

令和 4 年 6 月 3 日現在

機関番号：56203

研究種目：若手研究

研究期間：2019～2021

課題番号：19K15253

研究課題名（和文）ディープラーニングを活用した打音検査ハンマーの振動判別技術の開発と効果の検証

研究課題名（英文）A study of vibration classification in hammering inspection by using deep learning

研究代表者

岩本 直也（Iwamoto, Naoya）

香川高等専門学校・電子システム工学科・講師

研究者番号：10631046

交付決定額（研究期間全体）：（直接経費） 2,100,000円

研究成果の概要（和文）：打音検査においてハンマーに発生する振動波形から深層学習を用いて異常の有無を判断できるのではないかと考え研究を行った。市販のコンクリートブロックを試験体として使用し、特徴的な二つの領域をハンマーで打撃し振動波形を測定した。この振動波形からFFTスペクトルやSTFTスペクトログラムを生成し、それぞれを入力データとして深層学習モデルを学習させた。その結果、テストデータに対する学習済みモデルの精度はSTFTを入力データとして学習させた場合に最も高くなり平均で95%程度となることが分かった。

研究成果の学術的意義や社会的意義

高度経済成長期に建設された道路や建物などの建造物の多くは、老朽化が進んでおり、突然の崩壊崩落といった重大事故のリスクを抱えている。例えば、国内には約72万基の橋梁が存在し、2030年にはその半数以上が建設から50年以上を経過する。これに対し国土交通省は全ての橋梁について5年毎の定期点検を義務付けている。定期点検は近接目視点検を基本とし必要に応じて打音検査が行われる。打音の聞き分けには熟練を要するが、熟練の検査員を十分に確保することは容易ではない。この問題に対し本研究では打音検査において熟練の検査員に頼ることなく高精度な異常検出を実現しようとするものである。

研究成果の概要（英文）：A deep neural network based hammering inspection method has been studied. Vibration signals induced in the hammer by hitting two specific areas of a concrete brick are measured. FFT spectra and STFT spectrograms are extracted from the vibration signals. Deep neural network models are trained with either the vibration signals, the FFT spectra or the STFT spectrograms. The model trained with the STFT spectrograms can classify the two specific areas at a high accuracy around 95%.

研究分野：深層学習技術の応用

キーワード：打音検査 深層学習

1. 研究開始当初の背景

高度経済成長期に集中的に建設された道路や建物などの建造物の多くは、老朽化が進んでおり、突然の崩壊・崩落といった重大事故のリスクを抱えている。例えば、国内には約 72 万基の道路橋（橋梁）が存在し、2030 年にはその半数以上が建設から 50 年以上を経過する。これに対し国土交通省は、全ての橋梁について、その管理者に 5 年に一度の定期点検を義務付けている [1]。定期点検は近接目視による外観検査を基本とし必要に応じて打音検査が行われる。

打音検査は、検査対象物にハンマーを打ち付け、発生する打撃音を点検員が聴き分けることで外観検査では分からない内部の異常を検知する手法である。点検員 1 名とハンマー 1 本で実施できることから単純で利便性が高い反面、評価基準が点検員の主観や熟練度、周囲の騒音や反響等に依存し客観性に欠けるという問題がある。したがって打音検査を適切に行うためには熟練の点検員の確保が不可欠である。しかし国内の橋梁の 70%以上を管理する地方自治体等にとってそれは容易なことではない。

これに対し、点検員に頼ることなく打撃音をデータ解析することで点検の客観性を高めようとする研究が数多く行われてきた [2]。これらの研究の多くは、周波数解析等を用いて人間が特徴量を抽出し、さらに異常の有無等を判定するための基準を決定するという方式がとられている。

一方、近年では深層学習技術を中心とする人工知能技術の発展により、特徴量の抽出方法や判定基準（分類基準）を機械的に最適化することが可能となった。特に、画像認識の分野においてはすでに人間よりも高い精度が得られている [3]。したがって、打音検査における異常の有無の判定においても深層学習技術の活用が期待される。

2. 研究の目的

本研究では深層学習を活用した打音検査システムを開発し、その効果を検証する。上述したとおり、従来の打音検査には客観性に欠けるという大きな問題がある。これを解決するために、マイクを用いて打撃音を収録し、周波数解析により異常を検出するという手法や装置が多数提案されている。しかしながら、この場合も周囲の騒音の影響を受けることや、音の発生源とマイクの距離を一定に保つことが難しいといった問題が残されている。

そこで本研究では振動センサを搭載したハンマーを開発しハンマーの振動を測定することで、打撃音ではなくハンマーの振動から異常の有無を判断できないか検証する。ハンマーの振動を測定対象とする場合は、周囲の騒音の影響を排除でき、さらに振動源とセンサの距離を常に一定に保つことができるという点で非常に有利である。また、検査対象物となるコンクリート等の材料は、気温や湿度等の周辺環境によりその特性が変化するものと考えられる。このことから、ハンマーの振動を測定する際の気温や湿度などの周辺環境データを測定する。振動データに周辺環境データを加えて深層学習を行うことで異常判定の精度が高められるのか検証を行う。

3. 研究の方法

本研究では試験体として図 1 に示すコンクリートブロックを使用した。このコンクリートブロックの一方の面内において、下部に空洞のある部分を「領域 A」、空洞の無い部分を「領域 B」とし、これらを打撃した際のハンマーの振動状態から二つの領域を正しく見分けることを目的とした。ハンマーの振動測定には圧電素子を利用し、図 1 に示すように ABS 樹脂製のジグを用いてハンマーに固定した。

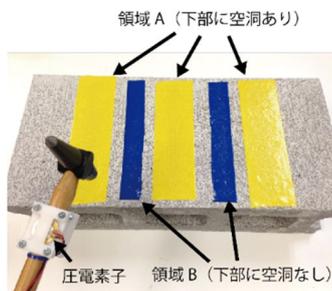


図 1 試験体のコンクリートブロックと圧電素子を取り付けたハンマー

振動測定装置の構成を図 2 に示す。ハンマーで打撃した際に発生する振動に応じて圧電素子に電荷信号が発生する。これをチャージアンプを介して電圧信号に変換し、データロガーを用いて PC で記録する。チャージアンプは Measurement Specialties 社製の Piezo Film Lab Amplifier を使用し、100 Hz から 1000 kHz のバンドパスフィルタを適用した。またデータロガーは National Instruments 社製のマルチファンクション DAQ USB-603 を使用し、サンプリングレート 20 kHz、最小分解能 0.32 mV で電圧信号を測定した。

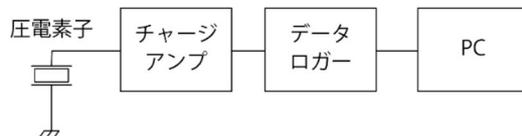


図2 振動測定装置の構成

領域 A および領域 B をハンマーで打撃した際に測定される振動波形（電圧信号）についてそれぞれ無作為に抽出した 10 波形を図 3(a)および(b)に示す。両者は非常によく似ており人間がこれらの違いを見極めることは非常に困難である。このような振動波形を領域 A および領域 B に対してそれぞれ 100 回ずつ測定し、この測定を日時を分けて合計 42 回行った。

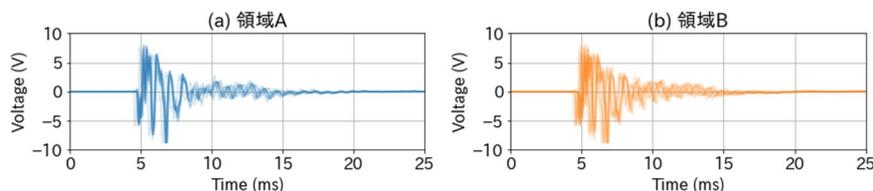


図3 測定される振動波形の例，(a)領域 A，(b)領域 B，ランダムに抽出した 10 波形を表示

日時を分けて測定を行った理由としては、コンクリートの特性が気温や湿度、気圧などの周辺大気の状態によっても変化し、振動波形に影響を及ぼす可能性があるためである。打音検査の実用性を考えると、天候や季節などが変化したとしても正しく異常個所を判断できる必要がある。したがって本研究でも振動波形だけでなくこれらの周辺大気の状態のデータを含めて深層学習を行う必要があるのではないかと考えた。

そこで振動波形の測定を行う際に卓上温湿度計 testo622 を用いて気温、湿度、気圧のデータを測定し記録した。42 回の測定における気温、湿度、気圧の分布を図 4 に示す。

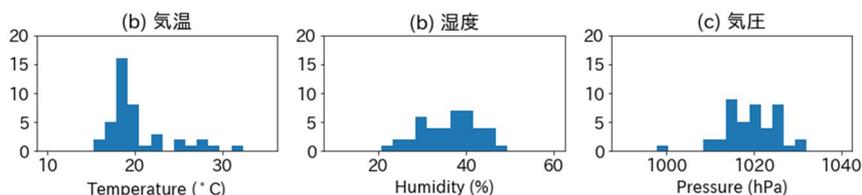


図4 振動波形測定時の周辺大気条件の分布，(a)気温，(b)湿度，(c)気圧

深層学習においては使用するデータに前処理を施すことでより良い結果が得られる場合がある。そこで本研究においても、図 5 に示すような前処理による効果の検証を行った。図 5(b)は図 5(a)の元波形全体を高速フーリエ変換 (FFT) することによって得られるスペクトルであり、図 5(c)は短時間フーリエ変換 (STFT) によって得られるスペクトログラムである。測定したすべての振動波形データに対して、FFT スペクトルおよび STFT スペクトログラムを生成し、深層学習に利用した。

また、気温、湿度、気圧のデータは値のオーダーが互いに大きく異なるため、深層学習に悪影響を与える可能性がある。このような場合は、データを標準化（平均 0、分散 1 の分布となるようリスケール）する機会が多いことから、本研究でも図 6 に示すように標準化後のデータを深層学習に用いることとした。

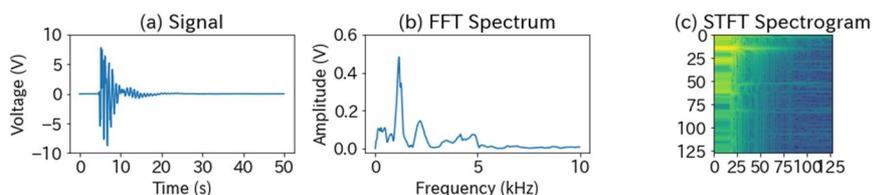


図5 振動波形の前処理，(a)元の振動波形，(b)FFT スペクトル，(c)STFT スペクトログラム

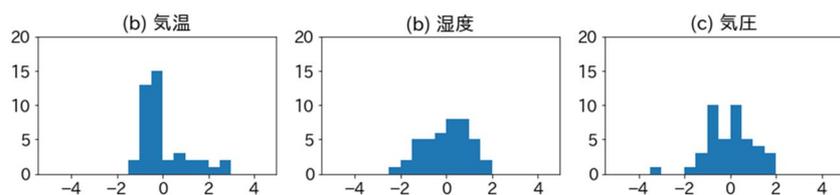


図6 標準化後の周辺大気条件の分布，(a)気温，(b)湿度，(c)気圧

以上のデータを入力データ 1 および入力データ 2 として表 1 に示すように 6 種類に組み合わせ

せ、深層学習を行うことで前処理の効果および周辺大気条件データの影響について検証した。

表 1 . 深層学習に使用した入力データの組み合わせ

		入力データ 2	
		なし	大気データ
入力データ 1	振動波形	1-1	1-2
	FFT スペクトル	2-1	2-2
	STFT スペクトログラム	3-1	3-2

深層学習のプログラムは TensorFlow と呼ばれる深層学習用フレームワークを用いて実装した。学習に使用した深層学習モデルの簡略図を図 7 に示す。図 7 の CNN は畳み込みニューラルネットワークを表し、入力データ 1 が振動波形または FFT スペクトルとなる場合（表 1 において 1-1, 1-2, 2-1, 2-2 の場合）は 1 次元の畳み込み層やプーリング層で構成されている。入力データ 1 が STFT スペクトログラムの場合（表 1 において 3-1, 3-2 の場合）は 2 次元の畳み込み層やプーリング層で構成されている。図 7 の MLP は多層パーセプトロンを表し、全結合層とドロップアウト層で構成されている。また入力データ 2（大気データ）を使用しない場合（表 1 において 1-1, 2-1, 3-1 の場合）は図 7(a) のモデルを、入力データ 2 を使用する場合（表 1 において 1-2, 2-2, 3-2 の場合）は図 7(b) のモデルを使用した。

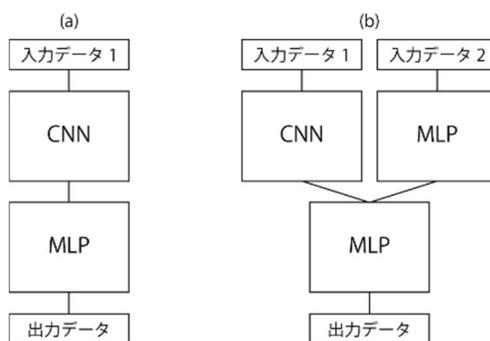


図 7 深層学習モデルの簡略図

また深層学習モデルの性能を評価するために交差検証を行った。図 8 に示すように、42 回に分けて測定したすべてデータのうち、41 回分の測定データ（8200 波形）を学習データとしてモデルの学習を行い、残りの 1 回分の測定データ（200 波形）をテストデータとして学習済みモデルの性能評価を行った。これを学習と評価の 1 セットとし、テストデータを変えながら 42 セット行った。

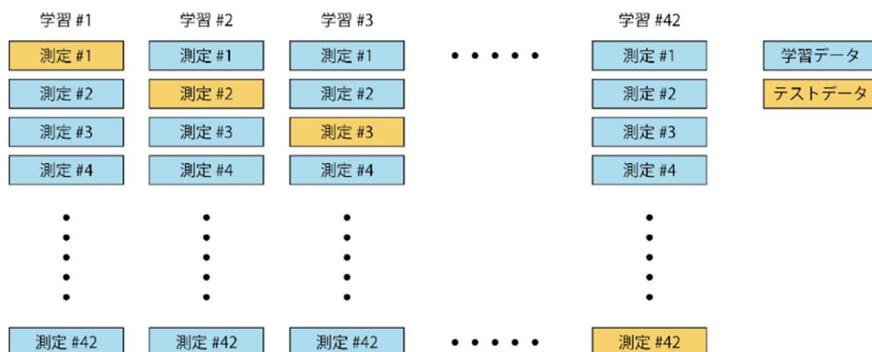


図 8 交差検証のためのデータの組み合わせ

深層学習モデルの評価指標としては表 2 に示す混同行列から式 1 で計算される正解率を使用した。

表 2 . 混同行列

		モデルの予測	
		領域 A	領域 B
正解	領域 A	TP	FP
	領域 B	FN	TN

$$\text{正解率 (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

4. 研究成果

表 1 に示した 6 組の入力データの組み合わせについて、図 8 に示す交差検証によって、学習と評価をそれぞれ 42 セットずつ行い、テストデータに対するモデルの予測精度の分布を求めた。結果を図 9 に示す。入力データ 1 として STFT スペクトログラムを使用する 3-1 および 3-2 の場合に正解率の平均値が最も高くなり 95.8%であった。一方、入力データ 1 として振動波形や FFT スペクトルを使用する場合は正解率の平均値は 77-80%程度であるが、個々の正解率は広い範囲に分布することが分かった。また、1-1 と 1-2、2-1 と 2-2、および 3-1 と 3-2 をそれぞれ比較した場合に正解率の平均値や分布に有意な差は見られないことから、周辺大気状態データを入力データ 2 として使用することによる効果は非常に少ないと考えられる。

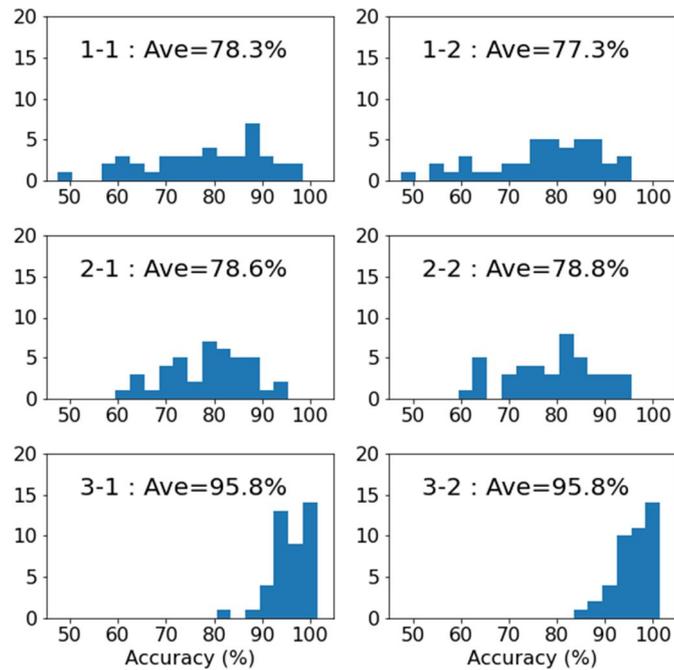


図 9 入力データの組み合わせとモデルの予測精度の分布の関係

以上のことから、深層学習を用いた振動波形の分類タスクにおいては、振動波形や FFT スペクトルを入力データとして用いるよりも、STFT スペクトログラムを用いた方が高精度な学習済みモデルを得られることが示唆された。

- [1] 国土交通省道路局，路橋定期点検要領，https://www.mlit.go.jp/road/sisaku/yobohozen/tenken/yobo4_1.pdf
- [2] (例えば) 神内教博ほか，土木学会第 67 回年次学術講演会 VI-247, 2012.
- [3] O. Russakovsky et al.: "ImageNet Large Scale Visual Recognition Challenge", arXiv:1409.0575v3 (2015).
- [4] TensorFlow, <https://www.tensorflow.org/>

5. 主な発表論文等

〔雑誌論文〕 計0件

〔学会発表〕 計0件

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
--	---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------