

構造部材の破壊音検出のための基礎的検討

東京理科大学 学生員 ○和泉田 健夫
東京理科大学 正会員 佐伯 昌之

1. 序論

大地震が発生した際には、構造物の損傷を迅速に把握する必要がある。そのため、構造部材が破壊した可能性がある箇所を地震後直ちに特定できれば有益と言える。破壊の検出方法としては、部材の振動をモニタリングし、大きな振動を検出したり、固有振動数の変化を検出したりする方法等が考えられ、それらに関する既往の研究も多い。しかしながら、加速度計などのセンサにより振動を検出する場合には、減衰などの問題もあり、多点にセンサを配置する必要があると思われる。

一方、近年では Deep Learning（深層学習）の登場により音声認識技術の発展が目覚ましく、我々も日常生活で利用できるレベルになっている¹⁾。また、主として防犯目的として、音によって起きている状況を認識する「音認識技術」が開発されており、カメラ映像だけでは見えにくい場所での音による状況確認の仕組みも開発されている²⁾。

このように我々は普段生活している中で、音で事象を判断することがしばしばある。多くの人は、部材が折れたときの「バキッ」という音を聞いて、破壊を認識することができる。本研究では計測した木材の破壊音から破壊の検出を試みる。

2. 音声認識に着目したアプローチ

(1) 音声認識の概要

音声認識の研究は、約 50 年以上前から行われているが、音声認識の識別技術の向上と AI (Artificial Intelligence) による Deep Learning の進展によって、2015 年頃からその精度が飛躍的に向上している¹⁾。

音声認識には、音響モデルと言語モデルが用いられている。音響モデルは、対象とする音が含まれる時間を一連の波形から取り出し、それを音素という小さな単位に切り分けて表される。音素には音響特徴量として、メル周波数ケプストラム係数 (Mel

Frequency Cepstral Coefficients, 以下 MFCC) が広く用いられており³⁾、音素の並び方を Deep Learning させることで音響モデルを構築する。また、言語モデルは、単語が音声という雑音のある通信路を伝わり、復号されるときに、その単語を生成する確率で表される。部材の破壊音は言語ではないことから、本研究では、音響モデルのみに着目する。

(2) MFCC の計算方法

MFCC の計算フローを図-1 に示す^{3), 4)}。MFCC の計算には、音声信号を 20ms 程度切り出し、それを一つの単位 (以下、フレーム) として使用する。フレームとして切り出した音声信号にハミングの窓関数をかけ、フーリエ変換する。ここで得られた周波数スペクトルの絶対値の 2 乗を計算することで、パワースペクトルを求める。求めたパワースペクトルに、メル周波数軸上で等間隔となるような 20 個の三角フィルタ (以下、メルフィルタバンク) を適用し、各フィルタの通過エネルギーを算出する。各フィルタ通過エネルギーの和をとって対数をとったものを、新たな信号データとして扱い、それを離散コサイン変換 (DCT) することで MFCC を得る。




図-1 MFCC の計算フロー図

キーワード：損傷判定指標, MFCC, Deep Learning, Neural Network Console

連絡先：〒278-8510 千葉県野田市山崎 2641 東京理科大学理工学部土木工学科構造工学研究室 TEL04-7124-1501(内線 4057)




図-2 計算した音の MFCC

(3) 木材の破壊音とその他の音の MFCC

木材の破壊音とそれ以外の音（本研究では、扉の開閉音と陶器の破壊音）を合計 20 データ計測し、それぞれの音の MFCC を計算した。図-2 にはその中でも特徴的な 4 つを示した。図には 2 つの木材破壊音をプロットしているが、一見したところ、陶器が割れる音と木材破壊音を区別するのは難しいように見える。そのため、この識別には Deep Learning を用いることにしている。

また、本稿における MFCC の計算では、フレーム長やメルフィルタバンクの周波数帯・分割数などのパラメータとして、言語を識別するための手法で広く用いられている値を使用している。そのため、木材の破壊音の検出に適しているとは言えず、今後、部材破壊音を検知するために適切なパラメータの値を検討する予定である。

3. Deep Learning による学習と評価結果

Sigmoid 関数と tanh 関数を用いて 2 層のニューラルネットワークをオープンソースの統合開発環境を使用して構築し、学習と評価を行った^{5) 6) 7)}。この結果を表-1 に示す。

表-1 評価結果

Validation	y'=0	y'=1
other	4	2
broken	0	4
Accuracy	0.8	

表-1 の y' は出力層のニューロンの状態を示している。 y' が 1 の場合は、ニューロンが発火している状態で、木材の破壊音として認識したことを示し、 y' が 0 の場合は、木材の破壊音以外と認識したことを示している。表中の broken は実際の木材の破壊音、other はそれ以外の音を表している。また、Accuracy は分類精度を表しており、今回の分類結果は 80% となっている。これは other の 6 つの音の中に broken と認識されたものが 2 つ含まれているためである。各データで評価値を比較すると、誤認された音の評価値はいくつかの木材の破壊音のそれよりも高い値を示していた。

4. 課題

第 2 章で述べたように、ここで計算した MFCC の各パラメータは音声認識技術の中で広く使われているものである。今後は、フレーム長、メルフィルタバンクの個数と MFCC の抽出領域などのパラメータに対して部材破壊音の検出に適した値を検討していかなければならない。

さらに、学習に用いるニューラルネットワークの検討とノイズ下での検証を繰り返し行い、学習データの確保と分類精度の向上が課題となる。

参考文献

- 1) 河原達也：音声認識技術，電子情報通信学会誌，Vol98, No.8, p710-717, 2015
- 2) 谷真宏，小松達也，ナリセッティチャイタニヤ，近藤玲史：NEC の音状況認識技術とシンガポールにおける実証実験への取り組み，電子電機情報通信学会技術研究報告，117 巻 106 号，2017 年 6 月 22・23 日，p29-32
- 3) 久保陽太郎：音声認識のための深層学習，人工知能 29 巻 1 号，p62-71，2014 年 1 月
- 4) Beth Logan：Mel Frequency Cepstral Coefficient for Music Modeling，2000
- 5) 岡谷貴之：深層学習，講談社
- 6) 足立悠：ソニー開発の Neural Network Console 入門—数式なし，コーディングなしのディープラーニング，株式会社リックテレコム
- 7) Neural Network Console—Sony：<https://dl.sony.com/ja/>