

# 航空写真を用いた被害認定調査における 屋根損傷率の自動判定手法の開発

藤田翔乃<sup>1</sup> 畑山満則<sup>2</sup>

**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。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、屋根全てを見渡すことができず、正確に屋根調査を行っていない。そこで本研究では被害認定調査の迅速化と正確化を目的として、航空写真から画像認識を用いて、屋根の損傷率を自動で算出するシステムを開発した。筆者らの先行研究では、災害時の深層学習による推測において、学習データの不足が大きな課題であることがわかっている。そこで、本研究はトリミング屋根画像を屋根面で分割し、学習データを増加させる方法をとる。この方法は精度向上が期待できるほか、損傷の可能性が高い部分を助言し、推測モデルの判断根拠を示すことができ、調査現場でも有効であると言える。そしてこれらのモデルの推測結果を危機管理課の職員に評価を行ってもらい有効性の確認をした。その結果、本モデルである航空写真による見えない部分の提示と、二つ目である調査員への損傷の可能性が高い部分の助言が行えていることがわかった。また推測結果は、30.00%の屋根画像が地上から調査した場合より精度が高く、80.00%の屋根画像が地上から調査した場合以上の精度を持つことがわかった。しかし現状では被災者の心情やモデル精度を考慮すると推測結果を直接利用することができないという回答を得たことから、モデルと人とが連携して調査を迅速化、正確化する方法が必要であることがわかった。

**キーワード**：深層学習、被害認定調査、罹災証明証、航空写真、instance segmentation

## Development of Automatic Method to Calculate Damage Rate of Roof in Building Damage Investigation using Aero-Photo Images

SHONO FUJITA<sup>†1</sup> MICHINORI HATAYAMA<sup>†2</sup>

### 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[1]。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。

また、被害認定調査とは自治体職員が中心となっていくものであり、一次調査、二次調査、再調査の三段階の調査の種類が存在する。被害認定調査は基本的に官民合意のもと行われるものであるため、被災者は調査結果に納得しなかった場合、二次調査・再調査の申請を行うことができる。一次調査は外観目視による比較的簡易な調査であり、二次調査・再調査は内部に立ち入る詳細な調査を行い、それぞれの調査では外観や建物の傾斜、壁や屋根、基礎などの部位の損傷度合いから建物の被害の程度を決定する[1]。しかし、屋根の調査時には屋根全てを見渡すことができず、遠くから見るなどして地上から見える範囲で調査を

行なっている。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屋根調査は非常に困難であり、多くの時間を要する。また、正確な調査を行っていないことは、被災者の調査結果の不満につながり、結果として第二次調査・再調査数が増加していると考えられる。

### 2. 研究目的

上記のような背景から、①被害認定調査に多くの時間を要し、被災者の支援が遅れている、②屋根調査では地上から見上げることしかできず、正確な調査が困難である、③調査方法が複雑であり、調査員に専門的知識が必要である、の三つの問題点が挙げられる。そこで本研究では、航空写真から画像認識を用いて、屋根の損傷率を自動で算出し、被害認定調査の迅速化と正確化を図ることを目的とする。画像認識を用いて屋根の損傷率を自動で算出することは、被害認定調査を効率化・迅速化することにつながる。また、航空写真を用いることで地上からは見えない屋根部分を調査することができ、正確な調査を行うことができる。そして、画像認識により算出された屋根損傷率を利用すること

<sup>1</sup> 京都大学大学院 情報学研究科  
Graduate School of Informatics, Kyoto University  
<sup>2</sup> 京都大学防災研究所  
Disaster Prevention Research Institute, Kyoto University

で、屋根調査において専門的知識が必要とならず、建築の専門家以外でも正確な調査を行うことができる。

### 3. 先行研究

松岡らの研究[2]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・松岡の研究[3]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、容易に学習データを増やすことができ、加えて災害時にデータを取得することが現実的に可能である。そして余震により被害の程度が度々変化することがあるが、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。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。これにより、学習データを大量に作る事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大幅に短縮される。

利根川ら[4]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なった。内藤ら[5]は地震発生直後に被害状況を把握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するモデルを開発した。これらより、災害時において航空写真から被害建物を抽出するために、深層学習による画像認識が有効であることがわかる。

Jiら[6]は発災前後の航空写真の差分情報からテキスト解析と 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。本研究では、発災後の航空写真のみを利用するため、発災前の航空写真を必要とせず、より運用しやすいシステムであると言える。

また、堀江ら[7]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。藤生ら[8]は被害認定調査迅速化のために遠隔建物被害認定システムのうちスマートフォンを用いた建物被害認定の学習アプリを開発した。このように様々な観点から被害認定調査迅速化を目的とした研究が行われてきたが、写真から建物の個別の部位、特に航空写真から屋根の損傷率を自動で算出した研究は、筆者の調査の限り存在していない。

## 4. 屋根損傷率自動判定手法

### 4.1 システムの全体図

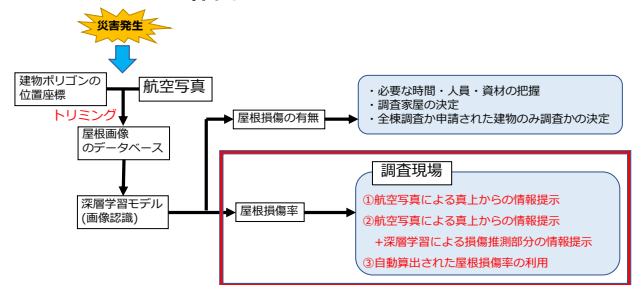


図1 システムの全体図

表1 システムの使用方法

|                              | 航空写真の利用 | 深層学習の利用 | 調査員の判断根拠               | 最終計算 |
|------------------------------|---------|---------|------------------------|------|
| ①航空写真による情報提示                 | ○       | ×       | 現地情報<br>+航空写真          | 調査員  |
| ②航空写真による情報提示<br>+深層学習による情報提示 | ○       | ○       | 現地情報<br>+航空写真<br>+深層学習 | 調査員  |
| ③深層学習による屋根損傷率の利用             | ○       | ○       | -                      | 深層学習 |

図1に本研究のシステムの全体図を示す。災害が発生した後、航空写真と GIS 上の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、屋根画像を自動で作成する。その後、各屋根画像を深層学習モデルへ入力し、屋根の損傷に関する推測を得る。筆者らの先行研究[9]において、屋根損傷の有無について推測を行い、必要な時間・人員・資材の把握、調査を行う家屋の決定、全棟調査か申請された建物のみ調査を行うかの調査方法の決定に寄与するシステムを構築した。本研究では深層学習モデルに屋根損傷率を算出させ、表1のように以下の三つの使用方法で被害認定調査を迅速化・正確化するシステムを構築する。

- (1) 航空写真を利用することによる地上から見えない屋根部分の提示
- (2) 航空写真を利用することによる地上から見えない屋根部分の提示に加え、調査員への損傷の可能性が高い屋根部分を提示と調査の助言
- (3) 深層学習モデルが推測した屋根損傷率の被害認定調査結果へのそのままの利用

また、屋根以外の調査があり現場を訪れる必要があるため、三つの使用方法とも調査員は現場にいることを留意しておきたい。

### 4.2 トリミングアルゴリズム




図2 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、屋根画像を自動で作成することができる(図2)。これにより、航空写真から一つ一つの建物を切り抜いて画像データを作

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。そして屋根以外の部分を黒く塗ることで、屋根損傷率の算出に不必要な情報を排除することができ、精度向上が期待できる。

#### 4.3 被害認定調査の屋根損傷率算出方法

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、それを全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。

$$\text{損傷率} = \sum_i \frac{\text{屋根面の面積} S_i}{\text{全体屋根面積}} \times \text{屋根面の損傷程度} D_i \quad (1)$$

#### 4.4 深層学習における課題

筆者らの先行研究[9]において、同様にトリミングした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が **balanced accuracy** が 75.58%, 再現率が 67.50% であり、ブルーシートの **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挙げられる。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。

#### 4.5 本研究の屋根損傷率算出手法

上記の課題を踏まえ、本研究では図3のようにトリミング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。一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ができるため、数倍の屋根損傷の学習データを得ることができる。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[10]は画像中のコケに識別のために、画像を細切れ




図3 本研究の損傷率算出手法

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、一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わかった。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。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。そして、損傷率が屋根面ごとで算出されるため、どの屋根面が損傷しているかを把握することができる。これにより、使用方法二つ目の損傷の可能性が高い屋根部分の助言を行うことが可能となる。使用方法三つ目の推測した屋根損傷率を被害認定調査の損傷率としてそのまま利用する方法では、調査員や被災者へのモデルの算出結果の判断根拠を示すことができる。被害認定調査の結果である建物の罹災度は被災者の支援内容を決定するため、罹災度に納得いかない場合や損傷率が罹災度分類の際どい場所に位置する場合に、被災者とトラブルを起こすことが多い。また、高い精度を持つ深層学習は膨大な数のパラメータが作用しあい、その学習や推測に直接人間が解釈や説明を与えることは困難である。しかし、本手法を用いることで高い精度に加え判断の根拠を与えることで、トラブルを避け円滑な対応を行うことができると考えられる。

#### 4.6 必要なデータ

本システムを運用する上でデータとして、航空写真と建物ポリゴンの位置情報、屋根面分割アルゴリズムと損傷程度分類モデルの深層学習の正解データであるラベルが必要である。航空写真は国土地理院や DRONE BIRD などの NPO 団体から無償で入手することができ、建物ポリゴンの位置情報は Open Street Map や基盤地図情報からダウンロードすることができる。深層学習のラベルに関しては、モデルの学習を発災前に行うか、発災後に行うかで対応が異なる。発災前に学習を行う場合、屋根形式などの地域特性を考慮できる汎用的なモデルを構築するためには様々な地域の航空写真を学習データとして利用しなければならない。発災後に学習を行う場合、推測データである航空写真の一部を学習データとして利用することで、地域特性を考慮できるモデルを構築することができる。しかしラベル入力を発災後に行わなければならないため、クラウドソーシングや調



査経験者・専門家への入力の依頼などを行わなければならない。このように航空写真と建物ポリゴンの位置情報としては既存のデータを利用でき、深層学習ラベルとしては既存のシステムや調査の知識を持つ職員などからデータを入力することができると考えられる。これは各被災自治体のみで運用できることを意味し、システムの実現可能性を保証するものである。

## 5. 屋根面分割

### 5.1 屋根面分割モデル

色・テキスト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、誤って一つの屋根面であると認識する恐れがある。このようなことから、本研究ではより複雑の特徴から、様々な形の屋根を分割できる深層学習の segmentation モデルによる屋根面抽出・分割を行う。Segmentation 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考えられる。

Segmentation には semantic segmentation と instance segmentation の二種類のモデルがある。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ず、instance segmentation はそれができる。深層学習を用いた semantic segmentation モデルの一つである deeplab V3 plus[11]を利用し屋根面分割を試みたが、屋根面同士が結合し一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、一つの屋根面として抽出されてしまうため、instance segmentation を利用する必要があることがわかる。本研究は、instance segmentation モデルとして Mask R-CNN[12]を利用する。

### 5.2 学習概要

データとして、熊本地震後の益城町付近の解像度 20cm 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。そして、このトリミング屋根画像に屋根面領域のラベルを入力した。パラメータ更新のための学習データとして 2400 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、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に関してはこれらのデータから排除した。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 を行なった。検証データでモデルの損失関数を確認




図 4 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)

し、それが増加したときを過学習とみなし、学習を止めた。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 GeForce GTX 1060 6GB を利用し、1000 エポックの学習を 16 時間 4 分かけて行なった。学習データと検証データの損失関数の推移を図 4 左に示す。損失関数の推移からエポック 500 で学習を止めたモデルを利用した。

### 5.3 分割結果

表 2 分割結果

|       | 初期実験<br>(全体) | 初期実験<br>(屋根面内<br>損傷画像) | 初期実験<br>(屋根面境界<br>損傷画像) | 初期実験<br>(木の葉が<br>映った画像) | 追加実験<br>(全体) | 追加実験<br>(屋根面境界<br>損傷画像) | 追加実験<br>(木の葉が<br>映った画像) |
|-------|--------------|------------------------|-------------------------|-------------------------|--------------|-------------------------|-------------------------|
| 平均IoU | 0.7580       | 0.7341                 | 0.6874                  | 0.7237                  | 0.7672       | 0.6858                  | 0.7074                  |
| 平均AP  | 0.6670       | 0.6846                 | 0.5752                  | 0.3979                  | 0.6934       | 0.6094                  | 0.4628                  |




図 5 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，  
それぞれ左から元画像，正解ラベル，モデル推測

その結果は表 2 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。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わかる。

損傷部分を持つ屋根画像では、屋根面内に損傷がある画像(図 5 左)と屋根面境界部分に損傷がある画像(図 5 右)で屋根面分割の精度が異なっていることがわかった。屋根面内に損傷がある画像 40 枚(元画像は 5 枚)では、表 2 から全ての画像の平均と比較すると、ほとんど同等の精度で屋根面分割を行えたと言える。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 2 から全ての画像の平均と

比較すると、正確な屋根面分割が行えていないことがわかる。また、IoU, AP が低い画像の中には木の葉が映っている屋根画像が多いこともわかった。

### 5.4 追加学習

以上のようなことから、屋根面境界に損傷がある屋根画像、木の葉が映った屋根画像をそれぞれ 160 枚(元画像は 20 枚)加え、学習データ 2720 枚、検証データ 800 枚、評価データ 800 枚で同様に学習を行った。図 4 の右のような損失関数の推移からエポック 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 のように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、IoU・AP 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追加により、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。

### 5.5 分割後の画像処理

分割された画像の中には、複数の推測領域が重なる部分、推測されていない見逃し領域が多くあることがわかった。複数の推測領域が重なる場合、同じ損傷部分が映った屋根面画像データが重複して作成されたり、屋根面の面積割合を過大評価したりする可能性がある。推測されていない見逃し領域がある場合、損傷部分を見逃したり、屋根面の面積割合を過小評価したりする可能性がある。これらは、後の損傷率算出に影響を与える恐れがあると考えられる。

推測領域が重なる部分は、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削除することができる。重なっている推測領域のうち、面積が大きい領域は面積が小さい領域にまで拡張しているものが多いことから、面積が小さい領域を選択し、それ以外を排除して、重なった部分を削除した。その結果、平均 IoU は 0.7673、平均 AP は 0.6931 となった。その後、各推測領域を拡張させることで見逃し部分の埋め合わせを行った。見逃し部分がなくなるまで、順番に各推測領域を上下左右の隣接するピクセルへと拡張させた。その結果、平均 IoU は 0.6428、平均 AP は 0.6931 となった。図 6 のようにこれら二処理の後、屋根面画像を作成した。




図 6 分割と二処理後の例

## 6. 損傷程度分類

### 6.1 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言えない。よっ

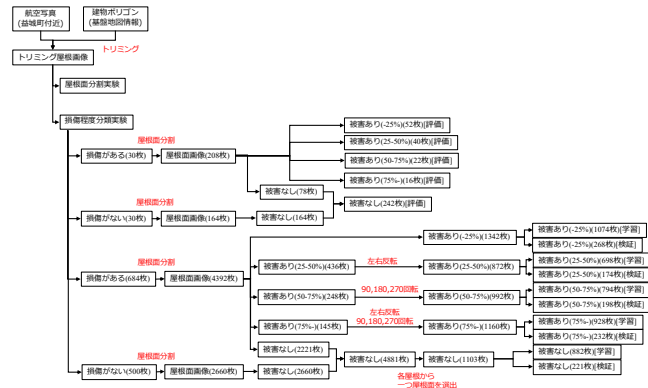


図 7 データの内訳

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 7 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、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三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言える。図 7 のように、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、一つの屋根からは一つの屋根面を選出するようにした。

### 6.2 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 を行なった。NVIDIA 社の GeForce 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 18 に示す。ここで 1 エポックは全ての学習データを 1 回学習させる回数とし、274 回の学習を意味する。図 8 から損失関数、正解率がともにまず増加傾向にあり、その後正解率が減少しているのがわかる。この初期の両方の傾向は、

正解率は増加しているが、誤った推測を行なったデータに対して高い推測確率を持ってしまい、損失関数が増加してしまっただけであると考えられる。しかし、本研究では推測確率より結果となる正解率を重視するため、正解率が最も高かつ損失関数が減少したエポック 150 のモデルを利用する。




図 8 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，右青線-正解率の移動平均

### 6.3 推測結果

表 3 損傷程度分類の混同行列

|     |               | 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 |

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。その結果、混同行列から被害の大きい屋根画像の再現率が低く、また被害を過小評価している傾向にあることがわかった。

この過小評価している屋根面画像を見ると、対象屋根面内で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、対象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ただけと考えられる。またラベル入力の際、低画質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。

## 7. 推測損傷率の算出

### 7.1 屋根損傷率算出手法

本研究では第 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 として屋根面程度を割り当て、面積割合をかけた値を全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 正解損傷率と正解損傷程度から算出された損傷率の比較

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、第 6 章の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正解損傷率と、第 6 章で述べた屋根面ごとに入力された正解損傷程度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、それら二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。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わかる。この屋根ごとに入力された正解損傷率と屋根面ごとに入力された正解損傷程度から算出された全体損傷率の誤差を以下、「正解誤差」とする。上記 30 枚の屋根面分割における平均 IoU と正解誤差の相関係数は 0.0356、AP と正解誤差の相関係数は-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係数はないと言える。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。同じ人が同じ屋根の損傷率を求めたのにも関わらず、本研究の算出方法がこのような過小評価の傾向にあるのは、屋根面ごとの損傷程度ラベルが過小評価されているからであると考えられる。ラベル入力の際に、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。また逆に、モデルが誤った屋根面分割をしたとしても、屋根面ごとの損傷程度から算出された全体の損傷率に精度低下をもたらさないと言える。これは 5.5 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と考えられる。しかし、使用方法二つ目の損傷の可能性が高い部分の助言と、使用方法三つ目の損傷率の利用の際のモデルの判断根拠の提示を行うためには、高い屋根面分割精度が必要であることを留意すべきである。

### 7.3 正解損傷率と推測損傷率の比較

第 6 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 9 となった。また損傷があるデータにおいて平均誤差は-13.44、損傷がない



データにおいて平均誤差は 2.641 であった。これより、損傷がある屋根データに関して、正解誤差が生じているのと同様に過小評価していることがわかる。これは第 6 章で述べたように損傷程度分類でも同様のことが起こっており、それが原因であると考えられる。損傷がない屋根データに関して、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一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 9 正解損傷率と推測損傷率の散布図

#### 7.4 モデルの有効性の評価

表 4 各屋根データに対する質問と回答

| 回答項目                         | できている                | できていない              | 合計                 |                      |    |
|------------------------------|----------------------|---------------------|--------------------|----------------------|----|
| 航空写真により地上から見えない部分の提示ができていますか | 60(100%)             | 0(0%)               | 60                 |                      |    |
| 回答項目                         | 完全に助言が行えているため、効率化できる | 一部助言が行えているため、効率化できる | 誤った助言の方が多く、効率化できない | 損傷のない屋根を損傷率0%と判定している | 合計 |
| 損傷の可能性が高い部分を助言し、調査を効率化できるか   | 16(26.67%)           | 32(53.33%)          | 0(0%)              | 12(20.00%)           | 60 |
| 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 10 質問に対する屋根データ

被害認定調査における表 1 の三つの使用方法について、本研究の有効性を確認するために、四万十町危機管理課の職員の方に本研究のモデルが推測した屋根画像 60 枚に対して、表 4 のような三つの質問を行ない、回答を得た。回答は図 10 のような画像と正解損傷率、推測損傷率から判断をしてもらった。図 10 左はトリミング画像から 3m の幅をもたせた画像、右は推測損傷程度を可視化した画像である。航空写真により地上から見えない部分の提示ができていますかという質問に対して、100%の割合で「できている」という回答を得た。したがって、使用方法一つ目の航空写真により地上から見えない部分の提示ができており、調査を効率化・正確化できると考えられる。損傷の可能性が高い部分を助言し、調査を効率化できるかという質問に対して、効率化できないという回答が 0%であった。損傷のない屋根に対してモデルが 0%ではなく被害ありと推測した 18

個のデータに関して、全てが「誤った助言の方が多く、効率化できない」ではなく、「一部助言が行えているため、効率化できる」という回答であった。入力者に確認をしたところ、損傷のない屋根面の情報を提示しているため、調査を効率化できると返答をいただいた。したがって、使用方法二つ目の航空写真から本研究のモデルにより推測された損傷のある屋根面を提示することで、調査員が損傷の可能性が高い部分を把握することができ、調査を効率化できると考えられる。本モデルの推測精度を評価する際、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、入手することは極めて難しい。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」の四つの区分に分類してもらい、定性的に評価を行った。これから、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、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できると言える。

また、モデルの総評に関していくつかの質問を行った。その結果、「屋根面ごとで推測損傷程度を出すことで、モデルの判断根拠を示せているか」という質問に対して、「示せている」という回答を得たことから、屋根面ごとで損傷程度を算出し可視化することでブラックボックスである深層学習モデルの推測に解釈を得ることができると考えられる。しかし、「どのような状況でモデルの推測損傷率をそのまま屋根調査結果として利用するか」という質問に対して、損傷がある場合は利用できない、被災者感情を考慮すると損傷の有無にかかわらず目視での確認は必ず行うという回答を得た。また、その他の意見に関しても、使用している画像では判断することが困難であり、現地の屋根調査は欠かせないという回答を得た。したがって、現状では使用方法 3 つ目のモデルの推測結果をそのまま被害認定調査の屋根調査結果には利用することができないと言える。

#### 7.5 従来方法と三つの使用方法の比較

本研究のモデルを運用するためには、航空写真、建物ポリゴン、深層学習モデルのラベルが必要である。航空写真に関して、国土地理院は発災後 1 週間以内に、DRONE BIRD などの各組織は発災数日後に撮影が行われる。また、クライスマッパーズ・ジャパン理事長の古橋大地氏によれば、熊本地震(前震)後に益城町付近の約 17000 棟の建物を 122 名のマッパーたちにより open street map の建物ポリゴンを約 1 日で描き終えた。建物ポリゴンとして基盤地図情報を利用する際は、ネット上からダウンロードできるため即座に建物ポリゴンを得ることができる。また、概算により本モデルのラベル入力、建築の専門家や被害認定調査の経

験者による入力が約 43(人・時間)、それ以外の人による入力が約 16(人・時間)を、学習には約 1 日要する。したがって、航空写真と建物ポリゴンのデータを得た後、ラベル入りに約 2~3 日、学習に約 1 日かかることから、約 10 日以内にモデルの運用を行うことができると言える。2016 年 4 月 14 日に前震、4 月 16 日に本震が起きた熊本地震で、熊本市は 4 月 28 日に本格的に被害認定調査の一次調査を開始したことが報告されている。これから被害認定調査開始には発災後約 10 日~2 週間要すると考えられるため、本研究の運用までに調査が開始することは概ねないと言える。以上のことを踏まえて 6.4 の評価結果から、三つの使用方法に関して精度と時間の軸から評価したものを図 11 に示す。また四万十町危機管理課の職員から、現状の屋根調査では一次調査の場合 5 分程度、二次調査・再調査の場合 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 135,819 件の一次調査が、37,809 件の二次調査、2,637 件の再調査が行われたことから、もし本研究の推測損傷率を利用できた場合、一次調査では約 472(人・日)、二次調査では 421~561(人・日)の時間を短縮できると言える。




図 11 三つの使用方法に関する評価

## 7.6 被害推測地図

本研究のモデルを利用して、益城町役場付近の 3513 棟の建物の屋根画像について損傷率を推測した。図 12 左は Miura ら[13]において作成された被害地図であり、図 12 右は本研究の推測結果を地図上にプロットしたものである。

この地図に関して、調査に必要な人的資源の把握や調査方法の決定に有効であるという意見を頂いた。




図 12 左:Miura らによる建物被害地図[13],  
 右:本研究による推測被害地図

## 8. まとめ

本研究では、被害認定調査における屋根調査の迅速化と正確化を目的として航空写真を用いて、屋根損傷率を自動で算出するモデルを開発した。先行研究[9]から得た課題である、災害時の航空写真から深層学習を用いた被害推測では学習データである航空写真が不足していることに対して、

本研究では屋根画像を屋根面で分割し、学習データを増加させる方法をとった。

本モデルは、使用方法一つ目である航空写真による見えない部分の提示と、二つ目である調査員への損傷の可能性が高い部分の助言が行えていることがわかった。また推測結果は、30.00%の屋根画像が地上から調査した場合より精度が高く、80.00%の屋根画像が地上から調査した場合以上の精度を持つことがわかった。また、研究の推測結果を地図上にプロットした図 12 右に関して、大まかな被害推測に有効であることがわかった。よって、一つの屋根の損傷率を表す局所的な被害推測にも、地域全体の被害を表す全体的な被害推測にも本研究は有効であると言える。

被害認定調査現場では、本モデルの推測結果をそのまま利用できないことから、今後はモデルと人とが連携して調査を正確化、効率化する方法を模索していかなければならないと考えられる。

**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] 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
- [2] 松岡ら: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
- [3] 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」
- [4] 利根川ら: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,2016
- [5] 内藤ら: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,2020
- [6] Min Ji, Lanfa Liu, Runlin Du and Manfred F. Buchroithner: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. 2019
- [7] 堀江ら: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-,地域安全学会論文集,2005.
- [8] 藤生ら:3次元建物モデルを用いた建物被害認定調査学習アプリ開発,土木学会論文集 A1(構造・地震工学),2015
- [9] 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,2020
- [10] Takeshi Ise, Mari Minagawa, Masanori Onishi : Classifying 3 Moss Species by Deep Learning,Using the “Chopped Picture” Method, Open Journal of Ecology, 2018,
- [11] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, Hartwig Adam : Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, In ECCV, 2018
- [12] Kaiming He, Georgia Gkioxari, Piotr Dollar, Ross Girshick : Mask R-CNN, arXiv:1703.06870, 2017.
- [13] Hiroyuki Miura, Tomohiro Aridome, Masashi Matsuoka : Deep Learning-Based Identification of Collapsed, Non-Collapsed and Blue Tarp-Covered Buildings from Post-Disaster Aerial Images, Remote Sens. 2020