

台風による強風被害発生後の補修需要推定に資する屋根葺き材種別の自動判定 Automatic Determination of Roofing Material Type for Estimating Repair Demand after Strong Typhoon

○高橋 徹・友清衣利子・竹内 崇・西嶋一欽

○Toru TAKAHASHI, Eriko TOMOKIYO, Takashi TAKEUCHI, Kazuyoshi NISHIJIMA

For the purpose of accurate and quick estimation on the repair demand of damaged houses after a strong wind disaster such as a typhoon, thereby, to reduce the mismatch between the supply and demand in the repair work, the authors have developed an automated approach for detecting roof damages together with their roof materials based on aerial photos with deep learning techniques. This study presents part of the approach concerning roof material classification. In the approach, the Mask R-CNN model was adopted. The precision is in the range between 80 and 90% depending on the roof material types. It is also found that classification tends more successful in cases the model trained with lower resolution data is applied to data with higher resolution.

1. はじめに

ひとたび台風による強風災害が発生すると、被害の把握に時間を要し、罹災証明の発行や家屋の修理に多大な時間と労力が割かれている。筆者らは、その解決策として、深層学習を用いて被害の自動判定を行い、さらに屋根葺き材の種別をも自動判定して補修需要を迅速かつ的確に把握し、地域外にも情報発信することで、補修に要する資材や人員を地域外から適時に投入する可能性を模索している。本報告では、その中でキーテクノロジーとなる、屋根葺き材の自動判別の可能性について、いくつかの検討を行った結果を述べる。

2. 深層学習に用いた画像データ

2019年台風15号に関する被害調査研究の際に入手した航空写真は1画素10cm×10cmの画像であったが、この解像度では屋根葺き材の種別を判定するには粗すぎるのがわかった。そこで、筆者らは2020年11月から12月にかけてドローンにより被災地の一部で写真撮影を行い、おおよそ数cm角の解像度を持つ写真を収集した。本報告では、深層学習の教師データの数を増やすために、これらに2022年10月に千葉県F市で収集した同程度の解像度を有するドローン空撮画像を加えて検討を行った。これらの画像の諸元を表1に示す。3つを比較すると、画像2のK町のものが、撮影高度、機材が違うせい、撮影時刻の違いによるものか、若干色味が赤く、解像度が粗い。そ

こで、それぞれの撮影範囲に存在する撮影屋根数も考慮し、T市とF市を合わせたものとK町を別々に学習させて比較検討を行うことにした。

表1 深層学習に用いた画像の諸元

	画像1	画像2	画像3
撮影場所	T市	K町	F市
撮影日時	2020/12/1 12/2	2020/11/30 12/1	2022/10/1
撮影機材	Mavic mini2	Phantom3	Mavic mini2
解像度	2.2 cm	3.6 cm	2.4 cm
撮影屋根数	528	1093	541

3. 深層学習の概要

昨年度の報告¹⁾では、画像を2値化して屋根の傾斜を計測したり凹凸を強調したりするなどの前処理を行ったが、今回は作業の単純化を鑑みて、ArcGISのMask R-CNNモデルを用い、オルソ化した画像をそのまま用い、屋根葺き材の種別を深層学習させた。訓練時のパラメータを表2,3に示す。

表2 訓練パラメータ (K町)

画像サイズ		訓練パラメータ	
Tile size	1200×1200	Max epoch	5
Stride size	600×600	Batch size	2
Rotation angle	45°	Backbone model	RESNET50

表3 訓練パラメータ (T市, F市)

画像サイズ		訓練パラメータ	
Tile size	1200×1200	Max epoch	10
Stride size	600×600	Batch size	1
Rotation angle	90°	Backbone model	RESNET50

訓練時の検証は(1)式で示される適合率を用い、領域の10%を検証用に確保して行った。記号の説明を表4に、訓練結果を図1と表5に示す。

$$\text{適合率} = \frac{TP}{TP + FP} \quad (1)$$

表4 記号の説明 (瓦の場合)

TP	自動判定が瓦で目視でも瓦だったもの
FP	自動判定が瓦で目視では瓦ではなかったもの
FN	自動判定が瓦ではなく目視では瓦だったもの
TN	自動判定が瓦以外で目視でも瓦以外だったもの




図1 K町における訓練時の損失カーブ

表5 深層学習させた項目と訓練時の適合率

K町訓練			T市 + F市訓練		
屋根葺き材	棟数	適合率	屋根葺き材	棟数	適合率
瓦	436	0.894	瓦	402	0.933
スレート	203	0.862	スレート	210	0.893
A.S.	11	0.642	A.S.	9	0.738
金属	307	0.837	金属	248	0.894
陸屋根	33	0.846	陸屋根	26	0.808
その他	103	0.764	その他	145	0.834

A.S.: アスファルトシングル

図1より、概ね安定して損失が減少しており、表5より、教師データが少ないアスファルトシングルを除けば80~90%の適合率が確保できることを確認できた。そこで、訓練に用いなかった画像で検証を行った結果を表6、表7に示す。ここで、表内で用いた変数の定義は(2)~(4)式による。

$$\text{再現率} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{正確率} = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

$$F \text{ 値} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (4)$$

表6 K町で訓練した結果をT市で検証した結果

T市 (K町訓練)	自動検出								再現率
	瓦	スレート	A.S.	金属	陸屋根	その他	対象外	合計	
目視	93	24	1	45	0	0	21	184	0.505
スレート	10	74	2	1	0	0	31	118	0.627
A.S.*	0	2	5	0	0	0	3	10	0.500
金属	2	6	0	124	2	7	9	150	0.827
陸屋根	0	0	0	0	2	1	7	10	0.200
その他	1	12	0	3	3	21	7	47	0.447
対象外	0	6	0	3	0	0	0	9	
合計	106	124	8	176	7	29	78	528	
適合率	0.877	0.597	0.625	0.705	0.286	0.724			
正確率	0.803	0.822	0.985	0.852	0.975	0.936			平均正確率 0.896
F値	0.641	0.547	0.556	0.761	0.235	0.553			平均F値 0.549

A.S.: アスファルトシングル

なお、K町においては、検証範囲ではアスファルトシングル屋根と陸屋根が自動検出されなかったため、これらを結果から除外している。表中に斜線で示した。正確率とF値については屋根葺き材ごとの値とそれらの相加平均も示している。

表7 T市, F市で訓練した結果をK町で検証した結果

K町 (TF訓練)	自動検出								再現率
	瓦	スレート	A.S.	金属	陸屋根	その他	対象外	合計	
目視	11	7	0	20	0	12	85	145	0.076
スレート	0	15	0	3	0	7	31	55	0.273
A.S.	0	1	0	0	0	0	0	1	0.000
金属	2	3	0	17	0	3	28	53	0.321
陸屋根	0	1	0	0	0	0	4	5	0.000
その他	0	0	0	0	0	5	16	21	0.238
対象外	0	0	0	0	0	0	0	0	0
合計	13	27	0	49	0	27	164	280	
適合率	0.846	0.556	0.347	0.757	0.982	0.185			
正確率	0.514	0.814	0.906	0.757	0.982	0.864			平均正確率 0.738
F値	0.139	0.133	0.333	0.333	0.208				平均F値 0.204

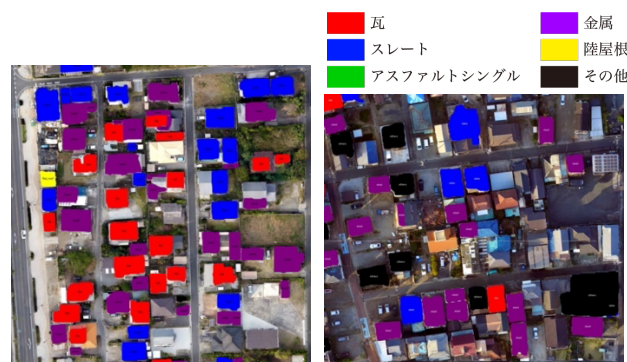


図2 K町で訓練したものをT市で検証した結果

図3 T, F市で訓練したものをK町で検証した結果

4. 考察とまとめ

表6、表7より、T市での検証結果は平均正確率で90%近い値を示しているが、K町での検証結果はそれよりも低い値となり、特にF値は低い結果となった。これらの対比からは、訓練データよりも検証データの側の解像度が高ければ、ある程度の再現性が期待できるのではないかと考えられるが、対角線上以外にも数字が存在するということはまだまだ誤判定が多いことを表している。特に、教師データとしてのサンプルが少なかった陸屋根については、訓練不足で再現率が低くなっている。

T市F市とK町の色味が違ったので、グレースケールでも検討してみたが、自動検出できなかった。グレー系の屋根を誤判定しているケースが多いことと併せ、今後の課題と考えている。

謝辞

本研究は京都大学防災研究所共同研究(2021G-07)の成果による。本報告の解析作業には、千葉大学学生、横山洋斗君の助力を得た。ここに記して謝意を表する。

参考文献

- 1) 友清衣利子ほか: ドローン空撮写真から生成される3次元点群データを用いた住宅屋根の自動分類, R3年度京都大学防災研究所研究発表講演会, D215, 2022.