

機械学習を用いた構造物の動的応答予測と経済性を考慮した規格部材配置最適化

Dynamic Response Prediction of Structures Using Machine Learning and Optimization of Standard Member Arrangement Considering Economics

○新田 広*¹, 藤田 慎之輔*²
Hiroshi NITTA*¹, Shinnosuke FUJITA*²

*1 北九州市立大学大学院 国際環境工学研究科 大学院生

Graduate Student, Faculty of Environmental Engineering, The University of Kitakyushu

*2 北九州市立大学大学院 国際環境工学研究科 准教授

Assoc. Prof., Faculty of Environmental Engineering, The University of Kitakyushu, Dr. Eng.

キーワード：時刻歴応答解析；ニューラルネットワーク；発見的手法

Keywords：Time history response analysis；Neural Network；Meta-heuristics.

1. はじめに

地震大国の日本において、時刻歴応答解析を用いた耐震設計は重要事項である。しかし、設計実務において、こういった構造形式が適切で合理的かを、限られた時間内に正確に捉えることは、時刻歴応答解析に伴う計算コストの面から困難であり、設計者の経験的な判断に頼ることが大きい。そういった建築設計問題を改善し、設計者の判断の補助的役割を担う方法として最適化手法の活用が挙げられる¹⁾。しかし、建築構造の最適化は一般的に解析負荷が高く、計算時間の短縮と解の収束性を担保するために様々な工夫を要する。振動解析においても最適化手法を活用するにあたり、応答値を時刻歴応答解析により算定する必要がある。しかし、先程述べたように、時刻歴応答解析は時間軸に対する繰り返し計算を伴うため、その都度時刻歴応答解析を行うことは計算コストの観点からも、実務における設計スケジュールの観点からも現実的でない。そこで本研究では、時刻歴応答解析を行わずに応答値を推定するために、機械学習による予測システムに置き換えることで、現実的な計算時間で経済性を考慮した鋼材の規格部材配置最適化を行う。

2. ビッグデータ作成

本研究では、膨大な数の解析モデルを用意し、オープンソースの構造解析ソフトとして知られている Opensees²⁾を用いて時刻歴応答解析を行う。解析モデルの形状は図1に示すように、6層6スパンの平面骨組を考える。梁は剛体として扱い、柱は表1にある規格断面リストの中から式(1)の規則で選択される。各層で選択される鋼材

の規格断面番号を $L_e (e = 1, \dots, 6)$ 、階数を n とおくと、

$$\mathbf{L} = \begin{cases} L_1 = d_1 & \text{if } d_1 = 15, \dots, 35 \\ \vdots \\ L_e = d_{n-1} - d_n & \text{if } d_n = 0, \dots, 5 \end{cases} \quad (1)$$

$$d_1 - \left(\sum_{i=2}^n d_n \right) \geq 0 \quad (2)$$

となり、剛性 \mathbf{K} は、各層で使用される鋼材の断面二次モーメントを I_{L_e} とおくと、

$$\mathbf{K} = \frac{12E}{h^3} \begin{bmatrix} I_{L_1} & \dots & I_{L_e} \end{bmatrix}^T \quad (3)$$

となる。

建物重量は各層 1500kN に設定し、時刻歴応答解析を実施するにあたり、部材の塑性化は考慮しないものとし、入力地震動の時刻歴加速度データは、El centro NS, Hachinohe NS, Taft NS の最大速度を 50kine で基準化したもののいずれかを作用させる。

$$\mathbf{A}_{\max} = \begin{cases} A_{\max}^{\text{El centro NS}} \\ A_{\max}^{\text{Hachinohe NS}} \\ A_{\max}^{\text{Taft NS}} \end{cases} \quad (4)$$




図1: 解析モデル




図 2: 入力地震動

表 1: 角形鋼管の規格断面リスト

番号	寸法 B×D(mm)	厚み t(mm)	断面積 A(cm ²)	断面二次モーメント I (×10 ⁻⁴ m ⁴)
1	0.25 × 0.25	0.006	0.05856	0.581
2	0.25 × 0.25	0.009	0.08676	0.841
3	0.25 × 0.25	0.0012	0.11424	1.081
4	0.25 × 0.25	0.0016	0.14976	1.373
5	0.30 × 0.30	0.006	0.07056	1.017
6	0.30 × 0.30	0.009	0.10476	1.480
7	0.30 × 0.30	0.012	0.13824	1.914
8	0.30 × 0.30	0.016	0.18176	2.451
9	0.30 × 0.30	0.019	0.21356	2.823
10	0.35 × 0.35	0.009	0.12276	2.381
11	0.35 × 0.35	0.012	0.16224	3.093
12	0.35 × 0.35	0.016	0.21376	3.983
13	0.35 × 0.35	0.019	0.25156	4.609
14	0.35 × 0.35	0.022	0.28864	5.199
15	0.40 × 0.40	0.009	0.14076	3.588
16	0.40 × 0.40	0.012	0.18624	4.677
17	0.40 × 0.40	0.016	0.24576	6.050
18	0.40 × 0.40	0.019	0.28965	7.023
19	0.40 × 0.40	0.022	0.33264	7.948
20	0.40 × 0.40	0.025	0.37500	8.828
21	0.45 × 0.45	0.012	0.21024	6.727
22	0.45 × 0.45	0.016	0.27776	8.731
23	0.45 × 0.45	0.019	0.32756	10.16
24	0.45 × 0.45	0.022	0.37664	11.53
25	0.45 × 0.45	0.025	0.42500	12.84
26	0.50 × 0.50	0.012	0.23424	9.303
27	0.50 × 0.50	0.016	0.30976	12.11
28	0.50 × 0.50	0.019	0.36556	14.12
29	0.50 × 0.50	0.022	0.42064	16.05
31	0.50 × 0.50	0.025	0.47500	17.91
32	0.55 × 0.55	0.016	0.34176	16.26
33	0.55 × 0.55	0.019	0.40356	18.99
34	0.55 × 0.55	0.022	0.46464	21.63
35	0.55 × 0.55	0.025	0.52500	24.17

このように、各層の柱に使用する鋼材の規格断面、入力地震動をランダムに組み合わせた解析モデルを合計 10 万種類作成し、時刻歴応答解析を行う。

3. ニューラルネットワーク回帰

解析モデルの応答値を予測するためにニューラルネットワークを用いる。ニューラルネットワークの基本構造は図 3 のように微分可能な変換をつなげて作られた計算グラフである³⁾。計算過程の例として、入力層と第一中間層における計算過程を示す。入力層の説明変数を n

個、中間層のニューロン数を N 個、中間層のノードの個数を k 個とすると、

$$\mathbf{u}_1 = \mathbf{W}_1 \mathbf{h}_0 \quad (5a)$$

$$\mathbf{u}_1 = [u_{11} \ \cdots \ u_{1k}]^T \quad (5b)$$

$$\mathbf{W}_1 = \begin{bmatrix} w_{1,11} & \cdots & w_{1,1n} \\ \vdots & \ddots & \vdots \\ w_{1,k1} & \cdots & w_{1,kn} \end{bmatrix} \quad (5c)$$

$$\mathbf{h}_0 = [h_{01} \ \cdots \ h_{0n}]^T \quad (5d)$$

と表すことが出来る。 \mathbf{h}_0 は入力層の入力変数ベクトルを示しており、式 (1~3) で示した各特徴量のスカラーとなる。 \mathbf{W}_1 は一層分のパラメータベクトル、 \mathbf{u}_1 は第一層中間出力ベクトルである。ここで式 (5) より算出された \mathbf{u}_1 は活性化関数で変換され、出力データ y を算出するまで式 (5) を繰り返す。ニューロン数 N は入出力関係の汎化能力に十分な個数を、試行錯誤的なシミュレーションで決定する場合が大半であるため、 $N = 1, \dots, 4$ の間で任意に設定され、ユニット数 k は多めに持たせておき徐々に減らしていく学習方法が適切である。活性化関数は 0 より大きければそのまま、0 より小さければ 0 に置き換えて出力する Relu、最適化手法には、極小値にトラップされること無く最小値を目指すためのアプローチである adam を使用し⁴⁾、損失関数は mse(平均二乗誤差)、評価関数は mae(平均絶対誤差)を用いる。

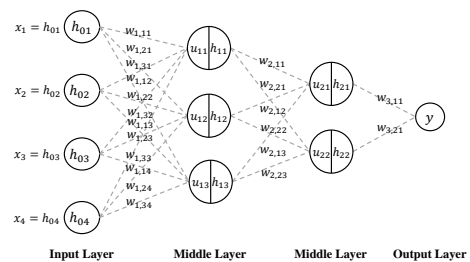


図 3: ニューラルネットワークの基本構造

4. 機械学習による動的応答予測

機械学習を実施するにあたり、10 万個のビッグデータの中から、8 万個の学習モデルと 2 万個の予測モデルを作成した。また、ニューラルネットワーク回帰を行うにあたって $N = 4, k = 128$ で固定し、バッチサイズ=16, 32, 64, 128, エポック数=100, 150, 200, 250 と調整しながら学習を行う。また、時刻歴応答解析を実施して算出した各層の最大応答変位である解析値 $\lambda_e (e = 1, \dots, 6)$ と、予測モデルを用いて算出した各層の最大応答変位である予測値 $\lambda_{p,e}$ との比較を行い予測モデルの精度を検証する。

以下に機械学習を実施するにあたって設定したパラメータ値の中で最適な設定とその正解率を表2に示す。正解率とは2万個の予測モデルに対する $\lambda_{p,e}/\lambda_e$ のクライテリア誤差を $\pm 20\%$ 以内、つまり $0.8 \leq \lambda_{p,e}/\lambda_e \leq 1.2$ と設定した値に収まっている割合を指す。

表2: パラメータごとの最適な設定と正解率

バッチサイズ	エポック数	上下20% 正解率 (%)					
		層1	層2	層3	層4	層5	層6
16	150	93.90	98.99	99.59	99.67	99.78	99.75
32	200	98.15	99.52	99.77	99.83	99.81	99.85
64	100	98.00	99.56	99.71	99.69	99.74	99.79
128	200	99.30	99.81	99.86	99.86	99.86	99.85

以上の表から、バッチサイズ=128、エポック数=200とした時の精度が安定して高いことがわかる。このときの誤差の収束過程を図4に示し、予測結果を図5に示す。




図4: 予測誤差収束履歴

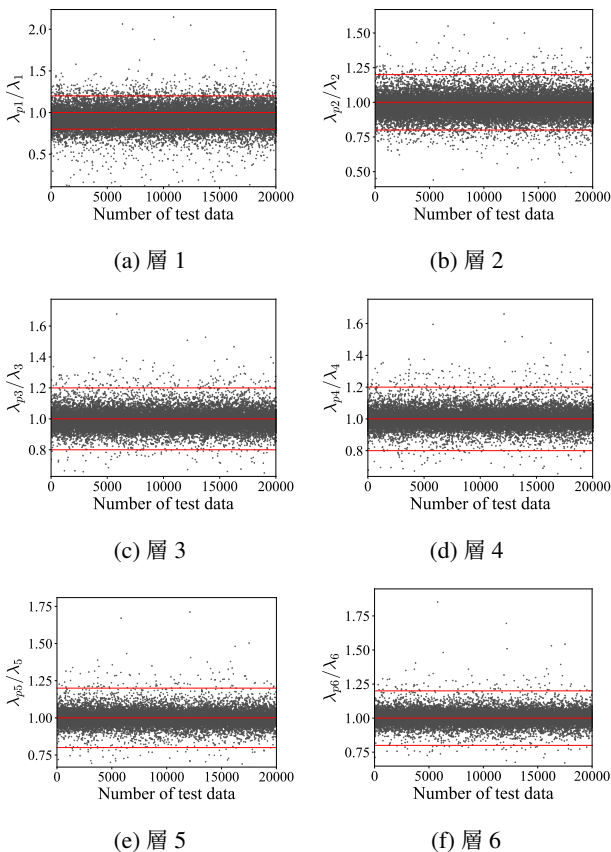


図5: バッチサイズ=16, エポック数=100の予測結果

図4を見ると、繰り返し計算が進むに連れて誤差が収束している事がわかる。また、収束過程において、小刻みに振動しているが発散していないためノイズの影響を受けながらも学習は成功していると考えられる。図5を見ると、 $\lambda_{p,e}/\lambda_e$ は概ね上下20%以内に収まっていることがわかり、予測精度も良好のため、この予測器を用いて鋼材の配置最適化問題を行う。

5. 最適化問題の定式化

本研究で扱う構造物の規格部材配置最適化問題の概要を示す。

$$\text{minimize } \sum_{e=1}^n A_{L_e} \cdot h \quad (6a)$$

$$\text{subject to } \frac{\lambda_{p,e} - \lambda_{p,e-1}}{h} \leq 1/100 \quad (6b)$$

$$d_1 - \left(\sum_{i=2}^n d_n \right) \geq 0 \quad (6c)$$

A_{L_e} : 各層で使用される鋼材の断面積

h : 階高

n : 階数

λ_e : 最大応答変位の解析値

$\lambda_{p,e}$: 最大応答変位の予測値

定式化した最適化問題は MIDACO⁵⁾を用い、繰り返し計算回数を20万回行った。計算機は Intel(R)Core(TM)i7-7700K@4.20GHz のCPUを持つものを使用する。

6. 解析結果

最適化における初期値は、体積が最大となるように設定し最適化を行う。以下に繰り返し計算を20万回行った際の目的関数の収束履歴を示す。




図6: 目的関数の収束履歴

図6を見ると、各地震波に対して目的関数は収束していることがわかる。計算コストに関しては、予測モデルを用いた場合の最適化時間は4974秒であり、1度の解析時間に約20秒費やす時刻歴応答解析をその都度行うより、効率が良いことは明らかである。

最適化後の鋼材配置図を図7に示す。また、この時の解析値と予測値との比較を各層の最大応答変位(図8)、層間変形角(図9)として示し、予測器の有用性を検討する。

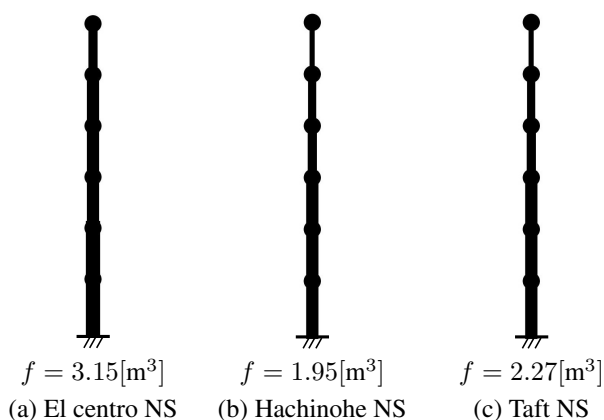


図7: 最適化後の鋼材配置図

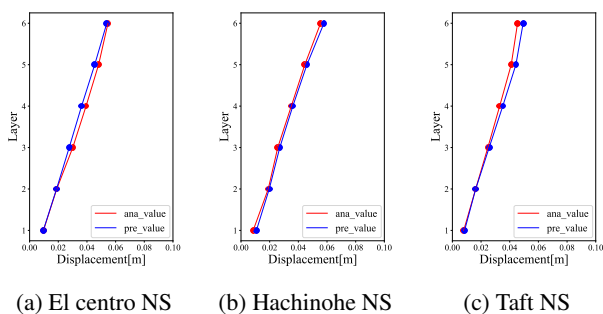


図8: 各地震波に対する予測値と解析値

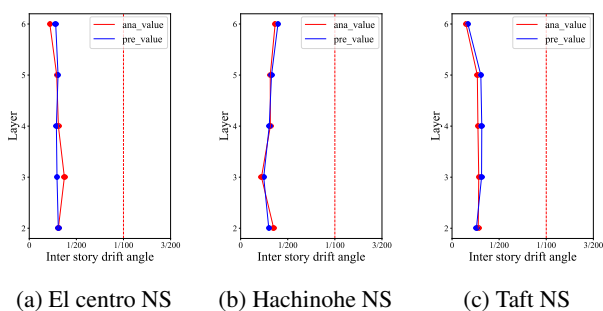


図9: 各地震波に対する層間変形角の予測値と解析値

図8, 図9を見ると、解析値に対する予測値の誤差が少なく、制約条件も満たしており、良好な結果を示していることがわかる。なお、本研究では、ビッグデータの数を10万に設定した上で予測モデルを作成しており、クライテリア誤差を±20%以内に収まっている割合を正解値として予測モデルの精度を判定しているため、正解値に対して多少の誤差は許容できるものとしており、実際に図8の(a)では、予測値が正解値に対して過小評

価している点が見つかる。構造設計実務において、建物の耐力を安全側に検討することが考えられるため、設計者判断により、クライテリア誤差を厳しくするなどして、より精度の良い予測モデルを使用し、正解値に対する予測値の誤差を厳しくすることが実務上有用な予測モデルの使用方法だと考える。

7. 結論

本研究では、機械学習を用いて時刻歴応答解析を実施することなく、解析モデルの応答を予測できる予測モデルを使用し、経済性を考慮した解析モデルの規格部材配置最適化を行った。以下に得られた知見まとめる。

応答予測に関しては、エポック数とバッチサイズの兼ね合いにより予測精度が決定されるため、それぞれのパラメータを変化させることによる予測精度の結果をまとめたところ、予測精度は良好な値を示しており、外れ値も2倍程度で収まっていることがわかる。しかし、解析値に対する予測値の誤差が生じているため、教師データをさらに増やすことで、予測精度を向上し、誤差を低減する事が可能だと考える。

部材配置最適化においては、目的関数の収束もみられ、制約を満たした上での経済性の高い設計が可能だと言える。また、予測器を使用したことによる計算時間の大幅な削減に伴い、設計期間中に十分なトライアンドエラーの機会を十分に確保ができる考える。

今後の展望として、予測モデルを用いた最適化を行うにあたって、鋼材の組み合わせだけでなく、免・制振デバイスを使用した場合での経済性を考慮した組み合わせ最適化を行うことが考えられる。

8. 謝辞

本研究の一部はJSPS 科研費 22K04416 の助成を受けたものである。ここに記して謝意を表する。

【参考文献】

- 1) 日本設計. 構造設計実務における最適化を用いた設計法の提案. 日本建築学会大会学術講演梗概集, pp. 275–276, 2020.9.
- 2) M. Zhu, F. McKenna, and M. Scott. Openseespy: Python library for the opensees finite element framework. *SoftwareX*, Vol. 7, pp. 6–11, 2018.1.
- 3) Seth Weidman. *Deep Learning from Scratch: Building with python from First Principles*. O'Reilly Associates Inc, 2019.09.
- 4) Diederik P Kingma and Jimmy Lei Ba. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR2015*, 2015.
- 5) M. Schlueter, J. A. Egea, and J. R. Banga. Extended ant colony optimization for non-convex mixed integer nonlinear programming. *Computers & Operations Research*, Vol. 36, No. 7, pp. 2217–2229, 2008.8.