

32. 構造設計へのAIの適用に関する基礎的研究
—実際の設計を学習に用いた場合の検討—

1710920107 吉井彪流
指導教員 藤井大地 教授

AI, 人工知能, 機械学習, ニューラルネットワーク, RC柱

1. はじめに

近年, AI (人工知能) 技術が発達し, 様々な分野に応用されつつある. 建築分野においても, スーパーゼネコンや中堅の大手ゼネコンが AI を活用したシステムの開発を進めている. そこで本研究では, 建築構造設計にこのような AI 技術を活用できないかと考え, その基礎研究を行う. 設計職の方々が, 建築構造設計において, 最も経験やノウハウが必要とするのは, 初期断面の設定である. そこで, 本研究では, 設計資料を使用し, AI 技術によってどの程度有効な初期断面を予測できるのかを, 最もシンプルな3層のニューラルネットワークを用いて調査を行う. 本研究で使用する学習データとテストデータは, 有限会社広島技術センターにご協力いただき, RC造の集合住宅の設計資料を用いて作成する. 入力層を4つに設定し, 建物の階数, 1階柱の負担面積と負担荷重, Fc値を入力層に, 1階柱の断面積を出力層に設定し, 柱の断面積を予測するAIを考える. そして, シンプルなAIで, どの程度正確な柱の断面積を予測することができるかを調査したので報告する.

2. 学習データの作成

設計資料から建物の階数, 1階柱の負担するスラブの総面積と総荷重, Fc(圧縮強度), 1階柱の断面積の値を63の図面から465組集めた. これらのデータをもとに, 今回は集合住宅の1階柱の初期断面の予測を行う.




図1 1階柱の負担するスラブ面積の考え方

検討1では, 465組からランダムに5組をテストデータに用いる場合, 検討2では, 63の建物の図面から1つの建物をテストデータに用いる場合とし, 予測精度を調査する. 検討2でのテストデータはFcが36N/mm² (5組)と33N/mm² (4組)の2通りの検討を行う.

作成したプログラムでは, 学習データの数値を0から1の間に設定する必要があるため, 建物の階数とFc値には10⁻²を, 総負担面積には10⁻⁴を, 総負担荷重には10⁻⁵を乗じる. 桁数が多いと単純なAIでは上手く学習できないため, 小数点以下4桁までとする.

3. パラメータの設定

今回のニューラルネットワークではパラメータとして, 隠れ層のノード数 (hnodes: hidden nodes) と学習率 (lr: learning rate), エポック数 (epoch) を設定する. 最適なパラメータを見つけるために, 学習データで訓練させた後, テストデータの正答率を調査し, パラメータを検討する. 各パラメータの検討毎に, 予測精度の平均値と最小値 (最悪値) の算出を3回行い, その平均値と最小値を比較して, 検討を行った.

3.1 検討1の場合

まず, 検討1の最適なパラメータを見つける. 初めに適当な学習率とエポック数を与え, ノード数(1~100)を検討する. ノード数の検討結果を図2に示す. 正答率が安定したグラフは得られなかったが, 今回は最小値と平均値の結果で検討しているため, 正答率が高く, 安定している3, 12, 18を最適なノード数の候補とする.

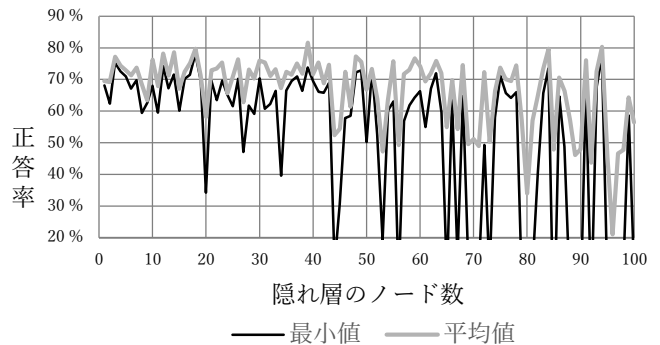


図2 隠れ層のノード数の検討

次に学習率(0.01~10)とエポック数(1~50)を検討する. ノード数18の学習率0.45から1.0の範囲が高い正答率で安定していた. したがって今回は最も正答率の高い0.60を最適な学習率とする(図3). 図3に示すグラフより, 正答率が最も高い10を最適なエポック数とする. 今回はノード数18で検討した学習率とエポック数をもとに, 再度ノード数を検討する.




図3 lr=0.60の検討結果

再度、ノード数を検討した結果を図4に示す。ノード数が20から37の範囲で精度が高く安定している。したがって、各ノード数の最小値と平均値の考慮し、35を最適なノード数とする。




図4 隠れノード数の再検討

3.2 検討2の場合

同様に、検討2の場合のパラメータの検討を行った。結果、Fc36の場合では hnodes=15, lr=0.75, epoch=12が最適であると判断した。また、検討方法2のFc33の場合では、hnodes=28, lr=0.85, epoch=4が最適なパラメータであると判断した。

4. 解析結果

設計資料から465組からテスト用のデータを4組または5組作成し、検討対象ごとにテストを行った。検討1の解析結果を表1に、検討2のFc36の解析結果を表2に、検討2のFc33の解析結果を表3に示す。検討1では正答率にばらつきがあるが、約80%以上で予測している。また、検討2では2つの解析例で正答率が90%以上で予測ができています。

表1 検討1の解析結果

階数	負担面積 (㎡)	負担荷重 (kN)	Fc (N/mm ²)	断面積 (㎡)	断面積[AI] (㎡)	正答率 (%)
18	392	3030	60	1.21	1.3242	90.6
15	393	2960	42	1.32	1.1504	87.2
15	312	2270	36	1.43	1.1430	79.9
10	566	4570	33	1.00	1.1109	88.9
4	122	970	27	0.784	0.8262	94.6

表2 検討2 (Fc36) の解析結果

階数	負担面積 (㎡)	負担荷重 (kN)	Fc (N/mm ²)	断面積 (㎡)	断面積[AI] (㎡)	正答率 (%)
12	218	1230	36	1.05	1.0607	99.0
12	245	1370	36	1.10	1.1013	99.9
12	318	1780	36	1.05	1.1122	94.1
12	435	2440	36	1.15	1.1236	97.7
12	608	3410	36	1.265	1.1627	91.9

表3 検討2 (Fc33) の解析結果

階数	負担面積 (㎡)	負担荷重 (kN)	Fc (N/mm ²)	断面積 (㎡)	断面積[AI] (㎡)	正答率 (%)
11	222	1750	33	1.00	0.971	97.1
11	239	1880	33	1.00	0.969	96.9
11	521	4110	33	1.00	0.970	97.0
11	530	4180	33	1.00	0.987	98.7

5. まとめ

本論文では、最もシンプルなAIである3層のニューラルネットワークを利用して、柱の断面積の予測精度を調査した。その結果、検討1では予測精度にばらつきが生じた。これは解析に用いた5つのデータにおいて、類似した学習データの数の偏りが要因の1つと考える。しかし、検討2では2つの検討対象において、共に解析に用いたデータが9割以上の精度で予測ができています。これは解析に用いた2つの建物に類似した学習データの割合が多く存在したことで精度よく予測可能であったと考える。したがって、シンプルなAIでも、様々な規模の設計例から約450組のデータを集めることができれば、類似の設計例の建物1棟の柱の断面積の予測に関しては、高精度で予測することが可能であると結論づけられる。

今回の研究では中間層が1つで建物の柱断面にのみ着目した。しかし実務で扱うには、中間層を増やしたディープラーニングを用いて予測精度を高め、同時に検討する部材を追加して予測する数を増やした、より実用的なAIである必要がある。AIは学習データが多いほど正確に予測精度が高くなるため、物件の規模ごとに多数の設計例を集めることで、より緻密に予測可能となり、構造設計への実用性が期待できる。今回使用していないディープラーニングを用いた場合との比較も含めて、予測精度の調査の余地があるため、今後の課題とする。

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.2-146
- 2) takahiro_itazuri『自分でニューラルネットワークを作ろう』Qiita (最終閲覧日: 2021年1月20日) https://qiita.com/takahiro_itazuri/items