

# 2016年熊本地震後の空中写真を用いた 深層学習による建物被害分類

東京工業大学 環境・社会理工学院  
釜ヶ谷悠馬・松岡昌志

## Damaged Building Recognition of the 2016 Kumamoto Earthquakes Using Deep Learning with Aerial Photographs

Yuma Kamagatani, Masashi Matsuoka  
School of Environment and Society, Tokyo Institute of Technology

### Abstract

In wide-area disasters such as earthquakes, quick grasp of building damage situation is important in order to become a decision-making material for recovery and reconstruction planning. Although there is a visual interpretation using aerial photographs as a method of grasping building damage after a disaster, it takes a great deal of time and labor and there is a limit to the damage that can be readable from the building appearance. Also, for the purpose of quickly grasping building damage, estimation of damage is attempted by image processing by machine learning, but it is limited to extraction of severely damaged buildings. In this research, we conducted Convolutional Neural Network (CNN) for the 2016 Kumamoto Earthquakes to learn images of damaged buildings in the aerial photograph, generated classifiers for building damage, and estimated the building damage level based on the field survey etc. Also, for the purpose of supplementing the point that not all damage parts can be judged from aerial photographs, estimated seismic intensity at the location of the building was added to the input of learning of CNN. As a result, it was shown that there is a possibility of detailed estimation of building damage degree based on the severely damage probability output from CNN.

### 1. はじめに

熊本地震のような広域的な地震災害では、建物被災状況の迅速な把握が復旧・復興計画、生活再建の判断材料になるために重要である。被災状況の調査は、調査員に知識や経験が求められ、ほとんどの場合、現地に赴くこととなるため時間がかかる。建物被害を早急に推定する方法として、被災地を観測した人工衛星や航空機からの画像を用いた目視判読やテキスト解析等の画像処理があるが、多大な時間と労力が必要であったり、抽出できる建物被害は甚大なものに限られたりしており、実用化には課題が残る。近年では、建物の空中写真と被害程度を Convolutional Neural Network (以下、CNN) により学習させ、被害建物を抽出する研究<sup>1),2)</sup>が報告されている。しかし、CNNによる建物被害推定は汎用性に課題があり、過去の地震被害のデータセットに基づき事前に学習した分類器を他の地震に適用する際には、地域による建物の特徴の違いなどにより十分な判別精度が得られない場合がある。そのため、CNNの実用化のためには、地震発生後に得られる被災地域の一部の被害情報を学習させ、その分類器を用いて被災地全域の建物被害を推定する方法が考えられる。

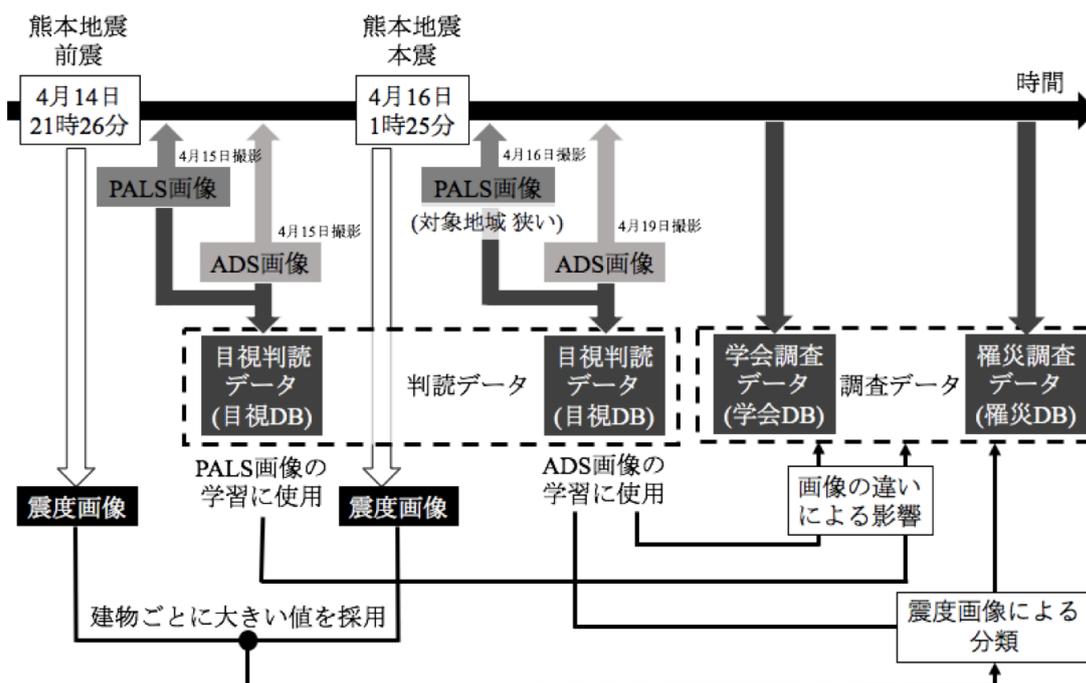


図1 使用するデータとCNNへの入力組み合わせ

本研究では、地震発生後に建物を撮影した画像と、その画像に基づき目視判読した被害程度を学習させ、被害認定調査等の被害程度を推定することを試みる。目視判読は確認できる被害箇所が限られ、また建物内部の被害も確認できないことから、被害を過小に評価してしまう。その結果、学習させる被害と目標とする被害に差が生じてしまうことが予想される。そこで、建物の立地場所における推定計測震度から建物ごとに震度画像を作成し、建物画像とともに学習することで、被害程度を細かく推定できる可能性があることを示す。

## 2. 使用データと研究の流れ

本研究では、熊本地震にて多くの建物が被害が確認されている熊本県益城町役場周辺を対象地域とした。学習には4月14日に発生した地震（以下、前震）の後と、15日の地震（以下、本震）の後にそれぞれ撮影された2種類の空中写真（ADS画像・PALS画像）と目視判読データ（以下、目視DB）を用いる。学習後、罹災調査における被害認定調査データ（以下、罹災DB）、建築学会による現地調査データ（以下、学会DB）の2種類を用いて評価を行う。使用するデータとCNNへの入力の組み合わせを図1に示す。

### 2.1 空中写真

本研究で用いるADS画像は航空機からラインセンサと呼ばれる航空カメラから連続的に直下視撮影された画像で、オルソ化してある。PALS画像は航空機から斜めに撮影された画像である。各画像は、建物が収まる大きさに切り出した後、256×256ピクセルにリサイズをしている。

### 2.2 目視判読データと調査データの比較

目視DBとは岡田・高井<sup>3)</sup>により作成された建物破壊パターンチャート内のDamage Gradeを参考にADS画像とPALS画像から目視により被害を判読したデータである。本研究の目視DBで扱うDamage-

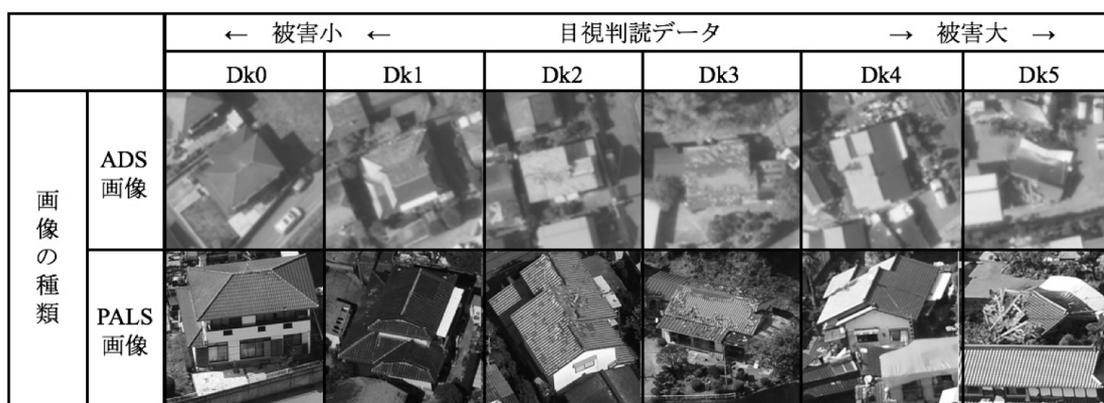


図2 目視判読データの各判読ラベルの画像例

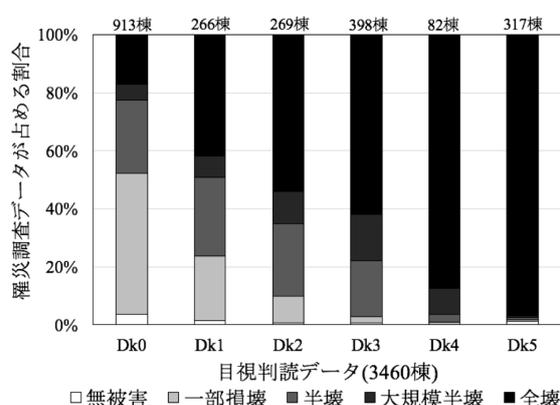


図3 目視判読データと罹災調査データの関係

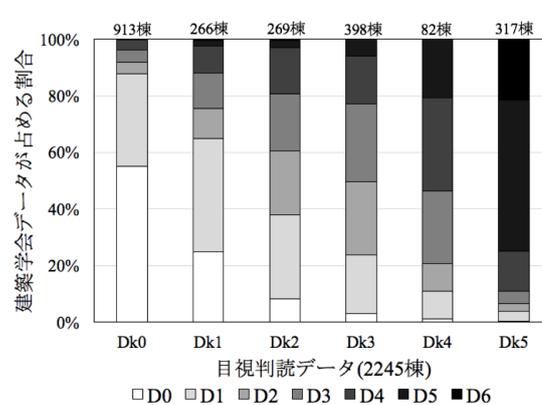


図4 目視判読データと建築学会データの関係

Grade は、「被害が確認できない建物」を「Dk0」、「壁面に亀裂・漆喰壁の小片落下」や「屋根瓦の一部が破損」を「Dk1」、「多くの壁に亀裂・漆喰壁の落下が目立つ」や「屋根瓦全体の 1/3 程度が破損」を「Dk2」、「ほとんどの壁に大きな亀裂・構造要素の一部が破壊」や「屋根瓦全体の 2/3 程度が破損」を「Dk3」、「壁面は重度の破壊・構造要素が連結性を失っている」や「屋根瓦のほぼ全てが破損及び一部が崩壊」を「Dk4」、「完全またはほとんど完全に崩壊」を「Dk5」とした。図2に各被害程度の例を示す。なお、前震後と本震後のそれぞれについて目視 DB を作成した。

罹災 DB は、「無被害」、「一部損壊」、「半壊」、「大規模半壊」、「全壊」の6つの被害程度に分けられている。被害程度は外観のみから行われたものと内部調査も行ったものが混在している。図3に本震後の目視 DB の被害程度に対する罹災 DB の被害程度が占める割合を示す。目視 DB の「Dk4」、「Dk5」は、罹災 DB における「全壊」が95%以上を占めており、罹災 DB と目視 DB との対応は良い。しかし、「Dk0」から「Dk3」については罹災 DB の被害程度が混在している。

学会 DB は、Damage Grade を参考に菊池ら<sup>4)</sup>により行われた外観調査をまとめた被害程度であり、「D0」から「D6」の7段階で表される。「D6」は、「D5」の内、建物が「崩壊」しているものを表す。図4に本震後の目視 DB の被害程度に対する学会 DB の被害程度が占める割合を示す。「Dk5」の約75%は学会 DB における「D6」であり、「D5」も含めると約90%を占める。また「Dk0」は、50%以上が「D0」であり、「D1」を含めると約90%を占める。しかし、「Dk2」から「Dk4」は罹災 DB の被害程度が混在している。罹災 DB および学会 DB は現地にて被害箇所を確認しているが、目視 DB は建物内部の被害や

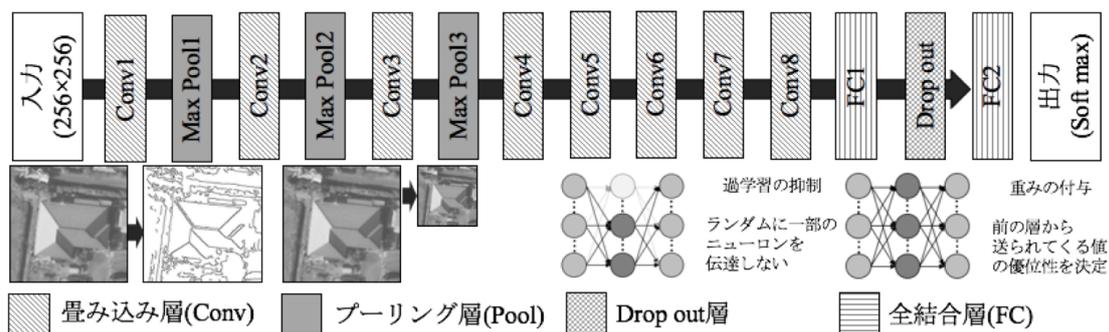


図5 本研究で用いる CNN の層構成

被害箇所が写っていないものがあるため被害を過小に評価したと思われる。これらより、本研究の CNN で学習に用いる目視 DB の被害程度は、他の被害程度に比べて信頼性が高い「Dk0」と「Dk5」を用いることとする。なお、各建物画像には1棟ごとに目視 DB、罹災 DB、学会 DB の被害程度を紐付けした。

### 3. ADS 画像と PALS 画像による学習と精度の検証

#### 3.1. CNN と学習のパラメータ

CNN とは、画像識別において高い精度が報告されている深層学習手法であり、画像内の特徴を抽出する畳み込み層とその特徴の画像内での位置ズレを吸収するプーリング層をニューラルネットワークに組み込んだものである。本研究で用いた CNN の層構成を図5に示す。層構成とは別に学習に使用するハイパーパラメータは、ミニバッチサイズを100枚、学習の反復回数を15,000回、学習率を0.001、減衰負荷係数を0.0005、モメンタムを0.9とした。

#### 3.2 データセットの作成

既往の研究<sup>1),2)</sup>で行なわれている CNN の入力画像は、直下視画像と現地写真であり、現地写真は直

表1 ADS 画像と PALS 画像の使用する各画像の枚数

		目視判読データ						
		Dk0	Dk1	Dk2	Dk3	Dk4	Dk5	total
ADS 画像	学習 データ	261 →6264	0	0	0	0	261 → 6264	522 →12528
	検証 データ	262	0	0	0	0	262	524
	評価 データ	1479	424	433	554	125	527	3542
PALS 画像	学習 データ	66 →1584	0	0	0	0	66 →1584	132 →3168
	検証 データ	61	0	0	0	0	61	122
	評価 データ	2855 実棟数 638	921 実棟数 209	823 実棟数 175	1139 実棟数 251	317 実棟数 70	2269 実棟数 368	8324 実棟数

下視画像に比べて分類精度が高いことが報告されている。これは、建物壁面の被害の確認が写り込んでいるためと考えられる。そこで、ADS 画像（直下視）と壁面情報を含む PALS 画像をそれぞれ学習させ、PALS 画像が被害推定に有効かを確認する。

表 1 に使用する ADS 画像と PALS 画像の枚数を示す。「学習データ」とは、学習時に CNN に入力する画像である。今回は、過学習（学習により作成される学習モデルが学習画像に過剰に適合してしまい汎化性能が低下すること）を抑制する目的で 24 倍（90 度ごとに回転と鏡像反転、コントラストの増加と低下）の水増しをおこなった（水増した画像数は表内の「→」以降に表示）。「検証データ」とは、学習が繰り返される度に作成される学習モデルに入力する画像で、推定された被害程度と実際の被害程度とを比較し、この違いが少なくなるようニューラルネットワークの重みを決定するのに用いられる。これらとは別に、対象地域内のすべての建物画像から構成される「評価データ」を作成した。このデータを用いて、学習に用いた被害程度（「Dk0」と「Dk5」）の判別精度の検証を行うと共に、他の建物被害データ（罹災 DB と学会 DB）の判別の可否を明らかにする。ADS 画像と PALS 画像のどちらについても「評価データ」は本震後の画像を用いるが、「学習データ」と「検証データ」は、ADS 画像の学習は本震後の画像を用いるが、PALS 画像は本震後の撮影範囲が狭く、画像数が少ないため前震後の画像を用いた。

### 3.3 学習の推移と検証

図 6 に ADS 画像と PALS 画像の学習による判別精度と誤差の推移を示す。ADS 画像は、学習の反復が 9,000 回前後で判別精度がピークに達し、以降は 87%程度である。PALS 画像は、学習の反復回数が 2,000 回程度で 85%程度となり、以降は 80%程度である。この違いは、PALS 画像は学習に用いている画

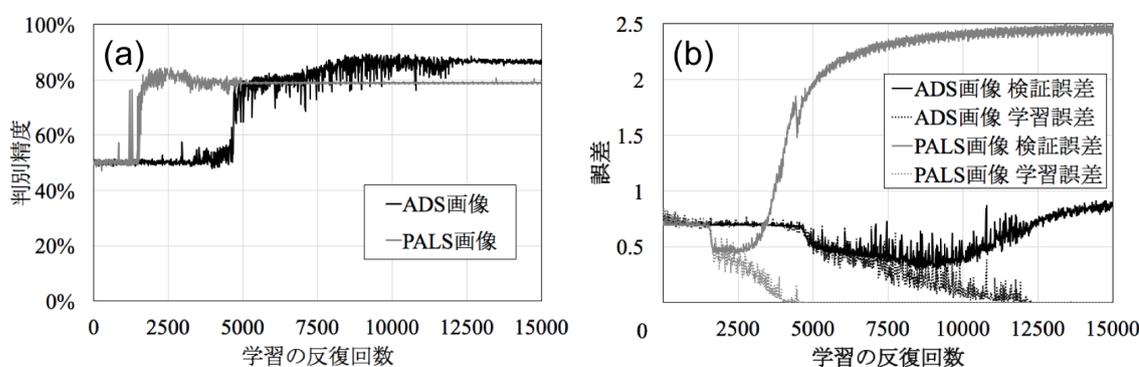


図 6 ADS 画像と PALS 画像の学習の推移, (a) 判別精度の推移, (b) 誤差の推移

表 2 各データセットにより作成した学習モデルによる判別結果（建物数）と建築学会データとの比較

		CNNによる判別結果											
		ADS画像				PALS画像				ADS画像+震度画像			
		Dk0	Dk5	total	producer's accuracy	Dk0	Dk5	total	producer's accuracy	Dk0	Dk5	total	producer's accuracy
建築学会データ	D0	538	45	583	92.3%	282	55	337	83.7%	534	49	583	91.6%
	D1	434	132	566		293	48	341		468	98	566	
	D2	91	149	240		74	13	87		136	104	240	
	D3	100	167	267		123	28	151		136	131	267	
	D4	73	159	232		154	46	200		93	139	232	
	D5	30	189	288	88.9%	158	50	208	24.0%	34	185	288	86.8%
	D6	2	67			41	23			4	65		
	total (D0+D5+D6)	1268 (570)	908 (301)	2176 (871)		1125 (481)	263 (128)	1324 (545)		1405 (572)	771 (299)	2176 (871)	
user's accuracy	94.4%	85.0%		91.2%	58.6%	57.0%		65.1%	93.4%	83.6%		90.0%	

像の枚数が少なく、被害の特徴も少ないためであると考えられる。誤差は判別精度の上昇とともに低下した後、判別精度が安定する頃には、検証誤差が上昇を始めている。この現象は過学習と呼ばれる。そこで、ADS 画像の学習では過学習が始まる前の 8,600 回、PALS 画像の学習では 2,200 回の状態（学習済みモデル）を用いて評価用データの評価を行い、目視判読データおよび 2 種類の現地調査データの判別結果を比較した。

学習済みモデルに評価用データの画像を入力すると、その画像が何パーセントの確率で「Dk5」であるかを表す指標（以下、確信度）が出力される。この確信度が 50%以上を「Dk5」、50%未満を「Dk0」として判別結果をまとめた。一例として表 2 に学習済みモデルによる判別結果と学会 DB の被害程度との比較を示す。PALS 画像は、ひとつの建物を様々な方向から撮影しているため、同じ建物でも画像ごとに異なる確信度が出力される。本研究では、それらの平均値を用いることとする。学習時の判別精度（図 6 参照）では、ADS 画像と PALS 画像はどちらも 80%以上の高い値が得られているが、表 2 に示す学会 DB を評価対象にした場合には PALS 画像は ADS 画像に比べて判別精度が低いことがわかる。その原因として本研究で用いたデータセットの枚数が PALS 画像は極端に少かったことが原因として考えられる。

#### 4. 震度画像を追加した学習と精度の検証

##### 4.1 データセットの作成

各建物の立地場所における計測震度の推定値<sup>5)</sup>から震度画像を作成し、ADS 画像とともに学習時に入力することで目視 DB からの学会 DB の被害程度の推定を試みる。震度画像の値は、計測震度を以下の式により 0 から 255 に変換している。なお、ADS 画像は 3 章で用いたものと同じである。

$$DN = \frac{255(INT - 5.0)}{7.5 - 5.0} \quad (1)$$

ここで  $DN$  は震度画像の値、 $INT$  は建物立地場所における前震と本震の計測震度のうち大きい値、7.5 と 5.0 は建物被害が想定される計測震度の範囲の上限と下限である。

##### 4.2 学習の推移と検証

図 7 に震度画像ありとなしの学習の推移を示す。震度画像を用いることにより、短い反復回数で判別精度がピークに達する。これは、1 回の学習で CNN に与えられる情報が増えたためであると思われる。表 2 の右欄には評価データにおける判別結果と学会 DB の被害程度との比較を示す。

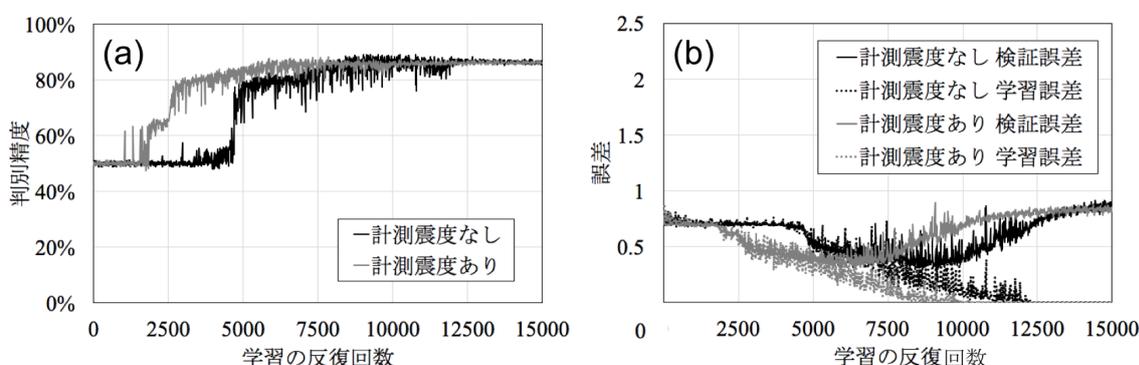


図 7 ADS 画像の計測震度ありとなしの学習の推移, (a) 判別精度の推移, (b) 誤差の推移

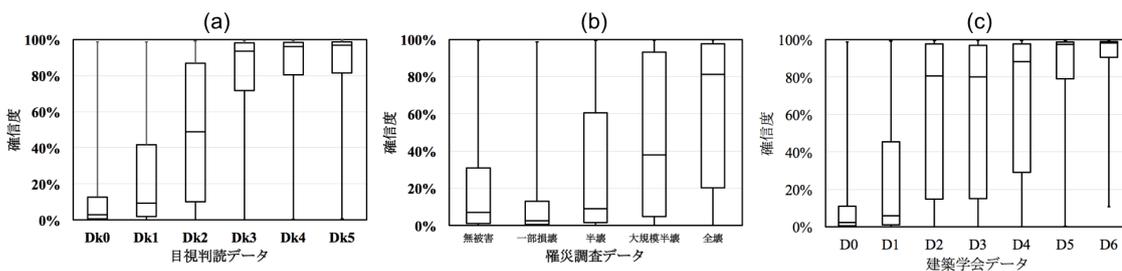


図8 ADS画像による各評価データの分類結果, (a) 目視判読データ, (b) 罹災調査データ, (c) 建築学会データ

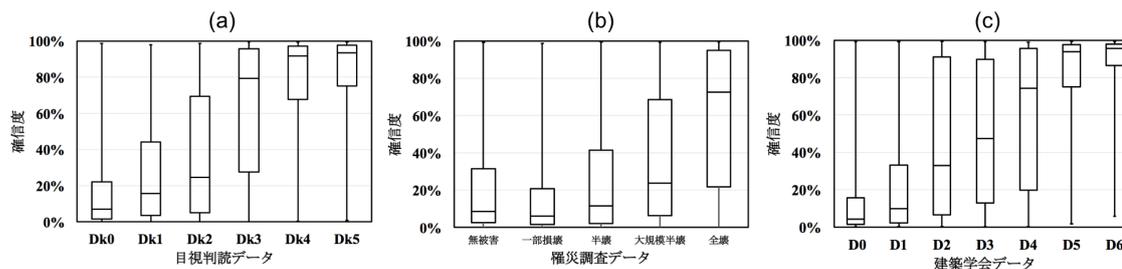


図9 ADS画像+震度画像による各評価データの分類結果, (a) 目視判読データ, (b) 罹災調査データ, (c) 建築学会データ

確信度に 50%の閾値を設定して行う判別では、震度画像の有無にかかわらず ADS 画像による「D0」と「D5」&「D6」の判別精度は 90%程度であることがわかる。また、表2内の「D1」から「D4」において、「Dk5」と判別された被害棟数数の割合に注目すると、学会 DB の被害程度が大きくなるにつれて「Dk5」に判別される建物数が多くなるのがわかる。

### 5. 被害程度の細分化への試み

目視判読の「Dk0」と「Dk5」の画像のみを学習して、被害程度を詳細に分類することを目的に、「Dk5」への確信度と被害程度の関係を検討した。ADS 画像の学習済みモデルによる評価データの確信度と各 DB の被害

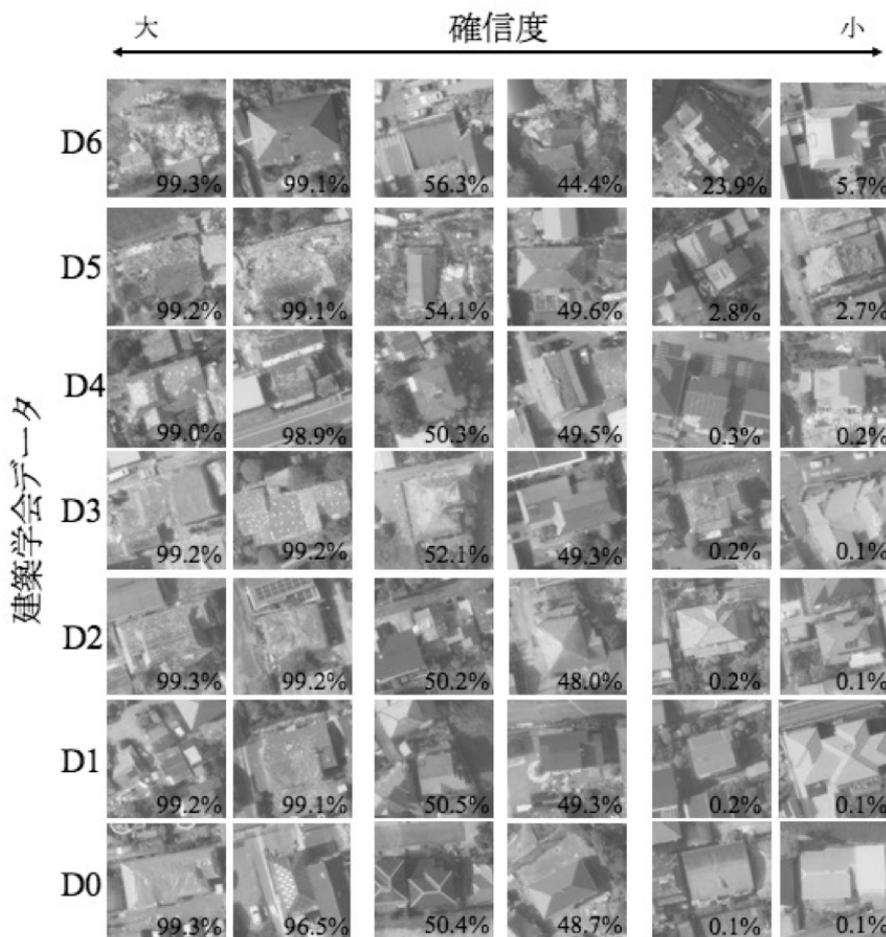


図10 学習済みモデルによる分類結果の例 (数値は確信度)

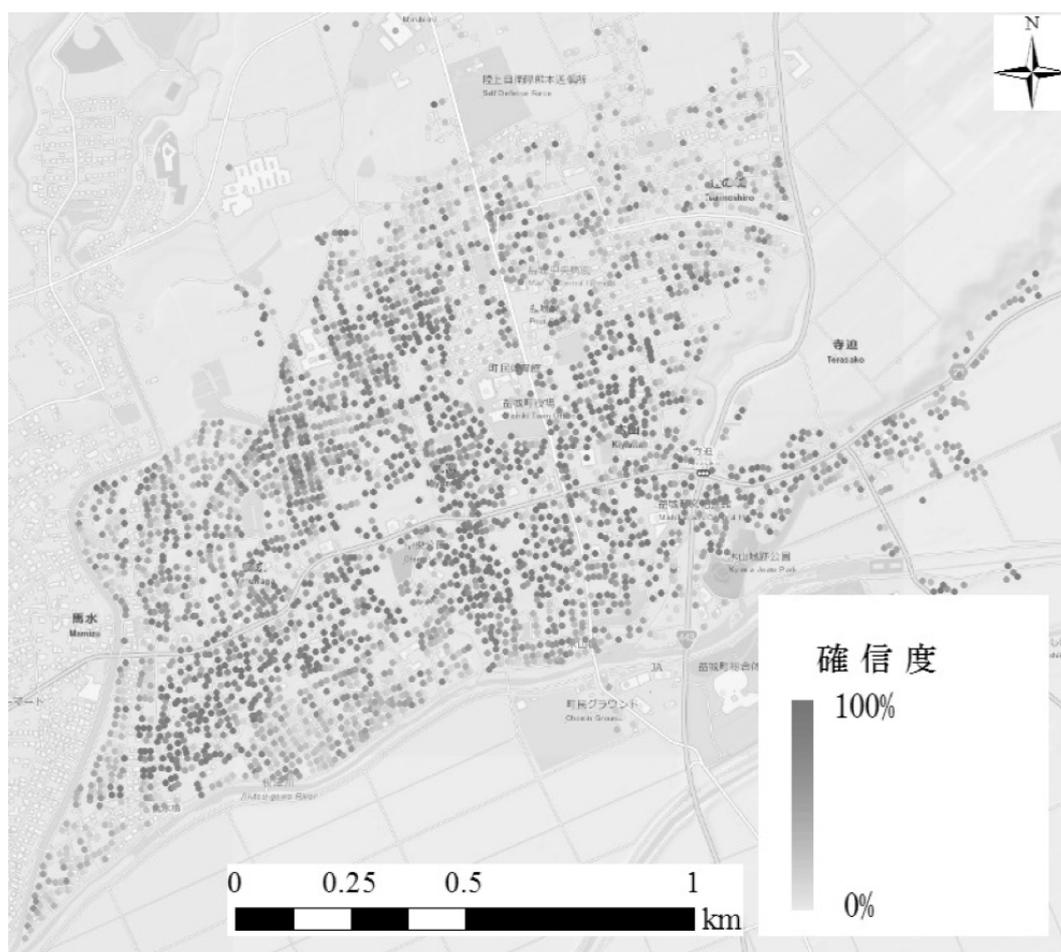


図 11 CNN による確信度の分布

程度を図 8 に、ADS 画像と震度画像の学習済みモデルによる評価データの確信度と各 DB の被害程度を図 9 に示す。罹災 DB への分類結果をみると、震度画像の有無にかかわらず、「一部損壊」の確信度は「無被害」の確信度よりも大きい傾向を示している。原因として、罹災 DB 内の「無被害」の枚数が極端に少ないためと思われる。学会 DB については、ADS 画像のみを用いた学習済みモデルによる分類において「D2」から「D4」の間に違いがほとんどみられないが、震度画像を加えた学習済みモデルでは、被害程度に応じて中央値にやや違いがみられる。そこで、ノンパラメトリックな有意差検定手法の 1 つである Mann-Whitney U test により、それぞれの確信度の傾向が、隣り合う被害程度との間に有意な差があるかを検定した。その結果、ADS 画像のみでは、「D2」から「D4」のそれぞれの被害程度の間には有意な差はみられなかったが、震度画像を追加することにより「D2」から「D4」の間に有意な差が生まれた。このことから、震度画像を加えることで、被害程度の細分化が行える可能性があることが明らかになった。

図 10 に学習済みモデルによる分類結果の例を示す。完全に倒壊している建物の確信度は、高い値を示している。一方、被害が小さい建物のいくつかにも高い値が示されている。原因として、学習には本震から 3 日後に撮影されたものを使用しており、屋根被害を受けた建物のブルーシートを被害の特徴として学習してしまったと考えられる。発災直後の画像を用いれば判別精度が向上すると思われる。図 11 に CNN による確信度の分布を建物ごとに示す。CNN の結果は建築学会 DB の被害分布と対応が良い。

## 6. まとめ

本研究では、熊本地震により被災した熊本県益城町を対象に ADS 画像と PALS 画像、目視判読データを用いて、CNN による学習を行い、調査データの分類を試みた。建築学会の調査データの Damage Grade における「D0」と「D5」&「D6」については、約 90%の精度で判別することができた。また、ADS 画像に震度画像を加えることで「D0」から「D5」の被害程度の間には確信度に有意な差が生まれることを明らかにした。よって、CNN より出力される確信度を用いて複数の被害程度への分類を行うことができる可能性を示した。

## 謝辞

本研究で使用した ADS 画像および PALS 画像は株式会社パスコから提供を受けた。また、益城町の被害建物悉皆調査データは日本建築学会九州支部より提供を受けた。記して謝意を表します。

## 参考文献

1. 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)、O-024、2015 年、pp479-480.
2. 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.
3. 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.
4. 菊池健児、田中圭：益城町の悉皆調査、2016 年熊本地震災害調査報告会資料、2016 年度日本建築学会大会 (九州) 災害部門 緊急報告会、2016 年
5. M. Matsuoka and N. Yamamoto: Web-based Quick Estimation System of Strong Ground Motion Maps Using Engineering Geomorphologic Classification Map and Observed Seismic Records, *Proc. 15th World Conference on Earthquake Engineering, PaperID:4016, 2012.*