

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

籠嶋 彩音¹・劉 ウェン²・丸山 喜久³

¹学生会員 千葉大学大学院融合理工学府 博士前期課程 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)
E-mail: a.kagoshima@chiba-u.jp

²正会員 千葉大学 大学院工学研究院 助教 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)
E-mail: wen.liu@chiba-u.jp

³正会員 千葉大学 大学院工学研究院 教授 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)
E-mail: ymaruyam@faculty.chiba-u.jp

2016年4月熊本地震では、熊本県熊本地方を震源とするMw 6.2の地震が発生し、その約16時間後に同地域を震源とするMw 7.0の地震が発生した。本研究では、地震による建物の被害状況を効率的にかつ安全に把握する方法として、航空レーザ測量データを深層学習することによって被災度判別モデルの構築を試みた。本震前後に収集した航空レーザ測量データに対し、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) を適用し、ネットワーク構成を変えながら最良のモデルの検討を行った。

Key Words : seismic damage to buildings, deep learning, convolutional neural network, 2016 Kumamoto Earthquake, Mashiki-town, LiDAR

1. 研究背景と目的

2016年4月14日21時26分に熊本県熊本地方を震源とする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。熊本県益城町では二度の震度7を観測した。熊本県内では建物やインフラ設備に大きな被害が生じた。建物の被害は全壊約8300棟、住家被害計が16万棟、加えて土砂崩れのために橋が崩落したりするなど、交通網にも大きな影響が生じた。本研究では、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定義する。

熊本地震のような規模の大きな地震が起きた際に被災者の生活再建のために欠かせないことは、罹災証明書の発行²⁾である。罹災証明書とは、自然災害により被災した住家などの被害の程度を証明する書類で、被災者生活支援金・災害義援金の支給・被災住宅の応急修理・仮設住宅への入居などの適用の判断材料として活用される。しかし、発行までには被災者が市町村へ申請してから調査員が直接赴いて被害状況の調査をすることが必要のため、発行の遅れが問題になっている。実際に熊本県内において、地震から一か月間の9万7741件の申請数に対し、発行数は2万8266件にとどまり、30%に満たない件数しか処理されていない。

この状況から、目視での建物の被災度の判定ではなく遠隔性・広域性のある方法として、リモートセンシング技術の活用が有効と考えられる。航空レーザ測量³⁾とは、航空機に搭載したレーザスキャナから地上にレーザ光を照射し、反射して戻ってきたレーザ光の時間差により、地上の標高や形状を計測することである。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³⁾ (以下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CNN⁴⁾を適用させ、地震被害建物の自動検出を試みる。なお、DSMとは、建物や樹木を含む三次元の地表モデルのことを指す (図-1)。



図-1 計測される DSM のイメージ³⁾

2. データセットの作成

(1) 使用データについて

本研究は、熊本地震の被害の大きかった益城町を対象に行った。航空レーザ測量データには、Moyaら⁶⁾が整備したデータを用いた(図-2)。航空レーザ測量は、前震後(2016年4月15日15:00~17:00)と、本震後(2016年4月23日10:00~12:00)に行われた。黒枠の範囲が対象地域である益城町である。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の差分のデータを用いる。

正解ラベルとして用いる建物の被害状況には、山田らが前震後(2016年4月15日)と本震後(2016年4月16日)の航空写真を比較し、建物被害をまとめたデータ⁷⁾を使った。山田らの調査では、岡田⁸⁾の提案した建物の被害尺度に則っている(表-1)。D0・D1・D2・D3・D4の被害の建物、もしくはD5の被害の建物の二種類に分類している。本研究では、D0・D1・D2・D3・D4に分類された建物をクラス0、D5に分類された建物をクラス1とする。




図-2 本震前の航空レーザ測量データ

表-1 建物の被害尺度⁸⁾

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て大きな亀裂。構成要素の一部が破壊。
D4	壁面は重度の破壊。スラブの一部が破壊。構成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

山田らのデータから、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50×50画素の画像を切り出した。内訳は、クラス0が2742枚、クラス1が454枚の計3196枚である。過学習を抑制し、汎化性能を向上させるため、5分割のクロスバリデーションを行う。また、各バリデーションデータセットでの訓練データには、鏡像反転、回転(±90°、+180°)、鏡像反転と回転(±90°、+180°)の処理を行い、データ数をオリジナルの画像データの8倍に拡張した。

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。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。畳み込み層で特徴を抽出し、プーリング層で圧縮するという工程を繰り返すことで、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幅広く用いられている⁹⁾¹²⁾。

(2) 学習条件

学習条件については、表-2に示している通りである。活性化関数にはReLU¹³⁾を用いる。ReLUは、関数への入力値が0以下の場合に出力値を常に0、入力値が0より大きい場合に入力値をそのまま出力値とする関数である。ReLUを使うメリットは、単純な関数であるため処理速度が速いことや、勾配消失が起きにくいことがある。勾配消失とは、ディープニューラルネットワークにおいてシグモイド関数などの活性化関数の場合、勾配が0に近くなってしまい、重みの更新ができなくなる状態のことである。

本研究のCNNのネットワーク構造を図-3に示す。本研究では、データ数の不足を解消するために行ったデータ拡張の効果について確認した上で、大きく3つの実験を行った。1つ目の実験では、学習率の異なるモデルの精度を比較した。2つ目の実験では、畳み込み層のフィルター数の異なるモデルの精度を比較した。3つ目の実験では、1つ目と2つ目の実験から得られた最良のモデルの過学習を抑制するため、正則化¹⁴⁾による効果を確認した。

表-2 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
バッチサイズ	64
エポック数	30

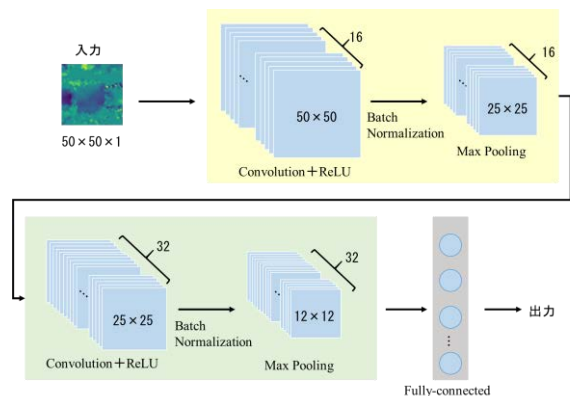


図-3 CNNのネットワーク構造

(3) 精度評価指標

損失関数値と2クラス分類の精度指標¹⁴⁾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-3のように定義する。

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

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

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

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

本研究では、各バリエーションにおいてテストで最も小さい損失関数値であったエポック時の精度指標を保存し、平均した数値を比較する。

表-3 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)

(4) 正則化

ディープラーニング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。本研究では、Adamのパラメータである weight decay¹⁵⁾の値を変化させ正則化を行う。Weight decayとは重み減衰とも呼ばれ、損失関数に重みの二乗和を加えたものを新しい損失関数とする。損失関数の値が小さくなるように重みが更新され、重み一つ一つの値が極端に大きい値、あるいは小さな値にならないように、パラメータに制約を加えている。重み減衰ありの損失関数は、式(5)のように表せる。

$$E = \min f(x) + \frac{\lambda}{2} \sum_{i=1}^n |w_i|^2 \quad (5)$$

4. 判別結果

(1) データ拡張による精度比較

少ないデータを補うために、CNNではデータの拡張¹⁶⁾が行われる。今回は、オリジナルの画像データのみモデルと、オリジナルと回転(±90°, +180°)で拡張を行った4倍拡張のモデル、オリジナルと回転(±90°, +180°)と鏡像反転かつ回転(0°, ±90°, +180°)の8倍拡張を行ったモデルの3つのモデルの精度比較を行った。表-4から、すべての精度指標において8倍拡張のモデルが最良であるとわかる。よって、これ以降のモデルでは、8倍拡張したデータセットを用いて学習を行う。

表-4 データの拡張による判別精度の比較

データセット	損失関数値	正答率	適合率	再現率	F値
拡張なし	0.00149	96.8	60.0	53.7	0.569
4倍拡張	0.00139	97.1	61.7	59.6	0.606
8倍拡張	0.00131	97.4	67.1	64.9	0.660

(2) 学習率の変化による精度の推移

学習率を10⁻⁷~10⁻¹の範囲で対数変化させた時の各モデルの損失関数値を図-4に示す。損失関数値は学習率10⁻³から小さくなり始め、10⁻⁴で極小値となった。10⁻³より大きい学習率では、刻みが大きいため最適解を通り過ぎている可能性がある。10⁻⁵より小さい学習率では、最適解に達する前に学習が終わってしまっている。そこで、最適な学習率を見つけるため、10⁻⁴から0.00005刻みで学習率を推移させ、精度の変化を細かく調べた(図-5)。表-5の結果から、10⁻⁴~0.00085の間で

は損失関数値があまり変わらないことがわかる。学習率 $10^{-4} \sim 0.00085$ の範囲で損失関数値が最小値の0.0013となったモデルの精度指標を表-5にまとめた。どのモデルも正答率はあまり変わらないが、学習率0.00045のモデルでは、適合率・再現率・F値が他のモデルに比べ高くなった。したがって、本研究のモデルでは学習率0.00045とする。




図-4 学習率 $10^{-7} \sim 10^{-1}$ のモデルの精度比較

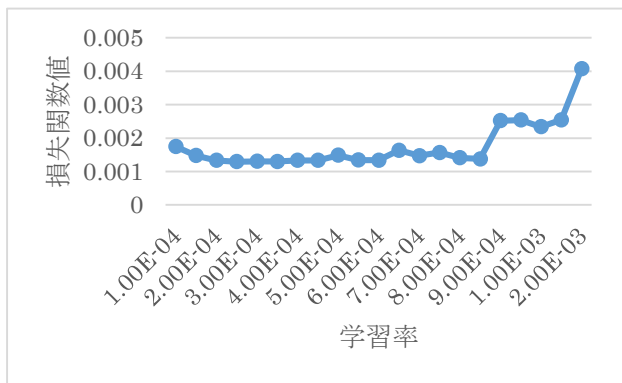


図-5 学習率 $10^{-4} \sim 0.00085$ のモデルの精度比較

表-5 学習率を変えたモデルの精度指標の比較

学習率	正答率	適合率	再現率	F値
0.00025	97.4	60.4	58.8	0.595
0.00035	97.4	60.7	58.2	0.594
0.0003	97.1	60.3	57.7	0.590
0.0002	97.3	60.6	58.0	0.592
0.00045	97.3	66.0	63.0	0.644
0.0004	97.2	61.7	59.7	0.606

(3) フィルター数の変化による精度の推移

一層目の畳み込み層に対し、フィルター数を変えたモデルの比較を行った。フィルター数を増やすことで出力される特徴マップが増えるため、精度の向上が期待できる。表-6を見ると、フィルター数が16以上になったところから損失関数値は横ばいになっている。フィルター数16のモデルの損失関数値の推移をみると、訓練時とテスト時の損失関数値が乖離していく傾向が見られ、過学習していることがわかる。よって、フィルター数を増やしてもより過学習が進んでしまうため、フィルター数16の

モデルを最良のモデルとし、過学習を抑制する方法を考えることとした。




図-6 フィルター数の異なるモデルの精度比較




図-7 フィルター数 16 のモデルの損失関数値の推移




図-8 フィルター数 16 のモデルの正答率の推移

表-6 フィルター数 16 のモデルの精度指標

損失関数値	正答率	適合率	再現率	F値
0.133	97.3	66.0	63.0	0.644

(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プロットしたグラフから、損失関数値の値は正則化しないモデル (weight decay=0) よりも大きくなってしまい、正則化の効果は見られなかった。

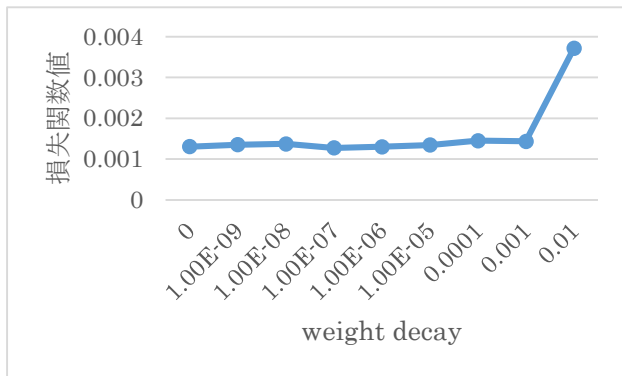


図-9 Weight decay の異なるモデルの精度比較

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。学習率や正則化のパラメータチューニングやCNNのフィルター数を変化させることによる精度の変化をまとめ、最良のモデルを決定した。最良のモデルの判別精度は、正答率97%を超えており高い確率で予測できていることがわかる。全データ中クラス1に分類されるものが15%程度しかない不均衡データであるため、正答率は上がりやすくなるものの、再現率を上げることが難しいという点が課題である。現在のモデルでは、再現率60%程度であり、今後精度向上を目指す。

本研究は、ネットワーク構造についての検討が十分であるとは言えないため、今後よりよいネットワークを試す予定である。また、正則化を行ったが過学習の抑制効果が見られなかった原因としては、データ数が少ないことが挙げられる。解決策として、正解ラベルとして罹災証明の被害認定調査の結果を用いることで、データ数を増やすことが考えられる。

REFERENCES

- 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) 総務省：大規模災害時における罹災証明書等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/000529199.pdf
- 3) 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
- 4) 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.
- 5) 藤田一弥, 高原歩：実装ディープラーニング, オーム社, 2016.
- 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) 石井友, 松岡昌志, 牧紀男, 堀江啓, 田中聡：兵庫県南部地震後に撮影された航空写真と現地写真を用いた深層学習による建物被災度判別の試み, *日本建築学会構造系論文集*, 第 83 巻, 第 751 号, pp.1391-1400, 2018.
- 10) 利根川凜, 飯塚博幸, 山本雅人, 古川正志, 大内東：被災がれき査推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出, *情報処理学会論文誌*, Vol.57, No.6, pp.1565-1575, 2016
- 11) 上岡洋平, 田中聡, 阿部郁男, 釜ヶ谷悠馬, 松岡昌志：2016 年熊本地震における斜め航空写真を用いた目視判読および深層学習による建物被害判別の検討, *地域安全学会梗概集*, No.41, pp.127-130, 2017.
- 12) 内藤昌平, 友澤弘充, 森悠史, 門馬直一, 中村洋光, 藤原弘行：複数の地震における航空写真を用いた深層学習による建物被害判別モデルの開発, *日本地震工学論文集*, 第 20 巻, 第 7 号, pp. 7_177-7_216, 2020.
- 13) Nair, V. and Hinton, G. E.: Rectified linear units improve restricted Boltzmann machines, *Proceedings of the 27th International Conference on Machine Learning*, 2010.
- 14) 平井有三：はじめてのパターン認識, 森北出版, 2012.
- 15) PyTorch Contributors: weight decay, <https://pytorch.org/docs/stable/generated/torch.optim.Adam.html>
- 16) 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.

Detection of Damaged Buildings due to Earthquakes by Deep Learning Technique using Aerial Laser Survey Data

Ayane KAGOSHIMA, Wen LIU and Yoshihisa MARUYAMA

- 1) Student Member, Graduate School of Science and Engineering, Chiba University
- 2) Member, Assistant Professor, Graduate School of Engineering, Chiba University, Dr. Eng.
- 3) Member, Professor, Graduate School of Engineering, Chiba University, Dr. Eng.

In the April 2016 Kumamoto earthquake, a moment magnitude 6.2 earthquake occurred in the Kumamoto region of Kumamoto Prefecture, Japan, and a moment magnitude 7.0 earthquake occurred shortly after 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.