

論文 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

森本 亮*¹・内田 慎哉*²・長谷 啓司*³・館田 英里香*¹

要旨：本研究では、道路橋 RC 床版における舗装打換工事の際に打音法を適用し、得られた打撃音のスカログラムを事前学習済みの畳み込みニューラルネットワークにより構築した欠陥分類モデルを用いて、床版の内部欠陥の有無を把握することを試みた。事前学習済みモデルには VGG19_bn を使用し、モデルの学習にはファインチューニングを利用することで、RC 床版の内部欠陥の有無を高い精度で評価できることがわかった。したがって、事前学習済みの畳み込みニューラルネットワークを用いて構築した欠陥分類モデルは、供用中の道路橋 RC 床版における舗装打換工事の際の点検ツールとして、極めて有用である。

キーワード：道路橋 RC 床版, 内部欠陥, 打音法, スカログラム, 畳み込みニューラルネットワーク

1. はじめに

道路橋 RC 床版では、舗装打換工事の際に点検ハンマを用い、打撃音を人の耳で聴く打音検査(写真-1 参照)によって、コンクリート表層の圧縮側鉄筋付近に欠陥があるかを判定している。しかしながら、舗装の打換工事区間は長く、そのため打音検査による点検範囲も広がり、多くの人手と時間が必要となる。さらに、打音検査は、検査員の経験に依存する主観的な点検手法のため、検出結果も検査員により異なる。このような背景から、簡便で効率的かつ誰が点検しても同じ結果になる点検手法の確立が望まれている。

このような背景から、我々の研究グループでは、「I: 供試体での検討」、「II: 実構造物での検討」、「III: 点検ロボットによる点検手法の確立」の3段階で開発を進めている。これまでに、「I: 供試体での検討」では、打音法で測定される打撃応答特性(時刻歴波形)をウェーブレット変換して可視化(スカログラム: 時間-周波数のカラー画像)し、周波数スペクトルなどの信号処理に明るくない検査員でも、欠陥評価を可能にする手法を提案したり²⁾。さらに、打撃音のスカログラムを畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)で分類し、欠陥の有無を自動判定するモデルを構築²⁾した。その結果、人工欠陥を90%以上の精度で検出できることが確認された²⁾。一方で、「II: 実構造物での検討」、すなわち道路橋 RC 床版における実地検証については、未だ着手できていないのが現状である。

そこで、本研究では、道路橋 RC 床版の舗装打換工事において打音法を適用し、得られた打撃音のスカログラムを用いて、事前学習済みの畳み込みニューラルネット



写真-1 舗装打換工事に伴う RC 床版表層の打音検査

ワーク(CNN)により構築した欠陥分類モデルにより、床版内部の欠陥を自動分類することを試みた。なお、本研究で使用した事前学習済みモデルは、5種類のモデル(VGG16³⁾, VGG16_bn³⁾, VGG19³⁾, VGG19_bn³⁾, ResNet 50⁴⁾)である。また、これらモデルの利用には、ファインチューニング(既に学習済みのモデルを今回のスカログラムに合わせて再学習)を適用し、さらにk-分割交差検証を併用することで、過学習を防ぎ、モデルの汎化性能を向上させる工夫を行った。なお、本研究では、これらの計算は Google Colaboratory 環境で実施し、開発言語には PyTorch を使用している。

2. 対象とした道路橋 RC 床版の概要

本研究では、供用中の3つの道路橋(A橋, B橋, C橋)の RC 床版を対象とした。それぞれの概要を写真-2 に示す。対象区間は、A橋が追い越し車線 171 m, B橋が走行車線 185 m, C橋が走行車線 203 m である。なお、これらの橋梁は全て舗装打換工事を実施しており、アスファルト舗装部は切削されている。


*1 富山県立大学大学院 工学研究科環境・社会基盤工学専攻 (学生会員)

*2 富山県立大学 工学部環境・社会基盤工学科准教授 博士(工学) (正会員)

*3 日本道路(株) 生産技術本部技術部



(a) A 橋



(b) B 橋



(c) C 橋


写真-2 対象とした道路橋 RC 床版の概要



写真-3 打音法による測定状況の例

表-1 各道路橋において打音法を実施した測定点数 (全データ数: 1487 点)

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



(a) 打撃波形

(b) 時刻歴波形

図-1 A 橋で得られた打撃波形および時刻歴波形の例 (測定箇所: 健全)

3. 打音法による測定概要

写真-3 に打音法による測定状況の例を示す。計測面は RC 床版の上面で、打撃には加速度センサ内蔵ハンマを使用し、打撃音の受信にはマイクroフォンを用いた。

打撃により入力される弾性波の上限周波数は、工学的な観点から、以下の式⁵⁾で算出できる。

$$f_{max} = \frac{291}{D} \quad (1)$$

ここで、 f_{max} : 入力される弾性波の上限周波数 (Hz)、 D : 鋼球直径 (m) である。測定に使用したハンマの打撃部の直径は 24.6 mm あり、式(1)より上限周波数は約 11.8 kHz となる。

打撃音の受信には、0.007~20 kHz の範囲でフラットな応答感度を持つマイクroフォンを使用した。受信した信号は、サンプリング時間間隔 1 μ s、サンプリング点数 25000 個 (計測時間 25 ms) でデジタル化し、その後波形収集装置に受信波形 (電圧) として記録した。また、入力で使用したハンマも波形収集装置に接続し、マイクroフォンと同じサンプリング時間間隔およびサンプリング点数でデジタル化して、打撃波形 (電圧) を記録した。

表-1 に各道路橋で打音法を実施した測定点数を示す。表に示す「欠陥」は、現場の検査員が浮き・剥離等の欠

陥があると指定した範囲の中から、打音検査に熟知した経験豊富な検査員が打撃音から欠陥があると判断した箇所を指す。一方、「健全」は、打音検査に熟知した検査員が欠陥無しと判断した箇所である。いずれの橋梁においても、「欠陥」および「健全」箇所に対して、表に示す測定点数分の打音法による測定を実施した。これにより、3 橋合計で 1487 点の測定が行われた。

4. 測定結果および考察

4.1 周波数スペクトル

図-1 (a) に、A 橋の健全箇所測定した打撃波形の例を示す。ハンマによる打撃は、非常に短時間の衝突現象 (インパルス入力) であるため、上に凸の波形となった。一方、マイクroフォンで受信した波形は、打撃力の違いにより音圧が変動するため、打撃波形で正規化することとした。具体的には、マイクroフォンで測定した受信波形を打撃波形の最大振幅値 (図-1 (a) 参照) で除すことにより、受信波形を正規化 (時刻歴波形と呼ぶ) した。図-1 (b) に時刻歴波形を示す。また、時刻歴波形に対して、高速フーリエ変換 (FFT) を適用し、周波数スペクト

ルを算出した。図-2に、3橋の健全箇所での測定結果から算出した周波数スペクトルの例を示す。なお、C橋では特徴的な周波数スペクトルが得られたため、2つの結果を併せて示している。図より、全ての橋梁において、約12 kHzまでの範囲で、周波数成分の出現が確認された。これは、3章で示した入力される弾性波の上限周波数(約11.8 kHz)と概ね一致している。しかしながら、図-2(d)に示すC橋の周波数スペクトルでは、その他の周波数スペクトルと比較して、4~10 kHzの周波数成分が多く出現していることがわかる。ここで、写真-4に、C橋の床版上面の状況を示す。写真から明らかとなおり、C橋では健全箇所や欠陥箇所を問わず、測定点となるコンクリート表面に凹凸が目立っていた。この凹凸がある箇所に対してハンマ打撃を行ったため、他の橋梁とは異なる周波数分布が得られたと考えられる。

図-3に、各橋梁の欠陥箇所での測定した時刻歴波形から算出した周波数スペクトルの例を示す。図より、C橋を含むすべての橋梁において、単一の鋭いピーク(図中の赤矢印)が出現していることが確認できる。このピークは、圧縮鉄筋付近に発生した欠陥に起因するたわみ共振現象であると考えられる。特に、測定面の表面性状が粗いC橋においても、たわみ共振現象が確認された点の特徴的である。この共振現象が観察された理由は、コンクリート表面の凹凸部の影響よりも、たわみ共振の影響が支配的であったためと推測される。また、図-3では、たわみ共振に起因するピーク以外にも幾つかのピークが出現していることが確認できる。これは、実際の道路橋RC床版で発生する欠陥が、供試体で模擬した一定深さかつ円盤状の欠陥^{1),2)}とは異なり、深さや形状が不均一であるためと考えられる。これにより、複数のピークが出現したと考えられる。

4.2 スカログラム

スカログラムとは、信号の変化を時間と周波数の2つの軸で表現する図である。これは、時刻歴波形に対してウェーブレット変換することで算出される。スカログラムを用いることで、信号の周波数成分が時間的にどのように変化しているかを直感的に把握することが可能となる。式(2)、(3)に、連続ウェーブレット変換⁶⁾を示す。

$$W_{\psi}[x](s, \tau) = \int_{-\infty}^{\infty} x(t) \psi_{s, \tau}^*(t) dt \quad (2)$$

$$\psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t - \tau}{s}\right) \quad (3)$$

ここで、 $W_{\psi}[x](s, \tau)$: ウェーブレット変換、 $x(t)$: 時刻歴波形、 s : 伸長パラメータ(周期または周波数に対応)、 τ : 位置パラメータ(時間シフト量)、 $\psi_{s, \tau}(t)$: ウェーブレット、*: 複素共役である。式(2)より、ウェーブレット変換 $W_{\psi}[x](s, \tau)$ は、時刻歴波形 $x(t)$ とウェーブレット $\psi_{s, \tau}$ の複素




図-2 周波数スペクトルの例(測定箇所:健全)



写真-4 C橋の床版上面

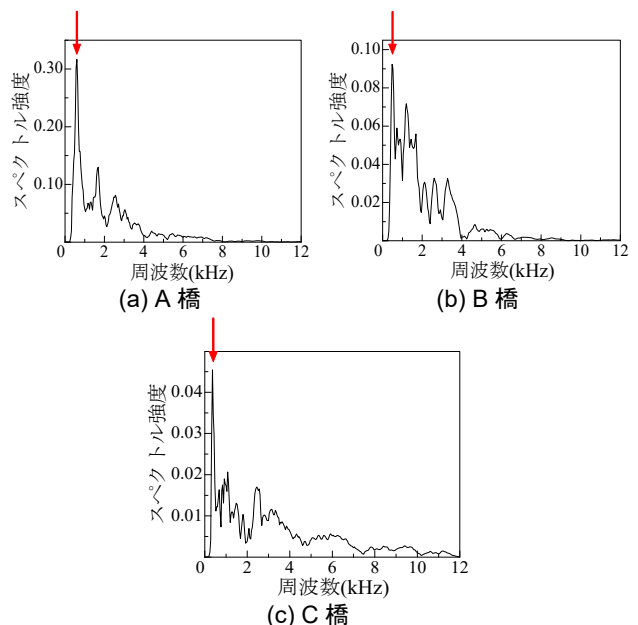


図-3 周波数スペクトルの例(測定箇所:欠陥)

共役 $\psi_{s, \tau}^*(t)$ との畳み込み積分で表される。畳み込み定理を用いると、式(2)はフーリエ変換の積として次のように表せる。

$$W_{\psi}[x](s, \tau) = \mathcal{F}^{-1}\{X(f) \cdot \Psi_{s, \tau}^*(f)\} \quad (4)$$

ここで、 $X(f):x(t)$ のフーリエ変換、 $\Psi_{s,\tau}^*(f)$: ウェーブレットの複素共役フーリエ変換である。

一方、式(3)に示すウェーブレットのフーリエ変換は、

$$\Psi_{s,\tau}(f) = \sqrt{s}\Psi(sf)e^{-j2\pi f\tau} \quad (5)$$

である。 $t' = (t-\tau)/s$ および $dt = sdt'$ と置換すると、

$$\Psi_{s,\tau}(f) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} \psi(t') e^{-j2\pi f(st'+\tau)} dt' \quad (6)$$

を得る。さらに、式(6)の変数 t' を t に戻すと、

$$\Psi_{s,\tau}(f) = \sqrt{s}\Psi(sf)e^{-j2\pi f\tau} \quad (7)$$

となる。式(7)は、スケーリングを行った周波数 sf におけるウェーブレットのフーリエ変換を表している。したがって、ウェーブレットの複素共役フーリエ変換は、

$$\Psi_{s,\tau}^*(f) = \sqrt{s}\psi(sf)e^{j2\pi f\tau} \quad (8)$$

である。以上より、式(4)は、

$$W_{\psi}[x](s,\tau) = \sqrt{s} \int_{-\infty}^{\infty} X(f)\psi(sf)e^{j2\pi f\tau} df \quad (9)$$

と変形できる。

以上のことから、周波数軸上での2つの関数の畳み込み積分の逆フーリエ変換は、時間軸上の元の2つの関数の積(相関)に等しくなっていることがわかる。なお、本研究では、次式で表される複素ウェーブレット(マザーウェーブレット)である Morlet ウェーブレット⁶⁾を用いた。

$$\psi(t) = e^{-\frac{t^2}{2\sigma^2}} e^{j\omega t} \quad (10)$$

ここで、 σ : 包絡線の幅 (=1), ω : 複素サインの角周波数 (=6) である。また、畳み込み定理に基づき連続ウェーブレット変換の離散近似を行うため、スケール s を次のように離散化した⁷⁾。

$$s_j = s_0 \cdot 2^{j\Delta_j} \quad (j=0,1,\dots,J) \quad (11)$$

$$J = \frac{1}{\Delta_j} \log_2 \left(\frac{N\Delta t}{s_0} \right) \quad (12)$$

ここで、 s_0 : 解像可能な最小のスケール (= $2\Delta t$), Δt : サンプル時間間隔, Δ_j : 周波数の解像度(分割数=0.375), J : 解像可能な最大のスケール, N : サンプル点数である。なお、式(11)および式(12)に、測定条件である $\Delta t = 1$ および $N = 25000$ を代入すると、 $s_0 = 0.01$ kHz, $J = 79.58$ kHz となる。スカログラムは、0~12.5 kHz の範囲内で周波数 s ごとに、以下の手順で算出した。まず、時刻歴波形のフーリエ変換 $X(f)$ とウェーブレットのフーリエ変換 $\Psi(sf)$ の積を計算し、その結果を逆フーリエ変換して $W_{\psi}[x](s,\tau)$ を求めた。その後、得られた結果に \sqrt{s} を乗じて、スカログラムを算出した。




図-4 スカログラムの例(測定箇所:健全)


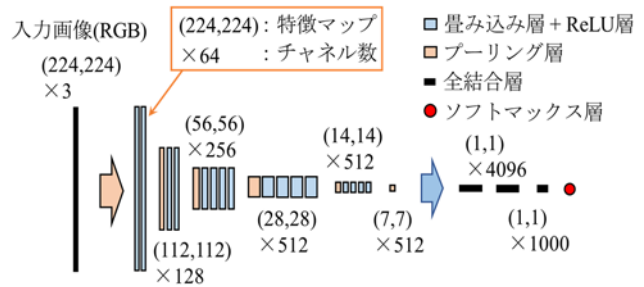


図-5 スカログラムの例(測定箇所:欠陥)

図-4 に、図-2 に示す健全箇所を得られた時刻歴波形にウェーブレット変換を適用して求めたスカログラムを示す。スカログラムは、特定の周波数がどの時間においてどの程度強い相関があるかを、相対的に色分けして表現している。具体的には、相関が最も高い領域を濃い赤色、相関が最も低い領域を濃い青色、その間を段階的に色分けしている。図-4 (a)~(c)に示すスカログラムでは、極めて短い時間に幅広い周波数帯域(1 kHz~10 kHz)で相関の高い領域が確認された。また、図-4 (d)に示すC橋の床版上面に凹凸がある測定点におけるスカログラムにおいても、図-4 (a)~(c)に示すスカログラムとは相関分布に違いが見られたものの、全体的には同様の傾向が観察された。このように、極短い時間に幅広い周波数成分が含まれる現象は、一般的に「インパルス応答」と呼ばれ、本研究でもこの現象が確認できたと考えられる。

図-5 に、図-3 に示す欠陥箇所を得られた時刻歴波形にウェーブレット変換を適用して求めたスカログラムを示す。図より、欠陥によるたわみ共振に起因する周波数付近で相関の高い領域が時間軸方向に延びていることが確認できる。

以上のことから、著者らの供試体を対象とした既往研究^{1),2)}での結果と同様、供用中の道路橋 RC 床版においても、打撃音のスカログラムを用いることより、床版内部の欠陥を把握できることが明らかになった。



5. 事前学習済みの CNN による欠陥分類モデルの構築

本研究では、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」とラベル付けし、ファインチューニングにより欠陥分類モデルを構築する。使用する事前学習済みモデルとしては、オックスフォード大学の Visual Geometry Group により開発された VGG³⁾および Microsoft Research の Kaiming He が考案した ResNet⁴⁾を採用した。VGG には、代表的なものとして16層および19層構造のモデルがある。本研究では、VGG16 (16層) および VGG19 (19層) に加え、過学習を抑制するためパッチ正規化を追加した VGG16_bn³⁾ および VGG19_bn³⁾も活用した。一方、ResNet⁴⁾については、50層 (ResNet50⁴⁾) を適用した。図-6 に、事前学習済みモデルの一例として、VGG19 の構造を示す。このモデルは、224×224×3 (RGB) のサイズの画像を入力し、畳み込み層 + ReLU 層、プーリング層および全結合層を通過後、ソフトマックス関数を使用して分類を行う。また、ファインチューニングを使用しているため、全てのレイヤー関数でパラメータが更新される。なお、本研究では、3橋で得られた合計1487枚のスカログラムをデータセットとして使用した。このうち80% (健全: 599枚, 欠陥: 590枚) を「学習データ」として欠陥分類モデルの構築に使用し、残りの20% (健全: 150枚, 欠陥: 148枚) を「評価データ」として欠陥分類モデルの性能評価(6章)に用いた。なお、「学習データ」による欠陥分類モデルの構築では、A橋、B橋およびC橋で得られたスカログラムを区別せずに使用している。さらに、k-分割交差検証も併用した。図-7 に k-分割交差検証の概要を示す。k-分割交差検証では、「学習データ」をランダムに k 個に分割し、(k-1)/k を訓練データ (図-7 中の T)、1/k を検証データ (図-7 の V) とする方法である。本研究では k=5 と設定し、図-7 に示すように訓練データと検証データを順次入れ替えることにより、5つのモデルを作成した。それぞれのモデルで精度を算出し、5つのモデルの平均精度を最終精度として採用した。

ここで対象とするスカログラム (学習データ) は、648×432 ピクセルの画像であるため、事前学習済みモデル




表-2 k-分割交差検証により求めた事前学習済みモデルの精度 (ファインチューニング)

モデル	VGG16	VGG16_bn	VGG19	VGG19_bn	ResNet50
1回目	0.987	0.992	0.987	0.992	0.987
2回目	0.979	0.979	0.979	0.975	0.979
3回目	0.992	0.987	0.987	1.000	0.941
4回目	0.987	0.996	1.000	0.996	0.992
5回目	0.992	0.996	0.992	0.992	0.996
平均値	0.987	0.990	0.989	0.991	0.979

に入力する前に 224×224 ピクセルにリサイズし、その画像の画素値が 0~1 の範囲となるようにスケーリングした。その後、画素値の平均および標準偏差がそれぞれ 0.5 となるように正規化した。なお、この計算は全ての画像に対して行っている。

表-2 に、k-分割交差検証により求めた各事前学習済みモデルの精度を示す。すべてのモデルで精度 97%以上を達成したが、最も高精度であった VGG19_bn を最終モデルとして採用した。

以上より、事前学習済みの CNN による欠陥分類モデルの構築には、「学習データ」をすべて使用⁸⁾し、事前学習済みモデルには VGG19_bn を選択、学習にはファインチューニングを利用した。この構築したモデルを用いて、次章では「評価データ」を使用して、事前学習済みの CNN による欠陥分類モデルの性能評価を行う。

6. 事前学習済みの CNN による欠陥分類モデルの評価

ここでは、「評価データ」を対象として、前章で構築⁸⁾した事前学習済みの CNN による欠陥分類モデルの妥当性を検証した。

表-3 混同行列 (A 橋) (データ数 : 43 枚)

		分類結果		正答率
		健全	欠陥	
正解ラベル	健全	22	0	100.0 %
	欠陥	1	20	95.2 %

表-4 混同行列 (B 橋) (データ数 : 75 枚)

		分類結果		正答率
		健全	欠陥	
正解ラベル	健全	36	0	100.0 %
	欠陥	1	38	97.4 %

表-5 混同行列 (C 橋) (データ数 : 180 枚)

		分類結果		正答率
		健全	欠陥	
正解ラベル	健全	92	0	100.0 %
	欠陥	0	88	100.0 %

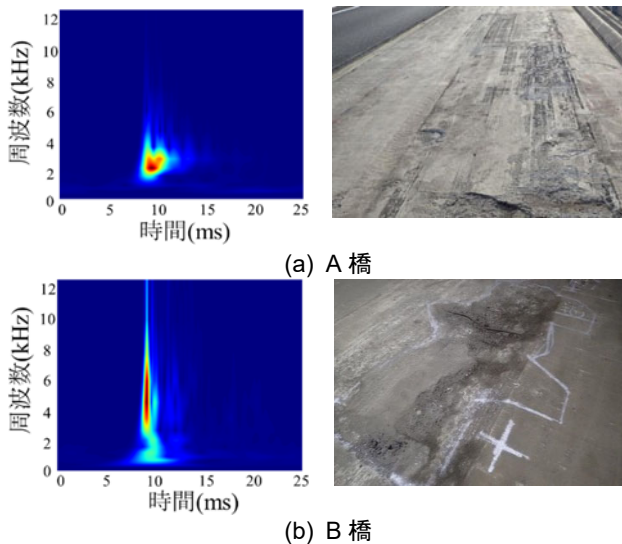


図-8 誤判定したスカログラムとその測定箇所の床版上面

表-3~表-5 に、A~C 橋の分類結果を混同行列として示す。表より、いずれの橋梁においても、健全の正答率は 100.0%と極めて高く、特に、C 橋では欠陥の正答率も 100.0%になった。一方、A 橋および B 橋の欠陥の正答率は、それぞれ 95.2 %および 97.4 %とやや低下した。ここで、図-8 に、A 橋および B 橋において欠陥を健全と誤判定したスカログラムと、その測定箇所の床版上面の状況を併せて示す。誤判定したスカログラムは、図-5 に示す欠陥の特徴とは異なり、むしろ図-4 に示す健全の特徴（インパルス応答）に近い画像であることが確認できる。実際の道路橋 RC 床版では、写真-4 や図-8 に示すように、打撃を行うコンクリート表面が平滑でない場合が少なくない。さらに、今回対象とした 3 橋には、コンクリート表面から土砂化している箇所が目視で確認できる箇所があり、また圧縮側鉄筋が露出している箇所もあった。これら要因が重なり、欠陥の特徴的なスカログラムが得られず、健全と誤判定したものと考えられる。

本研究の結果として、誤判定はわずか 2 箇所のみであった。このことから、構築した欠陥分類モデルは、供用中の道路橋 RC 床版の舗装打換工事の際の点検ツールとして、極めて有用であることが明らかとなった。

7. まとめ

本研究で得られた結論を以下に示す。

- (1) 道路橋 RC 床版で測定した打撃音のスカログラムに対して、「欠陥」および「健全」のラベル付けを行い、事前学習済みモデルとして VGG19_bn を使用し、ファインチューニングによってモデルの学習を行うことで、RC 床版の内部欠陥の有無を精度良く評価できることがわかった。
- (2) 上記の結果から、本研究で構築した欠陥分類モデルは、供用中の道路橋 RC 床版における舗装打換工事の際の点検ツールとして、極めて有用であることが明らかとなった。

参考文献

- 1) 森本 亮, 内田慎哉, 青沼拓朗, 長谷啓司: 打音法で得られたスペクトログラムによる道路橋 RC 床版内部の欠陥検出方法に関する基礎的検討, コンクリート工学年次論文集, Vol.45, No.1, pp.1468-1473, 2023
- 2) 森本 亮, 内田慎哉, 長谷啓司, 青沼拓朗: 畳み込みニューラルネットワークを用いた打撃音のスカログラムの自動分類による道路橋 RC 床版の非破壊探査手法, コンクリート工学年次論文集, Vol.46, No.1, pp.1903-1908, 2024
- 3) Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *International Conference on Learning Representations (ICLR)*, 2015
- 4) He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *Computer Vision and Pattern Recognition (CVPR)*, 2016
- 5) Sansalone, M. and Streert, W. B.: *Impact Echo*, Bullbrier Press, Ithaca, N. Y., pp.159-166, 1997
- 6) 例えば, P. S. Addison, 新誠一, 中野和司監訳: 図説ウェーブレット変換ハンドブック, 朝倉書店, 2005
- 7) Torrence, C. and Compo, G. P.: A Practical Guide to Wavelet Analysis, *Bulletin of the American Meteorological Society*, Vol.79, No.1, pp.61-78, 1998
- 8) Raschka, S.: Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning, University of Wisconsin-Madison, 2018