

効率的な打音検査のための連続的な打撃音を用いた コンクリート材料中のクラック検出

○藤井浩光（東京大学） 山下淳（東京大学） 浅間一（東京大学）

1. 序論

社会インフラの多くが耐用年数を迎え始めている中で、特にトンネルや橋梁などのコンクリート建造物に関して、崩落事故などの老朽化による問題が深刻化している。膨大な件数を継続的に保守・メンテナンスし、安全を確保するためには、従来は人手で行われてきた点検作業をロボットなどで自動化する必要がある。

ロボットにより点検作業を自動するためには、コンクリート中のクラックや浮き、剥離といった変状を精度良く自動診断するための手法が必要である。また、診断においては検出の精度と同時に、大規模な診断を効率的に行うための実施の簡便さが極めて重要となる。コンクリート建造物を精度良く簡便に診断するための方法論の構築が緊急の課題である。

コンクリート建造物の自動診断システムに関する研究 [2, 3] に関しては、例えば Iyer らがコンクリート製パイプラインの診断支援システム [3] を提案し、超音波センサと階層型ニューラルネットワークを用いて複数の変状を検出している。しかし、点検工による巡回検査を効率化するに留まっており、検査の実施にはセンシングのための下準備に人手での作業を必要とするなど効率の観点から十分ではない。

実際の点検現場においては、人手による目視検査と打音検査が広く用いられている。打音検査は検査用ハンマなどの検査用具により対象物を打撃し、打撃音の変化から変状を判定する診断法である。検出精度の点で優れており、かつ簡便であるという理由から打音検査は現在も広く行われている。しかし、人手による打診は検出精度の個人差も大きく、熟達には多くの経験が必要となるため、自動化の要求は高い。

ここで、トンネルのような広範囲に及ぶ対象の検査のためには、連続的に打診を繰り返すことで、ロボットなど検査主体が移動すると同時に変状のスクリーニングを行うような検査方法が適していると考えられる。このような打音検査の自動化に関しては、外壁タイルの剥離点検ロボットが提案されている [1] が、コンクリート建造物に対しての適用は行われていない。

筆者らは、木製合板やステンレス材料などの屋内建材中の変状を打音検査により自動検出する手法を提案してきた [4]。本研究では、コンクリート建造物の自動診断への適用を想定し、連続的な打診によりコンクリート材料中の変状を高精度かつ簡便に検出する手法を提案する。

2. 提案手法

本研究では、連続的な打診動作によりコンクリート材料中の変状を発見する検出器の構築を行う。まず、連続的な打診動作により得られた打撃音の特徴と、その

打撃音の特徴量化の手法について述べる。また、変状を検出する識別器（以下、変状検出器）は機械学習手法の1つであるブースティングを用いて生成することを述べ、個々の識別器の判別手法および評価に用いる特徴ベクトルの決定方法について述べる。

2.1 連続した打診動作による打撃音

本研究で行う連続的な打診動作で発生する打撃音（以下、連続打音）の信号を図 1(a) および図 1(b) に示す。コンクリート表面を約 150ms 間隔で 4 回打診した結果である。図 1(a) は時間領域での信号値で、横軸は時間を示し、縦軸はマイク入力の信号値を示している。図 1(b) は周波数領域でのスペクトログラムを示しており、スペクトログラムの色は暖色ほど振幅スペクトルの値が大きいことを示している。図 1(b) の横軸は時間であり、図 1(a) と同時刻の範囲を示している。縦軸は周波数を 0~48000Hz の範囲で示している。

図 1(b) の 4 回目の打音の残響部の継続時間から各打音の音響は約 200ms 以上続くと考えられるが、連続して打撃することで各打音の残響部に次の打音が重なっていることが確認できる。本研究では、このように周波数領域で連なっている振幅スペクトル群を連続打音の特徴量として用いることで、変状検出器の学習を行う際の訓練サンプル取得の効率化、および検出の際の精度向上を図る。次節で詳細に説明する。

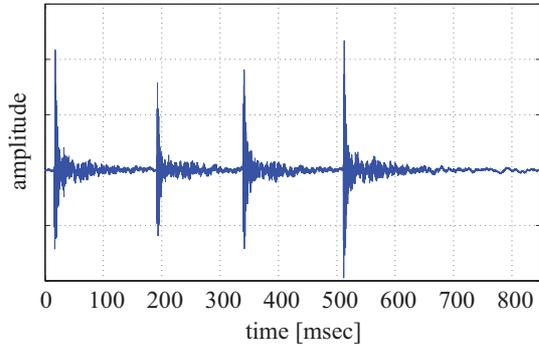
2.2 STFT 特徴量と訓練サンプルの取得

音響信号のような時系列信号の時間・周波数解析手法として、STFT が広く用いられている（例えば [5]）。時系列信号列 \mathbf{x} に対する離散時間 n での STFT は以下の式 (1) で表される。

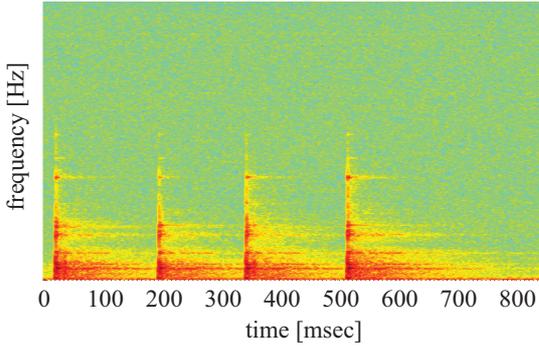
$$\text{STFT}_{\mathbf{x},w}[n,\omega] = \sum_{m=-\infty}^{\infty} x[n+m] w[m] e^{-i\omega m}, \quad (1)$$

ここで、 $w[n]$ は窓関数であり、 ω は角周波数である。STFT は時間領域において窓関数をスライドさせながら、切り出した連続信号に対して逐次的に FFT を行うことで周波数成分の時間変化を捉える手法であり、機械システムのモニタリングや非破壊検査の分野での信号解析に用いられている。

提案手法の処理概要を図 2 に示す。本研究では、変状検出器の学習時には STFT を用いて訓練サンプルを取得する。例えば、時間軸上に 2,048 サンプルの信号値を用いた場合、窓関数の幅を 1,024、窓関数のスライドの刻み幅を 1 とすると 1,024 の訓練サンプルが得られる。STFT による時間軸上に連続した振幅スペクトル群を訓練サンプルに用いることで、信号の推移に伴う性質の異なったデータを効率的に取得することができ



(a) 連続打音のマイク入力信号



(b) 連続打音のスペクトログラム

図1 連続打音の時間領域信号と周波数領域信号

る。さらに、変状の診断時には任意のタイミングでサンプリングした信号を用いることが可能となり、診断の高速化および高精度化を実現することが可能となる。

2.3 識別器の設計

本研究では検出器の生成に、アンサンブル学習の1つであるブースティング [6] を用いる。ブースティングでは、訓練サンプルの重みづけを更新しながら複数の識別器（弱識別器）を逐次生成していき、これら弱識別器の重み付き多数決によって最終的な識別関数（強識別器）を構成する。前段の識別器では識別困難なサンプルについての重みづけを大きくしていくことで、後段の識別器の生成で集中的な学習を行うため、単純なクラス分類手法では検出困難な問題にも有効である。しかし、訓練サンプルに誤分類や大きな雑音を含む場合、過学習が生じやすいという問題がある。本研究では、それら外れ値の存在に対して頑強な手法である MadaBoost [7] を用いる。

文献 [8] におけるコンクリートへの衝撃に関する調査では、直径約 20mm~30mm、重さ約 30g~100g の範囲の球の落下試験の場合、衝撃の強さによって振幅スペクトル分布が大きく変化しないという結果が得られている。そこで、本研究の弱識別機では、打診の強度によって変化する音圧の強さに依存しない、正規化相互相関を用いたテンプレートマッチングを行うことで、サンプルデータのスケールングに対して頑健な判定を行う。

正規化相互相関は式 (2) で表され、特徴量ベクトル

\mathbf{x} に対して $S_t(\mathbf{T}_t, \mathbf{x})$ が評価値となる。

$$S_t(\mathbf{T}_t, \mathbf{x}) = \frac{\sum_{k \in \mathcal{K}} (T_t(k) - \bar{T}_t)(x(k) - \bar{x})}{\sqrt{\sum_{k \in \mathcal{K}} (T_t(k) - \bar{T}_t)^2} \sqrt{\sum_{k \in \mathcal{K}} (x(k) - \bar{x})^2}}, \quad (2)$$

ここで、 \mathbf{T}_t は学習ステップ t において訓練サンプルの特徴量ベクトルから生成するテンプレートベクトルであり、 \bar{T}_t および \bar{x} はそれぞれテンプレートベクトル \mathbf{T}_t および特徴量ベクトル \mathbf{x} の平均値である。また、 k は離散化された周波数である。 \mathcal{K} は後述するテンプレートベクトルとの比較を行う周波数空間であり、各弱識別器に対して設計すべきパラメータの1つである。

正規化相互相関 $S_t(\mathbf{T}_t, \mathbf{x})$ を用いた各弱識別器の判別は式 (3) に従って行う。 θ は判定のための閾値である。

$$h_t(\mathbf{x}) = \begin{cases} 1 & \text{if } S_t(\mathbf{D}_t, \mathbf{x}) - S_t(\mathbf{C}_t, \mathbf{x}) > \theta \\ -1 & \text{otherwise} \end{cases}, \quad (3)$$

\mathbf{D}_t は変状部で測定した訓練サンプルから生成するテンプレートベクトルであり、 \mathbf{C}_t は健全部で測定した訓練サンプルから生成するテンプレートベクトルである。 \mathbf{D}_t および \mathbf{C}_t は、それぞれ検出対象および検出非対象の信号との類似度の計算に用いられ、式 (4)、および式 (5) で表されるように各クラスに属する訓練サンプル $\mathbf{x}^{(i)}$ について、ブースティングの学習の各ステップで更新される重み $w_t^{(i)}$ を考慮して計算される。

$$\mathbf{D}_t(k) = \sum_{i \in \mathcal{N}_D} w_t^{(i)} x^{(i)}(k), \quad (4)$$

$$\mathbf{C}_t(k) = \sum_{i \in \mathcal{N}_C} w_t^{(i)} x^{(i)}(k), \quad (5)$$

ここで、 \mathcal{N}_D および \mathcal{N}_C はそれぞれ変状部と健全部であらかじめ測定した訓練サンプルの識別番号から成る集合である。すなわち、 $i \in \mathcal{N}_D$ のとき $\mathbf{x}^{(i)}$ は変状部のクラスに属し、 $i \in \mathcal{N}_C$ のとき $\mathbf{x}^{(i)}$ は健全部のクラスに属する。

2.4 周波数の選択的利用

従来手法では、材料中の変状はある複数の周波数帯域に現れると考え、それぞれの弱識別機には訓練サンプルを適切に分類するように探索した周波数帯域を特徴ベクトルとして設定し、それらを統合することで異常検出を行った [4]。しかし、特に屋外のコンクリート構造物は湿気などの環境変動などでも周波数分布が

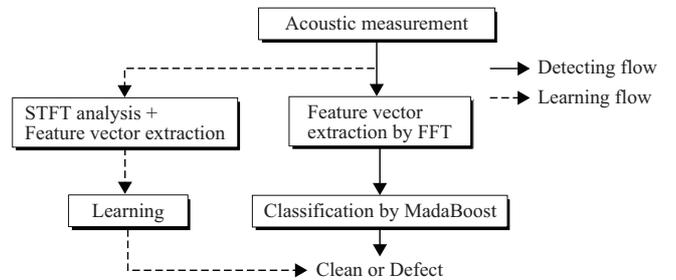


図2 提案手法の処理フロー

表 1 実験に用いたコンクリート試験体のスペック

試験体	サイズ / 変状の状態
学習用 健全サンプル (A)	100mm×100mm×400mm 変状なし
学習用 変状サンプル (B)	100mm×100mm×400mm 表面クラック幅 : 約 1.2mm 表面クラック深さ: 約 50mm
評価用 変状サンプル (C)	100mm×100mm×400mm 表面クラック幅 : 約 2.0mm 表面クラック深さ: 約 30mm



図 3 実験に用いたコンクリート試験体

異なることが知られている。ある幅を持たせた周波数帯を特徴量として学習させた場合、健全か変状であるかの識別に有用な周波数成分とは別の、環境によって変動し得る成分が含まれてしまう可能性がある。

そこで、本研究では弱識別器候補の特徴ベクトルを設定する際に、全特徴量空間の中からの復元抽出サンプルを用いる。具体的には、周波数領域での計測信号を N 次元の特徴量と考えた場合、弱識別器候補は全周波数成分から重複を許した M 個の成分 ($M < N$) をランダムに選択し、特徴量ベクトルとして評価に用いる。ここで、この特徴量ベクトルが式 (2) で記述した周波数空間 \mathcal{K} に相当する。この \mathcal{K} と、全周波数成分に対して特徴量ベクトルが占める割合 r ($r = M/N$)、式 (3) における判定のための閾値 θ が各弱識別器に対して設計すべきパラメータである。

復元抽出法を用いることで、変状の検出に有効な周波数成分を特徴量空間の全域から探索することができる。また、重複を許したことで検出に有効な周波数成分を重複選択した弱識別器の評価が高くなり、周波数成分の重み付けを得ることができる。

3. 実験

提案手法を用いて連続打音からコンクリート材料の変状を検出できることを確認するために、コンクリート試験体を用いたクラック検出の実験を行った。

3.1 実験設定

本実験ではコンクリート建造物における代表的な変状であるクラックの検出を行う。実際の現場には幅や深さが異なる多種多様なクラックが存在する。クラックは侵入の方向などにより互いに併合し、浮き・剥離などの変状にも繋がるため、その検出は極めて重要である。実験に用いたコンクリート試験体を図 3 に示す。

実験には 3 体の試験体を用いた。変状検出器を生成するために学習用に用いる変状なしのもの、同じく学習用に変状ありのもの、生成した変状検出器の性能評価のために変状ありのものを、それぞれ 1 体ずつ用いた。変状ありの試験体に関しては、変状検出器の汎化性能を確認するために、学習用と評価用でクラックの

幅と深さを変更した。各試験体のサイズおよび変状についての詳細を表 1 に示す。

実験環境を図 4 に示す。音響計測には、2 チャンネルのエレクトリックコンデンサマイクروفोनを搭載した Zoom 社製 H4n を用いた。量子化ビット数は 24bit、計測周波数は 96kHz とし、市販のオーディオインターフェイスを用いた計測を行った。検査用ハンマは、柄の長さが 420mm、ヘッド径が 20mm、ヘッド重量が約 220g のものを用いた。

変状検出器を学習する際のパラメータは、弱識別器の個数を 100、各学習ステップでの弱識別器候補の個数を 200 とした。STFT の窓関数の幅は 1,024、窓関数のスライドの刻み幅は 32 とし、打診時の FFT の窓関数の幅も同様に 1,024 とした。

訓練サンプルは、非検出対象である健全サンプルとして学習用試験体 (表 1 中 (A) および (B)) の健全部 (クラックを除く試験体中央部) を打撃した際の連続打音から 1,078 個のサンプルを取得した。また、検出対象の変状サンプルとしてクラックがある学習用の試験体 (表 1 中 (B)) のクラック上、および近傍を打撃した際の連続打音から 1,994 個のサンプルを取得した。

3.2 実験結果

実験では、図 5 に示すように、コンクリート試験体上の健全部を 4 回打診しながら移動し、変状部を通過



図 4 実験装置

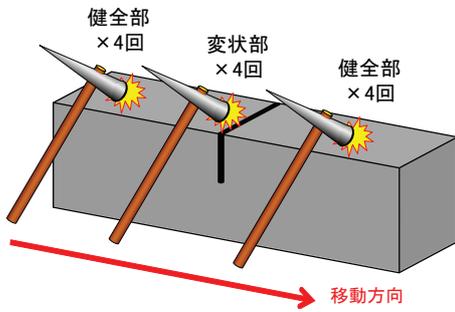


図5 実験における連続した打診動作

する際に4回打診し、再び健全部上を通過しながら4回打診する動作を行った。評価用試験体(表1中(C))を連続的に打診することでクラックを検出した結果を図6(a)に示す。横軸は時間軸、縦軸はマイク入力の時間領域での振幅を示している。同時時間帯における周波数領域の信号値をスペクトログラムとして図6(b)に示す。見やすさのために、健全部と変状部の打診の間には短時間のインターバルを設けている。

変状部での信号として検出された時間帯を図6(a)中に赤色の網掛けで示している。変状部を打診している4回の連続打音が、正しく変状部として検出されていることが確認できる。以上より、本手法によりクラックの深さが異なる場合も精度良く検出することが確認できた。

4. 結論

本研究では、コンクリート建造物に対する打音検査の効率を向上させる目的で、連続的な打診動作から得られる連続打音を用いてクラックを検出するための手法を提案した。

連続打音をSTFT解析することで得られた連続的な周波数成分から、復元抽出法を用いて検出に有効かつ環境変動の影響に頑健な特徴ベクトルを生成した。正規化相互相関を用いたテンプレートマッチングによる弱識別器群を、ブースティング手法により統合して変状検出器を構築した。クラックの深さが異なるコンクリート試験体を用いた実験を行い、提案手法により深さの異なるクラックを精度良く検出することが可能なことを確認した。

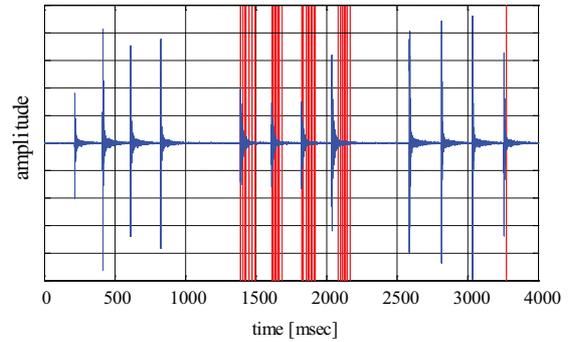
今後は、画像センサや振動センサなどその他のセンサ情報などを統合して用いることで、変状識別器を改良するアプローチも有効であると考えられる。実際の現場からは深さの異なるクラックの分類や、その他の変状の自動検出の要望も高い。クラックを深さごとに分類して検出する手法や、複数の変状を検出する手法は、今後の課題である。

謝辞

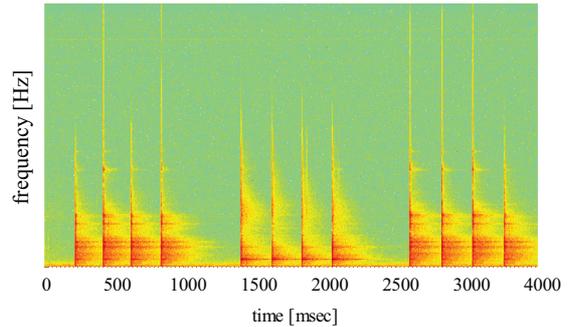
本研究の一部は、東急建設(株)技術研究所の支援を頂いた。

参考文献

[1] Fumihiko Inoue, Satoru Doi, Tatsuya Ishizaki, Yasuhiro Ikeda, Yutaka Ohta: "Study on Automated Inspection Robot and Quantitative Detection of Outer Tile Wall Exfoliation by Wavelet Analysis", Proceedings of International Conference



(a) 連続打音のマイク入力信号(赤色網掛け部が変状として検出された時間帯)



(b) 連続打音のスペクトログラム

図6 連続打音を用いたコンクリート試験体からのクラック検出(打撃は健全部4回、変状部4回、健全部4回の順)

on Control, Automation and Systems 2010, pp. 994–999, 2010.

[2] Takeshi Suda, Atsushi Tabata, Jun Kawakami and Takatsugu Suzuki: Development of an Impact Sound Diagnosis System for Tunnel Concrete Lining, Tunneling and Underground Space Technology, Vol. 19, Issue 4–5, pp. 328–329, 2004.

[3] Shivprakash Iyer, Sunil K. Sinha, Bernhard R. Tittmann, Michael K. Pedrick: "Ultrasonic Signal Processing Methods for Detection of Defects in Concrete Pipes", Automation in Construction, Vol. 22, pp. 135–148, 2012.

[4] 藤井浩光, 山下淳, 浅間一: "打診調査における AdaBoost を用いた異常状態の自動識別", 第19回ロボティクスシンポジウム講演予稿集, pp. 599–604, 2014.

[5] Marco Coconcelli, Radoslaw Zimroz, Riccardo Rubini, Walter Bartelmus: "STFT Based Approach for Ball Bearing Fault Detection in A Varying Speed Motor", Condition Monitoring of Machinery in Non-Stationary Operations, Springer Berlin Heidelberg, pp. 41–50, 2012.

[6] Yoav Freund and Robert E. Schapire: "A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting", Journal of Computer and System Sciences, Vol. 55, Issue 1, pp. 119–139, 1997.

[7] Carlos Domingo, Osamu Watanabe: "MadaBoost: A Modification of AdaBoost", Proceedings of the Thirteenth Annual Conference on Computational Learning Theory, pp. 180–189, 2000.

[8] 岡村雄樹, 檜貝勇: "衝撃応答特性による RC 床版のひび割れ評価方法" コンクリートの非破壊試験法に関するシンポジウム論文集, pp. 61–68, 1991.