

畳み込みニューラルネットワークを用いた構造物の損傷判別システムの構築

日大生産工(学部) ○大信田 憲進 日大生産工(院) 工藤博政
日揮株式会社 門 万寿男
日大生産工 高橋 亜佑美

1. まえがき

現在我が国では、高度経済成長期に集中的に建設された社会インフラ構造物の老朽化、経年劣化が社会問題となっている。構造物の劣化度を判断する検査方法としては目視検査や打音検査、超音波や放射線を用いた検査など多岐にわたる。この中で打音検査に着目検討を進める。打音検査は高価な機器を使用せず、短時間で検査できる手法であるが、判断には検査員の技量によるものが大きい。この判断をAIでできるようになればだれでも判断が可能になり、危険な状態の構造物を減らしていくことができると考えた。これまで、道路橋RC床版に設置した光ファイバセンサを用いた劣化度評価手法の提案¹⁾やICTやAIを活用した評価手法²⁾、畳み込みニューラルネットワーク(以下CNNとする)を用いた打音検査³⁾が提案されている。当研究室の研究では、1種類の木材の振動波形をCNN手法で学習させて検証や損傷判別するモデルの構築を行っている。今回は、複数の木材でも同じように検証、損傷判別ができるのか、結果を確認するものである。

2. 提案手法

構築するニューラルネットワークの推論の精度を確認できる根拠となるものを作成する必要がある。そのため、今回は正解のラベルとCNNが出力した値を混合行列として評価する方法を検討する。また、今回はCNNの既存モデルとなるvgg16を用いるが、入力データから推測できているかの信憑性を上げるため、学習済みのモデルと非学習モデルに0から学習させた場合の2種類の結果をとる。これまでに実施した検証は、1種類の木材の検証のみであったため、種類の異なる木材の検証を行う。また、複数の木材を学習させ木材ごとの判断も可能かを検証して、多種類の木材に適用できるかを検証する。

3. 実験方法および測定方法

3.1. 試料準備

振動波形データの収集をするために木材を準備する。杉やホウソウ、ヒノキの3種類のものを使い、寸法は縦500mm、横105mm、厚さ30mmで統一してそれぞれ傷なし(Fig1の左)、傷あり1(Fig1の中央)、傷あり2(Fig1の右)の3個の木材を用いる。



Fig.1 木材の傷処理

傷あり1は木材の中央部分に直径10mmの穿孔と横側に上下10mm離れた位置に同様の穿孔を施したものである。傷あり2は、中央の穴から上下側に10mm離れた部分にも同様の穿孔をしたものである。

3.2. 計測方法

この木材の中央から横側に50mm離れた位置に加速度の検査機を設置し、ハンマを用いて木材を叩き振動波形データをPCに取得して実験を行う。この際、5秒ごとに叩いて計測するがこれは、叩いた後の振動が収束し、次の打撃波形と混ざらないデータを取得する。



Fig.2 加速度検査機(左)と実験時の状態(右)

Development of Structural Damage Detection System for Structures Using
Convolutional Neural Networks

Kenshin Ohshida, Hiromasa KUDO, Masuo KADO and Ayumi TAKAHASHI

3.3. データ処理

収集した振動波形データはWavelet変換によりスカログラム化して画像とする。




Fig.3 処理前後のスカログラムデータ

スカログラムは時間と周波数の関数としてプロットされたwavelet変換の絶対値を示したものである。横軸が時間で縦軸が周波数、色がスペクトルの大きさをカラーグラデーションで表している。青が小さく暖色が大きい値を示している。Fig3の左の画像データだと特徴がある黄色部分がわかりにくい。既存研究からCNNにデータ入力前に前処理を行うと精度がよくなることがわかっているため、Fig1の画像は黄色の部分から後0.1秒間を取る波形を切り出しスカログラムで表したものである(Fig3の右の図)。

3.4 CNNモデル

(a)本研究では、モデルとしてVGG16を使用する。




Fig.4 vgg16 モデル図

(b)vgg16は畳み込み層13層＋全結合層3層の敬16層のニューラルネットワークである。3×3のフィルタを用いておりこれを複数回通した後に最大値プーリングを行い、サイズを半分にする流れを5回するものとなる。vgg16の利点はフィルタが3×3のみ使用しており、パラメータが少なくなるような処理をしているため、画像認識精度向上のために層を増やすときのデメリットとなるパラメータの増加を削減できることにある。

4. 実験結果および検討

4.1 データセット

今回のデータセットは杉とホワイトウッド(ww)、ヒノキの3種類のものを用意して、そこから2種類ずつを組み合わせたものと3種類すべてを含んだものの7セットを用意した。収集したデータの9割を学習データとして学習させ、残りの1割をテストデータとしている。

4.2 実験結果

表.1 vgg16 による精度および損失関数の結果

木の種類	非学習のものを使用し学習		学習済みのものをトレーニング	
	acc	loss	acc	loss
sugi	1.000	0.000	1.000	0.006
ww	0.950	0.134	1.000	0.004
hinoki	1.000	0.000	1.000	0.001
sugi&ww	0.994	0.010	0.983	0.039
sugi&hinoki	1.000	0.000	1.000	0.002
ww&hinoki	0.983	0.096	0.992	0.025
all_tree	0.978	0.154	0.961	0.056

表1がCNNを使用した結果となる。0から学習させたものと学習済みもので分かれており、それぞれに精度をacc,損失関数をlossと表記している。




Fig.4 混合行列で精度を示したもの

Fig4はホワイトウッドとヒノキのデータを表したもので白色の部分該当数が少なく、青色部分が該当数の多いものとなる。横軸がCNNの判定したクラス分類で縦軸が正解ラベルの値となる。今回の場合、対角成分が同じラベルの結果となる。

5. まとめ

5.1 まとめ

①異なる木材での結果は学習済みモデルと0から学習したもので大きく差のあるものはなく、複数の木材を使用して学習からテストまで行っても判別ができていることがわかる。

②混合行列は、Fig4の結果はホワイトウッドとヒノキの混合行列を示している。表1の結果から精度0.983であるため、**damage3**のものを**damage0**と判別しているものが1つ、**damage5**のものを**damage0**と判別しているものが1つあり評価結果と整合している。

5.2 今後の展望

CNNでの検証の場合、学習に使用した種類の木材と異なる木材をテストデータに使用すると精度が著しく下がるという結果が出ている。解決方法として対象データの関係性を把握し処理をするVision transformerを用いれば解決できる可能性がある。Vision transformerはCNNの画像分析手法よりも少ない学習データで判別が可能であるため、導入できればもう1つの課題である学習データ数の削減も期待できる。

参考文献

- 1) 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検査の定量化に関する検討”,AI・データサイエンス論文集,2020年1巻J1号 p. 522-529
- 2) 門 万寿男,前島 拓,子田 康弘, 中野 聡, 藤山 知可子,岩城 一郎,”RC床版の疲労損傷度評価手法に関する研究”,土木学会論文集 E2(材料・コンクリート構造),2015年 71巻4号 p.323-337
- 3) 工藤博政,門万寿男,高橋亜佑美,””機械学習を用いた振動波形の分類に関する研究”,日本機械学会関東支部 第30期総会・講演会講演論文集 [No.240-1]