

航空写真を用いた深層学習による地震災害時の屋根損傷家屋の把握

藤田翔乃[†] 畑山満則[‡]

京都大学大学院情報学研究科[†] 京都大学防災研究所[‡]

1 はじめに

地震や風水害等の災害が起こった際、自治体は一つ一つの被災した住家の被害の程度を調査し、被災者に住家が被災したことを証明するものとして、罹災証明書を交付する。罹災証明書は被災者の各種支援策の判断材料として活用され、生活再建に必要不可欠である。しかし、これまでの地震災害では被害認定業務の体制の不備や人員不足などが原因で多くの時間を要している。

2 研究背景

2.1 被害認定マニュアルの改定

2016年4月に起きた熊本地震でも罹災証明書の発行に多くの時間を要したことから、内閣府は「災害に係る住家の被害認定基準運用指針」と「実施体制の手引き」の改定を行い、航空写真による全壊の判定を可能にした。

2.2 地震災害時の屋根損傷

地震災害では建物の屋根、特に瓦屋根に損傷が生じることが多いが、被害認定業務の調査員は下から見上げることしかできず、適切な評価を行うことが困難である。

2.3 画像認識技術の向上

深層学習が画像認識の分野のデファクトスタンダードになったことにより近年の画像認識精度は大幅に向上しており、コンピュータの計算能力向上などからその精度はますます進歩していくことが予想されている。

3 研究目的

本研究では上記の研究背景を踏まえて、地震災害時に航空写真と深層学習による画像認識を用いて屋根損傷家屋を把握し、被害認定業務を迅速化させることを目的とする。

4 先行研究と本研究の位置付け

釜ヶ谷らの研究では、ラインセンサと呼ばれる航空カメラで撮影した航空写真から DCNN モデルを用いて被害の程度の分類予測を行った。本研究では上記の研究のようなラインセンサを

Estimation Method of Roof-damaged Buildings from Aero Photo Images using Deep Learning in Earthquake Disaster

[†]SHONO FUJITA, Kyoto University

[‡]MICHINORI HATAYAMA, Kyoto University

搭載した特殊な航空機などでなく、比較的安価で飛行が容易なドローンなどからの航空写真を主に用いることを想定している。これにより、容易にモデルの学習時に用いるデータを増やすことや実際の災害時にデータを取得することが現実的に可能である。また、航空写真から建物の画像データを取得する際、釜ヶ谷らの研究では一枚一枚人の手によって建物が収まるように画像を切り出して作成している。しかし本研究ではトリミングアルゴリズムにより自動的に建物の画像を切り出して作成する。

5 屋根損傷家屋把握システム

5.1 システムの構成

システムの全体図を図1に示す。まず航空写真から建物ポリゴンの位置情報を用いてトリミング作業を行い、屋根写真のデータベースを作る。次にそのデータベースの一部の画像に対して被害の有無などのラベルをつけ、画像認識モデルに学習をさせる。そして残りの画像データを画像認識モデルに分類予測をさせ、被害のある家屋を把握する。

被害認定業務を迅速化させるには以下の使用方法が考えられる。一つ目は被害の全体像の予測を行い、必要な人員・時間・機材を正確かつ迅速に把握することである。二つ目は調査を行う家屋を決定し、被害のない建物の調査に行く時間を短縮することである。そして三つ目は屋根の罹災度判定の損傷度合いの算出である。しかし、三つ目の使用方法ではかなりの精度が要求されるため本研究では対象外とする。

また、災害発生直後屋根の損傷部分は直接見える状態であるが、発災から時間が経つと多くの被災者はその損傷部分をブルーシートで覆う。そのため、本システムでは屋根の損傷を直接判別するモデルとブルーシートの有無を判別するモデルの2つのモデルを用いる。




図1. システムの構成図

5.2 トリミングアルゴリズム

本研究では航空写真と地理空間情報の建物ポリゴンの頂点の位置情報を用いて画像データベースを自動で作成し、建物の部分のみに色をつけたトリミングアルゴリズム(図 2)を使用した。これにより画像データベースを自動で作成ことができ、迅速な学習・予測を行うことができる。また、建物以外の無駄な部分を排除でき、正確に学習・予測を行うことができると期待できる。

5.3 必要なデータ

災害が起こった際、国土地理院は被災地域の航空写真を撮り、初動対応や被災状況の把握などの重要な資料としている。災害ドローン救援隊「DRONE BIRD」は災害時に被災状況を詳細かつ迅速に取得できる最新技術を持ったドローンにより撮影を行っている。

また、DRONE BIRD を運営しているクライシスマップパズ・ジャパンは発災後、世界中の人を地図作りに参加させ、Open Street Map に建物ポリゴンを描き、最新の情報を反映させた地図を作成している。

学習には被害の有無などのラベル付けが必要であるが、クラウドソーシングなどによりデータ入力が可能であると考えられる。「National Network for Emergency Mapping」によるオンライン上で災害対応に必要な地理空間情報作成と活用のための情報支援活動など、災害時でのボランティアによるデータ入力近年行われている。




図 2. トリミングアルゴリズム




図 3. 地図上への可視化

6 深層学習による分類・予測

本研究で AlexNet という画像認識モデルを用いた。AlexNet は深層学習ブームをもたらしたモデルであり、高い精度を持つことが知られている。

6.1 ブルーシート判別

航空写真としてドローンで撮影した大阪北部地震後の茨木市のデータを、建物ポリゴンの位置情報として OSM のデータを用いた。また、学習データとしてブルーシート有りを 4,896 枚、ブルーシート無しを 4,900 枚、テストデータとしてブルーシート有りを 169 枚、ブルーシート無しを 2,702 枚で実験を行なった。結果は再現率 93.49%、正解率は 92.86 %となった。

6.2 直接被害判別

航空写真として国土地理院が撮影した熊本地震後の益城町のデータを、建物ポリゴンの位置情報として OSM のデータを用いた。また、学習データとして被害有りを 5,984 枚、被害無しを 5,984 枚、テストデータとして被害有りを 1,488 枚、被害無しを 1,488 枚で実験を行なった。結果は再現率 66.98%、正解率は 90.48 %となった。

7 まとめ

ブルーシート判別では再現率、正解率ともに高い精度であったが、直接被害判別の再現度がかなり低い値となった。これは直接被害判別の方が特徴を抽出するのが難しいことと使用した画像データの画質が低かったことが原因であると考えられる。しかし、地震災害の頻度が低いことやドローン開発から日が浅いこと、ブルーシートがかかるまでに撮影しなければならないことなどから直接被害を撮影した高画質なデータは豊富に存在しない。今後は画像認識モデルの改良などに加え、各種機関でのデータの共有などの体制作りが必要である。また、予測結果は図 3 のように地図上に可視化でき、効率的な計画づくりを行うことが可能であると考えられる。

参考文献

- [1] 釜ヶ谷 悠馬, 松岡 昌志: 2016 年熊本地震後の空中写真を用いた 深層学習による建物被害分類, 東濃地震科学研究所報告「防災研究委員会 2017 年度報告書」No. 41 2017, pp. 49-57