

30. 構造設計へのAIの適用に関する研究 最適な鋼材断面の選定

1710920060 白木悠輔
指導教員 藤井大地 教授

AI ニューラルネットワーク ラーメン構造 H形鋼

1. はじめに

近年、AI（人工知能）に関する技術を様々な分野へ応用する動きが活発となっている。そこで本研究では、構造設計においてAIの活用ができないかを考え、その基礎的な研究を行う。構造設計をするにあたって、軸力やせん断力の算定に始まり、許容応力度の求値までを行い、それらの条件から判断して梁や柱など各部材の材料を選定する作業は避けて通れない。本研究では、複数のパラメータから目標とする値を予測する重回帰分析を基本として、ラーメン構造における梁の材料選定をAIに予測させるアルゴリズムを作成する。また、ここで3層ニューラルネットワークの構造を用い、中間層の数や活性化関数を変えながら各学習モデルの比較と解析結果の報告、学習精度の差に対する考察を行う。

2. 学習データの作成

本研究では、研究室で開発中の平面骨組の最適設計プログラムを用いて、学習データを生成した。本プログラムはExcelVBAで作成し、骨組解析を繰り返すことで、鋼材の規格断面表から応力度比 σ_{max}/f が1を超えない最小の断面を自動探査するものである。学習データに使用する鋼材はSS400のH形鋼（中幅）とした。




図1 学習データに用いるラーメン構造

学習データで扱う説明変数（入力信号）は、梁のスパン l と等分布荷重 w の2変数とし、 l は4000mmから12000mmの範囲で500mmずつ変化させた値を、等分布荷重 w は20kN/mから80kN/mの範囲で4kN/mずつ変化させた値を用いる。また、目的変数（出力信号）をH形鋼の断面寸法 A としたもの、H形鋼の断面積ごとに番号 N を振ったものの2種類で学習データを分ける。以上の条

件で説明変数と目的変数を設定し、これを272組用意したものを学習データとして使用する。

表1 目的変数を断面積とした学習データの一部

l (mm)	w (kN/m)	A (mm ²)
4000	20	194×150
4000	40	244×175
4000	80	294×200
5000	20	194×150
5000	40	244×175
5000	80	298×201
6000	20	244×175
6000	40	294×200
6000	80	386×299

表2 目的変数を番号とした学習データの一部

l (mm)	w (kN/m)	N
4000	20	0
4000	40	1
4000	80	2
5000	20	0
5000	40	1
5000	80	3
6000	20	1
6000	40	2
6000	80	6

3. 学習モデルの比較

本研究では、3層ニューラルネットワークのアルゴリズムを基本として学習モデルを作成する。ここで、各学習モデルの比較のため、入力層の活性化関数と中間層の数を変えて表1、2の学習データを入力する。使用する活性化関数は、ニューラルネットワークにおいて一般的に用いられるシグモイド関数、またはReLU関数とし、中間層を1つ、2つ、3つの場合でそれぞれ検討していく。また、出力層の活性化関数は全てソフトマックス関数とする。最初にエポック数（学習回数）を1000で試行し、

正解率が最も高くなった 200 前後で学習モデルの精度に関する考察を行う。




図2 表1を用いたモデルの正解率の推移




図3 表2を用いたモデルの正解率の推移

結果として、ReLU 関数を活性化関数として利用し、中間層1つの条件下で表2の学習データを用いたモデルが、正解率88.9%の最も高い精度を記録した。これに対し、表1の学習データを用いたモデルは、全体的に低い正解率となった。

表3 表1を用いたモデルの条件と正解率

活性化関数	中間層の数	正解率(%)
シグモイド	1	32.2
シグモイド	2	37.5
シグモイド	3	31.4
ReLU	1	28.2
ReLU	2	28.0
ReLU	3	35.0

表4 表2を用いた学習モデルの条件と正解率

活性化関数	中間層の数	正解率(%)
シグモイド	1	72.0
シグモイド	2	79.3
シグモイド	3	66.3
ReLU	1	88.9
ReLU	2	81.4
ReLU	3	81.7

4. 精度の差に関する考察

まず、活性化関数を変えても学習精度が変化しない原因として、各活性化関数の性質と、本研究で扱った学習データとの相性によるものだと考える。シグモイド関数は最小値から最大値までを0から1の間に収める変換を行うのに対し、ReLU関数は負の値を全て0に、正の値は変換せずにそのまま出力する関数である。今回使用した学習データは全て正の値であるため、どちらの関数であっても大きな影響が出なかったと考えられる。

次に、説明変数と目的変数の相関関係が学習に影響していると考え、これについて調査した。その結果、表1の学習データにおける相関関係が、 l と A は0.52、 w と A は0.35と、弱い相関であったのに対し、表2については、 l と N が0.8、 w と N が0.48と、比較的強い相関が見られた。また表3、4から見られるように、表2の学習データの方が高い正解率を出していることから、パラメータ同士の相関が高いほど出力結果の精度が高くなりやすく、相関が低いほど精度が低くなりやすいと考えられる。このため学習データを整形する前に、説明変数と目的変数の相関関係について調査しておく必要があると考える。

最後に、中間層の数が学習モデルの精度に及ぼす影響は、表3、4から見られるように、中間層が多ければ正解率が高くなるなどの関係は見られない。つまり、それぞれの学習モデル、学習データに応じて最適な中間層の数が存在すると考えられ、この点については、試行を繰り返しながら人間の手で設定する必要があると考える。

5. まとめ

本研究では、3層のニューラルネットワークを用い、ラーメン構造における梁に対して最適な鋼材断面を選定するアルゴリズムを作成し、どの程度正確な予測ができるかを調査した。作成したアルゴリズムは、結果として272組という一般的には少ない数の学習データから、中間層を1つ、活性化関数をReLU関数とし、鋼材の断面積を番号に変換したデータを用いることで88.9%の正解率を出したことから、データの数よりも学習の条件が重要だと考えた。多くの制限、条件下でAIによる学習、予測を試行してきたが、ディープラーニングを用いることで中間層の数を自動で決定し、人間が行うべき作業が省略されるのではないかと考えられる。

参考文献

- 1) 斎藤康毅『ゼロから作る Deep Learning ~Python で学ぶディープラーニングの理論と実装~』株式会社オライリージャパン、2016年、pp.1-164
- 2) Prateek Joshi『Python による AI プログラミング入門 ~ディープラーニングを始める前に身につけておくべき15の基礎技術~』株式会社オライリージャパン、2019年、pp.1-108