

機械学習を活用した叩き試験による道路橋 RC 床版の異常検知に関する研究

東北大学 学生会員 ○内山 育哉
NIPPO 正会員 渡邊 真一

東北大学 正会員 内藤 英樹
日本大学 正会員 前島 拓

1. はじめに

現在、我が国では社会基盤構造物の老朽化が懸念されている。ハンマーを用いた叩き試験は、熟練技術者でないと異常/正常を判定するのは難しく、技術の継承が課題となっている。これに対して、機械学習を活用することで、各種点検手法、非破壊検査、および構造ヘルスマニタリングの高度化と効率化が期待されている^{1),2)}。

本研究では、模擬空隙によって土砂化を再現した道路橋 RC 床版の試験体に対して、ハンマリングによる叩き試験を行った。打撃時に測定した床版試験体の加速度データに対して、機械学習を用いて損傷箇所の検出を試みた。

2. 実験概要

2.1 叩き試験概要

道路橋を模した RC 床版試験体を作製した。図-1 に示すように、床版厚さを 220mm、アスファルト舗装（密粒度舗装）の厚さを 75mm とした。舗装を施工する際に、床版の 3 箇所において上面に砕石を敷き詰めて、土砂化を模擬した。損傷の大きさは大きい順に 300, 200, 100mm であり以下、損傷大、損傷中、損傷小とする。

訓練データの収集は図-1 に青バツ印と黄バツ印の箇所に対して叩き試験を行ったものである。叩き試験では、打撃点から 2-3cm 程度離れた試験体表面に圧電式加速度センサ（感度: 10 mV/g）を指で押しあてて、打撃による応答加速度を測定した。ハンマリングは 1-2 秒程度の間隔で行った。コンクリート表面の性状によって得られるデータに多少の違いが出ることを考慮して、全く同じ箇所を叩くのではなく 10 回叩いたら 2~3cm 程度叩く箇所を変えらるというように試験を行った。センサの記録時間と実験者の疲労も考慮したうえで叩き試験は 1 セット 200 回程度とし、青バツ印の箇所から 1154 データ、黄色バツ印の箇所から 199 データ、計 1353 データを収集した。

テストデータは床版に設定した側線に対し、100mm

ピッチで側点を設定し、各測点に対し 5 回ずつ叩き試験を行ったものとした。なおこちらのデータは点検者を変えた時の結果がどのように変化するかを確認するため点検者 A の他に B も叩き試験を行った。

2.2 機械学習概要

叩き試験により収集した加速度データを打撃ごとに切り分け、それぞれに関して FFT をおこなった。周波数範囲は 0~10000Hz とし、分解能は 97.7Hz、パラメータ数は 102 とした。得られた周波数スペクトルを基に TensorFlow を使用して機械学習モデルを構築した。図-2 に機械学習モデルの概略図を示す。機械学習モデルは畳み込みニューラルネットワークを使い、訓練データにおいて入力データと圧縮を経て作られた再構成デー




図-1 試験体諸元




図-2 機械学習モデル概要

キーワード コンクリート床版, 叩き試験, 機械学習, 異常検知

連絡先

〒980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-06, TEL:022-795-7449

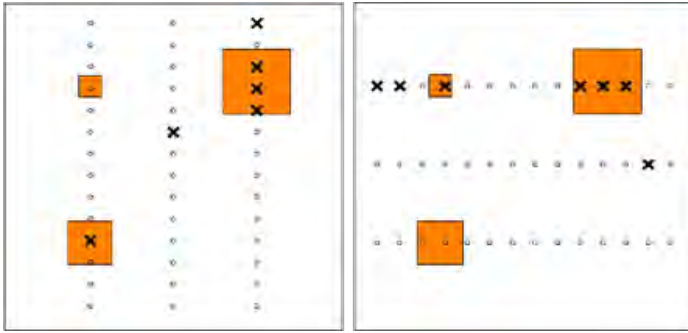


図-3 側線の結果(点検者 A)

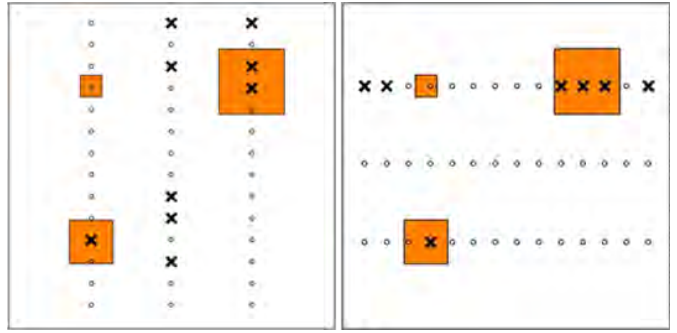


図-4 側線の結果(点検者 B)

タの差である絶対再構成誤差が小さくなるように学習を行った。各種パラメータに関してフィルターは 32, スライドは 2, カーネルサイズは 7, 活性化関数は隠れ層が ReLU, 出力層は sigmoid, 最適化手法は Adam, 学習率は 0.001, 損失関数は mse, バッチサイズは 32, エポック数は 300 とした。また各打撃に対し異常度を算出するが, 異常度の定義は絶対再構成誤差の面積を再構成データ面積で除したものとした。

機械学習から得られた異常度に対し, 閾値を用いて測点の健全/損傷判定を行った。この際, 閾値は訓練データのばらつきにより評価する手法をとり, 訓練データの異常度に関して上位 1%値を閾値とした。

最後に閾値に基づく性能評価を行った。

3. 結果と考察

結果に関して, 側線における測点の判定結果を図-3と図-4に示す。図に関して損傷と判断したものは測点に×印を, 健全と判断したものには測点に○印を書いた。今回叩き試験において叩く位置のずれを考慮して, 健全部と損傷部の境界から設定した側点の距離が 30mm 未満の測点に関しては境界部とし, 正解率等を算出する際には除外した。また端部に関しても端から 100mm の測点を端部とし, 境界部と同様に扱った。

全体の正解率は 90.9%で概ね検知出来ると考える。具体的に損傷大の再現率は 100%, 損傷中は 75%である。一方で損傷小に関して再現率は 25%であり, 検知できない結果となった。損傷小の箇所においては, 機械学習モデルにより出力された再構成データが入力データとかなり近いグラフとなっていて, モデルが学習した特徴量空間からの逸脱度は小さかった。よってこのモデル及び叩き試験の適用限界と考えている。参考のために図-5に損傷大における入出力データの比較図を示す。損傷大では, データがうまく再構成出来ないため, 異常検知が可能であった。また端部において判定を誤るケ




図-5 損傷大における入出力データの比較

表-1 評価指標

	適合率	再現率	F値
健全	99.1	93.0	95.9
損傷	61.9	92.9	74.3

注釈：端部, 境界部, 損傷小のデータを除いた

ースが多いが, こちらは端部の反射の条件によるものかつ端部も場所によって特性が違うことが起因していると考えている。最後にこの結果から導出される適合率, 再現率, F 値を表-1に示す。

4. まとめ

本研究では, 模擬空隙によって土砂化を再現した道路橋 RC 床版の試験体に対して, 叩き試験を行った。得られた加速度データに対して, 機械学習を用いて損傷箇所の検出を試みた。結果として, 床版厚さと同程度以上の空隙の大きさであれば床版内部の異常を検知できる可能性が示された。今後はリアルタイム診断など更なる点検の効率化と高精度化検討に取り組む予定である。

【参考文献】

- 1) 稲葉紅子, 谷川光, 内藤英樹: 機械学習を活用した鉄道用軌道スラブの打音検査の高精度化に関する研究, 第 27 回舗装工学講演会, 2022
- 2) 新保弘, 溝渕利明, 尾関智子, 野嶋潤一郎: 機械学習による打音探査の定量化に関する検討, AI・データサイエンス論文集, Vol.1, No.J1, pp.522-529, 2020