

(36) Autoencoder によるコンクリート打音試験の 浮き判定に関する研究

馬場 那仰¹・江本 久雄²・浅野 寛元³

¹学生会員 福島工業高等専門学校 専攻科産業技術システム工学専攻
(〒970-8034 福島県いわき市平上荒川字長尾 30)
E-mail: 20se11@fukushima.kosen-ac.jp

²正会員 福島工業高等専門学校准教授 都市システム工学科(〒970-8034 福島県いわき市平上荒川字長尾 30)
E-mail: emoto@fukushima-nct.ac.jp

³正会員 福島工業高等専門学校特命助教 都市システム工学科(〒970-8034 福島県いわき市平上荒川字長尾 30)
E-mail: asano@fukushima-nct.ac.jp

近年，わが国におけるコンクリート構造物の点検では，近接目視と同時に打音検査が実施されている．この打音検査は，コンクリートの空洞などの欠陥を簡便に発見できる手法であるが，点検者の主観（聴覚）に依存し客観的評価性に欠ける手法である．そのため，データの蓄積と評価に継続性を与えることが難しく，過去の点検結果との不一致が生じる場合がある．これまでも音色の特徴を示す周波数スペクトルを用いた解析や機械学習による識別が試されてきたが，いずれの研究においてもすべてのコンクリート構造物に共通する特徴や分類手法は発見されていない．

そこで著者らは，打音検査の定量化と精度向上を目的として，教師無しニューラルネットワークの一つである Autoencoder（自己符号化器）を用いた浮き判定を試みた．

Key Words: hammering test, FFT analysis, Artificial Intelligence, Neural Network, Autoencoder

1. はじめに

わが国では，高度経済成長期に大規模な社会基盤構造物の整備が行われた．しかし，建設時から約 50 年が経過した構造物では，劣化・損傷箇所が随所に現れ始めている．その機能維持および安全確保のためには，定期的な点検，評価，診断，管理計画，補修補強または構造物の撤廃，再建設のサイクルを計画的に行っていく必要がある．その中でも，サイクルの初動となる点検業務は特に重要なプロセスである．

上記のように点検業務の重要性が高まっている状況を受け，国土交通省は 2014 年に道路法施行規則の一部を改正し，橋梁およびトンネルの点検を 5 年に 1 回の頻度で，近接目視により実施することを義務付けた¹⁾．しかしながら，近接目視による点検のみでは，構造物内部の劣化・損傷を発見できないため，打音試験をはじめとした非破壊検査が近接目視と同時に行われている．その中でも打音検査は，必要とする器具がハンマーのみであり，簡便な手法であることから，橋梁等の事前点検においては主要な検査方法として用いられている．しかしな

がら，打音検査は，健全部と劣化部の打撃音を検査者の聴覚によって判断する手法であり，検査者の経験や熟練度によって検査結果が異なる場合がある．同時に，データの蓄積や評価に継続性を持たせることが困難であり，過去に実施された点検結果との不整合が起こり得るのが現状である．

これまでに，打音検査を定量化するために，音色の特徴を示す周波数スペクトルを用いた解析や機械学習による識別が行われてきた²⁾⁴⁾．それぞれの研究において異なる観点で打音の健全性が評価されてきたが，いずれの研究においても結論に反するデータが存在し，打音の健全性を正確に判断する指標は未だ発見されていない．

そこで，本研究においても打音検査を定量化するために，打音検査の識別を人間ではなくコンピュータで行う方法を検討する．打音検査は打音の清濁さによって健全性を診断する手法であることから，本研究においても音色の特徴を示す周波数スペクトルを打音の特徴量として用いる．そして，打音の識別には，教師なしニューラルネットワークの一つである Autoencoder（自己符号化器）を使用し，特徴量の次元削減による打音の識別を試みた．

2. 使用する打音データの概要

(1) 供用中の構造物における打音試験

本研究では、供用中である福島県いわき市内のコンクリート構造物 50 箇所を対象として、健全部と欠陥部における点検ハンマーによる打撃時の打撃点近傍の打撃音を録音したデータを使用する。なお、録音時、明らかに打撃の際の異音で容易に判断できる場所を欠陥部とみなして録音およびラベリングを行った。また、1 回の録音で 5 回（一部 4 回）の打撃を行い、打撃点から少し離れた位置に図-1 のように録音機を設置して録音した。使用した録音機の計測可能範囲は 60～20,000Hz、サンプリング周波数（標本化周波数）は 44.1kHz であり、ステレオ 2 チャンネルでの録音を行った。

(2) 打音主要部の抽出

録音した打音データには、打撃音のほかに風音や自動車の通過音などのノイズが含まれている。そこで、打音データ内のノイズの除去を目的として、データ長の調節を行った。この際、打撃時前後のノイズは完全に除去されているが、打撃時のノイズはある程度含まれているが、本研究では考慮しないものとする。また、この操作時には、高速フーリエ変換（FFT 処理）における周波数解像度を統一するために、打音データの長さをすべて統一する。本研究では、音圧の振幅ピークを境として、前方に 3msec、後方に打音の振幅が十分収束している 97msec までの計 100msec の区間（主要部）を抽出した。図-2 に打音主要部の抽出過程を示す。

(3) 打音特徴量の抽出

一般に、音は音圧、音高、音色の三要素で構成されている。この内、打音の識別において重要な要素は、打音検査が打音の清濁さによってコンクリートの健全性を評価する手法であることから、音色であると考えられる。そして、音色は周波数成分の違いによって変化するため、本研究では打音データの周波数成分（振幅スペクトル）を打音の特徴量として使用した。

打音データの周波数成分に関しては、前述の 100msec の打音データを FFT 処理することによって求めた。この時、録音された音が衝撃的で継続時間が短く、開始と終わりの音圧が 0 に近いことから、窓関数にはレクタングュラウィンドウ（矩形窓）を使用した。また、単一の打音を使用しているため、オーバーラップさせずに FFT 処理を実行した。なお、欠陥の有無による周波数成分の分布の違いを比較するため、式(1)によって、最大スペクトル値が 1 になるように正規化を行った。

$$S'(f[k]) = \frac{S(f[k])}{\text{Max}\{S(f)\}} \quad (1)$$



図-1 打音録音の様子




図-2 打音主要部の抽出




図-3 周波数スペクトル

ただし、 $S'(f[k])$ は補正後の $f[k]$ Hzにおける周波数スペクトル、 $S(f[k])$ は補正前の $f[k]$ Hzにおける周波数スペクトル、 $\text{Max}\{S(f)\}$ は周波数スペクトル（振幅スペクトル）全体の最大値である。

FFT 処理によって得られた周波数成分について、使用した録音機の計測可能範囲が 60～20,000Hz であることから、60Hz 未満および 20,000Hz を超える周波数スペクトルは使用しないものとした。この時、使用する打音データが 100msec（0.1sec）であることから、1 打音あたりのサンプル数は 1,994、周波数解像度は 10Hz である。図-3 に同一構造物における健全部と欠陥部の打音の周波数スペクトルの一例を示す。

3. Autoencoder による打音の識別モデル

(1) Autoencoder と打音の識別の考え方

本研究における識別モデルでは、Autoencoder を使用する。Autoencoder とは、ニューラルネットワークにおける中間層のニューロン数を入力層および出力層よりも少なく設定することで、圧縮（エンコード）および復元（デコード）過程を経て入力データを復元するアルゴリズムである。通常、入力データと出力データが等しいとき、中間層のデータは入力データの特徴を表しているとみなして、データの次元圧縮に用いられるアルゴリズムである。

本研究では、Autoencoder に健全部の周波数特性を過学習させた、健全部の周波数特性を再現する生成モデルを打音の識別に利用する。この時、入力されたデータに対する出力データの再現度（異常度）を算出し、入力されたデータを再現できる場合は「健全部」、再現できない場合は「欠陥部」とであると判断することで打音の識別（異常検知）を行う。

(2) 説明関数と目的関数および識別モデル

識別モデルにおける説明関数（入力データ）は、打音データを FFT 処理することで得られた 60~20,000Hz の振幅スペクトル（1,994 次元）を使用する。また、目的関数（出力データ）は、「健全部」もしくは「欠陥部」の 2 種類として識別モデルを作成した。本研究で使用した識別モデル（ニューラルネットワーク）の各パラメータを表-1 に示す。

(3) 打音の異常度の評価方法

打音の異常度を評価する際には、周波数スペクトルの分布の差を比較するために、打音データを識別モデルに入力した時の、入力データの周波数スペクトル A と出力データの周波数スペクトル F の面積の差分 ΔS を用いる。式(2)に異常度の評価式を示す。また、異常度の評価値を求める過程を図-4 に示す。

$$\text{異常度} = \frac{|\Delta S|}{S_A} = \int_{f_0}^{f_{\max}} \frac{|A_f - F_f|}{A_f} df \quad (2)$$

ただし、 A_f は周波数 f における入力データの周波数スペクトル、 F_f は周波数 f における出力データの周波数スペクトルである。なお、異常度の基準となる入力データの周波数スペクトルの面積 S_A は、使用する打音データによって異なるため、入力データと出力データの周波数スペクトルの面積の差分 ΔS を、異常度の基準となる入力データの周波数スペクトルの面積 S_A で除している。

しかし、FFT によって得られる打音データの周波数スペクトルは連続値ではないため、式(2)を式(3)のように離散化して用いる。

表-1 識別モデルの構成

ニューロン数	入力層	1994
	中間層 1	1024
	中間層 2	512
	中間層 3	256
	中間層 4	512
	中間層 5	1024
	出力層	1994
活性化関数	中間層	ReLU
	出力層	シグモイド関数
損失関数		二値交差エントロピー
最適化アルゴリズム		adam
バッチサイズ		Auto
エポック数		1000




図-4 異常度の算出過程

$$\text{異常度} = \sum_{i=1}^n \frac{|A_f \Delta f - F_f \Delta f|}{A_f \Delta f} = \Delta f \sum_{i=1}^n \frac{|A_f - F_f|}{A_f} \quad (3)$$

ただし、 n は打音データのサンプル数、 Δf は周波数分解能である。

また、式(3)における周波数分解能 Δf は、サンプル数 n と同様に、サンプリング周波数と打音データの長さに依存するため、サンプル数 n を用いて異常度の評価値を算出する。式(4)に本研究で用いた打音の異常度の評価式を示す。

$$\text{異常度} = \frac{1}{n} \sum_{i=1}^n \frac{|A_f - F_f|}{A_f} \quad (4)$$

(4) Autoencoder による評価結果

式(4)を用いて「健全部」のデータ 246 個と、「劣化部」のデータ 242 個、計 488 個のデータの異常度の評価値を算出した。その結果をヒストグラムにまとめたものを図-5 に示す。図-5 より、打音を異常であると判断する異常度の基準値を 0.5 に設定することで、「欠陥部」をすべて検出できる。なお、異常度の評価値が 0.5 を超えている「健全部」のデータはわずかしかなかったため、異常度の基準値は 0.5 に設定することが適切であると判断する。また、この時の識別精度は 0.99 (=486/488) であった。

(5) 5 打音平均との比較

打音の異常度の評価および識別に Autoencoder を用いることの効果を確認するために、健全部 5 打音の平均振幅スペクトルを使用した異常度の評価と識別を行った。図-6 に異常度評価の過程を示す。まず、健全部の打音データ 5 つの振幅スペクトルの平均を求め、これを異常度評価の基準データとする。そして、前節の式(4)を用いて、点検データの異常度の評価値を算出する。ただし、 A_f を基準データの振幅スペクトル、 F_f を点検データの振幅スペクトルとする。

以上の操作を「健全部」のデータ 246 個と、「欠陥部」のデータ 242 個、計 488 個のデータに対して行い、すべてのデータの異常度の評価値を算出する。その結果をヒストグラムにまとめたものを図-7 に示す。

図-7 より、すべての「欠陥部」を検出するためには、異常度の基準値を 0.3 に設定する必要があるが、この場合には異常度の評価値が 0.3 を超える「健全部」であるデータも「劣化部」とであると判断される。異常度の評価値が 0.3 を超えている「健全部」のデータが多く存在するため、ここでは打音を異常であると判断する異常度の基準値は 0.5 に設定することが適切だと判断する。また、異常度の基準値を 0.5 に設定した場合の識別精度は 0.95 (=465/488) であった。前節における Autoencoder を用いた場合に比べて識別精度は低くなっており、AI を用いることによる識別精度の向上が確認できた。

4. まとめ

本研究では、教師なしニューラルネットワークの一つである Autoencoder を使用し、特徴量の次元削減によるコンクリートの浮き判定を試みた。特徴量には音色の特性を示す周波数成分の振幅スペクトルを使用し、健全部と欠陥部の振幅スペクトルの分布の違いを利用した識別を行った。その結果、健全部 5 打音の平均振幅スペクトルを基準とした欠陥部の識別に比べて、Autoencoder による識別は高い精度を示し、浮き判定に Autoencoder を利用することの優位性を示せた。

今後は、本識別モデルを供用中の構造物へ試験的に使用して、その識別精度を確認し、使用する特徴量や識別モデルにおけるハイパーパラメータの再検討、現場においてリアルタイムで浮きの判定を行うシステムの構築を行う予定である。

謝辞：本研究は、公益財団法人高橋産業経済研究財団事務局の研究助成のもと推進できましたことに感謝申し上げます。また、本研究の実施にあたり、有益なご議論、情報提供をいただきました「構造工学での AI 活用に関




図-5 Autoencoder による異常度の度数分布




図-6 5 打音平均振幅スペクトルによる異常度の算出過程




図-7 5 打音平均振幅スペクトルによる異常度の度数分布

する研究小委員会（委員長：東京大学・全邦釘准教授）」及びWGの委員の皆様に感謝申し上げます。

参考文献

- 1) 国土交通省：維持修繕に関する省令・告示の規定について、<<http://www.mlit.go.jp/common/001042579.pdf>>, (入手 2020.06.08).
- 2) 国土交通省：道路法施行規則（昭和二十七年建設省令第二十五号），<https://elaws.e-gov.go.jp/search/elawsSearch/elaws_search/lsg0500/detail?lawId=327M50004000025>, (入手 2020.1.25).
- 3) 園田佳巨，川端健太，別府万寿博，福井雄気：打音データを用いたコンクリート内部欠陥の評価に関する基礎的考察，土木学会構造工学論文集，Vol.57A，pp.802-811，2011.
- 4) 新保貴広，坂憲浩，佐藤昌志：コンクリート床板の打音検査における数値化（見える化）に関する研究，第 59 回（平成 27 年度）北海道開発技術研究発表会，2015.