象でも最大経験変位に応じた各パラメータ値の変化もたらえる可能性があるため、ニューラルネットワークが複雑・大規模化することが考えられる。

5. 同定結果の活用と考察 一例として、中間層を20ユニットとし、全125組の学習データを4,000回学習させた結果を示す。まず、図-2に実線で示した骨格曲線を同定した結果、 $k_0=0.646\text{tonf/mm}$ 、 $\alpha_0=1.01$ 、 $\gamma_0=4.92$ となり、この値を用いて過渡的な変位経路に関する荷重経路の推定を行った。図-3は既述の式(2)の同定法①($k_1=k_0$)を、図-4は同定法②($k_1 \neq k_0$ 、 $k_1=0.85k_0$)を用いたものであり、特に後者は最外郭の履歴曲線の内側でやや接線勾配の変化が乏しい、やせ気味の筋錐形状になっているが、文献4)に示した直接同定と大差のない結果が得られ、実用上問題のないことが考察された。

参考文献

- 1) Rumelhart,D.E., et al. : "Learning Representations by Back-propagating Errors", Nature, Vol.323, pp.533-536, 1986.10
- 2) Ghaboussi,J., et al. : "Knowledge-Based Modeling of Material Behavior with Neural Networks", Jour. of Eng. Mech., ASCE, Vol.117, No.1, pp.132-153, 1991.1
- 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1992年度研究発表会，研究報告集〈構造系〉，pp.9-12, 1993.2
- 4) 山本広祐他："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
- 5) 吉村忍他："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

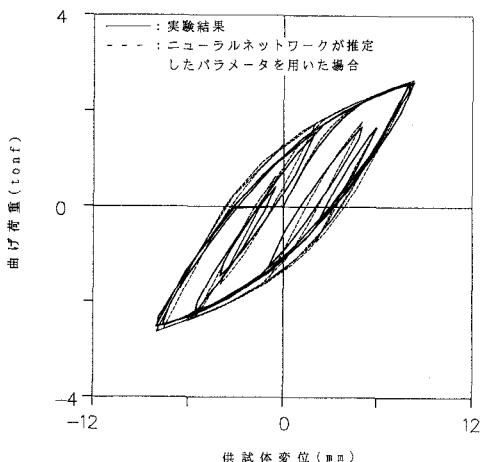


図-3 ニューラルネットワークによる結果と実験結果の比較 ($k_1 = k_0$)

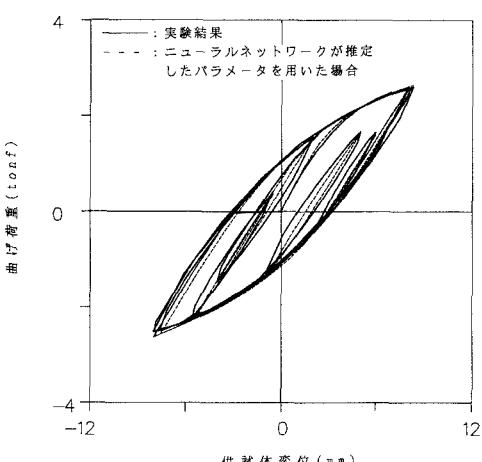


図-4 ニューラルネットワークによる結果と実験結果の比較 ($k_1 \neq k_0$)