

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

藤井 浩光^{*1}, 山下 淳^{*1}, 浅間 一^{*2}

Hammering diagnosis algorithm with automated calibration

Hiromitsu FUJII^{*1}, Atsushi YAMASHITA^{*1} and Hajime ASAMA^{*2}

^{*1,*2} Department of Precision Engineering, School of Engineering, The University of Tokyo
7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8656, Japan

Received 31 July 2015

Abstract

The hammering test has been widely used for inspection of social infrastructures because of its accuracy and efficiency of operation. In order to automate and apply the method to actual inspection sites, it is important for the system to calibrate itself against various environmental noise sources, such as strong winds, that influence the accuracy of the acoustic diagnosis. In this paper, a boosting based diagnostic algorithm with an updation rule for the weak learners that constitute the whole defect detector is proposed. Both clean and defective hammering sounds are templated in the frequency domain, and inner parameters of the weak learners are optimized by using the pair of frequency template vectors. Furthermore, a new updation rule for template vectors is proposed. In experiments, our method was applied to defect detection of concrete test-pieces having slant cracks, which are considered to be serious defects in inspection sites. From the results, the effectiveness of the proposed method was confirmed.

Key words : Hammering test, Non destructive inspection, Infrastructure maintenance, Boosting

1. 緒 言

社会インフラの老朽化は深刻化しており、特にトンネルなどのコンクリート構造物は高度経済成長期に急速に建築されたため、膨大な件数が一挙に耐用年数を迎え始めている (Takada and Oishi, 2013). 老朽化による事故を未然に防ぐためには、点検作業を継続的に行うことで早期に異常を発見することが必要である (Asakura and Kojima, 2003). しかし、点検作業の現場は高所や狭所など危険な場所が多く、人手のみで多数の構造物を点検することは困難である。そのような社会的背景のもとに、ロボットシステムなどによる点検作業の自動化が期待されており、システムに搭載するための自動診断手法の構築が強く望まれている。

自動点検システムに求められる要件として効率性と検出の正確さは極めて重要であり、その観点において打音検査法は有効な手法である (Hole et al., 2015). 打音検査は非破壊検査法の1つであり、検査用ハンマ (図1) や打診棒などの検査用具を用いて対象物を打撃した際の音の違いから材料中の異常状態 (変状) を検出する手法である。打音検査は実施の簡便さと高い検出精度から古くから広く用いられており、従来行われてきた1次検査におけるスクリーニングの用途だけではなく、例えば図2のようなロボットを用いた2次検査の実施も含め、打音検査に基づく診断の自動化に関する要求は高い。

打音検査の自動化に関しては現在に至るまで数多くの研究がなされている。その適用範囲も広く、コンクリート



Fig. 1 Hammering test using an inspection hammer.




Fig. 2 A prototype of a hammering robot.

構造物の診断 (Suda et al., 2004, Sonoda and Fukui 2010, Zhang et al., 2012, Ye et al., 2014) をはじめとして, 例えば高層ビルの外壁タイルの剥離診断システム (Inoue et al., 2010) や, 合金中の空洞やクラック検出アルゴリズムの構築 (Iguar et al., 2015) など様々な対象について研究がなされている. 我々の研究グループにおける打音検査の自動化に関する取り組みでは, 打音検査と3次元測定法を組み合わせることで変状箇所を特定する手法 (Yamashita et al., 2006) や, 打音検査と機械学習におけるブースティングを組み合わせた変状検出法を提案し, 屋内建材中のクラック検出 (藤井他, 2014) や実際のトンネルにおける打音を用いて剥離変状を識別できることを確認した (Fujii et al., 2015).

今後, これらの手法を実際の点検現場へ適用することが期待されている. その上で, 自動点検システムへの重要な要件の1つとして構築した検出器を現場の環境に応じて校正できること, すなわち検出アルゴリズムにおけるキャリブレーション機能が挙げられる. 例えばトンネルの場合, 天候変動によるトンネル内を吹き抜ける風量の差や通行車両の多寡などにより, 現場ごとに状況が異なることが想定される. その場合, 事前に構築した検出器では十分な性能が得られないという問題が生じる. そこで, 適用に際して十分な性能が得られない場合には既存の検出器を再利用し, 環境に応じてキャリブレーションできることが望ましい. これらは打音検査の先行研究において十分に考慮されていない課題である.

本研究では, 打音検査の自動化のためにキャリブレーション機能を備えた変状検出器を提案する. 提案手法では, 健全な状態 (健状) と変状に関する周波数テンプレート対を学習により生成し, 打音信号とそれぞれのテンプレート対との類似度の比較により変状検出を行う. 学習においては, 異なる周波数テンプレート対をそれぞれ有する複数の識別器 (弱識別器) を生成し, 統合することで変状検出器を構成する. 第2章では健状・変状テンプレート対の生成方法と, それを用いて変状を識別する手法を提案する. ここで, 打音信号は同じ種類の変状であっても劣化の度合いによって周波数特性が異なる. 第3章では, 多様な状態の変状に対応するために必要な, 異なる健状・変状テンプレート対を持つ複数の弱識別器群を, ブースティングアルゴリズムを応用することで生成し統合する. さらに, 本論文の主題である変状検出器の自動校正を実現するために, 周波数テンプレートの更新則を新規に提案する. 第4章では, 提案したアルゴリズムを用いて構築した変状検出システムについて述べ, 複数のコンクリート試験体を用いた検証実験の結果を示す. 提案手法を用いて正確な変状検出が可能であり, 弱識別器群の周波数テンプレートを更新することで, 変状検出器全体の校正が可能であることを確認する.

2. 打音のテンプレートマッチングによる弱識別器

2.1 短時間フーリエ変換

高速フーリエ変換 (Fast Fourier Transform: FFT) などの周波数変換は時系列信号の解析に広く用いられている有効な手法である. 本研究でも, 周波数領域でのスペクトル形状の類似性を評価値としたマッチングベースの手法で変状検出を行う. しかし, 周波数領域でのマッチングを行う場合には, 周波数解析を行うための時間窓を切り出すタイミングが問題となる. 例えば, 時間窓で切り出すトリガに時間領域での音響信号の立ち上がりを利用する場合, わずかなタイミングのずれによってスペクトル形状が大きく異なり, マッチングの際の誤検出の原因となる.

短時間フーリエ変換（Short-Time Fourier Transform: STFT）は、時間窓をスライディングさせながら式 (1) で表されるように FFT を行う時間・周波数解析手法であり、構造物の非破壊検査やシステムの異常診断に用いられている（Mjit et al., 2011, Cocconcelli et al., 2012）。

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

ここで、 $\mathbf{s} = (s[1], s[2], \dots, s[n], \dots)$ が解析対象の離散信号である。 n が解析対象の基点となる離散時刻、 m は離散的な時間窓関数 $W[m]$ のインデックスであり、 ω は角周波数である。 一般的に時間窓関数 $W[m]$ は、 $W[0]$ を最大として m についての一定の区間外で $W[m] = 0$ の値をとる関数である。

結果として得られるスペクトル群は、時間軸上で連続するスペクトルの変化を表す。本研究では、周波数解析で得られる個々のスペクトルを検査対象の性質を表す特徴量として扱う。すなわち、学習においては個々のスペクトルを訓練データとして扱い、診断時には個々のスペクトルを評価して健状・変状を判断する。学習時には、STFT による出力であるスペクトル群を用いることで、診断時には任意のタイミングで FFT を行った結果のスペクトルを用いることが可能となり、診断の精度を向上させることが可能である。また、診断時に行う単一の FFT は高速に実行できるため診断のオンライン化が可能である。

STFT を用いることは学習における前処理の観点からも有利である。STFT により 1 回の打音から異なるタイミングで周波数解析した連続したスペクトル群を得ることができるため、効率的に訓練データを準備可能である。

2.2 周波数テンプレートマッチングによる健状・変状との類似度評価

本研究では、健状部および変状部を打診した音響データを訓練データとして用いる。訓練データを用いて健状および変状に関するスペクトル形状の周波数テンプレートをそれぞれ生成し、テンプレートマッチングによりそれぞれ求めた類似度を用いて変状検出を行う。以下、テンプレートマッチングおよび周波数テンプレートの生成法について述べる。

2.2.1 重み付け正規化相互相関によるテンプレートマッチング

環境やマイク設置位置による音圧の違い（オフセット）の影響を考慮するために、正規化相互相関（ZNCC: Zero-mean Normalized Cross-Correlation）を用いて信号強度の正規化を行う。本研究で用いる ZNCC は、各周波数成分に対する重み付けを用いて拡張しており、以下の式 (2) で表される。

$$S(\mathbf{A}, \mathbf{u}, \mathbf{x}) = \frac{\sum_{k \in \mathcal{K}} u_{(k)} (A_{(k)} - \bar{A})(x_{(k)} - \bar{x})}{\sqrt{\sum_{k \in \mathcal{K}} u_{(k)} (A_{(k)} - \bar{A})^2} \sqrt{\sum_{k \in \mathcal{K}} u_{(k)} (x_{(k)} - \bar{x})^2}}, \quad (2)$$

ここで、 \mathbf{x} は評価対象の信号から得られる各周波数成分の振幅値からなるベクトルであり、 \mathbf{A} は新たな評価対象と比較・評価するための、訓練データから計算される周波数テンプレートベクトルである。 \mathcal{K} は \mathbf{x} と \mathbf{A} との類似度の比較を行う周波数成分のインデックスの集合である。 \mathbf{u} はインデックス集合 \mathcal{K} に対応付けられた各周波数成分の重みであり打音の特徴ベクトルを表す。 k は \mathcal{K} の中の特定の周波数成分を指すインデックスであり、例えば $A_{(k)}$ は \mathbf{A} の k 番目の成分を示す。 \bar{A} および \bar{x} は、それぞれ \mathbf{A} および \mathbf{x} の平均値である。テンプレートと信号との類似度を示す評価値 $S(\mathbf{A}, \mathbf{x}, \mathbf{u})$ の値域は一般的な ZNCC と同様に $[-1, 1]$ であり、値が大きいほど相関が高く類似していることを示す。

周波数テンプレートベクトルの k 番目の成分 $A(k)$ は、弱識別器が各訓練データ $\mathbf{x}^{(i)}$ に対して持つ重み $w^{(i)}$ と各訓練データの k 番目の成分 $x^{(i)}(k)$ を用いて以下のように生成する。

$${}^c\mathbf{A}(k) = \sum_{i \in \mathcal{C}} w^{(i)} x^{(i)}(k) \quad (3)$$

$${}^d\mathbf{A}(k) = \sum_{i \in \mathcal{D}} w^{(i)} x^{(i)}(k) \quad (4)$$

ここで、 \mathcal{C} および \mathcal{D} はそれぞれ健状および変状の訓練データを指すインデックス集合である。すなわち、 $\mathbf{x}^{(i)}$ ($i \in \mathcal{C}$) は健状サンプルであり、 $\mathbf{x}^{(i)}$ ($i \in \mathcal{D}$) は変状サンプルである。以下、同様に論文全体を通して健状に関する記号として \mathcal{C} (Clean)、変状に関する記号として \mathcal{D} (Defect) を用いることとする。

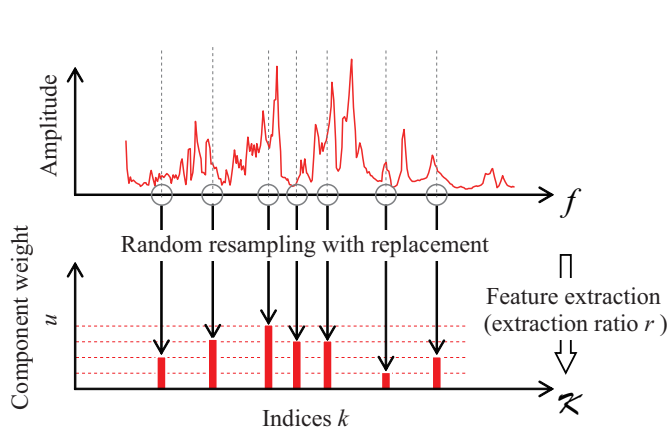


Fig. 3 Feature vector \mathbf{u} is weighted by bootstrapping feature extraction (subsection 2.2.2).

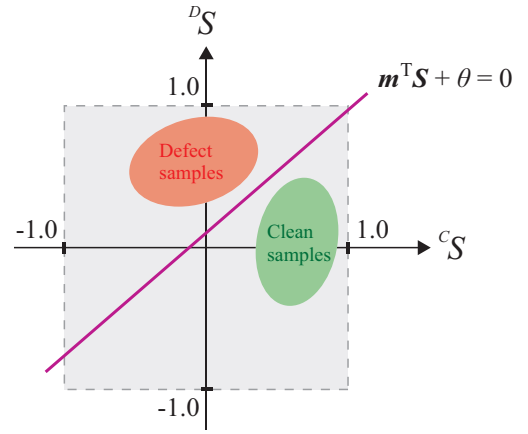


Fig. 4 Schematic of training data distribution in $C_S - D_S$ space and linear discriminant function.

各弱識別器は訓練データに対して異なる重みづけを有しており、それらの重みはブースティング学習時の繰り返し計算の中で獲得する。重み付けに関する詳細は3.1節で述べる。

2.2.2 復元抽出法による周波数テンプレート生成

テンプレートベクトルとの類似性を評価することで適切に変状を検出するためには、検査対象の状態を表現する適切な周波数成分で評価する必要がある。すなわち、式(2)中の周波数インデックス集合 \mathcal{K} の適切な選択が重要である。本研究では、復元抽出法を用いてインデックス集合 \mathcal{K} を選択すると同時に各周波数成分の重み \mathbf{u} を獲得する。

復元抽出法は、重複を許すランダムリサンプリングである(図3)。計測信号の全周波数成分を N 次元の特徴量空間と考えた場合、重複を許した M 個の成分($M < N$)をランダムに選択する。全周波数成分からの抽出率 $r = M/N$ に関しては弱識別器候補ごとにランダムに設定する。また、選択された周波数成分を指すインデックス群から要素が重複しないように生成した集合を \mathcal{K} とする。

本研究では、周波数成分にも重みを持たせて探索的な選択をすることで、訓練データをより良く識別することが可能な弱識別器を生成する。復元抽出法では選択の重複を許容するため、周波数成分が複数回選択される場合が生じる。そこで、インデックス $k \in \mathcal{K}$ が指す周波数成分の選択回数を、その周波数成分の重み $u_{(k)}$ とする。学習においては、1つの弱識別器を生成するためにパラメータ \mathcal{K} および \mathbf{u} を変化させながら、あらかじめ設定した有限回の繰り返し評価を行う。評価では全ての訓練データに対して計算した誤り率 ϵ を最小とするパラメータを選択することで、変状の検出に有効な周波数帯域と各周波数成分の重み付けを持つ弱識別器を獲得する。

2.3 弱識別器における線形識別関数による変状検出

訓練データ中の健状サンプルと変状サンプルを正確に分類可能な弱識別器を学習により求める。周波数インデックス集合 \mathcal{K} が適切に選択されている場合、健状および変状の訓練データ中から生成した周波数テンプレートに対して、式(2)から計算される訓練データ自体のそれぞれの類似度 C_S 、 D_S の分布は、図4の様になると考えられる。すなわち、健状サンプルおよび変状サンプルは自身と同じクラスのサンプル集合から生成された周波数テンプレートと類似しており、異なるクラスのサンプル集合からのテンプレートとは相関が低いため、両サンプル集合は $C_S - D_S$ 平面上で分類可能となる。ここで、 $C_S := S(\mathbf{c}_A, \mathbf{c}_u, \mathbf{x})$ 、 $D_S := S(\mathbf{d}_A, \mathbf{d}_u, \mathbf{x})$ とし、 \mathbf{c}_A 、 \mathbf{d}_A はそれぞれ健状および変状の訓練データから生成した周波数テンプレートベクトルであり、 \mathbf{c}_u 、 \mathbf{d}_u はそれぞれの各周波数成分の重みである。

本研究では、変状検出において以下の線形識別関数を導入する。

$$\mathbf{m}^T \mathbf{S} + \theta = 0, \quad (5)$$

ここで、 $\mathbf{S} = [C_S \ D_S]^T$ であり、係数列ベクトル \mathbf{m} 、およびバイアス項 θ は弱識別器において周波数テンプレート

に応じて固有に設計される内部変数である。このとき、弱識別器 $h(\mathbf{x})$ では式 (6) に従って変状検出がなされる。

$$h(\mathbf{x}) = \begin{cases} 1 & \text{if } \mathbf{m}^T \mathbf{S} + \theta \geq 0 \\ -1 & \text{otherwise} \end{cases}. \quad (6)$$

内部変数である \mathbf{m} および θ は、 ${}^c S - {}^D S$ 平面上において健状および変状の訓練データそれぞれと線形識別関数式 (5) とのマージンが最大となるように求める。この最適化問題は、線形サポートベクターマシンの訓練における凸二次計画問題として解法が広く知られている。本研究では、2 クラスが式 (5) の線形識別関数で完全に分類できない場合を許容するソフトマージン最大化を考え、 \mathbf{m} および θ の最適化計算には座標降下法を用いる。

以上より、式 (2) における \mathcal{K} および \mathbf{u} の選択により弱識別器の周波数テンプレートが決定し、式 (6) において訓練データを分類可能な識別関数を決定することが可能である。

3. テンプレート更新によるキャリブレーション

3-1 ブースティングを用いた弱識別器の統合

本研究では、機械学習におけるアンサンブル学習の 1 手法であるブースティングアルゴリズム (Freund and Schapire, 1997) を用いて変状検出器を構成する。一般的なブースティングの構造を図 5 に示す。ブースティングアルゴリズムでは、訓練データの重みづけを更新しながら複数の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。学習の各ステップにおいて、前段の弱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、後段の弱識別器の生成で集中的な学習を行うため、単独の弱識別器では検出困難な問題にも有効である。

評価サンプル \mathbf{x} に対しての強識別関数 $H(\mathbf{x})$ は、以下のように表される。

$$H(\mathbf{x}) = \sum_{t=1}^T \alpha_t \text{sign}[h_t(\mathbf{x})] \Big/ \sum_{t=1}^T \alpha_t, \quad (7)$$

ここで、 $h_t(\mathbf{x})$ は訓練ステップ t における弱識別器であり、 T は強識別器を構成する弱識別器の個数である。 α_t は訓練データに対する誤り率 ϵ_t から計算される各弱識別器の信頼度であり、以下のように計算される。

$$\alpha_t = \frac{1}{2} \log \left(\frac{1 - \epsilon_t}{\epsilon_t} \right), \quad (8)$$

ただし、2 クラス分類器に関して、 $\epsilon_t \leq 0.5$ および $\alpha_t \geq 0$ は常に成立する。強識別関数 $H(\mathbf{x})$ の出力は各弱識別器の信頼度を重みとした投票の結果であり、値域は $[-1, 1]$ に正規化されている。すなわち、 $H(\mathbf{x})$ の値が大きいほど変状サンプルと相関が高く、健全性が低いと判定されたことを示す。例えば、以下のように $H(\mathbf{x})$ の値について閾値 Θ に対する大小に注目することで健状・変状を 2 値判別することが可能である。

$$H^*(\mathbf{x}) = \begin{cases} 1 & \text{if } \text{sign}[H(\mathbf{x})] \geq \Theta \\ -1 & \text{otherwise} \end{cases}, \quad (9)$$

ここで、 $H^*(\mathbf{x}) = 1$ であるとき \mathbf{x} は変状部に対する打音のスペクトルであり、 $H^*(\mathbf{x}) = -1$ であるときは \mathbf{x} は健状部に対する打音のスペクトルである。

2.2.1 項で述べた訓練データの重みづけに関しては、各学習ステップで更新を行う。各学習ステップでは、変状検出器を構成する弱識別器が選定されるため、各ステップで更新された訓練データの重みは弱識別器に固有のベクトルとなる。以下、訓練データの重みづけに関して説明する。

訓練データは、測定された音響信号の振幅スペクトル \mathbf{x} と、 \mathbf{x} についてあらかじめ人手で付与した正解ラベル y のセットである。本研究では、 $y = 1$ は変状を示し、 $y = -1$ は健状を示す。個数 I の訓練データ集合を $\chi = \{(\mathbf{x}^{(1)}, y^{(1)}), \dots, (\mathbf{x}^{(I)}, y^{(I)})\}$ とする。訓練ステップ t の終了後に、 i 番目の訓練データ $(\mathbf{x}^{(i)}, y^{(i)})$ の重み $w_t^{(i)}$ は以下のように更新される。

$$w_{t+1}^{(i)} = w_t^{(i)} e^{-\alpha_t y^{(i)} h_t(\mathbf{x}^{(i)})}, \quad (10)$$

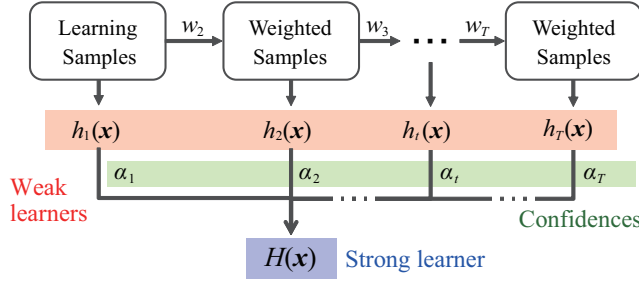


Fig. 5 Schematic of a general boosting algorithm.

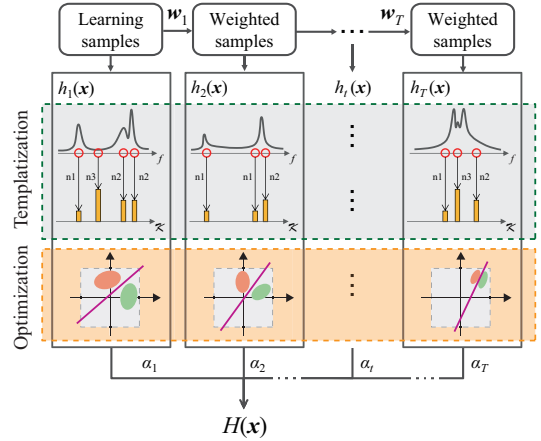


Fig. 6 Schematic of proposed boosting framework. Each weak learner has a different pair of frequency templates which can be altered in additional learning for calibrating the whole detector.

ただし、各訓練ステップのはじめには $\sum_i w_i^{(i)} = 1$ となるように正規化する。各ステップにおいて弱識別器 $h_i(\mathbf{x}^{(i)})$ により正しく識別される訓練データは、次のステップにおける重みが相対的に小さくなり、誤識別された訓練データの重みは相対的に大きくなる。

提案手法のブースティングの基本構造を図6に示す。各弱識別器は第2章で述べた周波数テンプレート生成部、および周波数テンプレートに応じた識別関数生成部を持つ。以下では、ブースティングの枠組みにおける周波数テンプレートの更新則を導出し、追加訓練データを用いて変状検出器全体をキャリブレーションする手法について説明する。

3.2 ブースティングにおける弱識別器の更新によるキャリブレーション

本節では既に事前学習で生成した変状検出器を更新する手法を提案する。追加訓練データを用いて周波数テンプレートベクトル \mathbf{A} を更新するアルゴリズムを提案する。本節で導出する周波数テンプレートの更新則は本論文が新規に提案するものであり、提案手法を用いて各弱識別器の周波数テンプレートを更新することで、変状検出器全体のキャリブレーションが可能となる。

事前学習におけるラベル付き訓練データ集合を $\tilde{\chi} = \{(\tilde{\mathbf{x}}^{(1)}, \tilde{y}^{(1)}), \dots, (\tilde{\mathbf{x}}^{(I)}, \tilde{y}^{(I)})\}$ とし、追加学習用のラベル付き訓練データ集合を $\chi' = \{(\mathbf{x}'^{(1)}, y'^{(1)}), \dots, (\mathbf{x}'^{(J)}, y'^{(J)})\}$ とする。ここで、 I および J はそれぞれの訓練データの個数である。それらを合わせた訓練データ集合 χ^* に属する訓練データ $\mathbf{x}^{*(\ell)}$ ($\ell = 1, \dots, I+J$) を以下のように定義する。

$$\mathbf{x}^{*(\ell)} = \begin{cases} \tilde{\mathbf{x}}^{(\ell)} & (1 \leq \ell \leq I) \\ \mathbf{x}'^{(\ell-I)} & (I+1 \leq \ell \leq I+J) \end{cases} \quad (11)$$

事前学習時と追加学習時の測定において、対象や点検用具の材質など共通する物理的条件が存在する。本研究では、それぞれの訓練データの部分的な類似性を仮定し、事前学習で生成されたテンプレートベクトルの形状を再利用することで、効率的に追加学習を行う。具体的には、訓練データ $\tilde{\chi}$ に属する i 番目の訓練データの重み $\tilde{w}_i^{(i)}$ 、および χ' に属する j 番目の訓練データ $w'_j^{(j)}$ に関して、 $\sum_{i=1}^I \tilde{w}_i^{(i)} : \sum_{j=1}^J w'_j^{(j)} = \tilde{\gamma}_i : \gamma'_i$ となる訓練データ集合同士の重みづけを設計することで、事前学習におけるテンプレートの形状を維持しつつ更新を行う。

訓練ステップ t における訓練データ集合の重み付け係数 $\tilde{\gamma}_t$ および γ'_t は、それぞれ更新前および更新後の弱識別器による追加訓練データの評価結果から以下のように計算される。

$$\tilde{\gamma}_t = \frac{\sum_{j=1}^J \sum_{t=1}^T (\frac{1}{2} \tilde{\alpha}_t (1 + y'^{(j)} \tilde{h}_t(\mathbf{x}'^{(j)})))}{\sum_{j=1}^J \sum_{t=1}^T \tilde{\alpha}_t} \quad (12)$$

$$\gamma'_t = \frac{\sum_{j=1}^J \sum_{t=1}^T (\frac{1}{2} \alpha'_t (1 + y'^{(j)} h'_t(\mathbf{x}'^{(j)})))}{\sum_{j=1}^J \sum_{t=1}^T \alpha'_t} \quad (13)$$

ここで、 $\tilde{\alpha}_t$ は事前学習で得られた弱識別器 $\tilde{h}_t(\mathbf{x})$ の信頼度である。 α_t' は追加学習で得られる弱識別器 $h_t'(\mathbf{x})$ の信頼度であり、訓練ステップ $t = t_c$ においては以下のように定義する。

$$\alpha_t' = \begin{cases} \alpha_t' & (1 \leq t < t_c) \\ \tilde{\alpha}_t & (t_c \leq t \leq T) \end{cases}. \quad (14)$$

ここで、追加学習済みの弱識別器の信頼度 $\alpha_t' (1 \leq t < t_c)$ に関しては、追加学習用の訓練データに対する誤り率から3.1節と同様に計算する。訓練ステップ $t = t_c$ における弱識別器 h_t' の定義に関しても式(14)における信頼度の定義と同様に設定する。

事前学習と追加学習で用いる訓練データ集合の和 $\{\tilde{\chi} \cup \chi'\}$ に属する訓練データの重みとして、 $w_t^{*(\ell)} (\ell = 1, \dots, I+J)$ を以下のように定義する。

$$w_t^{*(\ell)} = \begin{cases} \tilde{w}_t'^{(\ell)} & (1 \leq \ell \leq I) \\ w_t'^{(\ell-I)} & (I+1 \leq \ell \leq I+J) \end{cases}, \quad (15)$$

ここで、各学習ステップ t における $\tilde{w}_t'^{(i)}$ は、事前学習における訓練データの重み $\tilde{w}_t^{(i)}$ を定数倍したものである。具体的には、各訓練データの重みは $\sum_{\ell=1}^{I+J} w_t^{*(\ell)} = 1$ かつ $\sum_{i=1}^I \tilde{w}_t'^{(i)} : \sum_{j=1}^J w_t'^{(j)} = \tilde{\gamma}_t : \gamma_t'$ を満たすように、以下の式(16)および式(17)で更新される。

$$\tilde{w}_t'^{(i)} \leftarrow \frac{\tilde{\gamma}_t}{(\tilde{\gamma}_t + \gamma_t') \sum_{i=1}^I \tilde{w}_t'^{(i)}} \tilde{w}_t^{(i)}, \quad (16)$$

$$w_t'^{(j)} \leftarrow \frac{\gamma_t'}{(\tilde{\gamma}_t + \gamma_t') \sum_{j=1}^J w_t'^{(j)}} w_t'^{(j)}. \quad (17)$$

これらの訓練データの重みの更新則を2.2.1項におけるテンプレートベクトルの定義式に適用することで、以下のテンプレートベクトルの更新則を得る。

$$\begin{aligned} A_t^*(k) &= \sum_{\ell=1}^{I+J} w_t^{*(\ell)} \mathbf{x}^{*(\ell)} \\ &= \sum_{i=1}^I \tilde{w}_t'^{(i)} \tilde{x}^{(i)}(k) + \sum_{j=1}^J w_t'^{(j)} x'^{(j)}(k) \\ &= c_t \tilde{A}_t(k) + A_t'(k), \end{aligned} \quad (18)$$

ここで、 $c_t = \tilde{\gamma}_t / ((\tilde{\gamma}_t + \gamma_t') \sum_{i=1}^I \tilde{w}_t'^{(i)})$ であり、事前学習のテンプレートベクトル \tilde{A}_t の k 番目 ($k \in \mathcal{K}$) の成分 $\tilde{A}_t(k) = \sum_{i=1}^I \tilde{w}_t'^{(i)} \tilde{x}^{(i)}(k)$ を等倍で縮小する係数である。また、 $A_t'(k) = \sum_{j=1}^J w_t'^{(j)} x'^{(j)}(k)$ であり、追加学習用の訓練データから生成されるテンプレートベクトルである。追加学習用の訓練データ $x'^{(j)}$ の重み $w_t'^{(j)}$ は、式(10)と同様に以下のように更新される。

$$w_{t+1}'^{(j)} = w_t'^{(j)} e^{-\alpha_t' y'^{(j)} h_t'(x'^{(j)})}, \quad (19)$$

式(18)および式(19)から確認できるように、これらの更新則は事前学習で既に得られている訓練データ重みとテンプレートベクトル、および追加学習セット χ' のみから計算することが可能である。

式(18)におけるテンプレートベクトルの更新則を図7に模式的に示す。事前学習で得られたテンプレートベクトル \tilde{A}_t は、係数 c_t により形状を保ったまま振幅方向に縮小される(赤破線)。追加学習における新たな訓練データから計算される A_t' は、式(18)に斜線で示された差分に相当し、 \tilde{A}_t と足し合わせることで更新後のテンプレートベクトル A_t^* が得られる。

周波数テンプレートの更新後、2.3節と同様に線形識別関数の最適化を行う。変形した周波数テンプレートベクトルに応じて識別のための内部変数を更新することで追加訓練データを精度良く分類可能となる。以上のように、周波数テンプレートベクトルの更新により変状検出器のキャリブレーションが可能である。

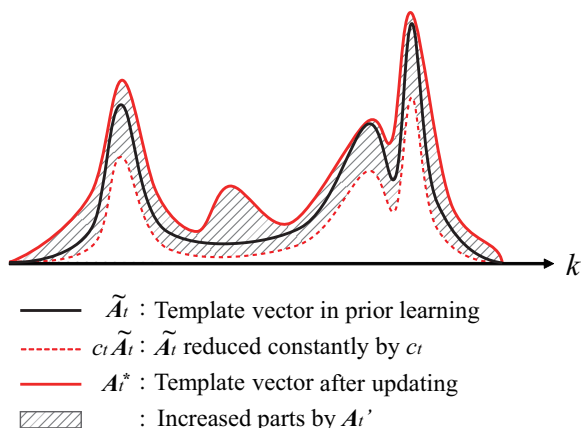


Fig. 7 Schematic of template vector update shown in eq. (18).

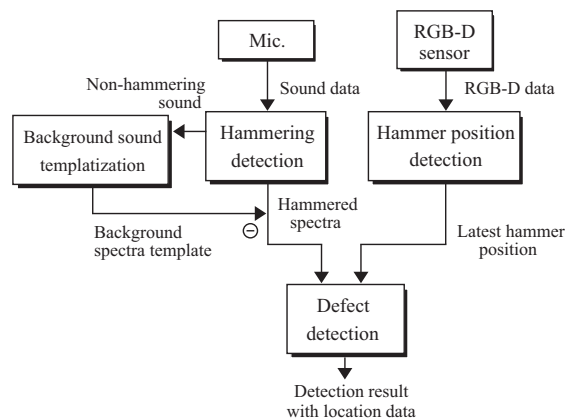


Fig. 8 Schematic of the proposed defect detection system.

4. コンクリート試験体を用いた評価実験

提案手法を打音検査に適用する目的で、第2章および第3章で提案した変状検出器を用いて、コンクリート構造物の変状検出を行う信号処理システムを構築した。さらに打音検査における提案手法の有効性を確認するために、コンクリート試験体を用いた検証実験を行った。この実験は、提案する変状検出器の性能評価、および事前学習により生成した変状検出器の再利用において提案するキャリブレーション手法の有効性を確認することを目的とした。学習済みの変状検出器が対応できない環境変化に対して新たな訓練データを用いて追加学習を行い、その検出器を用いた変状検出の性能評価を行った。

4.1 変状検出システムの構築

本研究で提案する打音信号による変状検出システムの概要を図8に示す。システムは大きく音響信号を扱う部分と映像および測距信号を扱う部分に分かれ、音響信号からは変状を検出し、映像および測距信号からは打点の3次元位置を検出する。以下詳細に説明する。

4.1.1 打音検出とスペクトル差分法による環境ノイズの除去

例えばコンクリートトンネルの点検作業ではトンネル内を吹き抜ける風切り音や、足場となる作業車の駆動音など定常的なノイズが存在する。検査環境に存在する定常的な背景ノイズからの影響を軽減するために、スペクトル差分法 (Boll, 1979) を用いて背景ノイズのスペクトル推定を行い、周波数空間でスペクトル同士の減算を行う。

背景ノイズのスペクトル推定には打診を行っていない時間の環境音を用いる必要がある。本研究では、検出の精度を向上させる目的で打診直前までの環境音を用いており、信号中の非打診区間を求めるためにトリガを用いた打音判定を行う (図9)。具体的にはあらかじめハンマ音に対してマイクのゲイン調整を行った上で、入力 of the maximum value against the trigger threshold is set, and the value is defined as the value used for the peak value of the peak value against 60dB attenuation up to the peak value of the peak value.

診断の際には、打音として検出された区間の信号を用いて行う。その区間においては、時間窓を窓幅ずつスライドしながらFFTを行い、得られた個々のスペクトルについて変状検出を行う。

4.1.2 RGB-D センサを用いた打点検出

点検作業の自動化においては、変状の有無だけではなく変状の存在位置の検出が重要である。例えば、1次検査のスクリーニングにおいても変状の位置を大まかに特定し記録することで、2次検査においてはその付近の点検を集中的に行う。また、2次検査においては変状の位置や分布している範囲の大きさなどの詳細な検査結果を基に帳票の作成や保存が義務付けられている。

本研究では、RGB-D センサを用いて打点の3次元位置を推定することで、変状位置の検出および変状の大きさを測定する (図10)。RGB-D センサは、通常のカメラで取得可能なRGBのテクスチャ情報に加え、ピクセルごとに距離情報が取得可能なセンサである。まずコンクリート構造物における検査対象は平面であることから、テ




Fig. 9 Hammered sound detection by trigger.




Fig. 10 Hammer head detection by using RGB-D sensor.

クスチャ情報および測距情報を用いて RANSAC (Fischler and Bolles, 1981) による平面検出を行い、検出された最も面積の広い平面を検査対象面とする。4.1.1 項の手法で判定された打音の継続中に、ハンマヘッドが検査対象面に最も近づいた点から検査対象面に下ろした垂線の足の 3 次元位置を打点とする。ハンマヘッドは図 10 中で赤色で示した部分であり、本研究ではハンマヘッドを実際に赤色に着色し、センサからのテクスチャ情報を用いた画像処理によって画像上の位置を推定する。ハンマヘッドの 3 次元位置は画像上の座標と、テクスチャ情報と同時に得られる距離情報、および既知情報であるセンサの内部パラメータから推定可能である。

4.2 斜めひび割れ変状の検出実験

4.2.1 コンクリート試験体および実験環境

トンネルなどのコンクリート構造物の点検においては、特に剥落の兆候となる変状の検出が重要である。例えば、コンクリート表層が薄く剥がれた状態の剥離変状は、振動などにより高所から落下し通行車両を傷つける危険性がある。また、ひび割れが斜め方向に侵入した場合にも同様の状態（斜めひび割れ変状）となり、特に複数の斜めひび割れ変状が合わさり閉合状態になったものは、規模の大きな剥落の原因となるため深刻視されている。本研究では、斜めひび割れ変状の検出に焦点を当て、斜めひび割れ変状を再現した試験体を用いた実験を行った。

コンクリート試験体は、実際の現場における表層付近の剥離変状を再現するように、生コンクリートを打ち込む際に斜め方向に鉄板を差し入れて固定し、コンクリートが固まった後に引き抜くことで製作した。実験に用いた装置とコンクリート試験体を図 11 に示す。実験に用いたコンクリート試験体は、変状を持たない健全な状態の試験体 1 体とそれぞれ異なる種類の斜めひび割れ変状を有する試験体 4 体の計 5 体である。試験体の詳細なスペックを表 1 に示し、斜めひび割れ変状の例として学習に用いた試験体 TP_{L2} の変状位置の詳細を図 12 に示す。図 12 中で赤い網掛けをしている部分が剥離変状に相似した状態となっており、変状として検出されるべき箇所である。試験体の体積は全て同じ幅 500 mm、奥行き 500 mm、高さ 150 mm である。試験体 TP_{L1} および TP_{L2} は学習に用いたものであり、変状を持たない試験体 TP_{L1} により健全なサンプルを取得し、斜めひび割れ変状を持つ試験体 TP_{L2} により変状に対する打音を取得する。試験体 TP_{V1} 、 TP_{V2} および TP_{V3} は提案手法の性能検証に用いた斜めひび割れ変状を持つ試験体であり、それぞれ侵入の角度が異なることでひび割れの到達している深さが異なる。

点検用具はコンクリートトンネルなどの検査に標準的に用いられている、ヘッド径 12.4 mm、ヘッド重量 0.1 kg である鉄製の検査用ハンマを用いた。ハンマは画像処理によるヘッド検出のために赤くペイントした。測定器具には 2 チャンネルの有指向性コンデンサマイクروفोनを用いて、解像度およびサンプリングレートはそれぞれ 24 bit, 48 kHz で測定した。2 つのマイクروفオンは左右に向かい合わせて設置し、訓練データを用いた学習時および検証における診断時のいずれにおいても左右のマイクروفオン入力の平均値を用いた。テクスチャ情報および測距情報を取得する RGB-D センサには Asus 社製 Xtion Pro Live を用いて、解像度はいずれも 640×480 pixels とした。変状検出器に関しては、時間窓幅を 1,024 サンプルとし窓関数にはハニング窓を用いて FFT を行った。弱識別器の個数は 256 とし、各弱識別器を選択する学習の繰り返し計算における繰り返し回数は試行錯誤的に 1,000 と設定した。また、計算には Intel Core™ i7-5600U CPU 2.60 GHz を搭載した計算機を用いた。






Fig. 11 Experimental devices for hammering test and concrete test pieces.



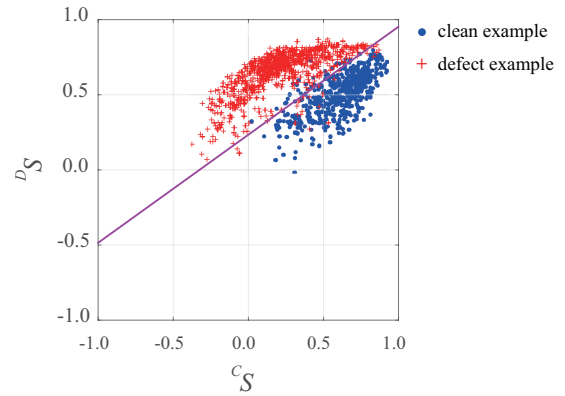
(a) Plan view of TP_{L2} . (b) Elevation of TP_{L2} .
Fig. 12 Schematic of test piece TP_{L2} for learning.

Table 1 The specifications of concrete test-pieces. All these are the same volume ($W \times D \times H = 500\text{mm} \times 500\text{mm} \times 150\text{mm}$).

Test-pieces	Entry degree of crack	Size of crack extension	Max depth the crack attains
for learning (TP_{L1})		clean (no crack)	
for learning (TP_{L2})	15 deg	200 mm \times 142 mm	38 mm
for validation (TP_{V1})	15 deg	200 mm \times 71 mm	19 mm
for validation (TP_{V2})	30 deg	200 mm \times 64 mm	37 mm
for validation of calibration (TP_{V3})	45 deg	200 mm \times 53 mm	53 mm



(a) Components weight u selected by bootstrapping for clean and defect comparison. The weak learner focuss on up to 4000 Hz.



(b) Distribution of training data set in $C_S - D_S$ plane. The defective and clean training samples are classified in the $C_S - D_S$ plane by using a pair of defective and clean frequency templates.


Fig. 13 Optimization result of a weak learner. One classifier focuss its own frequency subband. If single learner cannot classify all training samples, the proposed method increases whole performance of detection by integrating plural weak learners.

4.3 実験結果


4.3.1 検出性能の評価実験

提案手法により変状検出器の学習を行った。学習の訓練データには健全サンプルとして変状を持たない健全な状態の試験体 TP_{L1} の打音を用い、変状サンプルとして斜めひび割れを持つ試験体 TP_{L2} の変状部の打音を用いた。訓練データの総数は 4,263 であり、健全サンプル数は 1,617、変状サンプル数は 2,646 であった。


生成した変状検出器の弱識別器の訓練データに対する学習結果の例を図 13(a) および図 13(b) に示す。図 13(a) はある弱識別器において 2.2.2 項で述べた復元抽出法により獲得された周波数成分の重みである。横軸は周波数イ




(a) Hammering spectrogram of TP_{V1} (15 deg slant crack)




(e) Hammering spectrogram of TP_{V2} (30 deg slant crack)




(b) Zoom of 6th hammering spectrum of defect in Fig. 14(a).




(c) Zoom of 7th hammering spectrum of clean in Fig. 14(a).




(f) Zoom of 4th hammering spectrum of defect in Fig. 14(e).



(g) Zoom of 7th hammering spectrum of clean in Fig. 14(e).



(d) Result of defect detection of TP_{V1}




(h) Result of defect detection of TP_{V2}


Fig. 14 Result of slant crack detection in TP_{V1} and TP_{V2} from hammering sound. Figures (d) and (h) shows results of defect detection in time domain. In both figures, the areas emphasized by the half-tone background with red color indicate the time intervals whose spectrum was detected as defect. The resulting time intervals coincide the moments in which the defective parts were actually hammered.

ンデックス $k \in \mathcal{K}$ を周波数に換算した値であり、縦軸はその周波数成分に対する重み付け $u(k)$ の値である。青線および赤線はそれぞれ健全サンプルおよび変状サンプルに対して得られた周波数成分の重み付けであり、いずれも約 4.0 kHz までの周波数成分が集中的に選択された。図 13(b) は同じ弱識別器のテンプレートマッチングによる健全および変状サンプルの識別結果であり、横軸および縦軸はそれぞれ健全サンプルおよび変状サンプルを用いて生成した周波数テンプレートとの重みつき ZNCC の相関値である。青い丸の点が健全サンプルを、赤い十字の点に変状サンプルの値を示しており、紫色の直線が最適化計算により得られた識別直線である。多数の弱識別器候補から健全と変状を良く分類可能な周波数帯が探索され、それらを分類するための線形識別関数が獲得できたことが確認できる。


訓練データの取得に用いた試験体とは異なる試験体 TP_{V1} および TP_{V2} を用いて斜めひび割れ変状の検出実験を行った。15 度の角度で斜めひび割れが侵入している試験体 TP_{V1} に対する打診のスペクトログラムを図 14(a) に示す。また、定性的な比較のために変状部と健全部に関するスペクトログラムを時間方向に拡大して、それぞれ図 14(b)、図 14(c) に示す。例えば、健全部の打音は変状部と比較して、約 10 kHz から約 13 kHz におけるピーク値の継続時間が長いなどの定性的な差が確認でき、このような特性の違いを学習することで変状検出を行う。打音信号の周波数解析結果に対する時系列での変状検出の結果を図 14(d) に示す。また、30 度の角度で斜めひび割れが侵入している試験体 TP_{V2} についても同様に図 14(e)–(h) に結果を示す。図中の信号値のピークからも確認できるように打診動作は約 9 秒間で計 9 回行った。いずれの結果においても、各試験体の健全部、変状部、健全部の順でそれぞれ 3 回ずつ打診した。見やすさのために打診が行われた瞬間を図上部に逆三角形 (∇) でマークしており、変状検出器により変状と識別された時間帯を赤い網掛けで示している。図 14(d) および図 14(h) の結果から、




(a) Ground truth of defective area in TP_{V1} which has a 15 deg slant crack.



(c) Ground truth of defective area in TP_{V2} which has a 30 deg slant crack.



(b) Defect detection result of TP_{V1} .



(d) Defect detection result of TP_{V2} .

Fig. 15 Result of slant crack position detection in TP_{V1} and TP_{V2} . Figures (a) and (c) are the ground truth of the defective area of TP_{V1} and TP_{V2} , respectively. In both figures, the area under which exfoliation exists is emphasized by the half-tone background with red color. Figure (a) also shows a result of the stroke point estimation by detecting the hammer head, which is painted in red. The estimated stroke point is indicated as a blue point. Figures (b) and (d) are the results of defect detection from TP_{V1} and TP_{V2} , respectively. In both figures, the green spots indicate the stroke points estimated as cleans. The red spots indicate ones as defects. The proposed detector could detect the defective areas accurately.

変状信号を正しく識別できていることが確認できる。図 12 に示したように、学習に用いた変状試験体 TP_{L2} はひび割れの侵入距離が長く、評価に用いた試験体 TP_{V1} および TP_{V2} のひび割れが達する深さまでの変状サンプルの打音を学習時に取得することが可能であった。

変状検出器と RGB-D センサを用いて打点の検出とを組み合わせた変状検出システムにより、変状位置の検出実験を行った。打診箇所を診断を行うためには、打音信号全体についての健全・変状識別を行う必要がある。本実験では、打音継続区間で得られたスペクトル群に対する識別結果の多数決で診断した。すなわち、健全と識別された回数が変状よりも多い場合に健全と診断し、それ以外を変状として検出した。

変状位置の検出結果を図 15 に示す。試験体 TP_{V1} における変状位置の真値を図 15(a) に示し、変状位置の検出結果を図 15(b) に示す。表 1 で示した斜めひび割れ変状は、図 15(a) 中で赤く網掛けを位置している部分に侵入している。図 15(a) 中で青色の点で示されている点が、検出された打点の位置である。図 15(b) 中で赤および緑の点として記されている点が打診を行った点であり、赤色が変状検出システムにより変状と判定された点であり、緑色が健全と判定された点である。試験体 TP_{V2} についても同様の結果を図 15(c) および図 15(d) に示す。図 15(b) と図 15(d) のいずれの結果においても試験体中でひび割れが侵入している部分が精度良く検出できていることが確認できる。




Fig. 16 Hammering spectrogram of under the background noise of an air conditioner. The noise mainly overlapped hammering sound at up to 10 kHz. The noise influences the performance of the defect detector in diagnosis.




Fig. 17 Result of template update: The new template vector was updated based on the prior template vector that was reduced constantly by a factor of c_t in eq. (18). Although A^* basically retained the shape of the prior template vector according to eq. (18), the shape changed partly.

図 15(b)において、変状箇所がひび割れ開口部に集中している。試験体 TP_{V1} はひび割れの進入角度が 15 度と浅く、その剥離部分は極めて浅い位置に存在するため、表層下部にひび割れが存在する部分は極めて脆くなっている。本実験は開口部付近より行ったが、開口部付近から徐々に破損した破片がひび割れ内部に蓄積することで、設計値よりもひび割れの水平到達距離が短くなっていたことが原因と考えられる。

4.3.2 キャリブレーション実験

検査環境が変化した場合に変状検出器のキャリブレーションを行う実験を行った。事前学習を済ました変状検出器として 4.3.1 項で生成した変状検出器を用いた。検査環境の変化としては、トンネル内を吹き抜ける強風や通行車両のエンジン音などの背景ノイズの発生を想定して、室内空調機を作動させることで背景ノイズを発生させた。背景ノイズが存在する中で打診を行った際のスペクトログラムの例を図 16 に示す。図中の信号値のピークからも確認できるように、打診は 4.3.1 項と同様に約 9 秒間の間に 9 回行った。スペクトログラムの色から図 14(a) および図 14(e) と比較して、低周波数帯のノイズが大きいことが確認できる。打音に対するノイズの大きさの Signal-to-Noise Ratio (S/N 比) は約 26 dB であった。追加学習は背景ノイズの存在下での試験体 TP_{L1} および TP_{L2} の打音を用いて行った。追加学習には、687 個の訓練データを用いて行い、健全サンプル数は 393、変状サンプル数は 294 とした。

図 13 で示した弱識別器に関して、テンプレートベクトルの更新結果の例を図 17 に示す。横軸は周波数成分のインデックス k であり縦軸は振幅値である。更新後のテンプレートベクトル A^* は、式 (18) に従い、図 7 において模式的に示したように事前学習におけるテンプレートベクトル \tilde{A} の形状を維持しながら部分的に更新されたことが確認できる。

コンクリート試験体 TP_{V3} に関して、背景ノイズが存在しない場合における事前学習で生成した変状検出器の検出結果を図 18(a) に示す。さらに、図 16 で示した背景ノイズ存在下での事前学習および追加学習で生成した変状検出器による検出結果を、図 18(b) と図 18(c) にそれぞれ示す。提案手法の効果検証を行ううえでの比較のために、図 18(b) と図 18(c) では同じ打音信号を用いた。いずれの図においても図 14 と同様であり、計 9 回の打診に関しては、健全部、変状部、健全部の順でそれぞれ 3 回ずつ打診した。まず図 18(a) から、試験体 TP_{V3} に対しても変状部の打音信号を正確に検出可能な変状検出器が事前学習により獲得できたことが確認できる。次に図 18(b) では、変状部を正確に検出できず、かつ健全部を変状部と誤判定するように性能が低下したが、これは背景ノイズが出現による影響である。さらに、図 18(b) と図 18(c) との比較から、追加学習を行うことで正確に検出可能になったことが確認できる。本提案手法では 4.1.1 項で述べたように打診直前の背景ノイズのスペクトル推定を行い打音信号から減算することで変状判定の精度を向上しているが、背景ノイズの信号レベルが大きい場合には変状判定に用いていた打音信号の周波数成分が失われてしまい、健全と変状の周波数テンプレートのいずれとも相関が低くなってしまい誤判定が生じる。各弱識別器は、異なる周波数テンプレート対を用いて、異なる周波数帯における評価を行っている。追加学習では、背景ノイズが存在する環境での打音信号を訓練データとして用いることで、弱識別器ごとにノイズ環境下における識別性能を向上させるように背景ノイズのスペクトル形状を




Fig. 18 Result of validation experiment of updation algorithm of proposed method. The test piece TP_{V3} that has 45 deg crack was used to confirm the validity of the proposed method under the noise-free (a) and noisy (b), (c) environments. The areas emphasized by the half-tone background with red color indicate the time intervals that were detected as the defects.

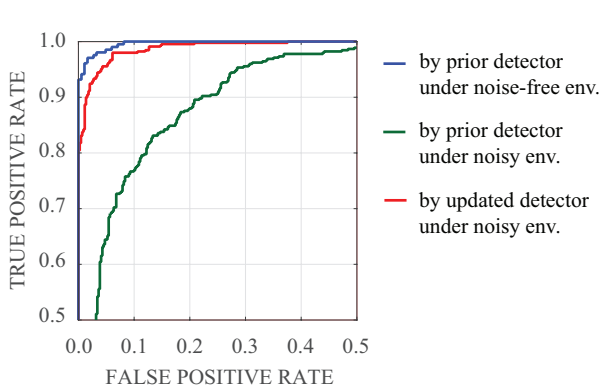


Fig. 19 ROC curves show the performance of the defect detectors, which were evaluated by using TP_{V3}. Blue line indicates the result by the prior detector under the noise-free environment. The proposed detector performed accurately. Green line is one by the prior detector under the noisy environment, whose performance of detection was decreased by influence of the noise. While, red line is the result by the updated detector under the noisy environment. The performance was considerably recovered by the proposed updation method.





Fig. 20 Ground truth of defect position of TP_{V3}, which has 45 deg slant crack. The area under which exfoliation exists is emphasized by the half-tone background with red color.

利用して周波数テンプレートを変形したと考えられる。

背景ノイズの出現による変状検出性能の低下、および提案手法を用いた性能の回復の定量的な度合いを図 19 に示す。評価においては、図 18 と同様に試験体 TP_{V3} の健全部、変状部に対する打音信号を用いた。変状検出器の性能評価には、識別器の性能評価に一般的に用いられる受信者操作特性 (Receiver Operating Characteristic: ROC) 曲線を用いた。ROC 曲線では、横軸に偽陽性率を示し、縦軸に真陽性率を示す。診断が適切であるほど ROC 曲線は (0,0) と (1,1) を結ぶ 45 度の線から左上方向に凸型になる。ROC 曲線の傾向を定量的に評価するためには、一般的に ROC 曲線下の面積 (Area Under the Curve: AUC) を用いる。AUC の値域は [0, 1] であり、1 に近いほど性能が良いと見なすことができる。ROC 曲線をプロットするために、変状検出においては式 (9) における閾値 Θ を変化させることで変状検出に関する感度の調整を行った。

青線は、事前学習で生成した変状検出器を用いて、背景ノイズの存在しない環境で行った実験結果を示しており、その AUC は 0.998 であった。緑線は、同じく事前学習で生成した変状検出器を用いて、背景ノイズが存在下での結果を緑線で示しており、その AUC は背景ノイズの影響により 0.928 と低下した。また赤線は、提案手法を用いて更新した変状検出器による、背景ノイズの存在下での実験結果を示しており、その AUC は提案手法により 0.997 と回復した。いずれの評価においても、健全部・変状部をそれぞれ 20 点ずつ打診した際のスペクトル群を用いて評価した。



(a) Result by the prior detector under the noise-free environment. The hammering sounds from defective parts were detected accurately, and the locations were identified correctly.

(b) Result by the prior detector under the background noise. The defective parts were not detected by influence of the noise.

(c) Result by the updated detector under the background noise. The defective parts has become identified correctly.

Fig. 21 Results of slant crack position detection in TP_{V3} . In all figures, the green spots indicate the stroke points estimated as cleans. The red spots indicate ones as defects. As shown in the ground truth of 図 20, the performance of the detector which had decreased by the influence of the noise was recovered by proposed method.

事前学習および追加学習による変状検出器を用いて、ひび割れ変状位置の検出実験を行った。変状位置の真値を図 20 に示し、提案手法を用いた検出結果を図 15 と同様の形式で図 21 に示す。図 21(a) および図 21(b) が事前学習で生成した変状検出器の検出結果であり、それぞれ背景ノイズが存在しない場合と背景ノイズの存在下での結果である。図 21(c) が提案手法を用いて追加学習によりキャリブレーションを行った変状検出器の検出結果である。事前学習で生成した変状検出では、背景ノイズの出現により検出性能が低下するが、提案手法を用いたキャリブレーションにより正確に斜めひび割れ変状の存在する範囲が検出可能となったことが確認できる。

本研究で提案した周波数テンプレートの更新則は、計算時間の面でも特長がある。一般的に多数の訓練データを用いた学習を一から行う場合は多大な計算時間を要する場合が多い。本研究でも、変状検出器の学習では各弱識別器の最適化計算においては全訓練データの評価を行い、選定のための繰り返し計算を行うために多くの計算時間を要する。一方、本研究では追加学習を更新則として導出しているため、選定のための繰り返し計算が不要である。例えば、本論文の結果では、256 個の弱識別器を生成するために、事前学習においては 4,263 個の訓練データを用いて、各弱識別器に対して 1,000 回の繰り返し計算を行った。その場合の計算時間は約 31,980 s であるのに対して、追加学習における計算時間は大幅に短縮され、256 個の弱識別器の更新に 687 個の追加訓練データを用いた場合で約 20 s であった。提案手法を適用することで、膨大なデータを用いて獲得した変状検出器をベースに、異なる背景ノイズが存在する環境において、短時間で性能の良い変状検出器が獲得できる。

以上の実験により、検査環境が変わった場合も提案手法を用いてキャリブレーションを行い、テンプレートベクトルを更新することで既存の変状検出器を再利用し、新たな変状を検出可能な検出器が生成できることが確認できた。

5. 結 言

本研究では、打音検査における変状検出器にキャリブレーション機能を備える目的で、ブースティングベースの追加学習アルゴリズムを提案した。第 2 章では、周波数領域におけるスペクトル形状を用いた健状・変状テンプレート対の生成方法を説明し、テンプレートマッチングによる類似度評価に基づく弱識別器を提案した。第 3 章では、異なる健状・変状テンプレート対を持つ複数の弱識別器群を、ブースティングアルゴリズムを応用することで生成し統合した。さらに、本論文の主題である変状検出器の自動校正を実現するために、周波数テンプレートの更新則を新規に提案した。第 4 章では、打音検出と同時に背景ノイズの影響を軽減する手法、RGB-D センサを用いた打点位置の検出手法について述べた。さらに、それらを備えた変状検出システムによる提案手法の検証実験を行い、現場で重要視されている斜めひび割れ検出に有効であることを確認し、信号レベルの大きい背景ノイズが存在する環境でキャリブレーションが可能であることを確認した。

実際の現場への適用する際には、健状・変状データは現場の一部においてあらかじめ取得できることが望ましい。しかし、事前のデータ取得が困難な場合も想定される。その場合には、例えば実験室環境で事前学習を行って生成した性能の良い変状検出器をベースとし、事前学習で用いた訓練データに現場で想定される背景ノイズを重畳させることで生成した音源を用いて、追加学習させるアプローチが考えられる。その際、実際の打音検査の現場への適用においてはトンネル内での風切り音以外にも、様々な環境の違いを考慮する必要がある。現場特有のノイズの特性と周波数テンプレートの更新のメカニズムに関する詳細な考察を行うことで本手法を発展させ、検出器の環境適応性能を向上させることは今後の課題である。

打音検査には、変状の有無の検出だけではなくひび割れが存在する深さを推定するなど、より詳細な検査への適用が期待されている。打音信号を用いた詳細な診断手法の構築も今後の課題である。

謝辞

本研究の一部は、NEDO 技術開発機構からの研究委託「SIP（戦略的イノベーション創造プログラム）インフラ維持管理・更新・マネジメント技術／維持管理ロボット・災害対応ロボットの開発／トンネル全断面点検・診断システムの研究開発」において実施したものであり、JSPS 特別研究員奨励費 26-9039 の助成、および東急建設株式会社 技術研究所の支援を受けたものである。

文 献

- Asakura, T. and Kojima, Y., Tunnel maintenance in Japan, *Tunnelling and Underground Space Technology*, Vol. 18, No. 2 (2003), pp. 161–169.
- Boll, S. F., Suppression of acoustic noise in speech using spectral subtraction, *IEEE Transaction on Acoustics, Speech and Signal Processing*, Vol. 27, No. 2 (1979), pp. 113–120.
- Cocconcelli, M., Zimroz, R., Rubini, R. and Bartelmus, W., STFT based approach for ball bearing fault detection in a varying speed motor, *Condition Monitoring of Machinery in Non-Stationary Operations*, Springer Berlin Heidelberg (2012), pp. 41–50.
- Fischler, M. A. and Bolles, R. C., Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography, *Communications of the ACM*, Vol. 24, No. 6 (1981), pp. 381–395.
- Freund, Y. and Schapire, R. E., A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, Vol. 55, Issue 1 (1997), pp. 119–139.
- 藤井 浩光, 山下 淳, 浅間 一, 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*, Vol. 80, No. 9 (2014), pp. 844–850.
- Fujii, H., Yamashita, A. and Asama, H., Improvement of environmental adaptivity of defect detector for hammering test using boosting algorithm, *Proceedings of the 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems* (2015), pp. 6507–6514.
- Hoła, J., Bień, J., Sadowski, Ł. and Schabowicz, K., Non-destructive and semi-destructive diagnostics of concrete structures in assessment of their durability, *Bulletin of the Polish Academy of Sciences Technical Sciences*, Vol. 63, No. 1 (2015), pp. 87–96.
- Igual, J., Salazar, A., Safont, G. and Vergara, L., Semi-supervised bayesian classification of materials with impact-echo signals, *Sensors*, Vol. 15, Issue 5 (2015), pp. 11528–11550.
- Inoue, F., Doi, S., Ishizaki, T., Ikeda, Y. and Ohta, Y., Study on automated inspection robot and quantitative detection of outer tile wall exfoliation by wavelet analysis, *Proceedings of International Conference on Control, Automation and Systems 2010* (2010), pp. 994–999.
- Mjit, M., Beaujean, P. J. and Vendittis, D. J., Comparison of fault detection techniques for an ocean turbine, *Proceedings of the Annual Conference of the Prognostics and Health Management Society* (2011), pp. 123–133.
- Sonoda, Y. and Fukui, Y., A basic study on hammering tests of deteriorated concrete structures, *35th Our World in Concrete and Structures*, 100035063 (2010).

- Suda, T., Tabata, A., Kawakami, J. and Suzuki, T., Development of an impact sound diagnosis system for tunnel concrete lining, *Tunneling and Underground Space Technology*, Vol. 19, Issue 4–5 (2004), pp. 328–329.
- Takada, R. and Oishi, N., Priority issues of infrastructure inspection and maintenance robot: A part of COCN 2012 project “Disaster response robot and its operational system”, *Humanitarian Technology Conference (R10-HTC)*, 2013 IEEE Region 10 (2013), pp. 166–171.
- Yamashita, A., Hara, T. and Kaneko, T., Inspection of visible and invisible features of objects with image and sound signal processing, *Proceedings of the 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems (2006)*, pp. 3837–3842.
- Ye, J., Iwata, M., Kobayashi, T., Murakawa, M., Higuchi, T., Kubota, Y., Yui, T. and Mori, K., Statistical impact-echo analysis based on grassmann manifold learning: Its preliminary results for concrete condition assessment, *Proceedings of 7th European Workshop on Structural Health Monitoring (2014)*, pp. 1349–1356.
- Zhang, G., Harichandran, R. S. and Pradeep, R., An automatic impact-based delamination detection system for concrete bridge decks, *NDT & E International*, Vol. 45, No. 1 (2012), pp. 120–127.

References

- Asakura, T. and Kojima, Y., Tunnel maintenance in Japan, *Tunnelling and Underground Space Technology*, Vol. 18, No. 2 (2003), pp. 161–169.
- Boll, S. F., Suppression of acoustic noise in speech using spectral subtraction, *IEEE Transaction on Acoustics, Speech and Signal Processing*, Vol. 27, No. 2 (1979), pp. 113–120.
- Cocconcelli, M., Zimroz, R., Rubini, R. and Bartelmus, W., STFT based approach for ball bearing fault detection in a varying speed motor, *Condition Monitoring of Machinery in Non-Stationary Operations*, Springer Berlin Heidelberg (2012), pp. 41–50.
- Fischler, M. A. and Bolles, R. C., Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography, *Communications of the ACM*, Vol. 24, No. 6 (1981), pp. 381–395.
- Freund, Y. and Schapire, R. E., A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, Vol. 55, Issue 1 (1997), pp. 119–139.
- Fujii, H., Yamashita, A. and Asama, H., Automated recognition of material condition using boosting algorithm in hammering test, *Journal of the Japan Society for Precision Engineering*, Vol. 80, No. 9 (2014), pp. 844–850 (in Japanese).
- Fujii, H., Yamashita, A. and Asama, H., Improvement of environmental adaptivity of defect detector for hammering test using boosting algorithm, *Proceedings of the 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (2015)*, pp.6507–6514.
- Hoła, J., Bień, J., Sadowski, Ł. and Schabowicz, K., Non-destructive and semi-destructive diagnostics of concrete structures in assessment of their durability, *Bulletin of the Polish Academy of Sciences Technical Sciences*, Vol. 63, No. 1 (2015), pp. 87–96.
- Igual, J., Salazar, A., Safont, G. and Vergara, L., Semi-supervised bayesian classification of materials with impact-echo signals, *Sensors*, Vol. 15, Issue 5 (2015), pp. 11528–11550.
- Inoue, F., Doi, S., Ishizaki, T., Ikeda, Y. and Ohta, Y., Study on automated inspection robot and quantitative detection of outer tile wall exfoliation by wavelet analysis, *Proceedings of International Conference on Control, Automation and Systems 2010 (2010)*, pp. 994–999.
- Mjit, M., Beaujean, P. J. and Vendittis, D. J., Comparison of fault detection techniques for an ocean turbine, *Proceedings of the Annual Conference of the Prognostics and Health Management Society (2011)*, pp. 123–133.
- Sonoda, Y. and Fukui, Y., A basic study on hammering tests of deteriorated concrete structures, *35th Our World in Concrete and Structures*, 100035063 (2010).
- Suda, T., Tabata, A., Kawakami, J. and Suzuki, T., Development of an impact sound diagnosis system for tunnel concrete lining, *Tunneling and Underground Space Technology*, Vol. 19, Issue 4–5 (2004), pp. 328–329.

- Takada, R. and Oishi, N., Priority issues of infrastructure inspection and maintenance robot: A part of COCN 2012 project “Disaster response robot and its operational system”, Humanitarian Technology Conference (R10-HTC), 2013 IEEE Region 10 (2013), pp. 166–171.
- Yamashita, A., Hara, T. and Kaneko, T., Inspection of visible and invisible features of objects with image and sound signal processing, Proceedings of the 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems (2006), pp. 3837–3842.
- Ye, J., Iwata, M., Kobayashi, T., Murakawa, M., Higuchi, T., Kubota, Y., Yui, T. and Mori, K., Statistical impact-echo analysis based on grassmann manifold learning: Its preliminary results for concrete condition assessment, Proceedings of 7th European Workshop on Structural Health Monitoring (2014), pp. 1349–1356.
- Zhang, G., Harichandran, R. S. and Pradeep, R., An automatic impact-based delamination detection system for concrete bridge decks, NDT & E International, Vol. 45, No. 1 (2012), pp. 120–127.