

複数種類のスパン・階高を含む教師データを用いた平面骨組の動的応答予測 Prediction of Dynamic Response of 2D Frames Using Training Data with Multiple Span and Story Heights

○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；グラフ埋め込み

Keywords：Time History Response Analysis；Neural Network；Graph Embedding.

1. はじめに

近年の機械学習手法の発展に伴い、機械学習を用いた建築構造物の解析結果を予測する等の設計支援手法が提案されている¹⁾。これらは、設計の利便性と精度を重視し、ニューラルネットワーク（以下 NN）を評価器として用いることが主流である。しかし、線材置換されたモデルが持つ接続性を無視している点や、入力サイズが変わると適用できなくなるという欠点が存在する。

本研究では、グラフ埋め込み (Graph Embedding, 以下 GE) 操作で得られる部材同士の不規則な接続性を持つデータから、同一サイズの特徴量を持つ連続変数を定義・抽出し、形状をランダムに操作した鋼構造平面骨組に対して時刻歴応答解析を用いて得られる応答性状を、NN を評価器として予測する手法を提案する。

2. ニューラルネットワークの基本構造

本研究では、機械学習における評価器として NN を使用する。NN の基本構造は、図 1 のように微分可能な変換を繋げて作られた計算グラフである。例として、入力層と第一中間層における計算過程を示す。入力層の個数を n 、中間層の個数を k 個とすると、

$$\mathbf{u}_1 = \mathbf{W}_1 \mathbf{h}_0 + \mathbf{b}_1 \quad (1a)$$

$$\mathbf{u}_1 = \begin{bmatrix} u_{11} & \cdots & u_{1k} \end{bmatrix}^T \quad (1b)$$

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

$$\mathbf{b}_1 = \begin{bmatrix} b_0 & \cdots & b_k \end{bmatrix}^T \quad (1d)$$

$$\mathbf{h}_0 = \begin{bmatrix} h_{01} & \cdots & h_{0n} \end{bmatrix}^T \quad (1e)$$

と表すことができる。ここで、 $\mathbf{h}_0 \in \mathbb{R}^n$ は入力層の入力変数ベクトル、 $\mathbf{W}_1 \in \mathbb{R}^{k \times n}$ は一層分のパラメータ行列、 $\mathbf{b}_1 \in \mathbb{R}^k$ はバイアスベクトル、 $\mathbf{u}_1 \in \mathbb{R}^k$ は第一中間層の出力ベクトルである。中間層での活性化関数 φ には正規化線形関数と呼ばれる ReLU を用いる。NN の構築には、Python で書かれた、TensorFlow 上で実行可能な高水準の NN ライブラリである Keras²⁾ を用い、最適化アルゴリズムには Adam³⁾ を使用する。誤差収束履歴は平均絶対誤差である MAE によって評価する。教師データの個数を N とすると NN は式 (2) に示す平均二乗誤差を最小化することでパラメータ行列 $\mathbf{W}$ を決定する。

$$\underset{\mathbf{W}}{\text{minimize}} \quad \text{MSE} = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (2)$$

y_i : i 番目の予測値

t_i : i 番目の正解値




図 1: ニューラルネットワーク概要図

3. 学習対象の解析モデル詳細

本研究で対象とする解析モデルは、図 2 に示す F 層、 S スパンの鋼構造平面骨組とする。このとき、 $F = 2 \sim 10$

層, $S = 3 \sim 6$ スパンの範囲の中でランダムに選択し, 階高やスパンはそれぞれ $3\text{m} \sim 5\text{m}$, $5\text{m} \sim 8\text{m}$ の間でランダムに変更したものとする. また, 各層の柱・梁断面は鋼材リスト 1, 2 内でランダムに選択された断面が下層から徐々に小さくなるように設定した解析モデルを, 教師データとして 5 万個用意する. 用意した解析モデルを, オープンソースの構造解析ソフトとして知られている OpenSees⁴⁾ を用いて時刻歴応答解析を行う. 解析に使用する設計用入力地震動は最大加速度を 500gal とした El Centro NS 波とし, 解析するにあたって, 梁は床面の剛性を考慮し軸剛性を 100 倍に設定し, 各層に生じる面荷重は, 普通コンクリートの単位体積重量を 23kN/m^3 , 床厚を 0.15m , 梁間を 6m することで, 最大スパンによって可変とする. これらは全て弾性範囲内での解析とする.

以上の操作で得られた解析モデル最上階の最大応答加速度 S_a , 最大応答変位 S_d を, NN を評価器として予測する.

4. GE 操作による部材の特徴量抽出

抽出する特徴量ベクトルのサイズを n_f とする. 節点数 n_n , 要素数 n_m , 接続行列 $\mathbf{C} \in \mathbb{R}^{n_m \times n_n}$ とし, 各節点に与える入力の数 n_{fn} , 各要素に与える入力の数 n_{fm} として, 節点の入力値, 部材の入力値をそれぞれまとめた行列 $\hat{\mathbf{v}} = [\mathbf{v}_1, \dots, \mathbf{v}_{n_n}] \in \mathbb{R}^{n_{fn} \times n_n}$, $\hat{\mathbf{w}} = [\mathbf{w}_1, \dots, \mathbf{w}_{n_m}] \in \mathbb{R}^{n_{fm} \times n_m}$ を用意し, 林ら⁵⁾ によって構築された以下の式 (3) を用いて, 部材の特徴量を更新する.

$$\hat{\boldsymbol{\mu}}_i^{(0)} = 0 \quad (3a)$$

$$\hat{\boldsymbol{\mu}}_i^{(t+1)} = \hat{\mathbf{h}}_1 + \hat{\mathbf{h}}_2 + \hat{\mathbf{h}}_3 \quad (3b)$$

$$\hat{\mathbf{h}}_1 = \theta_1 \hat{\mathbf{w}} \quad (3c)$$

$$\hat{\mathbf{h}}_2 = (\theta_2 \hat{\mathbf{v}}) \mathbf{C}_A^\top \quad (3d)$$

$$\hat{\mathbf{h}}_3 = \sum_{k=1}^2 \theta_3 \left(\mathbf{C}_k \mathbf{C}_A^\top \hat{\boldsymbol{\mu}}^{(t)} - \hat{\boldsymbol{\mu}}^{(t)} \right)^\top \quad (3e)$$

ここで, $\mathbf{C}_A$ は, 有向グラフの接続行列の各成分について絶対値をとる行列, $\mathbf{C}_1$ は接続行列の-1成分が1で他が0の行列, $\mathbf{C}_2$ は接続行列の1成分が1で他が0の行列である. また, 重み付けパラメータ $\theta_1 \in \mathbb{R}^{n_f \times n_{fm}}$, $\theta_2 \in \mathbb{R}^{n_f \times n_{fn}}$, $\theta_3 \in \mathbb{R}^{n_f \times n_f}$ を導入し, 隣接するノードと要素の構造特性を統合するために入力に重みを付けしたものと, 隣接行列を使用して部材の特徴量 $\boldsymbol{\mu} \in \mathbb{R}^{n_f \times n_m}$ を更新する.




図 2: 骨組モデル

表 1: 角形鋼管の規格断面リスト

番号	$H \times B$ [mm]	t [mm]	A_i [cm ²]	I_i [cm ⁴]
1	250×250	12	114.24	10812
2	250×250	16	149.76	13731
3	300×300	12	138.24	19144
4	300×300	16	181.76	24511
5	300×300	19	213.56	28233
6	350×350	16	213.76	39835
7	350×350	19	251.56	46087
8	350×350	22	288.64	51988
9	400×400	16	245.76	60503
10	400×400	19	289.56	70229
11	400×400	22	332.64	79483
12	400×400	25	375.00	88281
13	450×450	16	277.76	87315
14	450×450	19	327.56	101610
15	450×450	22	376.64	115295
16	450×450	25	425.00	128385
17	500×500	19	365.56	141181
18	500×500	22	420.64	160522
19	500×500	25	475.00	179115
20	550×550	19	403.56	189890
21	550×550	22	464.64	216265
22	550×550	25	525.00	241719
23	600×600	25	575.00	317448
24	650×650	28	696.64	450108
25	700×700	28	752.64	567450
26	750×750	32	919.04	791214
27	800×800	32	983.04	968045
28	850×850	32	1047.0	1169453
29	900×900	36	1244.2	1550622
30	950×950	36	1316.2	1835368
31	1000×1000	36	1388.2	2153018

表 2: H 形鋼管の規格断面リスト

番号	$H \times B$ [mm]	t_1 [mm]	t_2 [mm]	A_i [cm ²]	I_i [cm ⁴]
1	194×150	6	9	38.11	2630
2	244×175	7	11	55.49	6040
3	294×200	9	12	71.05	11100
4	340×250	9	14	99.53	21200
5	400×200	9	19	110.0	31600
6	450×200	9	22	126.0	45900
7	500×250	9	22	152.5	70700
8	600×250	12	25	192.5	121000
9	650×250	12	25	198.5	145000
10	700×250	12	25	205.8	173000
11	750×300	14	28	267.9	261000
12	800×300	14	28	274.9	302000
13	850×300	16	28	297.8	355000
14	900×300	16	28	305.8	404000
15	950×300	16	28	313.8	458000
16	1000×300	16	28	321.8	515000

表 3: ノード入力項目

Index	Input
1	1 if fixed, 0 otherwise
2	1 at the side, 0 otherwise

表 4: エッジ入力項目

Index	Input
1	1 if column, 0 beam
2	A/A _{max}
3	I/I _{max}
4	L/L _{max}

このように抽出された要素ごとの特徴ベクトル $\hat{\mu}$ を使用して学習を実施する．しかし，全要素に対して式 (3) で求められた $\hat{\mu}$ は，行列のサイズが各解析モデルの要素数によって可変となり，このままでは，NN を通して学習をすることは難しい．このような状況を回避する方法として， L^p ノルム (norm)($p = 1, \dots, 4$)

$$\|x_p\| = (|x_1|^p + |x_2|^p + \dots + |x_n|^p)^{1/p} \quad (4)$$

を使用し，各解析モデルにおける要素数分の特徴量を，各特徴量ごとにすべての要素に対してノルムを行い，各解析モデルにおける n_f 個の特徴量を持つベクトル Q に整理する．

$$Q_1 = (|\mu_{1,1}|^p + |\mu_{1,2}|^p + \dots + |\mu_{1,n_m}|^p)^{1/p} \quad (5)$$

$$Q = \{Q_1, Q_2, \dots, Q_{n_f}\} \in \mathbb{R}^{n_f}$$

5. 予測モデルの構築と精度検証

本研究では，NN を評価器とした学習を行うにあたって， $n_f = 100$ と設定して GE 操作を行う．次に，訓練データをデータ総量の 70%，検証データ 20%，テストデータ 10% に分割する．NN におけるハイパーパラメータは， $N = 4$ ， $k = 256$ で固定し，バッチサイズ = 64, 128, 256，エポック数 = 100, 200 と調整しながら学習を行い予測精度の検証を行う．予測精度とは，予測値 λ^p に対する正解値 λ^r の比 $\lambda = \lambda^p / \lambda^r$ が $0.9 \leq \lambda \leq 1.1$ の範囲に収まっている割合のことを意味する．以下では，これらの指標を用いて予測モデルの精度を検証する．

まず，GE 操作によって得られた解析モデルの特徴量 Q を入力層とした予測モデルの精度を表 5 に示し，その中の各 norm で予測精度が高い値を示したパラメータを代表して抽出し，誤差の収束履歴と予測精度を図 3~4 に示す．

Input Layer: $\{Q\}$
Output Layer: $\{\lambda_{S_a}, \lambda_{S_d}\}$

表 5: 予測精度一覧

	Batch	Epoch	MAE	$\lambda_{S_a}(\%)$	$\lambda_{S_d}(\%)$
L^1	64	100	4.18	56.52	31.22
		200	4.28	57.04	16.78
	128	100	4.43	56.98	21.82
		200	4.57	56.54	30.16
	256	100	4.33	57.22	29.84
		200	4.61	57.40	34.12
L^2	64	100	4.55	55.84	18.86
		200	4.71	55.82	11.34
	128	100	4.53	54.48	25.94
		200	4.57	56.24	29.1
	256	100	4.53	57.56	32.96
		200	4.67	53.32	26.1
L^3	64	100	4.48	58.76	28.84
		200	4.98	58.92	32.24
	128	100	4.76	56.14	32.5
		200	4.64	58.52	27.48
	256	100	4.71	57.32	11.84
		200	4.61	54.74	27.96
L^4	64	100	4.46	57.82	25.12
		200	4.86	52.3	17.8
	128	100	4.64	58.26	31.24
		200	4.77	56.58	26.88
	256	100	4.78	57.5	33.52
		200	4.84	57.92	31.84




図 3: 予測誤差収束履歴


図 4: L^1 norm, batch=256, epoch=200

表 5 を見ると，予測モデルの予測精度は，最大加速度で 55% 前後，最大応答変位で 30% 前後という結果になっている．図 3~4 を見ると，予測誤差は徐々に収束していることがわかる．また，加速度に関する予測精度は 1.0 に収束し，外れ値も最大で 1.6~1.8 倍と小さいが，変位に関しては外れ値が 40 倍と，非常に大きく外れていることがわかる．

次に、解析モデルの節点数 n_n 、要素数 n_m 、層数 F 、スパン数 S 、最高高さ $F_{\max}$ 、最大スパン $S_{\max}$ 、固有モード T を説明変数として追加し、学習を行う。

Input Layer: $\{Q, n_n, n_m, F, S, F_{\max}, S_{\max}, T\}$
Output Layer: $\{\lambda_{S_a}, \lambda_{S_d}\}$

表 6: 予測精度一覧

	Batch	Epoch	MAE	$\lambda_{S_a}(\%)$	$\lambda_{S_d}(\%)$
L^1	64	100	2.16	75.96	47.48
		200	2.28	75.18	50.9
	128	100	2.23	69.58	44.88
		200	2.49	67.78	53.16
	256	100	2.34	75.46	36.74
		200	2.36	75.04	41.24
L^2	64	100	2.24	74.94	58.6
		200	2.67	76.0	49.50
	128	100	2.74	75.86	51.66
		200	2.31	76.3	33.9
	256	100	2.44	70.94	41.08
		200	2.55	75.36	48.62
L^3	64	100	3.12	73.02	46.76
		200	2.41	78.50	38.04
	128	100	2.78	73.24	41.38
		200	2.34	77.48	49.68
	256	100	2.68	76.46	48.38
		200	2.72	76.80	40.08
L^4	64	100	2.23	74.30	47.54
		200	2.98	73.64	40.00
	128	100	2.46	70.52	41.50
		200	2.43	74.26	40.22
	256	100	2.94	77.02	47.56
		200	2.57	77.74	42.92




図 5: 予測誤差収束履歴




図 6: L^2 norm, batch=64, epoch=100

以上の結果から、 λ_{S_a} の予測精度は平均して 75% を出し、 λ_{S_d} に関しても平均して 45% 近い値が出ていることがわかる。また、図 6 に示す加速度、応答変位の予

測精度は、図 4 と同様に応答変位の予測精度は、数十倍外れる値が自然に存在していることがわかる。

6. 結論

本研究では、形状をランダムに変更した鋼構造平面骨組に対して、時刻歴応答解析を用いて得られる応答性状を予測するために、GE を用いて入力サイズの異なる情報から同じサイズの特徴ベクトルを持つ連続変数に整理し、NN を評価器とした解析モデルの応答性状を予測する手法を構築した。以下に得られた知見を示す。

GE 操作によって得られた部材同士の接続関係を考慮した特徴量のみを説明変数とした場合、予測誤差は収束していたが、予測精度はいい結果を示さなかった。理由として、動的解析における建物の応答性状に寄与する情報は、部材同士の接続性のみで表現できないことが原因と考えられる。

部材同士の接続情報のみならず、建物自体が持つ固有モードやそれらに寄与すると考えられる建物高さやスパンを説明変数として組み込むことで、予測精度は向上した。しかし、応答変位の予測精度に関しては、同様に外れ値が大きいため、予測モデルの精度は低いことがわかる。

以上の結果から、GE を利用した機械学習による動的応答予測は、部材の接続関係を考慮した離散構造物の特徴量だけでなく、時刻歴応答解析による構造物の動的性状を考慮した説明変数とすることが、予測精度向上に寄与することがわかった。今後、精度向上のために、教師データを増やすことや、動的性状に影響を与える可能性のある情報を GE を用いて抽出する手法を検討したい。

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】

- 金子健作. 任意階の床応答スペクトルの機械学習に基づく非構造部材の設計支援手法. 日本建築学会構造系論文集, Vol. 83, No. 754, pp. 1757–1765, 12 2018.
- Francois Chollet. *Deep Learning with Python*. Manning Publications, 2017/12/26.
- Diederik P Kingma and Jimmy Lei Ba. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR2015*, 2015.
- M. Zhu, F. McKenna, and M. Scott. Openseespy: Python library for the opensees finite element framework. *SoftwareX*, Vol. 7, pp. 6–11, 2018.1.
- Kazuki Hayashi and Makoto Ohsaki. Graph-based reinforcement learning for discrete cross-section optimization of planar steel frames. *Advanced Engineering Informatics*, Vol. 51, , 1 2022.