

深層学習を用いた航空写真および地上写真による 建物被害判別の検討

Deep Learning Interpretation of Building Damages using Aerial and Ground Photographs

○上岡 洋平¹, 田中 聡²

Yohei UEOKA¹ and Satoshi TANAKA²

¹日本ミクニヤ株式会社 環境防災部 (元 常葉大学大学院)

Environment and Disaster Prevention Department, Mikuniya Co.,Ltd. (Formerly Graduate Student, Tokoha Univ.)

²常葉大学大学院 環境防災研究科

Graduate School of Environment and Disaster Research, Tokoha University

This paper presents a study on deep learning interpretation of building damage using aerial and ground photographs. After disaster occurred, to be implementer various building damage survey, but it is a problem that the investigation will be prolonged due to the wide range of afflicted areas and lack of unvestigators. In this study, using aerial and ground photographs, detection of building damage by CNN. As a result, high discrimination accuracy was obtained in the 2 classification using aerial photographs and in the 2 and 3 classification using ground photographs.

Keywords : deep learning, building damage evaluation, CNN, aerial photograph, ground photograph, other classification

1. はじめに

大規模災害発生後には、さまざまな目的で建物被害調査が実施される。中でも応急危険度判定調査と建物被害認定調査は、地域住民にとって大きな役割を果たしている。応急危険度判定調査は、災害による 2 次的災害を防ぐことを目的としており、災害発生後から迅速な調査実施が求められる。また建物被害認定調査では、被災した建物の被害程度を認定する調査であり、この調査をもとに災証明書が発行され、仮設住宅の入居や義援金の支給など被災者支援の基準となるため、迅速かつ正確な調査が求められる。しかし実際の調査現場では、被災地が広範囲にわたることや調査員の不足に加えて、経験や能力のばらつきが大きく、調査の長期化が問題となっている。そのため、大規模災害時においても、短時間で正確な調査を実施できる手法が求められている。

衛星画像や航空写真など上空から撮影した被災地域の画像は、一度の撮影で複数の被災建物の情報が得られるため、大規模災害時における被害状況の把握には非常に有効であると考えられる。

近年、人工知能の分野において深層学習が注目されている。なかでも画像認識においては、畳み込みニューラルネットワーク (CNN) を用いることで高い判別精度が得られている。この手法を用いて航空写真から建物被害判別をおこなう研究がなされている。たとえば石井ら¹⁾では、兵庫県南部地震の被災画像を用いて、航空写真および地上写真の建物被災度判別の可能性について検討しており、「全壊」と「全壊以外」といった 2 クラスの判別では、ある程度の精度で判別可能であることが報告されている。しかし、3 クラス以上の被害判別についてはほとんど検討されていない。

そこで本研究では、航空写真および地上写真に CNN を適用させて、3 クラスの建物被害判別の可能性について

検討する。

2. CNN の概要 および使用データ

(1) CNN の概要

CNN の計算は、使用言語は Python を用い、フレームワークには Chainer を使用した。

CNN のモデルは、Network in Network²⁾ (NIN) を利用した。NIN における層構成およびハイパーパラメータは、Chainer で公開されている ImageNet モデル³⁾ を利用し、出力層のみを本研究に適した出力値に変更した。本研究における CNN のモデルを図 1 に示す。本プログラムでは、227×227pixel の画像を入力、画像の正規化を行い、各ピクセルの濃度値を 0~1 に変更したデータを CNN に入力している。学習条件として、学習のミニバッチサイズは 100 とし、学習の反復回数を 2000 回、最適化手法には Adam⁴⁾ を用いた。



*MLPConvとは、Multilayer Perception Convolutionの略
**GAPとは、Global Average Poolingの略

図 1 本研究で使用した CNN の層構成

(2) 使用データ

a) 航空写真

2016 年熊本地震において甚大な被害が発生した益城町を対象とし、(株)パスコが撮影した斜め航空写真を利用した。1 枚の航空写真には、数十棟から数百棟の建物が写っている。そこで、建物が画像の中心にくるように正方形に切り出し、227×227pixel にリサイズした。図 2

に航空写真および現地写真の画像の切り出し方法を示す。次に、これら切り出した画像にラベル付けを行った。航空写真による被害判読には、上岡らによる航空写真による被害チャート⁵⁾を利用した。その判読基準 (Damage Grade: D0 から D5 までの 6 区分) をもとに画像 1 枚ごとに、被害なしを表す D0 から倒壊を表す D5 の 6 区分にラベル付けを行った。

b) 地上写真

1996 年兵庫県南部地震および熊本地震において撮影された地上被災写真を用いた。兵庫県南部地震の被災写真は、震災復興都市づくり特別委員会の建物被災度判別結果について、建築研究所がデジタル化したデータ⁶⁾を利用した。熊本地震の被災写真は、著者らによる現地調査によって撮影した写真を利用した。さらに、無被害建物の写真については被災していない地域で撮影した建物画像を用いた。

本研究では、建物被害認定調査における木造住宅の外壁を対象として検討した。まず、被災写真から外壁の損傷がある部分を画像の中心にくるように抽出し、227×227pixel にリサイズした。次に、切り取った画像にラベル付けを行った。建物被害認定調査では、各部位の被害程度を判別するための代表的な被害写真が「災害に係る住家の被害認定基準運用指針 (損傷程度の例示)⁷⁾」に示されている。この損傷程度の例示には、部位ごとに損傷程度が程度 I から程度 V の 5 段階に分けられ、それぞれの代表的な損傷写真が示されている。ここで「被害なし」の区分を追加し 6 段階とした (図 3)。図 3 を参考に、画像 1 枚ごとに「被害なし」から「V」の 6 区分にラベル付けを行った。



図 2 画像の切り出し方法

	被害なし	I	II	III	IV	V
内閣府						
損傷の例示	被害なし	わずかなひび割れが生じている	仕上げ材の剥落が生じている	仕上げ材が剥落している	仕上げ材が剥落しており、下地材にひび割れが生じている	仕上げ材が剥落しており、下地材に破損が生じている

図 3 損傷区分写真の一例

3. 航空写真による建物被害判別

(1) データセットの作成

CNN に入力するデータセットを作成した。まず初歩的な検討として 6 段階の Damage Grade ではなく、「被害なし」と「被害あり」の 2 クラスに単純化して検討した。CNN では、各クラスにおける画像枚数をそろえることが好ましいとされている。そこで、「被害なし」の画像を「被害あり」の画像と同じ枚数になるようにランダムに抽出し同じ枚数にそろえた。さらに、これらの画像を 6:4 の割合で訓練データと検証データに分けた。表 1 に 2 クラスにおけるデータセットを示す。

次に、3 クラスの判別について検討した。3 クラスでは、D0 を「被害なし」、D1 と D2 を「被害小」、D3 から D5 を「被害大」とした。この際、各クラスの画像枚数は

「被害大」が最も少なかったため、「被害なし」と「被害小」の画像枚数を「被害大」の画像と同じ枚数になるようにランダムに抽出し同じ枚数にそろえた。さらに、これらの画像を 6:4 の割合で訓練データと検証データに分けた。表 2 に 3 クラスにおけるデータセットを示す。

また、過学習対策として、訓練データに対してデータ拡張を行った。コントラストの変化 (Hight, Low)、鏡像反転、ガウシアンノイズの追加を実施することで、データ数を 12 倍に拡張させたデータセットも作成した。

表 1 2 クラスにおける被害判別データセット

	被害あり		被害なし	
	訓練	検証	訓練	検証
切り出しデータ	1,011		1,011	
データ拡張なし	607	404	607	404
データ拡張あり	7,284	404	7,284	404

表 2 3 クラスにおける被害判別データセット

	被害なし		被害小		被害大	
	訓練	検証	訓練	検証	訓練	検証
切り出し画像	117		117		117	
拡張なし	71	46	71	46	71	46
拡張あり	852	46	852	46	852	46

(2) 学習結果

まず、2 クラスのデータセットに CNN を適用した。図 4 に学習結果を示す。図 4 より、データ拡張なしのデータセットでは、反復回数が 250 回を超えたところで損失率が大幅に増加しはじめ、過学習が発生した。一方、データ拡張ありでは、データ拡張なしよりも過学習を抑制することができた。表 3 にデータ拡張なしとデータ拡張ありのそれぞれの検証データに対する混同行列を示す。その結果、データ拡張なしの判別精度は、79.58%、データ拡張ありの判別精度は 81.44%であり、2 ポイント程度精度が向上していることが明らかになった。

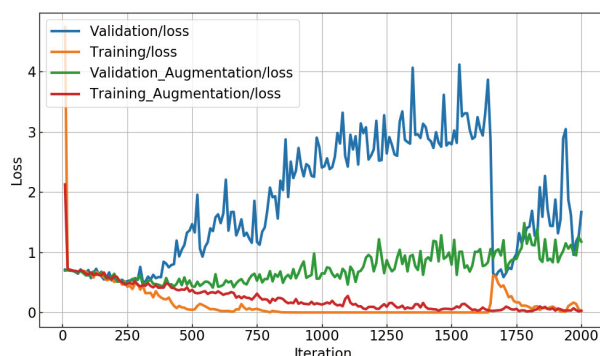


図 4 2 クラスにおける学習結果

次に、3 クラスに分けたデータセットに CNN を適用した。図 5 に学習結果を示す。図 5 より、データ拡張なしのデータセットでは、反復回数が 220 回を超えたところで損失率が大幅に増加しはじめ、過学習が発生した。一方、データ拡張ありでは、データ拡張なしよりも過学習を抑制することはできた。表 4 にデータ拡張なしとデータ拡張ありのそれぞれの検証データに対する混同行列を

示す。結果として、データ拡張ありの場合においても、判別精度は46.38%と低い結果となった。

表3 2クラス学習モデルを使用した検証データに対する混同行列

		Predicted Class		Predicted Class	
				被害なし	被害あり
拡張なし	True Class	被害なし	320	84	
		被害あり	81	323	
	accuracy = 79.58%				
拡張あり	True Class	被害なし	331	73	
		被害あり	77	327	
	accuracy = 81.44%				

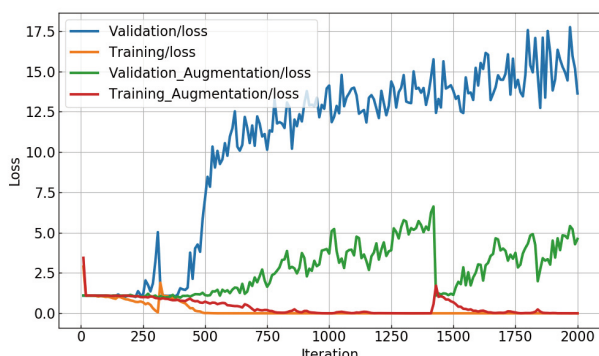


図5 3クラスにおける学習結果

表4 3クラス学習モデルを使用した検証データに対する混同行列

		Predicted Class			Predicted Class		
					被害なし	被害小	被害大
拡張なし	True Class	被害なし	25	14	7		
		被害小	11	13	22		
		被害大	5	20	21		
	accuracy = 42.75%						
拡張あり	True Class	被害なし	27	12	7		
		被害小	10	27	9		
		被害大	15	21	10		
	accuracy = 46.38%						

4. 地上写真による建物被害判別

(1) データセットの作成

まず航空写真の場合と同様に、「被害なし+Ⅰ+Ⅱ」と「Ⅲ+Ⅳ+Ⅴ」（以下、「被害小」と「被害大」と記す）の2クラスで検討した。このとき、「被害大」よりも「被害小」の方が画像枚数が少なかったため、「被害小」の画像を「被害大」の画像と同じ枚数にそろえるように、ランダムに抽出し同じ枚数にそろえた。さらに、これらの画像を7:3の割合で、訓練データと検証データに分けた。表5に2クラスにおけるデータセットを示す。

次に、「被害なし+Ⅰ」、「Ⅱ+Ⅲ」、「Ⅳ+Ⅴ」（以下、「被害小」、「被害中」、「被害大」と記す）の3クラスで検討した。3クラスにおいても2クラスと同様に画像枚数をそろえる操作を行った。さらに、これらの画像を7:3の割合で、訓練データと検証データに分け

た。表6に3クラスにおけるデータセットを示す。

また、過学習対策として、訓練データに対してデータ拡張を行った。画像の平行移動、コントラストの変化、鏡像反転、ガウシアンノイズの追加を実施することで、データ数を18倍に拡張させたデータセットも作成した。

表5 2クラスにおける被害判別データセット

	被害小		被害大	
	訓練	検証	訓練	検証
切り出しデータ	1,268		1,268	
データ拡張なし	761	507	761	507
データ拡張あり	13,698	507	13,698	507

表6 3クラスにおける被害判別データセット

	被害小		被害中		被害大	
	訓練	検証	訓練	検証	訓練	検証
切り出し画像	820		820		820	
拡張なし	493	327	493	327	493	327
拡張あり	8,874	327	8,874	327	8,874	327

(2) 学習結果

まず、2クラスのデータセットにCNNを適用した。図6に学習結果を示す。図6より、データ拡張なしのデータセットでは、反復回数が250回を超えたところで損失率が大幅に増加しはじめ、過学習が発生した。一方、データ拡張ありでは、データ拡張なしよりも過学習を抑制することができた。表7にデータ拡張なしとデータ拡張ありのそれぞれの検証データに対する混同行列を示す。その結果、データ拡張なしの判別精度は、83.62%、データ拡張ありの判別精度78.00%であり、データ拡張ありのデータセットの方が判別精度が低下する結果となった。その理由の一つとして、データ拡張の手法の問題ではないかと考えている。

次に、3クラスのデータセットにCNNを適用した。図7に学習結果を示す。図7より、データ拡張なしのデータセットでは、反復回数が350回を超えたところで損失率が大幅に増加しはじめ、過学習が発生した。一方、データ拡張ありでは、データ拡張なしよりも過学習を抑制することができた。表8にデータ拡張なしとデータ拡張ありのそれぞれの検証データに対する混同行列を示す。その結果、データ拡張なしの判別精度は、74.71%、データ拡張ありの判別精度は77.37%であり、3ポイント程度の精度向上が確認された。




図6 2クラスにおける学習結果

表 7 2クラス学習モデルを使用した検証データに対する混同行列

		True Class		Predicted Class	
				被害小	被害大
拡張なし	True Class	被害小	443	64	
		被害大	102	405	
accuracy = 83.62%					
拡張あり	True Class	被害小	420	87	
		被害大	136	371	
accuracy = 78.00%					

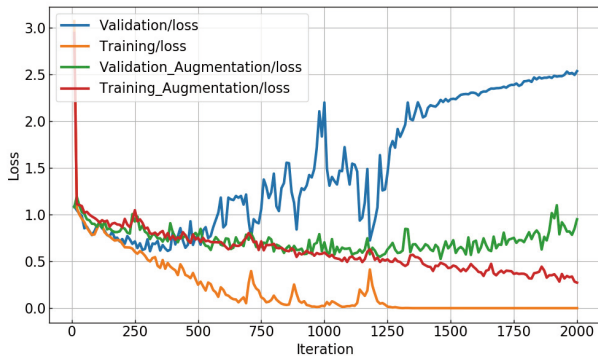


図 7 3クラスにおける学習結果

表 8 3クラス学習モデルを使用した検証データに対する混同行列

		True class		Predicted Class		
				被害小	被害中	被害大
拡張なし	True class	被害小	222	93	12	
		被害中	50	240	37	
		被害大	6	50	271	
accuracy = 74.71%						
拡張あり	True class	被害小	223	98	6	
		被害中	37	256	34	
		被害大	8	39	280	
accuracy = 77.37%						

(3) テストデータに対する被害判別

3クラス学習モデルにテストデータを入力し、その判別結果について検討した。テストデータは、損傷程度の例示に公開されている程度Ⅰから程度Ⅴの10枚の画像を用いた。図8に、3クラス学習モデルを用いたテストデータに対する判別結果を示す。図8より、10枚中6枚の画像が適切に判別した結果となった。特に、程度Ⅳと程度Ⅴの被害においては判別結果の信頼度も高い一方、程度Ⅰ、程度Ⅱ、程度Ⅲについては、信頼度が低く適切に判別できないという結果となった。

5. まとめ

本研究では、航空写真および地上写真にCNNを適用させ、建物被害判別の可能性について検討した。結果として、航空写真においては、「被害なし」と「被害あり」の2クラスであれば、80%程度の比較的高い精度で被害判別が可能であることが明らかになった。また、地上写

真においては、2クラス、3クラスとも75%-80%の精度で被害判別が可能であるという結果が得られた。しかし、判別ができなかった画像については、その要因を検討するまでには至っていない。現在、CNNではGrad-CAM⁸⁾という手法を用いることで、画像の何を判別しているのかをヒートマップで表す手法が開発されている。そこで、このような手法を用いて、判別結果の要因を検討することが今後の課題である。



図 8 3クラス学習モデルを用いたテストデータに対する被害判別（数字は信頼度）

謝辞

本研究で使用した航空写真は、(株)パスコから提供いただいた。また本研究を進めるにあたり、東京工業大学松岡昌志教授、ならびに大学院生の釜ヶ谷悠馬氏には大変有益なご意見をいただいた。記して謝意を表す。

参考文献

- 1) 石井友, 松岡昌志, 牧紀男, 堀江啓, 田中聡, 中村良介, 彦坂修平, 今泉友之, 藤田藍斗, 伊藤里保: 兵庫県南部地震の現地写真および航空写真を用いた深層学習による建物被災度判別, 地域安全学会梗概集, No. 39, pp. 85-88, 2016.
- 2) Min Lin, Qiang Chen, Shuicheng Yan: Network in Network, <https://arxiv.org/pdf/1312.4400.pdf>, 2018年4月20日現在.
- 3) Preferred Networks, inc.: Chainer, <https://github.com/chainer/chainer>, 2018年4月20日現在.
- 4) Kingma, Diederik, and Jimmy Ba.: Adam: A Method for Stochastic Optimization, arXiv:1412.6980, 2014.
- 5) 上岡洋平, 田中聡, 阿部郁男: 航空写真判読による2016年熊本地震における本震前の応急危険度判定調査の有効性に関する基礎的検討, 地域安全学会論文集, No. 32, 2018
- 6) 建設省建築研究所: 平成7年 兵庫県南部地震被害調査最終報告書, 1996.
- 7) 内閣府(防災担当): 災害に係る住家の被害認定基準運用指針 参考資料(損傷程度の例示), <http://www.bousai.go.jp/taisaku/pdf/jir-ai-lt.pdf>, pp. 1-15, 2018年4月20日現在.
- 8) Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, arXiv:1610.0239, 2017.