

## 15. 構造設計への AI の適用に関する基礎的研究 —スラブ厚の予測に対する検討—

1610920037 矢代美咲  
指導教員 藤井大地 教授

AI, ニューラルネットワーク, 初期断面, RC スラブ厚

### 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. 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, その基礎的研究を行う. 建築構造設計において, 最も経験やノウハウが必要とされるのは, 初期断面の設定である. そこで, 本研究では, 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. 本論文では, まず, 基本的な例題として, RC スラブの縦と横の長さ (入力層 2) からそのスラブ厚を予測する AI と, RC スラブの縦と横の長さとスラブに加わる荷重 (入力層 3) からそのスラブ厚を予測する AI を考える. そして, このようなシンプルな AI で, どの程度正確なスラブ厚を予測できるかを調査したので, その結果を報告する.

### 2. 学習データの作成

既存設計例から学習データを作成することは容易ではないため, 本論文では, 学習データにおけるスラブ厚は次式から算出するものとする.

$$t = 0.02 \left( \frac{\lambda - 0.7}{\lambda - 0.6} \right) \left( 1 + \frac{w_p}{10} + \frac{l_x}{10000} \right) l_x \quad (1)$$

学習データとして,  $l_x$ ,  $l_y$  (RC スラブの縦と横の長さ) を 2000 mm から 8000 mm の範囲で乱数として与え,  $w_p$  (固定荷重 + 積載荷重) を  $10 \text{ kN/m}^2$  から  $15 \text{ kN/m}^2$  の範囲で乱数として与える. ただし, 入力層 2 の場合は,  $w_p$  を  $10 \text{ kN/m}^2$  に固定する. これらの値から (1) 式よりスラブ厚を算出する. 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,  $l_x$ ,  $l_y$  には  $10^{-4}$  を,  $w_p$  には  $10^{-2}$  を,  $t$  には  $10^{-3}$  を乗じる. そしてこれらを 2000 組用意したものを基本学習データとする. また, 桁数が多いと単純な AI では上手く学習できないため,  $l_x$ ,  $l_y$ ,  $w_p$  は小数点以下 2 桁とし,  $t$  は 3 桁とする.

さらに, スラブ厚は基本的に 130mm 以上とされているため, 学習データの 130mm 未満のものを 130mm という制約を加えた場合でも予測可能かを調査する.

### 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, 学習データと同じ作成方法でテストデータを 100 組作成し, それぞれの精度の平均値を比較してパラメータを検討する.

まず, 入力層 2 の場合の最適なパラメータを見つける. ノード数の検討結果を図 1 に示す. ノード数が 19 から 39 の範囲で精度が安定している. したがって, 今回はこの範囲の中間である 29 を最適なノード数とする.

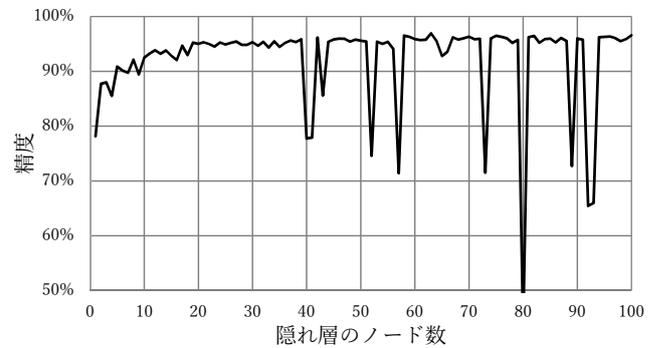


図 1 隠れ層のノード数の検討

学習率の検討結果を図 2 に示す. 学習率が小さいほうから 16 に向かって精度が高くなっており, 11 から 16 の範囲でかなり精度が高いことが分かる. したがって今回は 15 を最適な学習率とする.

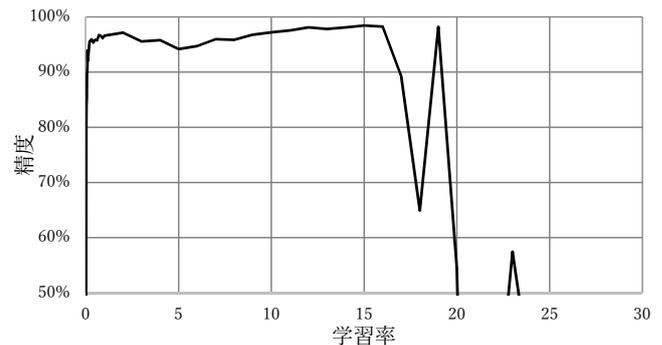


図 2 学習率の検討

エポック数の検討結果を図 3 に示す. エポックが多くなるにつれて精度が高くなり, 20 あたりから精度が一定になることが分かる. したがって今回は 20 を最適なエポック数とする.

同様に, 入力層 3 の場合のパラメータの検討を行った. ここでは, テストデータの精度の平均値ではなく最小値

(最悪値)を比較して検討を行った。結果,  $hnodes=76$ ,  $lr=0.82$ ,  $epoch=380$  が最適であると判断した。

また, 制約を加えた場合では,  $hnodes=173$ ,  $lr=0.76$ ,  $epoch=480$  が最適なパラメータであると判断した。

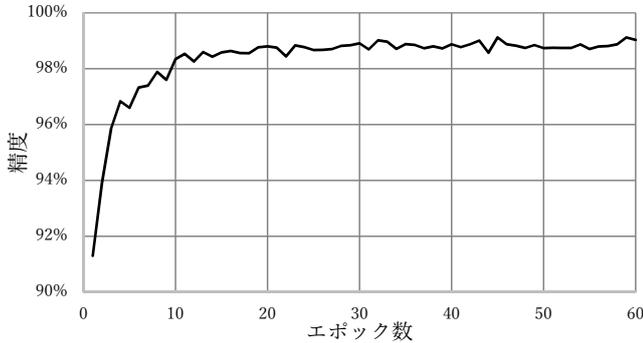


図3 エポック数の検討

#### 4. 学習データの量

次に, 学習データの量の増減による精度の変化を調査した。パラメータは前節で決めたものを使用する。

まず, 入力層2の場合, 学習データは2000組ほどあれば十分高い精度が出ることがわかった。よって, 学習データは2000組とする。

次に, 入力層3の場合も同様に検討した。結果, 学習データは3000組ほどあれば十分高い精度が出ることがわかった。よって, 学習データは3000組とする。

制約を加えた場合でも同様に検討したところ, 4000組が最適な学習データであると判断する。

#### 5. 解析結果

学習データと同じ方法で入力層2と入力層3, 制約を加えた場合のそれぞれで10組のデータを作成し, 解析を行った。入力層2の場合の解析結果を表1に, 入力層3の場合の解析結果を表2に, 制約を加えた場合の解析結果を表3に示す。制約を加えない場合ではかなり高い予測精度が出ており, 入力層2の場合では, 2mm以下の誤差となった。また, 制約を加えた場合でも, ある程度の予測が可能であることが分かる。

表1 入力層2つの場合の解析結果

$l_x$ (mm)	$l_y$ (mm)	$t$ (mm)	$t(AI)$ (mm)	誤差 (mm)	精度 (%)
2000	3000	78	77	1.0	98.68
4900	6600	211	212	0.8	99.62
4200	5800	177	177	0.3	99.85
2000	7700	85	86	0.9	98.96
3600	5800	153	151	1.9	98.77
5800	7000	250	250	0.1	99.94
2600	6700	112	111	0.3	99.74
6300	6600	257	259	1.6	99.39
4500	5500	185	183	1.6	99.15
3300	5200	138	136	1.9	98.66

表2 入力層3つの場合の解析結果

$l_x$ (mm)	$l_y$ (mm)	$w_p$ (kN/m <sup>2</sup> )	$t$ (mm)	$t(AI)$ (mm)	誤差 (mm)	精度 (%)
4100	4700	10	161	159	2.0	98.75
6100	7700	12	291	289	1.6	99.44
2300	4100	14	111	112	1.0	99.09
7100	7600	12	325	325	0.2	99.94
6700	8000	13	331	326	5.0	98.50
4100	7400	13	204	202	1.9	99.09
5400	7000	14	272	268	3.8	98.59
3800	7900	10	169	168	0.4	99.79
2200	6300	15	114	118	3.2	97.16
4400	6500	11	198	196	2.1	98.92

表3 スラブ厚130mm以上の検討

$l_x$ (mm)	$l_y$ (mm)	$w_p$ (kN/m <sup>2</sup> )	$t$ (mm)	$t(AI)$ (mm)	誤差 (mm)	精度 (%)
2000	8000	10	130	123	7.0	94.58
2300	2500	13	130	129	1.0	99.22
2600	3500	14	130	134	3.7	97.18
2800	3700	12	130	134	3.7	97.13
2800	6300	11	130	134	4.5	96.56
2700	6900	15	142	146	3.5	97.50
3200	4000	14	147	146	0.6	99.61
5900	7500	11	270	268	2.5	99.09
5100	7300	13	252	249	2.8	98.87
4400	7600	12	212	208	4.4	97.95

#### 6. 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, どの程度正確なスラブ厚を予測できるかを調査した。その結果, 誤差5mm程度以内で予測できることがわかった。したがって, シンプルなAIでも, スラブの縦と横の長さやスラブに加わる荷重を与えると, スラブ厚を予測することが可能であると結論づけられる。また, 130mm以上の制約を加えた場合, 制約なしより精度は劣るが, 誤差7mm程度以内の予測が可能であった。今後は, ディープラーニングを行うことで, さらに良い精度も期待できると考えられる。

#### 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.2-146
- 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: 2020年1月20日)  
[https://qiita.com/takahiro\\_itazuri/items](https://qiita.com/takahiro_itazuri/items)