

16. 構造設計へのAIの適用に関する基礎的研究 —柱初期断面の予測に対する検討—

1610920036 松本葉夏
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

人工知能 (AI) は, ニューラルネットワークにもとづく機械学習により, 人間の知能と同様の予測と判断を可能にするものであり, 最近では, ニューラルネットワークの中間層を多層にする深層学習 (ディープラーニング) の技術が発展し, 画像認識など多くの工学分野で活用され始めている. 本研究では, このようなAIの技術を建築構造設計の分野に活用できないかと考え, 構造設計で最も経験が必要とされる部材初期断面の設定に応用することを検討する. 本論文では, まずAIの基本的な性能を把握するため, 最も単純な3層 (入力層+中間層+出力層) のニューラルネットワークを用い, 部材断面の予測をどの程度正確に行えるかを把握する. 本研究室の矢代は, 床スラブの縦・横の寸法と床荷重からスラブ厚を予測するAIを作成したが, 筆者は, ビルの1階柱の初期断面幅を予測するAIを作成し, その予測性能の検討を行う.

2. 学習データ作成

AIを実装する上で重要となるのが学習であり, 学習を行うためには膨大な量のデータが必要となる. 今回, ビルの1階柱の初期断面幅を予測するためには, 当該柱に対する床スラブの負担面積, 床荷重, 建物階数などのデータが必要である. しかし, これを既存の2000~10000の設計図から読み取ることは容易ではない. そこで本論文では, 必要データの数値を乱数で与え, 柱を正方形断面とし, 学習用の柱断面幅を次式で計算するものとする.

$$\sqrt{A} = \text{負担面積} \times w_p \times \text{階数} / 0.3F_c \quad (1)$$

ここで, A は柱断面積である. 負担面積は, $8 \text{ m}^2 \sim 32 \text{ m}^2$ と $4 \text{ m}^2 \sim 64 \text{ m}^2$ の2通り検討を行う. w_p は, 床荷重で $10 \text{ kN/m}^2 \sim 15 \text{ kN/m}^2$ の乱数として与える. また, 階数は $1 \sim 9$ を乱数として与え, F_c (圧縮強度) は 24 N/mm^2 とする. ただし, 柱負担面積と階数のみを与える入力層2の場合は w_p を 10 kN/m^2 で固定する. また, 使用プログラムの制約から学習データは, $0 \sim 1$ の範囲に置き換え, データの桁数は小さく設定する必要がある. そのため負担面積には 10^{-2} , w_p には 10^{-2} , 階数には 10^{-1} を乗じて桁数を落とす. また, 入力層2の場合はデータ数2000個, 入力層3の場合はデータ数4000個とする.

3. 学習パラメータの設定

3.1 負担面積 $8 \text{ m}^2 \sim 32 \text{ m}^2$ の場合

本研究では, 中間層のノード数 (hnodes), エポック数 (epoch), 学習率 (lr) の3種類をパラメータとして設定する. 学習データと同手順で作成した100個のテストデータの平均精度を比較し, 最適なパラメータを導き出す.

入力層2の場合のパラメータ設定を行う. まず中間層のノード数を設定する. ノード数0から200の範囲で平均精度を表したグラフを図1に示す. ノード数9から113で精度が安定していることがわかり, その範囲で最も精度が高い64を最適なノード数とする.

次に, エポック数0から1200の範囲で精度を表したグラフを図2に示す.

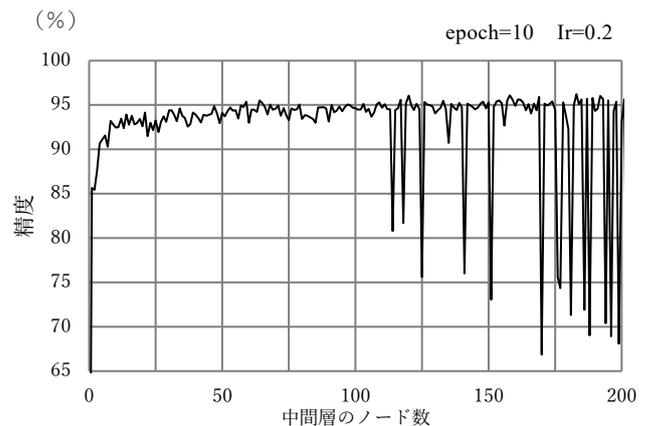


図1 中間層のノード数検討

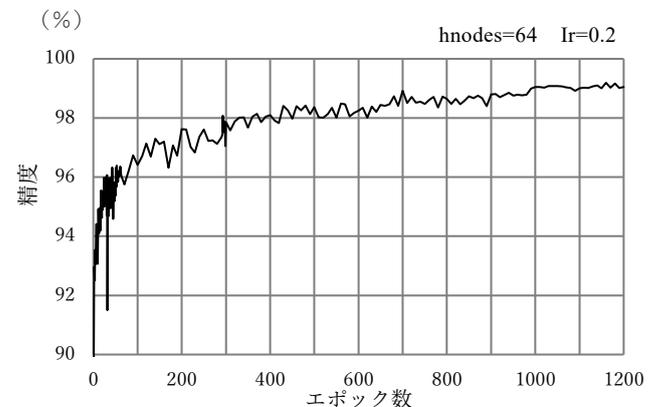


図2 エポック数検討

図2より、エポック数の増加と共に精度は高くなり、精度99%で安定している。1000を最適エポック数とする。

学習率は0から1の間で設定するのが一般的であり、この範囲で精度を表したグラフを図3に示す。最も精度が高い学習率は0.23なので、これを最適な学習率とする。

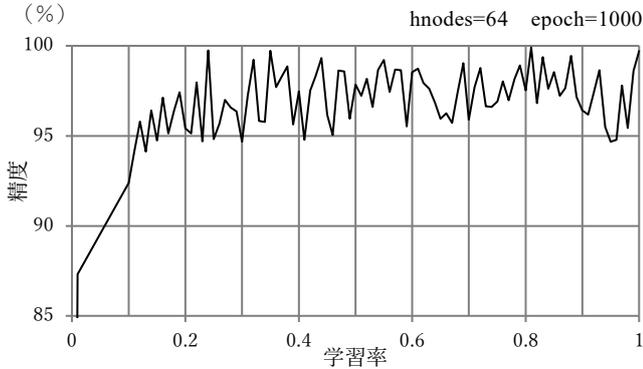


図3 学習率検討

以上の検討では、エポック数1000となり、学習時間がかなり長くなる。そこで設定順を変更する。ノード数→学習率→エポック数→学習率の順で、同じように設定を行う。結果、ノード数64、エポック数350、学習率0.82となり、エポック数の値を大幅に抑えることができた。入力層3の場合も同様に設定を行い、中間層のノード数74、エポック数20、学習率0.94となった。

次に学習データ数0から3000の範囲で精度を表したグラフを図4に示す。データ数の増加とともに精度は向上し、データ数3100あたりから精度98%以上で一定となる。よってこれを最適な学習データ数とする。入力層3の場合も同様に検討し、学習データ数は1500となった。

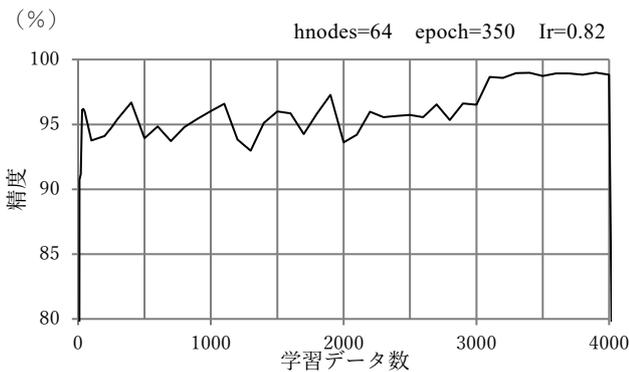


図4 学習データ数検討

3.2 負担面積4㎡～64㎡の場合

入力層2の場合、3.1と同様にパラメータを設定すると、中間層のノード数78、エポック数20、学習率0.2となり、学習データ数は1200となった。また、入力層3の場合、中間層のノード数30、エポック数290、学習率0.49となり、学習データ数は2600となった。

4. 予測結果

データをそれぞれ5種類ずつ、学習データと同じように作成し、その予測結果を以下に示す。負担面積8～32

㎡の場合の入力層2、入力層3の解析結果を表1、表2に示す。また、負担面積4㎡～64㎡の場合の入力層2、入力層3の解析結果を表3、表4に示す。

表1 負担面積8㎡～32㎡の解析結果(入力層2)

負担面積 (㎡)	階数	初期断面幅【正解】(cm)	初期断面幅【予測】(cm)	誤差(cm)
31	2	29	29	0
9	5	25	25	0
26	3	33	33	0
18	7	42	42	0
22	8	49	49	0

表2 負担面積8㎡～32㎡の解析結果(入力層3)

負担面積 (㎡)	階数	Wp (kN/㎡)	初期断面幅【正解】(cm)	初期断面幅【予測】(cm)	誤差(cm)
9	4	10	22	22	0
26	5	14	50	52	2
27	8	10	55	56	1
21	9	14	61	60	1
29	3	15	43	45	2

表3 負担面積4㎡～64㎡の解析結果(入力層2)

負担面積 (㎡)	階数	初期断面幅【正解】(cm)	初期断面幅【予測】(cm)	誤差(cm)
4	2	11	11	0
26	6	47	46	1
7	8	28	32	4
17	4	31	29	2
61	7	77	77	0

表4 負担面積4㎡～64㎡の解析結果(入力層3)

負担面積 (㎡)	階数	Wp (kN/㎡)	初期断面幅【正解】(cm)	初期断面幅【予測】(cm)	誤差(cm)
4	3	10	13	11	2
57	6	13	79	75	4
30	7	14	64	65	1
43	8	12	76	74	2
17	9	11	48	48	0

5. まとめ

本論文では、ビルの1階柱の初期断面幅を予測するAIを作成し、その予測性能の検討を行った。負担面積の範囲を分けて比較すると、負担面積8㎡～32㎡の場合ではより精度は高くなり、誤差は最大で2cmとなった。負担面積4㎡～64㎡の場合では最大で4cmの誤差が生じた。どちらの場合も入力層3では誤差が大きくなったが、ディープラーニングを行うことで精度を高めることが可能であると考えられる。

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.2-20
- 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: 2020年1月25日) https://qiita.com/takahiro_itazuri/items