

2016年熊本地震による建物被害を対象とした深層学習による 被災度分類の試み

Based on deep learning for building damage caused by the 2016 Kumamoto earthquake
Attempt of Classification of Degree of Disaster

○釜ヶ谷 悠馬¹, 松岡 昌志², 小岩 弘道³, 望月 貫一郎⁴
Yuma KAMAGATANI¹, Masashi MATSUOKA², Hiromichi KOIWA³,
Kanichiro MOCHIZUKI⁴

¹東京工業大学 環境・社会理工学院 建築学系

Department of Architecture and Building Engineering, Tokyo Institute of Technology

²東京工業大学 環境・社会理工学院 建築学系

Department of Architecture and Building Engineering, Tokyo Institute of Technology

³株式会社パスコ

PASCO CORPORATION

⁴株式会社パスコ

PASCO CORPORATION

On 2016 Kumamoto Earthquake, an earthquake with an intensity of 7 on the JMA scale occurred twice, and based on the airborne imagery after those earthquakes, we used deep learning in order to classify the amount the building damages. In deep learning, we used to train only two types (massive damage and no damage) of building images and we input the all images to the trained model, in order to output the probability(certainty factor) of the building damage (massive damage) from the image. In this study, we used this certainty factor to examine if it is possible to classify the building damage in to more that three types.

Keywords : Kumamoto earthquake, airborne imagery, building damage, Deep learning, Certainty factor

1. はじめに

平成28年4月14日から16日にかけて発生した熊本地震では熊本県を中心に住家建物の8,169棟が全壊、29,294棟が半壊、136,607棟が一部損壊¹⁾という甚大な被害をもたらした。このような災害においては、建物の迅速な被災状況把握が災害直後の初動対応や被災地域の復旧・復興計画、被災者の生活再建の判断材料になる為に重要である。建物の被害判定を行う方法は、現地や現地の写真から判読することとなるが、作業者に技術や経験が求められ、多くの時間を必要とする。

早急な建物被害を判定する手法として、空中写真をConvolutional Neural Network(以下、CNN)により学習させ、倒壊建物を抽出する研究²⁾が報告されている。しかし、この手法は倒壊か非倒壊の2つのクラスへの分類である。物体を認識させるCNNでは、複数クラスへの分類を行わせるには各クラスの学習用画像が必要になる。しかし、建物被害を推定させる際に各クラスの被害ラベル付きデータを用意することは早急な被害判定には適していない。

本研究では、地震による2つのクラス(全壊と無被害)の建物被害データからより多くのクラスへ分類することを目的とする。CNNでは入力に対して、それが何パーセントで何であるかを表す確率(確信度)が出力される。災害による建物被害は連続的な(本来クラスに分けることができない)値であると仮定し、確信度を用いて2つのクラスのデータによる複数のクラスへの分類を試みる。

2. 対象地域と目視判読

熊本地震において2度、震度7を観測した益城町役場周辺を対象に行った目視判読結果を用いる。目視判読の基準は岡田・高井³⁾により作成された建物破壊パターンチャートを参考にDamage Gradeと呼ばれる6段階の被害尺度に対応するように直下視画像と斜め画像を用いて行っている。本研究で扱うDamage Gradeは、D0を「被害が確認できない建物」、D1を「壁面に亀裂・まれに漆喰壁の小片落下」「屋根瓦の一部が破損」、D2は「多くの壁に亀裂・漆喰壁の落下が目立つ」「屋根瓦全体の1/3程度が破損」、D3は「ほとんどの壁に大きな亀裂・構造要素の一部が破損」「屋根瓦全体の2/3程度が破損」、D4は「壁面は重度の破壊・構造要素はお互いの連結性を失っている」「屋根瓦のほぼ全てが破損及び一部が崩壊」、D5は「完全またはほとんど完全に崩壊」としている。図1に各判読ラベルの画像例、図2に目視判読結果を示す。




図1 各判読ラベルの画像例




図2 目視判読結果

3. CNN用データセットの作成

CNN用の学習データと検証データを作成した。本研究では、災害後に現地写真等より入手が容易な直下視の画像(図1の上段)をCNNに利用することとした。学習データには本研究の目的であるD0とD5の2種類の建物画像のみを用いた。少ない画像でCNNを用いる際には一般的に画像の水増しが行われる。そのため、本研究においても学習データを水増しし、24倍(回転と鏡像とコントラストの変化)にした。検証データはD0からD5を用いることとした。また、この学習により造られる学習済みモデル(分類器)を評価するために全ての直下視による建物画像を評価用データとした。CNN用データの構成枚数を表1に示す。

表1 CNN用データセットの各構成枚数

	D0	D1	D2	D3	D4	D5	total
学習データ	312→7488	0	0	0	0	312→7488	624→14876
検証データ	209	59	44	144	37	131	624
評価用データ	4045	1157	876	677	173	624	7552

4. CNNによる学習

学習の超パラメータは、バッチサイズを 100、学習率を 0.001、減衰係数を 0.0005、モメンタムを 0.9、ネットワーク構成を以下の構成(図 3)とした。学習の反復回数については、損失関数を基に決定した。図 4 に学習時の損失関数の推移を示す。図 4 より、学習モデルと検証データとの違いを表す loss(val)が学習の反復回数の増加とともに上昇している。この値が上昇し始めると過学習(学習データに過剰に適合しすぎており汎用性が低下)している状態と言える。そのため、確実に loss(val)が下降している状態として、学習の反復回数が 4400 回の時の学習状況を分類器として用いることとした。




図3 CNNのネットワーク構成⁴⁾




図4 損失関数の推移




図5 Damage Gradeと確信度(D5)の関係

5. 確信度を用いた分類

作成した分類器を用いて、評価用データの分類を行った。分類後の画像には、確信度と呼ばれるCNNにより求められた各分類(本研究ではD0とD5)の確率が出力される。今回はD5である確率を基に検討を行った。図5に目視判読結果と確信度(D5)の関係を示す。全ての目視判読結果(Damage Grade)で確信度の値は幅広く分布していることがわかる。これらは、画像内の建物以外の要因に反応していることなどが考えられる。しかし、四分位範囲(IQR)はDamage Gradeにより異なり、確信度が大きいほどDamage Gradeも大きい傾向がある。よって、建物被害は連続的な値であり、確信度から複数クラスに建物被害を分類できるのではないかと考えられる。

図6に確信度を地図上にプロットしたものを示す。図2の目視判読結果に於けるD5が密集している地域はほとんど確信度が80%から100%である。しかし、D3の建物が密集している町役場北西などでも80%から100%の確信度で分類されていることが確認できる。これらの要因として、CNNに用いている画像が直下視画像だけであり、建物上部(屋根)に被害がある場合は確信度が大きく出してしまうためではないかと考えられる。




図6 確信度による建物被害密集地の可視化

6. まとめ

目視判読結果を用いてCNNにより2種類画像から構成される学習データの画像から6種類への分類を試みた。6種類への分類を行う方法として、CNNから出力される確信度に注目し、検討を行った。その結果、確信度が大きいほど建物の被害(Damage Grade)が大きくなる傾向があることが確認できた。また、確信度を基に地図上にマッピングを行った結果、建物被害が多い地域や建物被害が大きい建物については抽出できていると思われる。よって、複数クラスの被害を2種類の建物画像から推定することは可能であると考えられる。今後は、この分類器により、災害調査データや解体申請データの被害ラベルの建物を確信度を指標に推定できるかを確認する予定にしている。

参考文献

- 総務省消防庁：熊本県熊本地方を震源とする地震(第75報)、<http://www.fdma.go.jp/bn/1609021100>【第75報】熊本県熊本地方を震源とする地震%20.pdf、2016年、2017年8月1日確認
- 利根川凜、飯塚博幸、山本雅人、古川正志、大内東：被災がれき量推定に向けた画像解析を利用した倒壊建造物の自動抽出、FIT2015 (第14回情報科学技術フォーラム)、0-024、2015年、pp479-480.
- 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、1999年、pp65-72.
- 石井友、松岡昌志、牧紀男、堀江啓、田中聡：兵庫県南部地震の現地写真を用いた深層学習による建物被災度判定、2017年日本建築学会大会(中国)、21208、2017年、pp415-416.