

## リモートセンシングによる地震被害の把握

東京工業大学 環境・社会理工学院 松岡昌志  
東京工業大学 大学院総合理工学研究科 賀川健人, 石井 友

### 1 ALOS-2 衛星の PALSAR-2 画像から観た 2016 年熊本地震

#### 1.1 はじめに

2016 年 4 月 14 日以降に発生した日奈久断層帯および布田川断層帯に起因した一連の地震活動は、熊本県を中心に多数の死傷者と建物被害、ライフライン被害、地盤災害をもたらした。とくに、4 月 14 日 21 時 26 分の地震 (M6.5) では益城町で震度 7 を記録し、16 日 1 時 25 分の地震 (M7.3) では、益城町と西原村で震度 7 を記録するなど連続して大きな地震動に見舞われている。

本報では、2014 年 5 月に打ち上げられた ALOS-2 衛星に搭載された合成開口レーダ (PALSAR-2) により観測された画像から、熊本地震の地盤変動と被害を概観する。

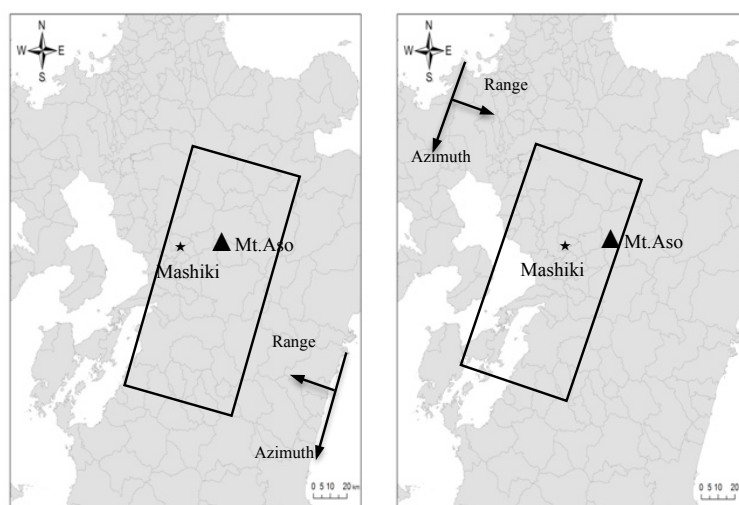
PALSAR-2 には、スポットライト (分解能  $1 \times 3m$ , 観測幅  $25km$ ), 高分解能 (分解能  $3m \sim 10m$ , 観測幅  $50km, 70km$ ), 広域観測 (分解能  $100m$ , 観測幅  $350km$ ) の 3 つの観測モードがあるが、ここでは観測頻度が最も高い高分解能モードの画像を使用している。分解能は約  $3m$ , HH 偏波である。表 1 に使用した PALSAR-2 画像のデータセットを示す。

なお、同じ観測条件の時系列画像からは、地表から反射したマイクロ波の振幅 (後方散乱強度) と位相の演算により、対象物の変化を抽出することが可能である。そこで、2014/11/14 と 2016/4/15 (M6.5 地震後) の組み合わせを条件①とし、2015/11/30, 2016/3/7, 2016/4/18 (M7.3 地震後) の組み合わせを条件②として以降での解析に用いることにした。観測条件と範囲を図 1 に示す。

表 1 使用した PALSAR-2 画像のデータセット

観測日	軌道	照射方向*	オフナディア角**
2014/11/14	下降	左向き	28.7°
2015/11/30	下降	右向き	32.8°
2016/3/7	下降	右向き	32.8°
2016/4/15	下降	左向き	28.7°
2016/4/18	下降	右向き	32.8°

\* 左向き：西北西に位置する衛星から東南東に向けてレーダを照射  
右向き：東南東に位置する衛星から西南西に向けてレーダを照射  
\*\* 衛星鉛直直下とレーダ照射方向のなす角度



(a) 条件①

(b) 条件②

図 1 観測地域 (矩形部分)

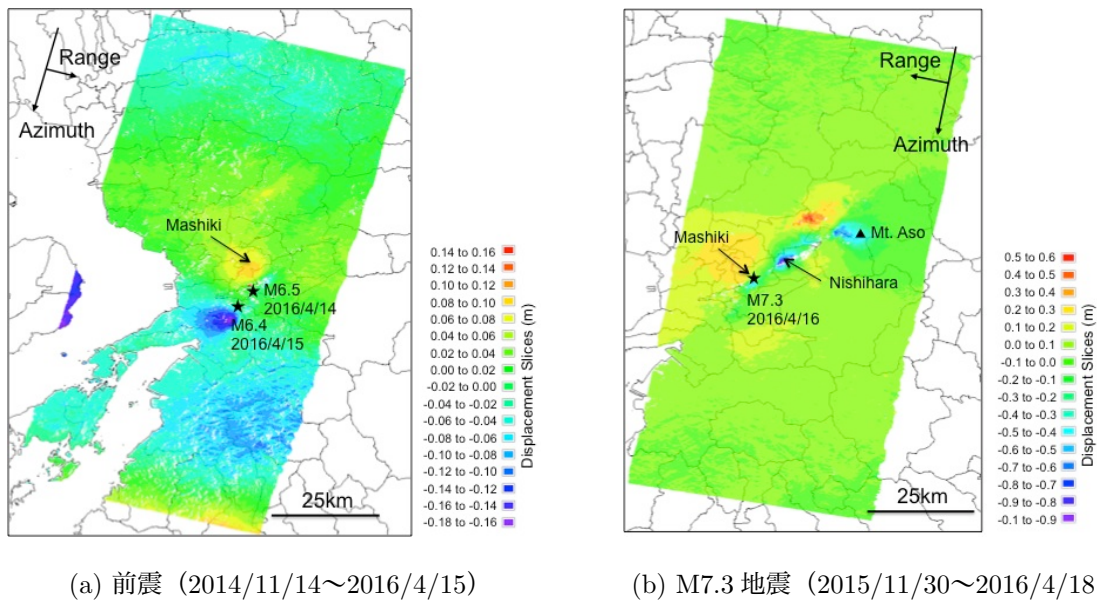


図 2 InSAR 解析による地盤変動分布

### 1.2 InSAR 解析による地盤変動

2014/11/14 と 2016/4/15 の条件①の観測ペアによる InSAR 解析の位相差から変動量に変換した画像を図 2a に示す。この 2 時期の間には 14 日 21 時 26 分の M6.5 の地震だけでなく、15 日 0 時 3 分に発生した M6.4 の地震も含まれているが、これらの地震がもたらした地盤変動は、震源の北側は衛星視線方向に約 12cm 近づき、震源の南側は約 16cm 遠ざかっている。図 2(b) には 2015/11/30 と 2016/4/18 の条件 ②の観測ペアによる InSAR 変動量を示す。断層が地表に現れたために地面が乱され、位相の干渉性(コヒーレンス)が低下している。したがって、断層近傍での変動量を正確に見積もることができないが、西原村では衛星視線方向に 1m 程度遠ざかっていることがわかる。通常の InSAR 解析では、これらのように衛星視線方向の変動しか測定できない。とくに、今回の地震を引き起こしたと考えられる布田川断層の走行は衛星進行方向にやや近いため、横ずれ成分の検出という点ではやや精度が落ちる。しかし、衛星進行方向の変動を検出することができる MAI (Multiple Aperture Interferometry) や、右向き・左向きの両方の照射方向から得られた 2 つのペアの InSAR 解析による 2.5 次元解析により、布田川断層に沿って上下変動を伴う右横ずれ変動が示されている<sup>1)</sup>。

### 1.3 コヒーレンス比<sup>2),3)</sup>による建物被害の抽出

2 時期の PALSAR-2 の観測期間内に、建物被害等のように地表に変化が生じた場合には、マイクロ波の位相も変化する。その変化の程度はコヒーレンスという指標で評価する




図 3 M7.3 地震 (2016/4/16) のコヒーレンス比の分布

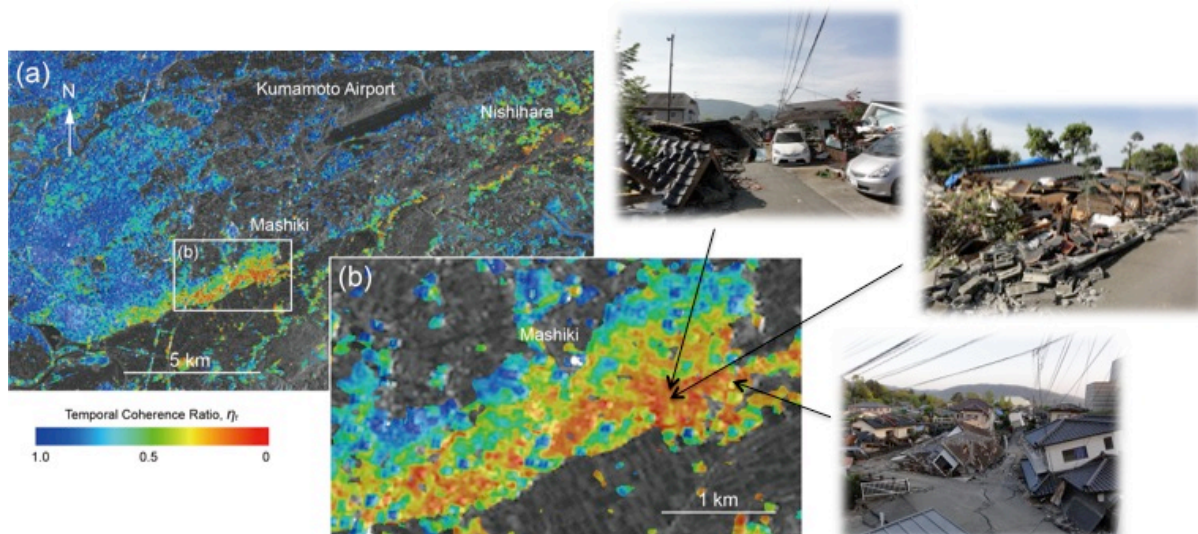


図4 M7.3地震(2016/4/16)のコヒーレンス比の分布(図3の拡大)と現地写真

ことが可能で、変化が大きい地域のコヒーレンスは低下する。したがって、地震前後の画像ペアから計算したコヒーレンスを用いることで建物被害を検出することが可能であるが、植生や水域のように季節変化や地震に無関係な変化も含まれるために、建物被害のみを分離することが容易ではない。そこで、地震前の画像を1シーン追加して、地震が発生していない状態での対象地域のコヒーレンス( $\gamma_{bb}$ )を地震前の画像ペアからあらかじめ求めておき、コヒーレンスの高い地域を選定する。そして、地震前後の画像ペアから得られるコヒーレンス( $\gamma_{ab}$ )を求めて両者を比較することで、地震に起因した変化を算出できるが、コヒーレンスは時間的な変化だけでなく、2つの衛星の空間的位置関係によっても変化することから、その値を衛星の観測条件から算出してキャンセルする。具体的には時間的なコヒーレンスの変化を次式のようにコヒーレンス比( $\eta_t$ )として算出する。

$$\eta_t = (\gamma_{ab}/\gamma_{bb})(\rho_{bb}/\rho_{ab}) \tag{1}$$

ここで、 $\rho_{bb}$  は地震前の2時期の衛星の空間的位置から求まるコヒーレンス、 $\rho_{ab}$  は地震前後の2時期の衛星の空間的位置から求まるコヒーレンスである。

2015/11/30, 2016/3/7, 2016/4/18 (M7.3地震後)の条件②のデータセットを用いて、コヒーレンス比を計算した結果を図3に示す。ここでは、 $\gamma_{bb}$  が0.6より大きい地域を選定している。地震前後に変化があった地域はコヒーレンス比が0~1の範囲にあると考えられ、値が小さいほど地表の変化が大きい(甚

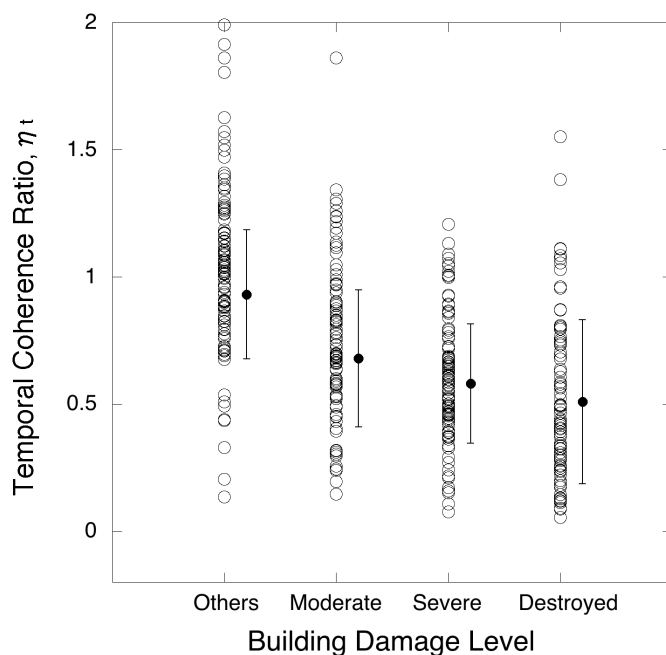


図5 2015年ネパール地震のバクタプルにおける建物被害程度と PALSAR-2 画像のコヒーレンス比の関係

大な建物被害)可能性が高い。図3をみると、益城町から阿蘇にかけて南西から北東方向にかけてコヒーレンス比は小さく、建物被害や地盤災害の影響が示唆される。図4には熊本市東部から益城町、西原村の拡大図を示す。益城町の南側の地域や西原村でコヒーレンス比が0.5以下の地域が広く分布し、現地での被害状況とも対応する。参考までに、2015年ネパール地震のバクタプル市における建物被害程度とコヒーレンス比の関係を図5に示す<sup>4)</sup>。建物の形状や構造、被害形態がネパールと日本では異なるため直接的な比較はできないが、コヒーレンス比が0.5程度あるいはそれ以下の地域は倒壊被害の建物が分布していると考えられる。

なお、2016/4/14のM6.5および4/15のM6.4の前震で益城町では建物被害が報告されている。前震に伴う建物被害の抽出については、地震前の2015/11/30と2016/3/7の条件①のペア、地震前後の2014/11/14と2016/4/15の条件②のペアを用いたコヒーレンス比から検討をしている。文献<sup>5)</sup>を参照されたい。

## 1.4 まとめ

2016年4月14日から熊本県を中心に発生した地震の被災地を観測したALOS-2衛星のPALSAR-2画像を用いて、InSAR解析により地盤変動を、コヒーレンス解析により建物等の被害の抽出を試みた。

## 2. 地震後に撮影された現地写真と航空写真を用いた深層学習による建物被災度判別の試み

### 2.1 はじめに

1995年1月17日に発生した兵庫県南部地震では、10万棟を超える建物が全壊、14万棟を超える建物が半壊となるなど、建物に甚大な被害が生じた<sup>6)</sup>。そのような建物被害の情報は、災害直後の初動対応やその後の復旧・復興計画、被災者の生活再建などの判断材料に用いる情報となるため、非常に重要とされる。災害における初動対応ではより早い対応が必要である。リアルタイム地震防災システム<sup>7)</sup>やリモートセンシング技術<sup>8)</sup>の利用が考えられるが、前者は精度の問題があり、後者は専門的な知識が必要とされる。

また、復旧・復興計画や生活再建などでは1棟単位の詳細な被害状況の把握が必要である。広域における調査には時間と労力がかかること、判定を行う人によって結果に差が生じることなどが問題とされ、迅速かつ正確な被害調査手法が求められている<sup>9)</sup>。建物の写真や図面を基に被災度を判定する手法<sup>10),11)</sup>などが考案されているが、専門家などが全ての建物の写真や図面を調査・審査することには変わりはなく、被災度判定の負担軽減や調査時間の短縮には限界がある。

近年、機械学習手法の一つである深層学習と呼ばれる手法が画像認識などの分野で注目を集めている。この手法は特徴量の設計が不要であるため、設計に必要な時間と労力を削減できる。また、深層学習のアルゴリズムの中でも、CNN(Convolutional Neural Network: 畳み込みニューラルネットワーク)と呼ばれる手法は人間を上回る精度で物体カテゴリ認識が可能であるという報告がなされている<sup>12)</sup>。CNNを用いて建物被災度を自動的に判別する手法を開発できれば、自治体職員や専門家などにかかる負担や時間を大幅に削減できる。

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対象に、航空写真および現地写真にCNNを適用することで、建物被災度判別の可能性を検討した。

### 2.2 CNNを用いた画像認識

#### (1) ニューラルネットワークとCNN

ニューラルネットワークとは人間の脳神経系を模した数理モデルであり、深層学習の基盤となる機械学習手法である。このニューラルネットワークに畳み込み層と呼ばれる画像の特徴抽出に特化した層とプーリング層と呼ばれる画像の位置ずれを吸収する層を組み合わせ合わせたものが CNN である。図 6 に本研究の学習に用いた CNN の層構成を示す。全結合層とは通常のニューラルネットワークの層を指す。また、本研究の学習のミニバッチサイズは 100 とし、学習の反復は 15,000 回、学習率は 0.001、減衰係数は 0.0005、モメンタムは 0.9 として学習を行った。これらは層構成も含めて超パラメータと呼ばれる。どのように機械が学習するのかを決定する指標である。

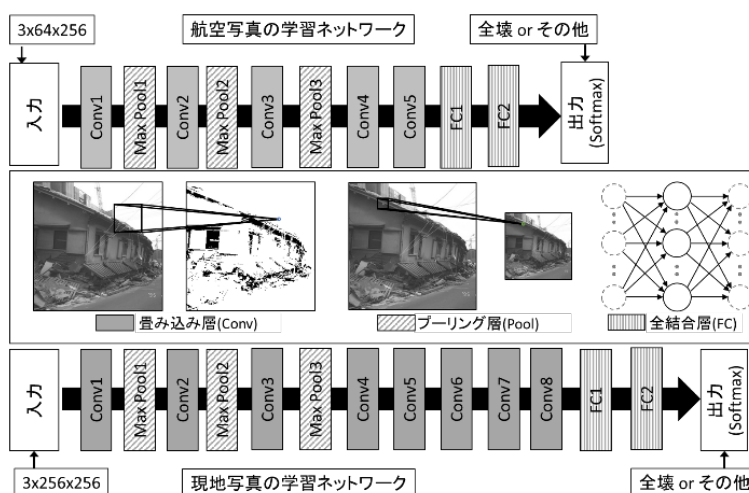


図 6 学習に用いた CNN の層構成

(2) 学習の推移と検証

CNN では学習と検証の段階が交互に行われる。それぞれの段階に用いるデータを学習データと検証データと呼び、異なるデータを用いるのが一般的である。学習段階では判別器の出力と正解との誤差が小さくなるように判別器の中身の更新を行い、CNN の判別器の精度を向上させる。一方、検証段階

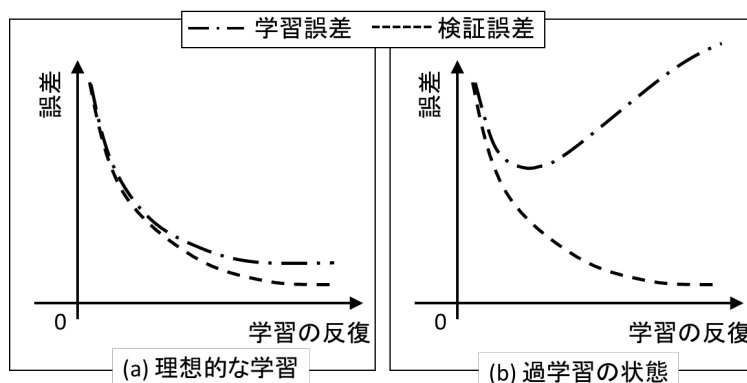


図 7 理想的な学習と過学習の状態

では判別器の出力と正解との誤差の増減を元に学習が正常に行われているのかの検証を行う。理想的に学習が行われた場合には図 7(a) のように学習誤差 (学習データに対する誤差) と検証誤差 (検証データに対する誤差) の値に大きな違いはない。一方で正常に学習が行われないと、図 7b のように学習誤差と検証誤差が大きく乖離する。この状態を過学習と呼び、過学習が発生すると学習データのみは正しく判別できるが、それ以外のデータは正しく判別できなくなり、判別器の汎用性がなくなる。過学習を避けるには、学習データの画像の反転・回転などを行い枚数を水増しするデータ拡張と呼ばれる方法などが知られている。

さらに、判別器の性能を評価する指標である判別精度は、表 2 に示す混合行列で表され、「正例」を判別器に与え、正しく『正例』であると判別できた場合を実際を TP(True Positive), 「正例」を『負例』と間違えて判別した場合を FN(False Negative), 「負例」を『正例』と間違えて判別した場合を FP(False Positive), 「負例」を『負例』と正しく判別できた場合を TN(True Negative) とすると、

表 2 混合行列の例

		判別結果	
		『正例』	『負例』
正解	「正例」	TP	FN
	「負例」	FP	TN

$$\text{特別精度} = (TP + TN) / (TP + FP + FN + TN) \quad (2)$$

として算出する。以後、入力画像のラベル (判別したいカテゴリ) を「」で囲み、判別器の判別結果を『』で囲む。

### 2.3 航空写真からの被害判別

#### (1) 対象地域とデータセット

本研究は兵庫県南部地震の被害集中帯の中でも、1 棟ごとの被災度情報が得られている兵庫県西宮市全域を対象地域とした。被災度情報など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した GIS データ 13) 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現地写真を統合した西宮 Built Environment DB14) (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。これは「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」を被害区分「その他」として統合し、「全壊」と「その他」を用いた。そして、建物ポリゴンと航空写真から、対象の建物が中心にくるように航空写真を 64 × 64 ピクセルで切り出した。「その他」のデータが「全壊」のデータより多かったため、「全壊」のデータ数と同じ数になるように「その他」のデータをランダムに抽出した。そのデータを 8 : 2 の割合で学習データ、検証データに分割してデータセットを作成した。また過学習対策として、学習データのみを鏡像反転し、データ数を 2 倍に増やすデータ拡張を行ったデータセットも作成した。それぞれのデータ数を表 3 に示す。

表 3 学習に用いたデータ (航空写真)


	「全壊」		「その他」	
	学習	検証	学習	検証
切り出し直後	9,376		9,376	
データ拡張なし	7,500	1,876	7,500	1,876
データ拡張あり	15,000	1,876	15,000	1,876

#### (2) 学習の推移と考察

図 8(a) にデータ拡張なし、図 8(b) にデータ拡張ありのデータセットで学習を行った場合の誤差の推移を示す。図 8(a) は学習の反復が 8,000 回を超えたあたりから検証誤差が増加しており、過学習が発生している。一方で図 8(b) は学習誤差と検証誤差に大きな乖離は見られず、データ拡張を行うことで過

表 4 判別器の混合行列 (航空写真)

		判別結果			
		データ拡張なし		データ拡張あり	
		『全壊』	『その他』	『全壊』	『その他』
正解	「全壊」	1,187 (TP)	689 (FN)	1,191 (TP)	685 (FN)
	「その他」	953 (FP)	923 (TN)	680 (FP)	1,196 (TN)



(a) データ拡散なし (b) データ拡散あり  
図 8 学習の推移 (航空写真)

習の発生を遅らせることが可能であることを確認できた。また、この学習によって生成された判別器の混合行列を表 4 に示す。判別精度はデータ拡張なしが 56.2%，データ拡張ありが 63.6%となり、後者は判別精度が 7 ポイント程度向上している。図 9 にデータ拡張ありの判別器の判別例を示す。画像上の数値は判別器がその画像が「全壊」であると判断した割合 (以後、確信度と呼ぶ) であり、0.5 以上を『全壊』、未満では『その他』と判別した。TP の上段の画像など、画像内の建物の屋根に大きな被害が出ていたり、周囲に瓦礫が散乱していることが確認できる画像では、確信度が 1 に近づいて『全壊』と判断する例が多かった。一方で、TN の下段の画像など、屋根に被害が出ていない画像や瓦礫が少ない画像では、確信度が 0 に近づいて『その他』と判断する例が多かった。しかし、FN の左上の画像では画像中心の建物に大きな被害が確認できる。また、FP の右下の画像では被害を確認できない。

今回の被災度情報として用いた西宮市り災調査データは、外観から調査を行う 1 次調査と内観から調査を行う 2 次調査に分けて調査されている。その 1 次調査では①外観による判定、②傾斜による判定、③部位による判定が行われるが、②や③の判定や 2 次調査の判定は建物のごく一部に注目して行なわれるため、建物全体を写す画像では被害がわからない場合がある。特に航空写真で確認できる建物被害は、屋根の被害や周囲への瓦礫の飛散状況であるため、「全壊」画像の中に被害を確認できない画像が含まれていた。一方、「その他」の建物であっても屋根に被害が生じた建物の画像や、中心の建物に被害が見られなくても、周囲の建物に被害が見られる画像など、「その他」の画像の中に被害を確認できる画像が含まれていた。その結果、誤分類が発生したものと考えられる。

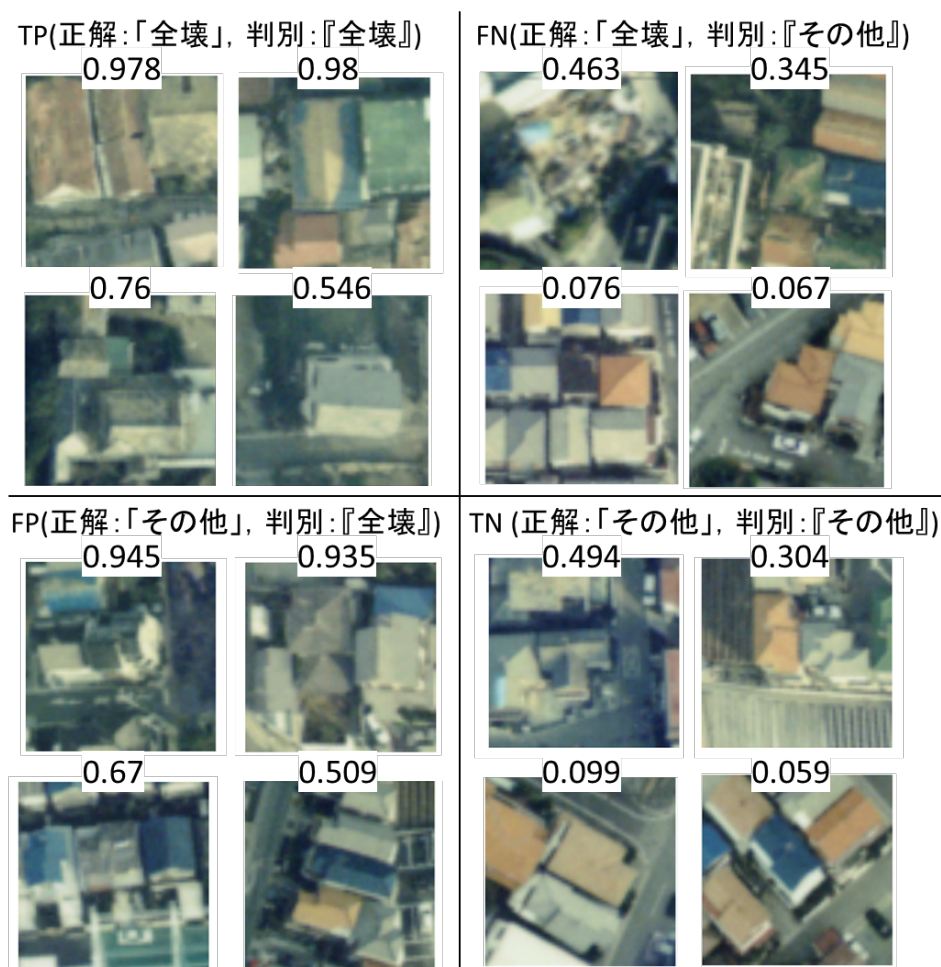


図 9 判別器の判別例 (航空写真)

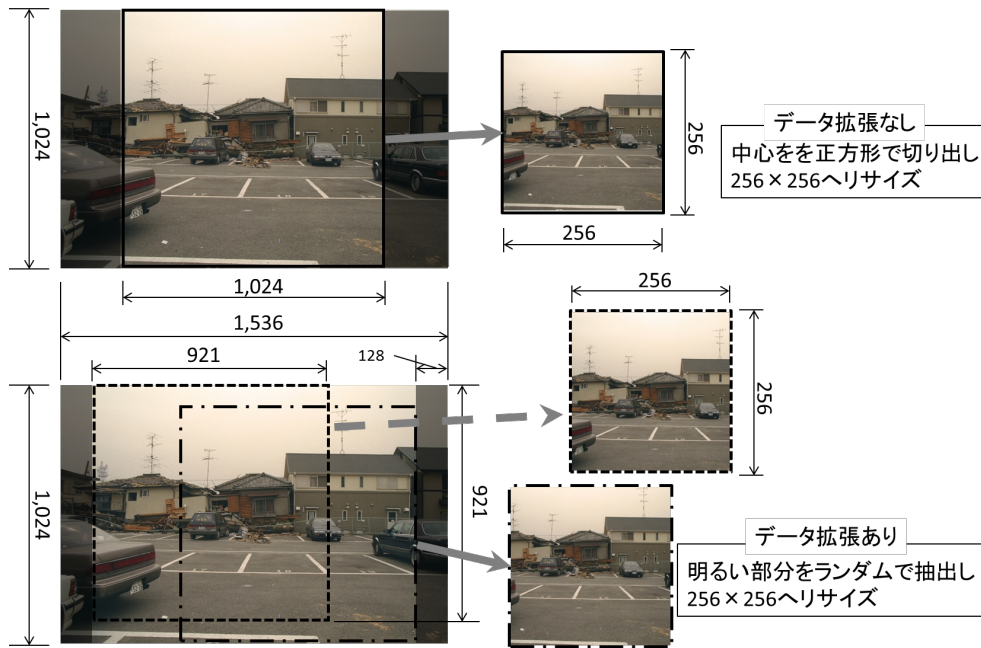


図 10 学習データの拡張方法（現地写真）

2.4 現地写真からの被害判別

(1) 対象地域とデータセット

西宮 DBに含まれる建物ポリゴンと現地写真，写真撮影ポイントから現地写真の中心に写る建物を機械的に特定し，建物が画像の中心に来るように画像を切り出した。図 10 に切り出した画像の例を示す。まず，現地写真の中心から  $1,024 \times 1,024$  のサイズで画像を切り出し， $256 \times 256$  にリサイズした。「その他」のデータが「全壊」のデータより多かったため，「全壊」のデータ数と同じ数になるように「その他」のデータをランダムに抽出した。

その中から 8:2 の割合で学習データ，検証データを抽出しデータセットを作成した。また，過学習対策として鏡像反転の手法を試行したが，過学習の抑制効果が薄かった。そこで画像の中心付近をランダムに  $921 \times 921$  のサイズで 20 回切り出し，データ数を 20 倍にさせたデータセットも作成

表 5 学習に用いるデータ数（現地写真）

	「全壊」		「その他」	
	学習	検証	学習	検証
切り出し直後	1,249		1,249	
データ拡張なし	999	250	999	250
データ拡張あり	19,980	250	19,980	250




図 11 学習の推移（現地写真）



した。それぞれのデータ数を表 5 に示す。

(2) 学習の推移と考察

図 11(a) にデータ拡張なし、図 11(b) にデータ拡張ありのデータセットで学習を行った場合の誤差の推移を示す。図 11(a) は学習の反復が 6,000 回を超えたあたりから検証誤差が大幅に増加し、過学習が発生している。一方、図 11(b) は検証誤差は微減しており、データ拡張による過学習の抑制を確認できた。判別器の混合行列を表 6 に示す。判別精度はデータ拡張なしが 54.8%，データ拡張ありが 73.6% であり、後者は判別精度が 19 ポイント程度向上している。図 12 にデータ拡張ありの判別器の判別例を示す。TP の上段の画像など、完全に倒壊している建物の画像では、確信度が 1 に近づいて『全壊』と判断する例が多かった。一方で、TN の下段の画像など、建物の形状が残っている画像では、確信度が 0 に近づいて『その他』と判断する例が多かった。しかし FN の左上の画像では、倒壊した建物が確認でき、FP の右下の画像では形状が残っている建物が確認できる。今回用いた現地写真の大半は対象建物の周囲領域を含む全景画像であった。そのため 2.3 節の考察と同様に、1 次調査の②傾斜や③部位による「全壊」判定されるような外部に大きな被害が確認できない画像が存在していた。また「その他」の画像では対象建物の周囲に瓦礫や倒壊建物が確認できる画像が確認できた。現地写真では屋根だけでなく壁面の被害を確認できる。壁面情報を含んでいることが、現地写真が航空写真よりも判別精度が高かった理由と考えられる。

表 6 判別器の混合行列 (現地写真)

		判別結果			
		データ拡張なし		データ拡張あり	
		『全壊』	『その他』	『全壊』	『その他』
正解	『全壊』	126 (TP)	124 (FN)	205 (TP)	45 (FN)
	『その他』	102 (FP)	148 (TN)	87 (FP)	163 (TN)

しかし FN の左上の画像では、倒壊した建物が確認でき、FP の右下の画像では形状が残っている建物が確認できる。今回用いた現地写真の大半は対象建物の周囲領域を含む全景画像であった。そのため 2.3 節の考察と同様に、1 次調査の②傾斜や③部位による「全壊」判定されるような外部に大きな被害が確認できない画像が存在していた。また「その他」の画像では対象建物の周囲に瓦礫や倒壊建物が確認できる画像が確認できた。現地写真では屋根だけでなく壁面の被害を確認できる。壁面情報を含んでいることが、現地写真が航空写真よりも判別精度が高かった理由と考えられる。



図 12 判別器の判断例 (現地写真)

## 2.5 おわりに

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、CNN と組み合わせた場合の建物被災度判別の可能性を検討した。その結果、航空写真と現地写真のどちらのデータセットでも過学習が発生したが、データ拡張による過学習対策を行うことで、航空写真では 63.6%、現地写真では 73.6% の精度で全壊とそれ以外の被災度に判別できた。

以上より、CNN を適用するには膨大なデータセットを必要とするものの、航空写真を用いると広域かつ早期の被災度判定に、現地写真を用いるとより正確な被災度判定に使える可能性があることがわかった。しかし、現状で判別可能な被害は倒壊など全壊の建物の一部に限られ、上空からのみでは判断できない建物被害や局所的な建物被害の判別は困難であった。今後は、斜め写真などの建物の側面情報を含んだ画像や被害部位に注目した画像も用いることで被災度判別の精度が向上すると考えられる。

### 謝辞

ALOS-2 衛星の PALSAR-2 画像は JAXA 大規模災害 WG の一環として JAXA から提供を受けた。西宮 *Built Environment DB* については、京都大学の牧紀男教授、インターリスク総研の堀江啓氏との共同研究の一環で利用した。記して謝意を表します。

### 参考文献

1. 国土地理院：平成 28 年熊本地震に関する情報，  
<http://www.gsi.go.jp/BOUSAI/H27-kumamoto-earthquake-index.html>, 2016.
2. 伊藤陽介，細川直史：干渉 SAR データを用いた地震被害度推定モデル，電気学会論文 C, Vol.122, No.4, pp.617-623, 2002.
3. Y. Ito, M. Hosokawa, M. Matsuoka: A Degree Estimation Model of Earthquake Damage Using Temporal Coherence Ratio, Proc. International Geoscience and Remote Sensing Symposium, IEEE, Vol.4, pp.2410-2412, 2003.
4. 松岡昌志：ALOS-2 画像を用いた 2015 年ネパール地震の建物被害判読，平成 27 年度第 2 回大規模災害衛星画像解析 WG 資料，2015.
5. 賀川健人，大申文誉，松岡昌志：2016 年熊本地震の被災地を観測した PALSAR-2 画像のコヒーレンスおよび後方散乱強度からの建物被害の抽出，地域安全学会梗概集，No.38, pp.185-186, 2016.
6. 内閣府：阪神・淡路大震災の概要と被害状況，内閣府 防災情報のページ，  
<http://www.bousai.go.jp/kyoiku/kyokun/pdf/101.pdf>, 平成 29 年 1 月 21 日確認.
7. 山崎文雄：リアルタイム地震防災システムの現状と展望，土木学会論文集，No.577/I-41, pp.1-16, 1997.
8. 三富創，松岡昌志，山崎文雄：最近の地震災害の空撮画像を用いた建物被害地域の自動抽出の試み，土木学会論文集，No.703/I-59, pp.267-278, 2002.
9. 藤生慎，沼田宗純，大原美保，目黒公郎：東日本大震災における建物被害認定調査の実態に関する分析，社会技術研究論文集，Vol.10, pp.96-105, 2013.
10. 田中聡：建物被害認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，No.10, pp.233-242, 2008.
11. 藤生慎，大原美保，目黒公郎：大規模地震災害時における遠隔建物被害認定システムの開発と評価，日本地震工学会論文集，Vol.12, No.7, pp.19-37, 2012.
12. K. He, X. Zhang, S. Ren, J. Sun: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, IEEE International Conference on Computer Vision (ICCV), arXiv:1502.01852, 2015
13. 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.
14. 呂恒儉，牧紀男，田中聡，林春男：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.