

衛星画像と構造物情報のマルチモーダル深層学習による地震被害判別

山梨大学 学生会員 山本 裕大
山梨大学 正会員 宮本 崇

1. はじめに

自然災害の発生時においては、適切な対応活動を取るための初動として被害分布の迅速な情報収集が重要となる。人工衛星による撮影画像は、広域の地震被災地を高速に直接計測する有力な情報源の1つである一方で、解像度の限界などの理由から十分な精度で被害を検知することが難しく、その精度向上は現在もなお重要な課題となっている。

そこで本稿では、衛星撮影画像を含む震災直後の計測情報や事前取得の可能な情報から地震時における被災地の住宅被害の判別を行う上で、近年に進展の著しい深層学習手法を適用することを提案する。ここでは、建築年などの住宅毎の属性情報と衛星撮影画像の2種を入力データとしたマルチモーダル深層学習による被害判別器を設計し、その有効性を検証する。

2. 被害判別システムの概要

著者らが開発を進めているシステムは、以下のような2段階を経ることによって住宅被害の判別を行うものである¹⁾。

まず、構造物の位置や外形情報が整備されたデータベースを利用して、広域の衛星画像から住宅毎の小画像片を抽出する。ここで、震災前後の撮影画像の差異を利用するために、衛星画像は震災前後の2枚の画像を利用する。

次に、抽出された個々の小画像片と、対応する住宅の属性情報を統合し、被害・無被害の2クラスへの判別を行う深層学習モデルを適用し、衛星撮影画像内の個々の住宅の被害状況を判別する。個々の判定結果と位置情報を統合し総計することにより、撮影域の被害分布を推定する(図-1)。




図-1 被害判別システムの概要

3. 深層学習モデル

一般に、衛星撮影画像は緊急撮影による震災後のものに加えて、定期的な撮影による震災直前のものが利用できる。従来の多くの研究は震災前後の画像の差分画像を利用している²⁾が、本研究では差分以外の特徴量を自動的に抽出し被害判別に利用することを目的として、深層学習モデルに3次元畳み込み層を導入した。

また、日本では築年数などの個々の住宅属性に関する情報が整備されており、そうした属性情報は統計的に地震被害の有無と関連が高い。そこで、本研究は畳み込みによって抽出された画像の特徴量に住宅属性を統合して判別を行う、マルチモーダル学習構造³⁾を利用した深層学習モデルの設計を行った。図-2に、深層学習モデルのネットワーク構造を示す。




図-2 提案する深層学習モデルの構造

4. データセットと問題設定

提案する被害判別システムの有効性の検証に利用するために、2016年熊本地震時に益城町において行われた悉皆調査結果⁴⁾を元に、2340棟からなる被災住宅のデータセットを整備した。ここでは、悉皆調査で判定された7段階の被害グレードのうち、住宅の完全な倒壊に当たる上位2グレードを被害あり、その他のグレード

Key Words: 地震被害判別, 衛星センシング, 時空間データ, マルチモーダル学習

〒400-8511 山梨県甲府市武田 4-3-11

を被害なしという2段階に再分類した。またデータセット上では、被害有無に加えて耐震基準の変遷年に応じた3段階の築年代と、木造やRC造といった構造種別の、2種の属性情報を個々の住宅に紐づけて整備した。

上述したデータセット内の住宅の被害有無を、震災前後の衛星撮影画像と建物の属性情報から判別する試行を通して、提案手法の有効性を検証した。衛星画像には、光学衛星画像の1種であるSpot 6 & 7によって2015年12月15日と2016年4月29日に撮影された2枚の画像を利用した。検証においては、表-1に示すようにデータをトレーニングデータと検証データに分割した。

5. 解析結果

提案手法の有効性を検証するために、図-2に示したネットワーク構造を含む計3ケースの異なる深層学習モデルの精度を比較した。ケース1は、従来と同様に震災前後の画像の差分値に対して2次元畳み込み層を適用するモデルであり、属性情報も利用しない。ケース2は、提案手法と同様に3次元畳み込み層による画像の時系列的な特徴の抽出を行うが、属性情報を利用しない。ケース3は提案手法である。

表-2は、各深層学習モデルの分類性能を4種類の指標で比較したものである。ケース1とケース2の比較から3次元畳み込み層を導入する有効性が、ケース2とケース3の比較から属性情報を統合したマルチモーダル構造の有効性が示されている。また、悉皆調査結果に基づく倒壊・非倒壊住宅の分布と、提案手法による被害判別結果を図-3に示す。南部に帯状に倒壊住宅が分布する解析対象地域の被害状況を、提案手法は適切に判別できていることが分かる。

表-1 検証に用いた住宅データ数：トレーニングデータには回転と鏡像反転による8倍のデータ拡張を適用

	被害なし	被害あり
トレーニング	8120(=1015*8)	1240(=155*8)
検証	1015	155

表-2 ケース毎の分類性能の比較

ケース	Accuracy	Precision	Recall	ROC-AUC
1	0.66	0.26	0.86	0.82
2	0.72	0.30	0.85	0.85
3	0.86	0.46	0.75	0.89




図-3 提案手法による被害判別結果

謝辞： 本研究の実施に当たり、国土交通省住宅局建築指導課、国土技術政策総合研究所、国立研究開発法人建築研究所から建物の建設年等の情報提供を受けました。記してここに感謝いたします。

参考文献

1) T. Miyamoto et al: Using multimodal learning model for earthquake damage detection based on optical satellite imagery and structural attributes, Proceedings of 2020 IEEE International Geoscience and Remote Sensing Symposium, accepted, 2020.
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, Journal of Disaster Research, vol. 12, pp.646-655, 2017.
3) J. Ngiam et al: Multimodal deep learning, ICML-11, pp.689-696, 2011.
4) 日本建築学会：2016年熊本地震災害調査報告，2018。