# 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\*1,山下淳\*1,淺間一\*1

# Automated Defect Detection Using AdaBoost in Hammering Test

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

\*1 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.utokyo.ac.jp



Fig. 2 Proposal method to detect defects

の異なる状態が検出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 の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.実際の現場では、これら2種類の診断法を 適宜使い分ける必要があり、本研究でも打音と擦過音 の両方に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.

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解析を行う際に、窓関数を用いて 時間・周波数解析を行う STFT が広く用いられている. 本研究でも計測した音響信号に対してハニング窓を用 いた STFT を行い、特徴的な変化を示す周波数帯の振 幅値を特徴ベクトルとして用いる.

2:2:2 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 AdaBoost<sup>(7)</sup> 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、学習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3).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 後段で重みづけを大きくすることで集中的な学習を行 う.そのため、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



Fig. 3 Boosting algorithm

は高速化が図られている Viola らのアルゴリズム<sup>(8)</sup>を 用いている.

AdaBoost では測定データ系列 *x* に対する強識別器 *H*(*x*) は,式(1)のように表される.

$$H(\boldsymbol{x}) = \operatorname{sign}\left[\sum_{t=1}^{T} \alpha_t h_t(\boldsymbol{x})\right], \qquad (1)$$

ここで、 $h_t(\mathbf{x})$ は t 番目の弱識別器であり、T は弱識別 器の個数である。 $\alpha_t$  が学習サンプルに対する誤り率か ら計算される弱識別器の信頼度であり、 $\alpha_t \ge 0$  である。

本研究の各弱学習機では、以下の式(2)で表される 正規化相関  $S_t(A_t, x)$ を用いた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リングに対 して頑健な判定を行っている.

$$S_t(\boldsymbol{A}_t, \boldsymbol{x}) = \frac{\sum_{k \in \mathcal{K}} (A_t(k) - \bar{A}_t) (x(k) - \bar{x})}{\sqrt{\sum_{k \in \mathcal{K}} (A_t(k) - \bar{A}_t)^2} \sqrt{\sum_{k \in \mathcal{K}} (x(k) - \bar{x})^2}} , \quad (2)$$

ここで、 $A_t$ は学習サンプルの特徴ベクトルから生成す る学習ステップtにおけるテンプレートベクトルであ り、 $\bar{A}_t$ および $\bar{x}$ はそれぞれ $A_t$ および特徴ベクトルxの平均値である.また、Kは後述するテンプレートベ クトルの生成に用いる周波数帯域である.

各弱識別器の判別は式(3)に従って行う. θ は後述 する判定のための閾値である.

$$h_t(\boldsymbol{x}) = \begin{cases} 1 & \text{if } S_t(\boldsymbol{A}_t^{\text{f}}, \boldsymbol{x}) - S_t(\boldsymbol{A}_t^{\text{f}}, \boldsymbol{x}) > \theta\\ -1 & \text{otherwise} \end{cases}, \quad (3)$$

ここで $A_t^f$ および $A_t^{\bar{t}}$ は、それぞれ異常信号と正常信号 の学習サンプルから生成されるテンプレートベクトル であり、式(4)で表されるように各クラスに属するサ ンプルについて学習サンプル $\mathbf{x}^{(i)}$ の学習ステップtに おける重み $w_t^{(i)}$ を考慮して計算される.

$$A_{t}^{f}(k) = \sum_{i \in \mathcal{N}^{f}} w_{t}^{(i)} x^{(i)}(k) ,$$
  

$$A_{t}^{\bar{f}}(k) = \sum_{i \in \mathcal{N}^{\bar{f}}} w_{t}^{(i)} x^{(i)}(k) ,$$
(4)



Fig. 4 Experimental environment



Fig. 5 Spectrum examples

 $N^{f}$ および $N^{\tilde{f}}$ 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.

### 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

TT 1 1 1	т •	1	<b>C</b> .	•	
Inhial	L ogrning	complee /	ot tan	nina	toct
I abic I	Leannie	samples	or tab	DILLE	usi
				. 0	

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 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 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. 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, class1はh<sub>l</sub>(**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, class0はh<sub>l</sub>(**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<sup>TM</sup> 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,class1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,class0は木製合板の擦過音および環境音

T-1-1- 7	T	a a	<b>f</b>		4
Table 2	Learning	samples	s of th	nning	test
14010 -	Dearing	our pres	0 01 10	comp.	

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、class1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、class0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. class1の検出 精度は95.3%, class0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 のスケーリングは考慮できるが,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

- 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.