論文　打音探査への機械学習の適用に関する基礎的検討

新保　弘[*1]・溝渕　利明[*2]・野嶋　潤一郎[*3]

要旨：本論文ではコンクリート構造物の総合劣化評価の一環として，打音探査の高度化・自動化を目的に，打音スペクトログラムの機械学習による劣化評価の適用性について検討した。空隙を内包した小型のコンクリート試験体を製作し，その打音スペクトログラムを機械学習で画像認識することにより，一定の精度で空隙の径と深さを推定することが可能であることを示した。また，本法によれば人が感知できない打音の違いを判別する可能性を示した。さらに塩害劣化したコンクリート桟橋において，同手法により専門家と同程度の精度で欠陥の状況を推定できる可能性があることを示した。

キーワード：非破壊検査，劣化評価，打音探査，機械学習，スペクトログラム

1. はじめに

筆者らはコンクリート構造物の総合的な劣化評価，寿命予測，維持管理支援を目的として，複数の診断技術の組み合わせによる劣化状態の総合評価，環境情報と設計情報を考慮した総合判断手法の構築を進めている。診断技術としては「電磁波探査による塩化物イオン量推定[1)]」，「赤外線探査による鉄筋腐食量診断[2)]」，「打音探査によるコンクリートの劣化診断」をターゲットとして，各診断技術の高度化と統合を進めている。加えてこれら診断技術で得られた構造物の劣化情報に加え，環境情報，設計情報を統合することにより，初期状態の推定，劣化の進行速度評価および耐用期間の推定を行うことを目指している。

2. 打音探査

打音探査によるコンクリート構造物の劣化診断は，コンクリート中の欠陥や浮きを簡便な方法で的確に探査できるため広く実用に供されているものである。しかしながら，打音の判断にはある程度の経験が必要なこと，また経験者でもその判断には相当の不確実性が伴うこと，さらには欠陥の深さがある程度以上になると探査が難しいことなどの課題もある。

本論文では，先に述べたコンクリート構造物の総合的劣化評価の一部として，「打音探査」の打撃音そのものを評価する方法を検討する。すなわち，コンクリートへの固定が必要な振動ピックアップ等を用いず，マイクロフォンによる収録音を用いる方法とし，収録した音をスペクトログラムに変換し，その画像を機械学習で認識することでコンクリート中の欠陥の状態を判別する方法の可能性について検討した。

打音探査の定量的な評価手法については 2000 年頃から研究がなされている。鎌田ら[3)]は打撃音と表面振動の等価性を示した。三好ら[4)]は音響解析により打音の特徴量を抽出した。これらはいずれも音圧スペクトルと欠陥との関係を検討している。一方，近年はコンピュータの性能向上に伴い機械学習の可能性が注目されている。打音探査への機械学習の適用としては，藤井ら[5),6)]，窪田ら[7)]が打音の短時間フーリエ変換を周波数領域で識別器にかける方法により打音の異常検出をシステム化している。本論文では鉄筋の腐食膨張によってコンクリート内部に生じる劣化初期の微細ひび割れや浮きの早期発見に主眼を置き，欠陥の深さや広がりについてより詳細な状況を簡単に把握することを目的として，周波数領域と時間領域双方の情報を学習データとして利用することの可能性について検討する。

3. 室内実験

3.1 試験体

打音探査へのスペクトログラムの適用性を確認し，機械学習の最適化に向けた試行データの取得を目的として，室内試験による打音データ取得のための試験体製作を行なった。ここでは 850mm×850mm×t300mm のコンクリートブロックに，厚さ 10mm の発泡スチロール円盤の径と深さを変えて埋設することにより，一定の空隙を設けた試験体を 2 体製作した。コンクリートの配合を**表-1** に示す。試験時のコンクリート強度は 47～55N/mm^2 であった。空隙の径と深さの水準は既往研究[8),9)]を参考に，**図-**

表-1　コンクリートの配合

W/C (%)	SF (cm)	S/a (%)	単位量 (kg/m^3)				
			W	C	S	G	Ad
45	60	51	172	382	878	842	6.49

*1 法政大学大学院 デザイン工学研究科 都市環境デザイン工学専攻　D1　修士（工学）（学生会員）
*2 法政大学大学院 デザイン工学研究科 都市環境デザイン工学専攻　教授　博士（工学）（正会員）
*3 （株）開発設計コンサルタント　茅ヶ崎技術事業本部　設備保全技術部　課長　博士（工学）（正会員）

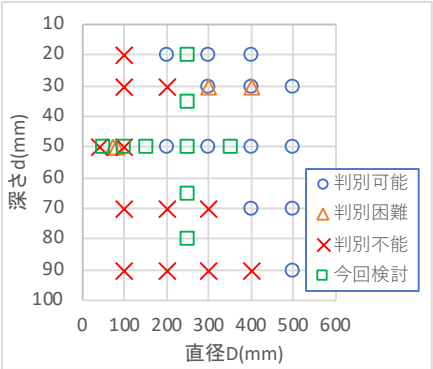

図−１ 空隙水準の設定

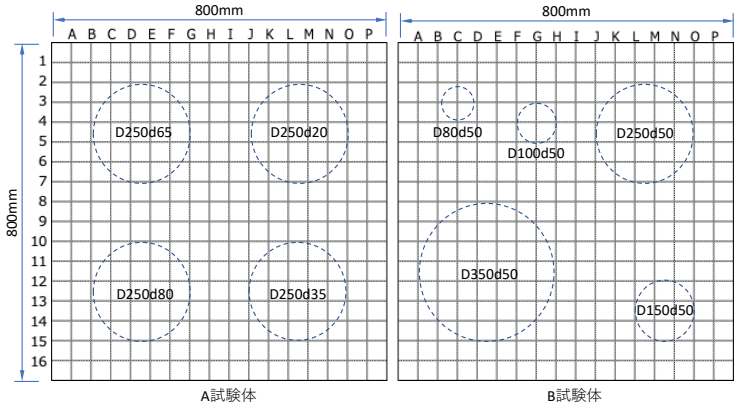

図−２ 試験体の空隙配置

１に示すように，打音から空隙の有無を人が判断できる深さと径の範囲をやや超える領域までを対象とした。試験体の空隙配置を**図−２**に示す。A 試験体は空隙径 250mm（以下 D250 と略記，他も同様）で，空隙深さを 20mm，35mm，65mm，80mm に変えている。B 試験体は空隙深さを 50mm（以下 d50 と略記，他も同様）とし，空隙径を 350mm，250mm，150mm，100mm，80mm に振っている。

3.2 打音データの採取とスペクトログラム化処理

打撃には小型のテストハンマー（質量約 400g，長さ約 600mm）を使用し，打点の近傍でデジタルレコーダー（ZOOM 社製 H6，付属マイクロフォンを使用）により打撃音を収録した。打撃時の試験体は単管パイプ製の架台の上に二辺支持で静置した状態とした。教師データ用の打音として，空隙部の打撃音は各空隙径内の直上を打撃，充実部の打撃音は内部空隙の影響および試験体周辺が解放されていることによる影響を念頭に置き，両試験体の中央付近で空隙から比較的離れた位置(A 試験体の G7~J10，B 試験体の I8~O11)および試験体縁端部の充実部分（第 1, 16 行，A,P 列）を打撃し，録音した。

短時間フーリエ変換によるスペクトログラムは音の周波数分布の時間変化を示すものであるが，打撃音の特徴を捉えるにはどのような仕様で入力データ画像を作成するかが課題となる。聴覚的には，空隙の存在による打撃音の特徴は周波数分布とその減衰の両方に表れていると考えられるが，人による判定では周囲の雑音，周辺環境による打撃音の反響や減衰，打撃位置の構造物の境界条件などを無意識に補正していると思われる。また画像の分解能は高ければ高いほど，すなわち情報量が多く音の特徴をより表現できるほうが推定精度の向上に寄与するであろうことが推察できる。一方で，短時間フーリエ変換では時間分解能と周波数分解能を同時に上げることができない。これらを含め，本手法のための最適なデータ前処理には大いに議論の余地がある。しかし本論文ではこの議論は割愛し，スペクトログラム画像の機械学習による欠陥推定への適用性を確認することに主眼を置き，軽量なデータサイズで，画像のグラデーション変化の大きい部分を切り取るものとした。**図−３**に打撃音の入力データ処理の一例を示す。ここに示したのは比較的大きく浅い空隙（D250d20）と空隙なしのデータであるが，スペクトログラムに見られるように，打音の特徴は周波数領域だけでなく時間領域にも表れていることがわかる。ここでは周波数方向と時間方向のグラデーション変化の比較的大きいエリアとして，データ取得開始から 0~125ms，周波数で 0~5.5kHz の範囲を 28×28 ピクセルのグレイスケール画像に変換した。なお，打撃音のスペクトログラム化処理及び機械学習には MathWorks 社の MATLAB ver. R2018a を使用した。

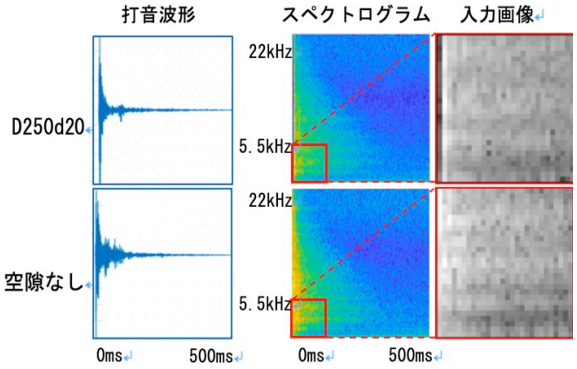

図−３ 入力データの処理

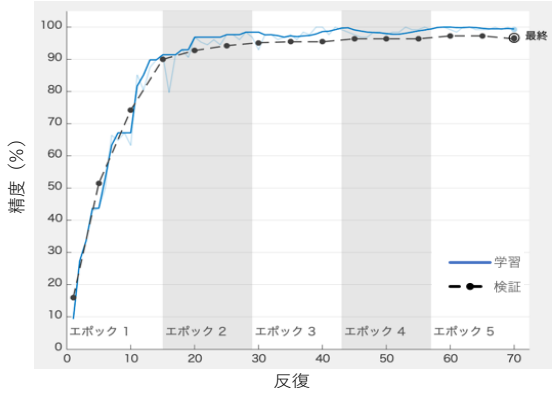

図−４ 学習経過の一例

表−２ 混同行列の一例

入力＼出力	D100 d50	D150 d50	D250 d20	D250 d35	D250 d50	D250 d65	D250 d80	D350 d50	D80 d50	充実中央	充実端部	正答率
D100d50	30	0	0	0	0	0	0	0	0	0	0	100.0%
D150d50	1	29	0	0	0	0	0	0	0	0	0	96.7%
D250d20	0	0	30	0	0	0	0	0	0	0	0	100.0%
D250d35	0	0	0	30	0	0	0	0	0	0	0	100.0%
D250d50	0	0	0	0	30	0	0	0	0	0	0	100.0%
D250d65	0	0	0	0	0	29	1	0	0	0	0	96.7%
D250d80	0	0	0	0	0	0	30	0	0	0	0	100.0%
D350d50	0	0	0	0	0	0	0	30	0	0	0	100.0%
D80d50	0	0	0	0	0	0	0	0	30	0	0	100.0%
充実中央	0	2	0	0	0	0	0	0	0	28	0	93.3%
充実端部	1	0	0	0	0	0	0	0	0	0	29	96.7%
											全体	98.5%

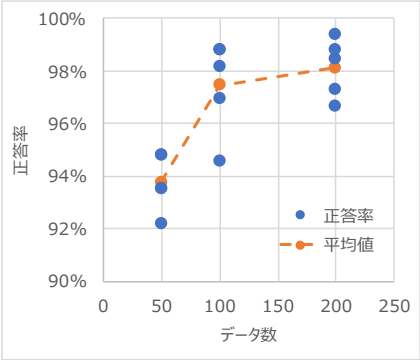

図−５ データ数と正答率

3.3 機械学習

機械学習には MATLAB の Neural Network Toolbox を用いて画像分類用の畳み込みニューラルネットワークアーキテクチャを定義した。機械学習の学習率は 0.01，エポック数は 5 とした。1 エポックは反復 14 回とし，反復 5 回ごとに検証データによる検証（学習に使っていないデータによるネットワークの精度の確認）を行った。9 種類の空隙タイプと試験体端部の影響を考慮した 2 種類の充実部を正解ラベルとした 11 ケースにそれぞれ 200 個のデータを作成した。各 200 データのうちランダムに抽出した 15%を検証用データとして確保し，残りの 1,870 画像を教師データとして機械学習を行なった。検証用データはネットワークの重み更新には用いず，過学習が起きていないことを学習中に定期的に検証した。学習経過の一例を**図−４**に示す。これより，学習と検証の精度に大きな乖離はないことから，過学習は起きていないと言える。

3.4 ニューラルネットワークの学習結果

表−２に学習結果の混同行列の一例を示す。ここでは最左列に示されたタイトルごとに与えられた 30 個の入力データに対して，学習後のニューラルネットワークにより推定された回答の集計を示している。全体の正答率は 96.7%と非常に高い値を示している。ここで与えている入力データは学習には使われていない検証データであるので，検証データでの高い正答率は過学習を否定できるものである。ただし，今回与えたデータの元となる打撃音は，一様な円形空隙に起因して，同一ケースでは聴覚的な類似性が非常に高く，スペクトログラム変換後も同様の傾向にあると考えられるため，今回の試験データに特化したネットワークとなっていることには留意が必要である。しかしながら，人間には打撃音からはほぼ判別できない「小径の空隙」「深い空隙」（D80d50 や D250d80）と空隙なし（充実中央や充実端部）を確実に分別している点は注目すべきものと考える。

1 ラベルあたりの教師データの数を 50,100,200 と変えて各 5 回学習を実施し，データ数と正答率の関係を調べた。その結果，**図−５**に示すように正答率の平均値は 100 データで 97.5%，200 データで 98%となり，データ数の

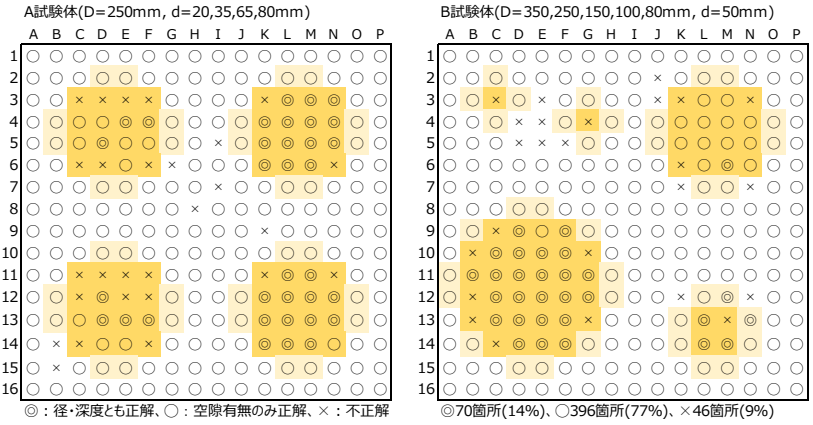

図−６ 機械学習による推定結果

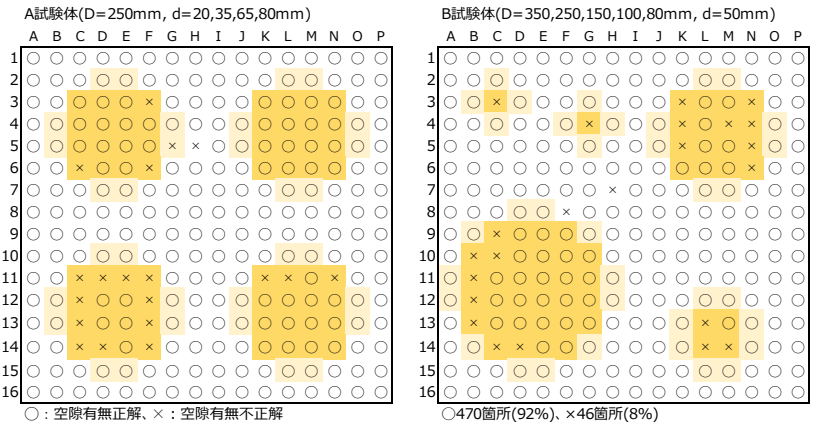

図−７ エキスパートによるブラインドテスト結果

増加に比して判定精度が向上しない傾向が確認できたため，今回のケースでは 1 ラベルあたり 200 データで十分であると考えられる。

3.5 機械学習による試験体の空隙の推定

推定結果評価用データとしては，**図−２**に示す試験体の表面に 50mm ピッチで印した線の交点（A1~P16）を 1 回ずつ打撃した際の音を収録し，教師データと同様の方法でスペクトログラム化した。これを学習済みのニューラルネットワークに与え，全点の状態推定を実施した。

機械学習による推定結果を**図−６**に示す。濃いハッチング部は直下に空隙がある場所，薄いハッチング部は空隙と充実部の境界にあたる。マス内の記号はその位置の推定結果の正解・不正解を示しており，径・深さとも正解したものは◎，空隙有無の正解は〇，空隙の有無も不正解の場合は×で表示した。なお境界部については所定の空隙仕様と空隙なしのいずれも正解とした。

3.6 室内試験の考察

空隙エリア（濃いハッチング部分）の推定結果を見ると，浅い空隙（A 試験体右側），比較的径の大きな空隙（B 試験体左下）では多くの領域で径と深度を正解している。ただし，空隙深さの深い空隙（A 試験体左側）や小さな空隙（B 試験体左上）では正答率が低くなっている。これより，打音に与える空隙の影響が小さくなることで打音の特徴が空隙なしに近づいているため誤判定していることが推察できる。

図中右下に示す全体の正答率は◎と〇を合わせて 91%となっており，検証データで得られた 98%前後の正答率よりは低くなっている。この原因は明らかではないが，教師データの打音は一時期にまとめて収録したため，同じ打撃位置での打音のばらつきが非常に小さいのに対し，評価では別の時期に収録した 1 打音のみで判定していることから，打音の収録状態や環境の影響が打音に作用し，誤判定させている可能性が考えられる。これについては打音収録の状態にバリエーションを与えるなどすることや，評価時においても複数の打音で判定することで正答率を向上させる可能性があると考えられる。

また今回，空隙なしの教師データは試験体縁端部とそれ以外の 2 種類を設定した。これは，同じ「空隙なし」点でも，側面が解放されている縁端部と試験体中央部とでは打音特性が異なることから便宜的に設定したものである。構造的な境界条件が打音に影響を与えることは実構造物においても生じるものであり，適切な推定を行うためには境界の影響を別途考慮するなど，何らかの対策が必要と考えられる。具体的には，人間が材端部付近を打撃した時にその打音への影響を自然に補正して判定していると考えられるように，例えば縁端距離をパラメータとしたマルチモーダル学習を導入する等により，縁端部の空隙有無を適切に判定することができると考えられる。

人による探査との比較として，打音探査のエキスパート 1 名により試験体の空隙の有無についてブラインドテストを行った結果を**図−７**に示す。結果は**図−６**に示す機械学習による推定結果とほぼ同様の傾向であり，両図の右下に示す正答率で見ると機械学習（◎と〇）で 91%，エキスパート（〇）が 92%と同程度の結果であった。個別に見ると，判定が難しい「深い空隙」や「小さい空隙」の部分で，いずれも判定精度が低くなる様子が見られる。しかしながら，人による判定は技量の個人差や環境などの影響が大きいため，機械学習による人に依存しない安定した判定が可能となることには意義があると考えられる。

今回の試験では，打撃音の聴覚的な特徴として，空隙位置が浅いものや径が大きいものは明らかに充実部と異なる音で判別が容易であるが，空隙位置が深く径が小さいものは空隙なしと極めて判別がつきにくいものであった。今回の試験体の打音では教師データのばらつきが小さいことや，データ数が少ないことからエキスパートの判定精度を上回ることはなかったが，一方で機械学習の検証においては，人には打撃音にほぼ違いが感じられない場合でも打音の特徴を認識して判別できる可能性が示された。これより，教師データや学習条件を改善することで，人による判定を上回る精度でコンクリートの欠陥を推定が可能になると考えられる。

4. 実構造物での試行

日本国内で建設後 30 年程度のコンクリート桟橋においてコンクリートの劣化調査が行われた。桟橋はコンクリートかぶり 80mm を確保しているが，塩害を受け鉄筋の腐食が進行し，広い範囲でコンクリートの浮きが発生している（**写真−1**）。調査においてコンクリート床版下面の打音探査および目視観察の結果と，現場で別途取得した打音データから生成したニューラルネットワークによ

写真−１ 実構造物での劣化状況例

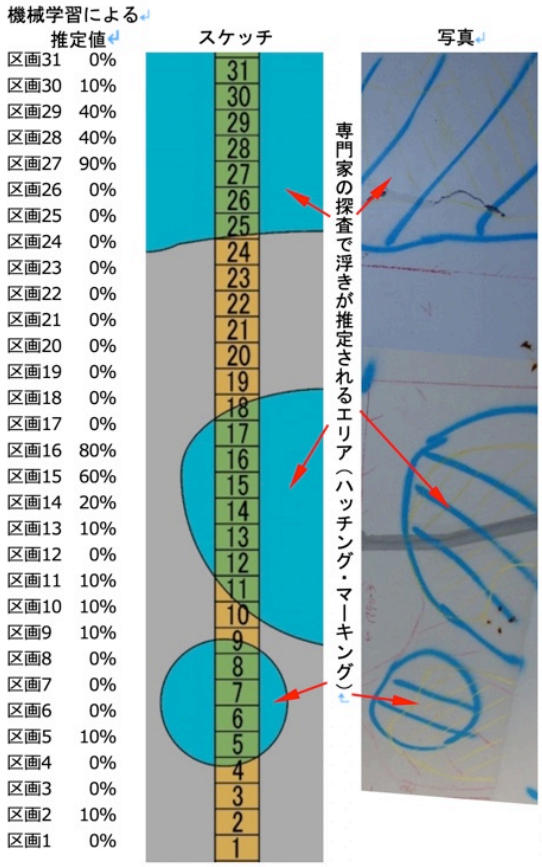

図-８ 実構造物での推定結果の一例

る推定結果を比較した。

劣化調査の過程で，打音探査のエキスパートにより**図-８**の 写真およびスケッチに青マーキング，青ハッチングで示されたエリアに浮きがあると判定された。一方，同じ桟橋の中で打音から明らかに浮き等の欠陥があると推定されるエリア，および打音からは健全と推測されるエリアそれぞれ 334 の打撃音を収録し，これを前述の方法によりスペクトログラムに変換し，これを教師データとしてニューラルネットワークを作成した。このネットワークにより当該スラブ下面に設定した 31 区画について，１区画あたり 10 回の打音についてそれぞれ推定を行い，欠陥ありと判定された回数の割合を**図-８**中に%表示した。これより，機械学習で欠陥ありと判定されたエリアは，専門家の打音判定で空隙ありと判定されたエリアにほぼ包含されていることがわかる。

機械学習の判定による「欠陥あり」のエリアの方がエキスパートの判定よりも狭くなっているのは，今回の教師データの採取にあたっては健全部と打音の違いが著しい，間違いなく大きな浮きが発生していると推定できるエリアでの打音を重点的に収録し，「欠陥あり」の教師データとした。そのため，専門家の判定よりも欠陥ありの判定がよりシビアな傾向（軽微な欠陥は欠陥ありと判定しない）になっていると考えられる。これを解消するためには，実物または実物大のモデル等で適切な教師データによりニューラルネットを作成する必要があり，これができれば室内試験と同様な精度で欠陥の状態が推定できると考えられる。

5. 結論

今回の一連の実験と試行から，以下の結論が得られた。

（１）打音スペクトログラムの画像認識にもとづく機械学習により，コンクリート中の欠陥の状態を推定できる可能性があることを確認できた。

（２）スペクトログラムによる打撃音の特徴抽出は，28×28 ピクセルのグレイスケール画像という非常に軽量なデータでも可能であることが確認できた。

（３）スペクトログラムの画像認識による打撃音の判別は，人が判別できないレベルの差異も認識できる可能性があることが確認された。

（４）本手法は適切な教師データ取得を行うことにより，現地での打音探査においても適用可能であることが推定できた。

6. 考察と今後の課題

たとえば，かぶりの厚い構造物で鉄筋腐食によるコンクリートの浮きを探査したい場合，人による打音探査で空隙の反応を捉えるためには質量の大きいハンマーを使うなどして比較的大きな打撃エネルギーを加える必要がある。しかしながら，自走式ロボット等による打音探査の自動化を考えると，遠隔自動で大きなエネルギーの打撃を与えることは難しく，できるだけ小さなエネルギーでコンクリート深部の反応を得ることが求められる。今回の手法によれば，打音からは人が判別できない程度の差異でも，機械学習であれば認識できる可能性が認められたことから，より小さなエネルギーで欠陥を検知できる可能性が示されたと言える。これは打音探査の自動化・高度化に本手法が有効となる可能性があるといえる。

また，人による打音探査では判定者の技量や環境条件などによる推定精度の揺らぎが避けられないため，欠陥ありと判定されたエリアを補修する場合には，推定範囲よりも広くはつることが必要とされる。機械学習により，より高い精度で欠陥エリアを推定することができれば，この余分なはつり作業を削減することも期待できる。

コンクリート構造物の劣化に伴い生じる浮きや空隙は微細なひび割れから進展するものである。本手法により打音探査の高精度化により初期ひび割れのような微細欠陥の検出が可能になれば，予防保全の効率化に寄与できるものと考えられる。

現地試験においては，本手法の適用性は確認できたが，教師データの精度が判別精度に直結することも確認され

た。実構造物では劣化程度の確認が容易でないため，正しい教師データを獲得するためには，劣化状態の明らかにできる構造物や実物大の試験体等での教師データ取得が必要である。

なお，今回の室内試験体では厚さ 10mm の一様な円形空隙を作成したが，実構造物の劣化で生じうる浮きや剥離の打音とは音色が異なるものとなっている。本手法を実構造物に適用するにあたっては，より多くの現実的な欠陥での打音データを集積し，適切なニューラルネットワークを構築することが重要である。

また，今回の検討では機械学習の適用性を確認するにとどまったが，28×28 ピクセルという極めて小さな画像データでも打音の特徴を捉えて一定の精度で打音判定が可能であることが確認できた。本論では割愛したが，データの前処理，学習方法やパラメータの最適化等を行うことにより，より適切で汎用的な打音評価用ニューラルネットワークの構築が可能と考えられる。この面でも様々な特徴を持つ実構造物や実環境でのデータの集積が必要である。

7. まとめ

本検討により，打音探査におけるスペクトログラムの画像認識によるコンクリートの内部欠陥の状態推定について適用可能性が確認できた。今後はより現実的な欠陥を対象とした検討を行い，機械学習による打音探査の高精度化とその適用性についての検討を行う。また機械学習による判別手法は経験的な判断の自動化や合理化に有効な手法であるため，他の探査手法，診断技術への適用についても検討を進めたい。

参考文献

1) 野嶋・内田・新井・溝渕：電磁波を用いたコンクリート中の塩化物イオン量推定技術の精度向上に関する基礎研究，土木学会論文集 E2(材料･コンクリート構造), Vol. 72, No. 2, 109-125, 2016.
2) 鎌田・淺野・国枝・六郷：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-55,66-79,2002 年 5 月
3) 三好・園田・川端：打音特性を用いた劣化診断に関する基礎的研究，コンクリート工学年次論文集,Vol.31,No.1,2009 年
4) 藤井・山下・淺間：打診検査のためのブースティングを用いた自動状態識別, 精密工学会誌 80 巻(2014)9 号 pp. 844-850, 2014 年 9 月
5) 藤井・山下・淺間：打音検査のための自動校正機能を備えた自動変状診断アルゴリズム，日本機械学会論文集, Vol. 82, No. 834, 15-00426, pp. 1-18, 2016 年 2 月
6) 窪田・野添・岩田：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,平成 30 年 8 月
7) 佐相・勝木・日比野：機械学習を利用した打音法のコンクリート浮き部検出精度に関する研究,土木学会第 73 回年次学術講演会,V-170,平成 30 年 8 月
8) 志田・高橋・村上：打音点検装置を用いた道路橋遊間部の打撃試験に基づく欠陥領域評価，土木学会第 73 回年次学術講演会,V-170,平成 30 年 8 月