

# 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に向けた基礎検討

20T0214M 江頭 彩奈  
指導教員：丸山 喜久, 劉 ウェン

## 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。この地震により、大きな人的被害・物的被害が生じた。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罹災証明書の交付が必要である。しかし、罹災証明書は実際に調査員が現地へ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一か月の時点で、申請件数に対する交付件数は3割未満となっている。

このような状況から、目視による建物の被災度の判定ではなく、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。本研究では、4月16日に発生した地震の前後で取得した数値表層モデル(DSM)と4月16日の地震後に取得した航空写真に対し、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)を適用し、地震被害建物の自動検出を目指す。なお、DSMとは、建物や樹木の高さを含む地表面の高さのモデルである。

## 2. データセットの作成

### (1) 本研究で使用したデータ

本研究は、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、Moya et al.<sup>1)</sup>が整備したデータを用いた。航空レーザ測量は、4月16日の地震前(2016年4月15日15:00~17:00)と4月16日の地震後(2016年4月23日10:00~12:00)に行われた。本研究では、地震前後のDSMの差分を用いた。また、航空写真は地震後に行われた航空レーザ測量の際に同時に取得されたものを用いた。それぞれの画像の解像度は、DSMは50cm、航空写真は25cmである。

また、正解データには2種類のデータを用いた。一つ目は、罹災証明書交付に伴う被害認定調査の結果である。これは全壊・大規模半壊・半壊・一部損壊・無被害の5段階に分けられていて、本研究では全壊の建物を検出することを目標とする。二つ目は、Yamada et al.<sup>2)</sup>が16日の地震の前後の航空写真を比較し、建物被災度をまとめたデータである。Yamada et al.の被害判定基準は、岡田・高井<sup>3)</sup>によって提案された建物の被害尺度(表1)に従ってD0~D5の6段階に分けられている。本研究では、D5の建物を検出することを目標とする。

表1 建物の被害尺度

被害尺度	被害状況
D0	被害なし
D1	壁面に毛髪亀裂。まれに漆喰壁の小片落下。
D2	多くの壁に亀裂。漆喰壁の落下が目立つ。
D3	ほとんどの壁に深く大きな亀裂。構造要素の一部が破壊。
D4	壁面は重度の破壊。スラブの一部が破壊。構造要素はお互いの連結性を失う。
D5	完全またはほとんど完全に崩壊。

### (2) データセットの構成

これらのデータを用いて、各正解データから抽出した経緯度のポイントデータを中心に、DSMは64×64画素、航空写真は128×128画素で画像を切り出した。罹災証明書の判定結果を用いたものをデータセット1、Yamada et al.の判定結果を用いたものをデータセット2とする。データセットのクラスごとの枚数の内訳を表2に示す。

表2 データセットごとの画像枚数の内訳

	クラス0 (全壊以外 /D0~D4)	クラス1 (全壊/D5)	合計
データセット1	6,417	3,319	9,736
データセット2	2,742	454	3,196

## 3. 地震被害建物の検出モデルの構築

本研究の学習条件を表3に示す。また、CNNのネットワーク構造を図1に示す。本研究ではサイズの異なる画像を同時に入力するため、64×64画素で切り出したDSMの画像を128×128画素にリサイズした。

本研究では、過学習を抑制し汎化性能を向上させるために5分割の交差検証を行った。また、少ないデータを補うために、訓練データに対してオリジナルと回転(±90°, +180°)と鏡像反転かつ回転(0°, ±90°, +180°)の8倍拡張を行った。訓練画像とテスト画像の枚数は、表4の通りである。

表3 本研究の学習条件

フレームワーク	Pytorch2.1.0
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	0.001
Weight decay	0
バッチサイズ	64
エポック数	30

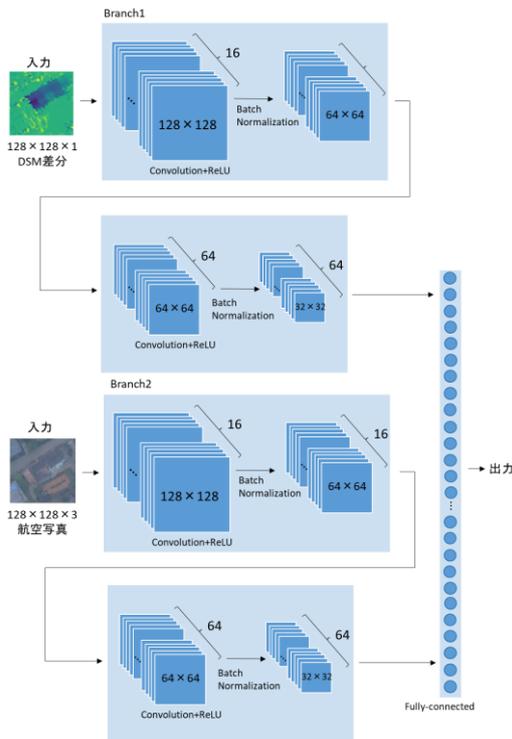


図1 本研究のCNNのネットワーク構造

表4 データセットごとの訓練画像とテスト画像の枚数

データセット	訓練画像	テスト画像
データセット1	62,312 (7,789)	1,947
データセット2	20,456 (2,557)	639

( ) 内は8倍拡張前の枚数

#### 4. 検出結果

それぞれのデータセットに適用した検出結果の精度指標を表5に示す。また、表5には籠嶋ら<sup>4)</sup>の結果に従って、学習率を変化させ正則化を行った結果も示した。

データセット1を用いたモデルとデータセット2を用いたモデルを比較すると、どの精度指標もデータセット2の方が高かった。この理由は、データセット2は地震前後の航空写真を比較して建物被災度を判断したデータを用いているため、入力したデータ(DSM差分と航空写真)と相性が良かったためと考えられる。

また、籠嶋ら<sup>4)</sup>は、地震前後のDSM差分を用いて全壊建物の自動検出に関する検討を行っている。これによると、学習率を0.0006、Weight decayを $10^{-4}$ としたモデルが最良であった。本研究のモデルのハイパーパラメータの値を上記の数値に設定し、精度を比較する。ハイパーパラメータ変更前と変更後のモデルをそれぞれ比較すると、データセット1を用いたモデルでは、ハイパーパラメータ変更前よりも変更後の方がどの精度指標も改善していた。しかし、データセット2を用いたモデルでは、損失関数値を除いてどの精度指標も改善が見られなかった。適切なハイパーパラメータの値を探索する必要がある。

表5 各データセットを適用したモデルの精度比較

データセット	損失関数値	正答率(%)	適合率(%)	再現率(%)	F値
データセット1	0.00981	67.7	59.8	14.7	0.214
データセット1(変更後)	0.00946	68.7	62.2	26.5	0.351
データセット2	0.00505	87.5	52.4	42.8	0.470
データセット2(変更後)	0.00502	87.2	51.6	41.9	0.461

#### 5. 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、航空レーザ測量データと航空写真を用いて深層学習により地震被害建物の検出モデルの構築を行った。学習を行った結果、データセット2を用いたモデルの方が、すべての精度指標においてデータセット1を用いたモデルよりも良かった。また、学習率、Weight decayの値を変化させて学習を行った結果、データセット1を用いたモデルは、すべての精度指標においてハイパーパラメータ変更後の方が改善した。データセット2を用いたモデルは、ハイパーパラメータ変更前と後を比べると、損失関数値を除いてどの精度指標も改善が見られなかった。

本研究のデータセット1を用いたモデルはどの精度指標もあまり良くない。また、データセット2を用いたモデルは、正答率は87%程度と高かったのに対し再現率が42%程度と低く、被害のある建物の見逃しが多いことが課題である。今後は、ネットワーク構造の見直しや入力画像の変更、ハイパーパラメータの値の変更等を行い、精度の改善を試みたい。

#### 参考文献

- 1) 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.
- 2) Yamada M., Ohmura, J. and Goto H.: Wooden building damage analysis in Mashiki Town for the 2016 Kumamoto Earthquakes on April 14 and 16, *Earthquake Spectra*, Vol. 33, No. 4, pp. 1555-1572, 2017.
- 3) 岡田成幸, 高井伸雄: 地震被害調査のための建物分類と破壊パターン, 日本建築学会構造系論文集, 第524号, pp.65-72, 1999.
- 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.