

A-10

航空レーザ測量データの機械学習による地震被害建物の検出

17T0213A 籠嶋 彩音
指導教員：丸山 喜久，劉 ウェン

1. 研究背景と目的

2016 年 4 月の熊本地震では、二度の大きな地震により建物やインフラ施設に甚大な被害が生じた。地震発生後の対応として、迅速に建物の被害状況を把握することは災害対応や復興・復旧支援の点で重要である。しかし、被害が広範囲である場合や二次災害が考えられる場合、直接足を運んで被害状況を把握することは困難である。罹災証明書は、被災者の生活再建に重要な役割を果たす。しかし、住家の被災度判定に膨大な時間を要するため、熊本地震の際には本震から 1 か月後の時点で申請件数の 3 割ほどしか交付されず、罹災証明書の発行の遅れが生じた。

そこで、対象地から離れていても迅速に広範囲を観測できるリモートセンシング技術の利用が有効である。本研究では、航空レーザ測量により本震の前後で取得した数値表層モデル(DSM)の機械学習によって地震被害建物の検出を試みる。なお、DSM とは、建物や樹木を含む 3 次元の表層モデルのことである。

2. 分析対象データ

本研究は、熊本地震の被害の大きかった益城町を対象に行った。航空レーザ測量データには、Moya らが整備したデータを用いた(図 1)。航空レーザ測量は前震後(2016 年 4 月 15 日 15 : 00 ~ 17 : 00)と、本震後(2016 年 4 月 23 日 10 : 00 ~ 12 : 00)に行われた。国土地理院の基盤地図情報ⁱⁱの 2015 年 10 月もしくは 2016 年 4 月に更新された建物の外周線を用いて、建物の位置を特定した。建物の被災度には、罹災証明書の発行のために行われた被害認定調査の結果を用いる。被災度は、被害程度によって無被害・一部損壊・半壊・大規模半壊・全壊に分類される。地震動の強さは、松岡ⁱⁱⁱが推定した 250m メッシュの地震動分布を用いた。




図 1 Moya らの整備した航空レーザ測量データ

3. データセットと学習条件

(1) DSM データの使用方法

本研究では本震前後での建物の高さの変化に注目し、本震前後の DSM の差分のデータを用いた。図 2 のような DSM データを持ったラスターデータに対し、ArcGIS 上で 50cm ごとにポイントを生成する。建物の外周線の内部および外周線から 1m 以内の範囲にあるポイントをその建物の DSM データとした。




図 2 ポイントに変換した DSM の例

(2) データセット

被害認定調査による建物の被災度と DSM の本震前後の差分が対応付けられたデータに対し、被害認定調査で全壊判定がなされた建物をクラス 1、それ以外の判定がなされた建物をクラス 0 とした。建物の被災度ごとのデータ数の内訳を表 1 に示す。12263 件の全データを訓練データとテストデータに 7:3 の割合で分割し、機械学習を行った。説明変数には、本震前後の DSM の差分の平均・分散・最大値・最小値、地震動分布として最大地表速度(PGV)を用いている。

表 1 建物の被災度ごとの内訳

無被害	943 件
一部損壊	4879 件
半壊	2178 件
大規模半壊	714 件
全壊	3549 件
合計	12263 件

(3) 機械学習の手法

プログラミング言語には Python, 機械学習のアルゴリズムにはランダムフォレストを用いた。ランダムフォレストとは、複数の決定木を統合させて行うアンサンブル学習である。また、汎化性能を向上させるため、訓練データに対して 5 分割のクロスバリデーションを行い、ハイパーパラメータの調整にはグリッドサーチを行った。

全壊のデータが少なくデータに偏りがあるため、学習を二回行いアンダーサンプリングした。本研究のアンダーサンプリングでは、一回目の学習で 85% 以上の確率でクラス 0（その他）に分類されたデータを訓練データから除き、二回目の訓練データとした。二回目の学習では、正答率もしくは F 値が最大となる 2 つのモデルを作成した。本研究では、一回の学習で構築した正答率もしくは F 値が最大となるモデル①・②と、学習を二回行い正答率もしくは F 値が最大となるモデル③・④の分類精度を比較する。

4. 学習結果

学習条件を変えたモデル①～④に対しそれぞれ学習を行い、得られた結果を表 2, 表 3 に示す。表 2 ではテストデータの判別結果を混同行列に表している。また、表 3 では学習結果から得られた精度指標を示している。

表 2 モデル別のテストデータの混同行列

モデル① 学習 1 回・正答率最大		予測結果	
		その他	全壊
実際の 結果	その他	2319	275
	全壊	618	467
モデル② 学習 1 回・F 値最大		予測結果	
		その他	全壊
実際の 結果	その他	1886	708
	全壊	323	762
モデル③ 学習 2 回・正答率最大		予測結果	
		その他	全壊
実際の 結果	その他	2318	276
	全壊	641	444
モデル④ 学習 2 回・F 値最大		予測結果	
		その他	全壊
実際の 結果	その他	1936	658
	全壊	361	724

表 3 モデル別の精度指標の比較

	モデル ①	モデル ②	モデル ③	モデル ④
正答率	0.76	0.72	0.75	0.72
適合率	0.63	0.52	0.62	0.52
再現率	0.43	0.70	0.41	0.67
F 値	0.51	0.60	0.49	0.59

5. 考察

モデル①・③は、モデル②・④に比べその他の判別は比較的できているものの、全壊の誤判別は多かった。そのため、適合率は高く再現率は低い結果となった。全壊のデータの方が少ないため、全壊の建物の判別精度が良くないことが正答率に与える影響は小さい。そのため、その他の建物の判別精度が良くなったと考えられる。モデル②・④は、全壊の見逃しが少ないため再現率が高い。防災分野では、全壊の見逃しを減らすことは重要な課題である。モデル②は、適合率と再現率の調和平均である F 値の値も 4 つの中で一番高く、釣り合いの取れたモデルであると考えている。モデル③・④は二回の学習を行ったモデルであるが、モデル①・②に劣る精度となった。アンダーサンプリングの効果よりも、学習データが減ってしまったことに要因があると考えられる。

6. 結論

本研究では、2016 年熊本地震における益城町を対象として、航空レーザ測量データの機械学習による地震被害建物の検出のモデルを構築することを試みた。どのモデルも正答率は 70%を超えていたが、再現率を保ちつつ、適合率とバランスをとることが困難であった。今後は今回用いた特徴量のうち何が一番有効であったかを分析するとともに、新たな特徴量を追加することで予測精度向上を目指す。

ⁱ Luis Moya,Fumio Yamazaki,Wen Liu,and Masumi Yamada: Detection of collapsed buildings from lidar data due to the 2016 Kumamoto earthquake in Japan,Natural Hazards and Earth System Sciences,18,pp.65-78,2018.

ⁱⁱ 国土地理院基盤地図情報
<https://fgd.gsi.go.jp/download/menu.php>

ⁱⁱⁱ 松岡昌志：強震観測記録に基づく 2016 年熊本地震の地震動分布の推定, 地域安全学会梗概集, No.42, pp.23-26, 2018.