

誤判定の軽減を目的としたカスケード型 AdaBoost による打音検査

Cascadetype AdaBoost with reduced misjudgement for hammering test

† 内山 竜吾 Ryugo UCHIYAMA † 渡邊 昂樹 Koki WATANABE † 田邊 造 Nari TANABE

公立諏訪東京理科大学 † Suwa University of Science
E-mail:†{T119030@ed, T118178@ed, nari@rs}.sus.ac.jp

1 はじめに

本論文は、カスケード分類器による複数の識別器を用いた自動判定システムを提案する。提案手法は、(Step1) 有色性駆動源カルマンフィルタを用いて所望信号を抽出する。次に (Step2) 打音信号から抽出した特徴量を教師データとして AdaBoost により識別器を生成する。(Step3) 最小検出率と最大誤検出率を満たす識別器を組み合わせたカスケード構造にして判定・評価する手法である。提案手法の特徴は、(i) 緩い閾値の識別器から通すことによる高速な識別と (ii) 複数の識別器を用いることによる健全部の判定制度向上である。

2 提案手法

Step 1 雑音推定と所望信号の抽出

n 時刻の観測信号 $x(n)$ を短時間フーリエ変換 (STFT) した観測信号スペクトルは、所望信号スペクトル $X(\lambda, k) = S(\lambda, k) + V(\lambda, k)$ と表される。ここで、 $S(\lambda, k)$ と $V(\lambda, k)$ は所望信号 $s(n)$ と雑音信号 $v(n)$ を STFT したものである。また、 λ と k はそれぞれフレーム番号と周波数ビン番号である。

雑音信号 $v(n)$ は $Q(\lambda, k) = \sqrt{\text{osub}(\lambda, k) \frac{\bar{V}(\lambda, k)}{\bar{X}(\lambda, k)}}$ を ISTFT することにより算出され、この分散値を求める。ここで、 $\bar{X}(\lambda, k)$ と $\bar{V}(\lambda, k)$ は平滑化観測パワースペクトルと平滑化雑音パワースペクトルである。

観測信号から所望信号を抽出するための状態空間モデルは、所望信号 $s(n)$ の時間的推移からなる状態方程式に加え、所望信号 $s(n)$ と雑音信号 $v(n)$ から成る観測方程式で、次のように構成される。

$$\left. \begin{aligned} [\text{状態方程式}] \quad & \mathbf{s}(n+1) = \phi \mathbf{s}(n) + \boldsymbol{\delta}(n+1) \\ [\text{観測方程式}] \quad & \mathbf{x}(n) = M^T \mathbf{s}(n) + \mathbf{v}(n) \end{aligned} \right\} \quad (1)$$

ここで、状態遷移行列 ϕ は 0 と 1 で構成される行列、有色性駆動源ベクトル $\boldsymbol{\delta}(n+1)$ は $\mathbf{s}(n+1)$ と 0 で構成されるベクトル、観測遷移行列 M^T は所望信号の発生から観測までの推移を示す行列、 $\mathbf{v}(n)$ は雑音信号ベクトルである。

式 (1) の状態空間モデルを解くことで、正確な所望信号 $\mathbf{s}(n)$ が推定される。

Step 2 AdaBoost の正誤判定学習

所望信号スペクトルピーク p_i とその周波数 f_i を特徴量 $\sigma_i(p_i, f_i)$ ($i = 1, \dots, N$) として、教師ラベル $t_i = \{+1, -1\}$ と重み w_i^m ($m = 1, \dots, M$) を初期値 $1/N$ として教師データとする。

弱識別器の判定失敗率を表す重み付き誤差関数 E_m は

$$E_m = \frac{\sum_{i=1}^m w_i^m I(y_m(\sigma_i) \neq t_i)}{\sum_{i=1}^m w_i^m} \quad (2)$$

が最小になる閾値 l_m を探索することで最良な判定をする弱識別器が得られる。ここで、 $I(y_m, t_n)$ は符号関数であり次式

$$I(y_m, t_n) = \{y_m \neq t_n | 1, y_m = t_n | 0\} \quad (3)$$

より求まる。なお、弱識別器の優先度を決定する信頼値 a_m は

$$a_m = \frac{1}{2} \ln \left(\frac{1 - E_m}{E_m} \right) \quad (4)$$

で算出される弱識別器の判定精度を表す値である。

以上より、最適な閾値 l_m と信頼値 a_m の 2 つから弱識別器 $y_m[a_m, l_m]$ が得られる。

次に、重み w_i^m は次式

$$w_i^{m+1} = w_i^m \exp\{a_m I(y_m(\sigma_i) \neq t_i)\} \quad (5)$$

で更新される。

重み更新後の教師データを用いて同様に学習を繰り返すことで、識別精度の高い強識別器を作成する。

Step 3 カスケード型 AdaBoost による正誤判定




図 1 カスケード型識別器のモデル

図 1 のようにカスケード型 AdaBoost は H 個の強識別器を組み合わせた構造をしており、第 h 段の判定式は

$$Y_h(\sigma_k) = \text{sign} \left(\sum_{m=1}^{M_h} a_{h,m} y_{h,m}(\sigma_k) - l_h \right) > 0 \quad (6)$$

で表され、 $Y_h(\sigma_k)$ が負になるまで繰り返される。ここで、 $y_{h,m}$ は第 h 段に選択される m 番目の弱識別器、 M_h は第 h 段に選択される弱識別器の個数、 l_h は第 h 段における閾値である。

このとき、識別器の少ないものから判定していくが、1 つでも損傷部判定がなされた場合にその打音信号の判定結果は損傷部となる。

3 計算機シミュレーション

表 1 AdaBoost 判定結果

[%]	場所 1	場所 2	場所 3	場所 4	場所 5	場所 6	場所 7	場所 8	平均
損傷部	94.35	95.27	98.71	97.68	91.17	99.28	99.19	89.27	95.62
健全部	90.15	71.04	68.14	72.11	78.95	82.14	87.23	82.11	78.98

提案手法の有効性を明らかにするために、強識別器を 3 つにして Cross-Validation した結果を表 1 に示す。

表 1 より、提案手法は前段の識別器である程度損傷部を割り出した後に、判定が難しい部分を後段の弱識別器に回していくため損傷部の精度は高くなると考えられる。一方、健全全部は損傷部と判定されずに後段の判定まで健全部と判定されるため、損傷部より精度が低くなってしまうことが考えられる。

以上より、提案手法は高速な正誤判定が可能となる。また、健全部の判定を向上させるために強識別器の数を増すことで精度の向上が見込めることも確認している。

4 まとめ

本論文は、複数の識別器からなるカスケード型の AdaBoost をもちいた正誤判定法を提案した。提案手法は、観測信号を雑音抑圧した後に、抽出した所望信号の特徴量を用いてカスケード型 AdaBoost によって学習評価した結果、損傷部が 95%以上の精度を実現した。

以上より、提案手法は打音判定において高精度なカスケード型 AdaBoost を実現している。

参考文献

- [1] 宮崎海, 田邊造, 古川利博 "AdaBoost を用いた音検査における正誤識別学習" 2020 年度電子情報通信学会信越支部大会.
- [2] Nari TANABE, Toshihiro FURUKAWA, Shigeo TSUJII "Robust Noise Suppression Algorithm with the Kalman Filter Theory for White and Colored Disturbance," IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, Volume E91.A, Issue 3, pp. 818-829 (2010).