

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¹ 畑山満則²

概要：被災者支援策の判断材料として用いられる罹災証明書の発行は迅速性と正確性を必要とするが、これまでの地震災害では多くの時間を要しており、行政は更なる効率的な仕組みを必要としている。本研究では、地震災害時に航空写真と建物ポリゴンのデータから深層学習を用いて地震被害の大まかな規模と全体像を把握する屋根損傷家屋把握システムを開発した。このシステムは航空写真と GIS の建物ポリゴンの位置情報を用いて、自動で画像データベースを作ることができ、迅速な予測が可能であると考えられる。ブルーシートの有無の判別の正解率は 97.00%、直接見える被害の判別の正解率は 84.03%という結果となった。深層学習では高画質で大量の画像データが必要である一方、現状では高画質な画像データ数が乏しいという問題点が浮き彫りになったため、画像認識モデルや学習方法に今後さらなる検討を行わなければならない。

キーワード：被害認定業務、深層学習、画像認識、GIS

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

SHONO FUJITA^{†1} MICHINORI HATAYAMA^{†2}

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・認定し、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[1]。罹災証明書は被災者の各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[2]。よって自治体は迅速かつ正確に罹災証明書を発行しなければならないが、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. 研究背景と目的

2.1 研究背景

(1) 被害認定マニュアルの改訂

2016年4月に発生した熊本地震では罹災証明書発行に多くの時間を要し、被災者の支援実施に大幅な遅れをもたらした。このことから、内閣府は平成30年3月に「住家の被害認定基準運用指針」と「実施体制の手引き」の改訂を行った[3]。平成30年6月に発生した大阪北部地震では、この改定内容の一つである「写真を活用した判定の効率化・迅速化」を利用し、被災者が持参した写真から比較的被害の小さいものに限り、被害認定を行った[4]。平成30年9月に発生した北海道胆振東部地震では、改定内容の一つである「航空写真等を活用して『全壊』の判定が可能」を利用し、航空写真から被害認定調査を行った[5]。

(2) 近年の画像認識技術の向上

2012年の画像認識の世界コンテストで深層学習を用いたモデルの AlexNet が優勝したこと[6]をきっかけに、深層学習でのアルゴリズムが画像認識分野のデファクトスタンダードとなり、精度が大幅に向上した。そして、ImageNet などの大規模な画像データ集合の開発や GPU などによるコンピュータの計算能力の向上から、深層学習を用いた画像認識のレベルはより進歩していくことが予想されている。

2.2 研究目的

本研究では、被害認定調査が簡略化の傾向にあり、更なる効率的な仕組みを必要としていること、広範囲の家屋の画像データを取得できる航空写真が積極的に利用されていること、近年画像認識の技術が大幅に進歩していることを踏まえて地震災害時に航空写真と画像認識技術を用いて被害認定業務を迅速化させることを目的とする。

深層学習の画像認識アルゴリズムである DCNN (Deep Convolutional Neural Network) を用い、航空写真から地震災害時の屋根損傷家屋を予測することで、地震被害の大まかな規模、全体像の迅速な把握が可能である。どの地域にどのくらいの被害があるかを把握することで、被害認定調査に必要な大まかな調査員・資機材の数、時間が予想でき、効率的な人材配置、応援職員の派遣、タイムスケジュールを行うことができると予想される。

¹ 京都大学
Kyoto University
² 京都大学
Kyoto University

3. 先行研究と本研究との位置づけ

深層学習や機械学習を用いて地震災害時の被害があった家屋を把握する研究は今までにいくつか行われてきた。

松岡ら[7]の研究では、UAVに赤外線カメラを搭載し、被災建物の撮影を行い、その赤外線画像における色の特徴により屋根被害箇所と無被害箇所の判別を行った。釜ヶ谷ら[8]の研究では、ラインセンサと呼ばれる航空カメラで真上から撮影した航空写真と斜めから撮影した航空写真から建物が写っている部分を切り出し、DCNNモデルを用いて被害の程度のカテゴリ予測を行った。

本研究では地震災害時の航空写真データとして、上記の研究のようなラインセンサを搭載した航空機や赤外線カメラを搭載したUAVでなく、比較的安価で飛行が容易なドローン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ができたり、実際の災害時にデータを取得したりすることが現実的に可能である。また、余震が起き、被害の程度が度々変化することがあるが、ドローンを用いることで随時被害状況のデータを手に入れることができる。

また、航空写真から一つ一つの建物の学習用・判別用データを取得する際、上記など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外接四角形を描いて作成している。しかし、本研究ではOSM(Open Street Map)などのGISから建物ポリゴンの頂点の位置情報を取得し、トリミング作業により自動的に建物の画像を切り出して作成する。これにより、学習データを大量に作るができることに加えて、地震災害時に判別する家屋の画像のデータベースを作成する時間が短縮される。

阪田[9]の研究では、発災後の空撮画像や映像からモデリング技術の一種であるSfM(Structure from Motion)により3次元化したデータと発災前の建物等の地理空間情報に基づいて、それらの高さの差分計算から被害を検出している。本研究では、阪田の研究や松岡らの研究では検出できない屋根被害を検出でき、また逆に本研究では検出できない屋根被害をこれらの研究は検出することが期待できる。したがって、本研究とこれらの研究とは相互補完の関係にあり、併用することで検出できない被害家屋は少なくなると考えられる。

罹災証明書発行についての研究に関しては、堀江[10]らは新潟県中越沖地震において、Damage Assessment Training Systemというシステムを開発・検証し、事前訓練から調査員の視点を統一し、公平性を確保できることがわかった。また、堀江[11]らは公的機関による建物被害調査の効率化を目的として、木造建物について、より最適な調査項目の設定についての研究を行った。

このように被害認定調査迅速化には、調査員の育成、調査内容などの観点からもアプローチが行われていることがわ

かる。

4. 屋根損傷家屋把握システム

被害認定業務迅速化を目的とし、航空写真からDCNNモデルを用いて地震災害時の被害の規模、全体像を把握する図1のようなシステムを屋根損傷家屋把握システムと定義する。

4.1 システムの構成

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、発災から時間が経ち雨などの悪天候が予想されると、多くの被災者はその損傷部分をブルーシートで覆う。航空写真を撮影するまで時間がかかる場合や、余震などによって再度撮影する場合にはブルーシートがかかっている状況で航空写真を撮影することが予想される。このとき、被害の全体像を確認するには、実際の損傷部分はブルーシートで覆われ、見えなくなっているためそのブルーシートの有無で損傷の有無を判断せざるを得なくなる。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。

本システムでは、地震発生前に被害を判別するためのDCNNモデルを作る学習ステップと地震発生後にそのDCNNモデルを使って、実際に判別を行う運用ステップの2ステップから構成される。地域ごとの屋根の損傷の仕方に違いはないと仮定し、災害発生前のデータを学習データとして用いることとする。

学習ステップでは航空写真から、まず建物ポリゴンの頂点の位置情報を使って一つ一つの建物の画像を切り抜くトリミングの作業を行う。次に建物、つまり屋根画像のデータベースを作り、被害・ブルーシートの有無を目視で判定し、それぞれの画像にラベル付けを行う。画像とラベルのデータベースから学習を行い、DCNNモデルのパラメータを設定し、モデルを構築する。そして地震発生後の運用ステップでは航空写真からトリミング作業を行い、画像のデータベースを作った後、学習ステップで作成したDCNNモデルから屋根損傷がある家屋を把握し、地震被害の大まかな規模、全体像の把握を行い、被害認定業務迅速化へとつなげる。

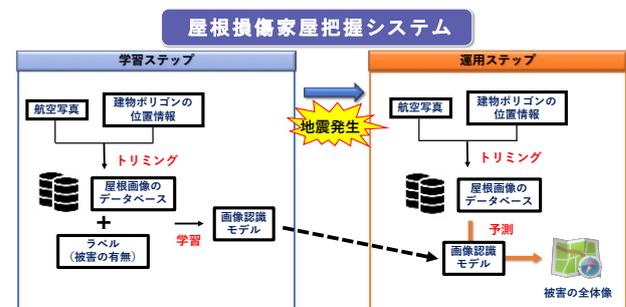


図1 システムの全体図

4.2 地震災害時のデータ

地震災害時に、本システムを運用する際に被災地域の航空写真と建物ポリゴンの頂点の位置情報が必要である。

(1) 航空写真データ

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、応急復旧、復興のための重要な資料としている。災害対応や研究などを目的とする場合、国土地理院に申請を行うことでその航空写真を入手することができる[12]。

特定非営利活動法人クライスマップーズ・ジャパンでは、災害ドローン救援隊「DRONE BIRD」という組織を運営している。DRONE BIRD は自然災害や政治的暴動などが起きたとき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を被災地に送り、その災害状況をマップ上に反映し、人命救助や支援活動のサポートを行っている[13]。この航空写真は Open Aerial Map と呼ばれるウェブサイトアップロードされており、自由にダウンロードすることが可能である。

国土地理院が撮影する航空写真は DRONE BIRD のものと比べて広範囲のものであるが、データ量が多く、ウェブサイト上でダウンロードすることはできない。それに対し、DRONE BIRD がドローンによって撮影する航空写真は範囲が狭くデータ量が少ないため、インターネット上でダウンロードが可能であり、災害発生後すぐに遠隔地からデータを入手できる。

このように、本システムの地震災害時での運用のための航空写真のデータは国土地理院や DRONE BIRD などから入手することが可能である。

(2) 建物ポリゴンの頂点の位置情報

DRONE BIRDを運営しているクライスマップーズ・ジャパンは、自然災害、政治的混乱等の危機的状況下で、地図情報を迅速に提供し、世界中に発信・活用することを目的としている特定非営利活動法人（NPO法人）である。現在ではOSMを利用し、インターネットを通して世界中の人たちが地図作り活動に参加し、被災状況を地図に反映させることができる[14]。この仕組みを利用して、大規模災害が発生すると、衛星写真やドローンなどの航空写真をもとに世界中のマッパーたちが現地の被災状況をOSMに反映させている。

OSMは地理空間情報を誰でも自由に利用できる地図であるため、本システムの運用ステップにおいて建物ポリゴンの頂点の位置座標を入手することが可能である[15]。

また建設や取り壊しにより建物の立地状況が日々変化している中、災害発生後から新たに描かれる OSM を用いることで最新の住宅や道路の情報を入手することができ、加えて地震の地殻変動による建物の位置情報のズレにも対応することができると思われる。

4.3 トリミングアルゴリズム

本章では、航空写真から建物ポリゴンの頂点の位置座標を用いて建物の屋根一つ一つの画像のデータベースを作るトリミング方法について述べる。

まず、GIS から得た建物ポリゴンの頂点の位置座標からその建物ポリゴンの外接四角形を求める。その四角形の中にある一つ一つのピクセルが建物ポリゴンの内に入っているかどうかの内外判定を行う。建物ポリゴンの外にある場合はそのピクセルを黒く塗り、内に入っている場合はそのままにすることで、図2のような建物の屋根部分を切りとった画像ができる。

内外判定は、図3のように判定するピクセルとそれと同じ高さの右端のピクセルが作る線分が建物ポリゴンの辺と何回交わるかを数える。その交点の数が偶数の場合は建物ポリゴンの外側、奇数の場合は建物ポリゴンの内側にあると判定する。

二つの線分が交わるかどうかは三角形の符号付き面積から判断する。A(xA,yA),B(xB,yB),C(xC,yC)を頂点とする△ABCの符号付き面積Sは以下の式(1)ようになる。

$$S = \frac{1}{2} * \{(x^A - x^C) * (y^B - y^C) + (x^B - x^C) * (y^C - y^A)\} \quad (1)$$

例えば、線分Kを構成する点をa,bとし、線分Mを構成する点をc,dとし、△abc, △abd, △cda, △cdbの4つの三角形の符号付面積をS1,S2,S3,S4とすると、S1とS2が異符号かつ、S3とS4が異符号のとき線分Kと線分Mは交わることがわかる[16]。



図2 トリミングを行なった後の画像

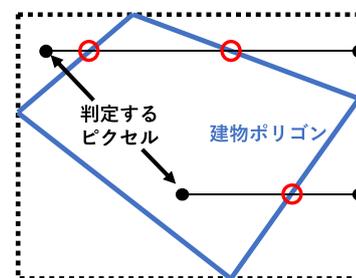


図3 内外判定

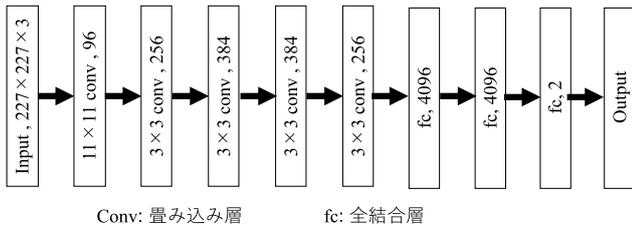


図4 AlexNet の構造



図5 交差検証でのデータ分け

5. DCNN モデルの実験

5.1 用いる DCNN モデル

本研究では AlexNet(図4)という DCNN モデルを用いる。AlexNet は 2012 年の世界的な画像認識コンテスト ILSVRC で優勝したモデルであり、高い精度を持つことが知られている[17]。

5.2 学習方法

画像データはパラメータ更新に用いる「学習データ」と、学習時にモデルの汎用性を評価する「検証データ」と学習後にモデルの精度を評価する「評価データ」に分け、図5のような3回の交差検証を行なった。

一般的に学習回数が多すぎると過学習を引き起こす[18]。よってモデルの汎用性を調べるために、1000回の学習回数毎に検証データの損失関数の1000回分の平均を求め、その平均が上がったときに過学習とみなし、学習を止めた。損失関数とはモデルの予測と実際の正解がどの程度ずれているかを表す指標である。

バッチ数128のミニバッチ学習を行い、ミニバッチ毎のデータの偏りを減らすために、1エポック毎にデータの順番を入れ替えた。そして学習率を学習回数が増す毎に小さくさせるために、パラメータ更新方法に Adam Optimizer を用いた。また、過学習抑制のために重みを小さくさせる weight decay を適用した。

5.3 ブルーシートの有無の判別

(1) 使用するデータ

画像データとして、京都大学防災研究所の山田真澄助教らが撮影した平成30年6月に発生した大阪北部地震で被害を受けた阪急茨木市駅周辺のドローンによる航空写真2枚(約6cm解像度)を、建物ポリゴンの頂点の位置座標として OSM を利用した。

データ数は表1の通りであり、学習データと検証データ

	ブルーシート有り	ブルーシート無し
学習データ	4416(276×16)	4416(2208×2)
検証データ	1472(92×16)	1472(736×2)
評価データ	184	1472

表1 ブルーシート判別のデータ数

	正解率	再現率	MCC
1回目	96.32%	97.83%	0.8432
2回目	97.71%	88.59%	0.8828
3回目	96.98%	93.48%	0.8585
平均	97.00%	93.30%	0.8615

表2 ブルーシート判別の結果

	被害有り	被害無し
学習データ	7152(447×16)	7152(3576×2)
検証データ	2384(149×16)	2384(1192×2)
評価データ	298	2384

表3 直接被害判別のデータ数

のブルーシート有りのデータは左右反転・回転・コントラスト変換を行い、データ数を16倍にし、ブルーシート無しのデータ数と揃えた。また、ブルーシート無しではコントラスト変換によりデータ数を2倍にした。

(2) 結果

結果は表2のようになった。ここで正解率とは全てのデータ数のうち正しく予測できたデータ数の割合であり、再現率とは実際にブルーシートがかかっているデータ数のうち、正しく予測できたデータ数の割合である。また、MCCとはクラス間のデータ数が大きく異なる場合でもモデルの精度を正確に評価できる指標であり、-1から1の間の値を示し、1に近いほど正しい予測ができていとみなせる[19]。

正解率の平均は97.00%、再現率の平均は93.30%、MCCの平均は0.8615となった。

5.4 直接見える被害の判別

(1) 使用するデータ

画像データとして、国土地理院が撮影した2014年4月に発生した熊本地震で被害を受けた熊本県益城町の航空写真(約20cm解像度)を、建物ポリゴンの頂点の位置座標として OSM を利用した。

データ数は表3の通りであり、ブルーシートの有無の判別と同様にデータ拡張を行い、学習データと検証データの被害有りのデータ数を被害無しのデータ数と同等とした。

	正解率	再現率	MCC
1回目	84.08%	64.09%	0.4055
2回目	82.74%	67.11%	0.3992
3回目	85.27%	74.16%	0.4700
平均	84.03%	68.45%	0.4249

表 4 直接被害判別の結果



図 6 ブルーシートがかかっていると間違えて予測した画像

(2) 結果

結果は表 3 のようになり、正解率の平均は 84.03%、再現率の平均は 68.45%、MCC の平均は 0.4249 となった。

5.5 考察

ブルーシート判別において、モデルは図 6 のように青い屋根を持つ画像をブルーシート有り間違えて予測する傾向にあることがわかった。また、図 7 は同様の条件でモデルを学習させた後、評価用データを予測した結果を地図上に可視化した例である。この図からわかる通り、ブルーシートがかかっているのかかかっていると間違えて予測したデータが多かった。ブルーシートがかかっている家屋の方が比較的多い災害では、このような問題が生じてしまう恐れがあると考えられる。

直接被害判別では、正解率・再現率・MCC の全てがブルーシート判別より低い結果となった。再現率が特に低いことから分かる通り、ブルーシートの特徴よりも屋根が被害を受けているという特徴を見つけることが難しいためであると考えられる。また、今回の直接被害判別で使用した画像データ(図 8)の解像度が低いことも大きな原因であると考えられる。しかし、地震災害の頻度の低さと高画質な航空写真を撮ることができるドローンの開発から日が浅いことから、屋根の損傷部分が直接見える高画質な画像データは多くは存在しない。また地震発生から数日後にはブルーシートがかかるため、被災地外からの支援者などがそれまでに撮影を行うことは容易ではない。よって、直接被害判別による迅速な被害予測を行うためにも、行政機関や支援団体、民間企業、研究機関などが協力し、できるだけ迅速に航空写真を撮影し、共有する仕組みが必要であると考えられる。

また図 8 のようにトリミングアルゴリズムにより画像データを作る際、実際の建物の形とはずれて切り抜いているデータが多く存在していた。このずれにより、屋根以外の



図 7 地図上に可視化した例(青丸:正解, 赤四角:予測)



図 8 直接被害判別で使用した画像データ

余分な情報が写ってしまったり、損傷部分が見切れてしまったりしたことにより精度が低下してしまったと考えられる。

6. まとめと今後の展望

本研究では被害認定業務迅速化のために屋根損傷家屋把握システムを提案した。ブルーシート判別では正解率 95% を超える精度となったが、直接被害判別では正解率 84.03%、再現率 68.45%と比較的精度が低い結果となった。

今後は青い屋根などのデータを正しく判別するために、先に青い色を含むかどうかで画像データをふるいにかけたのちに深層学習を用いてブルーシートかどうかを判別するなどの工夫が必要である。また、建物ポリゴンの位置情報に利用している測地系を変更するなどして、建物ポリゴンと実際の建物とのズレを無くすことで精度にどのような影響を与えるかを確認しなければならない。そして学習データの数が乏しい状況を考慮し、精度向上のために学習モデルや学習方法を改良していく必要がある。また屋根被害が出にくい瓦以外の屋根を持つ建物の被害を検出できるようなシステムを構築すると、より被害認定業務を効率化させることができると考えられる。

参考文献

- [1] “被害認定とは” .
http://www.bousai.go.jp/taisaku/pdf/higai_nintei.pdf, (参照 2019-1-20).
- [2] “罹災証明書の概要” .
http://www.bousai.go.jp/taisaku/hisaisayagousei/pdf/risaisayoumeisyo_gaiyou.pdf, (参照 2019-1-20).
- [3] “平成 30 年 3 月改訂の概要” .
<http://www.bousai.go.jp/taisaku/pdf/h3003kaitei.pdf>, (参照 2019-1-20).

- [4] “【大阪北部地震】罹災証明に必須の家屋調査進まず 窓口に住民殺到、調査まで2カ月待ちも… (1/2 ページ) - 産経ニュース”
<https://www.sankei.com/west/news/180627/wst1806270061-n1.html>, (参照 2019-1-20).
- [5] “罹災証明発行に 航空写真を活用 厚真町、認定迅速に：どうしん電子版（北海道新聞）”. https://www.hokkaido-np.co.jp/article/237773?rct=n_hokkaido, (参照 2019-1-20).
- [6] “IMAGENET Large Scale Visual Recognition Challenge: ImageNet Large Scale Visual Recognition Competition 2012 (ILSVRC2012)”. <http://image-net.org/challenges/LSVRC/2012/results.html>, (参照 2019-1-20)
- [7] 松岡佑樹, 藤生慎, 高山純一, 中山晶一郎, 須田信也, 坂口博紀. 小型無人機に搭載した赤外線カメラにより取得される被災地画像データを用いた地震災害直後の建物被害把握. 第55回土木計画学研究発表会・講演集, pp.1-4.
- [8] 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.
- [9] 3次元モデリング技術を活用した建物被害状況の迅速マッピング手法の開発.
[https://www.kenken.go.jp/japanese/research/lecture/h29/pdf/PT14\(Sakata\).pdf](https://www.kenken.go.jp/japanese/research/lecture/h29/pdf/PT14(Sakata).pdf), (参照 2019-1-20)
- [10] 新潟県中越地震における被害認定調査・訓練システムの実践的検証—小千谷市のり災証明書発行業務への適用—,
https://www.jstage.jst.go.jp/article/jisss/7/0/7_123/_pdf/-char/ja, (参照 2019-1-20)
- [11] 震災時における木造建物の被害調査手法の開発—調査目的と調査項目—,
https://www.jstage.jst.go.jp/article/jisss/2/0/2_139/_pdf/-char/ja, (参照 2019-1-20)
- [12] 空中写真 | 国土地理院,
<http://www.gsi.go.jp/gazochosa/gazochosa41006.html>, (参照 2019-1-31)
- [13] 災害ドローン救援隊 DRONEBIRD | クライシス・マッパーズ・ジャパン, <http://dronebird.org/>, (参照 2019-1-20)
- [14] CrisisMappers Japan, <http://crisismappers.jp/about.html>, (参照 2019-1-19)
- [15] OpenStreetMap Japan | 自由な地図をみんなの手に/The Free Wiki World Map,
<https://openstreetmap.jp/#zoom=5&lat=38.06539&lon=139.04297&layers=0BFF>, (参照 2019-6-21)
- [16] 譚 学厚, 平田 富夫, 計算幾何学入門 幾何アルゴリズムとその応用, pp.26-27, 森北出版, 2001
- [17] ImageNet Classification with Deep Convolutional Neural Networks, <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>, (参照 2019-10-20)
- [18] Automatic early stopping using cross validation: quantifying the criteria, https://ac.els-cdn.com/S0893608098000100/1-s2.0-S0893608098000100-main.pdf?_tid=81b43c15-1c7b-4275-8716-a8ff4f7b7b8a&acdnat=1552112269_e37d123071e7da147716703839d69cbd, (参照 2019-3-9)
- [19] B.W.MATTHEWS, COMPARISON OF THE PREDICTED AND OBSERVED SECONDARY STRUCTURE OF T4 PHAGE LYSOZYME, *Biochimica et Biophysica Acta*, 405 (1975) 442-451