

打音検査に基づく変状検出手法における環境適応性能の向上

藤井 浩光^{*1}, 山下 淳^{*1}, 滝間 一^{*1}

Improvement of Environmental Adaptivity for Defect Detection in Hammering Test

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

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

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 real inspection sites, its environmental adaptability such as portability to other situations is highly significant. In this paper, in order to improve environmental adaptivity of a defect detector of hammering test, a boosting based algorithm with an updatation rule for detecting another defect is proposed. Specifically, an optimization of feature vectors of hammering sound and an updatation rule of template vectors are presented. In an experiment, our method was applied to the detection problem of crack defect using two different concrete test-pieces. As the result, the effectiveness of the proposed method was confirmed.

Key Words : Automated diagnosis, Defect detection, Hammering test, Boosting

1. 序論

社会インフラの老朽化は深刻な問題であり、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る始めている⁽¹⁾。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。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、ロボットなどを用いた点検作業の自動化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非常に重要である。打音検査法は非破壊検査の手法の1つであり、その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いる。打音検査では、検査用ハンマー（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。打音検査法に基づく異常診断の研究は多数なされおり^{(2)~(4)}、我々の研究グループにおいても打音を用いた変状検出手法を提案してきた^{(5)~(7)}。特に打音検査法と機械学習におけるブースティング手法を組み合わせた変状検出手法においては、

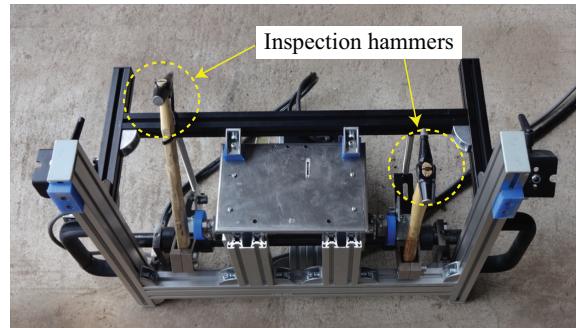


Fig. 1 A prototype of a hammering robot

屋内建材に対してその有効性を確認した⁽⁶⁾⁽⁷⁾。

今後、例えば図1のような自動装置を用いて、これらの手法を実際の点検現場に適用していくことが期待される。しかし、実際の現場に適用する際の重要な要件として、検査手法の環境適応性が挙げられる。実際の点検現場では、事前学習で得られた変状検出器を複数の現場に適用することが望まれている。例えば、あるトンネルに対して構築した検出器を異なる時間帯の同一のトンネルあるいは他のトンネルに適用した場合、十分な性能が得られないという問題が生じる。天候変動による風量の差や車両通行の頻度などで異なる環境ノイズの有無、または構造物の立地などの物理的な条件が異なった場合、得られるデータは事前学習に用いたデータとは性質が大きく異なり、正確な検出ができ

^{*1} 東京大学大学院工学系研究科精密工学専攻（〒113-8654 東京都文京区本郷7-3-1) {fujii,yamashita,asama}@robot.t.u-tokyo.ac.jp

ない。検出器の生成には多数のデータを収集する必要があり現場ごとに一から識別器を生成するのは困難である。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。

転移学習の領域で、ブースティング手法における追加学習に関する研究が報告されている^{(8)~(10)}。これらの手法では、仮想環境において生成した膨大かつ多様なデータを基に事前学習を行うことが可能である。そのため、CG やシミュレーションなどを利用して理想的な環境下で識別器を生成し、実際の環境に適用する際に追加学習で整合性を持たせるというアプローチが多くとられている。しかし、本研究で対象とする打音診断では、得られるデータは検査対象や環境に大きく依存し、複雑に変化するために打音のシミュレーションを行うことは困難である。また、様々なノイズが存在する実環境においては、十分な種類と量のデータを得ることは困難であるため、同様のアプローチをとることは難しい。

本研究では、打音検査における変状検出器の環境適応性能を向上させる目的で、ブースティング手法に基づく追加学習アルゴリズムを提案する。具体的には、周波数領域でテンプレートマッチングを行う識別器をブースティング手法を用いて統合する際に、テンプレートベクトルの更新、および各周波数成分に対する重み付けの最適化を行う機構を導入する。提案手法を用いた実験では、事前学習で生成した検出器の追加学習により、事前学習済みの変状に対する検出性能を維持しつつ、新たな変状を正確に検出可能な検出器が得られることを示す。

2. 打音のテンプレートマッチングによる変状検出

2.1 短時間フーリエ変換 周波数変換は時系列信号の解析に広く用いられている手法であり非常に有効である。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、時間窓の位相ずなわち周波数解析を行う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 (STFT: Short-Time Fourier Transform) は、式 (1) で表されるように時間窓をスライディングさせながら 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⁽¹¹⁾⁽¹²⁾。

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

ここで、 $w[n]$ は時間窓関数であり、 ω は角周波数である。結果として得られるのは時間軸上で連続するスペクトルの変化であり、本研究ではこのスペクトル群を検査対象の性質を表す特徴量として学習させることで変状検出を行う。STFT による出力信号を学習させることで、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る。単一の FFT は高速で行うことが可能であるため、診断のオンライン化が可能であることも本手法の利点の 1 つである。

2.2 重み付け正規化相互通関によるテンプレートマッチング 本研究では、スペクトル形状のテンプレートマッチングにより変状検出を行う。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、正規化相互通関 (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、評価対象の信号から得られる x に対して以下の式 (2) で表される。

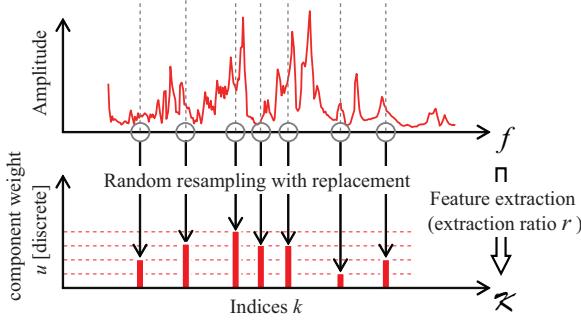
$$S(A, u, x) = \frac{\sum_{k \in \mathcal{K}} u_{(k)}(A_{(k)} - \bar{A})(x_{(k)} - \bar{x})}{\sqrt{\sum_{k \in \mathcal{K}} u_{(k)}(A_{(k)} - \bar{A})^2} \sqrt{\sum_{k \in \mathcal{K}} u_{(k)}(x_{(k)} - \bar{x})^2}}, \quad (2)$$

ここで、 A は新たな評価対象と比較・評価するための、訓練サンプルから計算されるテンプレートベクトルである。 \mathcal{K} はテンプレート A と x 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。 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 A の k 番目の成分を示す。 \bar{A} および \bar{x} は、それぞれ A および x の平均値である。

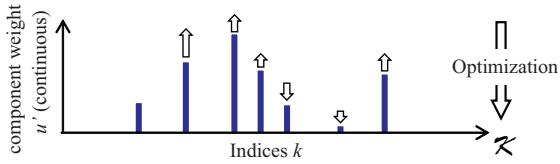
ZNCC に基づく評価値 $S(A, u, x)$ を用いた識別器 $h(x)$ は式 (3) で表される。

$$h(x) = \begin{cases} 1 & \text{if } S(^D A, ^D u, x) - S(^C A, ^C u, x) > \theta \\ -1 & \text{otherwise} \end{cases}, \quad (3)$$

ここで、 θ は判別のための閾値で識別器に対して固有に設計される定数である。 $^D A$ および $^C A$ は、それぞれ変状および健状の訓練サンプルから生成されるテンプレートベクトルである。識別器のテンプレートベクトルは各訓練サンプル $x^{(i)}$ に対して、その識別器が固



(a) Bootstrapping feature extraction: the components of selected feature vector \mathbf{u} are discrete value.



(b) Optimization by the downhill simplex method: the components of optimized feature vector \mathbf{u}' are continuous value.

Fig. 2 Feature extraction using a Bootstrapping (section 2.3) and optimization of feature vector using the downhill simplex method (section 2.4)

有に持つ重み $w^{(i)}$ を考慮して, ${}^D\mathbf{A}(k) = \sum_{i \in \mathcal{I}} w^{(i)} x^{(i)}(k)$, ${}^C\mathbf{A}(k) = \sum_{j \in \mathcal{J}} w^{(j)} x^{(j)}(k)$ として生成する. \mathcal{I} および \mathcal{J} はそれぞれ健状および変状の訓練サンプルを指すインデックス集合である. すなわち, $\mathbf{x}^{(i)}$ ($i \in \mathcal{I}$) は健状の訓練サンプルであり, $\mathbf{x}^{(j)}$ ($j \in \mathcal{J}$) は変状のサンプルである. 各訓練サンプルの重みづけはブースティング学習時の繰り返し計算の中で行われ, その詳細は 3.1 節の中で述べる. ${}^D\mathbf{u}$ および ${}^C\mathbf{u}$ は, それぞれ健状データおよび変状データにおける各周波数成分の重みである.

式(2)および式(3)において, θ , \mathcal{K} および \mathbf{u} が識別器に対して固有に設計されるパラメータである. 特に, 周波数成分のインデックス集合 \mathcal{K} と, 各周波数成分の重みである特徴ベクトル \mathbf{u} が打音の特徴量を表す. これらのパラメータは学習時に訓練サンプルに対する誤り率 ϵ が最小となるように設定される. インデックス集合 \mathcal{K} および成分重み \mathbf{u} の選択と最適化に関しては 2.3 節と 2.4 節で詳述する.

2.3 復元抽出法による特徴ベクトル化 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をするためには, 検査対象の状態を表す適切な周波数成分で評価する必要がある. すなわち, 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 2(a)). 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. 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} とし, 各インデックス $k \in \mathcal{K}$ が指す周波数成分が選択された回数を, 各周波数成分の重み $u(k)$ とする. 学習の過程では, それぞれ異なる \mathcal{K} と \mathbf{u} を与えた識別器候補について式(3)をそれぞれ計算することで, 訓練サンプルに対して誤り率 ϵ を最小とする, すなわち変状の検出に有効な周波数成分と重み付けを探査する. 同時に, 全周波数成分からの抽出率 $r = M/N$ も識別器候補ごとに与えた探索を行う. ここで得られた成分重み \mathbf{u} が打音の特徴ベクトルとなる.

2.4 特徴ベクトルの最適化 本研究の特徴ベクトルの抽出手法では, 重複を許す選択を行うことで周波数成分に対する重み付けを自然に獲得することができる. しかし, 一方でランダムなサンプリングを行っていることで正確な検出を阻害する周波数成分が混入するという問題がある.

本研究では, 検出に不要な成分を抑圧するために特徴ベクトルの最適化を行う (図 2(b)). この問題は非線形の制約条件付き多次元最適化問題として以下のように記述される.

$$\text{minimize : } V(\mathbf{u}) \quad (4)$$

$$\text{subject to : } \mathbf{u} \in \mathcal{S}_{\mathbf{u}}, \quad (5)$$

ここで, 周波数成分に対する重みである特徴ベクトル \mathbf{u} が最適化対象のパラメータである. $V(\mathbf{u})$ は評価関数であり, 訓練サンプルに対する識別の誤り率 ϵ に相当する. $\mathcal{S}_{\mathbf{u}}$ は制約条件を満たす最適化パラメータの集合であり, $u(k) > 0$ ($k \in \mathcal{K}$) の制約条件を設けている.

訓練サンプルとラベルの数学的関係や, 特徴ベクトルに関する検出精度の導関数は明らかではないため, 最適化には直接探索法である滑降シンプレックス法⁽¹³⁾ を用いる. 探索の初期値に 2.3 節で選択された特徴ベクトルを用いることで, 正確な検出を阻害する成分の重みを小さくすることが可能である. この最適化により抑圧された周波数成分は, 対象の性質が変化した場合には, 再度重みが調整され顕在し得る潜在的な成分である.

3. 追加学習のためのテンプレート更新則

3.1 ブースティング用いた識別器の統合 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⁽¹⁴⁾ 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 3 に示す. ブースティングアルゴリズムでは, 訓練

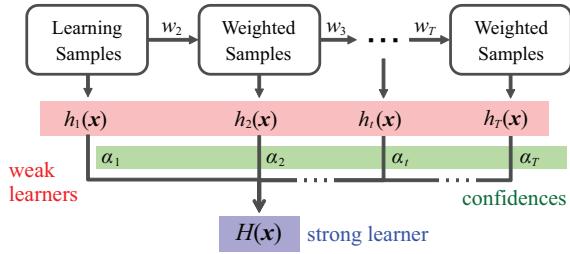


Fig. 3 Schematic view of a general boosting algorithm

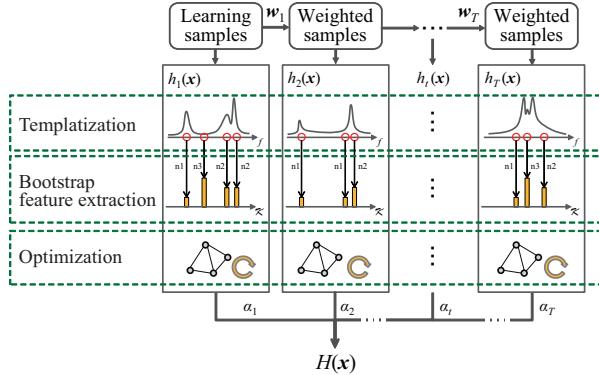


Fig. 4 Schematic view of newly proposed boosting framework for additional learning.

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）を逐次生成していく、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、単独の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} に対しての強識別器 $H(\mathbf{x})$ は、以下のように表される 2 クラス識別器である。

$$H(\mathbf{x}) = \text{sign} \left[\sum_{t=1}^T \alpha_t h_t(\mathbf{x}) \right] \in \{-1, 1\}, \quad (6)$$

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 は訓練サンプルに対する誤り率 ϵ_t から計算される各弱識別器の信頼度であり、 $\alpha_t = \frac{1}{2} \log((1 - \epsilon_t)/\epsilon_t)$ と計算される。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。

提案手法のブースティングの基本構造を図 4 に示す。各弱識別器は第 2 章で述べたテンプレート生成部、復元抽出法による特徴ベクトル抽出部、特徴ベクトルの最適化部を持つ。

個数 I のラベル付き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

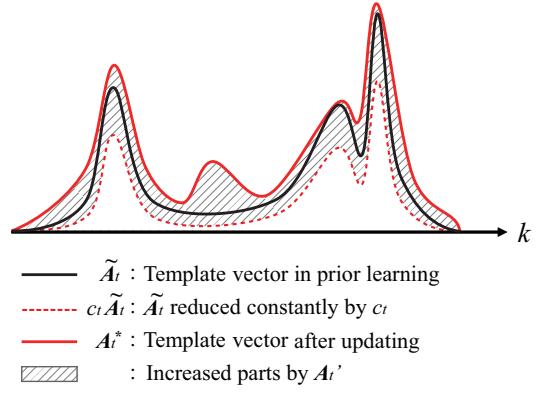


Fig. 5 Schematic view of template vector updatation of our method shown in 式 (15)

了後に、 i 番目の訓練サンプル $(\mathbf{x}^{(i)}, y^{(i)})$ の重み $w_t^{(i)}$ は以下のように更新される。

$$w_{t+1}^{(i)} = w_t^{(i)} e^{-\alpha_t y^{(i)} h_t(\mathbf{x}^{(i)})}, \quad (7)$$

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

3.2 ブースティングにおける評価関数の更新 本節では既にブースティングアルゴリズムで事前学習を行った強識別器に対して、追加訓練セットを用いてテンプレートベクトル A および特徴ベクトル u から成る評価関数を更新するアルゴリズムを提案する。

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 はそれぞれの訓練サンプルの個数である。それらを合わせた訓練データ集合 χ^* に属する訓練サンプル $\mathbf{x}^{*(\ell)}$ ($\ell = 1, \dots, I+J$) を以下のように定義する。

$$\mathbf{x}^{*(\ell)} = \begin{cases} \tilde{\mathbf{x}}^{(\ell)} & (1 \leq \ell \leq I) \\ \mathbf{x}'^{(\ell-I)} & (I+1 \leq \ell \leq I+J) \end{cases}. \quad (8)$$

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、訓練セット $\tilde{\chi}$ に属する i 番目の訓練サンプルの重み $\tilde{w}_t^{(i)}$ 、および χ' に属する j 番目の訓練サンプル $w_t'^{(j)}$ に関して、 $\sum_{i=1}^I \tilde{w}_t^{(i)} : \sum_{j=1}^J w_t'^{(j)} = \tilde{y}_t : y_t'$ 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サンプルの評価結果から以下のように計算される。

$$\tilde{\gamma}_t = \frac{\sum_{j=1}^J \sum_{t=1}^T (\frac{1}{2} \tilde{\alpha}_t (1 + y'^{(j)} \tilde{h}_t(\mathbf{x}'^{(j)})))}{\sum_{j=1}^J \sum_{t=1}^T \tilde{\alpha}_t}, \quad (9)$$

$$\gamma_t' = \frac{\sum_{j=1}^J \sum_{t=1}^T (\frac{1}{2} \alpha_t' (1 + y'^{(j)} h_t'(\mathbf{x}'^{(j)})))}{\sum_{j=1}^J \sum_{t=1}^T \alpha_t'}, \quad (10)$$

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。

$$\alpha_t' = \begin{cases} \alpha_t' & (1 \leq t < t_c) \\ \tilde{\alpha}_t & (t_c \leq t \leq T) \end{cases}. \quad (11)$$

ここで、追加学習済みの弱識別器の信頼度 α_t' ($1 \leq t < t_c$) に関しては、追加学習用の訓練サンプルに対する誤り率から 3.1 節と同様に計算する。弱識別器に関しても信頼度と同様に定義する。

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

$$w_t^{*(\ell)} = \begin{cases} \tilde{w}_t^{*(\ell)} & (1 \leq \ell \leq I) \\ w_t^{*(\ell-I)} & (I+1 \leq \ell \leq I+J) \end{cases}, \quad (12)$$

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サンプルの重み $\tilde{w}_t^{(i)}$ を定数倍したものである。具体的には、各訓練サンプルの重みは $\sum_{i=1}^I w_t^{*(i)} = 1$ 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 (13) および式 (14) で更新される。

$$\tilde{w}_t^{*(i)} \leftarrow \frac{\tilde{\gamma}_t}{(\tilde{\gamma}_t + \gamma_t') \sum_{i=1}^I \tilde{w}_t^{(i)}} \tilde{w}_t^{(i)}, \quad (13)$$

$$w_t'^{(j)} \leftarrow \frac{\gamma_t'}{(\tilde{\gamma}_t + \gamma_t') \sum_{j=1}^J w_t'^{(j)}} w_t'^{(j)}. \quad (14)$$

これらの訓練サンプルの重みの更新則を 2.2 節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。

$$\begin{aligned} A_t^*(k) &= \sum_{\ell=1}^{I+J} w_t^{*(\ell)} \mathbf{x}^{*(\ell)} \\ &= \sum_{i=1}^I \tilde{w}_t^{(i)} \tilde{x}^{(i)}(k) + \sum_{j=1}^J w_t'^{(j)} \mathbf{x}'^{(j)}(k) \\ &= c_t \tilde{A}_t(k) + A_t'(k), \end{aligned} \quad (15)$$

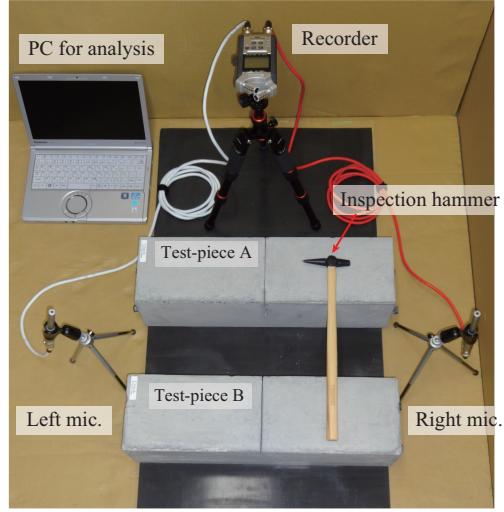


Fig. 6 Experimental devices for hammering test

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、 $A_t'(k) = \sum_{j=1}^J w_t'^{(j)} \mathbf{x}'^{(j)}(k)$ であり、追加学習用の訓練サンプルから生成されるテンプレートベクトルである。追加学習用の訓練サンプル $x'^{(j)}$ の重み $w_t'^{(j)}$ は、式 (7) と同様に以下のように更新される。

$$w_{t+1}'^{(j)} = w_t'^{(j)} e^{-\alpha_t' y'^{(j)} h_t'(\mathbf{x}'^{(j)})}. \quad (16)$$

式 (15) および式 (16) 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サンプル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 (15) におけるテンプレートベクトルの更新則を図 5 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サンプルから計算される A_t' は、式 (15) 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。

テンプレートの更新後、2.4 節と同様に特徴ベクトルの最適化を行う。事前学習の際に抑圧された周波数成分の重みを増すことで、更新されたテンプレートベクトルに特徴ベクトルを適合させる。以上のように、テンプレートベクトルの更新および特徴ベクトルの再最適化により新たな環境に適合した評価関数を獲得することが可能である。

4. 環境適応性能の評価実験

提案手法を打音検査に適用可能であることを示すために、コンクリート試験体を用いた検証実験を行った。

Table 1 The specifications of concrete test-pieces

Test-pieces	Size / Status
for prior learning (TP_A)	140 mm×150 mm×530 mm
	Crack width: 0.5 mm
	Crack depth: 88 mm
for additional learning (TP_B)	140 mm×150 mm×530 mm
	Crack width: 2.0 mm
	Crack depth: 88 mm

この実験は、提案手法が事前学習による既存変状の検出精度を損なうことなく、新たな変状の検出器を生成可能であることを確認する目的で行った。ある変状を学習済みの検出器について検出不能な新たな変状データの追加学習を行い、その検出器の評価を行った。

4.1 実験設定 実験に用いた装置を図 6 に示す。表面ひび割れ変状を有する 2 種類のコンクリート試験体を用いた。これらは点検工の検査訓練用に標準的に用いられている試験体であり、ひび割れの幅が異なるものを用いた。試験体の詳細なスペックを表 1 に示す。試験体 TP_A は事前学習に用いたものであり、試験体 TP_B は追加学習に用いたものである。

点検用具はコンクリー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。測定器具には 2 チャンネルのコンデンサマイクロフォンを用いて、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。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た。弱識別器の個数は 100 とした。

4.2 実験結果

4.2.1 特徴ベクトルの最適化結果 特徴ベクトルの最適化結果を図 7 に示す。横軸は訓練ステップ数 t を示し、各訓練ステップではそれぞれ弱識別器 h_t を生成した。縦軸は誤り率の改善度合いであり、最適化前の誤り率 $\epsilon_t [\%]$ と最適後の誤り率 $\epsilon'_t [\%]$ に関する $\epsilon_t - \epsilon'_t [\%]$ の値を示している。訓練サンプルとして、変状部に対してはひび割れ変状の近傍を打診した打音から成る 1,488 サンプル、健状部に対してはひび割れのない位置を打診した打音および環境音を含む 3,496 サンプルの計 4,984 サンプルを用いた。特徴ベクトルの最適化により、いずれの弱識別器においても誤り率が減少し、改善していることが確認できる。誤り率の改善度合いの平均値は 3.0 % であった。

4.2.2 環境適応性能の評価結果 環境適応性能の評価として、検査対象が異なった場合に追加学習を行う実験を行った。事前学習は試験体 TP_A の左半面で取得したサンプルを用いて行い、追加学習は試験体 TP_B

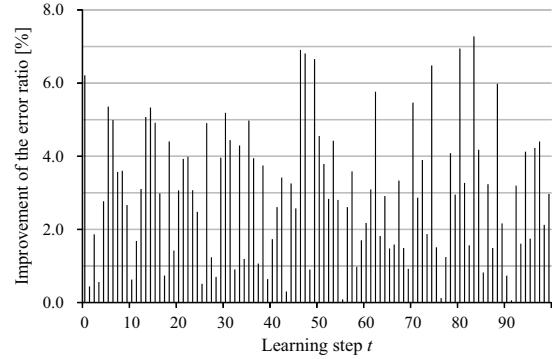


Fig. 7 The optimization result on the error ratios of each weak learners

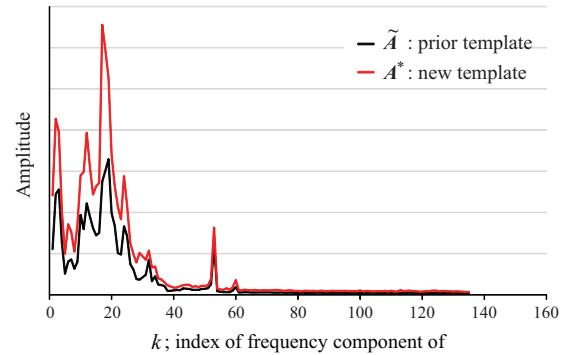


Fig. 8 A result of template updation

の左半面で取得したサンプルを用いて行った。追加学習には、3,624 個の訓練サンプルを用いて行い、変状サンプル数は 800、健状サンプル数は 2,824 とした。

テンプレートベクトルの更新結果の例を図 8 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(15)に従い、図 5 に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。

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の比較を、図 9(a) と図 9(b) にそれぞれ示す。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 10 秒間で計 12 回行った。評価には学習時と異なるデータを用いており、いずれの試験体も学習時とは異なる部分（右半面）で実験を行い、試験体 TP_B の変状部、試験体 TP_B の健状部、試験体 TP_A の変状部、試験体 TP_A の健状部をそれぞれ 3 回ずつ順に打診した。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 9(a) と図 9(b) との比較から、初めの 3 回の打診において、事前学習による検出器では検出でき

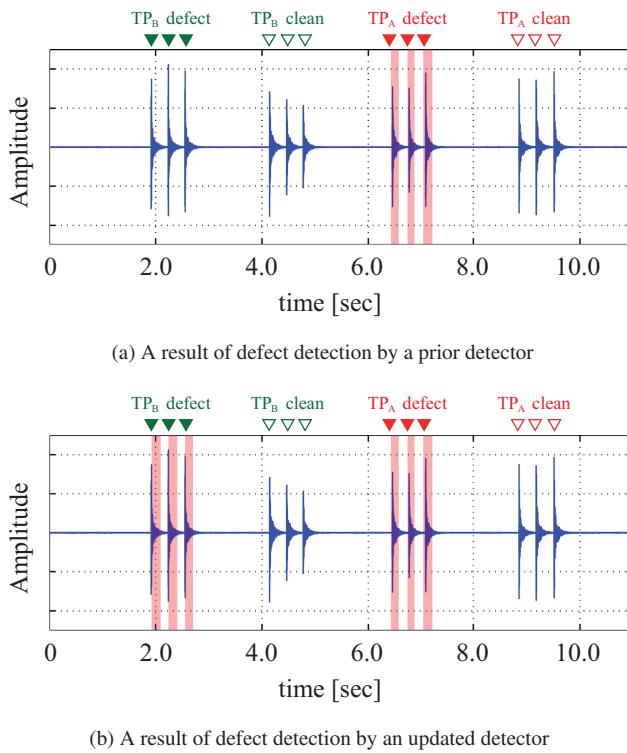


Fig. 9 A comparison of the detection results between a prior detector (Fig. 9(a)) and an updated detector (Fig. 9(b))

ていなかった試験体 TP_B の変状が、追加学習済みの変状検出器によって正確に検出可能になったことが確認できる。また、同時にテンプレートベクトルの形を維持したことで、事前学習で識別できていた試験体 TP_A の変状に関しても精度よく検出できている。

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。実験では、検査用ハンマのヘッド径が収まるサイズに区切られた 12×12 の格子状の各領域を打診した。打点の位置は、検査用ハンマのヘッドにマーカを取り付けることで、画像処理により検出した。打診は各領域に対して 20 回ずつを行い、変状として検出された割合を変状検出率として百分率で求めた。

事前学習および追加学習による変状検出器を用いたひび割れ変状位置の検出結果を図 10(a) および図 10(b) にそれぞれ示し、真値を図 11 に示す。いずれの図においても横軸は X 軸、縦軸は Y 軸とし、試験体 TP_A および試験体 TP_B は Y 方向のそれぞれ上部および下部に位置する。図 10(a) および図 10(b) において、色の濃淡で変状検出率を示しており色が濃いほど打診の結果において変状として検出された回数が多いことを示す。また、試験体 TP_A および試験体 TP_B の試験面

が存在する範囲をそれぞれ赤色の枠および緑色の枠で囲んで示している。

図 10(a) と図 10(b)との比較により、事前学習による変状検出器では検出できない TP_B のひび割れ位置 ($X = 300 \text{ mm}$ 近傍, $Y = 240 \text{ mm} \sim 410 \text{ mm}$ 近傍) が追加学習を行うことで検出可能となったことが確認できる。また、同時に追加学習を行いテンプレートおよび特徴ベクトルの更新を行った場合も、事前学習時に検出可能であった TP_A の変状 ($X = 300 \text{ mm}$ 近傍, $Y = 50 \text{ mm} \sim 210 \text{ mm}$ 近傍) の検出精度は損なわれていないことが確認できる。また、検出された変状位置も図 11 における実際の変状位置とよく一致している。

以上の実験により、提案手法を用いてテンプレートベクトルを更新することで、事前学習における検出性能を維持しながら、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. 結論

本研究では、打音検査における変状検出器の環境適応性能を向上させる目的で、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。周波数領域でスペクトル形状のテンプレートマッチングを行う識別器を導入し、テンプレートベクトルの更新則および各周波数成分に対する重み付けの再最適化を行う機構をブースティング手法に適用したアルゴリズムを提案した。コンクリート試験体を用いた実験では、提案手法により事前学習における検出性能を維持しながら、新たな変状の正確な検出が可能であることを確認した。

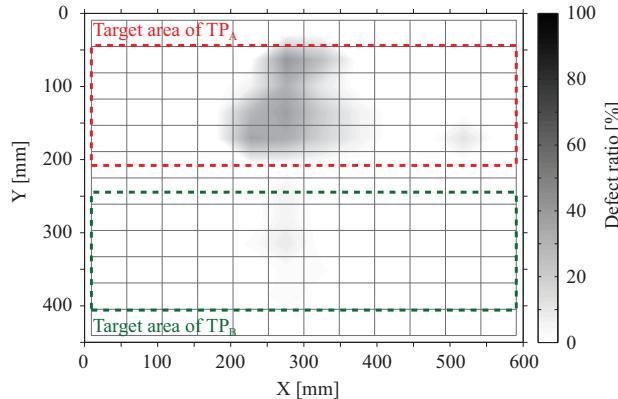
異変状に対する検出器のキャリブレーション以外にも、実際の打音検査の現場においてはトンネル内での風切り音や図 1 に示すような打診ロボット自体の駆動音などの環境ノイズに対する頑健性も重要となる。環境適応性能向上の観点から、本手法を発展させ検出器の耐ノイズ性能を向上させることは今後の課題である。

謝辞

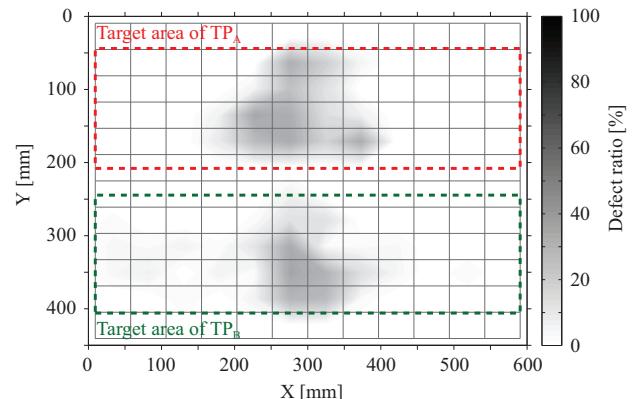
本研究の一部は、NEDO 技術開発機構からの研究委託「SIP（戦略的イノベーション創造プログラム）インフラ維持管理・更新・マネジメント技術／維持管理ロボット・災害対応ロボットの開発／トンネル全断面点検・診断システムの研究開発」において実施したものであり、JSPS 特別研究員奨励費 269039 の助成、およびに東急建設（株）技術研究所の支援を受けたものである。

参考文献

- (1) Ryohei Takada, Naoki Oishi, "Priority Issues of Infrastructure Inspection and Maintenance Robot: A



(a) A detection result of crack locations by prior detector



(b) A detection result of crack locations by updated detector

Fig. 10 A comparison of the detection results of crack location between the prior detector (Fig. 10(a)) and the updated detector (Fig. 10(b))

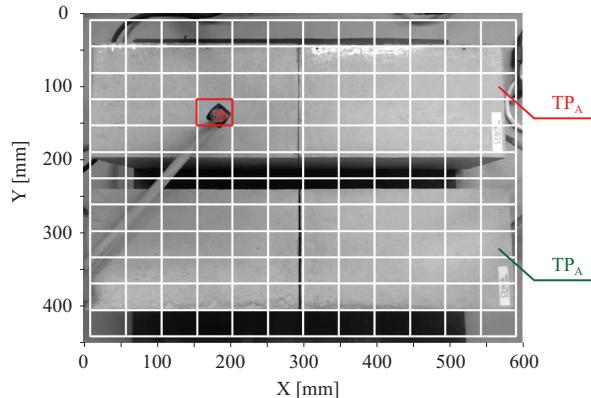


Fig. 11 The ground truth of the crack location in TP_A and TP_B

Part of COCN 2012 Project ‘Disaster Response Robot and its Operational System’”, Humanitarian Technology Conference (R10-HTC), 2013 IEEE Region 10, pp. 166–171, 2013.

- (2) Takeshi Suda, Atsushi Tabata, Jun Kawakami, Takatsugu Suzuki, “Development of an Impact Sound Diagnosis System for Tunnel Concrete Lining”, Tunnelling and Underground Space Technology, Vol. 19, Issue 4–5, pp. 328–329, 2004.
- (3) Fumihiro 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 on Control, Automation and Systems 2010, pp. 994–999, 2010.
- (4) Gang Zhang, Harichandran Ronald S., Ramuhalli Pradeep, “An Automatic Impact-Based Delamination Detection System for Concrete Bridge Decks”, NDT & E International, Vol. 45, No. 1, pp. 120–127, 2012.
- (5) Atsushi Yamashita, Takahiro Hara, Toru Kaneko, “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, pp. 3837–3842, 2006.

- (6) 藤井 浩光, 山下 淳, 滝間 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ア講演予稿集, pp. 599–604, 2014.
- (7) 藤井 浩光, 山下 淳, 滝間 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, pp. 844–850, 2014.
- (8) Nikunj C. Oza: “Online Bagging and Boosting”, Proceedings of the International Conference on Systems, Man and Cybernetics, Vol. 3, pp. 2340–2345, 2005.
- (9) Wenyuan Dai, Qiang Yang, Gui-Rong Xue, Yong Yu: “Boosting for Transfer Learning”, Proceedings of the International Conference on Machine learning, pp. 193–200, 2007.
- (10) Junbiao Pang, Qingming Huang, Shuicheng Yan, Shuqiang Jiang, Lei Qin: “Transferring Boosted Detectors Towards Viewpoint and Scene Adaptiveness”, IEEE Transactions on Image Processing, Vol. 20, No. 5, pp. 1388–1400, 2011.
- (11) Mustapha Mjiti, Pierre-Philippe J. Beaujean, David J. Vendittis: “Comparison of Fault Detection Techniques for an Ocean Turbine”, Proceedings of the Annual Conference of the Prognostics and Health Management Society, pp. 123–133, 2011.
- (12) Marco Cocconcelli, 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.
- (13) John A. Nelder, Roger Mead: “A Simplex Method for Function Minimization”, The Computer Journal, Vol. 7, No. 4, pp. 308–313, 1965.
- (14) Yoav Freund, 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.