

論文 ランダムフォレストによる機械学習を用いた外壁タイル張り仕上げの剥離診断

田中 大貴*1・伊藤 洋介*2・河辺 伸二*3・山本 純平*4

要旨: 外壁タイル張り仕上げの打音検査は、機械による診断方法が求められる。本研究では、打音の特微量から結果の解釈が比較的容易なランダムフォレストを用いた機械学習により剥離診断を行う。特微量重要度の高い特微量と、これらの特微量の選定が診断精度に与える影響を示した。この結果、浮きの有無でラベル付けする場合、特微量重要度が高い最大ウェーブレット係数、1次および2次残響時間の組み合わせで交差検証による F1 Score は 1.0 である。下地モルタル厚さでラベル付けする場合、特微量重要度が高い最大ピーク周波数、1次および2次ピーク周波数の組み合わせで少ない特微量で高い F1 Score が得られる。

キーワード: タイル、打音検査、機械学習、決定木、ランダムフォレスト、ウェーブレット解析

1. はじめに

外壁タイル張り仕上げの打音検査は、検査者の個人差によって診断結果にばらつきが生じる可能性があるため、機械による診断方法が求められる。著者ら²⁾³⁾は、打音の周波数解析からピーク周波数、最大ウェーブレット係数、残響時間により剥離診断を行ったが、閾値の設定により診断結果が変化する可能性がある。また、剥離診断に機械学習を用いることで、人が閾値を判断することなく診断できると考え、打音のスペクトログラム画像の複素 PARCOR 係数を用いたパターン認識によってタイルの剥離を診断した⁴⁾。この方法は二値画像をアルゴリズムに入力して容易に診断できるが、算出される複素 PARCOR 係数と音の物理量との関係性の解釈が難しい。

そこで、既往の研究²⁾³⁾で得られた打音のピーク周波数等を特微量とし、ランダムフォレスト⁵⁾による機械学習を用いた診断を行う。ランダムフォレストは、数ある学習モデルのうち結果の解釈が比較的容易で、ブラックボックスでない決定木を利用したモデルであるため、診断結果の説明や診断方法の適用可能な範囲の検討ができると考える。また、複素 PARCOR 係数によるパターン認識と併せて利用することで、診断精度の向上や診断結果の説明が可能になると考える。

本研究ではランダムフォレストを用いて、ラベルの付け方に対して、1) 機械学習による分類結果に影響する度合いである重要度（以下、特微量重要度とする）の高い特微量と、2) 特微量の選定が診断精度に与える影響を明らかにする。これにより、ランダムフォレストによる機械学習を用いた外壁タイル張り仕上げの剥離診断に有効な特微量を検討できる。また、本研究の成果はウェブ

レット解析により周波数ごとに分解したデータを用いるため、プロペラの風切り音を周波数で分離する必要がある壁面接触型ドローンを用いた診断²⁾⁶⁾にも応用できる。

2. 疑似浮き試験体

本研究では、国土交通省建築基準整備促進事業 T1 の標準浮き試験体に準拠して作製した疑似浮き試験体²⁾を使用した。図-1 に疑似浮き試験体の断面を示す。ポリエチレン発泡シートをコンクリートと下地モルタルの界面に設置することで疑似的な浮きを作製した。

3. 実験方法

3.1 打音の計測

タイル用テストハンマーを用いて疑似浮き試験体のタイル壁面を打撃し、その打音をマイクとスマートフォンで計測する。図-2 に疑似浮き試験体の浮きと打撃の位置を、表-1 に打撃により計測した打音の種類とサンプル数を示す。図中の離隔距離は 4.1 節にて説明する。タイル用テストハンマーを用いて先端の球が壁面から垂直に 100 mm 離れた位置から、壁面に垂直方向にタイルの中心を打撃する。打撃回数は 1 か所あたり 50 回とす




図-1 疑似浮き試験体の断面

*1 名古屋工業大学大学院 工学専攻 修士(工学) (学生会員)

*2 名古屋工業大学大学院 准教授 博士(工学) (正会員)

*3 名古屋工業大学大学院 教授 工博 (フェロー会員)

*4 名古屋工業大学大学院 工学専攻 (学生会員)




図-2 疑似浮き試験体の打撃位置

る。本研究では、叩く強さのばらつきを機械学習の範囲に含める。マイクは小型のコンデンサマイクで指向性を有するものを用いて、壁面の打撃位置から 300 mm 離れた位置に固定する。計測データはビット深度 16 bit, サンプリング周波数 44.1 kHz とする。

3.2 ウェーブレット解析と特徴量の抽出

計測した打音のウェーブレット解析は、基底関数に Gabor Wavelet を用いた連続ウェーブレット解析とし、時間間隔 44.1 kHz, 周波数間隔 20 Hz, 周波数範囲 20 Hz~10000 Hz とする。

ウェーブレット解析により得られるスカログラムから、打音の特徴量を抽出²⁾する。図-3 にスカログラムの例を示す。最大となるウェーブレット係数を最大ウェーブレット係数とし、図-4 に示すその時刻におけるウェーブレット係数と周波数の関係を得る。このとき、卓越してウェーブレット係数が大きくなる周波数（以下、ピーク周波数とする）を、周波数が低い順に 1 次および 2 次ピーク周波数とする。

表-2 に抽出する特徴量の種類を示す。既往の研究¹⁾で剥離診断に用いた 1 次ピーク周波数, 最大ウェーブレット係数, 残響時間を用いる。加えて、関連する特徴量として最大ウェーブレット係数を示すピーク周波数（以下, 最大ピーク周波数とする）, 2 次ピーク周波数, 後述する 1 次および 2 次ピークの上昇率および下降率についても特徴量とする。

図-5 に 1 次および 2 次ピーク周波数におけるウェーブレット係数の時刻歴の例を示す。ピークの時刻 t_{max} , ピークのウェーブレット係数の 50%（以下, 半値とする）の時刻 t_1, t_2 とする。 $t_1 \sim t_{max}$ および $t_{max} \sim t_2$ の単位時間あたりのウェーブレット係数の変化量を上昇率および下降率とする。残響時間は時刻 t_1, t_2 の差 $t_2 - t_1$ とする。半値の近傍におけるウェーブレット係数はほとんど線形に時間変化し、特徴量を抽出しやすいため半値を利用する。

3.3 ランダムフォレストを用いた機械学習

ランダムフォレストは、ツリー構造（樹形図）の決定木とバギングを組み合わせたものである。学習データから複数の決定木を構築し、それぞれの結果の多数決を最終的な結果とする。本研究では、計測したデータを学習

表-1 打音の種類とサンプル数

No.	浮き面積	下地モルタル厚さ D	サンプル数
1	健全 (浮き無し)	5 mm	50×4 枚 = 200
2		10 mm	50×4 枚 = 200
3		15 mm	50×4 枚 = 200
4	200 mm 角浮き	5 mm	50×8 枚 = 400
5		10 mm	50×8 枚 = 400
6		15 mm	50×8 枚 = 400
7	300 mm 角浮き	5 mm	50×18 枚 = 900
8		10 mm	50×18 枚 = 900
9		15 mm	50×18 枚 = 900




図-3 スカログラムの例
(200 mm 角浮き部, 下地モルタル厚さ 15 mm)




図-4 最大ウェーブレット係数を示す時刻におけるウェーブレット係数と周波数の関係の例

表-2 抽出した特徴量の種類

No.	特徴量名	単位
1	最大ウェーブレット係数	-
2	最大ピーク周波数	Hz
3	1次ピーク周波数	Hz
4	2次ピーク周波数	Hz
5	1次残響時間	s
6	2次残響時間	s
7	1次下降率	×10%/s
8	2次下降率	×10%/s
9	1次上昇率	×10%/s
10	2次上昇率	×10%/s




図-5 1 次および 2 次ピーク周波数におけるウェーブレット係数の時刻歴の例

データとし、そのうち 7 割を訓練データ, 3 割を検証データとしてランダムに抽出する。過学習を防ぐため決定木の深さは最大 3 層までとし、決定木の本数は本学習の結果に影響がない程度に十分な 100 本とする。

本研究では学習モデルによる診断精度を評価する指

標として F1 Score⁷⁾ を用いる。また、学習モデルの妥当性や過学習となっていないことを確認するため、K-分割交差検証による F1 Score (K 回の平均値) を用いる。本研究では、検証精度を高めるため K = 10 とする。

一般的に打音検査では、補修範囲の把握のために浮きの範囲と、補修工法の検討のために浮き深さを明らかにする。これを考慮して設定するラベルは、浮きの有無(健全/浮き)と、浮き深さに影響する下地モルタルの厚さ(5 mm/10 mm/15 mm)とする。

4. 実験結果と考察

4.1 特徴量の抽出

打撃ごとのばらつきや打撃位置ごとの変化を検討するために、健全部と浮き部の特徴量の分布を箱ひげ図で示す。表-3 に打撃位置の種類を示す。浮き部では図-2 に示す打撃位置から浮きと健全の境界までの最小距離(以下、離隔距離とする)ごとに分類して示す。図-6 から図-11 に各特徴量と打撃位置の関係を示す。

図-6 より最大ウェーブレット係数は、健全部は 10000 以下でばらつきはほとんどなく、浮きの値との差が大きい。一方、浮き部では打撃ごとのばらつきが大きい。また、離隔距離が大きくなると、平均値および中央値は大きくなる傾向がある。これは、離隔距離が大きくなると、健全部に支持された浮き部のタイル、モルタルが一体となった板(以下、浮き板²⁾とする)の面外方向のたわみが大きくなるため、振動が大きくなり、最大ウェーブレット係数が大きくなると考える。下地モルタル厚さによる明確な傾向はみられない。

図-7 より最大ピーク周波数は、健全部は打撃ごとのばらつきが小さく 4000~5000 Hz であるが、打撃位置に

よっては浮き部と分布が重なる場合がある。浮き部において四分位範囲が大きい打撃位置は、全体として正規分布しておらず、第1四分位と第3四分位の近傍に集中する2つの群がある。これは、異なる次数のピーク周波数が最大ピーク周波数として抽出されるため、打撃ごとのばらつきではない。また、離隔距離が大きい方がばらつきは小さく、平均値および中央値は低くなる傾向がある。これは、打撃位置が浮き部の中心に近づくことで低次の固有振動が発生しやすくなり、低次のピーク周波数が最大ピーク周波数として抽出されるためと考える。

図-8 より1次および2次ピーク周波数は、既往の研究^{2),3),6)}と同様に、浮き部では下地モルタル厚さが大きくなると高くなる傾向がある。最大ピーク周波数と同様に、四分位範囲が大きい打撃位置は、第1四分位と第3四分位の近傍に分布が集中する2つの群がある。200 mm 角

表-3 打撃位置の種類

No.	浮き面積	下地モルタル厚さ D [mm]	離隔距離 [mm]	
1	200mm 角 浮き	5	25	
2			50	
3			25	
4		50		
5		15	25	
6		50		
7	300mm 角 浮き	5	25	
8			50	
9			75	
10			125	
11			25	
12			50	
13		75		
14		125		
15		15	25	
16			50	
17			75	
18			125	
19	健全		5,10,15	-

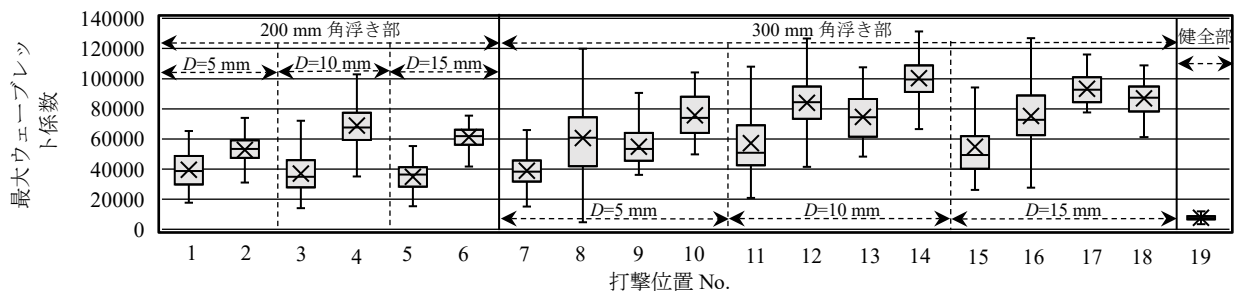


図-6 打撃位置ごとの最大ウェーブレット係数の分布




図-7 打撃位置ごとの最大ピーク周波数の分布

浮き部では離隔距離によって1次および2次ピーク周波数はほとんど変化しないが、300 mm 角浮き部では離隔距離が大きくなると1次および2次ピーク周波数は低くなる傾向がある。これは200 mm 角浮き部より300 mm 角浮き部の方が、浮き板の厚さに対する面積の比が大きく、面外方向に変形しやすいため、高次の振動モードが発生しやすいと考える。また、離隔距離が大きい浮き板の中心付近は、1次モードの腹であり、2次以降の高次のモードの節になりやすい。一方、離隔距離が小さい浮き板の端部付近は、2次以降の高次のモードの腹になりやすい。したがって、300 mm 角浮き部の離隔距離 25, 50 mm の場合は、2次以降の高次の固有振動が支配的にな

り、1次モードによるピーク周波数が抽出されなかったと考える。

図-9より1次および2次残響時間は、健全部で0.002 s以下で、ばらつきはほとんどなく、浮き部の分布と離れている。一方、300 mm 角浮き部で離隔距離ごとのばらつきが大きい。これは、1次および2次ピーク周波数が2つの群に分布が集中する場合に、異なるピーク周波数における残響時間が抽出されるためと考える。

図-10と図-11より1次および2次下降率と上昇率は、打撃によるばらつきが比較的大きく、健全部と浮き部で値に差があまりない。また、下地モルタル厚さによる明確な傾向はみられない。




図-8 打撃位置ごとの1次および2次ピーク周波数の分布




図-9 打撃位置ごとの1次および2次残響時間の分布




図-10 打撃位置ごとの1次および2次下降率の分布

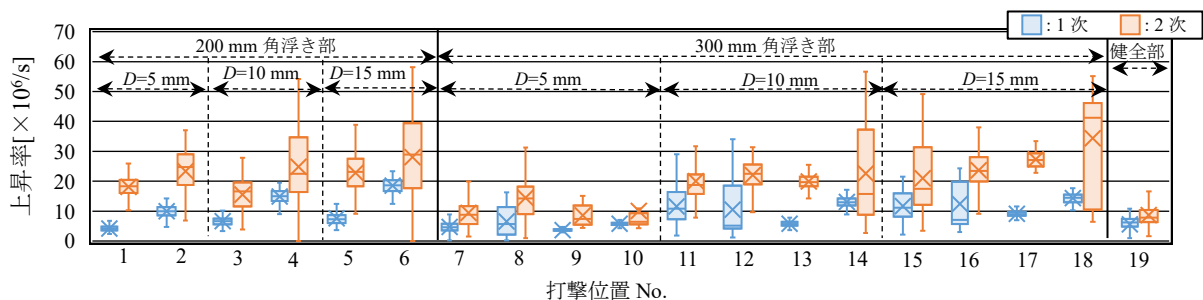


図-11 打撃位置ごとの1次および2次上昇率の分布

4.2 浮きの有無によりラベル付けした学習

浮きの有無（健全/ 浮き）によりラベル付けした上で学習を行う。図-12 に構築されたツリー構造の例を示す。Gini はノード内のサンプルについてクラスの混在の割合を表すジニ不純度を示す。既往の研究³⁾と同様に、残響時間が短い場合は健全側に、最大ウェーブレット係数が小さい場合は健全側に分類されることがわかる。

表-4 に混同行列⁷⁾を示す。全てのサンプルが健全または浮きに正しく分類され、学習モデルの評価指標である正解率、適合率、再現率、F1 Score は 1.0 である。

図-13 に特徴量ごとの特徴量重要度を示す。特徴量重要度は、ジニ不純度 Gini を減少させた量により算出される。最大ウェーブレット係数は特徴量重要度が 0.26 と最も高く、1 次残響時間は特徴量重要度が 0.25 と次に高い。一方、最大ピーク周波数や 1 次および 2 次下降率、1 次および 2 次上昇率は特徴量重要度が 0.02 以下と低い。4.1 節より、最大ウェーブレット係数や 1 次残響時間は、健全部のばらつきが小さく、健全部と浮き部で値の分布が離れているため、特徴量重要度が高くなると考える。

ここで、特徴量重要度が低い特徴量を学習から除外した場合でも診断精度が維持されることや、特徴量重要度の高い特徴量のみを利用することで診断精度が向上すると考え、特徴量重要度が低い特徴量から順に学習から除外する。図-14 に F1 Score と除外した特徴量の数の関係を示す。全ての特徴量を用いる場合は、学習モデルの F1 Score は 1.0 で交差検証による F1 Score は 0.9998 である。特徴量を 1~6 個または 8 個を除外した場合は、F1 Score に変化はない。7 個を除外した最大ウェーブレット係数、1 次残響時間、2 次残響時間の組み合わせを利用する場合は、交差検証による F1 Score は 1.0 である。また、9 個を除外した最大ウェーブレット係数のみ利用する場合は、学習モデルの F1 Score が 0.9993、交差検証による F1 Score が 0.9991 とわずかに低下する。したがって、診断精度を高めるためには、特徴量重要度が最も高い最大ウェーブレット係数だけでなく、加えて次に特徴量重要度が高い 1 次残響時間と 2 次残響時間を組み合わせて利用することが有効であると考えられる。

4.3 下地モルタル厚さによりラベル付けした学習

浮き部の打音のみを対象に、下地モルタル厚さ（5 mm/ 10 mm/ 15 mm）によってラベル付けした上で学習を行う。表-5 に混同行列⁷⁾を示す。下地モルタル厚さ 5 mm のサンプルは 18 個、下地モルタル厚さ 10 mm と 15 mm のサンプルは 34 個が不正解である。F1 Score は 0.9273 となり、浮きの有無をラベルとした学習と比べて低い。これは、健全部と浮き部を比較する場合に特徴量の値の分布が離れている特徴量がみられるのに対し、浮き部の下地モルタル厚さで比較する場合に離隔距離や浮き面積によ

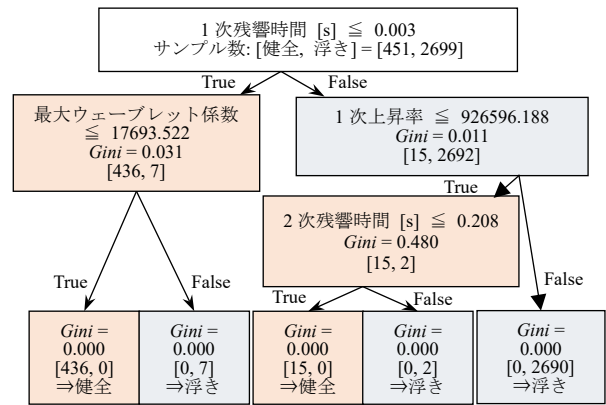


図-12 構築されたツリー構造の例
(ラベルの付け方: 浮きの有無)

表-4 混同行列 (ラベルの付け方: 浮きの有無)

		予測のクラス	
		健全	浮き
実際のクラス	健全	172	0
	浮き	0	1178

※下線は正解のサンプル数

正解率: 1.0, 適合率: 1.0, 再現率: 1.0, F1 Score: 1.0




図-13 特徴量重要度 (ラベルの付け方: 浮きの有無)




図-14 F1 Score と除外した特徴量の数の関係
(ラベルの付け方: 浮きの有無)

表-5 混同行列 (ラベルの付け方: 下地モルタル厚さ)

		予測のクラス		
		5mm	10mm	15mm
実際のクラス	5mm	363	15	3
	10mm	34	352	0
	15mm	27	7	369

※下線は正解のサンプル数

正解率: 0.9265, 適合率: 0.9310, 再現率: 0.9265, F1 Score: 0.9273

る値の変化で分布が重なるためと考える。

図-15 に特徴量重要度を示す。1 次ピーク周波数は特




図-15 特徴量重要度
(ラベルの付け方: 下地モルタルの厚さ)

特徴量重要度が 0.41 と最も高く、2 番目に高いのは最大ピーク周波数での 0.22 である。また、2 次ピーク周波数は 3 番目に特徴量重要度が高く、上位 3 個がピーク周波数の高さに関する特徴量である。4.1 節より、1 次ピーク周波数は、浮きで打撃によるばらつきが小さく、下地モルタル厚さとの相関もあるため特徴量重要度が高くなると考える。また、最大ピーク周波数と 1 次および 2 次ピーク周波数は離隔距離によって異なるモードの固有振動によるピークが抽出されるため、1 個の特徴量で分類できない場合でも、組み合わせで学習することで特徴量重要度が高くなり分類ができると考える。1 次および 2 次下降率と上昇率は、下地モルタル厚さによる明確な傾向がみられなかったため、特徴量が低いと考える。

4.2 節と同様に、特徴量重要度が低い特徴量から順に学習から除外する。図-16 に F1 Score と除外した特徴量の数の関係を示す。除外した特徴量の数が 8 個のときに学習モデルの F1 Score は 0.951 と最大になるが、交差検証による F1 Score は 0.9175 と低いため、過学習の可能性がある。除外した特徴量の数が 5~7 個のときは、学習モデルと交差検証ともに F1 Score が比較的高い約 0.945 である。よって、少ない特徴量で学習モデルと交差検証ともに高い F1 Score が得られるのは、7 個を除外した 1 次ピーク周波数、最大ピーク周波数、2 次ピーク周波数の組み合わせである。また、9 個を除外した 1 次ピーク周波数のみ利用する場合は、学習モデルの F1 Score が 0.7969、交差検証による F1 Score が 0.7904 と大きく低下する。

5. まとめ

本研究の範囲内で以下のことがわかった。

- 1) 浮きの有無でラベル付けする場合、最大ウェーブレット係数は特徴量重要度が 0.26 と最も高く、1 次残響時間は特徴量重要度が 0.25 と次に高い。最大ウェーブレット係数、1 次残響時間、2 次残響時間の組み合わせでは、交差検証による F1 Score は 1.0 である。
- 2) 下地モルタル厚さでラベル付けする場合、特徴量重要度が高い上位 3 個は、1 次ピーク周波数、最大ピ




図-16 F1 Score と除外した特徴量の数の関係
(ラベルの付け方: 下地モルタル厚さ)

ーク周波数、2 次ピーク周波数であり、ピーク周波数の高さに関する特徴量である。1 次ピーク周波数、最大ピーク周波数、2 次ピーク周波数の組み合わせで、少ない特徴量で高い F1 Score が得られる。

謝辞

本研究は、JST 次世代研究者挑戦的研究プログラム JPMJSP2112 の支援を受けたものです。名古屋工業大学大学院山田学教授、有限会社エムアンドティー渡辺正雄氏に協力を得ました。ここに謝意を表します。

参考文献

- 1) 添田智美, 伊藤秀太郎, 藤沼智洋, 三上貴正: 模擬剥離試験体を用いたタイル剥離診断装置の有効性の検証, 日本建築学会構造系論文集, Vol.85, No.767, pp.1-9, 2020.1
- 2) 田中大貴, 伊藤洋介, 河辺伸二: 壁面接触型ドローンによる外壁タイル張り仕上げの打音検査のための FEM 解析を用いた剥離診断の検討, 日本建築学会構造系論文集, Vol.89, No.817, pp.247-255, 2024.3
- 3) 田中大貴, 伊藤洋介, 河辺伸二, 永井晴己: ウェーブレット解析による残響時間とウェーブレット係数を用いた外壁タイル張り仕上げの剥離診断方法の検討, コンクリート工学年次論文集, Vol.46, No.1, pp.1819-1824, 2024.7
- 4) 田中大貴, 河辺伸二, 伊藤洋介: スペクトログラムのパターン認識によるタイル張り外壁の打音検査, 日本建築学会東海支部研究報告集, Vol.56, pp.29-32, 2018.2
- 5) Leo Breiman: Random Forests, Machine Learning, Vol.45, pp.5-32, 2001.10
- 6) 永井晴己, 田中大貴, 伊藤洋介, 河辺伸二: 壁面接触型ドローンに搭載したへらによる打音のウェーブレット解析を用いた外壁タイル張り仕上げの剥離診断, コンクリート工学年次論文集, Vol.46, No.1, pp.1849-1854, 2024.7
- 7) C. J. Van Rijsbergen: Information Retrieval, 2nd ed., Butterworths, 1979.3