

航空レーザ測量データを用いた深層学習による地震被害建物の検出

DETECTION OF DAMAGED BUILDINGS DUE TO EARTHQUAKES BY DEEP LEARNING TECHNIQUE
USING AERIAL LASER SURVEY DATA

21WM1309 籠嶋 彩音
Ayane Kagoshima

指導教員 丸山 喜久，劉 ウェン

SYNOPSIS

In the April 2016 Kumamoto earthquake, a moment magnitude 6.2 earthquake occurred in Kumamoto region of Kumamoto Prefecture, Japan, and a moment magnitude 7.0 earthquake occurred about 16 hours later in the same region. In this study, we attempted to construct a damage discrimination model using aerial laser survey data as an efficient and safe method to assess the damage to buildings caused by the earthquake. Convolutional neural network (CNN), one of the algorithms of deep learning, was applied to the aerial laser survey data collected after the main shock, and the best model was investigated by changing the network configurations. As a result, a model with a correct response rate of over 90% was constructed, which was better than the authors' model developed by Random Forests.

1. はじめに

2016 年 4 月 14 日 21 時 26 分に熊本県熊本地方を震源とするモーメントマグニチュード(Mw)6.2 の地震が発生し，4 月 16 日 1 時 25 分には同地域を震源として Mw 7.0 の地震が発生した．対象地である熊本県益城町では二度の震度 7 を観測した¹⁾．本論文では，14 日に発生した地震を前震，16 日に発生した地震を本震と呼ぶ．

地震発生後の対応として，迅速に建物の被害状況を把握することは，災害対応や復興・復旧支援の点で重要である．しかし，被害が広範囲である場合や二次災害が考えられる場合，直接足を運んで被害状況を把握することは困難である．罹災証明書は，被災者の生活再建に重要な役割を果たすが，住家の被災度判定に膨大な時間を要することもある．熊本地震の際には本震から一か月後の時点で申請数の 3 割ほどしか交付されず，罹災証明書の発行の遅れが生じた．

このような状況から，目視での建物の被災度の判定ではなく遠隔性・広域性の高い方法として，リモートセンシング技術の活用が有効と考えられる．本研究では，航空レーザ測量により本震の前後で取得した数値表層モデル²⁾ (DSM) に対し，画像認識の分野で幅広く使われている深層学習のアルゴリズムの一つである畳み込みニューラルネットワーク (CNN)^{3),4)} を適用し，地震被害建物の自動検出を試みる．なお，DSM は，建物や樹木を含む三次元の地表モデルのことを指す．

著者ら⁵⁾は，この航空レーザ測量データの機械学習に基づき，被害認定調査で全壊判定を受けた建物を検出するモデルを構築した．機械学習の手法としてランダムフォレストを用い，正答率 70%程度の精度を示した (表-1)．本研究では，同データに CNN を適用することによって，既往研究よりも高い精度で，地震による建物被害を抽出することを目標とする．

2. データセットの作成

(1) 使用データ

航空レーザには，Moya et al.⁶⁾が整備したデータを用いた (図-1)．本研究では，本震前後での建物の高さの変化に注

目し，本震前後の DSM の差分データを用いる．

正解ラベルとして用いる建物の被害状況には，二つのデータを用いた．一つは，Yamada et al.⁷⁾が前震後と本震後の航空写真を比較し，建物被害をまとめたデータである．Yamada et al.⁷⁾の調査は，岡田⁸⁾の提案した建物の被害尺度に則り，D0・D1・D2・D3・D4 の建物，もしくは D5 の建物の二種類に分類している．本研究では，D5 に分類された建物の判別を目標とする．

もう一つは，罹災証明書の発行のための被害認定調査⁹⁾のデータを用いた．被害認定調査の被災度は，無被害・半壊・一部損壊・大規模半壊・全壊の 5 段階に分けられている．本研究では，全壊建物の判別を目標とする．

表-1 既往研究におけるモデルの精度指標⁵⁾

手法	正 答 率 (%)	適 合 率 (%)	再 現 率 (%)	F 値
ランダム フォレスト	70.0	53.4	76.1	0.634




図-1 本震前後の差分の航空レーザ測量データ




図-2 益城町内の正解データの分布

(2) データセットの構成

Yamada et al.⁷⁾のデータを使用したデータセットをデータセット 1、被害認定調査のデータを使用したデータセットをデータセット 2 とする。各データセットから建物の経緯度とクラスを抽出し、航空レーザ測量データに対しその建物を中心として 64×64 画素(32×32[m])の画像を切り出した。データセットのクラスごとの枚数の内訳を表-2 に示す。ただし、データセット 2 において同一の建物に対し異なる複数の判定結果があった場合は、被害の大きい判定結果をその建物の判定結果とする。本研究では、過学習を抑制し、汎化性能を向上させるため、データセットに対し 5 分割のクロスバリデーションを行う。

表-2 データセットごとの画像枚数

	クラス0 (D0～D4/ 全壊以外)	クラス1 (D5/全壊)	合計
データセット(文献7)	2742	454	3196
データセット(罹災証明)	6358	3267	9625

3. 判別モデルの構築

(1) CNN の概要

CNN は、出力層側のユニットが隣接する入力層側の特定のユニットに結合されている順伝播型ネットワークである。畳み込み層、プーリング層と呼ばれる層を中間層にもつことが特徴である。一般に、CNN は入力層、畳み込み層、プーリング層、全結合層、出力層から構成される。畳み込み層は、画像の特徴抽出を目的とし、画像にフィルタを畳み込んだような画像を出力する。プーリング層は、画像の微小な位置ずれの影響を削減し、データを圧縮した画像を出力する。全結合層は、判別と推定を行い、入力に対する判別結果を出力する。畳み込み層とプーリング層を繰り返すことで、特徴を維持したまま情報量を圧縮することが可能である。画像認識の分野において、CNN は最も使われているアルゴリズムであり、地震による建物被害の抽出に関する研究でも広く用いられている。

(2) 学習条件

学習条件を表-3 に示す。CNN のネットワーク構造は図-3 に示す。本研究では、各データセットに CNN を適用させた精度の比較とデータ拡張の効果を評価する。最も精度の高かったモデルに対し、学習率と weight decay のパラメータチューニングを行い精度の比較を行う。パラメータチュ

ーニングによる精度向上と過学習抑制を目指す。

(3) 精度評価指標

損失関数値と 2 クラス分類の精度指標¹⁰⁾を用いて結果を評価した。各精度指標は式(1)～(4)であり、式中の TP、FP、FN、TN は表-4 のように定義する。

$$\text{正答率(Accuracy)} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$\text{適合率(Precision)} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{再現率(Recall)} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F値(F-measure)} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

(4) 正則化

深層学習のネットワークは膨大な数の重みをもっている。学習時にこのパラメータの値に制約をつけて、過学習を抑える方法を正則化という。正則化の一般的な方法として、L1 正則化と L2 正則化がある。L1 正則化は次元圧縮に用いられ、L2 正則化は過学習を防ぐために用いられる。本研究では、Adam のパラメータである weight decay¹¹⁾の値を変化させ L2 正則化を行う。

表-3 本研究の学習条件

フレームワーク	Pytorch1.11.0
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

表-4 精度評価のための混同行列

		予測結果	
		クラス0	クラス1
実際の結果	クラス0	TN (True Negative)	FP (False Positive)
	クラス1	FN (False Positive)	TP (True Positive)




図-3 本研究の CNN のネットワーク構造

4. 判別結果

(1) データセットごとの精度比較

各データセットに適用したモデルの精度指標を表-5に示す。データセット1を用いたモデルとデータセット2を用いたモデルの精度を比較すると、データセット1は正答率、再現率、F値がデータセット2よりも高かった。正答率が高かった要因として、データセット1はクラス1のデータが全データの約15%しか含まれていない不均衡データであることが挙げられる。そのため、予測結果でクラス0が多いと正答率は高くなるが、適合率は低くなる。データセット2を用いたモデルでは、正答率が70%程度となりあまり良い精度は得られなかった。したがって、精度の高かったデータセット1を用いたモデルに対し、さらなる精度向上を目指す。

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	0.00554	86.3	51.0	38.8	0.439
データ セット2	0.0100	68.7	60.2	22.3	0.325

(2) データ拡張による精度比較

少ないデータを補い過学習を抑制するために、CNNではデータの拡張¹²⁾が行われる。今回は、オリジナルの画像データのみのモデルと、オリジナルと回転($\pm 90^\circ$, $+180^\circ$)と鏡像反転かつ回転(0° , $\pm 90^\circ$, $+180^\circ$)の8倍拡張を行ったモデルの2つのモデルの精度比較を行った。拡張による精度比較を表-6に示す。拡張なしモデルと8倍拡張モデルの精度の推移を比較する(図-4, 図-5)。正答率の推移では、拡張なしモデルの方が10エポック付近から徐々に過学習の傾向が見られるのに対し、8倍拡張モデルではバリデーションデータセットによっては緩やかな上昇になった。損失関数値の推移では、8倍拡張モデルの方が訓練時と学習時のグラフが乖離せず、過学習が抑制されていることがわかる。なお、Train1~5とTest1~5は交差検証により5分割したデータである。

表-6 データの拡張による判別精度の比較

データ セット1	損失 関数値	正答率 (%)	適合率 (%)	再現率 (%)	F値
拡張なし	0.00554	86.3	51.0	38.8	0.439
8倍 拡張	0.00430	89.7	60.2	48.8	0.535




図-4 拡張なしモデルの正答率(右図)と損失関数値(左図)の推移




図-5 8倍拡張モデルの正答率(右図)と損失関数値(左図)の推移

(3) 学習率の変化による精度の推移

本研究では、確率的勾配降下法に対し振動を抑えるための改良を行った最適化手法であるAdamを用いている。Adamのデフォルトの学習率は0.001に設定されているが、ここでは学習率の変化による精度の比較を行う。最適な学習率を見つけるため、 10^{-5} ~ 10^{-3} まで学習率を推移させ、損失関数値の変化を細かく調べた(図-6)ところ、学習率0.0006のモデルにおいて損失関数値が最小となった(表-7)。




図-6 学習率 10^{-5} ~ 10^{-3} のモデルの損失関数値の比較

表-7 学習率=0.0006のモデルの精度

学習率	損失 関数値	正答率 (%)	適合率 (%)	再現率 (%)	F値
0.0006	0.00403	90.2	60.7	50.6	0.551

(4) 正則化による過学習抑制

Adamのweight decayを変化させ、過学習抑制の効果を確認する。正則化が効いている場合、訓練時とテスト時の損失関数値が乖離していくのが抑えられ、かつテスト時の最小の損失関数値が小さくなる。weight decayを変えたモデルのテスト時の最小の損失関数値を図-7に示す。

全てのモデルで正則化なし(weight decay=0)のモデルよりも損失関数値が小さくなり、正則化の効果が見られた。精度指標については、正答率と適合率は同程度であり、再現率とF値はweight decay= 10^{-4} のモデルが最も良い精度を示した(表-8)。正則化なしのモデルの損失関数値とweight decay= 10^{-4} のモデルの損失関数値の推移の比較(図-8)では、weight decay= 10^{-4} のモデルの方がわずかに訓練時とテスト時の精度の差が小さいように見える。学習終了時の訓練時とテスト時の精度の差の平均からも、weight decay= 10^{-4} の方が正則化なしのときよりも差が小さいことがわかる(表-9)。したがって、精度向上と過学習抑制効果が見られたことから、weight decay= 10^{-4} を設定し正則化を行ったモデルを本研究での最良モデル(図-8)とした。

著者らの機械学習⁵⁾は、被害認定調査で全壊判定を受けた建物を正解ラベルに用いている。一方、本研究はYamada et al.⁷⁾のD5と判定された建物を抽出対象としている。表-1

の機械学習と本研究の精度を比較すると、正答率と適合率が向上したが、再現率は低くなった。正解ラベルが同一ではないので直接精度を比較することは難しいが、正答率が90%に達したのは CNN を適用した効果であると考えられる。一方、再現率が 54%程度と低く、改善が必要である。




図-7 weight decay の異なるモデルの損失関数値の比較




図-8 weight decay=10⁻⁴のモデルの精度の推移

表-8 weight decay =10⁻⁴のモデルの精度指標

weight decay	損失関数値	正 答 率 (%)	適 合 率 (%)	再 現 率 (%)	F値
0	0.00403	90.2	60.7	50.6	0.551
10 ⁻⁵	0.00395	90.2	61.4	48.4	0.537
10 ⁻⁴	0.00398	90.4	61.7	53.9	0.574
10 ⁻³	0.00398	90.2	60.6	51.6	0.555
10 ⁻²	0.00396	90.6	60.5	49.7	0.542




図-8 正則化なしのモデル(左図)と weight decay=10⁻⁴のモデル(右図)の損失関数値の推移

表-9 訓練時とテスト時の精度の差

weight decay	損失関数値	正答率(%)
0	0.0182	11.7
10 ⁻⁴	0.0142	12.8

5. まとめ

本研究では、2016 年熊本地震における益城町を対象として、航空レーザ測量データを用いた深層学習による地震被害建物の検出のモデルを構築することを試みた。DSM データを用いたモデルの有用性を図るため、二つのデータセットを用意し、各データセットを適用したモデルの精度を比較した。データ数の不足を補うためにデータの拡張を行い精度向上と過学習抑制効果を確認した。より高い精度を示した Yamada et al. ⁷⁾のデータを正解データとして用い、学

習率や正則化のパラメータチューニングによる精度の変化をまとめ、最良のモデルを決定した。

本研究の最良のモデルは、正答率 90%を超えており高い精度を示した。しかし、再現率が 55%程度であり、被害のある建物の見逃しが多いことが課題である。より汎用性の高いモデルを構築するために、今後データ数の不足を補うことや、ネットワーク構造の見直しが必要である。

本研究では、2 クラス分類として全壊判定の建物の検出を行っているが、今後は多クラス分類とし、被害認定調査の代替としての有効性を確認することが課題である。また、本震前後のデータを用いて検討を行ったが、本震後のみの DSM を用いたモデル、もしくは本震後の DSM と事前の数値標高データ (DEM) を用いたモデルの構築を行うことで、汎用性の高いモデルの構築を試みる。さらに、DSM の特性を活かした方法として、層破壊の検出を行うことが挙げられる。層破壊とは、建物のある一層が潰れる壊れ方のことであり、高さ変化を注視する DSM を用いたモデルとの相性が良いと考えられる。層破壊は人間の生存空間が失われるため、人的被害が大きくなると言われている。層破壊の建物を早期に特定することで、人命救助の一助になると期待される。

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
- 2) 国土交通省国土地理院：航空レーザ測量の仕組み，https://www.gsi.go.jp/kankyochiri/Laser_senmon.html
- 3) 斎藤康毅：ゼロから作る Deep Learning —Python で学ぶディープラーニングの理論と実装，オライリージャパン，2016。
- 4) 藤田一弥，高原歩：実装ディープラーニング，オーム社，2016。
- 5) 籠嶋彩音，劉ウェン，丸山喜久：航空レーザ測量データの機械学習による地震被害建物の検出，令和 3 年度土木学会全国大会第 76 回年次学術講演会，Paper No. CS10-48, 2p, 2021.
- 6) 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, 18, pp.65-78, 2018.
- 7) 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.
- 8) 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.
- 9) 内閣府：災害に係る住家の被害認定基準運用指針，http://www.bousai.go.jp/taisaku/pdf/r203shishin_2.pdf (参照 2020-01-04).
- 10) 平井 有三：はじめてのパターン認識，森北出版，2012.
- 11) PyTorch Contributors: weight decay，<https://pytorch.org/docs/stable/generated/torch.optim.Adam.html>
- 12) 小川雄太郎；Pytorch による発展ディープラーニング，マイナビ出版，2019.