028

# 現地写真を用いた深層学習による地震時の建物被災度判別モデルの構築

Deep Learning of On-site Photos to Detect Building Damage after an Earthquake

20WM1325 戸澤 謙弥 Ken'ya Tozawa 

## SYNOPSIS

To support an efficient and rapid investigation of seismically induced damage to buildings, this study applies a deep learning algorithm to on-site photos taken after earthquakes. The convolutional neural network (CNN) is employed to detect the collapsed wooden houses after the 2016 Kumamoto earthquake. The accuracy of discrimination was improved when the on-site photos of collapsed buildings after the other Japanese earthquakes were included in the image dataset. The dropout layer was also very effective to prevent overfitting. The overall accuracy was 80.8%, and this study is helpful to support damage investigation performed by municipalities soon after an earthquake.

1. はじめに

地震をはじめとした自然災害の発生後,被災地やその周 辺の自治体職員等によって,構造物の被災程度を把握する ための様々な調査が実施される.その一つとして,内閣府 の被害認定調査基準<sup>1)</sup>に基づき実施される住家の被害認定 調査がある.この調査では,外観目視を基本とした第一次 調査を行ったのちに,必要に応じて内観等を含む詳細な調 査(第2次調査)を実施し,建物の被害を5段階で評価す る.得られた調査結果は,罹災証明書として被災者に交付 され,被災者支援措置に活用される.しかし,このような 調査は,災害の規模が広範囲に及ぶと調査対象となる建物 が急増することから,人員不足に伴う調査時間の遅延が問 題視されている.2016年に発生した熊本地震を例に挙げる と,地震発生から1ヶ月の時点で,罹災証明書の申請件数 に占める交付数の割合は3割程度にとどまっており,罹災 証明書発行の遅れが問題となった.<sup>2)</sup>

このような問題を受けて既往研究<sup>3)</sup>では,1995年の兵庫 県南部地震で被災した建物を対象に畳み込みニューラルネ ットワーク(CNN)を適用することで,対象建物の全壊・ 非全壊を判別するモデルを構築した.被害認定調査とは異 なる目的で実施された調査で撮影された画像を使用してい たため,最終的な判別精度は73.6%に留まっている.

本研究では、より精度の高いモデルの構築を目指し、2016



a) 建物全景画像

年熊本地震後の住家の被害認定調査で実際に使用された現 地写真を画像データセットに用いた.その上で,画像分類 によって建物の全壊・非全壊を判別するモデル(以下「全 壊判別モデル」と称する)と,物体検出によって建物の損 傷箇所を特定するモデル(以下「損傷検出モデル」と称す る)を構築し,被害認定調査の迅速化に向けた検討を進め た.熊本市および益城町で実施された被害認定調査では, 木造住家の73.6%が第1次調査で得られた結果を最終的な 被災度としており,第1次調査の迅速化は被災者支援措置 を早期に実施する上で大きな役割を果たせる.

#### 2. 現地写真を用いたデータセットの作成

本研究では、2016年熊本地震の際に実施された住家の被 害認定調査において、市町村別の調査棟数が特に多かった 熊本市と益城町を対象としている.一般に、木造・プレハ ブ造の被害認定調査(第1次調査)<sup>4)</sup>は、①外観による判 定、②傾斜による判定、③部位(基礎)による判定、④部 位による判定の計4つの調査項目に大別される.

調査の第1段階にあたる項目①から③では,層破壊や液 状化に伴う基礎破壊の有無,外壁・柱の傾斜の大きさなど を確認し,対象建物が全壊か否かを判定する.これらの調 査項目を満たさなかった場合は,第2段階として,建物を 屋根・外壁・基礎の3区分に分け,各部位の損傷率を規定



b) 外壁接写画像

図1 選定後の建物画像例

の方法で算出し、それらを統合することで建物全体の損傷 割合を算定する(④部位による判定).したがって、全壊判 別モデルは第1次調査の第1段階、損傷検出モデルは第2 段階の補完を目的としており、それぞれ異なった特性を有 する画像からデータセットを作成する.

使用する建物画像は,住家の被害認定調査データから選定する.まず,調査が行われた建物に対して,構造種別が 木造であること,第1次調査にて被災度が判定されている ことを条件に絞り込みを行った.この条件は,構造種別に よる被害認定調査の内容や被災度の決定方法の差異を考慮 し設定した.続いて,絞り込み後の建物画像のうち,建物 全体が映りこんでいる画像(建物全景画像)と,外壁の損 傷が詳細に確認できる画像(外壁接写画像)を目視で取り 出す.選定後の画像は,それぞれ全壊判別モデルと損傷検 出モデルのデータセットとして用いた.データセットに使 用した画像の一部を図1に例示する.

全壊判別モデルで使用したデータセットについて、本研 究では第1次調査の項目①~③で全壊判定がなされた建物 全景画像をクラス1,その他の判定がなされた建物全景画 像をクラス2としてアノテーションを行った.訓練データ のクラス1には、国内で発生した既往地震で全壊した建物 の全景画像(現地調査にて撮影、計81枚)を追加した.さ らに、訓練データ(追加データ含む)には鏡像反転と回転 処理(±5°)を施し、データ数をオリジナル画像の4倍に 拡張した.これにより、訓練データの不足に伴う過学習の 抑制と判別精度の向上を図っている.当該モデルで使用し たデータセットの画像数の内訳を表1に示す.

損傷検出モデルで使用したデータセットは、第1次調査 の項目④で大規模半壊と判定された建物の外壁接写画像か ら作成した.このモデルに適用される物体検出は、画像の 中から定められた物体の位置と種類(クラス),個数(イン スタンス数)を特定する技術である.そのため、データセ ットには対象画像から確認できる損傷の種類や位置といっ た属性情報を与える必要がある.本研究では、損傷率算定 時に確認する外壁のひび割れと剥落、下地材を異なるクラ スとして定義し、アノテーションツール COCO Annotator を 用いて損傷箇所ごとに属性情報を与えた.このツールは GUI アプリケーションであるため、画像内の任意の物体を マウス操作で囲むことによって属性情報を付与できる.当 該モデルで使用したデータセットの画像数およびインスタ ンス数の内訳を表2に示す.

|       |      | 非全壊       |     |          |     |  |  |
|-------|------|-----------|-----|----------|-----|--|--|
|       | 全壊   | 大規模<br>半壊 | 半壊  | 一部<br>損壊 | 無被害 |  |  |
| Train | 2592 | 668       | 668 | 672      | 592 |  |  |
|       |      | 2600      |     |          |     |  |  |
| Test  | 566  | 155       | 155 | 155      | 95  |  |  |
|       |      |           | 50  | 50       |     |  |  |

表1 全壊判別モデル用データセットの画像数(単位: 枚)

## 表2 損傷検出モデル用データセットの画像数とイ ンスタンス数

|       | 両 梅 粉 [ 歩 ] | イ    | インスタンス数 |     |  |  |
|-------|-------------|------|---------|-----|--|--|
|       | 回该致[权]      | ひび割れ | 剥落      | 下地材 |  |  |
| Train | 780         | 871  | 223     | 139 |  |  |
| Test  | 100         | 104  | 28      | 25  |  |  |

#### 3. 画像分類モデルの構築

画像分類に用いられる CNN は、全結合層のみで構成さ れる一般的なニューラルネットワークとは異なり、畳み込 み層やプーリング層を持つことが特徴である.これらの層 を導入することで学習すべきパラメータが減少し、視覚的 な特徴の抽出が可能となった.また、畳み込み層における カーネルの計算やプーリング層での計算処理は独立してお り、GPU を用いた並列計算が可能なことから、計算の高速 化にも適している.本研究では、畳み込み層を2層から3 層連続して配置することにより、シンプルな構造で多層化 を実現した VGG アーキテクチャをベースに、全壊判別モ デルのネットワークを構築した.図2に使用したネットワ ークの構成を示す.図中の畳み込み層と全結合層の直下に は、過学習を抑制する手段としてドロップアウト層とバッ チ正規化層を導入している.

また、全壊判別モデルの学習は表3に示す学習条件に基づいている.活性化関数について、中間層には勾配損失問題を防ぐためにReLu関数を、出力層には入力値の正規化と損失関数値の算出を兼ねたSoftmaxWithLossを導入した. 学習の最適化アルゴリズム(Optimizer)にはAdamを使用している.このアルゴリズムは重みパラメータの二乗平均と指数移動平均を1次モーメントと2次モーメントとして考慮することで、パラメータごとに適切なスケールに基づいた値の更新を可能としている.

### 4. 物体検出モデルの構築

物体検出は、一枚の画像に複数のクラスが存在する場合 に有効な技術である.画像分類と異なり、入力画像から物 体のクラスとそれを含むバウンディングボックスを予測す る.本研究では、物体検出のアルゴリズムの一つである Mask R-CNN を利用した. Mask R-CNN はバウンディング ボックスの予測に加え、その領域内をピクセル単位でクラ ス分類し、物体の形状を推定するモデルとなっている.

Mask R-CNN のネットワークは Backend 部, RPN(Region Proposal Network)部, Head 部の 3 つに大別される. Backend 部は画像分類のタスクで用いる CNN と同様の機能を有しており,入力画像の特徴を抽出する役割を担う. RPN 部は

| Input<br>(112×112×3) | Conv1-1 | Conv1-2 | Max Pooling | Conv2-1           | Conv2-2 | Max Pooling | Conv3-1 | Conv3-2 | Max Pooling | FC1      | FC2  | Output |
|----------------------|---------|---------|-------------|-------------------|---------|-------------|---------|---------|-------------|----------|------|--------|
| カーネルサイズ              | 3       | 3       | 3           | 3                 | 3       | 3           | 3       | 3       | 3           | -        | -    | -      |
| ストライド                | 1       | 1       | 2           | 1                 | 1       | 2           | 1       | 1       | 2           | -        | -    | -      |
| フィルター数               | 32      | 32      | -           | 64                | 64      | -           | 128     | 128     | -           | -        | -    | -      |
| ノード数                 | -       | -       | -           | -                 | -       | -           | -       | -       | -           | 512      | 512  | 2      |
| Convolution Lavor    |         |         |             | Max Pooling Laver |         |             |         | Enlly   | Connor      | tad L or | uar. |        |

図2 本研究で用いた CNN の構成

表3 CNN の各種パラメータ

|              | ReLu(中間層)       |  |  |  |
|--------------|-----------------|--|--|--|
| 活性化関数        | SoftmaxWithLoss |  |  |  |
|              | (出力層)           |  |  |  |
| Optimizer    | Adam            |  |  |  |
| バッチサイズ       | 16              |  |  |  |
| 学習回数         | 15000           |  |  |  |
| 学習率          | 0.001           |  |  |  |
| Weight Decay | 0.001           |  |  |  |
| (荷重減衰係数)     | 0.001           |  |  |  |
| Dropout rate | 0.2             |  |  |  |



図3 本研究で用いた Mask R-CNN(Backend 部)の構成

物体らしき領域の候補を抽出する役割を, Head 部はその領 域について、RoI Align5)で物体のクラスと領域の位置を推 定する役割をそれぞれ担っている.本研究では, Backend 部 のネットワークに ResNet (101 層) を採用し, 作成した訓 練データ(表 2)を用いて 30000 回学習を行った.使用し たネットワークの詳細を図3に示す.

#### 全壊判別モデルの評価と被害推定 5

表1のデータセットに対して,前述の条件に基づき学習 を行った.判別モデルの学習と並行して、1 エポックごと にテストを行い, テストデータに対する正答率と損失関数 値を出力させている.正答率は、2 クラス分類の判別器の 定義に従って算出した.「正例」を判別器に与え,「正例」 であると判別できた場合を TP(True Positive),「負例」と誤 判別した場合を FN(False Negative),「負例」を与え「正例」 と誤判別した場合を FP(False Positive),「負例」と判別でき た場合を TN(True Negative)とする. 全壊判別モデルでは, 全壊を「正例」,非全壊を「負例」として,種々の評価指標 を算出した. 表4に示した混同行列から算出されるモデル の適合率は 81.0%, 再現率は 80.7%である. 誤判別データ の内訳より, FP (107) と FN (109) に有意な差は見られず,

クラスごとの判別精度に差異はないことがわかる.

また、全壊判別モデル用データセットに追加した画像の 有意性を検証するため、追加データを除いたデータセット を別途作成し、同様の条件下で学習を行った、同モデルの テストデータに対する判別精度について,正答率は78.5%, 損失関数値は 0.84 であり、いずれも追加データを含むデー タセットで学習したモデルの判別精度(表4)を下回った.

本研究では、全壊判別モデルで生じた誤判別の要因を考 察するにあたり、勾配可視化技術(Grad-CAM)のを利用し た. Grad-CAM は、予測クラスの出力値に大きく寄与する ところが分類において重要であるという考えに基づき, CNN が分類のために注視している範囲をカラーマップで 表示する手法である.出力値に対する寄与率の高さは、勾 配の大きさから判断することができ、一般に最も出力層に 近い畳み込み層の予測クラスの出力値に対する勾配が用い られる.建物全景画像に Gard-CAM を適用し、被害認定調 査の結果と全壊判別モデルの予測結果の組み合わせ別に表 示した(図4).正しく全壊と判別された画像(TP)をみる と,赤く表示されている箇所が建物の層破壊が起きた部位 や外壁の剥落箇所と重なっていることから、判別モデルが 適切に特徴を捉えていることがわかる.一方,誤って全壊

|      |     |     | 判別結果 |       | 評価指標   |              |             |
|------|-----|-----|------|-------|--------|--------------|-------------|
|      |     | 全壊  | 非全壊  | 計     | 適合率    | 再現率          | F 値         |
|      | 全壊  | 457 | 109  | 566   | 91.00/ | 80.70/       | 80.00/      |
| 真の結果 | 非全壊 | 107 | 453  | 560   | 81.0%  | 80.7%        | 80.9%       |
|      | 計   | 564 | 562  | 1,126 | IE     | 医答率 = 80.8%, | Loss = 0.73 |

表4 全壊判別モデルのテストデータに対する判別精度

TP(被害認定調查:全壞,予測:全壞)



FP(被害認定調查:非全壞,



## FN(被害認定調查:全壊,予測:非全壊)



図4 建物全景画像の判別結果と Grad-CAM 適用後の画像例

| 表5 損1 | 易検出モデ | ルのテス | トデータ | マに対す | る検出精度 |
|-------|-------|------|------|------|-------|
|-------|-------|------|------|------|-------|

| Lass |      | AP   |      | m A D | mAP             | mAP              |
|------|------|------|------|-------|-----------------|------------------|
| Loss | ひび割れ | 剥落   | 下地材  | IIIAP | $(IoU \ge 0.5)$ | $(IoU \ge 0.75)$ |
| 0.16 | 0.39 | 0.45 | 0.82 | 0.55  | 0.72            | 0.61             |



図5 損傷検出モデルによる推定結果の例

と判別された画像(FP)をみると、建物にかかったブルー シートや建物以外の地物(樹木など)を注視しているケー スが多い.また、このような建物に共通して、被害認定調 査時に基礎の損傷やひび割れの侵食の程度に基づいた判定 がなされていることが確認できた.

6. 損傷検出モデルの評価と被害推定

物体検出の分野において、画像中の物体をどの程度正し く検出できているか評価する指標として mAP が用いられ ている. mAP はクラスごとに算出した AP(Average Precision)の平均値であり、AP は式(1)から得られる.

$$AP = \int_{0}^{1} p(r)dr \tag{1}$$

ここで、p は適合率、r は再現率を表す.物体検出におけ る適合率と再現率は、正解データに対する予測データの重 複率を表す IoU(Intersection over Union)に基づき定義されて いる.そのため、適合率と再現率から算出される AP と mAP は、あらかじめ設定する IoU の閾値によって変化する.表 5 には、標準的な AP および mAP に加え、IoU の閾値を 0.5 と 0.75 に変化させた際に得られた数値をそれぞれ表示し た.各クラスの AP を比較すると、下地材の値がひび割れ や剥落の値に比べて高い.下地材は面的な損傷箇所に露出 するため、線的な損傷(ひび割れ、剥落)との区別が容易 である.また,損傷箇所の境界もはっきりとしているため、 このような結果が得られたものと考えられる.

図5には、外壁接写画像と建物全景画像に含まれる損傷 箇所の推定結果を示した.外壁接写画像への適用例より、 損傷箇所が確認しやすいモルタル外壁だけでなく、タイル 張りの外壁についても適切に損傷を検出できていることが 分かる.また、建物全景画像に含まれる細かなひび割れま で検出できていることから、損傷検出モデルは外壁の形状 や材質を問わず適用可能である.

7. まとめ

本研究では、CNN 及び Mask R-CNN を利用して建物の全 壊・非全壊の判別と損傷箇所の検出を行った.各モデルの 画像データセットには、2016 年熊本地震後に実施された被 害認定調査(第1次調査)の際に撮影された現地写真を用いた.

全壊判別モデルについて,国内の既往地震で全壊した建 物の全景画像を加えた結果,過学習の抑制や判別精度の向 上が確認され,画像データを追加することの有意性が証明 された.モデルの判別精度80.8%は,被害認定調査(第1次 調査)の第1段階を補完する役割をある程度果たせるもの と考えられる.導入に際しては,被害認定調査を実際に行 う行政職員や,調査を受ける地域住民の理解を得ることも 重要となるだろう.

損傷検出モデルでは、より先進的なアルゴリズムを導入 することで、高精度の損傷検出を可能とした.このモデル は、入力画像に対してピクセル単位でクラス分類を行うた め、建物全景画像使用時も高い精度で損傷を検出する、そ のため、モデルの改良を進めることで被害認定調査(第1 次調査)の第2段階の補完が期待できる.

参考文献

- 内閣府:災害に係る住家の被害認定,http://www.bousai. go.jp/taisaku/pdf/r203kaitei.pdf
- 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
- 3) 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, Vol. 83, No. 751, pp. 1391–1400, 2018.
- 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
- He, K., Gkioxari, G., Doll'ar, P., Girshick, B. R.: Mask R-CNN, arXir : 1703.06890 [cs], 2018.
- 6) Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. and Batra, D.: Grad-cam: Visual explanations from deep networks via gradient-based localization, Proceedings of the IEEE International Conference on Computer Vision, pp. 618–626, 2017.