

25. 打音検査を用いたアスファルト内部欠陥検出への AI 手法導入に関する実験報告

立命館大学
立命館大学
大林道路株式会社

○佐々木 優一
横山 隆明
光谷 修平

1. はじめに

道路維持管理の課題の一つにアスファルト舗装のポットホール対策がある。雨水の浸透等により進行する舗装内部の損傷は、路面上から発見することが困難であり、ある日突然、表層の一部が崩壊してポットホールとなり、騒音振動や水はねの原因となるほか、通行車両の走行安全性を著しく低下させる¹⁾²⁾。このため、舗装内部の損傷をなるべく早期に、できればポットホール化する前に非破壊で検知する方法が求められている。この損傷検知方法として、簡便かつ低コストで実施可能な非破壊試験法である打音検査が用いられている。しかし、打音検査はハンマーの使用方法や打撃音の判断に熟練を要するという短所を有しており、また近年では人口減少に伴う建設技術者の不足も問題となっている。そのため、検査員の経験や感覚に依存せず、経験の浅い者でも実施可能な打音診断システムの構築が必要であると考えられる。

本研究では、打音検査結果の判定を AI で分析することにより、損傷有無の判断をサポートする打音診断システムを構築し、表層下に模擬的に損傷部を配置した実験舗装に対して打音試験を行い、その妥当性を検証した。

大林道路株式会社技術研究所にて供試体を作成した。供試体の寸法・構成は、コンクリート平板（300mm×300mm×50mm）に損傷を模擬した円形の窪み（ $d: \phi 0, 50, 100, 150\text{mm} \times h: 5\text{mm}$ ）を設け、その上部に阪神高速道路仕様の基層用アスコン 35mm で構成した。実際の舗装にはこの上に厚さ約 40mm の表層があるが、本研究試験では省くものとした。使用したコンクリート及びアスコンの配合表を表-1、表-2 に示す。

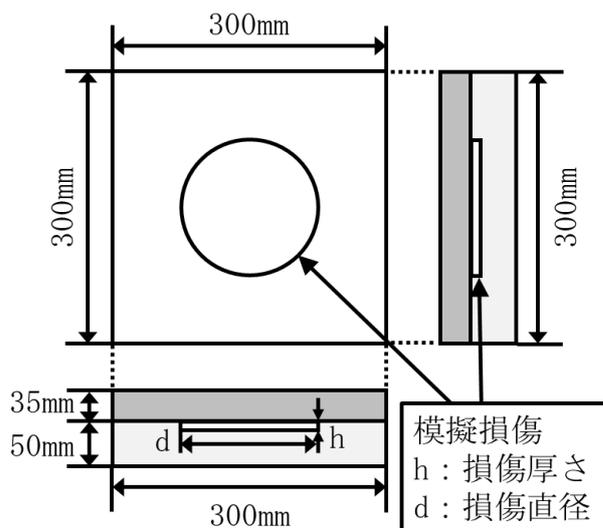


図-1 供試体概要図

2. 実験概要

2.1 供試体・打音収録器具

実験では、コンクリート床版上の舗装を念頭に

表-1 コンクリートの配合

W/C (%)	s/a (%)	単体量(kg/m ³)						混和剤量(g/m ³)	
		C	W	S1	S2	G1	G2	AS	AE
55.0	45.0	304	167	242	575	507	504	3435	5.3

表-2 アスコンの配合

単位 %						
6号碎石	7号碎石	SCR	碎石	細砂	石粉	As
34.9	18.9	8.5	14.2	13.2	4.7	5.6

打音データは、重量 133.5g、頭口径 18mm のハンマーで打撃し、周波数範囲：20Hz～20kHz、正面感度：-34dB±30% (1kHz)、負荷インピーダンス：≥1000Ω、S/N 比：78dB の単一指向性コンデンサーマイクロフォンにより収録した。

2.2 損傷検出システム構築手法

損傷検出システムを構築するために、打音検査結果の Deep Learning (DL) を行った。DL は、人工知能の要素技術の一つで、人間が自然に行うタスクをコンピュータに学習させる機械学習の手法の一つである。人間の神経細胞の仕組みを模したシステムであるニューラルネットワーク (NN) の隠れ層 (図-2 参照) を多層にして用いることで、データに含まれる特徴を段階的により深く学習することが可能となる。多層構造の NN に大量の音声データを入力することで、コンピュータのモデルはデータに含まれる特徴を各層で自動的に学習する。これにより DL のモデルは極めて高い精度を誇り、近年の進歩により人間の認識精度を超えるまでとなっている³⁾。

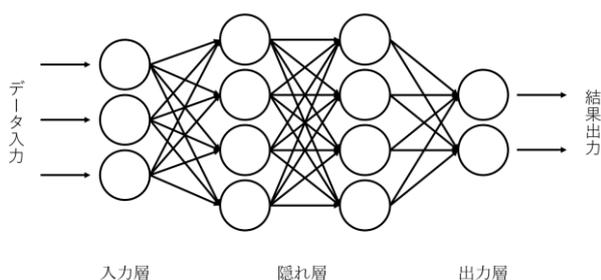


図-2 DL の概念図

本実験で実施する DL の流れを図-3 に示す。それぞれについて、以下に順に説明する。

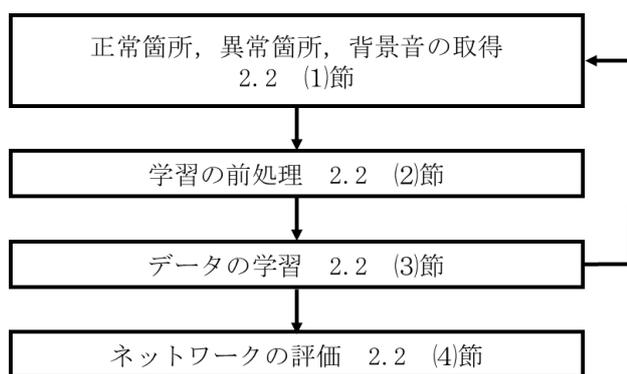


図-3 本研究で実施する DL の流れ

(1) 正常箇所, 異常箇所, 背景音の取得

サンプリング周波数 f_s は 8820Hz で行い、判定に使用する信号長を 0.25s、検出する最少のピークの高さを 0.05 (max は 1) とした。正常箇所を図-1 の $d=0\text{mm}$ の供試体, 異常箇所を $d=50, 100, 150\text{mm}$

の供試体とし、背景音は打撃を行わない状態とした。

(2) 学習の前処理

取得した各々のデータ数に隔りがある場合、正常に学習されないことがあるため、各々のデータが均一になるようにランダムに抽出した。次に、学習用 (70%), 検証用 (10%), テスト用 (20%) にデータセットを分割し、各々のデータセットからスペクトログラムを取得した。さらに、ネットワークの定義, 学習のオプションの設定を行った。

(3) データの学習

学習の進行状況は、横軸：学習の反復, 縦軸：精度 (%) で表される。学習が正確に進行する場合、図-3 に示すように学習反復が進行するにつれて精度が 100% に近づく。一方で精度が上昇しない場合や減少する場合には、学習データだけに最適化されてしまい汎用性がない状態に陥る過学習となり、実験方法やネットワークの見直しが必要となる。

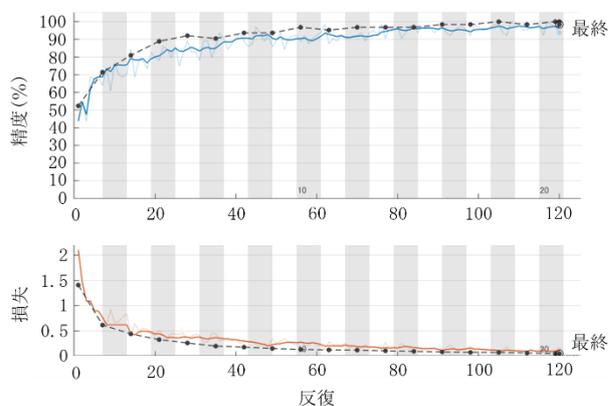


図-4 データの学習状況

(4) ネットワークの評価

3 値分類以上の機械学習モデル性能を測る指標として使用される多クラス混同行列を可視化し、評価を行った。混同行列は、図-5 に示すように列と行の要約を使用し、モデルがどの程度の精度で分類し、どこで問題が発生した可能性があるか判別する。解析の都合上、図-5 では正常箇所を normal, 異常箇所を abnormal, 背景音を background としている。最左端は取得音声データを表し、横方向にそれぞれのデータごとに判別した数を示している。これらを基に正解率および図-6 で定義する再現率, 適合率, F 値の 4 指標による比較を行った。正解率は全データのうち正解したデータ数の割合, 再現率は判別したいデータ数のうち実際に判別できた割合, 適合率は判別対象のデータを判別した数のうち, それが正解している割合を示し, F 値は適合率と再現率の調和平均であり, 一般的な性能評価の指針となる。

	abnormal と判断した数	background と判断した数	normal と判断した数
abnormal	a	b	c
background	d	e	f
normal	g	h	i

図-5 多クラス分類の混同行列

	再現率 (%)	適合率 (%)	F 値 (%)
abnormal	$a/(a+b+c)$	$a/(a+d+g)$	再現率と適合率 の調和平均
background	$e/(d+e+f)$	$e/(b+e+h)$	〃
normal	$i/(g+h+i)$	$i/(c+f+i)$	〃

図-6 各指標の定義³⁾

本実験では、上記の手順に沿って以下 2 点の手法を用いて評価を行った。

(a) 損傷大きさおよびデータ数の増加による学習精度の比較

損傷直径 $d=50, 100, 150\text{mm}$ について、各異常音をそれぞれ学習・評価することで、模擬損傷大きさの違いによる学習精度を比較した。また、データ数の増加による精度向上を検討するため、正常箇所、異常箇所、背景音それぞれ 200 個および 2000 個のデータを取得した。

(b) 学習対象の増加に伴う精度比較

実際の道路では、ポットホール発生段階の様々な状態を検知する必要があるため、一度に複数の対象を学習させることで、精度がどの程度変動するか評価を行った。ここでは、初めにデータ数を正常音 1000 個、背景音 1000 個、異常音 $d=50$ を 1000 個取得し、以降 $d=100, 150\text{mm}$ それぞれ 1000 個ずつ順に追加し、その際の F 値をそれぞれ比較した。

なお、ハンマーは図-1 に示す供試体の中心部付近を 1 秒に 1 回の間隔で打撃し、マイクロフォンの位置は打撃位置より 50mm 離れた位置に配置した。打音データ取得の様子を写真-1 に示す。



写真-1 打音データ取得の様子

3. 実験結果および考察

(a) 損傷大きさおよびデータ数の増加による学習精度の比較

表-3 に 200 個のデータ数を取得した結果の平均値を示す。損傷直径が大きくなるにつれて、再現率、適合率はともに上昇している。F 値は、 $d=50\text{mm}$ の結果は良好であり、 $d=150\text{mm}$ では $d=50\text{mm}$ と比較して 2.4% 高く、更に精度が上がっている。これは、損傷内に含まれる空気の量が打音の周波数特性に何らかの影響を及ぼしているためだと考えられる。図-7 は、取得データから算出した振幅スペクトルを示す。 $d=50, 100\text{mm}$ のピーク値は、2.5~3.0kHz であるのに対し、 $d=150\text{mm}$ のピーク値は約 4.0kHz であり、最大振幅値が大きく、高周波であることがわかる⁵⁾。なお、0.5kHz 以下の低周波数領域は計測時に近くにあった室外機の影響と考え、打音とは無関係であるとした。このことから、損傷直径が大きい程音声の判別が容易であり、学習精度が上がると考えられる。次に、表-4 に 2000 個のデータ数を取得した結果の平均値を示す。データ数 2000 個の結果と比較して、全体的に精度が上がっており、損傷直径が大きくなるにつれて、再現率、適合率はともに上昇している。 $d=50\text{mm}$ は、学習の出来が良好だったためか、飛躍的に精度が上がっており、 $d=150\text{mm}$ よりも高い精度を示した。反対に、 $d=100\text{mm}$ は微々たる増加となった。原因としては、マイクの位置がずれたことで生じた音を誤認したためではないかと考える。これらより、データ数は多い程、精度は上昇することが確認できた。ただし、打撃の仕方や雑音等により精度が変動することが確認できたため、変動範囲を明らかにすることが今後の課題として挙げられる。また、データ数の増加に比例して学習時間も長くなるため、適切なデータ数の取得を行う必要があると考える。

表-3 損傷直径ごとの各指標における比較
(データ数 200 個時)

指標 \ d (mm)	50	100	150
正解率 (%)	93.3	95.0	95.8
再現率 (%)	93.3	95.1	95.8
適合率 (%)	93.5	95.1	96.1
F 値 (%)	93.3	95.0	95.7

表-4 損傷直径ごとの各指標における比較
(データ数 2000 個時)

指標 \ d (mm)	50	100	150
正解率 (%)	99.1	95.3	98.3
再現率 (%)	99.1	95.4	98.3
適合率 (%)	99.1	95.3	98.4
F 値 (%)	99.1	95.3	98.3

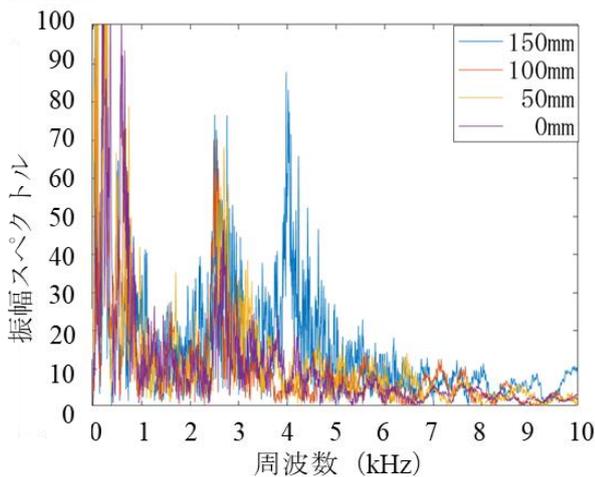


図-7 各損傷直径の振幅スペクトル

(b) 学習対象の増加に伴う精度比較

表-5 に、各異常音を順に追加した結果の平均値を示す。d=50mm 時点での精度は良好であり、d=100mm のデータを追加して得られた結果は、全体的に減少しており、特に適合率が 4.3%減少している。さらに d=150mm を追加した際には、精度は上がっているが、d=50mm だけの結果と比べるとやはり減少している。この結果から、学習対象を複数にすることで精度は減少することが確認できた。ただし、d=50, 100mm のような小さな損傷を追加することで精度は下がるが、d=150mm を追加した際に精度が上がったことから、損傷が大きいものや破壊が進行しているものは判別が比較的容易なため、精度が引き上げられているのではないかと考える。そのため、今後損傷直径の種類を広げ、対象をさらに増やすことで、精度の変動が損傷大きさによるものであるかを確認するとともに、損傷の大きさに区分を設けることで学習の正確性を上げることが課題として挙げられる。

表-5 学習対象の追加に伴う各指標の比較

指標 \ d (mm)	50	50, 100	50, 100, 150
正解率 (%)	95.8	92.8	95.3
再現率 (%)	95.8	93.8	95.7
適合率 (%)	95.9	91.6	93.1
F値 (%)	95.8	92.4	94.3

以上より、いくつか課題点が挙げられたが、舗装内部損傷の判定に AI 手法の一つである Deep Learning を用いた打音検査は有効であり、損傷の大きさを複数にした場合の検知も可能であることがわかった。この手法は実際の舗装にも適用できる可能性があると考えられる。

4. まとめ

本研究は、打音検査の舗装内部損傷判定に AI を適用する際の有効性を検討したものであり、以下の知見が得られた。

- 1) 個別データを取得した際、模擬損傷直径が大きい程、F 値は高くなり、損傷の判定精度が上がる事が確認できた。
- 2) 取得データ数を増やすことで、損傷判定の精度は高くなる事がわかった。データ数の増加に比例して学習時間も長くなるため、精度が上昇しなくなる範囲を明らかにする必要がある。
- 3) 測定対象を複数にした際、対象を増やすほど F 値は減少するが、約 92~95%と高く、実際の道路におけるポットホール発生段階の様々な状態を認識することが可能ではないかと考える。

今後の予定を以下に述べる。本研究では試行回数を増加することで各指標による精度向上および精度の変動範囲を把握することで正確性向上を図る。また、今回は模擬損傷を 3 種類用意したが、幅広い範囲の大きさを増やすことで、より実際の舗装に近づけた実験を行う。そして、本研究ではハンマーを用いて打音データを取得したが、実道下におけるハンマーの点検は、広範囲を点検するには多大な労力や時間を要することが問題として挙げられるため、回転式打音検査器具を導入する予定である。同検査器を移動・回転させた際に発生する連続打音の変化によるポットホールの評価を行うことで、その有効性の検証および点検効率の解決を試みる。

参考文献

- 1) 橋爪謙治, 橋本和明, 明石行雄, 全邦釘: 排水性舗装の基層以深の劣化を要因としたポットホール発生予測手法の一提案, 土木学会論文集 E1 (舗装工学), vol.70, No.3 (舗装工学論文集第 19 巻), I_17-I_24, 2014
- 2) 橋爪謙治, 橋本和明, 全邦釘, 中畑和之, 石田哲也: 排水性舗装におけるポットホール発生リスクに関する定量分析, 土木学会論文集 E1 (舗装工学), vol.72, No.3 (舗装工学論文集第 21 巻), I_115-I_123, 2016
- 3) 江本久雄, 馬場那仰, 浅野寛元, 長瀬大和: AI 手法による打音検査の浮き判定の検討, AI・データサイエンス論文集 1 (J1), 514-521, 2020
- 4) 全邦釘, 嶋本ゆり, 大窪和明, 三輪友寛, 大賀水田生: ディープラーニングおよび Random Forest によるコンクリートのひび割れ自動検出手法, 土木学会論文集 F3 (土木情報学), Vol.73, No.2, pp.297-307, 2017
- 5) 浅野雅則, 鎌田敏郎, 六郷恵哲, 遠藤友紀雄: 論文 コンクリート打撃音の周波数特性とその欠陥評価への適用, コンクリート工学年次論文集, Vol.24, No.1, pp.1545-1550, 2002