

地理空間情報と光学衛星画像の深層学習処理による地震時構造物被害の自動検出

山梨大学 正会員 ○宮本 崇

山梨大学 非会員 濱崎 泰知

1. 背景

災害の発生時には、被害情報を迅速に収集することは適切な災害対応を取るうえで重要である。衛星などによるリモートセンシング技術は、そのような災害被害の情報を即座に収集する手段として有力視されており、近年においても洪水や地滑りといったマクロな被害に加えて地震時の構造物被害といったミクロな被害分析のための研究が進んでいる。本稿では、地震により被災した地域の災害前後の光学衛星画像に対して畳み込みニューラルネットワークを適用し、住宅構造物の被害を1棟単位で検出する技術を提案する。

2. 手法の概要

本稿で開発する技術の目的は、広域に渡る被災地を撮影した光学衛星画像から1棟単位での住宅被害を検出することである。これは画像認識分野における物体検出の問題と捉えることができ、本稿では以下のような手順でこれを解く手法を開発する(図1)。

まず、構造物の位置や外形情報が整備された地理空間情報を用いて、広域の衛星画像から住宅毎の小画像片を抽出する。抽出された個々の小画像片に対して地震被害の有無を識別することによって、物体検出の問題をより容易なカテゴリ認識の問題に置き換える。

画像の分類や識別を行うカテゴリ認識の問題に対しては、畳み込みニューラルネットワークなどの深層学習手法が高い性能を有することが知られている。本稿では地震前後の構造物状態の変化に関する情報を利用するために、被災後の撮影画像に加えて被災前の撮影画像を含む3次元の時空間テンソルを入力とする畳み込みニューラルネットワークを用いて、抽出された住宅画像片に対する地震被害の有無を識別する。

3. 地理空間情報を用いた構造物単位の小画像片の抽出

光学衛星画像にピクセル単位で付与されている撮影地域の空間座標と、1棟単位で構造物の種別や位置・外形などの情報が整備された地理空間情報を用いて、住宅1棟単位の小画像片を抽出する。まず、住宅の外形情報を元に、住宅を囲う最小の矩形領域の座標値を取得する。この矩形領域を光学衛星画像に重ね合わせ、矩形領域を含むピクセルを当該の住宅の小画像片として抽出する(図2)。



図1 提案手法の概要




図2 構造物単位の小画像片の抽出

キーワード 光学衛星画像, 地震被害判別, 深層学習, 畳み込みニューラルネットワーク

連絡先 〒400-8511 山梨県甲府市武田4-3-11 山梨大学土木環境工学科 TEL:055-220-8524 E-mail:tmiyamoto@yamanashi.ac.jp

4. 畳み込みニューラルネットワーク

上記の小画像の抽出処理を地震前後での被災地の撮影画像に対してそれぞれ行うことで、1棟の住宅に対して2枚の画像が得られる。本稿では、この2枚の画像から構成される時空間テンソル $X_{thwc}(t$:時間方向のインデックス, h,w :空間方向のインデックス, c :RGBのチャンネル番号を示すインデックス)を入力とする3次元畳み込みニューラルネットワークを用いて、入力された画像の住宅が地震によって被害を受けたかどうかを判定する。

5. 交差検証法

2015年12月15日、2016年4月29日に光学衛星SPOT6&7によって撮影された、2016年熊本地震の前後2枚の光学衛星画像に対してそれぞれ上記の手法を適用して住宅毎の小画像を作成し、悉皆調査結果を元にして個々の住宅に対して被害あり・被害なしの2種のラベルを付与した。ラベルが付与されたデータを2分割し、表1に示す内訳からなる訓練データとテストデータを作成し、図3に示す層構成の畳み込みニューラルネットワークに対して交差検証法を実施した。

6. 計算結果

図4は、500回のバッチ学習を行った際の正解率の推移を示す学習曲線である。テストデータに対する正解率は収束しており、最大で75%の正解率が得られている。

また、畳み込みニューラルネットワークは入力された画像が被害ありの住宅のものである確率が0から1の範囲で出力するモデルとして設計しており、図4の正解率は確率0.5を閾値として、閾値以上の値となった画像を被害ありと判断した際の正解率である。この閾値を上下させることによって得られるROC曲線を図5に示す。被災後の画像のみを用いた通常のCNNと比較して、被災前後の2枚の画像を用いた本稿のCNNは高い性能を有しており、提案手法の有効性が示唆される。

7. おわりに

本稿では、地震前後の2枚の光学衛星画像から住宅毎の小画像を抽出し、畳み込みニューラルネットワークによって被害あり・被害なしに分類することによって、住宅構造物の被害を1棟単位で検出する技術を提案した。被災前の画像を活用することで、被災後の画像のみを用いる場合よりも分類性能が向上することを示した。

参考文献

- 1) S.N.K.B. Amit et al.: Analysis of satellite images for disaster detection, IGARSS 2016, pp.5189-5192., 2016.
- 2) Y. Bai et al.: Machine Learning Based Building Damage Mapping from the ALOS-2/PALSAR-2 SAR Imagery: Case Study of 2016 Kumamoto Earthquake, *J. Disaster Research*, Vol.12, pp.646-655, 2017.

表1 訓練データ・テストデータの内訳

クラス	訓練データ※	テストデータ
被害あり	2,032	253
被害なし	2,024	536
総数	4,057	789

※鏡像反転処理と回転処理によって

8倍のデータ拡張を実施後の数値を示す。




図3 畳み込みニューラルネットワークの層構成




図4 学習による正解率の推移




図5 被災前画像の有無によるROC曲線の比較