

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*

藤井 浩光** 山下 淳*** 浅間 一***

Automated Recognition of Material Condition Using Boosting Algorithm in Hammering Test

Hiromitsu FUJII, Atsushi YAMASHITA and Hajime ASAMA

Automated diagnosis systems are necessary for maintenance of superannuated social infrastructures. This paper presents an automated classification method to detect defects of materials using acoustic signals in hammering test. The approach consists of two steps. The first step is extraction of features using Short-Time Fourier Transform (STFT) and the second one is training of classifiers based on AdaBoost which is a kind of ensemble learning algorithm. We use the weak classifiers based on simple template matching method, which can consider both variable scale of amplitude and variable range of frequency. In the experiments, we discriminate between woody and metal materials by different methods of hammering test, which are tapping and rubbing. Furthermore, our method can be applied to actual diagnosis; detection of crack in plaster walls.

Key words: automated diagnosis, maintenance and inspection, hammering test, boosting

1. 序 論

近年、高度経済成長期に建設されたトンネルや橋梁などの社会インフラの老朽化が問題となっている。安全のためには施設の継続的な点検による早期の問題発見が必須となるが、点検を必要とするインフラは膨大な件数に上っており、高所や狭所など人にとって危険な場合が多い。そのため、全ての点検作業を人手で行うことは困難であり、移動ロボットなどを利用した自動診断の実現が強く求められている。

設備点検の現場では、目視と打診(図1)が広く用いられており、検出精度の面で優れていることから主に人手による打診が行われてきた。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。熟練した点検工が減少しつつある現状で、安全・迅速かつ高精度に点検作業を遂行できる自動診断システムの開発・導入は緊急の課題である。

点検作業の自動システムに関しては、高層建築物の外壁やコンクリート製トンネルの内壁を検査する打診調査ロボットが開発されている^{1)~5)}。しかし、このようなシステムでの診断は遠隔操作のオペレータによる目視点検で行われる場合が多く、打診による調査の自動化も、タイルの剥離診断^{1),3)~5)}やコンクリートの窩洞調査²⁾など特定の項目に限定されている。

設備点検における自動診断の手法に関して、Support Vector Machineやニューラルネットワークなどの機械学習を用いたアプローチが数多く提案されている^{6)~8)}。特に音響信号を用いた手法としては、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⁸⁾を提案している。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、大きさの異なるクラックや陥没など複数の異常モードを自動検出しているが、測定機器を携帯した作業員による巡回検査を効率化するためのシステムであり、危険な現場における膨大な件数の点検作業を自動化するという




Fig. 1 Hammering test (tapping and rubbing)

観点では十分ではない。このように、設備点検における異常診断を高精度かつ自動で行うための方法論は確立されていない。

本研究では、点検作業における異常診断の自動化を目的とし、検出精度の高い識別器の構築を行う。打診で得られた音響信号を時間・周波数解析し、得られた特徴ベクトルをAdaBoostを用いて異常状態を検出する識別器を提案する。まず、提案手法が異なる打診法に適用可能であることを示した上で、実際の建築物における壁面のクラック検出が可能であることを確認する。

2. 打診法に基づく異常状態の検出手法

2.1 打診法

点検作業では、打診棒を用いた打診法が広く用いられている(図1)。打診法には、対象物を打突する音を利用する打音検査法と対象物の表面を擦る音を利用する擦過音検査法があり、いずれも検査法でも打診中の音響の変化をもとに異常状態を判定する。一般に、打診音から精確に異常状態を検出するには熟練を要するが、目視検査よりも精度良くかつ簡便に実施できることから、構造物の健全性をスクリーニングする上で有力な検査方法である。

実際の現場では、状況に応じて打音検査法と擦過音検査法を

* 原稿受付 平成 25 年 12 月 24 日

掲載決定 平成 26 年 6 月 27 日

** 学生会員 東京大学大学院 (東京都文京区本郷 7-3-1)

*** 正 会 員 東京大学大学院

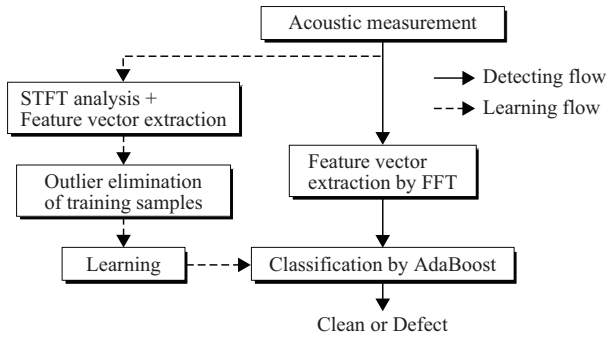


Fig. 2 Proposed method to detect defects

適宜使い分ける必要があり、本研究でも打音と擦過音の両方を適用可能な検出法を提案する。

2.2 音響信号による異常状態検出のためのアプローチ

本研究における異常状態の検出手法の概要を図 2 に示す。計測した音響信号は、短時間フーリエ変換 (STFT: Short-Time Fourier Transform) により時間・周波数解析を行う。特徴的な周波数帯における振幅値を特徴量ベクトルとして、アンサンブル学習における Boosting アルゴリズムの一種である AdaBoost を用いた学習を行い識別器を構成する。以下、詳細に説明する。

2.2.1 STFT による特徴ベクトルの抽出


音響信号など時系列信号の時間・周波数解析手法として、STFT が広く用いられている^{9)~11)}。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も用いられている。本研究でも打診音に対してハニング窓を用いた STFT を行い、得られた振幅スペクトル中の特徴的な周波数帯を特徴ベクトルとして用いる。

STFT は同じく時間・周波数解析手法であるウェーブレット変換などと比較して計算コストの低い手法であるが、周波数分解能を向上させるためには窓関数を広げサンプル数を大きくする必要があり、処理コストが大きくなることが懸念される。本研究では図 2 に示すように、識別器を生成する際の学習時には STFT を用いて、診断時には通常の FFT を用いて処理コストの削減を行う。STFT を用いて振幅スペクトルの連続的な変化を学習することで、診断時には任意の時刻で切り出した信号に対して評価することが可能となり、診断の処理速度を向上させ効率化を図ることができる。


例として、木製合板とステンレス鋼板における打音検査時の特徴ベクトルの違いを図 3 に示す。図 3(a)、図 3(b) は、それぞれ木製合板とステンレス鋼板についての結果である。いずれも横軸は周波数、縦軸は周波数成分の振幅値を示しており、高速フーリエ変換のサンプリング数は 2,048、特徴ベクトルの空間は 465 次元である。特徴としてステンレス鋼板の方が高周波数成分が大きいが確認できる。本研究では、このような周波数領域におけるスペクトルの相違を特徴量として利用することで状態識別を行う。

2.2.2 訓練データ中の外れ値除去

教師あり学習において精度の良い識別器を生成するには正確な訓練データを用意することが重要である。しかし、訓練データの測定における環境ノイズなどの影響により訓練データ中に



(a) Woody material



(b) Metal material

Fig. 3 Spectrum examples

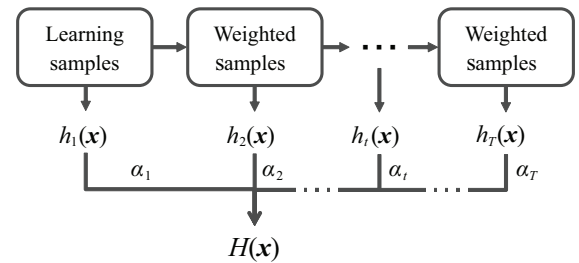


Fig. 4 Boosting algorithm

矛盾が生じることがある。本研究では識別器生成の前処理として訓練データのフィルタリング処理を行い、あらかじめ外れ値を除去する。

訓練データは、それぞれの音圧の違いを考慮するため標準化する。外れ値の判定は、標準化した特徴量空間での各データのばらつきに基づいて行う。訓練データの素性ごとに平均ベクトル (重心) を求め、重心からの距離を正規分布に従うと仮定した上で、標準偏差 σ に対して 3σ の外側にある訓練サンプルを外れ値として除去する。

2.2.3 AdaBoost による識別器の生成

本研究では、Boosting アルゴリズムの一種である AdaBoost¹²⁾ を用いて異常状態の識別器を生成する。Boosting アルゴリズムでは、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 (図 4)。AdaBoost は画像処理などの分野で広く用いられている有効な手法であり、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異常状態の識別に適していると考えられる。本研究では高速化が図られている Viola らのアルゴリズム¹³⁾ を用いる。

AdaBoost では、測定データ系列 \mathbf{x} に対する強識別器 $H(\mathbf{x})$ は、式 (1) のように表される 2 値識別器である。

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

ここで、 $h_t(\mathbf{x})$ が t 番目の弱識別器であり、 N は弱識別器の個数、 α_t は弱識別器 $h_t(\mathbf{x})$ の信頼度である。 α_t は訓練サンプルに対する誤り率 ϵ_t から式 (2) に従って計算される。

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

ただし、2 値判別において常に $\epsilon_t \leq 0.5$ 、 $\alpha_t \geq 0$ である。また、 t 回目の学習ステップ終了後における訓練サンプル $\mathbf{x}^{(i)}$ の重み $w_t^{(i)}$ は、以下の式 (3) に従って更新する。

$$w_{t+1}^{(i)} = w_t^{(i)} \left(\frac{\epsilon_t}{1 - \epsilon_t}\right)^{1 - e^{(i)}}, \quad (3)$$

ここで、 $e^{(i)}$ は訓練サンプル i の識別結果に応じて設定される変数であり、正しく識別された場合は $e^{(i)} = 0$ 、正しく識別されなかった場合は $e^{(i)} = 1$ とすることで、現在の学習ステップで識別を誤った訓練サンプルについて、次の学習ステップにおける重みを大きくする。また、 $w_t^{(i)}$ は各学習ステップにおいて

$$\sum_i w_t^{(i)} = 1 \quad (4)$$

となるように正規化する。

本研究の各弱識別機では、以下の式 (5) で表される正規化相互相関 $S_t(\mathbf{T}_t, \mathbf{x})$ によるテンプレートマッチングを行うことで、打診の強度によって変化する音圧の強さに依存しない、サンプルデータのスケージングに対して頑健な判定を行っている。

$$S_t(\mathbf{T}_t, \mathbf{x}) = \frac{\sum_{k \in \mathcal{K}} (T_t(k) - \bar{T}_t)(x(k) - \bar{x})}{\sqrt{\sum_{k \in \mathcal{K}} (T_t(k) - \bar{T}_t)^2} \sqrt{\sum_{k \in \mathcal{K}} (x(k) - \bar{x})^2}}, \quad (5)$$

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 および特徴ベクトル \mathbf{x} の平均値である。また、 \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帯域である。

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 (6) に従って行う。 θ は後述する判定のための閾値である。

$$h_t(\mathbf{x}) = \begin{cases} 1 & \text{if } S_t(\mathbf{D}_t, \mathbf{x}) - S_t(\mathbf{C}_t, \mathbf{x}) > \theta \\ -1 & \text{otherwise} \end{cases}, \quad (6)$$

\mathbf{D}_t は異常信号の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 は正常信号の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 (7) で表されるように各クラスに属する訓練サンプル $\mathbf{x}^{(i)}$ について重み $w_t^{(i)}$ を考慮して計算される。

$$\begin{aligned} D_t(k) &= \sum_{i \in \mathcal{N}_D} w_t^{(i)} x^{(i)}(k), \\ C_t(k) &= \sum_{i \in \mathcal{N}_C} w_t^{(i)} x^{(i)}(k), \end{aligned} \quad (7)$$

ここで、 \mathcal{N}_D および \mathcal{N}_C はそれぞれ異常信号と正常信号について用意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 $\mathbf{x}^{(i)}$ は異常信号のクラスに属し、 $i \in \mathcal{N}_C$ のとき $\mathbf{x}^{(i)}$ は正常信号のクラスに属する。

\mathcal{K} および θ が個々の弱識別器を特徴づける設計すべきパラメータである。 \mathcal{K} はテンプレートベクトルとの比較を行う周波数帯域であり特徴ベクトル空間に相当する。打診検査におい




Fig. 5 Experimental environment

Table 1 Learning samples of tapping test

Class	Learning sample	Number of samples
class 1	tapped sound of stainless board	1,508
	tapped sound of plywood and environmental sound	
class 0	tapped sound of plywood and environmental sound	1,756

て観測できる音響信号の性質は、検査対象の保全状態や材質により非常に多様である。本研究では、扱う問題の性質に応じた識別器を適応的に生成することを目的に、個々の弱識別器が状態識別に用いる周波数帯域をも含めて学習する。また、 θ は正規化相互相関の値の差に対する閾値である。 \mathcal{K} および θ の値は、毎回の学習ステップにおいて用意した複数の弱識別器の中から、訓練サンプルを識別したときの誤り率が最小になるように選択する。

以上より、新たな評価サンプル \mathbf{x} に対する識別は、式 (1) に示した複数の弱識別器 $h_t(\mathbf{x})$ による各信頼度 α_t に応じた重み付き多数決で決定される。具体的には、観測データのうち検出対象のサンプルは $H(\mathbf{x}) = 1$ なる class 1 として分類され、それ以外の非検出対象のサンプルは $H(\mathbf{x}) = -1$ なる class 0 として分類される。

3. 実験：異なる打診法を用いた材料・状態識別


提案手法が、異なる打診法に適用できることを確認するため、打音検査法による異種材料の識別および擦過音検査法によるクラック状態の検出を行った。

3.1 実験環境


実験装置を図 5 に示す。打診の対象物には木製合板とステンレス鋼板を用いた。実験では打音検査法 (3.2 節) と擦過音検査法 (3.3 節) の 2 種類の打診法を用いた識別を行い、いずれの実験においても訓練サンプルの取得および検証のための打診は人手により行った。

音響信号の計測には市販のエレクトリックコンデンサマイクロフォンを用い、打診対象の上部中央 500mm の位置に固定した。マイクロフォンのサンプリングレートは 44.1kHz であり、高速フーリエ変換のサンプル数は 2,048 とし、ハニング窓を用いた。

AdaBoost における弱識別器の個数は 100 とし、弱識別器を特徴づけるパラメータ \mathcal{K} および θ については以下のように設



(a) Result of detecting metal material in time domain



(b) Result of detecting metal material in frequency domain

Fig. 6 Result of detecting metal by tapping test

定した. テンプレートベクトルを生成するための周波数帯 \mathcal{K} は, 下限を 50Hz と固定し, 上限を材料および打診音の特徴が表れやすい 5,000Hz から 10,000Hz の範囲と設定した. テンプレートマッチングにおける類似度の閾値 θ の範囲は $0 < \theta < 1.0$ とした. \mathcal{K} および θ は, 学習の各ステップごとに上記の範囲でランダムで値を設定した弱識別器群の中から, それぞれのステップで更新された重み付きサンプルに対して誤り率が最小となるものを選択した.

3.2 打音による金属材料の検出

打音により異種材料の識別が可能であることを確認するため, 音源の異なる種々のサンプルからステンレス鋼板の打音を検出する実験を行った.

用いた訓練サンプルを表 1 に示す. ここで, class 1 はステンレス鋼板の打音の特徴ベクトルが含まれる $H(\mathbf{x}) = 1$ なる検出対象のクラスであり, また, class 0 は木製合板の打音および環境音 (足音や空調の風切り音など) の特徴ベクトルが含まれる $H(\mathbf{x}) = -1$ なる検出対象以外のクラスである.

学習結果の評価は, k -分割交差検定法で行った. $k = 10$ の分割数で class 1 の検出精度は 99.9%, class 0 の検出精度は 99.8% であった. 学習に要した平均時間は Intel 社製 Core™ i7-4770 CPU (3.40GHz) を搭載したデスクトップ PC を用いて約 402sec であった.

打音によるステンレス鋼板の検出結果を図 6 に示す. 用いた音響データは, 訓練サンプルとは別に測定したサンプルである. 図 6(a) は打音の時間変化であり, 横軸が時間 [ms] で縦軸がマイクロフォンの信号レベルである. 図 6(b) は打音の時間・周波数解析結果のスペクトログラムである. 横軸は時間 [ms] で縦軸が周波数 [Hz] であり, 縦軸には解析対象の周波数帯 50Hz–10,000Hz の範囲を示している. 色の濃淡でスペクトル成分の強さを示しており, 色が濃いほど振幅が大きいことを示している. 10,000ms の間に木製合板, ステンレス鋼板, … の順で計 8 回の打突を繰り返した. 図 6(b) のマイクレベルの急峻な変化からも打突の瞬間 (例えば, 木製合板に対する 1 度目の打突は約 1,250ms の瞬間) が確認できる.

図 6(a), (b) の両図ともに網掛けで強調している約 2,400ms–2,700ms, 約 4,500ms–4,750ms, 約 6,650ms–7,000ms,




Fig. 7 Experiment to detect pseudo crack

Table 2 Learning example to detect pseudo crack

Class	Learning sample	Number of samples
class 1	rubbed sound at the moment of passing on the crack	1,405
	rubbed sound of plywood	
class 0	and stainless board and environmental sound	1,476

約 8,900ms–9,250ms の 4 区間は, 識別器によりステンレス鋼板の打音として検出された区間であり, 実際にステンレス鋼板を打突した時刻とよく一致している. また, 非検出対象の class 0 として学習させた木製合板の打突および打突を行わなかった区間の信号は検出されておらず, 打音によって正確な識別が行われていることも確認できる.

3.3 擦過音による木材中のクラック検出

擦過音検査法により木製合板表面のクラックを検出する実験を行った. 実際の点検作業の現場においては, 点検対象の置かれている環境や対象物の材質・構造などにより, 生じ得るクラックの規模は多様であると考えられる. そこで, 本研究では 2 枚の木製合板を組み合わせ隙間の大きさを調整することが可能なテストピース (図 7) を用いて, 幅長さの異なるクラックを疑似的に再現した実験を行った. 同じ材質の合板上で確認された過負荷などにより生じたクラック幅を参考に, クラック幅を約 1mm から約 5mm の範囲で調整した実験を複数回行った. 以下, 代表的な例として実験に用いたクラック幅の中央値である幅 3mm と設定した場合の実験結果を示す. その他の実験機材および識別器のパラメータは 3.2 節における異種材料の識別の場合と同様に設定した.

実験に用いた訓練サンプルを表 2 に示す. ここで, class 1 はクラック上を通過する際の擦過音の特徴ベクトルが含まれる検出対象のクラスであり, class 0 は木製合板およびステンレス鋼板の擦過音と環境音 (足音や空調の風切り音など) の特徴ベクトルが含まれる検出対象以外のクラスである.

学習結果の評価は, 10 分割の交差検定法で行った. class 1 の検出精度は 98.1%, class 0 の検出精度は 98.6%, 学習に要した平均時間は約 356sec であった.

擦過音による木製合板の疑似クラック検出結果を図 8 に示す. 用いた音響データは, 訓練サンプルとは別に測定したサンプルである. 図 8(a), (b) の両図ともに図 6 と同様の形式である.

10,000ms の間に疑似クラックを通過する擦過動作を計 5 回繰り返している. 図 8(a) のマイクレベルの急峻な変化におい

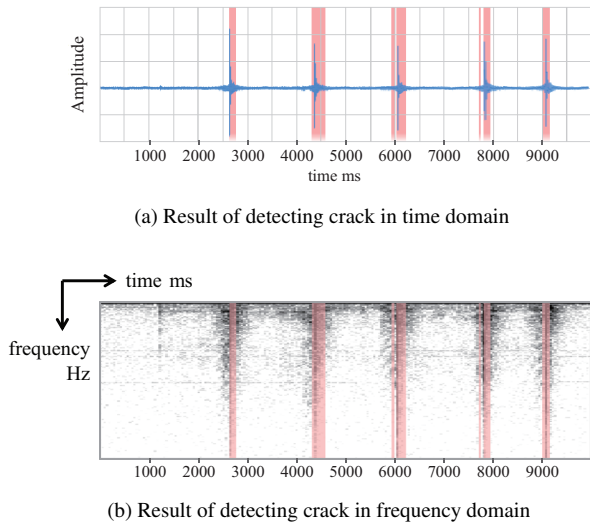


Fig. 8 Result of detecting crack in woody materials

ても疑似クラック上を通過する際に発生した微小音（例えば、1度目の通過は約 2,500ms–2,750ms の瞬間）が確認できる。

図 8(a), (b) の両図ともに網掛けで強調している約 2,600ms–2,750ms, 約 4,300ms–4,600ms, 約 5,900ms–6,200ms, 約 7,700ms–7,900ms および約 9,000ms–9,200ms の 5 区間は、識別器により疑似クラック上での擦過音として検出された区間であり、実際に疑似クラック上を擦過していた時刻とよく一致している。木製合板の正常部を擦過中および擦過を行わなかった時刻の信号は検出されなかったが、クラック上を通過している際に正常状態と識別されている時間帯も存在する。

識別を誤る原因として、例えば訓練サンプルと評価サンプルにおける擦過速度の違いなどが考えられる。高速に擦過した場合、高周波成分が大きくなるため学習時のテンプレートとの類似度が低下する。式 (5) で示した弱識別器の評価関数では音響信号のスケールは考慮できるが、擦過速度の違いによるスペクトル成分の相違を考慮することはできない。実験では訓練サンプルの取得および検証のための打診を人手により行っており、擦過速度を厳密に設定しなかったことが誤識別を招いたと考えられる。

提案手法をロボットによる自動点検作業に適用する場合は、訓練サンプルの取得時と検出時の擦過速度を一定に保つことが重要であるが、速度情報を用いた対応も考えられる。例えば、映像信号などを用いて擦過速度を推定し速度情報付きの学習を行うことで、検出時の速度変化にも対応可能な周波数領域のスケールを考慮した識別器を生成する手法が今後の展望として挙げられる。

3.4 学習結果のまとめと考察

基礎実験で生成した打音検査と擦過音検査による 2 種類の識別器について、弱識別器の数と交差検定における識別誤差の関係を図 9 に示す。横軸は弱識別器の個数、縦軸は識別誤差の値を百分率で示している。いずれも交差検定における分割数は 10 とし、識別誤差率は各試行の平均である。弱識別器の個数が増加するとともに識別誤差率が減少しており、複数の弱識別器の組み合わせが有効であることが確認できる。

AdaBoost では、前回の学習ステップ $t-1$ で識別困難であった訓練サンプル $\mathbf{x}^{(i)}$ に対して式 (3) に従って重み $w_t^{(i)}$ を増すよ

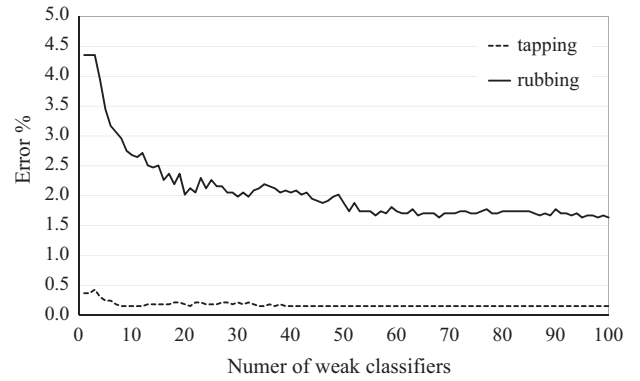


Fig. 9 Error of training result in cross validations




Fig. 10 Final weights of training samples in the crack detecting test

うに更新する。例えば、環境音に特定周波数が含まれる場合などは、特徴量空間上で異なるクラスの訓練サンプル同士が類似してしまう。このようなサンプルは、前処理における外れ値のフィルタリングでは除去できない本質的に識別が困難なデータであり、学習の最終ステップにおいて重みが突出する。

3.3 節で生成したクラック状態の識別器に関して、最終学習ステップ ($t = 100$) における各訓練サンプルの重みを図 10 に示す。横軸は訓練サンプル固有のラベル i であり、縦軸は学習における重み $w_{100}^{(i)}$ を示している。更新された重みが訓練サンプルごとに異なっており、識別困難であった訓練サンプルの重みが大きくなっていることが確認できる。

4. 実験：石膏ボード壁面からのクラック検出

提案手法により単一材料中の異状態が検出可能であることを確認するために、打音検査の応用例として石膏ボード製の壁面中のクラック検出を行った。石膏ボードは近年のオフィスビルの壁材などに広く用いられているが、十分な強度を持たないにもかかわらず家具の固定などに用いられており、震災における二次災害を引き起こす要因として指摘されている。石膏ボード中のクラック検出は、強度不足による壁材の劣化などを示す指標として有用であると考えられる。

4.1 実験環境

打音検査法を用いて壁面中からクラックの位置を検出する実験を行った。訓練サンプルの取得および検出のための打診は人手で行い、打診時の打音および打点の位置を検出するためにマイクロフォンおよびカメラを用いた。実験環境を図 11(a) に示す。

ここで、打診検査においては検査用具である打診棒のサイズを適切に選定することが重要となる。例えば、打音検査法に関




Fig. 11 Experimental environment of crack detection on the plaster wall

Table 3 Learning samples of detecting crack on wall

Class	Learning sample	Number of samples
class 1	tapped sound of defect wall	494
class 0	tapped sound on normal wall and environmental sound	837


する先行研究⁴⁾においてもタイル外壁の診断において、調査対象に応じて適切な打診棒先端の径サイズが存在することが実験的に言及されている。本研究においても、打音検査法による石膏ボード上のクラック検出に適した打診棒を試行錯誤的に選択し、先端径が 18mm のステンレス製の打診棒を用いた。

打突時の打点位置は、カメラ画像を格子状に区切ることで小領域に分割し、各領域において赤色で着色した打診棒の先端を画像処理により検出することで求めた。検査対象領域全体を図 11(b) に示し、格子状に分割した小領域で打診棒の先端を検出した様子を図 11(c) に示す。いずれも水平方向および垂直方向をそれぞれ X 軸および Y 軸とする。


マイクロフォンおよびカメラは壁面と平行になるように設置し、壁面からの距離は約 500mm とした。カメラは解像度が 640 × 480 ピクセルのカメラを用い、検査対象領域はカメラの画角に納まるように X 方向に約 460mm、Y 方向に約 350mm の範囲とした。実験では人手による打診を行っているため、毎回の打診において打点位置に誤差が生じる。そこで、あらかじめ上記の打診棒を用いた試行を繰り返して打点位置のばらつきを測定することで、小領域のサイズを横方向に約 55mm、縦方向に約 40mm と定め、その上で解像度が最大となるように分割数を縦横方向に 8 × 8 と設定した。

実際の建築物では壁の裏側に筋交いや配管スペースが存在する。そのため、クラックが存在しない石膏ボードの打音は非常に多様であり、環境によっては打音のスペクトル分布がクラック状態に類似している箇所が存在する。そこで、訓練サンプルは図 11 の検査対象とは異なる複数の場所で取得した。

実験に用いた訓練サンプルを表 3 に示す。ここで、class 1 はクラック付近の石膏ボードを打突した音の特徴ベクトルが含まれる検出対象のクラスであり、class 0 はクラックが存在しない石膏ボードの打突音および環境音の特徴ベクトルが含まれる検出対象以外のクラスである。識別器のパラメータは、前節の実験の場合と同様に設定した。



(a) Cracks detection result in time domain



(b) Cracks detection result in frequency domain

Fig. 12 Results of cracks detection on plaster wall by tapping

4.2 実験結果

打音による石膏ボード壁面からのクラック検出結果を図 12 に示す。用いた音響データは、訓練サンプルとは別の場所において測定したサンプルである。図 12(a), (b) の両図ともに図 6, 図 8 と同様の形式である。10,000ms の間に壁面中の異なる 4 箇所において、打音検査法による診断をそれぞれ連続して 2 回ずつ、計 8 回行った。図 12(a) のマイクレベルの急峻な変化においても壁面を打診した時に発生する打音（例えば、1 度目の打診は約 1,200ms–1,500ms の瞬間）が確認できる。

実験では 3 箇所目である 5 回目と 6 回目にクラックに対する打診を行った。図 12(a), (b) の両図ともに網掛けで強調している約 5,750ms–6,000ms、約 6,250ms–6,500ms の 2 区間が、識別器によりクラックの打音として検出された区間であり、実際に壁面上のクラックを打診した時刻とよく一致している。

生成した識別器を用いて壁面中からクラックの 2 次元位置を検出した結果を図 13 に示す。検出精度を評価するために小領域を各 30 回ずつ打診し、クラック状態 (class 1) と判定された回数の割合を検出率として算出した。グラフの XY 軸は図 11(b) に示した画像中の位置と対応している。検出率を百分率で表したものを色の濃淡で示しており、色が濃いほどクラックと判定された割合が高いことを示している。




Fig. 13 Result of defect detection on plaster wall

図 13 中の X 方向中央 (X=150mm–250mm) 付近で、Y 方向に検出率が約 60%–90% と高い領域が確認できる。これは、図 11(b) に示した壁面中にある実際のクラックの位置とよく一致している。以上より、提案手法によりクラックの位置を正確に検出可能であることが確認できる。

5. 結 論

本研究では、点検作業における高精度な異常診断の自動化を目的とし、打診検査時の音響信号を用いた STFT と AdaBoost による異常検出手法を提案した。打音検査法を用いた材料識別実験 (3.2 節)、擦過音検査法を用いた木材中のクラック検出実験 (3.3 節)、および打音検査法を用いた石膏ボード壁面中のクラック検出実験 (4 章) を行った。実験結果から、提案手法が異なる打診法に適用可能であること、および提案手法を適用することで高精度な材料識別・異常検出が可能であることを確認した。

提案手法において時間・周波数解析および識別に要する全体の平均処理時間は約 6ms であった。本提案手法は、打診法による簡便な検査法を採用しており、廉価な装置で構成されたシステムによって高精度かつリアルタイムでの検出が可能である。実際の現場での巡回点検をロボットにより自動化する上で、実

装面および精度・導入コストの面からも有効な手法であると考えられる。

特徴ベクトルおよび弱識別器の改良による提案手法の高精度化や複数センサおよび音響以外のセンサを利用した統合的な異常検出手法の構築、実際の設備点検の現場におけるデータ収集・解析などは今後の課題である。

参 考 文 献

- 1) 堂山 敦弘, 汐川 孝, 井上 文宏, 太田 有: 外壁タイル剥離判定の自動化に関する研究: その 1 ウェーブレットによるタイル打撃音の解析, 日本建築学会 学術講演梗概集. A-1, 材料施工, 1016, (2003), 31.
- 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, **19**, 4–5, (2004), 328.
- 3) 遠藤 健, 加藤 晃敏, 安部 満, 白都 滋: 外壁タイル自動診断ロボットの開発 (その 2), ロボティクス・メカトロニクス講演会講演概要集, (2009), 1A2-C14.
- 4) 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), 994.
- 5) 土井 暁, 井上 文宏, 坂上 肇, 大本 絵利, 浜田 耕史: 超高層集合住宅を対象とした垂直自走式外壁検査システムの開発, 日本建築学会 学術講演梗概集 A-1, 材料施工, 1475, (2011), 949.
- 6) 小野田 崇, 伊藤 憲彦, 山崎 博信: SVM に基づく水力発電所の異常予兆発見支援, 人工知能学会 2008 年全国大会, (2008), 2B3-01.
- 7) 幸 和範, 小林 央宜, 大石 博之, 杉本 博之, 飯田 毅, 古川 浩平: SVM を用いた土木設備の補修必要度評価, 土木学会論文集 F4 (建設マネジメント), **68**, 2, (2012), 52.
- 8) 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, **22**, (2012), 135.
- 9) Shiwei Ma, Tetsuya Sasaki, Etsuji Yoshihisa, Takashi Honda: Time-Frequency Analysis of Ultrasonic Echoes and its Application to Non-destructive Evaluation of Thermal Damage of Steel, Research Reports of the National Institute of Industrial Safety, NIIS-RR-2002, (2003), 1.
- 10) 黒川 悠, 水谷 義弘, 井上 裕嗣: 時間-周波数解析を用いた TOFD 法による欠陥高さ測定の高精度化, 非破壊検査, **55**, 12, (2006), 635.
- 11) 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, (2012), 41.
- 12) 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, **55**, 1, (1997), 119.
- 13) Paul Viola and Michael Jones: Robust Real-time Face Detection, International Journal of Computer Vision, **57**, 2, (2004), 137.