

航空レーザ測量データと航空写真を用いた地震被害建物の検出

Detection of Earthquake-Damaged Buildings Using Airborne LiDAR Data and Aerial Images

24WM1321 江頭 彩奈
Ayana Egashira

指導教員 丸山 喜久, 劉 ウェン

SYNOPSIS

In the 2016 Kumamoto earthquake, a JMA seismic intensity of 7 was recorded twice, resulting in significant casualties and building damage. To support safe and rapid assessment of building damage, this study develops a deep learning-based model for detecting completely collapsed buildings. The proposed approach uses a digital surface model (DSM) obtained from airborne LiDAR surveying together with post-earthquake aerial images. The model was trained using two different datasets. The results showed that the model achieved higher performance when using four-band images that combine the difference between pre- and post-earthquake DSM with post-earthquake aerial imagery. Based on this dataset, hyperparameter optimization using Optuna was further applied to improve the detection performance. The final model achieved an accuracy of approximately 81% and a recall of approximately 63%.

1. 研究背景と目的

2016年4月に発生した熊本地震では、二度の震度7を観測した。この地震では、全壊建物が約8300棟、住家被害の総数が約16万棟に達するなど大きな被害が生じたり、このような規模の大きな地震が発生した際には、被災者の生活再建のために迅速かつ確かな罹災証明書の交付が必要である。罹災証明書は、災害により被災した住家等についてその被害の程度を証明する書類であり、被災者生活再建支援金や災害義援金の支給等、被災者支援措置に必要な書類として活用されている。しかし、罹災証明書の交付には調査員が直接現地に赴いて被害状況の調査を行う必要があるため、交付の遅れが問題となっている。実際に熊本地震では、地震が発生してから1ヶ月の時点で、申請件数に対する交付件数は3割未満となっている²⁾。

このような状況から、広域性・遠隔性のある方法であるリモートセンシング技術の活用が有効であると考えられる。航空レーザ測量³⁾は、航空機に搭載したレーザスキャナーから地上にレーザ光を照射し、地上から戻ってくるレーザ光との時間差より得られる距離と航空機の位置情報により地上の標高や形状を調べる測量方法である。本研究では、航空レーザ測量によって得られた数値表層モデル (DSM) と測量時に同時に取得された航空写真の2つのデータを用いた。

本研究では、リモートセンシング技術で取得された広域にわたるデータの機械学習によって、地震被害を受けた建物を自動的に検出することを目的とする。これによって、罹災証明書の迅速な交付や調査員の人員削減・安全性の確保に貢献することを目指す。籠嶋ら⁴⁾は、地震前後のDSM差分データを用いて、地震被害建物の検出を行っている。これによると、罹災証明書発行のための被害認定調査で全壊と判定された建物を抽出対象としたモデルでは、正解率が68.7%、適合率が60.2%、再現率が22.3%、F値が0.325となっている。本研究では、地震前後のDSM差分データに加えて、地震後の航空写真を組み合わせることによって、精度指標の向上を試みる。

2. 深層学習用データセットの作成

(1) 本研究で使用したデータ

本研究では、熊本地震において被害の大きかった熊本県益城町を対象とした。航空レーザ測量データには、アジア航測(株)の航空レーザ測量によって取得され、Moya et al.⁵⁾が整備したものをを用いた。航空レーザ測量は2016年4月16日に発生した地震の前後に行われている(表1)。航空レーザ測量で得られるDSMは建物や樹木を含む高さデータのことであり、本研究では地震前後の差分データを用いる。また、地震後の航空レーザ測量の際に同時に取得された航空写真も併せて使用する。データの空間解像度については表1の通りである。

表1 航空レーザ測量の実施日時と画像の解像度

	DSM	航空写真
地震前	2016年4月15日 15:00~17:00	
地震発生日時	2016年4月16日1時25分	
地震後	2016年4月23日10:00~12:00	
空間解像度	50 cm	25 cm

また、正解データには罹災証明書交付に伴う被害認定調査⁶⁾の結果を用いた。これは表2のように全壊から無被害の5段階に分類されている。データセットの画像には、大規模半壊から無被害の建物を全壊以外(クラス0)、全壊の建物を全壊(クラス1)とラベル付けしており、本研究では全壊を検出することを目指す。

表2 罹災証明による建物の被災度(5段階)

被害尺度	全壊	大規模半壊	半壊	一部損壊	無被害
損害割合	50%以上	40%以上 50%未満	20%以上 40%未満	20%未満	0%

(2) 画像の切り出し

画像を切り出す際には、正解データから抽出した経緯度のポイントデータを使用した。このポイントデータを中心として、32m 四方の範囲を切り出した。空間解像度を踏まえると、DSM 差分は 64×64 画素、航空写真は 128×128 画素となる。また、切り出した画像内に異なる判定結果の建物が混在している場合には、中心にある建物の判定を正解データとした。切り出した DSM 差分と航空写真の画像例を図 1 に示す。

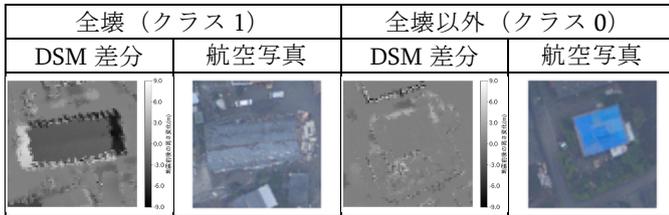


図 1 データセットの画像例

(3) 画像データセットの作成

切り出した画像を訓練画像、検証画像、テスト画像として $6:2:2$ の割合で分割した。そして、訓練画像に対してオリジナルと回転 ($\pm 90^\circ, 180^\circ$) と鏡像反転かつ回転 ($0^\circ, \pm 90^\circ, 180^\circ$) の 8 倍拡張を行った。

本研究では画像データセットを 2 通り作成した。データセット 1 は航空写真 (RGB の 3 バンド画像)、データセット 2 は DSM 差分と航空写真を組み合わせた 4 バンド画像とした。 64×64 画素で切り出した DSM 差分は、航空写真と組み合わせるために 128×128 画素にリサイズした。クラスごとの画像枚数の内訳を表 3 に、訓練画像、検証画像、テスト画像の枚数の内訳を表 4 に示す。

表 3 画像データセットとクラスごとの画像枚数の内訳

	バンド	クラス 0 (全壊以外)	クラス 1 (全壊)	合計
データセット 1	航空写真 (RGB)	6406	3319	9725
データセット 2	DSM 差分+航空写真 (RGB)	6406	3319	9725

表 4 訓練画像、検証画像、テスト画像の内訳

訓練画像		検証画像		テスト画像	
クラス 0 (全壊以外)	クラス 1 (全壊)	クラス 0 (全壊以外)	クラス 1 (全壊)	クラス 0 (全壊以外)	クラス 1 (全壊)
3843	1991	1281	664	1282	664
5834 (46672)		1945		1946	

() 内は 8 倍拡張後の枚数

3. 地震による全壊建物の検出モデルの構築

(1) ネットワーク構造と学習結果

本研究では、画像認識の分野で広く使われる、畳み込みニューラルネットワーク (CNN) を使用してモデルを構築した。画像分類タスクで広く使用されている 2 種類の CNN モデル (ResNet18⁷⁾ と MobileNetV3-Small⁸⁾ と本研究独自に仮定した CNN の 3 種類を用いる。本研究独自の CNN の学習条件を表 5 に、仮定したモデルのネットワーク構造を図 2 に示す。既往研究の 2 種類の CNN は後述する。

表 5 本研究の学習条件

フレームワーク	Pytorch2.7.1
活性化関数	ReLU
損失関数	クロスエントロピー誤差
最適化アルゴリズム	Adam
学習率	$1e-5$
Weight Decay	$1e-4$
ドロップアウト	0.5
バッチサイズ	16
エポック数	100

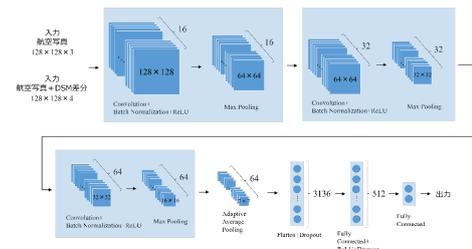


図 2 本研究で仮定したネットワークの構造

作成した訓練画像、検証画像を用いて、学習と検証を行った。画像はバンドごとに、訓練画像の画素値から計算した平均値、標準偏差を用いて標準化を行った。データセット 1 (航空写真)、データセット 2 (DSM 差分+航空写真) のそれぞれを用いた際の検出モデルの損失関数値と正解率の推移を図 3、図 4 に示す。

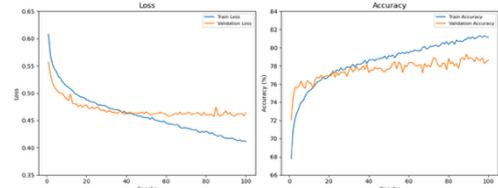


図 3 データセット 1 (航空写真) を用いた検出モデルの損失関数値、正解率の推移

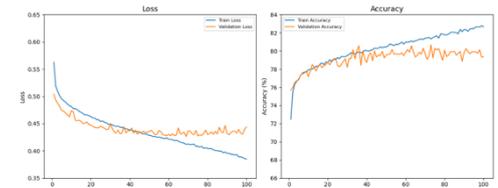


図 4 データセット 2 (DSM+航空写真) を用いた検出モデルの損失関数値、正解率の推移

損失関数値が最も小さくなったのは、データセット 1 を用いた検出モデルではエポック 84 のときで損失関数値が 0.457、正解率が 78.3% となった。データセット 2 を用いた検出モデルではエポック 69 のときで損失関数値が 0.426、正解率が 80.3% となった。それぞれの損失関数値が最小のときの検出モデルを用いて、テスト画像でテストを行った。そのときの精度指標を表 6 に示す。

表 6 テスト画像に対する精度指標

データセット	損失関数値	正解率 (%)	適合率 (%)	再現率 (%)	F 値
1	0.455	78.3	74.6	55.0	0.633
2	0.440	80.4	79.3	57.5	0.667

テスト画像に対する精度指標をみると、正解率、適合率が80%前後であるのに対し、再現率が55%程度とあまり高くない。またそれぞれの検出モデルの精度指標を比較すると、航空写真のみのデータセット1を用いたモデルよりも、航空写真にDSM差分を追加したデータセット2を用いたモデルの方が、精度指標が高いことがわかる。このことを踏まえ、既存の2種類のCNNを用いた検討にはデータセット2を用いることとする。

(2) 既存CNNの転移学習

転移学習とは、すでに公開されている大規模データセット上での訓練によって得られた知識を他のタスクに転用することである。本研究では、画像分類タスクで広く使用されている2種類のCNNモデル(ResNet18⁷⁾とMobileNetV3-Small⁸⁾の転移学習(ファインチューニング)を行い、2章で準備した画像データセットに適用することとした。これらのCNNはImageNet-1K⁹⁾で事前学習されている。ImageNet-1Kには約143万枚の自然画像が含まれており、1000種類のカテゴリに分類される。

ここでは、前節で精度が高かったデータセット2を用いてファインチューニングを行う。本研究では、既存CNNの事前学習の重みの利用方法を3通り設定した(表7)。また、ファインチューニングにおいても画像の標準化を行った。

表7 各条件・モデルの組み合わせごとの名称

	重みを更新する層		
	方法1	方法2	方法3
	入力層、全結合層(事前学習の重みあり)	全層(事前学習の重みあり)	全層(事前学習の重みなし)
ResNet18	モデル①	モデル②	モデル③
MobileNetV3-Small	モデル④	モデル⑤	モデル⑥

モデル①から⑥の学習・検証を行った結果、検証の損失関数値が最も小さくなったときのエポック数とその値、正解率を表8に示す。方法2,3を用いたモデル②,モデル③,モデル⑤,モデル⑥は損失関数値が最小となったのは学習開始直後であり、うまく学習が進んでいないことがわかる。そのため、これらのモデルの結果は今後の検討から除外する。

表8 損失関数値が最も小さくなったときのエポック数, 損失関数値, 正解率

	エポック数	損失関数値	正解率(%)
モデル①	87	0.488	77.8
モデル②	1	0.464	78.7
モデル③	1	0.487	76.6
モデル④	64	0.517	76.3
モデル⑤	5	0.456	78.7
モデル⑥	6	0.525	75.3

検証の損失関数値が最も小さくなったとき(表8)の検出モデルを用いてテストを行った。テスト結果の精度指標を表9に示す。前項でデータセット2を用いた検出モデルも含めて精度指標を比較すると、すべての精度指標において最も高くなったのは、前項で述べた本研究独自のCNNによる検出モデルであった。このように、ResNet18や

MobileNetV3-Smallの転移学習の際に、方法2,方法3で著しい過学習の影響がみられたことも踏まえると、ResNet18やMobileNetV3-Smallの表現力に対して本研究の画像データセットの画像数が少なく、一般的な特徴を学習するのではなく、訓練画像を正解ラベルと紐づけて丸暗記してしまった可能性があげられる¹⁰⁾。そのため、本研究では膨大な画像数で事前学習した既存のCNNではなく、独自のCNNを用いて今後の検討を進めることとした。

表9 テスト画像に対する精度指標

	損失関数値	正解率(%)	適合率(%)	再現率(%)	F値
モデル①	0.493	77.4	72.8	53.9	0.619
モデル④	0.514	76.0	71.6	49.1	0.583
図2のCNN	0.440	80.4	79.3	57.5	0.667

(3) Optunaを用いたパラメータの最適化

Optuna¹¹⁾は、ハイパーパラメータ自動最適化フレームワークの一つである。図2に示した本研究独自のCNNに対して、Optunaを用いてハイパーパラメータや仮定したネットワーク構造の最適化を行う。探索は50エポックまでとし、100試行を行った。また、探索時の条件は損失関数値が最小となることとした。

探索した結果、63回目の試行のときに、損失関数値が最も小さくなった。そのときのパラメータの値を表10に、モデルのネットワーク構造を図5に示す。さらに、このときのハイパーパラメータ、CNNのネットワーク構造で、再び100エポックまでの学習と検証を行った。そのときの損失関数値と正解率の推移を図6に示す。

表10 最適化後のパラメータの値

試行回数	63
損失関数値	0.396
学習率	1.33e-4
Weight Decay	5.48e-3
ドロップアウト	0.462
バッチサイズ	128
モデルの畳み込み層の数	3
モデルの最初のフィルタ数	64
全結合層のニューロン数	256

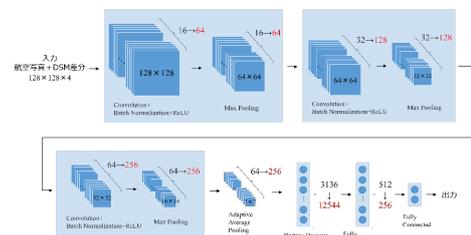


図5 最適化後の全壊建物検出モデルのネットワーク構造

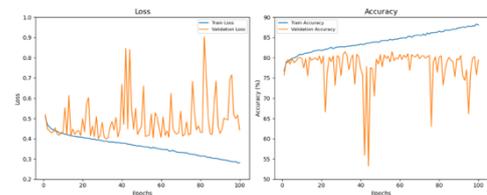


図6 最適モデルの損失関数値, 正解率の推移

図 6 のグラフをみると、エポック 30 あたりから過学習の傾向があることがわかる。また検証の結果、損失関数値が最も小さくなったのは、エポック 32 のときに損失関数値が 0.399、正解率が 81.5%だった。このときの検出モデルを用いて、テスト画像に対する精度評価を行った。精度指標を表 11 に示す。精度指標をみると、適合率以外の精度指標が改善し、特に再現率が大きく改善した。さらに、航空写真と DSM 差分の 4 バンド画像を用いたことによって、DSM 差分データのみを用いた文献⁴⁾よりも精度は大きく向上した。

表 11 最適モデルでテストを行ったときの精度指標

	損失関数値	正解率 (%)	適合率 (%)	再現率 (%)	F 値
最適化後	0.412	81.0	77.3	62.7	0.692
最適化前	0.440	80.4	79.3	57.5	0.667

(4) テスト画像への検出モデルの適用結果

最適化後の検出モデルのテスト画像への適用結果を分析する。図 7 に全壊建物の検出の成功例と失敗例を示す。

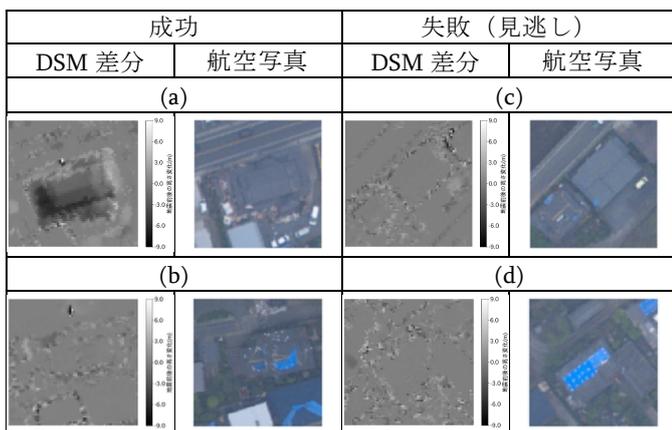


図 7 全壊の建物の検出成功例と失敗例

図 7 の(a)の成功例の DSM 差分をみると、地震前後で顕著な高さの低下があることがわかる。また、(b)の画像は高さの低下はないが、航空写真の屋根の部分に乱れがあるということがわかる。(c)、(d)の失敗例をみると、どちらも高さの低下はない。また航空写真の屋根は、(d)の画像にはブルーシートがあるが、どちらも屋根の乱れがないということがわかる。このように、建物高さの低下があれば全壊を検出でき、ブルーシートがあっても高さの低下や屋根の乱れがなければ全壊を検出できなかった。このことから、建物高さの低下が少ないが被害認定調査で全壊の判定であった建物を見逃している可能性があり、正解率、適合率に比べて再現率が低かった原因につながると考えられる。

4. まとめ

本研究では、2016 年熊本地震において被害の大きかった熊本県益城町を対象として、航空レーザ測量で取得された DSM 差分データと航空写真を組み合わせた 4 バンド画像の深層学習により、地震で被害を受けた建物の自動検出を行った。本研究では独自に仮定した CNN と既存の 2 種類の CNN を用いて、テスト画像に対する精度評価を行った。その結果、本研究の画像データセットの枚数が少ないため、

既存の CNN の表現力に適さず、一般的な特徴が学習されなかった。訓練画像を正解ラベルと紐づけて丸暗記し、著しい過学習を示す傾向が見られた。そのため、本研究独自の CNN を用いて検討を進め、Optuna を用いてハイパーパラメータとネットワーク構造の最適化に関する検討を行った。その結果、適合率を除き精度指標が改善し、特に再現率が大きく改善した。これは DSM 差分データのみを用いた既往研究⁴⁾よりも良好な精度を示した。

今後は、Grad-CAM や SHAP 等を用いて、検出モデルが画像のどこの部分に注目して予測したかを可視化して、さらに詳しく検出結果を分析したい。また、能登半島地震等の他の地震にも検出モデルが適応できるかどうかを確かめ、汎用性の高いモデルの構築を目指したい。

参考文献

- 1) 内閣府：防災情報のページ，https://www.bousai.go.jp/kohou/kouhoubousai/h28/83/special_01.html (参照 2025-10-11)
- 2) 総務省：大規模災害時における罹災証明書の交付等に関する実態調査 —平成 28 年熊本地震を中心として—，https://www.soumu.go.jp/main_content/000528758.pdf (参照 2025-10-12)
- 3) 国土交通省国土地理院：航空レーザ測量，https://www.gsi.go.jp/kankyochiri/Laser_index.html (参照 2025-12-19)
- 4) 籠嶋彩音，劉ウエン，丸山喜久，堀江啓：航空レーザ測量データの深層学習に基づく地震被害建物の検出，土木学会論文集，Vol. 79, No. 13, 22-13020, 2023.
- 5) Moya, L., Yamazaki, F., Liu, W. and Yamada, M.: Detection of collapsed buildings from lidar data due to the 2016 Kumamoto earthquake in Japan, Natural Hazards and Earth System Sciences, Vol. 18, pp.65-78, 2018.
- 6) 内閣府：災害に係る住家の被害認定基準運用指針，https://www.bousai.go.jp/taisaku/pdf/r303shishin_all.pdf (参照 2025-12-19)
- 7) He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.
- 8) Howard, A., Sandler, M., Chu, G., Chen, L., Chen, B., Tan, M., Wang, W., Zhu, Y. Pang, R., Vasudevan, V., Le, Q. V. and Adam, H.: Searching for MobileNetV3, Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), pp. 1314-1324, 2019.
- 9) Deng, J., Dong, W., Socher, R., Li, L., Li, K. and Fei-Fei, L.: ImageNet: A Large-Scale Hierarchical Image Database, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.248-255, 2009.
- 10) Zhang, C., Bengio, S., Hardt, M., Recht, B. and Vinyals, O.: Understanding Deep Learning Requires Rethinking Generalization, Proceedings of the International Conference on Learning Representations (ICLR), 2017.
- 11) Akiba, T., Sano, S., Yanase, T., Ohta, T. and Koyama, M.: Optuna: A Next-generation Hyperparameter Optimization Framework, Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 2623-2631, 2019.