

打撃音のスカログラム画像による道路橋 RC 床版の内部欠陥探査手法の検討

日本道路（株）技術部 ○長谷 啓司

富山県立大学 工学部環境・社会基盤工学科 内田 慎哉

富山県立大学 工学研究科環境・社会基盤工学専攻 館田 英里香

1. はじめに

道路修繕工事では、道路橋の舗装打換の際、アスファルト舗装撤去後の RC 床版面を点検ハンマで打撃し、その打撃音を人の耳で聴く打音検査によりコンクリート表層の鉄筋付近の水平ひび割れの有無を点検し、内部欠陥を発見して補修する（写真-1）。しかしながら、打音検査は検査員の経験に基づく定性的な点検手法であり、加えて検査箇所は施工箇所全面となるため労力、時間とも多大となる。一方、近年、少子高齢化が急速に進んでおり、建設業でも担い手不足が懸念され、労働基準法の改正により時間外労働の上限規制が適用されるなど、より一層の生産性向上が求められている。このような背景から、簡便かつ効率的で誰が点検しても同じ結果になる手法の確立が課題である。

このことから、打音法で得られた打撃応答特性（時刻歴波形）を変換して可視化（スカログラム画像化）し、さらにコンクリートの欠陥の有無を AI 画像認識により自動で判断する手法を検討した。



写真-1 RC 床版の打音検査の事例

2. 打撃応答特性の可視化による非破壊探査手法

本研究では、以下の I～III のステップを踏んだ研究開発を行っている。

- I: 打音法で測定された打撃応答特性（時刻歴波形）をウェーブレット変換して可視化（スカログラム画像化）し、検出可能な欠陥の深さと直径の関係を把握する。
- II: 畳み込みニューラルネットワーク（以下 CNN :「Convolutional Neural Network」の略）を用いて、スカログラム画像による欠陥の有無を自動分類するモデルを構築する。
- III: 社会実装を想定して、これら技術を搭載した点検ロボットを開発する。

3. スカログラム画像による欠陥評価

3.1 RC 床版供試体

コンクリート内部に直径・深さの異なる複数の人工欠陥を埋設した RC 床版供試体を対象に、打音法による計測を行い、得られた打撃応答特性（時刻歴波形）をウェーブレット変換することでスカログラムを算出し、打撃応答特性の可視化により欠陥を非破壊で評価することを試みた。

写真-2 に RC 床版を模擬した供試体を示す。対象とする供試体は合計 3 体、1 体当たりの寸法は幅 2500 mm×長さ 2000 mm×厚さ 200 mm である。欠陥供試体内部には、写真-3 に示すとおり厚さ 5 mm の円形発砲スチロールにより、水




写真-2 RC 床版を模擬した供試体

平ひび割れによる損傷を模擬した人工欠陥を設置した。人工欠陥の直径は 500、400、300、250、200、150、100、50 mm の 8 種類で、コンクリート表面から深さ 30 mm と 50 mm に埋設した。また、人工欠陥を埋設していない健全供試体も併せて作製した。いずれも引張側に鉄筋 (D13) を格子状に 200 mm 間隔で設置している。

3.2 時刻歴波形の特性

写真-4 に打音法による測定状況を示す。打撃には加速度センサ内蔵ハンマを使用し、打撃音の受信にはマイクロフォンを用いた。打撃位置は、欠陥供試体では人工欠陥の中心となるコンクリート表面を、健全供試体では供試体中央付近の 20 箇所とした。受信位置はいずれも、写真-4 に示す位置で行った。

ハンマの打撃力の違いにより打撃音が変動するため、マイクロフォンで受信した波形をハンマの電圧波形の最大値で除すことにより、受信波形の正規化を行った。図-1 に、健全および欠陥供試体 (欠陥深さ 30 mm, 欠陥直径 500 mm) で得られた正規化後の波形 (時刻歴波形) を示す。健全供試体の波形は、振幅が小さく減衰の大きい波形になっている。一般的にハンマによる打撃は、非常に短い時間であるため、短い時間に幅広い周波数成分を含むインパルス応答と呼ばれる現象となるが、健全供試体の波形でもこの様なインパルス応答がみられた。一方、欠陥供試体の波形では、欠陥深さ 30 mm で直径 150~500 mm、深さ 50 mm で直径 200~500 mm の 11 ケースにおいて、周期的で減衰しにくく、振幅の大きいたわみ振動が顕著になった。

以上より、欠陥供試体と健全供試体には打撃応答特性 (時刻歴波形) に違いがあることがわかった。

3.3 スカログラムによる画像特徴

AI による画像識別で欠陥評価を行うため、時刻歴波形を変換して画像による特徴抽出を検討する。画像取得手法として、受信波形に対してウェーブレット変換することによりスカログラムを算出した。スカログラムとは、信号の変化を時間と周波数の 2 つの軸で把握するための図であり、相関が最も高い領域を濃い赤、低い領域を濃い青として段階的に色分けしている。

本研究では、打撃位置の違いが打撃音のスカログラムに与える影響についても検討するため、埋設された人工欠陥に対して、写真-5 に示す打撃位置となるコンクリート表面で打撃した。打撃点数は、1 つの人工欠陥およびその周辺に対し、21 点となる。なお、人工欠陥を埋設していない健全供試体では、供試体中央部付近で 50 mm 間隔で計 125 点、計測を行った。計測した打撃音の時刻歴波形に対して連続ウェーブレット変換することによりスカログラムを算出した。




写真-3 人工欠陥の配置状況例




写真-4 打音法による測定状況例




図-1 時刻歴波形の例




写真-5 打撃位置の設定例

図-2 に、健全供試体で得られたスカログラムを示す。図より、短い時間で幅広い周波数を含む現象（インパルス応答）が確認できる。一方、図-3 に示す欠陥深さ 30 mm、直径 500 mm のスカログラムでは、打撃位置が「中心」、「中間」、「端部(10 mm 内側)」および「端部」においては、1 次～3 次のたわみ共振に起因する相関の高い領域が時間軸方向に延びていることがわかる。そして、「端部(10 mm 外側)」および「欠陥外」では、図-2 に示す健全供試体と同様のスカログラムになった。このことから、打撃応答特性をスカログラムによる画像化することで、特徴抽出が可能となった。なお、この欠陥検出は、時刻歴波形と同じく人工欠陥が欠陥深さ 30 mm で直径 150 mm 以上、深さ 50 mm で直径 200 mm 以上において可能であった。

4. AI による打撃音のスカログラムの自動分類

次に、スカログラムで人工欠陥を検出できた画像を欠陥部、健全供試体で得られたスカログラム画像を健全部とラベル付けし、機械学習により二値分類を行った。機械学習は、教師あり学習として CNN を用いた深層学習で行った。CNN は、主に画像認識や

動体検知に用いられ、画像の特徴を抽出する「畳み込み層」と、特徴を分析する「プーリング層」で構成されている。画像に対する高いパターン認識能力があり、素早く識別できる特徴がある。

4.1 転移学習による欠陥分類モデルの構築

転移学習は、同じ分野で学習されたモデルを活用して学習を行うため、0 からデータを学習させる必要がなく、学習時間の短縮にもつながり、高い精度を実現できる。事前学習モデルは、オックスフォード大学の Visual Geometry Group により開発された VGG19 と畳み込み後にバッチ正規化を行った VGG19_bn を用いた。

対象とするスカログラムは、欠陥部の画像 131 枚、健全供試体の画像 125 枚とした。また、モデルの検証方法は k-分割交差検証とした。k-分割交差検証はデータをランダムに k 個に分割して、そのうち k-1 組を訓練データとし、モデルを構築し、残った 1 組で検証データとし、正解率の評価を行う。この作業を k 回行なって精度の平均をとる手法である。今回は k=5 とし、欠陥部および健全部の画像のうちランダムに抽出した 80 %を訓練用データ、残り 20 %を検証用データとした。

図-4 に精度の学習曲線を示す。ここで言う「精度」は、全データに対する正解数の割合である。図より、繰り返し回数が増えると、精度が高くなっていき、繰り返し回数が 20 回と極めて少ない回数で精度が上限に到達していることが確認できる。その結果を踏まえて 1 回の検証は 20 回の繰り返し学




図-2 スカログラムの例（健全供試体）




図-3 スカログラムの例（欠陥供試体）




図-4 精度の学習曲線の例

習とした。表-1 に転移学習を行った各モデルの精度を示す。転移学習を用いることで、精度の高い自動分類ができることが明らかとなった。

4.2 ファインチューニングによる欠陥分類モデルの構築

前節の転移学習は、入力に近い部分は事前学習済みモデルで決められたパラメータで固定し、出力に近い部分のパラメータのみを学習する方法である。一方、ファインチューニングとは、事前学習済みのパラメータを初期値として利用するが、それ以降のパラメータは学習対象とする方法である。

ファインチューニングは、転移学習の手法の一つで、学習データが大量にある場合に向いていると言われ、精度の向上が見込まれる。

表-2 に k-分割交差検証により求めた各モデルの精度を示す。いずれの事前学習済みモデルにおいても、転移学習よりも精度が向上した。特に、VGG19_bn については、精度が 1.0 と極めて高いことがわかった。

表-1 転移学習を行った学習済みモデルの精度

検証回数 モデル	1 回目	2 回目	3 回目	4 回目	5 回目	平均値
VGG19	0.882	0.961	0.941	0.904	0.922	0.922
VGG19_bn	0.980	0.922	0.980	1.000	0.980	0.973

表-2 ファインチューニングを行った学習済みモデルの精度

検証回数 モデル	1 回目	2 回目	3 回目	4 回目	5 回目	平均値
VGG19	0.981	0.961	1.000	1.000	1.000	0.988
VGG19_bn	1.000	1.000	1.000	1.000	1.000	1.000

5. まとめと今後について

本研究で得られた結論を以下に示す。

- 1) RC 床版供試体で、人工欠陥上のコンクリート表面を打撃すれば、欠陥部のたわみ共振現象をスカログラムで把握することができる。
- 2) スカログラムで可視化した画像を、事前学習済み畳み込みニューラルネットワークにより、RC 床版供試体を対象とした欠陥部と健全部の二値分類を行った。事前学習済みモデルには VGG19_bn を、モデルの学習にはファインチューニングを利用することで、精度の高い AI 分類が可能である。

本検討では、供試体による検証を報告した。現在は、本手法の妥当性を検証するため、実際の道路橋 RC 床版を対象に検証実験を行っている（写真-6）。実際の RC 床版では、欠陥が発生する位置（深さ）やその形状は多種多様である。加えて、打撃するコンクリート表面は凹凸がある。これらが複合的に重なり合って多様な打撃応答特性となる。そのため、現道の測定実績を積み、訓練用データに実績結果を含めてモデル構築を行って、十分な精度を担保できるように取り組んでいる。

今後は、社会実装を想定して、本手法の実用化として打音診断ロボットの開発を目指す。



写真-6 RC 床版での打音法による測定

6. おわりに

高度成長期のインフラ整備に伴い、道路舗装に関する技術も先人達により築き上げ、確立、継承されてきた。しかしながら、近年、少子高齢化に伴い、担い手不足により築き上げた技術の確立が難しい社会となっている。そのため、本手法の様に AI やロボットによる技術や ICT などの DX 技術による検査、試験、施工技術の標準化が必要と考える。一方、DX の浸透により、変革した技術による社会実装が可能な時代となったとも言える。新しい技術の標準化による省力化、生産性の実現に向けて、引き続き検証を進め、取り組む所存である。