# 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

Recognition of Building Damage Grade Using Deep Learning Based on Ground and Aerial Photos Observed after the Kobe Earthquake

 $\circ$ 石井 友<sup>1</sup>, 松岡 昌志<sup>2</sup>, 牧 紀男<sup>3</sup>, 堀江 啓<sup>4</sup>, 田中 聡<sup>5</sup>, 中村 良介<sup>6</sup>, 彦坂 修平<sup>6</sup>, 今泉 友之<sup>6</sup>, 藤田 藍斗<sup>6</sup>, 伊藤 里保<sup>6</sup>

Yuu Ishii<sup>1</sup>, Masashi Matsuoka<sup>2</sup>, Norio Maki<sup>3</sup>, Kei Horie<sup>4</sup>, Satoshi Tanaka<sup>5</sup>, Ryosuke Nakamura<sup>6</sup>, Shuhei Hikosaka<sup>6</sup>, Tomoyuki Imaizumi<sup>6</sup>, Aito Fujita<sup>6</sup> and Riho Ito<sup>6</sup>

1東京工業大学大学院総合理工学研究科

Interdisciplinary Graduate School of Science and Engineering, Tokyo Institute of Technology <sup>2</sup> 東京工業大学環境·社会理工学学院

Department of Architecture and Building Engineering, Tokyo Institute of Technology 3 京都大学 防災研究所

Disaster Prevention Research Institute, Kyoto University

<sup>4</sup>インターリスク総研

InterRisk Research Institute & Consulting, Inc.

5 常葉大学 社会環境学部

Faculty of Social and Environmental Studies, Tokoha University

6 産業技術総合研究所人工知能研究センター

Artificial Intelligence Research Center, National Institute of Advanced Industrial Science and Technology (AIST)

Damage grade surveying is an important procedure for post-disaster recovery and reconstruction. In widespread disaster, this task takes enormous times and efforts. So, it has been required a more efficient surveying method. In order to solve this problem, deep learning technique was applied for damage grade recognition based on the dataset of ground and aerial photos acquired soon after the1995 Kobe earthquake. In the preliminary study, we divided two classes including severely damage and others, and then input them into CNN called LcNet to generate a prediction model. In the result, we found that the classification accuracies using ground and aerial photos are about 71% and 64%, respectively.

Keywords: Building damage, Ground photo, Deep learning, Convolutional Neural Network, Kobe earthquake

### 1. はじめに

地震などの災害発生後に被災地にある建物の被害程度 を調査することは、災害対応や復旧・復興計画を策定す る上で非常に重要である.一般には,建築技術者や自治 体の職員などが現地に赴き,対象建物の外観や内部を目 視により調査して損傷箇所を特定し、損傷が占める割合 によって被災度を認定する.しかし、このような詳細な 調査は災害規模が大きく被災地域が広域にわたる場合に, 対象となる建物数が増大するために人手が足りなくなり, 作業者への負担が重たくなること、判定に多大な時間を 要するため復旧・復興が遅れることなどの問題が指摘さ れている.

そのような問題に対する解決策として、被害を受けた 被災者自身が図面などに建物の被害の状況を整理し,建 物の被害程度を診断して申告する自己診断-自己申告モデ ル<sup>1)</sup>や, 被災地で撮影された対象建物の写真を遠隔地に 送り,遠隔地で建物の被害判定を行う遠隔建物被害判定 システム<sup>2)</sup>などが提案されている.これらの手法を用い ることで被災地における自治体職員などの負担を軽減す ることができると考えられる.しかし,被災者が申告し た内容を審査したり, 遠隔地で被害判定を行う場合には, 被害程度の判別に関する訓練を受けた人間が判別を行う 必要があり、より時間と労力を必要としない判別方法を 確立することができれば、さらなる負担の軽減につなが

### るものと考えた。

近年、機械学習法の一つである深層学習は画像認識な どの分野で従来の機械学習法を大きく上回る認識性能を 打ち出している. 中でも, 畳み込みニューラルネットワ ーク(Convolutional Neural Network : CNN)と呼ばれる手法 は画像を扱う課題において大きな成功を収めている.こ のCNNを利用して建物の被害程度の判別を自動で行うこ とができれば、災害時の建物の被害程度の調査に掛かる 時間と労力を削減できる. そこで本研究は, 1995年の兵 庫県南部地震で被災した建物を側面から撮影した現地写 真をCNNで学習させ、建物被災度の判別が可能であるの かを検証することを目的とする.

また, 航空写真や衛星画像などの上空から被災地域を 撮影した画像は、一度の撮影で複数の建物の情報を得ら れること,現地で写真を撮影する必要がないことなどか ら,広域災害時などにおいて被災した建物のデータを得 る手段として非常に有効であると考えられる. この航空 写真と現地写真を組み合わせてCNNで学習すれば、より 速やかに広範囲の被災度判別が可能になる. 今回は,現 地写真と航空写真それぞれをCNNに学習させ、建物被災 度の判別が可能かどうかについて検討した.

# データセット作成 2.1 対象地域と使用データ

本研究は震災の帯と呼ばれる被害集中帯であり,かつ 衛星写真と現地写真および建物の被災度情報を得られて いる兵庫県西宮市全域を対象地域とした.現地写真と航 空写真および被災度情報のデータ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<sup>3</sup>したデータに,西宮市り災調査データと 航空写真,写真撮影ポイントおよび写真を統合した西宮 Built Environment DB<sup>4</sup>(以後,西宮DBと呼ぶ)を用いた. ここで,被災度情報は西宮DBに含まれる西宮市り災調査 データを用いた.図1に示したように,西宮市り災調査デ ータの建物被災度は全壊,半壊,一部損壊,無被害の4段 階に分けられていたが,本研究では初期的な検討として, 半壊,一部損壊,無被害を新たな被害区分「その他」に 再分類し,「全壊」と「その他」を教師ラベルとした.

# 2.2 データセット作成

現地写真から作成するデータセットは、2.1節で述べた 教師ラベルおよび写真撮影ポイントから写真に写る建物 の被災度を特定し、その建物が画像の大部分を占めるよ うに画像をトリミングした.ここで,西宮市り災調査デ ータから被災度を特定することができた画像の数は「全 壊」が252枚、「その他」が173枚と少なかった、しかし、 深層学習は多くの教師データを学習させることで精度が 向上するため、データの水増しを行った.具体的には図2 に示したように、トリミング後の画像を一度512×512ピ クセルにリサイズし(図2上段左側の画像), その中のラン ダムな位置を中心に256×256ピクセルの画像を抽出する ことで、教師データを水増しした(図2上段右側の画像). 図2では1枚の画像から2枚の画像を抽出しているが、実際 に用いた教師データは1枚の画像から11枚の画像を抽出し, データの水増しによって「全壊」を2772枚、「その他」 を1903枚に増加させた.また、検証データはトリミング 後の画像(図2下段左側の画像)を256×256ピクセルにリサ イズしたものを用いた(図2下段右側の画像).また,航空 写真から作成するデータセットでは、図3に示したように、 西宮DBに含まれるある建物のポリゴンの重心を中心とし て128×128ピクセル(51.2m四方)の大きさになるように航 空写真を切り出し、中心の建物の教師ラベルと組み合わ せたものを用いた. これらの方法で作成したデータセッ トの内訳を表1に示す.

# 2.3 ネットワーク構成と学習

図4に本研究で使用したネットワーク構成を示す.この ネットワークは、衛星画像の土地被覆分類タスクで検証 されたLcNetと呼ばれるCNN<sup>5)</sup>を簡略化したものである. 東日本大震災の津波によって流出した建物を対象として、 震災前後2時期の高分解能衛星画像をこのネットワークに 学習させたところ、90%以上の精度で流出した建物の判 別ができたということが藤田らによって明らかにされて おりの、震災後の建物被害区分の判別方法として有効な ことが示唆される.本研究では、現地写真および航空写 真をこのネットワークで学習させた.また、学習のミニ バッチサイズは100とし、学習の反復は6000回とした.ま た学習率は0.001、減衰負荷係数は0.0005、モメンタムは 0.9として学習した.



図1 西宮市り災調査データと教師ラベルの違い





図2 現地写真のデータセットの作成方法



図3 航空写真のデータセットの作成方法

	教師データ		検証データ	
	全壊	その他	全壊	その他
現地写真	2772	1903	80	60
航空写真	7500	7500	1876	1876



# 3. 現地写真を学習させた実験

表2に現地写真を学習した判別モデルに検証データを判 別させた結果の混合行列を示す.ここで,実際は「全壊」 の画像を「全壊」と正しく判別した場合がTP(True Positive), 「その他」と間違えて判別した場合がFN(False Negative), 実際は「その他」の画像を「全壊」と間違え て判別した場合はFP((False Positive), 「その他」と正し く判別した場合はTN(True Negative)である. この結果よ り、この判別モデルの判別精度は71%程度であることが 分かった. 判別精度は以下の式より算出した.

判別精度 = (TP + TN)/(TP + FP + FN + TN)さらに、図5に現地写真を学習させた際の学習の反復に対 する検証データの損失と判別精度の推移を示す.本来, 赤い損失の線が反復が進むにつれて低下し、青い判別精 度の線が上昇するのが理想的な損失と判別精度の推移で ある.しかし、今回の学習では反復が進むにつれて赤い 損失の線が上昇している.また、青い判別精度も1500反 復を前に上昇が止まっている.このことから、このモデ ルは過学習に陥っているものと思われる.過学習の主な 原因としては、データ数の不足が挙げられる. 2.2節でデ ータを水増ししてデータセットを作成したが、512×512 ピクセルの画像内から256×256ピクセルの画像を抽出し て水増しを行ったため、少し位置がずれただけの似たよ うな特徴の画像が多くを占め、多様な特徴の画像の数を 増やせなかった. そのため, 教師画像に多く含まれる限 られた特徴が「全壊」や「その他」の唯一の特徴である と学習し、過学習に陥ったものと考えられる.また、図6 に学習に用いた教師データの例と検証データの例を示す. 上段(a),(b)が教師データの例,下段(c)が検証データの例 である.教師データは通常、(a)に示したように建物が写 っている画像が主であるが、(b)に示した画像の様に建物 が含まれていない、もしくは含まれていても範囲が非常 に狭いような画像も一部含まれていた. この画像は被災 度判別に重要であろう建物の側面情報が写っておらず, 関係ない特徴を学習してしまうために誤認識に繋がった ものと考えられる. さらに, (c)に示したように検証デー タは建物の全体像を写した画像を用いている.しかし教 師データは水増しによって領域が狭められており、建物 の全体像が写っている画像は少なかった. このような違 いも誤認識の原因となったと考えられる.よって、デー タ不足を補うために行ったデータ水増しが原因となり, 判別精度が向上していないと考えられる、今後、西宮DB に含まれるすべての現地写真を使うなど、教師データを 十分に増やすことができれば、データの水増しは不要と なり、過学習が抑えられ、より判別精度を向上できるよ うになると考えている.

表2 現地写真で学習させたモデルの混合行る	η
-----------------------	---

		判別結果	
		全壊	その他
実際	全壊	62 (TP)	18 (FN)
	その他	23 (FP)	37 (TN)





教師データ



(c) 検証データ

図6 現地写真の教師データ例と検証データ例

## 4. 航空写真を学習させた実験

表3に航空写真を学習した判別モデルに検証データを判 別させた結果の混合行列を示す.この結果より、この判 別モデルの判別精度は約64%であることが分かった. さ らに、図7に航空写真を学習させた際の学習の反復に対す る検証データの損失と判別精度の推移を示す.現地写真 の結果と異なり、緩やかに損失は低下し、判別精度が向 上していることが分かる. つまり, 過学習の兆候は見ら

れなかった.しかし、判別精度は64%程度と現地写真の 結果よりも低い値となった.図8に「全壊」ラベルの航空 写真の教師データ例を示す. すべて「全壊」に判別され ている画像であるが、この航空写真のみでは「全壊」の 被害を受けていると判断できる画像は少ない.これは, 今回用いた航空写真の空間分解能と教師ラベルの影響だ と思われる.今回用いた航空写真の空間分解能は40cmと やや粗い空間分解能である.そのために建物の屋根の被 害や建物周囲の瓦礫の飛散状況など,建物の被害を判別 する上で重要な情報が潰れているために「全壊」の建物 と判断することができない可能性がある.また、今回教 師ラベルとして用いた西宮市り災調査データは、現地で 建物の外観だけでなく,建物によっては内観を調査して 被害区分を判断した被災度情報である.そのため、外観 上の被害は「全壊」ではないが、内観の被害状況と総合 的に判断して「全壊」となったものや、建物の側面から 見た場合は「全壊」であるが、上面から見ると「全壊」 に見えない建物が存在し、上空から撮影した航空写真の みでは「全壊」と判別することができない可能性もある. このような画像を「全壊」の教師データとして用いた結 果,「全壊」の画像の判断基準が「その他」の画像の判 断基準と近くなってしまい、「その他」の画像の中で 「全壊」に誤判別されるFPのデータが増えたものと考え られる.また、上空から見ただけでは「全壊」と判りに くい被害の建物の画像が「その他」に誤判別されるFNの データも多く存在したために、判別精度が64%程度に留 まっているのではないかと考えている. 今後, より高分 解能の航空写真を用いることや、教師ラベルに用いる被 災度情報を建物の外観のみで判断された学会調査の被害 判定にするなど,深層学習による建物被災度判別の有効 性や限界を明らかにしていく予定である.また,誤判別 の原因を特定するためにも、判別モデルが何をもって 「全壊」と「その他」を判別したのかの判断基準を明ら かにすることも今後の課題であると考えている.

な, 加上ナ長 (ナロビビル ビノルの)(2011))
-----------------------------

		判別結果	
		全壊	その他
実際	全壊	1098 (TP)	778 (FN)
	その他	579 (FP)	1297 (TN)

### 5. まとめ

本研究では、西宮Built Environment DBの航空写真と現 地写真、建物被災度情報からデータセットを作成し、深 層学習による建物被災度判別の可能性を検討した.その 結果、現地写真を学習させた場合には70%程度となるこ とが分かった.現段階ではデータ数が少なく過学習が発 生しているため、教師データとなる画像とそれに対応す る教師ラベルを集める必要がある.また、航空写真を学 習させた場合は64%程度の判別精度となることが分かっ た.上空から見ただけでは「全壊」と判りにくい被害の 建物の画像が精度に影響を及ぼしていると考えられ、よ り高分解能の画像を用いることや教師ラベルに用いる被 災度情報自体を変更する必要があると考えている.

#### 謝辞

この研究は科学研究費補助金(課題番号:16K12843)の助成 を受けた.記して謝意を表する.





図8「全壊」ラベルの航空写真の教師データ例

#### 参考文献

- 田中聡: 建物被害判定自己診断システムの提案 -自己診断-自 己申告モデルの構築にむけて-,地域安全学会論文集(10), pp.233-242, 2008.
- 藤生慎ほか: 大規模地震災害向け遠隔建物被害判定システムに関する実証実験の実施と評価, 土木学会論文集A1(構造・地震工学), 70(4), pp. I\_263-I\_272, 2014.
- 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.
- 4) 呂恒倹ほか: 阪神・淡路大震災被災地Built Environmental Inventory データベースの作成に関する検討:西宮市の事例, 日本建築学会大会学術講演梗概集. B-2, pp.81-82, 1999.
- 5) 伊東里保ほか:ディープラーニングを適用した衛星画像からの土地被覆分類手法の評価,2016年度人工知能学会全国 大会,北九州市,2016.
- 藤田藍斗ほか:建築物被害度推定に向けた深層学習による 地物認識, https://docs.google.com/viewer?a=v&pid=sites &srcid=ZGVmYXVsdGRvbWFpbnxkcmlzand8Z3g6MmRiYjVj NDAxN2M1MzllOQ,減災情報システム第5回合同研究会, 2016,2016年9月1日確認