

京都大学大学院 学生員 ○坂平佳久
 京都大学工学部 正員 杉浦邦征

京都大学工学部 正員 渡邊英一
 京都大学工学部 正員 宇都宮智明

1.はじめに

過大な繰返し荷重を受ける構造物の安全性、経済性、合理性を追求するために、構造物の種々の終局境界状態を正しく評価する必要がある。そのため、簡易で、精度の高い構造物および材料のモデリング手法の構築が望まれている。特に、非弾性解析の精度は用いる構成方程式と材料パラメータに大きく左右されるため、金属材料の非弾性特性および塑性力学モデルのパラメータを合理的に決定する手法を確立する必要がある。ここでは「ニューラルネットワーク」を用いて行い、弾塑性の分類・評価により一般的な弾塑性構成則の確立に役立てる。本研究では、弾完全塑性型、バイリニア型などをベースとしたモデルに対し、ニューラルネットワークの適用性を検討する。ここでは、弾性係数、降伏応力、塑性二次勾配、等方硬化、移動硬化等の材料特性について検討する。

2.ニューラルネットワークへの適用

ニューラルネットワークとは、人間の脳をモデル化した情報処理システムで、ある数値を複数入力しある数値を複数出力させる演算ユニットと考えられる。またこの演算ユニットの特性は図1に示すニューロン(○印)を結ぶ結合荷重によって特徴づけられる。この結合荷重を決定するのがニューラルネットワークにおける「学習」で、一般にバックプロパゲーション法が用いられる。また図2に各ニューロンの演算式を示す。このニューラルネットワークには次のような特徴が挙げられる。

- (1) 離散的な入出力関係を学習させるだけで非線型性の強い写像をネットワーク内の結合係数として構築できる。
- (2) 学習パターンを滑らかに内挿し、未学習の入力に対しても工学上妥当な値を出力できる。
- (3) いったん学習が終了してしまえば、積和演算を行うだけで出力が得られる。

本研究では、以上のようなニューラルネットワークの学習・推定能力と、計算力学の有する定量的な評価性能に着目し、両者を融合して、種々の材料の変形挙動から非弾性構成方程式の材料パラメータを予測することを試みる。

一般に種々の材料挙動をニューラルネットワークを用いて解析する場合、次の2通りの方法がある。1つは、材料挙動のグラフをそのまま「図形認識」という形で学習させて解析する方法である。この方法は、実験データ等の非線形関係を数学的に定式化することなく、ニューラルネットワークによる学習を用いて直接その近似関数を構築するものである。この方法ではひずみの値をインプットデータとし、応力の値をアウトプットデータとしているので材料パラメータを予測させることはできない。もう1つは、材料挙動に関する離散的なサンプルデータインプットデータとし材料パラメータをアウトプットデータとしてネットワークに学習させて解析する方法である。

本研究では、「パラメータ同定」を主とする後者の方法を対象とする。

3.SS400材における材料パラメータ同定

ここでは、一般構造用鋼材であるSS400材の単調裁荷引張試験から得られる応力-ひずみ曲線をもとに弾性係数、降伏応力、硬化開始点ひずみ、塑性係数の同定を試みる。したがって、図3に示すようなトライリニア型の応力-ひずみ曲線を設定した。




図1 本研究で用いたニューラルネットワーク




図2 各ニューロンの演算式

入力パターンの設定は学習過程における評価関数の値の収束状況を決める重要な要因である。したがって、教師データ（ここではヤング率 E 、降伏応力 σ_y 、硬化開始点ひずみ ϵ_{sh} 、塑性2次勾配 EP ）間では、明確な違いがあるよう入力パターンを設定した。本シミュレーションでは、あらかじめ、ひずみ ϵ の値(%)を設定しておき、それに対する個々の応力 σ の値を入力データとした。抽出したひずみ ϵ の値を以下に示す。

$\epsilon=0, 0.03, 0.06, 0.09, 0.12, 0.15, 0.18, 0.21, 0.24, 0.25, 0.5, 0.75, 1.0, 1.25, 1.5, 1.75, 2.0, 2.25, 2.5, 2.75, 3.0$

ひずみ ϵ の値を等間隔で設定しない理由は、ヤング率の値と、塑性2次勾配の値には非常に大きな違いがあるので、ヤング率の変化や塑性2次勾配の変化にあわせて反応する入力層の数字の列を作成するためである。

学習データの個数は、ここでは、

ヤング率の値を $(2.52, 2.10, 1.68) \times 10^6$ [kgf/cm²] の3種類

降伏応力の値を $(40, 30, 20) \times 10^2$ [kgf/cm²] の3種類

塑性2次勾配の値を $(5.0, 4.0, 3.0, 2.0) \times 10^4$ [kgf/cm²] の4種類

硬化開始点ひずみの値を $(2.5, 2.0, 1.5, 1.0)$ [%] の4種類

を採用し、合計 $3 \times 3 \times 4 \times 4$ の144種類に対する入力データを学習データとして作成した。また、中間層のニューロンの数によって学習の収束状況や、未学習データに対してどのような影響を及ぼすかを調べるため、本シミュレーションでは、21、30、40、50、の4種類で試行錯誤的に望ましい値を定めた。中間層のニューロン数と予測精度の関係には、なんら法則性はないが、予測精度を上げるためには中間層のニューロン数を適切に設定する必要があると考えられる。

図4に中間層のニューロン数と、予測誤差の関係（最小自乗法による結果を正解とした）を、図5,6にそれぞれ予測した材料パラメータから求められる図3に示す応力-ひずみ関係を実験値と比較した結果を示す。

また、図5の結果が、図6の結果と比べて予測誤差が大きいのは実験値の応力-ひずみ形状が塑性域で不安定で設定したモデルとはかなりかけ離れていたためと思われる。




図5 3.3mm厚試験片での実験値との比較




図6 6.0mm厚試験片での実験値との比較

4. 結論

- 1) ニューラルネットワークによってSS400材の材料パラメータ同定が可能であることが分かった。ただし、 EP の推定は他のパラメータと比べ予測精度が低い。
- 2) ニューラルネットワークの学習過程における評価関数値や、予測精度は、学習データの個数、中間層の数、入力パターンなどによって、変化してくるので、それらを適切に決定する手法を確立する必要がある。

繰り返し荷重を受けるSUS304材の材料パラメータ同定結果は講演当日報告する。