

# 【招待ショートサーベイ】インフラ点検のための変状識別技術

藤井 浩光<sup>†</sup> 山下 淳<sup>†</sup> 浅間 一<sup>†</sup>

<sup>†</sup> 東京大学大学院 工学系研究科 〒113-8654 東京都文京区本郷 7-3-1

E-mail: †{fujii,yamashita,asama}@robot.t.u-tokyo.ac.jp

あらまし 現在、トンネルや橋梁など社会インフラの老朽化が深刻化しており、維持管理において点検・診断の自動化のためのパターン認識技術が強く求められている。機械学習を用いたインフラ診断の自動化に関する研究は古くより数多くなされている。本論文では、アンサンブル学習を利用したアプローチに焦点を当て、インフラ診断の自動化に関する研究を、筆者らが今まで取り組んできたトンネル打音診断の技術を交えて概説する。

キーワード インフラ点検, 異常検知, アンサンブル学習, 打音検査

## A Short Survey on Defect Detection for Inspection of Social Infrastructures

Hiromitsu FUJII<sup>†</sup>, Atsushi YAMASHITA<sup>†</sup>, and Hajime ASAMA<sup>†</sup>

<sup>†</sup> School of Engineering, The University of Tokyo Hongo 7-3-1, Bnkyo-ku, Tokyo, 113-8654 Japan

E-mail: †{fujii,yamashita,asama}@robot.t.u-tokyo.ac.jp

### 1. ま え が き

現在の日本の道路インフラに関する国土交通省の調査 [1] によると、日本全土における道路トンネルの総数は約 10,000 本、総延長は約 4,200 km と報告されている。件数、規模ともに膨大なインフラの維持管理は極めて深刻な問題であり、構造物の異常を早期に発見し事故を未然に防ぐために、ロボットなどを用いた自動点検の技術が必要とされている [2]。

供用中にある構造物の点検では、点検対象の損傷を避けるために一般的に非破壊検査が行われる。これまでに数多くの非破壊検査法が提案されてきており、各手法の特長や制限に関しては、Hohla らによるサーベイ [3,4] に体系的にまとめられている。これらの非破壊検査法を用いて正確な診断を行うためには、計測機器の扱いや得られるデータの解釈に多くの知識と経験が必要であり、その観点からも自動化の要請は高い。そのような背景から、従来より機械学習を用いて非破壊検査における診断の自動化に関する研究が数多くなされてきた。

本論文では、特に自動診断のためのパターン認識技術に焦点を当てる。既存研究における事例とともに筆者らが今まで取り組んできたトンネル打音診断技術について概説する。

### 2. 機械学習を用いた自動診断

#### 2.1 インフラ診断における機械学習の利用

構造物の診断は、多くの場合、異常検知の課題の 1 つとして取り込まれる [5]。特に機械学習を用いたアプローチは、検査

対象の性質に応じて教師なし・半教師ありの手法と、教師ありの手法に大別される。

教師なし・半教師ありのアプローチでは、構造物の診断では健全な状態に対して異常な状態が極めて稀であるという前提の下に、得られたデータから健全なモデルを推定し、そのモデルからの外れ値として異常を検出する [6-8]。例えば、Iwasaki らは半教師ありの手法を提案している [6]。検査対象に取り付けた歪みゲージの値をモニタリングし異常を検知するために、初期のセンサデータから健全なモデルとしての応答曲面を推定し、統計的な検定手法を用いて健全モデルとの類似性を評価することで合成梁の損傷を検出した。また、Louhi らは打音検査法に基づく教師なしのアプローチを提案している [7]。ベテラン点検員が局所的な検査をする際の手順に倣い、連続的な打叩による打音を周波数をもとに逐次クラスタリングし、そのクラスタから外れ値として検出された箇所を異常箇所として検出することで診断を行った。

一方で、検査対象の実際のサンプルが入手可能な場合や、検査対象の劣化を再現した供試体や模擬的な環境が用意できる場合など、健全および異常な状態のサンプルが十分に獲得できる場合には、教師ありのアプローチが有効である [5]。例えば、Yamana らは配電柱の架線に使われる腕金の再利用性を診断するために、目視検査法に基づき画像中の腕金の錆び具合をサポートベクタマシンを用いて識別する研究を行った [9]。コンクリート構造物に関しては、Zhang らがコンクリート橋の甲板から深さの異なる層間剝離を検出するために、打音検査法に

基づき打叩音を RBF ニューラルネットワークで分類した [10]. また, Iyer らはコンクリートパイプラインの状態診断を行うために, 超音波探傷法に基づき離散ウェーブレット変換を用いて解析した超音波信号を多層パーセプトロンで学習し, 異常の有無および種類を識別した [11]. このように様々な検査対象, および非破壊検査法に対して診断の自動化のための研究がなされており, 機械学習のテクニックも多岐にわたっている [9–12].

## 2.2 異常検知における課題とアンサンブル学習

機械学習を用いた識別問題の課題として, 特徴量空間が多次元で有効な特徴量が明らかではない場合に, 識別精度の向上に貢献しない特徴量を評価することによる誤識別の増大が知られている. 構造物の異状診断においても, 複数の多チャンネルセンサを用いることが多く, 取得可能なデータは多次元となる. 診断に有効な特徴量は明らかではないため, 2.1 節で示した例のように多くの場合は人手により特徴量が設計されてきた. しかし, 設計に用いたデータに過適合を起こすことも多く, 正しい診断のための特徴量の設計は大きな課題であった.

近年の異常検知などデータマイニングの分野において, その解決法の 1 つとしてアンサンブル学習の利用が注目されてきた [13]. アンサンブル学習は, 複数の異なる識別器を統合するためのメタアルゴリズムの総称であり, 代表的なものとしては boosting [14] や bagging [15], stacking [16] などの手法が知られている. 例えば, 顔認識などの識別問題 [17] や, クラスタリング [18], 外れ値検出 [19] などで有効性が確認されてきた. 特に, Lazarevic ら [19] は異常検知におけるアンサンブル学習の有効性を初期に主張している. 局所外れ値因子を用いた外れ値検出において, データセット中に識別に貢献しない特徴量が存在し単一の識別器では性能が低下する場合にも, 数十個程度の異なる識別器を組み合わせることで, より性能の良い検出が可能であることを示した.

## 3. 時間周波数パターン識別による打音診断

筆者らは, 道路トンネルの点検・診断のために打音検査に基づき, 構造物中の異常 (変状) を検出する診断法を提案してきた. 打音検査法は非破壊検査法の 1 つであり, 検査対象物に衝撃を与えた際に生じる可聴域の音響信号の違いから構造物の異常を検出する検査法である. 検査対象物にセンサを接触させることなく簡便に実施可能であり, さらに検出精度も高いことから, 現在でも目視検査とともに広く用いられている. それらの特長から, 打音検査を用いた診断アルゴリズムの開発 [7, 12, 20–22] だけではなく, 打音信号の解析 [23] や検査ジグの効率化 [24], 点検システムの開発 [10, 25, 26] など, 現在も打音検査に関する研究が盛んに行われている.

### 3.1 パターン認識問題としての打音検査

打音検査では音響信号を用いた識別を行うが, 利用可能な事前知識が少ないという点で特徴的である. 音響信号のパターン認識では, 対象に関する物理的な事前知識の利用や, マルチモーダル化を行うことで解決しようとするアプローチがなされてきた. 例えば, 音声認識では人の声帯や声道の形状, 人の音声の特性などに関する詳細な解析結果に基づき, 発話認識に有効な

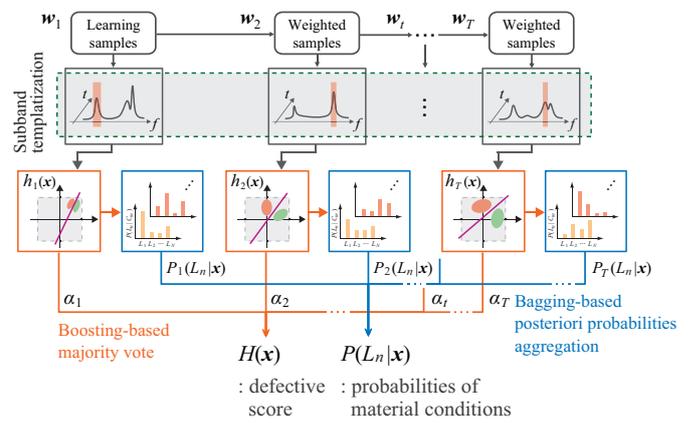


図1 Boosting と bagging を組み合わせた変状の状態推定を伴う変状検出器 [22]

Fig.1 Schematics of our detector [22] by combining boosting-based defect detector and bagging-based material condition estimator.

メル周波数ケプストラム係数などの特徴量が提案されてきた. また, 発話認識を行う識別器を獲得するには, 音声コーパスと呼ばれる数千人から数万人規模の発話サンプルのデータベースを用いて統計的な音響モデルを構築するのが一般的である. 打音検査においても物理的なモデルに基づく打音の解析的研究は行われてきたが, 変状の種類やその劣化の度合いに関して十分なデータベースは存在せず, 診断のために有効な特徴量は提案されていない.

検査時に計測可能な情報に関しても, 打音検査での検出が期待されている浮き変状などは, コンクリート内部に存在し目視で発見することが困難な変状であるため, 映像情報など他モーダルを用いることができない場合も多い. さらに, 打音検査は音響診断であるにもかかわらず, 作業が実施されるのは屋外のトンネルや橋梁などであり, 風切り音や車両のエンジンノイズなど環境雑音の影響, トンネルなどにおける音の反響の影響など, 現場ごとに検査環境の音響特性の違いが大きな問題となる. 打音検査では, そのような大きな制約の中で検出対象を正しく識別するための特徴量をいかに抽出するかが課題となる.

筆者らの提案手法では, 時間周波数解析した打音信号から, 健全である状態 (健状) と変状を精度良く識別可能な部分周波数帯を複数抽出し統合する. アンサンブル学習の枠組みを用いることで, 変状検出 [20], 変状の状態推定 [21], 環境雑音の出現など検査環境の変化した場合の自動校正 [22] を統一的に実現する変状検出器が構成可能であることを示した. 提案した変状検出器の構成を図 1 に示し, 以下で概要を説明する.

### 3.2 Boosting と Bagging との統合による変状状態推定

提案手法では, boosting を用いた変状検出を行った. 特徴量空間は観測する周波数成分全体であり, 複数の識別器 (弱識別器) は特徴量空間をランダムにサンプリングした, それぞれ異なる部分周波数帯を扱う.

弱識別器は, 健状と変状の訓練データそれぞれに関して, 弱識別器に特有の部分周波数帯における時間周波数パターンの重み付き平均としてモデルを獲得する. 健状・変状モデルとの類

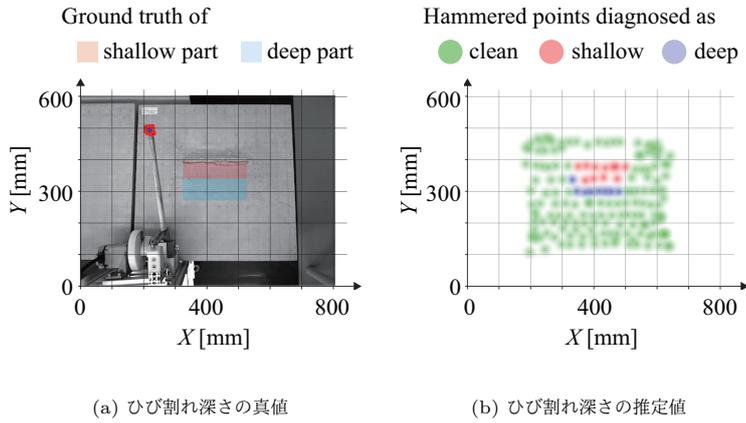


図 2 斜めひび割れ変状の検出および深さ推定 [22].  
Fig. 2 Result of defect detection and depth estimation of slant crack [22].

似性を用いて、訓練データ中の変状・健全サンプルを分離する識別関数をサポートベクタマシンで学習し、以下に示す各弱識別器の信頼度を重みとした投票の結果として変状を検出する。

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

ここで、 $\mathbf{x}$  は時間周波数領域での打音の 2 次元信号であり、 $T$  は弱識別器の統合個数である。  $h_t(\mathbf{x})$ ,  $\alpha_t$  は、それぞれ  $t$  番目の弱識別器に関する識別結果および学習の過程で算出される信頼度であり、 $h_t(\mathbf{x})$  の値域は  $[-1, 1]$  であり、 $\alpha_t > 0$  である。強識別関数  $H(\mathbf{x})$  の出力は  $[-1, 1]$  に正規化されており、 $H(\mathbf{x})$  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、 $H(\mathbf{x}) \geq \Theta$  のように  $H(\mathbf{x})$  の値について閾値  $\Theta$  に対する大小に注目することで健全・変状を 2 値判別することが可能である。

さらに、各弱識別器が扱う部分周波数帯においては、変状の劣化状態ごとに健全・変状モデルとの類似度の分布に大きな偏りが生じることに注目し、変状状態の推定を行った。訓練データの健全・変状モデルとの類似度の分布を、各弱識別器  $h_t(\mathbf{x})$  ( $t = 1, \dots, T$ ) ごとに Mean Shift を用いてクラスタリングし、変状の状態をクラスタ  $C$  に関する状態ラベル  $L_n$  の事後確率分布  $P_t(L_n | C)$  を求める。変状状態推定においては弱識別器群は bagging により統合され、最終的に打音信号  $\mathbf{x}$  に対して推定する変状状態のラベル  $L^*(\mathbf{x})$  は以下のように推定される。

$$L^*(\mathbf{x}) = \underset{L_n}{\operatorname{argmax}} \sum_t P_t(L_n | C_t(\mathbf{x})), \quad (2)$$

ここで、 $C_t(\mathbf{x})$  は  $t$  番目の弱識別器により推定された、打音信号  $\mathbf{x}$  の所属するクラスタである。

表層に対して斜めに侵入したひび割れを再現したコンクリート供試体を用いた実験を行った。健全部の打音と、到達深さ 30 mm を基準として“浅い”、“深い”とラベル付けした変状部の打音を含む訓練データを用いて、ひび割れの到達深さに関してマルチラベルの推定を行った。図 2(a) に示すひび割れの到達深さの分布と図 2(b) に示す推定値との比較で示すように、精

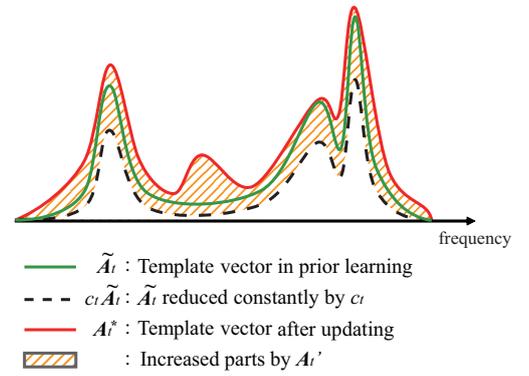


図 3 提案手法 [21] による周波数テンプレート更新  
Fig. 3 Updation of frequency template by the proposed method [21].

度良く斜めひび割れ位置の検出、および深さに関するラベルの推定が可能であることを確認した。

### 3.3 モデル更新による自動校正

打音検査を実施する現場では、強風や通行車両のエンジン音などによる影響は大きく、状況によっては検出器を再構築する必要が生じる。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、追加学習による自動校正法を提案した。各弱識別器が持つ健全・変状モデルである時間周波数領域でのテンプレートを更新するために、boosting アルゴリズムを拡張することで追加訓練データに対する重みを考慮した、以下のようなテンプレートの更新則を導出した。

$$\mathbf{A}_t^* = c_t \tilde{\mathbf{A}}_t + \mathbf{A}'_t, \quad (3)$$

ここで、 $\mathbf{A}_t^*$  が更新後のテンプレートであり、 $\tilde{\mathbf{A}}_t$  は事前学習で獲得した更新前のテンプレート、 $\mathbf{A}'_t$  が追加学習における新たな訓練データから計算される差分である。  $c_t$  は、事前学習で生成した検出器を用いた評価で得られる事前訓練データに対する追加訓練データの重みの逆比であり、追加学習の過程で得ることができる。式 (3) における周波数テンプレートの更新則を図 3 に模式的に示す。事前学習で得られた周波数テンプレート  $\tilde{\mathbf{A}}_t$  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（黒破線）。追加学習における新たな訓練データから計算される  $\mathbf{A}'_t$  は、図 3 に斜線で示された差分に相当し、 $c_t \tilde{\mathbf{A}}_t$  と足し合わせることで更新後の周波数テンプレート  $\mathbf{A}_t^*$  (赤実線) が得られる。

式 (3) から確認できるように、テンプレートの更新則は事前学習で既に得られている事前学習におけるテンプレートと、 $c_t$  の計算のための訓練データの重み、および追加学習データのみから計算することが可能である。追加学習を更新則として導出しているため、多数の弱識別器を更新する際にも選定のための繰り返し計算が不要であり、高速にテンプレートの更新が可能である。

実験では、コンクリート供試体実験による定量評価および実際の供用中のトンネルでの検証を行った。いずれの実験においても環境雑音の発生により音響的な条件が変化し、変状検出の

性能が低下した場合にも、提案手法を用いた追加学習によって性能の回復が可能であることを示した。

#### 4. あとがき

本論文では、社会インフラ点検における診断の自動化に焦点を当て、特に機械学習を用いたパターン認識技術の概要について述べた。既存研究における事例とともに筆者らが今まで取り組んできたトンネル打音診断技術について概説した。

すでに述べたように、インフラ診断の技術には教師なし・半教師あり、教師ありのアプローチが数多く研究されている。各状態のモデルに基づく教師ありのアプローチは、診断の精度を求め、より詳細に構造物の状態を推定する上では有効であるが、実際の現場では十分なデータが入手できない状況や、状態が定義できない状況も存在する。一方で、十分な事前知識がない状況では、教師なしのアプローチをとることは困難である。今後、インフラ診断の自動化に取り組むにあたり、健状モデルをベースとした半教師ありの診断法の構築が興味深い課題である。

#### 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、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

- [1] Ministry of Land, Infrastructure, Transport and Tourism, "Road statistics annual report," 2015.
- [2] R. Takada and N. Oishi, "Priority issues of infrastructure inspection and maintenance robot: A part of cocn 2012 project 'disaster response robot and its operational system'," 2013 IEEE Region 10, Humanitarian Technology Conference, pp. 166–171, 2013.
- [3] J. Hoła and K. Schabowicz, "State-of-the-art non-destructive methods for diagnostic testing of building structures – anticipated development trends," Archives of Civil and Mechanical Engineering, vol. 10, no. 3, pp. 5–18, 2010.
- [4] J. Hoła, J. Bień, Ł. Sadowski, and K. Schabowicz, "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, pp. 87–96, 2015.
- [5] C.C. Aggarwal, Outlier Analysis, Springer, 2013.
- [6] A. Iwasaki, A. Todoroki, Y. Shimamura, and H. Kobayashi, "Unsupervised structural damage diagnosis based on change of response surface using statistical tool (application to damage detection of composite structure)," JSME International Journal. Series A, Solid Mechanics and Material Engineering, vol. 47, no. 1, pp. 1–7, 2004.
- [7] J.Y. Louhi (Kasahara), H. Fujii, A. Yamashita, and H. Asama, "Unsupervised learning approach to detection of void-type defects in concrete structure using hammering and clustering," The 6th International Conference on Advanced Mechatronics, pp. 319–320, 2015.
- [8] J. Igual, A. Salazar, G. Safont, and L. Vergara, "Semi-supervised bayesian classification of materials with impact-echo signals," Sensors, vol. 15, no. 5, pp. 11528–11550, 2015.
- [9] M. Yamana, H. Murata, T. Onoda, and T. Ohashi, "Development of system for crossarm reuse judgment on the ba-

- sis of classification of rust images using support vector machine," 17th IEEE International Conference on Tools with Artificial Intelligence, pp. 1–5, 2005.
- [10] G. Zhang, R.S. Harichandran, and P. Ramuhalli, "An automatic impact-based delamination detection system for concrete bridge decks," NDT & E International, vol. 45, no. 1, pp. 120–127, 2012.
- [11] S. Iyer, S.K. Sinha, B.R. Tittmann, and M.K. Pedrick, "Ultrasonic signal processing methods for detection of defects in concrete pipes," Automation in Construction, vol.22, pp.135–148, 2012.
- [12] J. Ye, M. Iwata, K. Takumi, M. Murakawa, H. Tetsuya, Y. Kubota, T. Yui, and K. Mori, "Statistical impact-echo analysis based on grassmann manifold learning: Its preliminary results for concrete condition assessment," EWSHM-7th European Workshop on Structural Health Monitoring, pp. 1349–1356, 2014.
- [13] C.C. Aggarwal, "Outlier ensembles (position paper)," ACM SIGKDD Explorations Newsletter, vol. 14, no. 2, pp. 49–58, 2013.
- [14] Y. Freund and R.E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," European Conference on Computational Learning Theory, pp. 23–37, Springer, 1995.
- [15] L. Breiman, "Bagging predictors," Machine Learning, vol. 24, no. 2, pp. 123–140, 1996.
- [16] D.H. Wolpert, "Stacked generalization," Neural networks, vol. 5, no. 2, pp. 241–259, 1992.
- [17] P. Viola and M.J. Jones, "Robust real-time face detection," International Journal of Computer Vision, vol. 57, no. 2, pp. 137–154, 2004.
- [18] A. Strehl and J. Ghosh, "Cluster ensembles — a knowledge reuse framework for combining multiple partitions," Journal of Machine Learning Research, vol. 3, pp. 583–617, 2002.
- [19] A. Lazarevic and V. Kumar, "Feature bagging for outlier detection," The eleventh ACM SIGKDD International Conference on Knowledge Discovery in Data Mining, pp.157–166, 2005.
- [20] H. Fujii, A. Yamashita, and H. Asama, "Automated diagnosis of material condition in hammering test using a boosting algorithm," 2014 IEEE International Workshop on Advanced Robotics and its Social Impacts, pp. 101–107, 2014.
- [21] H. Fujii, A. Yamashita, and H. Asama, "Improvement of environmental adaptivity of defect detector for hammering test using boosting algorithm," 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 6507–6514, 2015.
- [22] H. Fujii, A. Yamashita, and H. Asama, "Defect detection with estimation of material condition using ensemble learning for hammering test," 2016 IEEE International Conference on Robotics and Automation, pp. 3847–3854, 2016.
- [23] M. Asano, T. Kamada, M. Kunieda, K. Rokugo, and I. Kodama, "Impact acoustics methods for defect evaluation in concrete," Non-Destructive Testing in Civil Engineering 2003, BB 85-CD, 2003.
- [24] Y. Sonoda, and Y. Fukui, "A basic study on hammering tests of deteriorated concrete structures," 35th Our World in Concrete and Structures, 100035063, 2010.
- [25] T. Suda, A. Tabata, J. Kawakami, and T. Suzuki, "Development of an impact sound diagnosis system for tunnel concrete lining," Tunneling and Underground Space Technology, vol. 19, pp. 1–8, 2004.
- [26] A. Watanabe, J. Even, L.Y. Morales, and C. Ishi, "Robot-assisted acoustic inspection of infrastructures-cooperative hammer sounding inspection," 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 5942–5947, 2015.