

## コンシューマ・サービス論文

画像セグメンテーションを用いた屋根面分割  
による屋根損傷率自動算出手法の開発藤田 翔乃<sup>1,a)</sup> 畑山 満則<sup>2</sup>

受付日 2021年10月10日, 採録日 2022年2月10日

**概要:** 災害が起こった際、自治体は被災した住家の被害の程度を調査し、被災者に罹災証明書を交付する。罹災証明書は被災者の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ため、自治体は迅速かつ正確に発行しなければならない。しかし、これまでの地震災害では被害認定調査・罹災証明書発行に多くの時間を要しており、円滑な被災者支援を妨げていた。加えて現在の屋根調査においては、屋根すべてを見渡すことができず、正確に屋根調査を行えていない。そこで、本研究では航空写真から自動で屋根損傷率を算出する画像処理モデルを開発した。筆者らの先行研究(2020)から得た学習データの不足という問題に対して、本研究は深層学習による画像セグメンテーションを用いて屋根画像を屋根面で分割して学習データを増加させるという方法をとった。

**キーワード:** 画像認識, セグメンテーション, 被害認定調査, 地震災害

Development of Automatic Method to Calculate Damage Rate of  
Roof Dividing Roof Image into Sections by Image SegmentationSHONO FUJITA<sup>1,a)</sup> MICHINORI HATAYAMA<sup>2</sup>

Received: October 10, 2021, Accepted: February 10, 2022

**Abstract:** In the event of a natural disaster, Japanese local governments investigate the level of damage of the buildings and issue damage certificates to the victims. The damage certificate is used to determine the contents of support provided to the victims; hence, they must be issued rapidly and accurately. However, in the past, the investigation of damage was time consuming, thus delaying the support provided to the victims. Additionally, while investigating the roof of the damaged building, it was difficult for the investigators to look at the entire roof and calculate the damage rate accurately. To address this issue, we have developed an image processing model to automatically calculate the rate of damage on a roof through image recognition from aerial photos. To circumvent the problem of lack of training data reported in our previous study (2020), in this study, roof images were divided into roof surfaces based on image segmentation by deep learning, and the number of training data was increased.

**Keywords:** image recognition, segmentation, building damage investigation, earthquake

## 1. 研究背景と目的

## 1.1 被害認定調査における問題

地震や風水害などの災害が起こった際、自治体は被災し

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ため、自治体は迅速かつ正確に発行しなければならない [2]。東日本大震災の後に災害対策基本法が改定され、罹災証明書を遅滞なく発行することが義務付けられた [3]。しかし、これまでの地震災害では被害認定調査・罹災証明書発行に多くの時間を要しており、円滑な被災者支援を妨げていた。

<sup>1</sup> 京都大学大学院情報学研究科  
Graduate School of Informatics, Kyoto University, Kyoto  
606-8501, Japan

<sup>2</sup> 京都大学防災研究所  
DPRI, Kyoto University, Uji, Kyoto 611-0011, Japan

<sup>a)</sup> fujita.shono.32x@st.kyoto-u.ac.jp

また部位による判定の1つである屋根被害調査において、屋根すべてを見渡すことができず、遠くから見ると地上から見える範囲で調査を行っている。加えて、屋根面ごとに損傷程度を算出する必要があり、高度な専門的知識を要する。地上から見ることしかできないという調査方法に加え、専門的知識を有しない調査員からすると正確に屋根調査を行うことは非常に困難であり、多くの時間を要する。

## 1.2 災害時の航空写真の利用

2016年4月に発生した熊本地震の後、内閣府は平成30年3月に「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[4]、「航空写真等を活用して『全壊』の判定が可能」を明記したことから、航空写真の積極的な利用を促進していることが分かる。

また、災害時には多様な行政機関や研究機関が航空機やドローンを利用して航空写真の撮影を行っている。国土地理院は被災地域の航空写真を撮影し、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[5]。特定非営利活動法人クライシスマップャーズ・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おり、ドローンで撮影した航空写真から人命救助などの支援活動を行っている[6]。よって、災害時にはこれらの機関により航空写真データを利用できることが分かる。

## 1.3 深層学習における課題

筆者らの先行研究[1]において、屋根画像から深層学習を用いて損傷部分の有無とブルーシートの有無の判別を行った。損傷部分判別の精度は balanced accuracy が 75.58%、再現率が 67.50% であり、ブルーシートの精度は balanced accuracy が 93.16%、再現率が 93.49% であった。ここで balanced accuracy は 2 クラスの再現率の平均を表す。損傷部分判別において両方の値が低いという結果に対して、特徴抽出が困難であったこと、利用していた航空写真データがドローンではなく航空機による写真であったことが原因であると結論づけた。深層学習モデルの精度を向上させるには学習データを豊富に利用することが必要である。しかし、地震災害により損傷を受けた屋根を映した高画質な航空写真は豊富に存在しない。この理由としては、地震災害の頻度が低いこと、高画質な航空写真データを撮影できるドローンの開発からまだ日が浅いこと、ブルーシートがかかる前に撮影を行わなければならないという時間的制約が存在することなどがあげられる。したがって、災害時の航空写真から深層学習を行う本研究の課題として、精度向上に必要な学習データが豊富には存在しないということが考えられる。

## 1.4 研究目的

上記の研究背景から、本研究では従来の現地調査員による判定以上の精度で航空写真から屋根損傷率を自動算出する画像処理モデルを開発する。また、上記の課題に対して学習データを増加させるために、深層学習により屋根面を分割するモデルも開発し、精度向上を目指す。これらにより迅速かつ正確な屋根被害調査が行われることが期待される。

## 2. 先行研究

松岡らの研究[7]では、赤外線カメラ搭載 UAV の赤外線画像における色の特徴により被害箇所と無被害箇所の判別を行った。釜ヶ谷らの研究[8]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深層学習を用いて被害の程度のカテゴリ推測を行った。本研究では、上記の研究のような特殊な航空写真ではなく、比較的安価で飛行が容易な航空機やドローンなどからの航空写真を用いる。これにより、容易に学習データの増加や、災害時の推測データの取得を行うことができる。また、航空写真から1つ1つの建物のデータを取得する際、上記の研究では1枚1枚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。本研究では地理空間情報の建物ポリゴンの位置情報を用いた独自のトリミングアルゴリズムにより、自動で建物の画像を切り出してデータを作成する。

Ji ら[9]は発災前後の航空写真の差分情報からテクスチャ解析と CNN により特徴を抽出し、ランダムフォレストを利用して被害建物を推測した。これは被害のあった建物の屋根の変化が発災前後の航空写真の差分情報として現れることを利用している。しかし被害のあった地域において、発災前の航空写真の撮影時期が古く、建物の情報が発災時と大きく異なる可能性がある。この場合差分がある建物には、被害がある建物だけではなく新築の建物や取り壊しになった建物が含まれてしまう。本研究では、発災後の航空写真のみを利用するためこのような問題は生じないと考えられる。

利根川ら[10]は、被災瓦礫量推定のために東日本大震災で倒壊・流出した家屋を航空写真から深層学習を用いて推測を行った。内藤ら[11]は災害対応を迅速化することを目的として、複数の地震における航空写真を用いて深層学習により木造建物の被災程度を自動判別した。Miura ら[12]は航空写真から深層学習を用いて、倒壊建物とブルーシートがかかった建物を検出した。これらの研究により、災害時において被害建物を抽出するために、航空写真を用いた深層学習による画像認識が有効であることが分かる。しかし、これらは倒壊建物や建物全体の被害を判定したものであり、屋根の損傷率を判定したものは存在していない。

屋根面分割における先行研究では、Susaki[13]は輝度値

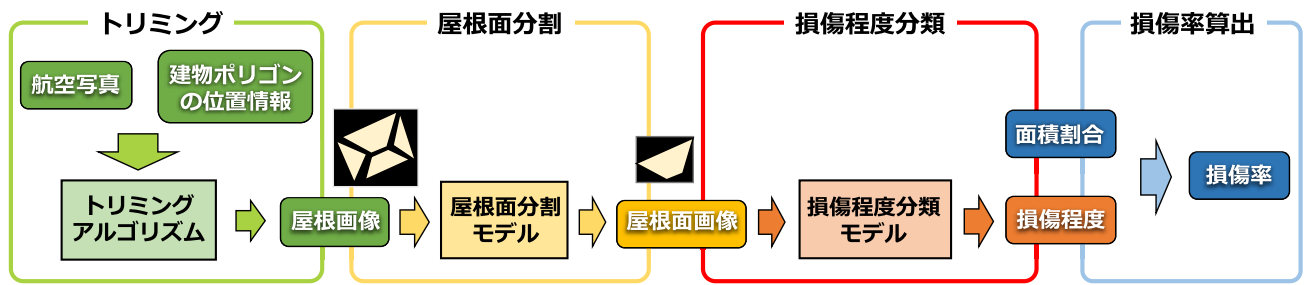


図 1 本研究の屋根損傷率算出のフロー

Fig. 1 Calculation flow of roof damage rate in this study.

を少数個の値に離散化し、長方形に近い領域を優先的に抽出し、屋根領域を分割した。このとき、離散化の幅を複数用意することで、影を持つなどの輝度値の分散が大きいテクスチャを持つ屋根でも対応することができた。しかしこれは屋根面ではなく、1つの建物の屋根を抽出するものであるため、長方形に焦点を当て屋根と認識しているが、屋根面を分割する際、長方形以外の形の領域も抽出する必要がある。また、このような色・テクスチャ情報から抽出を行う方法では、地震災害による損傷や屋根面上の汚れなど不規則な部分が存在する場合、誤って1つの屋根面であると認識する恐れがある。以上のようなことから、本研究では形や色、テクスチャ情報だけではなく、より複雑の特徴から、様々な形の屋根を抽出できる深層学習の segmentation モデルによる屋根面抽出・分割を行う。Segmentation モデルとは画像内の物体ごとの領域を抽出するものであり、これを利用することで屋根面を抽出・分割することができると思われる。

### 3. 屋根損傷率自動算出手法の開発

#### 3.1 被害認定調査における屋根損傷率算出手法

部位による判定では壁や基礎、屋根の損傷率を算定し、それらの合計から建物の被災度を決定する。この屋根の損傷率は式 (1) のように、屋根面ごとに損傷程度と面積割合をかけ、それをすべての屋根面で足し合わせることで算出される。損傷程度は、損傷の種類や損傷箇所により百分率で表される。同一屋根面内で損傷程度が異なる部分が存在する場合は面積の加重平均で損傷程度が求められる。

$$\text{損傷率} = \sum_i \frac{\text{屋根面 } i \text{ の面積}}{\text{全体屋根面積}} \times \text{屋根面 } i \text{ の損傷程度}$$

#### 3.2 本研究における屋根損傷率算出手法

図 1 に本研究の屋根損傷率算出手法のフローを示す。本手法では、トリミング、屋根面分割、損傷程度分類、損傷率算出の4つの処理を行い、屋根損傷率を自動で算出する。

#### 3.3 学習データ不足に対する解決手法

1.3 節の課題をふまえ、本研究では図 1 のように屋根画

像を屋根面で分割し、学習データを増加させるという方法をとる。1つのトリミング屋根画像から複数の屋根面画像を作ることにより、数倍の数の屋根損傷画像の学習データを得ることができる [1]。そして、分割された屋根面画像は損傷程度分類モデルへ入力され、損傷程度が推測される。その値と面積割合をかけ、各屋根面で足し合わせることで最終的な屋根ごとの損傷率を算出することができる。

Ise ら [14] は画像中のコケに識別のために、画像を細切れにした学習データを利用して深層学習を行うことを提案し、高い精度をもたらした。これにより、1枚の画像から多量の学習データを生成することが可能になるだけでなく、形状が不安定な対象物についても深層学習により分類を行うことができることが分かった。また、分割することは画像内の損傷部分を大きくすることができ、検出をより容易にさせることができると考えられる。そして、分割された画像はサイズが小さくなっており、保持する情報量も小さくなっているため、後の損傷程度分類モデルに必要なパラメータ数を削減できることが期待される。被害認定調査の観点からは、この本研究の手法は実際の調査手法に沿っており近い算出結果が期待できるほか、被災者の推測数値に対する懐疑心も軽減されると考えられる。

### 4. トリミングアルゴリズム

トリミングアルゴリズムでは、航空写真と地理空間情報である建物ポリゴンの頂点の位置情報を用いることで、図 2 のように屋根画像データを自動で作成することができる。筆者らの先行研究 [1] においても、この手法を用いてデータを作成した。これは図 3 のように航空写真の各ピクセルを建物ポリゴンの内にあるか外にあるかの内外判定を行い、内にあるピクセルの色はそのまま、外にあるピクセルは黒色とすることで実装することができる。対象とするピクセルから半直線を伸ばし、その半直線とポリゴンとの交点の数が奇数である場合は内、偶数である場合は外であると判定することができる。

トリミングにより航空写真から1つ1つの建物を切り抜くことから、画像データを作成する時間を削減することができ、迅速に推測することが可能となる。加えて大量の




図 2 トリミングアルゴリズム  
Fig. 2 Trimming algorithm.




図 3 ピクセルの内外判定  
Fig. 3 Judging pixel inside of building polygon.

学習データを作成することができる。また、建物ポリゴンを利用していることから、エリア・メッシュ単位での推測ではなく、建物単位での推測を行うことができ、より詳細な情報を得ることができる。利根川ら [10], 内藤ら [11], Miura ら [12] の先行研究でも同様に建物ポリゴンを利用して、画像データを作成している。しかし、目的が建物全体の被害検出であるため、建物ポリゴンの外接四角形を利用するなどしてポリゴンの外の情報も画像データに含んでいる。本研究のトリミングアルゴリズムでは、上記の先行研究とは違い、図 3 のような方法を用いて屋根以外の部分を黒く塗り、屋根部分のみを抽出することができる。これにより、屋根損傷率算出に不要な地上部分などの情報を排除でき、精度向上が期待できる。

## 5. 屋根面分割

### 5.1 Segmentation モデル

深層学習を用いた segmentation モデルは semantic segmentation モデルと instance segmentation モデルの 2 種類が存在する。どちらの segmentation モデルとも画像内の各ピクセルのクラスを分類し領域を抽出するが、semantic segmentation は画像内の同クラスの物体を個別に認識することができない。深層学習を用いた semantic segmentation モデルの 1 つである deeplab V3 plus [15] を利用し屋根面分割を試みたが、図 4 のように屋根面同士が結合し 1 つの屋根面となった。このように semantic segmentation では隣接する屋根面を個別に認識することができず、1 つの屋根面として抽出されてしまう。よって本研究では、instance segmentation を利用する必要があることが分かる。

本研究は、深層学習を用いた instance segmentation モデ




図 4 semantic segmentation による屋根面分割  
Fig. 4 Result of division by semantic segmentation.

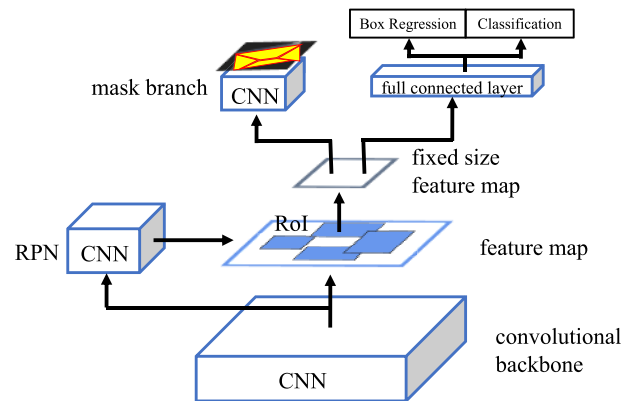


図 5 Mask R-CNN の構造  
Fig. 5 Structure of Mask R-CNN.

ルのうち Mask R-CNN [16] を利用する。これは世界的な画像コンペティションである 2016 年の COCO challenge において、instance segmentation, bounding-box object detection, person key point detection の 3 つのタスクで優勝したモデルである。Mask R-CNN のモデルを図 5 に示す。このモデルでは、まず畳み込み層である convolutional backbone 層から特徴を抽出し、feature map を得る。次に畳み込み層である RPN (Region Proposal Network) 層で物体らしい領域 RoI (Region of Interest) の外接四角形を得る。Feature map から RoI の領域を抽出し、固定されたサイズに変換を行う。その抽出・サイズ変換した領域を畳み込み層である mask branch に入力し、ピクセルごとに物体か背景を分類する。同時に抽出・サイズ変換した領域を全結合層に入力し、物体領域の誤差とクラス分類の結果を得る。最後に全結合層のクラス分類結果と、mask branch の物体に分類したピクセルから画像内の物体領域を抽出することができる。このモデルはクラス分類タスクと segmentation タスクを分けることで計算量を削減し、精度を向上させている。

### 5.2 利用するデータ

学習データとして、熊本地震後の益城町付近の航空写真から基盤地図情報の建物ポリゴンを用いてトリミングした屋根画像を利用した。この航空写真はドローンではなく、航空機によるものであり解像度は 20 cm 分解能である。そ




図 6 損失関数の推移 (左: 初期実験, 右: 追加実験, 橙線: 学習データ, 青線: 検証データの移動平均)

Fig. 6 Loss function (left: the first experiment, right: the additional experiment, orange line: train data, blue line: validate data).

表 1 初期実験の分割結果

Table 1 Division result of the first experiment.

	全体	屋根面内 損傷画像	屋根面境界 損傷画像	木の葉が 映った画像
平均IoU	0.7580	0.7341	0.6874	0.7237
平均AP	0.6670	0.6846	0.5752	0.3979

して、このトリミング屋根画像にアノテーションツール「labelme」を用いて、屋根面領域のラベルを入力した。その入力時間はおおよそ屋根画像1枚につき、約1分であり、合計8~9時間の時間を要した。パラメータ更新のための学習データとして2,400枚(300×8)、過学習確認のための検証データとして800枚(100×8)、モデルの精度評価のための評価データとして800枚(100×8)のトリミング屋根画像を用いた。それぞれ、元の画像に対して左右反転、90度・180度・270度回転をさせて8倍にデータ数を増加させた。損傷のある屋根画像にもモデルを対応させ、評価するために、学習データ・検証データ・評価データそれぞれに屋根損傷のある画像データを含ませた。建物ポリゴンと実際の建物の位置は多少のずれが生じており、大きくずれている屋根画像と人の目で屋根面が判断できない画像に関してはこれらのデータから排除した。

### 5.3 学習概要

あらかじめCOCOデータセットで学習させたモデルに対して、トリミング屋根画像、屋根面領域のラベルを用いて再度学習を行うfine tuningを行った。一般的に学習を行きすぎると学習データに特化したモデルとなり、汎化性能を失い、精度が低下する。そこで、検証データでモデルの損失関数を確認し、それが増加したときを過学習と見なし、学習を止めた。本実験の損失関数は、RPNのRoIの位置のずれによる損失関数、RPNのRoIの物体か背景の分類による損失関数、最終全結合層の物体領域の位置ずれに

よる損失関数、最終全結合層のクラス分類による損失関数、mask branchの物体か背景かクラス分類による損失関数の合計である。分類クラスは屋根か背景かの2クラス、入力の画像サイズは256×256、バッチサイズは2、1エポックあたりのステップ数は100、検証データの損失関数計算のステップ数は5であった。また、GPUとしてNVIDIA社のTesla K40cとGeoForce GTX 1060 6GBを利用した。

### 5.4 初期実験の分割結果

初期実験として、1,000エポックの学習を16時間4分かけて行い、上記のデータで評価をした。学習データと検証データの損失関数の推移を図6左に示す。損失関数の推移からエポック500あたりから上昇が見られたので、エポック500で学習を止めたモデルを利用した。その結果は表1が示すように画像ごとの平均IoUが0.7580、平均APが0.6670であり、そのヒストグラムは図7のようになった。ここでIoUとは正解領域と推測領域の重なり具合を示すものであり、積集合を和集合で割った値である。各画像が持つ複数の推測領域のIoUの平均を求め、さらに画像ごとのその平均をとった。また、APとは画像ごとで求められる推測の適合率と再現率の高さを表す指標である。

インスタンス平均IoU・APが高かった画像を図8左に、インスタンス平均IoU・APが低かった画像を図8右に示す。平均IoU・APが高かった画像を見ると屋根面の領域が大きく、領域数が少ない傾向にあることが分かる。逆に平均IoU・APが低かった画像を見ると屋根面の領域が小




図 7 IoU (左) と AP (右) のヒストグラム  
 Fig. 7 Histogram of Iou and AP.




図 8 左: IoU・AP が高い画像, 右: IoU・AP が低い画像 (各列左から元画像, 正解領域, 推測領域)

Fig. 8 Left: Roof images with high IoU and AP, right: Roof images with low IoU and AP (Each row shows original image, correct region, and estimated region from left to right).




図 10 木の葉が映った屋根画像 (各列左から元画像, 正解領域, 推測領域)

Fig. 10 Roof images with leaf (Each row shows original image, correct region, and estimated region from left to right).




図 9 左: 屋根面内に損傷がある屋根画像, 右: 屋根面境界に損傷がある屋根画像 (各列左から元画像, 正解領域, 推測領域)

Fig. 9 Left: Roof images with damage in roof surface, right: Roof images with damage in boundary (Each row shows original image, correct region, and estimated region from left to right).

さく, 領域数が多い傾向にあり, 隣接する屋根面の色の差が小さいなど境界線が薄い画像も多かった. また, 複数の推測領域が重なる部分が存在すること, 推測されていない見逃し領域が多くあることが分かった.

### 5.5 特徴を持つ屋根画像

図 9 のような損傷部分を持つ屋根画像に着目すると, 屋根面内に損傷がある画像 (図 9 左) と屋根面境界部分に損傷がある画像 (図 9 右) で屋根面分割の精度が異なってい

ることが分かった. 屋根面内に損傷がある画像 40 枚 (元画像は 5 枚) では, 表 1 が示すように平均 IoU が 0.7341, 平均 AP が 0.6846 であった. すべての画像の平均と比較すると IoU は 0.0239 低く, AP は 0.0176 高くなっていたことから, 屋根面内に損傷がある画像はその他の屋根画像とほとんど同等の精度で屋根面分割を行えたといえる. つまり, 損傷などによる屋根面内の色や模様が不連続であっても, 正確に屋根面分割を行えていることから, 深層学習の instance segmentation の利用が有効であったといえる. 屋根面境界部分に損傷がある画像 40 枚 (元画像は 5 枚) では, 表 1 が示すように平均 IoU が 0.6874, 平均 AP が 0.5752 であった. すべての画像の平均と比較すると IoU が 0.0706, AP が 0.0918 低くなっていたことから, 屋根面境界部分に損傷がある画像はその他の屋根画像と比較すると, 正確な屋根面分割が行えていないことが分かる.

また, 平均 IoU・AP が低い画像の中には上述した特徴を持つ屋根だけではなく, 図 10 のように木の葉が映った屋根が多いことが分かった. 表 1 が示すように, この木の葉が映った屋根画像 24 枚 (元画像 3 枚) の平均 IoU が 0.7237, 平均 AP が 0.3979 であり, すべての画像の平均と比較すると IoU が 0.0343, AP が 0.2691 低くなっていた. これは葉によって屋根部分が隠れてしまったことに加えて, 葉の周り付近は屋根面ではなく庭や道路などの外の地

表 2 追加実験の分割結果

Table 2 Division result of the additional experiment.

	全体	屋根面境界 損傷画像	木の葉が 映った画像
平均IoU	0.7672	0.6858	0.7074
平均AP	0.6934	0.6094	0.4628

面であると誤って認識していると考えられる。これは建物ポリゴンと実際の建物の位置にずれが生じ、学習データの一部で、屋根以外の外の地面部分が木の葉とともに多少映り込んだことが原因であると考えられる。このずれによって現れた葉の周り付近は外の地面であるため屋根と認識する必要はない。しかし、木の葉によって一部隠れてしまった本来屋根である部分付近もこの傾向により屋根と認識しなかったと考えられる。

### 5.6 追加実験の分割結果

以上のような特徴を持つ画像にも対処するために、学習データに屋根面境界部分に損傷を持つ屋根画像、木の葉によって隠れてしまった屋根画像をそれぞれ 160 枚（元画像は 20 枚）を新たに加え、学習データ 2,720 枚、検証データ 800 枚、評価データ 800 枚で、追加実験として同様に学習を行った。図 6 の右のような損失関数の推移からエポック 600 あたりから上昇が見られたので、エポック 600 で学習を止めたモデルを利用した。その結果、表 2 が示すように全体の平均 IoU が 0.7672、平均 AP が 0.6934 となり、初期実験と比べて両方の値とも増加が見られた。表 2 が示すように、屋根面境界に損傷を持つ屋根画像 40 枚の平均 IoU は 0.6858、平均 AP は 0.6094 であり、初期実験と比べると平均 IoU は 0.0016 の減少が、平均 AP は 0.0342 の増加が見られた。木の葉が映った屋根画像 24 枚の平均 IoU は 0.7074、平均 AP は 0.4628 であり、初期実験と比べると平均 IoU は 0.0163 の減少が、平均 AP は 0.0649 の増加が見られた。屋根面境界に損傷を持つ屋根画像、木の葉が映った屋根画像とも、両方の値の増加は見られなかったが、両方の値の増減の差を考慮すると学習データの増加により、それらの画像においてある程度の精度上昇が起こったと考えられる。

### 5.7 分割後の画像処理

#### (1) 重なった部分の削除

損傷部分の重複抽出、面積割合の過大評価を防ぐために推測領域が重なる部分を削除する必要がある。どの推測領域が正しいかを選択し、それ以外の推測領域を排除することで重なる部分を削除することができる。

図 11 のような重なった部分を持つ屋根画像から、面積が大きい領域が小さい領域にまで拡張しているものが多いことが分かった。そこで追加実験の推測の後、重なった領




図 11 重なった部分を持つ屋根画像（各列左から元画像、正解領域、推測領域、推測領域（重なり削除））

Fig. 11 Roof images with overlapping regions (Each row shows the original image, correct region, estimated region and estimated region after eliminating the overlapping regions from left to right).




図 12 見逃し領域を拡張した屋根画像（各列左から元画像、正解領域、推測領域、推測領域（重なり削除））

Fig. 12 Roof images with overlooked regions (Each row shows the original image, correct region, estimated region and estimated region after eliminating the overlooked regions from left to right).

域のうち面積が小さい領域を自動で選択し、それ以外を排除して、重なった部分を削除した。それぞれの屋根面の面積は、ピクセル数を数えることで比較することができる。

#### (2) 見逃し部分の削除

推測損傷部分の見逃し、面積割合の過小評価を防ぐためにどの推測領域にも含まれていない屋根部分を削除する必要がある。そこで、面積が小さい領域を選択する重なった部分の削除を行った後、図 12 のように推測領域を拡張させることでその見逃し部分の埋め合わせを行った。ここでは、建物ポリゴン内の画像領域に見逃し領域が存在しなくなるまで、各推測領域が同等の速さで四方に広がるアルゴリズム（図 13）を作成し、推測領域の拡張を行った。

Instance segmentation により屋根面が分割され、重なり部分の削除、見逃し部分の削除の二処理を行った後、図 14 のように屋根面個別の画像データを作成した。トリミング画像と同様に屋根以外の部分は黒色とした。

**Algorithm 1** Delete Overlooked Region

---

```

1: while overlooked region exist in building polygon region of image do
2:   for  $R_i \in$  all estimated regions do
3:      $R' \leftarrow R_i$ 
4:     for  $P_j \in$  all pixels in  $R_i$  do
5:       for  $P'_k \in$  pixels adjacent to top, bottom, left and right of  $P_j$  do
6:         if  $P'_k$  is in building polygon and  $P'_k$  is not in any estimated regions then
7:            $P'_k$  is added to  $R'$ 
8:         end if
9:       end for
10:    end for
11:     $R_i \leftarrow R'$ 
12:  end for
13: end while

```

---

図 13 見逃し領域削除のアルゴリズム

Fig. 13 Algorithm to remove overlooked region.




図 14 屋根面画像の作成例

Fig. 14 Example of divided roof surface data image.

## 6. 損傷程度分類

### 6.1 モデル概要

本研究では損傷程度分類モデルにおいても深層学習モデルの1つのResNet50 [17] を利用し、屋根面ごとの損傷程度を推測するモデルを構築する。このResNetは2015年の世界的画像認識コンテストのILSVRCで優勝したモデルであり、画像分類において高い精度を持つことで知られている。またILSVRCとは1,000クラスものカテゴリ进行分类するものであるため、ResNetは高い汎用性を持つモデルであるといえる。一般的に深層学習において、層数が多いモデルは複雑な表現力を持ちうる [18]。しかし層数が多すぎる場合、誤差逆伝播の際に損失関数の勾配が下層に伝わる事ができず、パラメータの更新が行われない勾配消失が生じる。ResNetではresidualモジュールというショートカットの層を追加させることで、層数を増やしても勾配を消失させず下層に伝えることができる。また、深層学習APIの1つであるkeras Applicationsでは層数の違いによる複数の種類のResNetを提供している [19]。本研究は分類タスクが損傷程度に限定されていること、屋根面分割により画像サイズが減少していることから、パラメータ数が最も少ないResNet50を利用する。

### 6.2 データ作成

屋根面分割により作成される屋根面画像データは、解像度20cm分解能の屋根画像を分割したものであるため画質

が荒く、詳細に損傷程度を決定できるとはいえない。よって本研究では屋根面を被害なし、被害あり(-25%)、被害あり(25-50%)、被害あり(50-75%)、被害あり(75%-)の5クラスに分類し、損傷程度を推測するモデルを構築する。ここでは、図15のようにデータを作成した。評価データとして損傷がある屋根画像を30枚、損傷がない屋根画像を30枚使用した。損傷がある屋根画像30枚は、多様な損傷程度の屋根面画像を入手するために大まかに被害程度のばらつきがあるように選択した。損傷がある屋根画像に5章のモデルを利用して屋根面分割をし、それらの屋根面画像208枚に対して、実際に被害認定調査の経験がある高知県四万十町危機管理課の職員に損傷程度ラベルの入力を行ってもらった。入力の際には図16のように、屋根面画像、その屋根面を色付けた屋根全体画像、屋根全体のみ画像の3つから判断を行ってもらった。学習データ・検証データとして、損傷がある屋根画像を684枚、損傷がない屋根画像を500枚使用した。この損傷がある屋根から分割された屋根面画像4,392枚に対して、評価データのラベルや損傷程度例 [1]などを参考にし、筆者自らラベル入力を行った。その結果、損傷がある屋根画像684枚から合計2,171枚の損傷がある屋根面画像を作成したため、3.174倍の学習データの増加を行うことができたといえる。図15のとおり、これらの学習データ・検証データに左右反転や回転を行い、クラス間のデータ数をほぼ同じにした。また被害なしのデータは、加えて多様な種類の屋根を持つように、1つの屋根からは1つの屋根面を選出するようにした。

また、筆者が行った学習データ・検証データ作成の際、約24,000枚の屋根面画像から損傷がある屋根画像684枚を抽出するのに約10時間、そこから分割された屋根面画像4,392枚の損傷程度のラベルづけを行うのに約12時間の時間を要した。自治体職員が行った評価データ作成の際には、屋根面画像208枚に対して約2時間の時間を要した。

### 6.3 学習概要

上記のデータを用いて、バッチサイズ16、入力画像サ



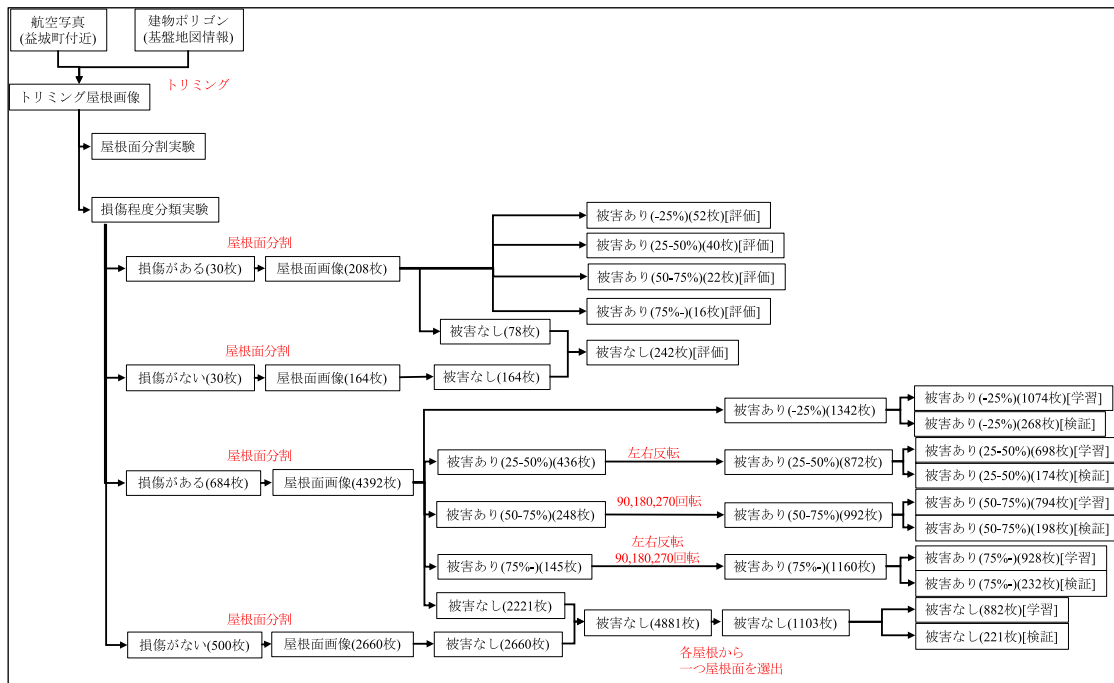


図 15 損傷程度分類に用いたデータ内訳

Fig. 15 Breakdown of data used in classification of degree of damage.



図 16 入力の際の判断画像

Fig. 16 Image used for judgement in inputting.

サイズ 256 × 256, 損失関数として交差エントロピーを用いて ResNet50 を学習させた。このとき, ImageNet という大規模データセットであらかじめ学習をさせた ResNet50 モデルに再度学習を行う fine tuning を行った。NVIDIA 社の GeoForce GTX 1060 6GB の GPU を利用して, 200 エポックで 5 時間 56 分を要した。その損失関数, 正解率の推移を図 17 に示す。ここで 1 エポックはすべての学習データを 1 回学習させる回数とし, 274 回の学習を意味する。図 17 から, 正解率が高いかつ損失関数が減少したエポック 150 のモデルを利用した。

6.4 推測結果

評価データを用いたモデルの推測結果は表 3 の混同行列のようになった。各クラスの再現率は被害なしが 0.7479, 被害あり (-25%) が 0.5577, 被害あり (25-50%) が 0.1250, 被害あり (50-75%) が 0.1364, 被害あり (75%-) が 0.2500, 平均再現率は 0.3634 となった。各クラスの再現率から, 被害なしのデータより被害ありのデータ, 特に被害あり (25-50%), 被害あり (50-75%), 被害あり (75%-) の再

表 3 損傷程度分類の混同行列

Table 3 Confusion matrix of classification of damage.

		正解					平均再現率
		被害なし	被害あり (-25%)	被害あり (25-50%)	被害あり (50-75%)	被害あり (75%-)	
推測	被害なし	181	15	9	4	0	
	被害あり (-25%)	42	29	19	6	6	
	被害あり (25-50%)	8	5	5	5	5	
	被害あり (50-75%)	6	1	3	3	1	
	被害あり (75%-)	5	2	4	4	4	
再現率		0.7479	0.5577	0.1250	0.1364	0.2500	0.3634

表 4 各クラスの推測割合

Table 4 Matrix of tendency of estimation by our model.

		正解				
		被害なし	被害あり (-25%)	被害あり (25-50%)	被害あり (50-75%)	被害あり (75%-)
推測	被害なし	0.7479	0.2885	0.2250	0.1818	0.0000
	被害あり (-25%)	0.1736	0.5577	0.4750	0.2727	0.3750
	被害あり (25-50%)	0.0331	0.0962	0.1250	0.2273	0.3125
	被害あり (50-75%)	0.0248	0.0019	0.0750	0.1364	0.0625
	被害あり (75%-)	0.0207	0.0380	0.1000	0.1818	0.2500

現率が低いことが分かる。また表 4 に, それぞれの混同行列の値を各クラスの実際のデータ数で割り, 各クラスのデータがどのくらいの割合でどのクラスに予想されているかの割合を示す。これから被害の大きな屋根面である被害あり (25-50%), 被害あり (50-75%), 被害あり (75%-) のデータの損傷程度が過小評価されている傾向にあることが分かる。

図 18 に損傷程度が過小評価されてしまったデータ例を示す。これらの屋根面は, 対象屋根面に瓦の崩れなどの損傷部分の面積は小さいが, 屋根全体が大きく崩れているものや, 対象屋根面に損傷部分のみが映っているものが多




図 17 左：損失関数の推移，右：正解率の推移，左橙線：学習データ損失関数，左青線：検証データ損失関数の移動平均，右橙線：学習データ正解率，右青線：検証データ正解率の移動平均

Fig. 17 Left: loss function, right: accuracy, orange line: train data, blue line: validate data.




図 18 被害が大きいが過小評価されたデータ（各列左から推測対象の屋根面画像，全体屋根画像のうち推測対象屋根面が色付けされたもの，全体屋根画像，上正解：被害あり（75%-），上推測：被害あり（-25%），中正解：被害あり（50-75%），中推測：被害なし，下正解：被害あり（25-50%），下推測：被害なし）

Fig. 18 Underestimated roof images with extensive damage. The true label of the upper row images was damage (75%-), estimated label of upper row was damage (-25%), true label of middle row was damage (50-75%), estimated label of middle row was no damage, true label of lower row was damage (25-50%), estimated label of lower row.

かった。これらは、評価データの損傷程度のラベル入力の際、対象の屋根面だけではなく他の屋根面などの情報を考慮して、判断が行われていたと思われる。したがって、屋根面だけの情報から学習、推測を行っているモデルが過小評価してしまっていると考えられる。またラベル入力の際、低画像の航空写真を使用していることから、ラベル判定基準として個人の主観が混入していると考えられる。したがって、これら過小評価されたデータに関しては学習データのラベル入力を行った筆者の判定傾向が、正解である評




図 19 被害がないが被害ありと推測したデータ（各列左から推測対象の屋根面画像，全体屋根画像のうち推測対象屋根面が色付けされたもの，全体屋根画像，上正解：被害なし，上推測：被害あり（-25%），中正解：被害なし，中推測：被害あり（-25%），下正解：被害なし，下推測：被害あり（25-50%））

Fig. 19 Roof images without damage estimated as damaged. The true label of upper row was no damage, estimated label of upper row was damage (-25%), true label of middle row was no damage, estimated label of middle row was damage (-25%), true label of lower row was no damage, estimated label of lower row was damage (25-50%).

価データのラベル入力者の判定傾向と多少異なっていたことも、影響していると考えられる。

また、被害なしの屋根面画像のうち被害ありと推測したデータを図 19 に示す。これらから、瓦屋根の光の反射による表面のざらつき、建物ポリゴンのズレによる地面や外の物体、屋根境界にある別素材などを損傷と誤って推測してしまっていることが分かる。このように損傷部分と似た部分は多種多様に存在しているため、より多様な被害なし屋根面画像を学習データに追加することが精度向上に必要であると考えられる。

## 7. 損傷率算出

### 7.1 推測損傷率算出手法

本研究では5章で分類推測した5クラスに対して、被害なしを0、被害あり(-25%)を0.125、被害あり(25-50%)を0.375、被害あり(50-75%)を0.625、被害あり(75%-)を0.875として損傷程度を割り当て、面積割合をかけた値をすべての屋根面で合計することで屋根損傷率を算出する(式(1))。面積割合は、各屋根面のピクセル数を全体の屋根のピクセル数で割ることで求めることができる。ここで屋根面、全体の屋根のピクセルとは、トリミングを行い屋根ではないとされた部分である黒色のピクセル以外を指す。

### 7.2 正解誤差を用いた本研究の算出手法の評価

屋根損傷率の正解ラベルを入手するために、屋根面の損傷程度ラベルと同様に四万十町危機管理課の職員の方に、図15に示す評価データのうち損傷のある屋根画像30枚に対して、被害認定調査における屋根損傷率の入力を依頼した。この屋根画像30枚の屋根ごとに入力された全体屋根損傷率と、5章で述べた屋根面ごとに入力された損傷程度ラベルから本研究による上記の方法で屋根損傷率を算出した結果、それら2つの値の決定係数が0.4226、相関係数が0.9450、平均誤差が-9.482、平均絶対値誤差が9.681であった。この2つの損傷率の誤差を以下、「正解誤差」と呼ぶ。平均誤差から本研究の算出方法では損傷率を過小評価する傾向にあることが分かる。またそれら30枚の正解誤差と屋根面分割における平均IoUの相関係数は0.0356、APの相関係数は-0.0409であったことから、屋根面分割が正確に行われることと本研究による算出方法で誤差が出ることに相関関係はないといえる。したがって、正確に屋根面分割が行われたとしてもこの正解誤差、過小評価は生じてしまうと考えられる。

上記から、同じ人が同じ屋根の損傷率求めたのにもかかわらず、本研究の算出結果がこのような過小評価の傾向にあることが分かった。ここで本研究の算出結果において、誤差が出る可能性があるものに分解し原因を分析する。式(1)のように、実際の調査と同様の損傷率算出手法を用いていたこと、面積割合はピクセルを数えることでほぼ正確に算出できていたこと、屋根面分割の精度と正解誤差の相関がなかったことから、算出結果の過小評価は入力段階で屋根面ごとの損傷程度が過小評価されているからだと考えられる。前述したとおり図16のように、対象屋根面画像、対象屋根面が色付けされた全体画像、全体画像の3つから入力の判断をしてもらった。このとき対象屋根面画像の端に損傷が現れた場合や周りの損傷情報から損傷程度が判断される場合などに、正しいラベル入力が困難であったと考えられる。また、被害ありの屋根面画像に関して、4段階のクラスを利用したが、このクラス分けが精度




図 20 正解損傷率と推測損傷率の散布図

Fig. 20 Scatter diagram of correct damage rate and estimated damage rate.

に与えた影響も今後分析しなければならない。

逆にモデルが誤った屋根面分割をしたとしても、正解誤差、過小評価の増加をもたらさないといえる。これは4.8の分割後の処理において、損傷部分、その他屋根面部分の重複、見逃しを防いだことで、全体として損傷程度と面積割合が一定に保たれたためであると考えられる。しかしより説明性があり被災者に納得してもらえるモデルを構築するには、損傷している屋根面が把握できたり、実際の損傷率算出手法に近づけたりする必要がある。したがって、屋根面画像をメッシュやパッチごとに分割し、損傷率を算出する方法ではなく、本手法による屋根面分割が有効であり、高い屋根面分割精度が求められることに留意すべきである。

### 7.3 正解損傷率と推測損傷率の比較

5章で分類推測した損傷がある屋根画像30枚、損傷がない屋根画像30枚の合計60枚に対して、屋根面ごとに分類推測された損傷程度から上記の方法で全体の屋根損傷率を推測した。その結果、正解損傷率と推測損傷率の決定係数は0.3445、相関係数は0.6486、平均誤差は-5.401、平均絶対値誤差は11.07であり、散布図は図20のようになった。また損傷があるデータにおいて平均誤差は-13.44、誤差のヒストグラムは図21左、損傷がないデータにおいて平均誤差は2.641、誤差のヒストグラムは図21右となった。

損傷がある屋根データに関して、平均誤差と誤差のヒストグラムから、モデルは過小評価していることが分かる。これは、6.4の損傷程度分類の際の過小評価と、7.2のラベル入力段階の過小評価が影響していると考えられる。

損傷がない屋根データに関して、誤差のヒストグラムから多くは、損傷率数%で損傷していると推測しており、完全に損傷率0%と推測したのは30枚中12枚であった。これは、損傷程度分類推測の際、分割した数個の屋根面のうち1つでも被害ありと推測してしまうと、全体の損傷率も被害があるように算出してしまうためである。この誤りに対しては、損傷程度分類モデルの被害なしの再現率を上げなければならないと考えられる。




図 21 推測損傷率と正解損傷率の誤差のヒストグラム (左: 損傷がある屋根データ, 右: 損傷がない屋根データ)

Fig. 21 Histogram of error between correct damage rate and estimated damage rate. Left side: roof data with damage, right side: roof data without damage.




図 22 推測損傷率の誤差が大きかった画像データ (各列左から元画像, 正解屋根面領域, 推測屋根面領域, 正解損傷程度可視化画像, 推測損傷程度可視化画像, 上から正解損傷率: 70%, 推測損傷率: 15.88%, 正解損傷率: 54%, 推測損傷率: 9.994%, 正解損傷率: 38%, 推測損傷率: 7.645%, 正解損傷率: 0%, 推測損傷率: 23.93%)

Fig. 22 Roof images with a large error of estimated damage rate. Each row shows the original roof image, whole roof image painting true roof surfaces, whole roof image painting estimated roof surfaces, whole roof image painting true damage degree and whole roof image painting estimated damage degree ordered from left to right.

誤差が大きかった屋根データを図 22 に示す. 左から 4 つ目の推測損傷程度の可視化画像と, 5 つ目の正解損傷程度の可視化画像では, 被害あり (-25%) を黄緑色, 被害あり (25-50%) を黄色, 被害あり (50-75%) を橙色, 被害あり (75%-) を赤色として色付けている. これから各屋根面で損傷程度の誤差が生じてそれらが積み重なった場合大きな誤差が生じているものが多かったことが分かる. また, 屋根面分割において誤って大きく分割してしまった領域,

もしくはそもそもの面積割合が大きい領域に対して, 加えて損傷程度分類推測においても誤った推測を行うと, 大きな誤差が生じてしまったデータも存在した.

#### 7.4 モデルの精度評価

四万十町危機管理課の職員の方に本モデルが推測した屋根画像 60 枚に対して, 精度の評価を行ってもらった.

モデルの精度を評価する際, 地上から屋根を見たときの調査員の精度, 航空写真と地上から見たときの調査員の精度と定量的に比較するのが望ましいが, そのようなデータを作成, 入手することはきわめて難しい. よってモデルの推測損傷率の精度を, 「航空写真と地上から判断した調査員と同等」, 「(前述未満) 地上から判断した調査員より高い」, 「(前述未満) 地上から判断した調査員と同等」, 「地上から判断した調査員より低い」の 4 つの区分に分類してもらい, 定性的に評価を行った. その結果は表 5 が示すように, 「航空写真と地上から判断した調査員と同等」が 25.00%, 「(前述未満) 地上から判断した調査員より高い」が 5.000%, 「(前述未満) 地上から判断した調査員と同等」が 50.00%, 「地上から判断した調査員より低い」が 20.00%であった. これらのデータ数から, 本研究により 30.00%の屋根が従来の地上から調査する方法より高い精度で損傷率を算出することができるといえる. また, 80.00%の屋根が従来の地上から調査する方法と同等, もしくはそれより高い精度で損傷率を算出することができるといえる.

図 23 にこの回答別の推測損傷率の誤差の箱ひげ図を示す. これから「航空写真と地上から判断した調査員と同等」と「(前述未満) 地上から判断した調査員より高い」の屋根はおおよそ誤差 10%以下であり, 「(前述未満) 地上から判断した調査員と同等」の屋根はおおよそ誤差 20%以下, 「地上から判断した調査員より低い」の屋根はおおよそ誤差 20%以上であることが分かる. これらの箱ひげ図の各数値や平均が, 回答された 4 つの精度分類に対して単純に増加傾向にないのは, 対象建物の周囲の状況や屋根の構造により, 比

表 5 モデルの精度評価結果

Table 5 Result of accuracy evaluation of the model.

回答項目	航空写真と地上から判断した調査員と同等	地上から判断した調査員より高い	地上から判断した調査員と同等	地上から判断した調査員より低い	合計
精度はどの程度か	15(25.00%)	3(5.000%)	30(50.00%)	12(20.00%)	60




図 23 回答別の推測誤差の箱ひげ図 (“=photo and ground” は航空写真と地上から判断した調査員と同等, “>ground” は(前述未済)地上から判断した調査員より高い, “=ground” は(前述未済)地上から判断した調査員と同等, “<ground” は地上から判断した調査員より低い, を示す)

Fig. 23 Box plots of error of estimated damage rate of each class. This shows box plots of “equal to investigators who looks at roof from ground and aerial photos”, “(lower than the above and) higher than the investigator who looks at roof from ground”, “(lower than the above and) equal to the investigator who looks at roof from ground” and “lower than the investigator who looks at roof from ground” ordered from left to right.

較対象である地上から判断した調査員の精度が変化するためであると考えられる。

7.5 システムの効率性評価

本システムを運用するにあたって、データの取得、学習データのアンノテーション作業、モデルの学習を行う必要がある。

データの取得において、基盤地図情報はネット上から即座にダウンロードすることができ、航空写真は国土地理院などが発災約1週間後から撮影し、それを利用することができる。アンノテーション作業において、5.2節の屋根面分割では、筆者は400枚の学習データの屋根面入力作業に約6時間要した。また6.2節の損傷程度分類では、筆者は24,000枚の屋根画像から被害のある屋根画像684枚を抽出するのに約10時間要した。損傷程度のカテゴリ入力には職員1人で1枚あたり約35秒要したことから、本研究で利用した屋根面画像4,392枚には約43人時間必要であ

ると考えられる。そして、屋根面分割における学習時間が約16時間、損傷程度分類の学習時間が約6時間であった

以上のことからシステム運用には、データの取得に約1週間、アンノテーション作業に約59人時間、学習に約22時間必要である。熊本地震時の熊本市では、被害認定調査の開始に発災後約2週間要した[20]ことから、調査実施前にはシステム運用の準備が完了すると考えられる。また、図1に示す本システムのフローは自動で実行されるため、調査開始後に即座に損傷率算出を行うことができる。

被害認定調査には外見から判断する1次調査と、詳細に調査を行う2次調査・再調査が存在する。職員の方の聞き取りから、現状の屋根調査では1次調査の場合5分程度、2次調査の場合15~20分程度かかることが報告されている。熊本地震での熊本市では135,959件の1次調査が、37,807件の2次調査が、2,635件の再調査が行われた[21]ことから、もし本研究の推測損傷率をそのまま利用できた場合、1次調査では約472(人日)、2次調査では394~525(人日)、再調査では27~37(人日)の時間を短縮できるといえる。

8. まとめと今後の課題

本研究では、航空写真から被害認定調査における屋根損傷率を自動算出することを目的として、トリミング・屋根面分割・損傷程度分類・損傷率算出の4つの処理からなる画像処理モデルを開発した。筆者らの先行研究[1]から得た課題である、災害時の学習データの不足に対して、本研究ではinstance segmentationを用いた屋根面分割を行い、学習データを増加させる方法をとった。

屋根面分割において、損傷などによる屋根面内の色や模様が不連続であっても、正確に屋根面分割を行えたことから、深層学習のinstance segmentation利用が有効であったことが分かった。また、間違いやすい屋根画像を学習データに追加することで、ある程度の精度上昇が起こった。しかし平均IoU, AP両方の値をより増加させるには、モデルが間違いやすいデータをさらに見つけ、学習データを量・質ともにより豊富にしなければならない。

損傷程度分類では、平均再現率が0.3634であり、課題点が多く見られた。対象屋根面だけではなく全体の屋根の情報などをモデルの入力値として利用して過小評価を防ぐことや、複数のラベル入力者による学習データ作成から汎用的なモデルを構築することが必要であることが分かった。

損傷率算出では、入力の段階で入力ラベルの過小評価が

生じていることが分かり、より工夫された入力方法・損傷程度の表現方法が必要であることが分かった。これらの過小評価により、被害のある屋根画像の推測損傷率にも同様に過小評価が生じていることが分かった。また、被害のない屋根画像を正確に判定するには、損傷程度分類の際の被害なし屋根面の再現率を増加しなければならないことが分かった。

調査経験のある自治体職員による精度評価では、30.00%の屋根を従来の地上から調査する方法より高い精度で損傷率を算出することができ、80.00%の屋根が従来方法と同等、もしくはそれより高い精度で損傷率を算出することができた。このことから、本モデルにより従来の現地調査員による判定以上の精度で航空写真から屋根損傷率を自動算出することができたと見える。しかし、評価に利用したデータや評価者が十分な数とはいえないので、今後はより豊富なデータで精度を評価する必要がある。また、過去の調査の結果から本システムの効率性を評価した。

7.4 節で述べたように従来方法と比較すると高い精度をもたらしたが、7.3 節で述べたように航空写真から人が判断した場合と比較すると、精度向上に多くの改善の余地が見られた。今後は以上のような課題に加えて、建物ポリゴンが大きすぎて、または画質が悪いなどの理由から排除された屋根画像にも対応できるような、高い精度を持つモデルを開発しなければならない。

謝辞 高知県四万十町危機管理課の川上様によりデータ入力を行っていただきました。この場を借りて深く御礼申し上げます。

## 参考文献

- [1] 藤田翔乃, 畑山満則: 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, 土木計画学研究・論文集第 37 巻, Vol.75, No.6, pp.L127-L135 (2020).
- [2] 内閣府 (防災担当): 災害に係る住家の被害認定基準運用指針 (2020).
- [3] 内閣府 (防災担当): 災害に係る住家被害認定業務実施体制の手引き (2017).
- [4] 内閣府: 平成 30 年 3 月改定の概要, 入手先 (<http://www.bousai.go.jp/taisaku/pdf/h3003kaitei.pdf>) (参照 2021-05-10).
- [5] 国土交通省 国土地理院: 空中写真 | 国土地理院, 入手先 (<http://www.gsi.go.jp/gazochosa/gazochosa41006.html>) (参照 2021-05-10).
- [6] DRONEBIRD: 災害ドローン救援隊 DRONEBIRD | クラウド・マップ・ジャパン, 入手先 (<https://dronebird.org/>) (参照 2021-05-10).
- [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 (2017).
- [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, pp.49-57 (2017).
- [9] Ji, M., Liu, L., Du, R. and Buchroithner, M.F.: A Comparative Study of Texture and Convolutional Neural Network Features for Detecting Collapsed Buildings After Earthquakes Using Pre- and Post-Event Satellite Imagery, *Remote Sens*, Vol.11, 1202 (2019).
- [10] 利根川凜, 飯塚博幸, 山本雅人, 古川正志, 大内 東: 被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出, 情報処理学会論文誌, Vol.57, No.6, pp.1565-1575 (2016).
- [11] 内藤昌平, 友澤弘充, 森 悠史, 門馬直一, 中村洋光, 藤原広行: 複数の地震における航空写真を用いた深層学習による建物被害判別モデルの開発, 日本地震工学会論文集, Vol.20, No.7, pp.7.177-7.216 (2020).
- [12] Miura, H., Aridome, T. and Matsuoka, M.: Deep Learning-Based Identification of Collapsed, Non-Collapsed and Blue Tarp-Covered Buildings from Post-Disaster Aerial Images, *Remote Sens*, Vol.12, 1924 (2020).
- [13] Susaki, J.: Segmentation of Shadowed Buildings in Dense Urban Areas from Aerial Photographs, *Remote Sensing*, Vol.4, pp.911-933 (2012).
- [14] Ise, T., Minagawa, M. and Onishi, M.: Classifying 3 Moss Species by Deep Learning, Using the “Chopped Picture” Method, *Open Journal of Ecology*, Vol.8, pp.166-173 (2018).
- [15] Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F. and Ada, H.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, *ECCV* (2018).
- [16] He, K., Gkioxari, G., Dollár, P. and Girshick, R.: Mask R-CNN, arXiv:1703.06870 (2017).
- [17] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, arXiv preprint arXiv:1512.03385 (2015).
- [18] 岡谷貴之: 画像認識のための深層学習の研究動向—畳み込みニューラル ネットワークとその利用法の発展, 特集「ニューラルネットワーク研究のフロンティア」, p.171 (2016).
- [19] Keras Applications: Keras Applications, available from (<https://keras.io/api/applications/>) (accessed 2021-05-10).
- [20] 熊本市: 熊本復興 1-6 章, 入手先 ([https://www.city.kumamoto.jp/common/UploadFileDsp.aspx?c\\_id=5&id=18725&sub\\_id=1&fid=133191](https://www.city.kumamoto.jp/common/UploadFileDsp.aspx?c_id=5&id=18725&sub_id=1&fid=133191)) (参照 2021-12-10).
- [21] 熊本県危機管理防災課: 平成 28 (2016) 年熊本地震等に係る被害状況について【第 308 報】, 入手先 (<https://www.pref.kumamoto.jp/uploaded/attachment/126303.pdf>) (参照 2021-12-10).



藤田 翔乃 (学生会員)

2019 年京都大学工学部地球工学科卒業。2021 年同大学大学院情報学研究科社会情報学専攻修士課程修了。同年京都大学大学院情報学研究科社会情報学専攻博士後期課程に入学、現在に至る。



畑山 満則 (正会員)

2000年東京工業大学大学院総合理工学研究科博士後期課程修了。博士(工学)。2002年京都大学防災研究所助手, 2005年同助教授, 2007年同准教授, 2016年教授となり, 現在に至る。