

## 打診調査における AdaBoost を用いた異常状態の自動識別

藤井 浩光<sup>\*1</sup>, 山下 淳<sup>\*1</sup>, 浅間 一<sup>\*1</sup>

### Automated Defect Detection Using AdaBoost in Hammering Test

Hiromitsu FUJII<sup>\*1</sup>, Atsushi YAMASHITA<sup>\*1</sup> and Hajime ASAMA<sup>\*1</sup>

<sup>\*1</sup> Department of Precision Engineering, School of Engineering, The University of Tokyo  
7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8656, Japan

Automated diagnosis systems are necessary for maintenance of social infrastructures which have superannuated. This paper presents an automated classification method in order to detect defects of different 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 boosting algorithm. In the experiments, we discriminate between woody and metal materials by different methods of hammering test, which are tapping and rubbing. We also show the crack which is imitated artificially can be accurately detected from woody materials.

**Key Words :** Automated Diagnosis, Maintenance and Inspection, Hammering Test, AdaBoost

### 1. 序 論

近年、高度経済成長期に建設された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、膨大な件数に上る点検作業を全て人手で行うことは困難である。そのため、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、検出精度の点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、高精度かつ迅速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、コンクリート製トンネルの内壁や高層建築物の外壁を検査する打診調査ロボットが開発されている<sup>(1)~(3)</sup>。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コンクリートの窩洞調査<sup>(1)</sup>やタイルの剥離診断<sup>(2) (3)</sup>など特定の項目に限定された比較的単純な検査までにとどまっている。

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




Fig. 1 Hammering test (tapping and rubbing)

学習を用いたアプローチが数多く提案されている<sup>(4)~(6)</sup>。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半自動診断システム<sup>(6)</sup>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、人手による点検作業の支援を前提としたシステムであり完全な自動化には至っていない。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を提案する。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から AdaBoost を用いて異常状態を検出する識別器を提案する。提案手法により異種材料の識別が異なる打診法で可能であることを示し、同一材料中

<sup>\*1</sup> 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








Fig. 4 Experimental environment



(a) Woody material



(b) Metal material

Fig. 5 Spectrum examples

$N^f$  および  $N^{\bar{f}}$  はそれぞれ異常信号と正常信号について用意した学習サンプルの識別番号から成る集合である。

$\mathcal{K}$  および  $\theta$  が個々の弱識別器を特徴づけるパラメータである。 $\mathcal{K}$  はテンプレートベクトルの生成に用いる周波数帯域であり特徴ベクトル空間に相当する。 $\theta$  は正規化相関の値の差に対する閾値である。 $\mathcal{K}$  および  $\theta$  の値は、毎回の学習ステップにおいて学習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される。

### 3. 打診法による識別実験

**3.1 実験概要** 提案手法が、異種材料の識別および同一材料における異常状態の識別に適用できることを確認するため、打診調査を想定した模擬実験を行った。実験装置を図4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。異種材料の識別には打音検査法(3.2.1項)と擦過音検査法(3.2.2項)の2種類の打診法を用いて、同一材料中の状態識別では木製合板における疑似クラックの検出(3.3節)を行った。

音響信号の計測には市販のコンデンサマイクローフォンを用い、サンプリングレートは44.1kHzとした。高速フーリエ変換のサンプル数は1,024とし、ハニング

Table 1 Learning samples of tapping test

Class	Learning sample	Number of samples
class 1	tapped sound of stainless board	2,996
class 0	tapped sound of plywood and environmental sound	3,770




Fig. 6 Result of detecting metal by tapping test

窓を用いた。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の例を図5に示す。図5(a), 5(b)は、それぞれ木製合板とステンレス鋼板の結果であり、両図ともに横軸は周波数であり縦軸は各周波数成分の振幅値である。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ことが確認できる。

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 $\theta$ については以下のように設定した。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に固定し、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 $\theta$ の範囲は $0 < \theta < 1.0$ とした。 $\mathcal{K}$ および $\theta$ 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 異種材質の識別

**3.2.1 打音による識別** 打音による検査で異種材料の識別が可能であることを確認するため、木製合板の打音と環境音を含む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。表1に用いた学習サンプルを示す。ここで、class 1は $h_t(\mathbf{x}) = 1$ なる検出対象が含まれるべきクラスであり、ステンレス鋼板の打音の特徴ベクトルから成る。また、class 0は $h_t(\mathbf{x}) = -1$






Fig. 7 Rubbing test (four to-and-fro motions)

なる検出対象以外が含まれるべきクラスであり、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）の特徴ベクトルから成る。

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 98.3%，class 0 の検出精度は 99.9%であった。学習に要した平均時間は Intel 社製 Core™ i5-2540M CPU (2.60GHz) を搭載したラップトップ PC を用いて約 446sec 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、学習サンプルとは別に測定したサンプルである。上図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。下図は打音の時間・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 9 回の打突を繰り返した。上図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 1,100ms の瞬間）が確認できる。

上下図ともに網掛けで強調している約 2,000ms–2,400ms, 約 4,000ms–4,400ms, 約 6,100ms–6,500ms, 約 8,200ms–8,500ms 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 class0 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、打音によって精確な識別が行われていることも確認できる。

**3.2.2 擦過音による識別** 擦過音による検査で異種材料の識別が可能であることを確認するため、木製合板の擦過音と環境音を含むサンプルからステンレス鋼板の擦過音を検出する実験を行った。表 2 に用いた学習サンプルを示す。ここで、class 1 はステンレス鋼板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 は木製合板の擦過音および環境音

Table 2 Learning samples of rubbing test

Class	Learning sample	Number of samples
class 1	rubbed sound of stainless board	3,020
class 0	rubbed sound of plywood and environmental sound	2,904




Fig. 8 Result of detecting metal by rubbing test

（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、打音による識別の場合と同様の環境で 10 分割の交差検定法で行った。class 1 の検出精度は 98.7%，class 0 の検出精度は 99.6%，学習に要した平均時間は約 455sec であった。

擦過音によるステンレス鋼板の検出結果を図 8 に示す。用いた音響データは、学習サンプルとは別に測定したサンプルである。上図は擦過音の時間変化、下図は擦過音の時間・周波数解析結果のスペクトログラムであり、上下図ともに図 6 と同様の形式である。

10,000ms の間に図 7 に示すような木製合板とステンレス間の往復運動を繰り返しており、検出対象であるステンレス鋼板上の擦過動作は 5 回行っている。図 8 のマイクレベルの変化（上図）においても木製合板とステンレス鋼板の境界を通過する際に発生した微小音（例えば、木製合板からステンレス鋼板への 1 度目の遷移は約 2,200ms の瞬間）が確認できる。

上下図ともに網掛けで強調している約 2,200ms–2,400ms, 約 3,700ms–3,900ms, 約 5,300ms–5,600ms, 約 7,000ms–7,200ms, および約 8,600ms–8,800ms の 5 区間は、識別器によりステンレス鋼板の擦過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擦過していた時刻とよく一致している。また、非検出対象の class0 として学習させた木製合板の擦過および擦過




Fig. 9 Experiment to detect pseudo crack

を行わなかった区間の信号は検出されておらず、擦過音を用いて精確な識別が可能であることが確認できる。

**3.3 同一材料内における異状態の識別** 提案手法により同一材料内の異なる状態を検出できることを確認するために、2枚の木製合板の間に隙間を設けて作成した疑似的なクラック状態を検出する実験を行った。実験環境を図9に示す。木製合板間の隙間は3mmとし、打診法としては擦過音検査法を用いた。表3に用いた学習サンプルを示す。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、異種材料の識別の場合と同様の環境で10分割の交差検定法で行った。class 1の検出精度は95.3%、class 0の検出精度は94.6%、学習に要した平均時間は約467sec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10に示す。用いたデータは、学習サンプルとは別に測定したサンプルである。上下図ともに図6および図8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。上図のマイクレベルの急峻な変化におい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1,300ms–1,500msの瞬間）が確認できる。

上下図ともに網掛けで強調している約1,300ms–1,500ms、約3,100ms–3,300ms、約5,000ms–5,200ms、約6,800ms–7,000msおよび約8,600ms–8,800msの区間は、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。

**3.4 実験結果のまとめと考察** AdaBoostにより生成された識別器の学習結果を図11に示す。本研究で生成した打音検査と擦過音検査による鋼材の検出、

Table 3 Learning example to detect pseudo crack

Class	Learning sample	Number of samples
class 1	rubbed sound at the moment of passing on the crack	2,939
class 0	rubbed sound of plywood and stainless board, and environmental sound	3,592




Fig. 10 Result of detecting crack in woody materials

および擦過音検査による木材中のクラック検出のための計3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示している。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。いずれの識別器に対して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。識別誤差率の変化に関しては見やすさのために、縦軸の一部分を省略した。いずれの識別器においても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。

しかし、擦過音によるクラック検出においては、10個以上の弱識別器から識別誤差率の増減が振動的になっており、30個以上からは増加傾向にある。このような汎化性能の低下が生じている原因としては、学習サンプルにおけるノイズの影響が大きいと考えられる。クラック検出のための識別器における最終学習ステップでの学習サンプルの重みを図12に示す。横軸は学習サンプル固有のラベルであり、縦軸は学習における重みを示している。AdaBoostでは、前段までの学習ステップで識別困難な学習サンプルに対して重みを増していく。つまり、図12の丸印で示したような学習後半において重みが突出したサンプルはノイズを含んでいる可能性が高く、最終的にも識別困難となる

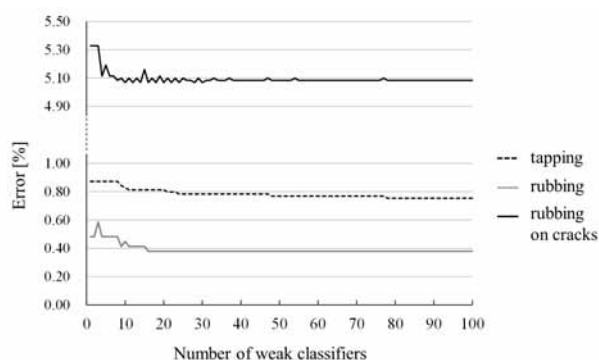


Fig. 11 Error of training result in cross validations

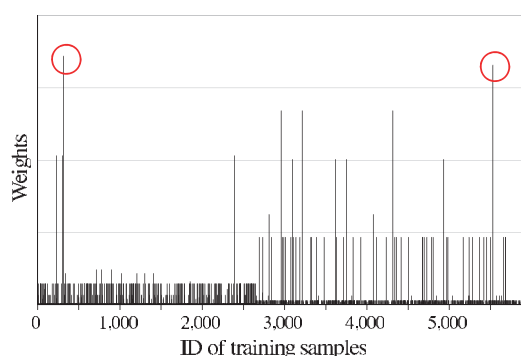


Fig. 12 Final weights of training samples in the test of rubbing on cracks

か強制的に学習されることにより過学習が発生する。

学習サンプルにおけるノイズとして、例えば学習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(4)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。実際のロボットによる点検作業では、急激な速度変化は想定し難いが、この問題には音響信号以外に映像信号や速度情報などの利用が考えられる。

また、クラック上の擦過音は木製合板やステンレス鋼板の表面と比べて、音響信号の残響が少ないことも原因の1つとして上げられる。この問題は、石材やコンクリートなどの残響の少ない材質の打診においても同様に生じ得る。本研究で特徴ベクトルの生成に用いたSTFTでは、窓関数の幅が一定であるため高周波信号に対して時間分解能が向上しないという欠点が指摘されている。ウェーブレット変換など高周波解析で局所的に時間分解能を上げることが可能な手法を適用することで、検出の精度を向上できると考えられる。

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3msであった。本提案手

法は、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で自動化する上で、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。

#### 4. 結 論

本研究では、従来は困難であった高精度な診断の自動化を目的とし、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。提案手法により異種材料の識別が可能であることを確認し、異なる打診法（打音検査法と擦過音検査法）を用いた場合においてもそれぞれ適用可能であることを確認した。また、木製合板において疑似的なクラックの検出を行い、同一材料内の異常検出においても有効であることを確認した。

特徴ベクトルの改良による提案手法の高精度化や音響以外の複数センサを利用した統合的な異常検出手法の構築、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) 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, (2004), pp. 328-329.
- (2) 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), pp. 949-950.
- (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)", 日本機械学会ロボティクス・メカトロニクス講演会講演概要集, (2009), 1A2-C14.
- (4) Takashi Onoda, Norihiko Ito, Hironobu Yamasaki, "Trouble Condition Sign Discovery Based on Support Vector Machines for Hydroelectric Power Plants", *International Joint Conference on Neural Networks*, (2009), pp. 2358-2365.
- (5) 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), Vol. 68, No. 2, (2012), pp. 52-61.
- (6) Shivprakash Iyer, Sunil K. Sinha, Bernhard R. Tittmann and Michael K. Pedrick, "Ultrasonic Signal Processing Methods for Detection of Defects in Concrete Pipes", *Automation in Construction*, Vol. 22, (2012), pp. 135-148.
- (7) 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, (1997), pp. 119-139.
- (8) Paul Viola and Michael Jones, "Robust Real-time Face Detection", *International Journal of Computer Vision*, Vol. 57, No. 2, (2004), pp. 137-154.