

# 打撃音のスカログラムに基づく道路橋 RC 床版の欠陥検出における CNN・CNN-SVM ハイブリッドの計算コストおよび検出性能の比較

日本道路(株) 正会員 ○長谷 啓司

富山県立大学 正会員 内田 慎哉, 学生会員 舘田 英里香

## 1. はじめに

本研究では、道路橋 RC 床版の舗装打換工事における打音検査の効率化・客観化を目的に、打撃音のスカログラムを入力とする深層学習に基づく2種類の欠陥分類モデル (CNN および CNN-SVM ハイブリッド) を構築し、両者の計算コストと欠陥検出性能との関係を整理した。

## 2. 打撃音のスカログラム

### 2.1 対象とした道路橋 RC 床版および打音法による測定

本研究では、3つの道路橋 (A 橋, B 橋, C 橋) の RC 床版を対象とした。各橋梁の床版上面の状態として、A 橋は平滑、B 橋は凹凸、C 橋はひどい凹凸であった。なお、いずれも舗装打換工事期間中に実施しており、測定時にはアスファルト舗装が切削除去されている。

写真-1 に打音法による測定状況を示す。計測面は RC 床版の上面であり、使用したハンマやマイクロフォンおよび波形収集条件は既往研究<sup>1)</sup>と同じである。

表-1 に各道路橋において打音法を実施した測定点数を示す。表に示す「健全」とは、熟練した検査員が打撃音から欠陥無しと判断した箇所である。一方、「欠陥」とは、上記の検査員が欠陥ありと判定した箇所である。3 橋併せて、合計 1487 点で測定した。

### 2.2 スカログラム

図-1 に B 橋の RC 床版で得られたスカログラムの例を示す。図に示すスカログラムは、時刻歴波形に対してウェーブレット変換をすることで求めた。図より健全では、相関の高い領域が周波数軸方向に伸びるインパルス応答が確認された。一方、欠陥では、相関の高い領域が時間軸方向に伸びるたわみ現象が現れている。なお、A 橋および C 橋で得られたスカログラムにおいても概ね同様の傾向が確認された。

## 3. 欠陥分類モデルの構築および評価

対象とした3橋の RC 床版で得られたスカログラムに対して「健全」および「欠陥」のラベル付けをして、「CNN」および「CNN-SVM ハイブリッド」により、欠陥分類モデルをそれぞれ構築し、評価データの分類を行うことで、計算コストと正解率を比較した。

### 3.1 CNN

ここでは、3種類の事前学習済みモデル (VGG16, VGG19, ResNet50) を採用した。いずれも今回のデータセット (スカログラム) を使ってパラメータを更新 (ファインチューニング) している。図-2 に事前学習済みモデルの一例として、VGG16 の構造を示す。VGG16 は、224×224 ピクセル、3 チャンネル (RGB) の入力画像に対して、複数の畳み込み層および ReLU 活性化層、プーリング層、全結合層を順に適用し、最終的にソフトマックス層によりクラス分類を行うモデルである。なお、データセット (3 橋合計 1487 点) のうち、80%



写真-1 打音法による測定状況の一例

表-1 各道路橋において打音法を実施した測定点数

	A 橋	B 橋	C 橋
健全	125 点	200 点	424 点
欠陥	126 点	182 点	430 点




図-1 B 橋の RC 床版で得られたスカログラムの例

を欠陥分類モデルの構築に用いる「学習データ」、残り 20%を欠陥分類モデルの評価に使用する「評価データ」とした。また、モデルの過学習を防止し、汎化性能の向上を図ることを目的に、「学習データ」に対し左右反転、上下反転、上下・左右方向への平行移動を組み合わせた 6 通りのデータ拡張を実施した。その結果、データ拡張後の「学習データ」は、合計 4443 枚（健全：2206 枚，欠陥：2237 枚）となった。表-2 に「学習データ」をすべて用いて欠陥分類モデルを構築した際に要した計算時間と B 橋の「評価データ（健全：36 枚，欠陥：39 枚）」を分類した正解率を示す。紙面の都合で B 橋の結果のみを示している。いずれの事前学習済みモデルにおいても、計算時間は長くなったものの、正解率は 0.98 以上と非常に高い結果となった。

### 3.2 CNN-SVM ハイブリッド

本研究では、CNN を特徴抽出器として利用し、最終的なクラス分類には SVM を適用するハイブリッド型の学習フレームワークを構築した。これにより、CNN の特徴抽出能力と SVM の高い分類性能を組み合わせ、過学習の抑制および分類精度の向上を図った。なお、ここでは、前節同様、VGG16, VGG19 および ResNet50 の事前学習済みモデルを採用したが、CNN のパラメータは再学習させていない。図-3 に、CNN の事前学習済みモデルとして VGG16 を特徴抽出器に用いた CNN-SVM ハイブリッドの構造を示す。VGG16 では、複数の畳み込み層および ReLU 活性化層、プーリング層を順に適用し、最終的に 7×7 ピクセル、512 チャンネル、計 25088 次元の特徴ベクトルを抽出した。この高次元特徴ベクトルを SVM の入力とし、欠陥分類モデルを構築した。「学習データ」には、合計 4443 枚（健全：2206 枚，欠陥：2237 枚）のスカログラムを使用した。この「学習データ」を用いて欠陥分類モデルの構築に要した計算時間を表-3 に示す。また、表-3 には、B 橋の「評価データ」を分類した結果も併せて示した。計算時間に着目すると、いずれのモデルも 3 分以下と非常に短時間で学習が完了していることがわかる。一方、正解率に関しては、いずれのモデルも CNN と比較すると若干劣る結果になったものの、0.97 以上と高い水準であった。

## 4. まとめ

舗装打換工事における道路橋 RC 床版の点検ツールとして、CNN は高い分類精度が得られる一方、CNN-SVM ハイブリッドは計算時間や計算負荷を抑えつつ実用的な精度を確保できる。したがって、要求精度や運用条件に応じた手法選択により、柔軟かつ実用的な点検が可能であることが示された。

### 参考文献

- 1) 森本 亮, 内田慎哉, 長谷啓司, 舘田英里香 : 道路橋 RC 床版の舗装打換工事における打音点検への事前学習済み畳み込みニューラルネットワークの適用, コンクリート工学年次論文集, Vol.47, No.1, pp.1728-1733, 2025.




図-2 事前学習済み CNN の構造 (VGG16 の例)

表-2 計算時間と正解率 (CNN)

モデル	VGG16	VGG19	ResNet50
計算時間 (分)	78	87	63
正解率	1.000	0.987	0.987




図-3 CNN-SVM ハイブリッドの構造 (VGG16 の例)

表-3 計算時間と正解率 (CNN-SVM ハイブリッド)

モデル	VGG16	VGG19	ResNet50
計算時間 (分)	3	3	1
正解率	0.987	0.973	0.973