

画像解析・機械学習を用いた 熊本地震における 建物被害判別手法開発

防災科学技術研究所
内藤昌平

※本研究は総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム (SIP) 「レジリエントな防災・減災強化」によって実施された。
※航空写真撮影、目視判読、画像解析に関して株式会社パスコ様、機械学習手法の開発に関してみずほ情報総研株式会社様にご協力いただいた。


2018/04/14
NU-NIED 研究交流会

目次

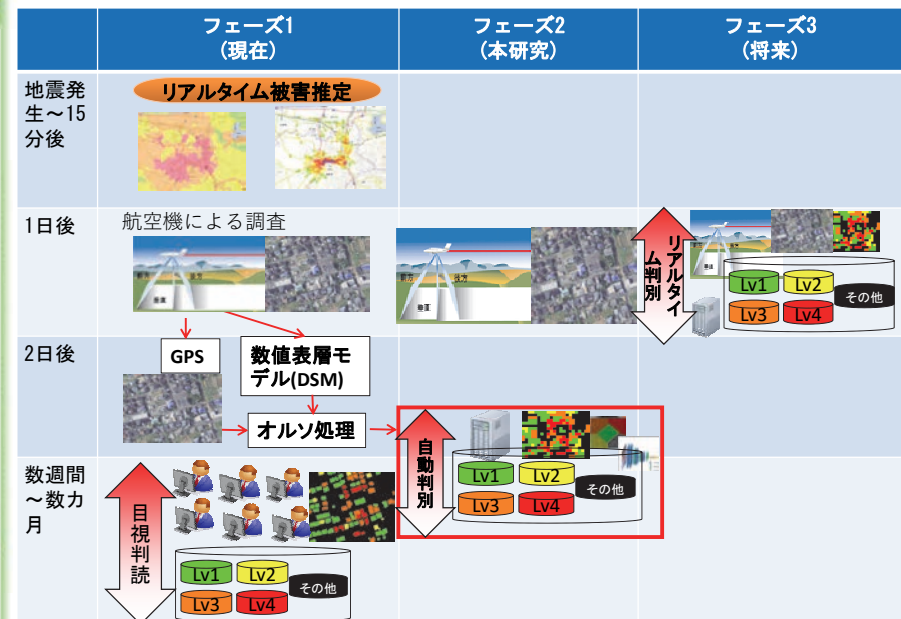
1. 研究の背景と目的
2. 航空写真目視判読にもとづく建物被害調査および訓練データの構築
3. 画像解析による建物被害抽出
 - 3-1. DSM差分
 - 3-2. ブルーシート抽出
 - 3-3. テクスチャ解析
4. 機械学習による建物被害判別
 - 4-1. 局所特徴量およびSVMを用いた手法
 - 4-2. 深層学習を用いた手法
 - 4-3. 判別結果の比較
 - 4-4. 深層学習による広域判別試行
5. 今後の研究計画

1. 研究の背景と目的


- 災害発生直後に被害状況を迅速に把握することは災害対応の上で重要。
- SIP5で開発中のリアルタイム被害推定・状況把握システムにより全国250mメッシュの被害推定が可能になりつつある。しかし推定結果には不確実性が伴うため、合理的な意思決定のためには巡回や目視等の正確な情報で補完することが必要。
- 航空機等を用いることで広域にわたる被災画像を迅速に取得可能である。一方で被害範囲が甚大・広域であるほど画像判読作業には多数の人手と時間を要する。
- 画像解析、機械学習手法を用いることにより画像から被害を自動判別し、より迅速な状況把握が可能になると考えられる。本研究では様々な手段によって取得された画像から被害を抽出し、リアルタイム被害推定情報を補完する状況把握技術の開発を目的とする。



航空写真による地震被害判別のタイムライン



2. 航空写真目視判読にもとづく建物被害調査 および訓練データの構築




熊本地震本震直後に取得された垂直オルソ画像（約1,800枚）を主に使用して建物被害を目視判読した。

■撮影範囲
熊本市（北区・東区・中央区・西区・南区）宇土市 宇城市 嘉島町 御船町 伊佐町 益城町 西原村 大津町 南阿蘇村 阿蘇市

訓練データ作成に利用した航空写真の撮影範囲

画像種別	方向	撮影日	撮影機関	解像度	枚数
航空オルソ画像	垂直	2016年4月16～20日	国土地理院	20cm	1,228
航空オルソ画像	垂直	2016年4月19日	株式会社パスコ	20cm	198
航空オルソ画像	垂直	2016年4月19日	株式会社パスコ	20cm	447


建物被害判読結果の入力方法




データの突合

ArcGISを用いて航空写真上の被害建物の位置に被害レベルを区分したポイントデータを作成後、国土地理院のポリゴンと突合した。

また、建物の形状から木造／非木造を区分し、新旧の航空写真を用いて建物の建築年代を1979年以前／以降に区分した。



国土画像情報（1974～1978年撮影）



オルソ画像（本震直後）

航空写真による建物被害判読基準

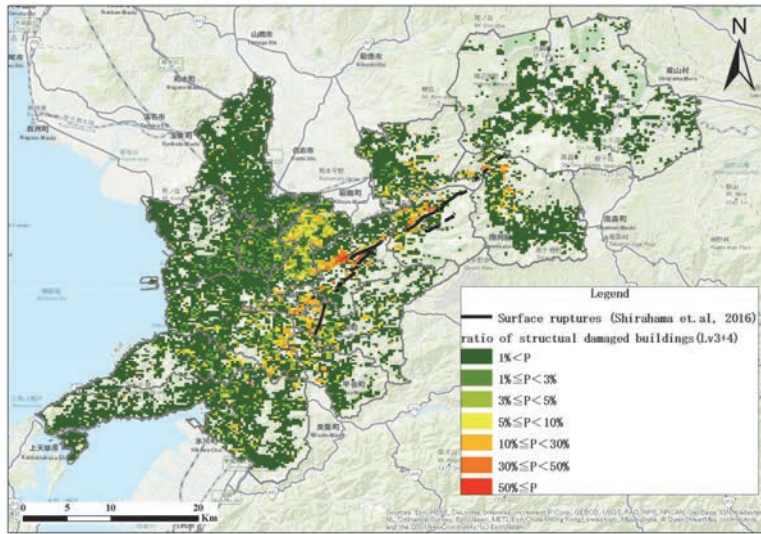
- ・使用した画像データ（撮影期間：2016年4月16～20日）
対象地域全域：垂直オルソ画像（20cm解像度）
一部地域：斜め画像（20cm解像度）、ヘリ画像（5cm解像度）
航空写真1枚分：DSM高さ差分データ
- ・使用したGISデータ
国土地理院が公開する「基盤地図情報（建築物）」（2014～2016年整備）

被害区分	（航空写真上の特徴）	バタンの対応 ※岡田・高井(1999)	画像の例
LEVEL1 （無被害）	被害なし	D0	
LEVEL2 （被害小）	屋根瓦の一部が崩落している ブルーシート面積が屋根の半分以下	D1	
LEVEL3 （被害中）	屋根瓦の大部分が崩落している ブルーシート面積が屋根の半分以上	D2, D3	
LEVEL4 （被害大）	建物が傾斜している、ずれ・ねじれが確認できる DSM高さが本震前後で3m以上変化 層破壊もしくは倒壊している	D4, D5	

建物被害判読データの突合結果




LEVEL3(被害中)+LEVEL4(被害大)建物の割合 (250mメッシュ毎)



合計約32万棟の建物について被害区分を行ったGISデータを作成した。目視判読作業には10名の技術者により約42日間を要した。判読速度は1人1日あたり平均1,000棟程度である。


機械学習用訓練データの構築



垂直オルソ画像および被害判読GISデータを用いて被害レベル1～4が概ね均等に含まれるように合計10,603棟分の訓練用画像を抽出した。また、建物領域毎の被害区分認識のために建物ポリゴンを使って色分けしたマスク画像を作成した。

レベル1 被害無 (3,317棟)	レベル2 被害小 (2,570棟)	レベル3 被害中 (2,604棟)	レベル4 被害大 (2,112棟)


3. 画像解析による建物被害抽出
3-1. DSM差分



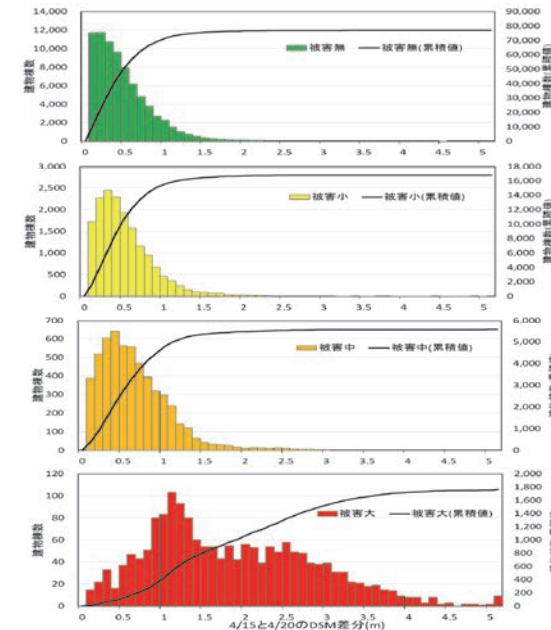
4/15 (前震直後)の航空写真から作成したDSMと4/20 (本震直後)の航空写真から作成したDSMとの差分を作成した。



DEM(Digital Elevation Model)
建物ポリゴン毎に標高差分データの平均値を計算



前震後と本震後のDSM差分と建物被害レベルとの関係



LEVEL1
データ数: 77,026
平均値: 0.434
中央値: 0.342
標準偏差: 0.392


LEVEL2
データ数: 16,779
平均値: 0.467
中央値: 0.384
標準偏差: 0.372

LEVEL3
データ数: 5,563
平均値: 0.600
中央値: 0.514
標準偏差: 0.456

LEVEL4
データ数: 1,761
平均値: 1.794
中央値: 1.617
標準偏差: 1.020

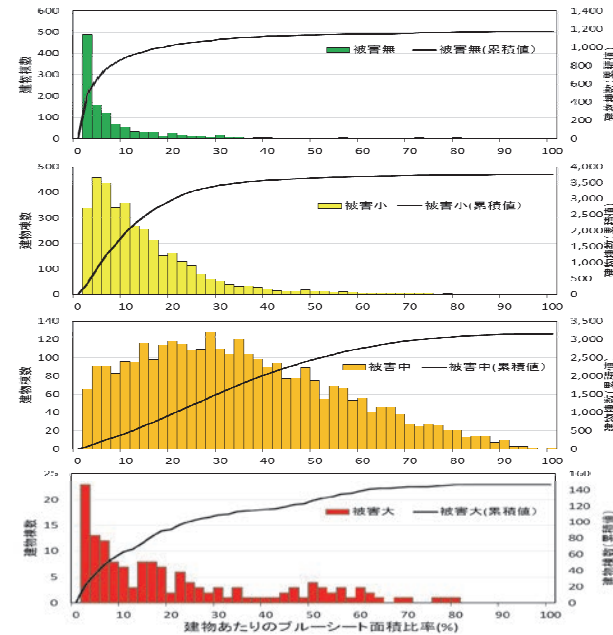
3-2. ブルーシート抽出

4/20に撮影された画像を用いて領域分割を行い、HSV色空間での閾値設定によりブルーシート領域を抽出した。



(本田ほか, 2016) 13

建物に対するブルーシート部分の面積比と被害レベルとの関係



3-3. テクスチャ解析

オリジナル画像のR, G, Bの平均値を用いて1バンド画像へ変換

$$I = (R + G + B) / 3$$


8近傍ラプラシアンフィルタによりエッジ部分を強調する

$$K = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$



$$I'(x, y) = \sum_{i=-w}^w \sum_{j=-w}^w K(i, j) I(x + i, y + j)$$

8ビット符号なし変数 (0~255) への変換



元画像の各画素についてフィルタ係数をかけ総和をとるということを繰り返す




オリジナル画像

1バンド化


ラプラシアンフィルタ適用

建物ポリゴン毎にテクスチャ指標を計算




建物ポリゴン毎にテクスチャ指標を計算し、被害区分との関係进行调查した。航空写真1枚分 (1.5×2km) について結果を集計した。


テクスチャ指標（標準偏差）と被害レベルとの関係




LEVEL1
データ数：1,327
平均値：18.1
中央値：17.6
標準偏差：5.18



LEVEL2
データ数：542
平均値：18.4
中央値：18.2
標準偏差：3.80



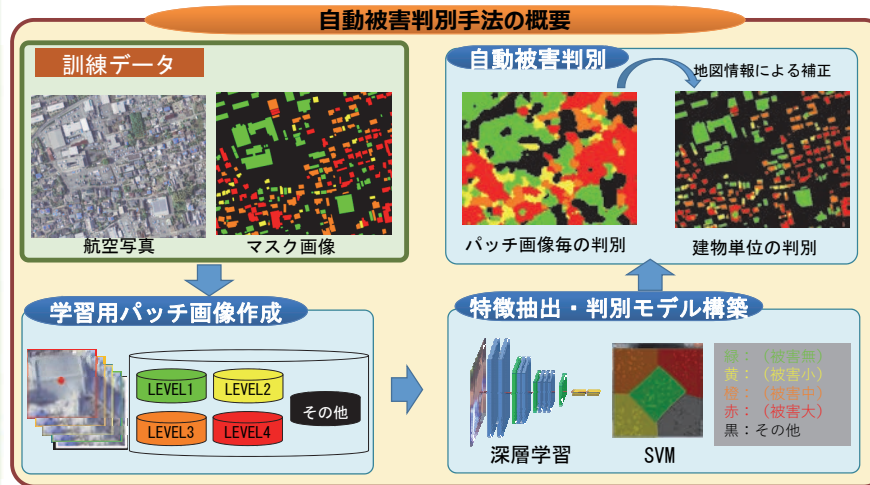
LEVEL3
データ数：768
平均値：20.4
中央値：20.5
標準偏差：3.72



LEVEL4
データ数：707
平均値：22.1
中央値：22.1
標準偏差4.04


4. 機械学習による建物被害判別

機械学習は画像から局所特徴量を計算しSVMにより分類する手法と、深層学習を用いた手法の2通り開発した。いずれも航空写真および被害を区分したマスク画像を用いて学習用パッチを切り出し、パッチ画像毎の判別を基本とする。




学習用パッチ画像群の作成手順

①航空写真画像とマスク画像をそれぞれパッチサイズ80×80[pixels]、走査幅20[pixel]でラスタスキャン



②各パッチに30%以上建物が含まれる場合、パッチ内の面積比率が最大の被害区分の学習データとする

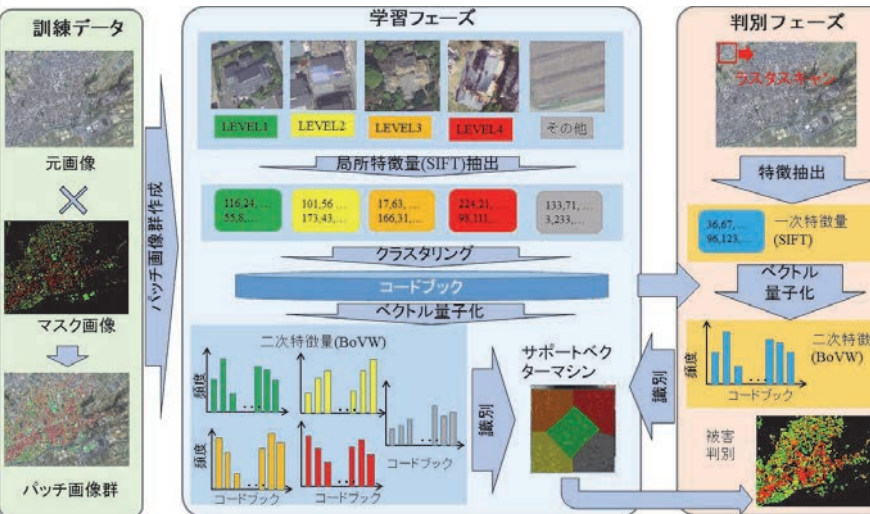



③パッチ内、および周辺40[pixel]に建物が含まれない場合、その他の学習データとする。




4-1. 局所特徴量およびSVMを用いた手法

パッチ画像から抽出した特徴点毎に異なる2つの半径のSIFT特徴量（128次元×2）を計算することで近傍の情報を統合した特徴抽出を行う。次に、各クラスにおいて計算された特徴ベクトルの集合をクラスタリングにより分類したコードブックの出現頻度をクラスごとに集計し次元削減を行う。クラスごとの識別境界をSVMで定めることにより学習を行う。




SIFT特徴量について

オリジナル画像



$$I(x, y)$$

平滑化画像



$$G(x, y, \sigma) * I(x, y)$$


$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right)$$

DoG (Difference of Gaussian) 画像




①スケール（平滑化の度合い）が異なる Gaussian filter を畳み込んだ画像の差分から検出した極値を元にして特徴点を算出

②特徴点周辺の輝度勾配強度および方向を算出したヒストグラムを作成




⑤画像の照明変化、回転、拡大縮小に対して強い不変性をもつ



③特徴点を記述する領域をオリエンテーション（主方向）に合わせて回転



④16ブロックに分割した各ブロックごとに8方向の特徴ベクトルを記述



4-2. 深層学習 (Convolutional Neural Network) を用いた手法

■畳み込み層 入力画像

92	97	109	115	114	117	118	118	123	134
91	109	121	115	97	93	97	100	107	121
95	121	137	119	106	108	108	111	121	121
93	115	131	138	170	189	185	176	165	161
86	94	107	151	214	218	214	218	214	200
85	96	113	148	193	201	210	222	226	222
85	97	114	130	146	163	191	222	230	229
83	92	108	126	138	151	172	207	229	232
82	88	102	120	138	151	163	183	219	234
79	85	98	118	138	148	156	171	204	226

畳み込み フィルタ

0.01	0.08	0.01
0.08	0.62	0.08
0.01	0.08	0.01

出力画像


0	0	0	0	0	0	0	0	0	0
0	106	116	110	98	95	98	101	107	0
0	115	129	118	110	112	112	112	114	0
0	110	125	136	163	178	176	169	161	0
0	94	110	148	198	208	207	209	205	0
0	94	111	144	183	194	204	216	219	0
0	94	111	128	146	163	187	214	223	0
0	90	106	122	136	149	170	200	221	0
0	87	100	117	134	147	160	181	212	0
0	0	0	0	0	0	0	0	0	0

■プーリング層



93	93	95	100	96	86	83	85	85	89
101	95	106	110	100	83	83	85	86	97
115	114	119	115	92	82	82	87	97	113
127	131	123	103	86	83	86	94	112	127
129	131	114	93	88	89	94	104	121	129
132	123	97	86	87	93	102	118	129	128
108	88	84	87	93	107	128	138	139	141
107	88	90	101	114	130	142	143	145	146
122	112	119	133	136	139	135	135	140	138

フィルタサイズごとに最大値を抽出することで情報圧縮

■全結合層



最終層ではSoftmax関数（総和が1になる関数）により判別結果を出力



誤差逆伝搬法により誤差関数Enを最小化するように最適化を行う

$$E_n = \frac{1}{2} \|y(x_n) - d_n\|^2 \quad \delta_j^{(l)} \equiv \frac{\partial E_n}{\partial u_j^{(l)}}$$

VGG-16 (K. Simonyan and Z. Zisserman, 2014) を参考にネットワークを構築。以下の工夫により学習性能を向上させた。

- ・ミニバッチ（効率化のため学習データを分割したひとまとまり）毎に正規化（ $\mu=0, \sigma=1$ に変換）を行うBatch Normalization層の追加。
- ・ミニバッチ毎の学習データの偏りを防ぐため、学習時にクラス毎に学習データの順番を入れ替える処理を追加。
- ・学習順が後半になるほどパラメータが最適化されてしまうため、1エポック（学習試行回数）毎にミニバッチの順番を入れ替える処理を追加。


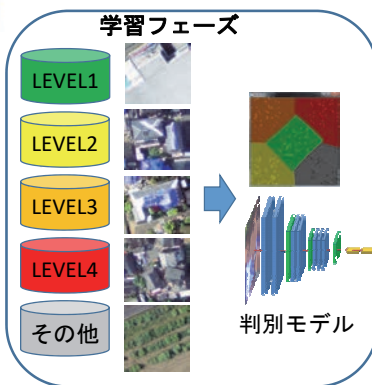
学習パラメータ

パラメータ	設定値
対象航空写真	02KD754
データ数	計12,500データ（各クラス2,500データ、クラス毎のデータ数は間引き、左右反転により回数とした）
バッチサイズ	80 × 80 [pixels]
走査幅	20pixel
ミニバッチサイズ	100
最適化手法	adam
学習係数	1e-3
重み減衰	1e-9
試行回数	200 epoch


構築したネットワークモデル

項目	層	サイズ	フィルタ数	バッチサイズ	ストライド	活性化関数
①	Input	80×80×3				
	Convolution	80×80×64	64	3×3	1	ReLu
	Batch Normalization	80×80×64				
	Convolution	80×80×64	64	3×3	1	ReLu
	Batch Normalization	80×80×64				
②	Pooling	40×40×64		2×2	2	
	Convolution	40×40×128	128	3×3	1	ReLu
	Batch Normalization	40×40×128				
	Convolution	40×40×128	128	3×3	1	ReLu
	Batch Normalization	40×40×128				
③	Pooling	20×20×128		2×2	2	
	Convolution	20×20×256	256	3×3	1	ReLu
	Batch Normalization	20×20×256				
	Convolution	20×20×256	256	3×3	1	ReLu
	Batch Normalization	20×20×256				
	Convolution	20×20×256	256	3×3	1	ReLu
	Batch Normalization	20×20×256				
	Convolution	20×20×256	256	3×3	1	ReLu
	Batch Normalization	20×20×256				
④	Pooling	10×10×256		2×2	2	
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
⑤	Pooling	10×10×512		2×2	2	
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
	Convolution	10×10×512	512	3×3	1	ReLu
	Batch Normalization	10×10×512				
⑥	Pooling	5×5×512		2×2	2	
⑦	Fully Connected	1×1×4096				ReLu
	Dropout	1×1×2048				
⑧	Fully Connected	1×1×5				Softmax
	判別結果					


学習により構築した判別モデルを用いた建物被害判別



画像全体を80×80[pixels]のパッチ毎に走査幅20[pixel]でラスタスキャンし判別結果を出力する



20×20[pixels]毎に16個の判別結果が得られるため、最頻値を採用した。
 (例) 判別結果 {1, 2, 4, 3, 3, 2, 3, 1, 3, 1, 3, 2, 3, 1, 3, 3}
 の場合は「3」を採用




4-3. 判別結果の比較

益城町役場付近の航空写真1枚 (1.5×2km) 全域を用いた機械学習による判別結果の比較



オリジナル画像



目視判読結果

建物数:約3,300棟


それぞれの手法で航空写真から取得したパッチ画像を用いた学習を行いパラメータチューニングを実施した結果、10分割交差検証法による予測精度は以下のようになった。

SVMによる予測精度


項目	予測精度
教師データ	98.9%
交差検証法	75.0%

深層学習による予測精度

項目	予測精度
教師データ	99.9%
交差検証法	86.4%



SVMによる判別結果




深層学習による判別結果

4-4. 深層学習による広域判別試行

深層学習による判別モデルを用いて20枚の航空写真 (建物数29,379棟) の建物被害をパッチ画像単位で自動判別した。



航空写真



深層学習による判別

パッチ単位での予測精度 (航空写真20枚)

項目	予測精度
教師データ	99.6%
交差検証法	85.4%

航空写真20枚の判別時間の比較

深層学習 (GPU使用)	目視判読
約120分 (約5~6分/枚)	約30人日 (1人日で約1,000棟)

深層学習による予測精度 (クラス毎)

航空写真1枚を使用した判別モデル (教師データ予測)

判別結果	判別結果					合計数	精度
	非建物	レベル1 (被害なし)	レベル2 (被害小)	レベル3 (被害中)	レベル4 (被害大)		
非建物	2248	7	0	0	4	2250	99.9511111
レベル1 (被害なし)	1	2248	1	0	0	2250	99.9911111
レベル2 (被害小)	0	8	2248	3	6	2250	99.9244444
レベル3 (被害中)	0	0	4	2248	1	2250	99.7777778
レベル4 (被害大)	0	0	1	4	2248	2250	99.9777778
合計数	2251	2249	2250	2250	11250		
精度	99.9337111	99.9233203	99.8888177	99.9511241			
教師データ	合計数	60000	合計数	60000	合計数	60000	合計数
	99.971	99.971	99.971	99.971	99.971	99.971	99.971

航空写真1枚を使用した判別モデル (交差検証法)

判別結果	判別結果					合計数	精度
	非建物	レベル1 (被害なし)	レベル2 (被害小)	レベル3 (被害中)	レベル4 (被害大)		
非建物	2409	44	18	1	31	2500	96.36
レベル1 (被害なし)	32	2023	383	1	61	2500	80.92
レベル2 (被害小)	9	195	2187	62	97	2500	85.48
レベル3 (被害中)	2	1	95	2310	92	2500	92.4
レベル4 (被害大)	28	53	117	132	2170	2500	86.8
合計数	2310	2247	2250	2451	12500		
精度	87.3488774	77.7839572	92.1787709	88.5352917			
教師データ	合計数	10000	合計数	10000	合計数	10000	合計数
	86.4	86.4	86.4	86.4	86.4	86.4	86.4

航空写真20枚を使用した判別モデル (教師データ予測)

判別結果	判別結果					合計数	精度
	非建物	レベル1 (被害なし)	レベル2 (被害小)	レベル3 (被害中)	レベル4 (被害大)		
非建物	2247	16	0	0	9	2250	99.8888889
レベル1 (被害なし)	28	2248	36	0	0	2250	99.7244444
レベル2 (被害小)	0	94	2248	53	6	2250	99.32
レベル3 (被害中)	0	0	70	2247	3	2250	99.8755556
レベル4 (被害大)	4	3	24	27	2242	2250	99.7222222
合計数	2251	2247	2250	2246	11250		
精度	99.4889136	99.4216311	99.6445559	99.9186575			
教師データ	合計数	60000	合計数	60000	合計数	60000	合計数
	99.654	99.654	99.654	99.654	99.654	99.654	99.654

航空写真20枚を使用した判別モデル (交差検証法)

判別結果	判別結果					合計数	精度
	非建物	レベル1 (被害なし)	レベル2 (被害小)	レベル3 (被害中)	レベル4 (被害大)		
非建物	2419	84	7	1	23	2500	96.2
レベル1 (被害なし)	40	2039	393	2	21	2500	81.56
レベル2 (被害小)	4	378	1824	150	98	2500	79.96
レベル3 (被害中)	0	19	226	2281	34	2500	88.84
レベル4 (被害大)	14	22	54	99	2389	2500	94.04
合計数	2423	2204	2239	2487	12500		
精度	89.8146893	73.8932919	93.0929119	95.2927922			
教師データ	合計数	10000	合計数	10000	合計数	10000	合計数
	86.2	86.2	86.2	86.2	86.2	86.2	86.2

航空写真20枚を使用した判別モデル (航空写真1枚ずつを学習に使わないようにして交差検証)

判別結果	判別結果					合計数	精度
	非建物	レベル1 (被害なし)	レベル2 (被害小)	レベル3 (被害中)	レベル4 (被害大)		
非建物	223	1789	3603	54	187	2128	81.2822165
レベル1 (被害なし)	5	742	2454	345	104	3850	67.2328767
レベル2 (被害小)	2	10	302	741	91	1146	64.8596859
レベル3 (被害中)	7	13	60	70	296	451	65.6319291
レベル4 (被害大)	1829	6119	1213	873	2897		
合計数	95.2492579	98.2002398	90.8974543	43.6576171			
精度	85.4152	85.4152	85.4152	85.4152	85.4152	85.4152	85.4152
教師データ	合計数	10000	合計数	10000	合計数	10000	合計数
	86.4	86.4	86.4	86.4	86.4	86.4	86.4

5. 今後の研究計画

これまでの取り組み

熊本地震本震後の垂直オルソ画像を使用して建物被害自動被害判別手法を開発した。

課題 訓練データの偏り (汎用性) 被害の定量化 (棟数集計)

- ・作成した訓練データは熊本地震本震後の航空写真のみから作成しており偏りがある。
- ・開発したアルゴリズムは建物被害領域の抽出には活用可能だが、自動被害判別結果を災害対応へ活用するためには棟数を集計し、被害を定量化する手法の開発が必要である。

今後、深層学習を用いた建物被害自動判別手法開発の汎化性能向上や自動被害判別結果の活用のため以下の開発を行う。

被害自動判別作成手法の汎化性能向上のための開発

- ・他の被害地震画像や異種プラットフォームを用いた訓練データ作成および判別モデル開発
- ・熊本地震前後の画像を用いた差分解析、広域画像解析
- ・画像解析および深層学習の統合手法開発

被害自動判別結果の活用のための定量化手法開発

- ・被害区分別棟数集計
- ・メッシュデータ作成

