

機械学習による打音検査の画像識別の基礎的検討

福島工業高等専門学校 学生会員 ○土屋 裕 福島工業高等専門学校 学生会員 飯高 優翔
 福島工業高等専門学校 学生会員 馬場 那仰 福島工業高等専門学校 正会員 江本 久雄
 福島工業高等専門学校 正会員 浅野 寛元

1. はじめに

近年、わが国において供用年が 50 年を経過した構造物が急増しており、老朽化による劣化・損傷が顕著に現れてきた。この状況に対し道路橋においては国土交通省により、5 年に 1 回の近接目視点検が義務付けられている¹⁾。また、近接目視点検のみでは構造物内部の異常を検知することができないため非破壊検査の 1 つである打音検査が同時に行われている。しかし、打音検査は点検者の感覚に基づく手法であるため、定量的な結果が得られない。そこで、本研究では打音検査を定量化するために得られた打音の周波数成分をグラフ描画し、畳み込みニューラルネットワーク (CNN) を用いて画像識別可能かどうかの検討を行った。

2. CNN 及び転移学習について

本研究で用いる CNN^{2), 3)}とは、畳み込み層とプーリング層、全結合層などから構成されるニューラルネットワークである。CNN では画像の特徴量を抽出した後に特徴マップを作成し、集約することで重みを決定する。近年、CNN は画像認識や音声認識の分野で注目されている。本研究では、音色の特徴を示す周波数スペクトルに打音を識別するための特徴があると考え、周波数スペクトルを描画した画像に対し、CNN を適用した。また、学習および検証に使用するデータが、CNN の適用事例としては少なく、データの性質上水増しができないため、学習の効率化と識別精度の向上を目的として、転移学習を用いた。

転移学習^{3), 4)}とは、既に学習済みのモデルの重みを、他のニューラルネットワークに適応させた上で再学習する手法である。転移学習は、手元にあるデータセットが少ない場合において、有効な手法として知られている。転移学習を用いた際の利点として、比較的少ないラベル付きデータからモデルを学習できること、学習時間と計算リソースを大幅に削減できることが挙げられる。故に、転移学習は今日までに、物体検出、画像識別、音声認識の分野で成果をあげている。そこで、転移学習によるニューラルネットワークの構築を行い、画像識別を試みた。

3. 機械学習による画像識別の手順

3.1 打音データに対する前処理

本研究では、いわき市内のコンクリート構造物において採取した打音データを用いた。測定箇所は 50 箇所であり、それぞれ健全部と異常部において、技術者による点検結果を基に 5 打音ずつ録音したものである。

初めに、学習の簡易化と画像識別結果の精度向上を目的として、グラフ描画した際の周波数領域及び画素数を統一した。本研究では、周波数の描画領域を 0Hz~10000Hz、画素数を 545×213 ピクセルに統一した。また、振幅スペクトルは最大値で除して 0~1 に正規化している。

上記の操作を行った健全部 246 個、異常部 242 個、合計 488 個のラベル付き打音データを機械学習に使用した。図-1 に健全部の周波数スペクトルの一例を示す。図-2 に異常部の周波数スペクトルの一例を示す。ここで、図-1 及び図-2 は同一構造物から採取した打音データである。

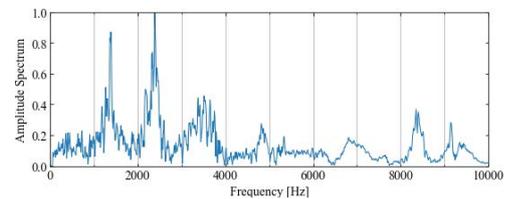


図-1 健全部の周波数スペクトル

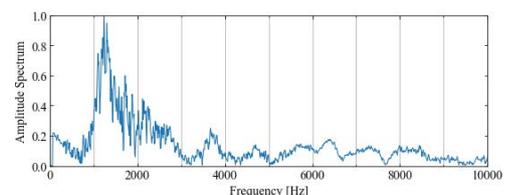


図-2 異常部の周波数スペクトル

3.2 識別モデルの構築

本研究では、事前に CNN での識別可能性について検討してみた。しかし、周波数領域を変更して種々シミュレーションしたが、その精度は5割程度だったため転移学習による識別を試みた。転移学習の識別モデルの構築にあたり、Karen Simonyan と Andrew Zisserman によって開発された学習済みモデルである VGG16⁴⁾を使用した。VGG16 は13層の畳み込み層と、3層の全結合層の合計16層から成る畳み込みニューラルネットワークで構築され、ImageNet データベース(140万枚のラベル付き画像と1000個のオブジェクト)から訓練されたモデルである。本研究で VGG16 を採用した理由として、広範囲のイメージに対する豊富な特徴表現を学習していることが挙げられる。

続いて打音データの学習及び検証には、Python のライブラリである tf.keras を用いた。3.1 節で作成した 488 個のラベル付き打音データを train(訓練データ:9割)と validation(検証データ:1割)に振り分け、VGG16 を基に、打音データの特徴を学習し、ネットワークの重みとバイアスを更新する識別モデルを構築した。

4. 学習条件と学習結果

3.2 節で構築した識別器を用いて、同じ学習条件において計3回(No.1～No.3)の学習を行った。学習結果として train(訓練データ)及び validation(検証データ)の正解率(accuracy)、損失値(loss)が得られた。本研究では、No.1～No.3 全てにおいて正解率が約80%、損失値が約0.4となった。図-3に識別モデルの学習結果を示す。

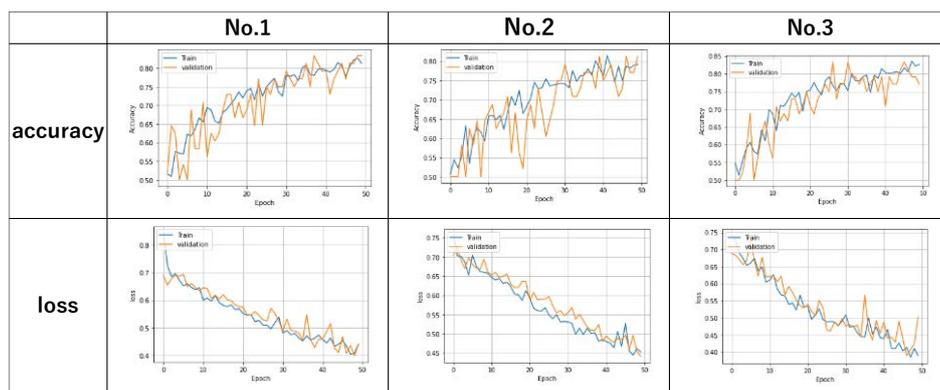


図-3 識別モデルの学習結果

5. まとめ

本研究では、機械学習の一つである畳み込みニューラルネットワークを用い、打音の周波数成分をグラフ描画したものが画像識別可能かどうかの検討を試みた。VGG16 を基に作成した識別器を用い、No.1～No.3 全てにおいて正解率が約80%、損失値が約0.4%を得ることができた。これより、機械学習による打音検査の画像識別が可能であることが分かった。

今後の課題として次の事柄が挙げられる。一つ目は最適な周波数領域の決定である。本研究では周波数領域を0Hz～10000Hzで統一しているが、周波数領域を変えることで、識別する画像の概形が変化する。そのため、画像識別に適した周波数領域が存在するのではないかと考える。二つ目は最適な画素数の決定である。本研究では、画素数を545×213ピクセルで統一したが、画素数を変えることでも、識別する画像の概形が変化する。そのため、画像識別に適した画素数が存在すると考える。

参考文献

- 1) 国土交通省：道路法施行規則（昭和二十七年建設省令第二十五号）、
<https://elaws.egov.go.jp/search/elawsSearch/elaws_search/lsg0500/detail?lawId=327M50004000025>（入手2021.1.19）。
- 2) 佐々木俊介，陳奎延，馬場孝明：畳み込みニューラルネットワーク(CNN)を用いた手書き日本語文字認識システムの試作，第68回(平成27年度)電気・情報関係学会九州支部連合大会，pp.348, 2015。
- 3) 斎藤健毅：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，pp.205-210, pp.254, 2016。
- 4) François Chollet：Python と keras によるディープラーニング，株式会社マイナビ出版，pp.149-158, 2018。