

論文

NN を用いた打音による内部欠陥の多クラス判別手法に及ぼす 教師データセットの影響

福井智大*, 黒田一郎**, 歌川紀之***, 黒田千歳***

*防衛大学校, 理工学研究科後期課程 (〒239-8686 神奈川県横須賀市走水 1-10-20)

**博(工), 防衛大学校教授, システム工学群建設環境工学科 (〒239-8686 神奈川県横須賀市走水 1-10-20)

***佐藤工業株式会社, 技術センター (〒300-2658 茨城県つくば市諏訪 C30 街区 1)

本研究は, ニューラルネットワーク (NN) を用いた打音によるコンクリートの内部欠陥の多クラス判別手法の適用性と, 教師データセットの構成条件 (データ数, 正常ラベルと整合しない誤ったデータ (誤ラベルデータ) の混入) が判別結果に及ぼす影響を人工欠陥を有する供試体を用いた実験によって明らかにしたものである. 三つの出力ノードを有する NN モデルを用いることで, コンクリートの内部欠陥を小さな欠陥, 大きな欠陥, 健全の 3 クラスに判別可能であることがわかった. この際, 陽性と陰性の教師データ数が少ない場合や, 教師データセットに誤ラベルデータが混入した場合には判別精度が低下することがわかった.

キーワード: 非破壊検査, 打音, 内部欠陥, ニューラルネットワーク

1. はじめに

近年, 道路橋 RC 床版の老朽化が問題視されており, 延命化や長寿命化といった対策が重要な課題となっている. 限られた予算の制約がある中で適時適切な対策を施すためには, 点検・検査によってできるだけ早期に, 遅くとも床版内部の水平ひび割れが発生する段階¹⁾ (加速期) において劣化, 損傷状況を定量的に把握することが有用であると考えられ, それを可能とする技術開発が求められている.

目視困難なコンクリート内部の劣化, 損傷を評価する手法としては非破壊検査技術の活用が期待され, これまでに電磁波レーダ法²⁾, 赤外線サーモグラフィ法³⁾, 衝撃弾性波法⁴⁾, 打音法⁵⁾といった多くの検査手法が提案されている. このように非破壊検査技術に関して多くの知見が積み重ねられているものの, 精度の面では未だ改善の余地があるうえ, 器材によっては高価である点や, 検査の計画・測定・評価の各段階において専門的な知識を持った技術者を要するなど, 簡便さや効率性の面においても課題が残されている. 予算の制約や, 検査に従事する技術者の不足が懸念されている現状を鑑みると, 低コストで, 簡便さに優れた検査技術の開発が望まれる.

他方で, 最近では非破壊検査技術に AI 技術 (機械学習) を取り入れた研究⁶⁻⁸⁾も積極的に行われている. その内の一つとして, 検査の容易性に優れた打音法に機械学習を活用した手法⁹⁻¹²⁾が挙げられ, これらは打音データ

の分析・評価を機械化することで効率性や精度の向上が見込めるだけでなく, 測定の段階においても技能が不要となるなどの利点が挙げられる. また, 現状では劣化, 損傷の定性的評価に留まっているものの, 定量的評価への応用の可能性を有しており, 今後の更なる発展が期待される.

一方, これらの手法の多くは豊富, かつ質の良い教師データセットの使用を前提としているが, 実用性を考えるとデータ収集は容易でなく, 収集できるデータ数に制約がある場合や, 判定対象のテストデータとの整合性という観点で低品質な教師データセット (例えば, 打撃方法の管理が不十分, 劣化・損傷のバリエーションが乏しい, その他使用器材の性能が低い場合など) が構築される恐れがあり, それに気づかぬまま学習に用いてしまうケースや, 場合によってはこれらを使わざるを得ないようなケースが想定される. しかしながら, このようなデータの量や質が検査結果に及ぼす影響については未だ十分な研究が行われていないという現状にある.

上記の背景を鑑み, 本研究では, 機械学習を活用した打音によるコンクリートの内部欠陥の定量的評価手法の構築を目指し, ニューラルネットワーク (以下, NN) に基づく多クラス分類手法の適用を試み, その適用性を確認するとともに, 教師データセットの構成条件 (データ数, 正常ラベルとは異なる誤ったデータ (以下, 誤ラベルデータ) の混入) の影響について検討を行った. なお, 本研究は初歩的段階の検討として, 三つの出力ノードを




図-1 欠陥供試体の諸元およびデータ収集箇所




図-2 NN モデル

有する NN モデルを用いて、欠陥の直径が小さな欠陥、大きな欠陥、健全の 3 クラスの判別を試みた。

2. 実験概要

2.1 打音データの収集

図-1 に本研究で用いた欠陥供試体の諸元およびデータ収集箇所を、表-1 にコンクリートの示方配合を示す。この供試体の内部には、厚さ 25 mm の発泡スチロールでモデル化された円形の人工欠陥（コンクリート表面に平行な欠陥を模擬）が 20 種類設けられているが、本研究ではこの内、深さ 80 mm の直径 100 mm および直径 300 mm の 2 種類の人工欠陥を判別対象とした。

打撃は、インパクトハンマ（重さ 160 g, 感度 2.27 mV/N）によって行った。各欠陥箇所は円形全体を、また、供試体端部および人工欠陥から 50 mm 以上離れた 270 mm × 300 mm の健全な領域を 3 箇所設定し、それらの領域を

表-1 コンクリートの示方配合

W/C (%)	s/a (%)	空気量 (%)	単位量 (kg/m ³)				
			水	セメント	細骨材	粗骨材	混和剤
49.5	42.9	4.5	162	327	786	1061	3.27

表-2 データ区分

区分	欠陥諸元		陽性・陰性	データ数 (個)
	直径 (mm)	深さ (mm)		
φ 100	100	80	陽性 (欠陥有り)	各 100
φ 300	300			
N ₁	—		陰性 (健全)	
N ₂				
N ₃				

まんべんなく打撃した（図-1）。なお、人工欠陥の中央付近と円の外側付近では打音の特性が異なることが考えられるが、本研究においては人工欠陥上の打撃位置の影響については考慮していない。打音は、打撃位置の直上 300 mm の位置に設置したマイクロフォン（感度 45.76 mV/Pa, 最大音圧容量 109 Pa）によって収録し、マイクロフォンから電圧として出力された音圧をサンプリング速度毎秒 10 万回（ナイキスト周波数 50 kHz）のデータロガーで A/D 変換し音圧時刻歴として記録した。なお、本研究ではサンプル長さを打撃時の余韻を含ませた 40 ms（サンプル数 4000）とした。

打音データは、表-2 に示す通り、陽性（欠陥有り）データ φ 100, φ 300 と、陰性（健全）データ N₁, N₂, N₃ に区分される（陰性データの記号 N の添字は収集箇所を表す）。各区分 100 個の打音データを収集した。

2.2 NN による内部欠陥の多クラス判別


(1) NN モデル

本研究では、コンクリートの内部欠陥を小さな欠陥（直径 100 mm）、大きな欠陥（直径 300 mm）、欠陥無し（健全）の 3 クラスに分類することを試みるため、図-2 に示すような三つの出力ノードを有する NN モデルを採用した。また、本研究が実験室レベルでのサンプル収集であり、学習に使用できるデータサンプル数に制約があるため、中間層は 1 層の最小構成とした。なお、中間層ノード数は 8、エポック数は 1000 とした。


学習方法には、誤差逆伝播法および勾配降下法を採用し、活性化関数には標準シグモイド関数を用いた。

(2) 特徴量

収録した音圧時刻歴は離散フーリエ変換によって振幅



(a) 陰性データ (区分 N_1 , N_2 , N_3)



(b) 陽性データ (区分 $\phi 100$, $\phi 300$)

図-3 スペクトルの一例

スペクトル (以下、スペクトル) に変換し、最大値が 1.0 となるように正規化処理を施した。なお、窓関数には Hann 窓を採用した。

本研究では、DC オフセットの影響を取り除くため、500 Hz 未満の低周波帯域を分析から取り除き、5000 Hz 以降の帯域では振幅が小さくなっている点を考慮して、特徴量として用いるスペクトルの周波数帯域を 500～5000 Hz (サンプル長さが 40 ms のため周波数分解能は 25 Hz) に設定し、181 次のベクトルデータの特徴量として使用した。

ここで一例として、図-3 にデータ区分ごとのスペクトルを示す。まず、図-3(a)に示す陰性データ (区分 N_1 , N_2 , N_3) のスペクトルを見ると、三つの収集箇所それぞれ波形が異なり、特定の傾向は認められないものの、いずれも広い範囲で複数のピークが確認できる。一方、図-3(b)に示す陽性データ (区分 $\phi 100$, $\phi 300$) のスペクトルを見ると、区分 $\phi 100$ の波形は広範囲に複数箇所ピークが認められ、図-3(a)の陰性データと似た特徴を示しているのに対し、区分 $\phi 300$ の波形は 2000 Hz 前後の 2 箇所しかピークは認められず、明確な違いが見受けられる。なお、これらのスペクトル波形の違いから内部欠

表-3 混同行列

		推定クラス		
		直径 100 mm	直径 300 mm	健全
実際クラス	直径 100 mm	真陽性	直径誤推定	偽陰性
	直径 300 mm	直径誤推定	真陽性	偽陰性
	健全	偽陽性	偽陽性	真陰性

陥の有無や欠陥の大きさを判別することも可能であるが、機械学習を活用することで個人の技量に依存することなく、かつ効率的な判別が可能となる。

(3) データセット

詳しくは次節 2.3 判別シリーズで後述するが、Data Leakage を避ける観点から、陽性データ 200 個 (区分 $\phi 100$, $\phi 300$ 各 100 個)、陰性データ 300 個 (区分 N_1 , N_2 , N_3 各 100 個) のデータ群 (表-2) からそれぞれ教師データとテストデータ間の重複を避けたうえでランダムに選択し、教師データセットとテストデータセットを作成した。この際、各区分のデータ数を 10 個、20 個、40 個と変化した教師データセットと、それらの教師データ中に正解ラベルが誤った誤ラベルデータを混入率 10%, 20%, 30% で混入させた教師データセットを作成した。なお、一回の判別に用いる検証のためのテストデータセットは各区分 20 個とした。

(4) テストデータの多クラス判別・評価方法

本研究では、コンクリートの内部欠陥を三つの出力ノードから算出された出力値の大きさによって直径 100 mm, 直径 300 mm, 健全の 3 クラスに判別を行った。出力値は標準シグモイド関数の値であるため、0.0～1.0 の範囲の値となる。学習過程においては、直径 100 mm の教師データには 1 番目のノードを 1.0、2 番目と 3 番目のノードを 0.0 に、直径 300 mm の教師データには 2 番目のノードを 1.0、1 番目と 3 番目のノードを 0.0 に、健全の教師データには 3 番目のノードを 1.0、1 番目と 2 番目のノードを 0.0 に設定した。テストデータを判別する際には三つの出力値の内、最も大きな出力値をそのデータの出力結果として選択することにし、1 番目のノードの出力値が最も大きかった場合には結果は推定直径 100 mm, 2 番目のノードの出力値が最も大きかった場合には推定直径 300 mm, 3 番目のノードの出力値が最も大きかった場合には推定健全となる。

判別結果は、推定直径 100 mm, 推定直径 300 mm, 推定健全の 3 クラスである。60 個のテストデータはすべていずれかに判別されるが、必ずしも実際クラスと一致す

表-4 判別シリーズ
(a) 教師データ数を変化させた条件

シリーズ名称	教師データ数		
	陽性（欠陥有り）		陰性（健全）
	区分 ϕ 100	区分 ϕ 300	区分 N_1, N_2, N_3
n10	10	10	10
n20	20	20	20
n40	40	40	40

※テストデータ数：各区分20

(b) 誤ラベルデータを混入させた条件

シリーズ名称	対象シリーズ	教師データセットへの誤ラベルデータの混入状態			
		陽性（欠陥有り）		陰性（健全）	混入率
		区分 ϕ 100	区分 ϕ 300	区分 N_1 , N_2 , N_3	
cr10-n10	n10	区分 N_1 , N_2 , N_3 が混入	区分 ϕ 100 が混入	区分 ϕ 100 が混入	10%
cr20-n10					20%
cr30-n10					30%
cr10-n20	n20				10%
cr20-n20					20%
cr30-n20					30%
cr10-n40	n40				10%
cr20-n40					20%
cr30-n40					30%

るわけではなく誤診が想定される．そのためテストデータは真陽性，偽陽性，直径誤推定，偽陰性，真陰性の5通りに分類することができ，これらを表-3の混同行列に整理した．具体的な数値の説明は3.1節で後述する．

2.3 判別シリーズ

表-4に，本研究で行った判別シリーズを示す．本研究では教師データ数を変化させた条件と，これらの教師データセットに誤ラベルデータを混入させた条件でコンクリートの内部欠陥の多クラス判別を行った．

表-4(a)の教師データ数を変化させた条件は，各区分のデータ数を10個，20個，40個の3段階とした（シリーズn10，n20，n30）．ただし，各区分のデータ数の比率は同じである．

一方，表-4(b)の誤ラベルデータを混入させた条件は，シリーズn10，n20，n40の教師データセットを対象に，区分 ϕ 100で構成される陽性の教師データ中に区分Nを，区分 ϕ 300で構成されるもう一つの陽性の教師データ中には区分 ϕ 100を，区分Nで構成される陰性の教師データ中に区分 ϕ 100を誤ラベルデータとして混入させた．この際，各誤ラベルデータの混入率は10%，20%，30%

の3段階とした．

これらの判別により，本手法の適用性と，教師データ数や誤ラベルデータの混入が判別結果に及ぼす影響について検討を行った．なお，NNモデルの性能評価には交差確認法を採用し，いずれのシリーズにおいても10回試行した．

3. 判別結果

3.1 教師データ数の影響

表-5に陽性（区分 ϕ 100， ϕ 300），陰性（区分 N_1, N_2, N_3 の混合）の教師データ数を変化させた条件（ただし，データ数の比率はいずれも同じ）であるシリーズn10，n20，n40（表-4(a)）の判別結果を示す．なお，以降で示す結果は，すべて実際クラスの区分（100mm，300mm，健全）ごとに20個（計60個）のテストデータが前述の混同行列（表-3）において，どのカテゴリーにどれだけ推定されたかを整理したものであり，試行10回分の平均値を表している（単位は個）．また，表の右端に実際クラスの区分ごとに正しく推定されたテストデータの数を，テストデータ数の合計20個で除した値を正答率（%）と

表ー5 判別結果（教師データ数の影響）

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	14.7	0.4	4.9	73.5%
	300mm	0.1	19.9	0.0	99.5%
	健全	4.3	0.7	15.0	75.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	16.6	0.1	3.3	83.0%
	300mm	0.2	19.8	0.0	99.0%
	健全	4.6	0.2	15.2	76.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	17.4	0.2	2.4	87.0%
	300mm	0.0	20.0	0.0	100.0%
	健全	3.6	0.3	16.1	80.5%

表ー6 判別結果（誤ラベルデータ混入の影響）

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	14.4	1.2	4.4	72.0%
	300mm	0.0	20.0	0.0	100.0%
	健全	5.9	1.4	12.7	63.5%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	11.2	4.1	4.7	56.0%
	300mm	0.6	19.4	0.0	97.0%
	健全	7.0	1.9	11.1	55.5%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	8.0	6.0	6.0	40.0%
	300mm	0.4	19.2	0.4	96.0%
	健全	8.0	2.6	9.4	47.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	14.4	1.2	4.4	72.0%
	300mm	0.1	19.9	0.0	99.5%
	健全	4.9	0.7	14.4	72.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	11.3	3.4	5.3	56.5%
	300mm	0.0	20.0	0.0	100.0%
	健全	6.9	0.9	12.2	61.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	8.8	5.5	5.7	44.0%
	300mm	0.0	19.7	0.3	98.5%
	健全	8.8	1.5	9.7	48.5%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	14.5	1.5	4.0	72.5%
	300mm	0.0	20.0	0.0	100.0%
	健全	5.4	0.6	14.0	70.0%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	12.9	3.1	4.0	64.5%
	300mm	0.0	19.9	0.1	99.5%
	健全	8.0	1.1	10.9	54.5%

		推定クラス			正答率
		100mm	300mm	健全	
実際 クラス	100mm	9.3	5.8	4.9	46.5%
	300mm	0.0	20.0	0.0	100.0%
	健全	11.5	1.1	7.4	37.0%

して示す。

各シリーズにおける実際クラスの区分ごとの正答率を比較すると、教師データ数が少ないほど各クラスの正答率が低調となる傾向が認められる。具体的には実際クラス直径 100 mm の正答率を、シリーズ n10（表ー5(a)）と n40（表ー5(c)）とで比較すれば、ポイントの差が生じており（73.5%と 87.0%）、実際クラス健全の正答率ではその差は 5.5 ポイントである（75.0%と 80.5%）。ただし、実際クラス直径 300 mm については教師データ数が最も少ないシリーズ n10 であっても、ほぼすべてのテストデータを正しく推定可能であり、教師データ数の増減による影響は認められない。

以上の結果より、三つの出力ノードを有する NN モデルを用いることで、コンクリートの内部欠陥を小さな欠

陥（直径 100 mm）、大きな欠陥（直径 300 mm）、欠陥無し（健全）の 3 クラスにある程度の精度で判別可能であることがわかった。この際、陽性と陰性の教師データ数が少ないほど、小さな欠陥（直径 100 mm）と欠陥無し（健全）の判別精度が低下する傾向を確認した。

3.2 誤ラベルデータ混入の影響

次に、前節 3.1 で検討を行ったシリーズ n10, n20, n40 を対象に、それぞれ教師データセットに誤ラベルデータを混入率 10%, 20%, 30% で混入させた条件（表ー4(b)）の判別結果を表ー6 に示す。

誤ラベルデータが混入していない n10, n20, n40（表ー5）の結果と比較すると、cr10-n10 の実際クラス直径 100 mm（72.0%、表ー6(a)）と cr10-n20 の実際クラス健全

(72.0%, 表-6(d))を除き、概ね各シリーズにおいては混入率 10%の段階で実際クラス直径 100 mm と実際クラス健全の正答率が 10%程度低下しており、混入率が 20%, 30%と高くなるにつれて更なる大幅な低下が認められる。具体的には誤ラベルデータが混入することで、実際クラス直径 100 mm については偽陰性の割合だけでなく、直径 300 mm と推定してしまう直径誤推定の割合が多くなり、実際クラス健全については直径 100 mm と推定してしまう偽陽性の割合の増加傾向が目立つ。他方で、実際クラス直径 300 mm についてはいずれのシリーズにおいても誤ラベルデータの混入の影響は認められなかった。

以上のことから、教師データセットに誤ラベルデータが混入した場合、誤ラベルデータ混入無しの条件においても比較的判別結果が低かった実際クラス直径 100 mm と実際クラス健全の判別結果がより悪化しており、その傾向は誤ラベルデータの混入率が高いほど顕著となることがわかった。よって、データ収集においては判別するクラスごとにできるだけ多くのデータ数を収集することが望ましく、その際小さな欠陥の陽性データと健全の陰性データ収集時には、特に誤ラベルデータが混入しないような注意が必要であると言える。なお、本研究は板状供試体を対象とした実験で、欠陥の種類やデータセットの構成条件、誤ラベルデータの混入パターンなど、未だ限られた条件下での検討である。道路橋床版への適用のためには、今後更なる検討が必要である。

4. まとめ

本研究は、NN を用いた打音によるコンクリートの内部欠陥の多クラス判別手法の適用性と、教師データセットの構成条件（データ数、誤ラベルデータの混入）が判別結果に及ぼす影響について検討を行ったものである。以下に得られた知見を示す。

- (1) 三つの出力ノードを有する NN モデルを用いることで、コンクリートの内部欠陥を小さな欠陥 (直径 100 mm)、大きな欠陥 (直径 300 mm)、欠陥無し (健全) の 3 クラスにある程度の精度で判別可能であるものの、陽性と陰性の教師データ数が少ない場合には小さな欠陥 (直径 100 mm) と欠陥無し (健全) の判別精度が低下する傾向を確認した。
- (2) 教師データセットへの誤ラベルデータの混入によって、比較的判別が難しい小さな欠陥 (直径 100 mm) と欠陥無し (健全) の判別結果がより低下し、誤ラベルデータの混入率が高いほど低下の度合いが顕著となることを確認した。

参考文献

- 1) 緒方辰男, 久保圭吾, 本間雅史: 土木学会鋼構造シリーズ 27 道路橋床版の維持管理マニュアル 2016, コンクリート工学, Vol.55, No.6, pp.495-501, 2017.
- 2) 吉沢勝, 朴錫均, 魚本健人: レーダ法を用いた RC 床版の空隙探査に関する基礎研究, コンクリート工学年次論文報告集, Vol.18, No.1, pp.1239-1244, 1996.
- 3) 金光寿一, 柳内睦人, 三星智典: 舗装熱を利用したサーモグラフィ法による RC 床版内部の欠陥検出に関する研究, 土木学会論文集, No.732/V-59, pp.95-108, 2003.
- 4) 内田慎哉, 鎌田敏郎, 前裕史, 山本健太: 道路橋 RC 床版の水平ひび割れ面の形状が衝撃弾性波法により得られる周波数スペクトルに与える影響, コンクリート工学年次論文集, Vol.31, No.1, pp.2125-2130, 2009.
- 5) 北川真也, 木村定雄, 歌川紀之, 森山守: 内部損傷を有するコンクリート床版の打音特性に関する基礎実験, 土木学会論文集 E1 (舗装工学), Vol.72, No.1, pp.1-11, 2016.
- 6) 全 邦釘, 嶋本ゆり, 大窪和明, 三輪知寛, 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, Vol.73, No.2, pp.297-307, 2017.
- 7) 鈴木達也, 西尾真由子: 橋梁定期点検における部材損傷度判定への深層学習の適用に関する検討, 土木学会論文集, Vol.75, No.1, pp.48-59, 2019.
- 8) 多田祐希, 三浦泰人, 中村光: 自己組織化マップを用いた電磁波レーダによる内部ひび割れ領域ならびに鉄筋腐食領域の検出に関する研究, 土木学会論文集, Vol.176, No.3, pp.158-170, 2020.
- 9) 佐相聡実, 勝木太, 日比野克彦: 機械学習を利用した打音法のコンクリート浮き部検出への適用性に関する基礎的研究, コンクリート構造物の非破壊検査シンポジウム論文集, Vol.6, pp.201-206, 2018.
- 10) 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, 第 1 巻, J1 号, pp.514-521, 2020.
- 11) 竹谷晃一, 佐々木栄一, 范書舒, 伊藤裕一: 時間・周波数領域の特徴量評価とニューラルネットワークを用いた打音法の感度向上と効率化, AI・データサイエンス論文集, 第 2 巻, J2 号, pp.721-732, 2021.
- 12) 飯高優翔, 江本久雄, 馬場那仰: k 近傍法によるコンクリートの打音判定の周波数領域と周波数解像度の感度分析, AI・データサイエンス論文集, 第 2 巻, J2 号, pp.733-740, 2021.

(2024 年 7 月 12 日受付)