

深層学習による有限要素解析の代替手法に関する基礎的検討

茨城大学 学生会員 ○真保 琢海
茨城大学 正会員 車谷 麻緒

1. はじめに

有限要素解析は、現在構造解析で最も用いられている解析方法であり、線形解析だけでなく非線形解析も適用できることから広範囲で利用されている。しかし、有限要素解析は、解析を行う人の技量によって解析結果に差が生じることや、解析モデル作成までの手間や時間がかかることなどの問題がある。このような背景から、深層学習を用いた代替手法を考える。深層学習は機械学習の一種であり、大量の学習データからそのデータ群の特徴を抽出し、モデルに記憶させることで学習結果を得ることができる。しかし、高い精度での学習結果を得るには質の高い学習データを大量に用意しなければならないという課題がある。

既往の研究として、全らりは鋼構造物について、有限要素法を用いることで学習データ作成を行い、深層学習を行って座屈耐荷力を予測した。この研究では実験の代わりに有限要素解析を利用してデータを作成し、深層学習を行っているが、本研究では有限要素法そのものの深層学習での再現性に着目し、線形解析と非線形解析の深層学習での再現性を検討する。今回は基本的な構造解析の例として、円孔を有する構造物を解析モデルに選定し、有限要素解析を行う。これにより作成された学習データで学習を行い、学習結果を FEM 結果と比較することで、その再現性について検討することを本研究の目的とする。

2. 提案手法

深層学習の概要図を図-1 に示す。図のように、深層学習のモデルでは入出力値および中間ユニットを層状に配置し学習を行い、最終的な出力結果を得る。深層学習のモデルにはいくつか種類があり、基本となる多層パーセプトロン (MLP)、画像解析に適した畳み込みニューラルネットワーク (CNN)、言語の解析に適した再起型ニューラルネットワーク (RNN) などがあるが、本研究では多層パーセプトロン (以後 MLP とする) のみを用いて学習を行った。MLP では、前の層のそれぞれ




図-1 深層学習の概要




図-2 解析対象物の条件

の x の値を元に y (次の層の x) の値が決定する。この作業を各層、各要素で繰り返すことで最終的な出力値を求め、あらかじめ用意された正解値と比較し、その誤差が小さくなるようそれぞれの要素の影響度を表す重み w で偏微分することにより学習モデルを更新する。これを一連の学習として何度も誤差を修正することで正解に近い値を出力する学習モデルが作成される。

3. 検証例題

3.1 有限要素モデル

本研究では、正方形構造物に任意の位置に円孔を与え、垂直方向に強制変位を作用させた条件で有限要素解析を行った。構造物形状および拘束条件を図-2 に示す。材料条件として、構造物のヤング率を 10000 MPa、ポアソン比を 0.3 とした。本研究では解析条件として、この正方形構造物を縦横に 50 分割し、計 2500 個の正方形要素にメッシュ分割をして有限要素解析を行った。

3.2 学習方法

本研究では、入力値を円孔の中心位置座標 (x, y) のみ

キーワード 機械学習 教師あり学習 深層学習 多層パーセプトロン 有限要素法

連絡先 〒316-8511 茨城県日立市中成沢町 4-12-1 茨城大学工学部 TEL : 0294-38-5151 FAX : 029-38-5268




図-3 線形解析 (von-Mises 応力) と学習結果

とし、学習データの種類については、有限要素解析の結果の内、線形解析によって求めた von-Mises 応力、非線形解析により求めた相当塑性ひずみと von-Mises 応力を用意して学習を行った。学習データ数について、線形解析ではそれぞれ 1000 個、5000 個、10000 個の学習データを用意し、非線形解析 (相当塑性ひずみ, von-Mises 応力) ではそれぞれ 10000 個の学習データを用意して学習を行った。

4. 学習結果

学習の精度を確かめるために、学習に用いていない入力値として、線形解析では構造物の中央、非線形解析では中央に加え、対称性を考慮して中央から左、上、左上の円孔位置を学習モデルに入力し、学習結果の精度を確かめた。

まず、図-3 に、線形解析 (von-Mises 応力) で学習させた学習結果と FEM 結果の比較を示す。学習データが 1000 個のとき、精度はあまり高くなく円孔の周囲など応力が集中している領域の再現度も低くなっているが、学習データ数が 5000、10000 と増えるにつれて精度の低い領域が少なくなっていく、応力やひずみが集中している領域の再現度も高くなっている。

次に、図-4、図-5 に非線形解析による学習として von-Mises 応力及び相当塑性ひずみの学習結果と非線形 FEM 結果を示す。どちらの学習結果も非線形 FEM 結果の分布の傾向を捉えたような結果を得ることができた。しかし、相当塑性ひずみでの学習結果において、ひずみの値が大きくなっている領域の再現度が低くなった。これは、図-5 における非線形 FEM の結果からわかるとおり、相当塑性ひずみの分布は 0 である領域が広く、平坦な分布の多い学習データで学習を行ったため、大きな値が集中している領域に対応できなかったと考えられる。




図-4 非線形解析 (von-Mises 応力) の精度の比較




図-5 非線形解析 (相当塑性ひずみ) の精度の比較

このように、人間が解析を行うと手間や時間がかかる非線形 FEM 結果でも、深層学習では線形 FEM 結果と同じように正解に近い出力結果を示すことができることを示した。

5. おわりに

円孔を有する構造物の問題を対象に、深層学習を用いて構造解析の結果の再現性を検討した。線形解析との結果の比較では学習データ数の増加による精度の向上を示すことができ、非線形 FEM 結果による学習についても、相当塑性ひずみ, von-Mises 応力ともに高い精度での結果を示すことができた。今後の方針として、精度向上のための、学習モデルの改良を行うことを考える。

参考文献

- 1) 全邦釘, 秋山大誠, 真鍋祐輔: ニューラルネットワークを用いた腐食鋼板の座屈耐荷力推定, 土木学会論文集 A2 (応用力学), Vol. 71, No. 2 (応用力学論文集 Vol. 18), I_39-I_47, 2015.