

(16) 打音探査への機械学習の適用に関する検討

新保 弘¹・溝渕 利明²・尾関 智子³・野嶋 潤一郎⁴

¹ 正会員 法政大学 デザイン工学部 (〒184-8584 東京都小金井市梶野町 3-7-2)

E-mail: hiroshi.shimbo.3w@stu.hosei.ac.jp

² 正会員 法政大学 デザイン工学部 (〒184-8584 東京都小金井市梶野町 3-7-2)

E-mail: mizobuch@hosei.ac.jp

³ 東海大学 情報理工学部 (〒259-1292 神奈川県平塚市北金目 4-1-1)

E-mail: tozeki@tsc.u-tokai.ac.jp

⁴ 正会員 (株) 開発設計コンサルタント 茅ヶ崎事業本部 (253-0041 神奈川県茅ヶ崎市茅ヶ崎 1-9-88)

E-mail: nojima@jpde.co.jp

打音探査はコンクリート構造物の劣化に伴う剥離やひび割れを簡便に知る方法として広く利用されている。しかし、その探査精度は技能者の技量や経験によるところが大きく、定量的・安定的な評価が難しい。本稿では、打音の評価に機械学習を導入することにより、評価の定量化・安定化と高精度化を目指す検討を行った。具体的には、打音をスペクトログラム変換することにより画像化し、畳み込みニューラルネットワークにより分類する方法でコンクリートの変状を推定する。模擬欠陥を与えたコンクリート試験体及び塩害劣化した実構造物で試験を行い、極めて軽量なデータにより熟練技術者と同程度の精度でコンクリートの欠陥を診断可能であること、また学習により得られたニューラルネットワークには一定の汎化性能が認められることなどを示した。

Key Words: concrete structure, impact-echo, machine learning, spectrogram, convolutional neural network

1. はじめに

高度成長期に建設されたコンクリート構造物の多くが建設後 50 年を超えて劣化進展期を迎えるようになり、構造物の調査診断・補修補強が急務となっている。打音探査は調査方法の中でも簡便・有効なため広く用いられているが、その探査精度が技能者の技量や経験によるところが大きく、また定量評価も難しい。人口減少に伴う担い手確保の観点からも打音診断を自動化・高精度化することにより調査診断を合理化する意義は大きく、実際に自動化する技術開発も進められている¹⁾。

2. 打音探査

打音探査の定量化に関する研究は 2000 年頃から行われており、主として欠陥に伴う打音の音圧の変化、打音の卓越周波数とその対象とされている²⁾。音圧の変化はコンクリートのたわみ振動を前提としているため、微細

な欠陥を捉えることが困難である。また卓越周波数は構造物の物性や境界条件等に大きく影響を受けるため、欠陥による変化を定量的に捉えることが難しい。ここでは、打音のスペクトログラムを機械学習させることにより、熟練技術者と同程度、もしくはそれ以上の精度でコンクリート構造物の劣化に伴う微細な剥離やひび割れを安定的に精度良く探知する可能性について検討する。

一般に、打音探査はコンクリートに入力された縦弾性波の反射として解釈されている。コンクリート表面を打撃することにより入力された弾性波はコンクリート中の欠陥、低密度部や他の境界面で反射され、コンクリート表面で空気を振動させる。一般的な構造コンクリート中では 3,000-4,000 m/s となる縦弾性波の速度を考慮すると、通常の打音探査で検知可能な数 cm 程度の浅い欠陥部による反射波は十数 μ s 程度で表面に到達するが、人間には打撃の直接音とその極短時間の反射を分離して捉えることはできない³⁾ため、打音技師はそれよりも長い時間の音の特徴から変状を検知していると考えられる。一方、コンクリートに与えられた振動エネルギーの 90%以上は

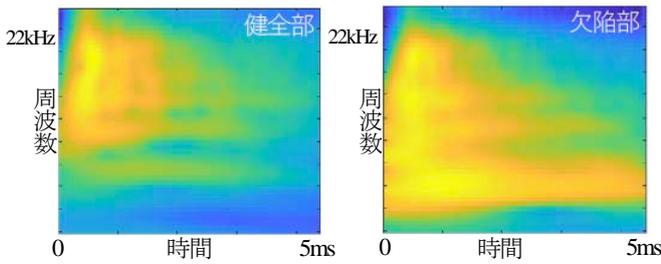


図-1 実構造物の健全部と欠陥部の平均スペクトログラム

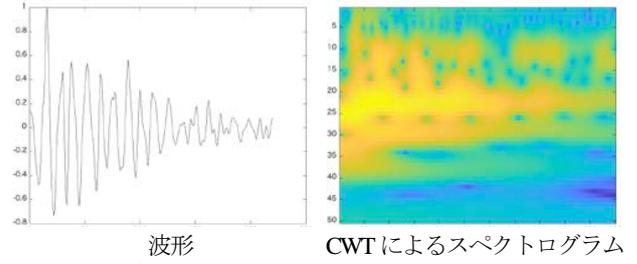


図-3 波形とスペクトログラムの一例 (5ms 相当)

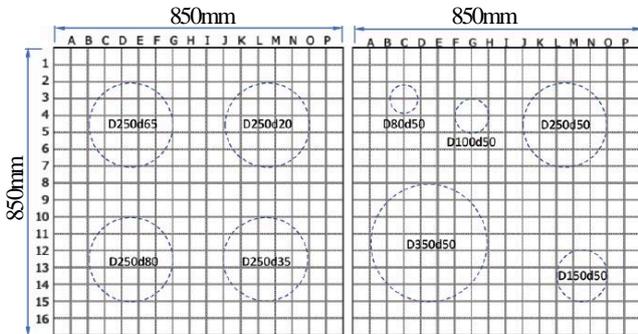


図-2 試験体平面図

コンクリート表面を伝わるレイリー波になる⁴⁾ため、エネルギーの大きさからも、打音技師は縦弾性波の反射そのものでなく、レイリー波の二次的な反射なども含めて劣化を判断していると考えられる。これは図-1に示すように、実構造物の健全部と欠陥部の打音スペクトログラムの平均画像を比較すると、図中黄色で示されるエネルギーの高いエリアは、欠陥部では周波数方向及び時間方向に広がっていることから推測される。そこで、ここでは現象として意味の大きい極短時間のデータと人間の知覚の観点から比較的長時間のデータによる推定を比較する。

打音を機械学習により評価する方法には様々考えられるが、ここではスペクトログラム化した画像をCNN (Convolutional Neural Network)により分類する方法で、「教師あり学習」を用いて検討した。また一般に、機械学習では教師データに含まれないデータの推定は不可能であるが、実務においては対象や条件などに依存せず正しく推定できる「汎化性能」が求められる。大規模なニューラルネットワークでは汎化性能を獲得することも知られている⁵⁾が、ここでは、現地試験において学習時と推定時で条件を変えた検討を行い、ネットワークの汎化性能についても検討を行った。

3. 室内試験

(1) 試験方法

図-2に試験体平面図を示す。2体のコンクリート製試験体(外形寸法:0.85m×0.85m×厚さ0.35m)には、内

表-1 機械学習の条件と精度

ケース	1	2	3	4	
時間範囲	1ms	5ms	30ms	125ms	
周波数範囲	0~22kHz	0~22kHz	0~22kHz	0~5.5kHz	
変換方法	CWT	CWT	CWT	STFT	
画像サイズ	27×45	50×222	75×1324	28×28	
精度	学習時	76.7%	94.8%	99.7%	98.5%
	テスト時(ラベル正解)	37.2%	47.3%	56.5%	72.5%
	テスト時(空隙有無)	67.6%	77.0%	81.1%	89.6%

部に模擬空洞として、径 D (80mm~350mm) と深さ d (20mm~80mm) をパラメータとした厚さ 10mm の発泡スチロール製の円盤 9 種類を埋設した。打撃にはテストハンマー(長さ約 60cm, 質量約 400g)を用い、打音はデジタルレコーダー(ZOOM社製 H6)と付属マイクにより、量子化ビット数 16bit, サンプル周波数 44.1kHz で収録した。教師データとしての打音は、9種類の「円形模擬空洞エリア内」及び「試験体中央付近の充実部分」と「試験体端部の充実部分」2種類、計 11 種類でラベル付して各 200 音、計 2,200 音収録した。試験体端部と中央付近では境界条件の影響で打音が異なるため充実部を 2 種類に分類した。テストデータとしての打音は、試験表面に記した 50mm 間隔のラインの交点で 1 打音づつ、計 512 音収録した。

打音波形データから切り出し時間を変えてスペクトログラムに変換した画像データセットを作成した。変換精度確保のため 1ms, 5ms, 30ms の波形は連続ウェーブレット変換(CWT), 125ms の打音は短時間フーリエ変換(STFT)で変換した。スペクトログラムの例を図-3に示す。

学習時は 1 ラベルあたりの 200 音のうち 25% を検証用データとして留保し、残り 75% のデータで学習を行った。学習にはコンボリューション層 3 層の比較的浅いネットワークを用いた。

(2) 試験結果と考察

各ケースのデータ諸元と学習時およびテスト時の推定精度を表-1に、推定結果の一例を図-4に示す。学習時の検証データによる推定精度が非常に高いのに比べて、テスト時の推定精度は低い傾向にある。検証データの精度

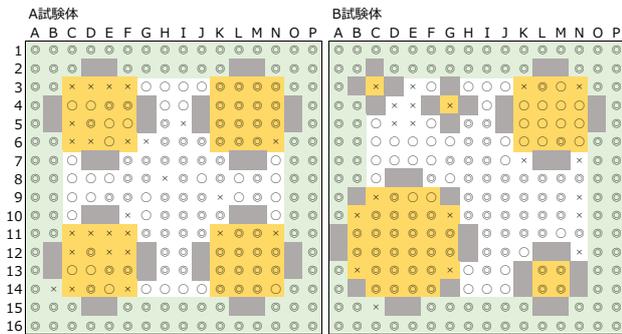


図4 機械学習による推定結果の一例（ケース4）

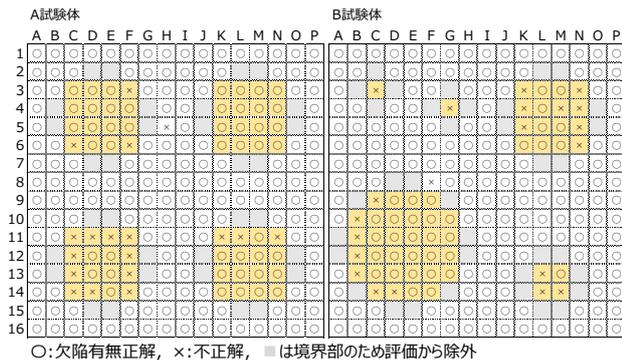


図5 熟練技術者によるブラインドテスト結果

が高いため過学習ではないと考えられるが、学習データから抽出した検証データが学習データの特性とよく一致しているため擬似的な過学習の状態となり、わずかに環境の違う状態で得られた学習データで大きな誤差が生じている可能性などが考えられる。

一方、実務的な観点として空隙の有無であれば 80～90%程度の精度で推定できている。図-5 に示すように、同じ試験体で行った熟練技能者によるブラインドテストの結果は 92%の正解率であったため、機械学習により熟練技能者と同程度の精度で推定が可能といえる。

推定精度は 125ms の打音を 28×28 pixel でスペクトログラム化したデータがもっとも精度良く、データ時間が長い方が精度が良いという結果が得られた。これは比較的長時間のデータがより打音の特徴を保有しているものと考えられる。

4. 現地試験

(1) 試験方法

模擬空洞を内包した試験体で得られる打音は、コンクリートの曲げ振動に由来する比較的大きく澄んだ打音で、実構造物の劣化時の打音とは異なる。そこで、塩害劣化が進行した RC 栈橋において、本法の適用性を検討した。

現地試験での教師データは、打音から明らかに剥離が推定される箇所、健全と推定される箇所を選定し、室内

表-2 現地試験データによる学習結果

時間範囲	5ms		125ms		
周波数範囲	0~22kHz		0~5.5kHz		
変換方法	CWT		SFTF		
画像サイズ	50×222		28×28		
ハンマー	X	Y	X	Y	
データ数	教師データ	114	60	114	60
	検証データ	38	20	38	20
検証精度	100%	100%	100%	100%	
学習済みネットワーク	NX1	NY1	NX2	NY2	

表-3 現地試験の推定結果

No.2ライン 脚頭部側面		5ms				125ms			
ケース		5	6	7	8	9	10	11	12
↓鉛直方向	学習済みNW	NX1	NY1	NX1	NY1	NX2	NY2	NX2	NY2
	テストデータ	DX		DY		DX		DY	
	a	1.00	1.00	0.94	0.97	0.72	0.67	0.63	0.91
	b	0.98	0.96	0.83	0.93	0.82	0.69	0.72	0.72
	c	1.00	1.00	0.40	0.36	0.61	0.50	0.16	0.41
	d	0.22	0.13	0.21	0.14	0.09	0.14	0.00	0.01
	e	0.25	0.12	0.00	0.00	0.04	0.05	0.00	0.00
	f	0.57	0.52	0.00	0.00	0.52	0.08	0.03	0.06
	g	-	-	-	-	-	-	-	-
	h	0.79	0.78	0.25	0.10	0.35	0.34	0.03	0.02
	i	0.23	0.18	0.00	0.00	0.08	0.15	0.00	0.23
	j	0.05	0.00	0.00	0.00	0.09	0.14	0.01	0.16
	k	0.17	0.03	0.00	0.00	0.10	0.43	0.00	0.10
	l	0.69	0.48	0.20	0.15	0.16	0.21	0.03	0.31
	m	0.15	0.15	0.17	0.01	0.11	0.31	0.02	0.20
	n	0.12	0.09	0.67	0.67	0.28	0.32	0.05	0.18
	o	0.71	0.77	0.30	0.32	0.38	0.25	0.04	0.09
	p	0.92	0.97	-	-	0.49	0.11	-	-

試験と同様の方法で収録した。打音の収録には室内試験で用いた小型のテストハンマーXに加え、大型ハンマーY（質量約 1kg、長さ約 30cm）による打音データも収録した。同じ位置でのハンマーの違いによる打音の違いは、聴覚上、明らかに異なるものと認識できる。

テストデータは、劣化部分の補修にむけて熟練技能者により「要ハツリ」部分がマーキングされたエリアを含む測線を設定し、測線上を 10cm 間隔に一箇所あたり 10 音づつ打音を収録した。

打音データの前処理は、打撃開始から 5ms を CWT により 50×220pixel でスペクトログラム化したもの、125ms を SFTF により 28×28pixel でスペクトログラム化したもの 2 種類を作成した。

学習は室内試験と同様に教師データのうち 25% を検証データとして留保し、全体の 75% で学習を行い、検証データで逐次検証を行いながらネットワークを更新した。各データセットでのデータ数と学習時の最終状態を表-2 に示す。

(2) 試験結果

現地試験の推定結果を表-3 に示す。表中左の写真にはコンクリート面に「要ハツリ」の意味を示す青のスプレーマーキングがなされており、写真中のアルファベットが打撃位置を表している。表中青のハッチングで示され

ている位置はスプレーマーキングに含まれる位置であることを示しており、アルファベットが赤字になっている箇所は打音から明らかにコンクリートのうきや剥離が認められる位置を示す。表中の数字はその位置でネットワークにより推定された評価値を示しており、1.0 が健全、0.0 が欠陥ありを代表する。機械学習における二値分類では、通常は 0.5 を境界として分類するが、ここでは評価値そのものを表示し、0.5 を下回る位置を赤字ハッチングとした。評価値は、同位置での 10 音各々で推定して得られた 10 個の評価値の平均値を示している。

横軸はネットワークとデータの組み合わせを示しており、「学習済み NW」の行において、NX は小ハンマーの打音データで作成したネットワーク、NY は大ハンマーの打音で作成したネットワークを、添字の 1, 2 はそれぞれ 5ms, 125ms のデータに対応することを示す。「テストデータ」として大ハンマーのテストデータを与えた場合の推定結果を DX, 小ハンマーのテストデータを与えた場合の推定結果を DY としている。

(3) 考察

a) 推定精度

表-3 より、全体的にはネットワークによる推定値は熟練技能者によるハッチング範囲と同等か、やや狭い範囲で 0.5 を下回る傾向にあった。実務においては確実な補修を行うため、ハツリ範囲の指定は探査により推定される欠陥エリアよりもやや広めにとるため、この推定値の傾向は実務で指定された傾向と整合しており、機械学習の結果としての欠陥判定範囲は概ね適切と考えられる。

b) 教師データの特性の影響

現地試験での教師データは、現地での打音から明らかに欠陥が推測される、ダメージの大きい箇所サンプルしたため、中程度の劣化に対応する打音データが含まれていない。一方で、テストデータには中間的な劣化も含まれていると考えられるが、欠陥範囲が概ね適切に評価できていることから、得られたネットワークは中程度の劣化についても推定できていると考えられる。

c) サンプル時間の影響

5ms と 125ms のデータによる推定結果を比較した場合、125ms の方がやや広い範囲で欠陥を推定する傾向にある。技能者によるハツリ指定範囲と概ね一致しているとみなせる範囲であるため、125ms のデータにより得られたネットワークは、より鋭敏にコンクリートの変状を検知している可能性もある。

e) ネットワークの汎化性について

「学習済み NW」と「テストデータ」の条件が異なるケースとして、5 と 6, 7 と 8 を比較した場合、推定結果の傾向は「学習済み NW」でなく「テストデータ」に支

配されている傾向が認められる。これは得られたネットワークが学習時の条件の違い（今回はハンマーの大きさ）により、与えられた打音データの特性に強く影響されていることを示しており、これらのネットワークが一定の汎化性を持っていることの傍証といえる。今回はハンマーの違いに限られたが、条件や環境の異なるデータについても今後確認すべきと考えられる。

5. まとめ

今回の室内試験および現地試験を通じて、打音のスペクトログラム画像を CNN により分類するコンクリートの欠陥探査手法について、以下の結論が得られた。

1. 本法によれば 28×28pixel と比較的軽量なスペクトログラム画像データでも熟練技能者と同等レベルの推定精度を達成できた。
2. 本法による打音の評価では、現象から想定される数 ms 前後の極短時間の応答よりも、比較的長時間のデータを与えることで推定精度が向上することが示された。
3. 現地試験における欠陥部の教師データは明らかに浮きが認められる極端な打音のみを採用したが、中間的な劣化部についても概ね妥当な推定が可能であった。
4. 機械学習による推定結果はネットワークよりもテストデータに依存する傾向が認められたことから、打音判定に関するニューラルネットワークはある程度の汎化性を持っていることが推察できる。

今回の一連の試験検討から本法の適用性を確認できた。今後は劣化度が確認できる対象でのデータの収集を進めることにより、精度と実用性の向上が可能と考える。

参考文献

- 1) 窪田裕一, 野添裕輔, 岩田昌也, 村川正宏: AI 打音検査システムの開発, 土木学会第 73 回年次学術講演会, V-171, 2018.
- 2) 鎌田敏郎, 浅野雅則, 国枝稔, 六郷恵哲: コンクリート表層部欠陥の定量的非破壊検査への打音法の適用, 土木学会論文集 No.704, V-55, pp.66-79, 2002.
- 3) 田原靖彦, 佐藤洋, 西谷修一: エコーの時間的分離知覚限界に基づく聴覚積分特性の一検討, 日本音響学会誌 61 巻 1 号, pp.14-23, 2005.
- 4) Schubert F. and Köhler B.: Ten Lectures on Impact-Echo, *Journal of Nondestructive Evaluation* 27, pp.5-21, 2008.
- 5) Zhang C., Recht B., Bengio S. and Hardt M.: Understanding deep learning requires rethinking generalization, <<https://arxiv.org/abs/1611.03530>>, (accessed 2020.6.14).