

地震応答波形データを用いた深層学習による損傷認識手法

埼玉大学 学生会員 ○王 路遥 埼玉大学 正会員 党 紀
埼玉大学 学生会員 Ashish SHRESTHA 東京理科大学 非会員 王欣

1. はじめに

近年、スマートフォンや安価な MEMS 加速度センサーを用い、構造物の地震時挙動を高密度に観測する研究が数多く行われた。これらのリアルタイムに観測された波形データから、構造物の損傷を検出することは、地震直後の避難や救援の必要性に関する判断には有効な手段である。この場合、建物全体だけでなく、損傷箇所の同定にも極めて重要な役割を果たしている。鋼構造には、部材の破断や座屈によって剛性が低下し、構造全体の傾斜または崩壊まで進行する。しかし、応答特性の識別や波動伝搬法などの従来の構造物の損傷検出手法を使用して局所損傷を認識することは困難である。一方で、破断の一瞬衝撃による波形の変化から、鋼部材の破断を波形から直接目視で認識することは可能である。近年、画像分類およびオブジェクト検出技術の発展につれ、深層学習の一種である畳み込みニューラルネットワーク (CNN) が 2 D 画像データからの特徴抽出において高い性能を有することが知られている。本研究では、CNN モデルを用いて加速度波形から鋼部材の破断を検出する手法を構築した。性能向上の損傷分類器を訓練するためには、膨大な訓練データが必要である。振動台試験などから得られる実データには限りがあり、CNN の訓練に必要な、大量のデータを収集することは困難なため、まずは数値シミュレーションにより生成された大量の加速度波形を使用して CNN の訓練を行い、その後に、18 階の高層鉄骨造建物の振動台試験データで本手法の実現性を検証した。

2. 畳み込みニューラルネットワーク

本研究では、Python の深層学習ライブラリの 1 つである Keras を用いて 1 D CNN モデルを構築した。表-1 に示すように、CNN モデルは、3 つの 1D Convolution-Max pooling-Dropout 層と 2 つの全結合層 (Fully

connected layer) から構成されている。各層のパラメータ数を表-1 に示す。
図-1 に示すように、数値シミュレーションにより生成された加速度波形を訓練セットと検証セットに分け、E-ディフェンスにおいて振動台試験データをテストセットとし、データベースを作成した。また、各データを「無損傷」か「損傷」にラベリングされ、図-2 に例を示す。

表-1 CNN の構成と各層のパラメータ

層構成	出力次元	パラメータ
Conv1D (32x5x1)	196×1×32	192
Max Pooling	98×1×32	0
Dropout (50%)	98×1×32	0
Conv1D (64x3x1)	96×1×64	6208
Max Pooling	48×1×64	0
Dropout (20%)	48×1×64	0
Conv1D (128x1x1)	48×1×128	8320
Max Pooling	24×1×128	0
Dropout (20%)	24×1×128	0
Flatten	3072	0
Fully Connected 1	128	393344
Fully Connected 2	2	258
Total Parameters: 408,322		




図-1 データベース

キーワード 深層学習, 畳み込みニューラルネットワーク, 損傷認識

連絡先 〒338-0825 埼玉県さいたま市桜区下大久保 255 建築構造工学研究室 E-mail : o.r.984@ms.saitama-u.ac.jp




図-2 波形データの例

3. CNN による損傷の分類

訓練データでCNNを訓練し、訓練結果を図-3に示す。図の示すように、訓練精度は最初から迅速的に80%に向上し、最終的な精度は100%という非常に高い精度が得られたことがわかる。




図-3 訓練の結果

4. 振動台実験データによる実現性の検証

梁端部破壊を検出する手法の実現性を検証するために、表-3の混同行列で定義した精度(P)と再現率(R)に示している。また、 t_p 、 f_p と f_n の定義の早見表を表-2にまとめる。表-3に示すように、全部の振動台試験データを正しく分類されていることがわかる。

表-2 判定結果分類の早見表

	判定		
		A	Not A
	A	True Positive(t_p)	False Negative(f_n)
正解	Not A	False Positive(f_p)	True Negative(t_n)




図-4 テストデータで評価した混同行列

表-3 混同行列のパラメータ

	Precision(P) $t_p/(t_p+f_p)$	Recall(R) $t_p/(t_p+f_n)$	No.
損傷	1.00	1.00	20
無損傷	1.00	1.00	20
平均/合計	1.00	1.00	40

5. まとめ

深層学習を用いて加速度波形から鋼部材の破断を検出する手法を構築するため、数値シミュレーションから得られた加速度波形で1D CNNを訓練し、振動台実験データで訓練されたCNNの実現性を検証した。非常に高い精度を得られたが、この分類器により他の実データの適用性を検討する必要があり、これに関しては、E-ディフェンス公開実験データを利用し、さらに膨大なテストセットに拡張する必要と考えられる。

参考文献

- 1) Ashish SHRESTHA, Ji DANG. Bridge Vibration Status Realization Method Using Deep Learning and Smart Device. 第9回インフラ・ライフライン減災対策シンポジウム講演集. 2019.01

謝辞

本研究を行うあたり国立研究開発法人防災科学技術研究所「ASEBI」より、「鉄骨造高層建物の崩壊余裕度の定量化」のデータを使用させて頂きました。