

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

¹学生会員 京都大学大学院 情報学研究科社会情報学専攻 (〒606-8501 京都市左京区吉田本町)
E-mail: fujita.shono.32x@st.kyoto-u.ac.jp

²正会員 京都大学防災研究所教授 巨大災害研究センター (〒611-0011 京都府宇治市五ヶ庄)
E-mail: hatayama@dimisis.dpri.kyoto-u.ac.jp

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。一方で、深層学習の一つであるDCNNによる画像認識の精度は近年著しく向上しており、今後よりいっそう発展していくことが予想される。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DCNN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。データ不均衡問題や過学習などを考慮し、DCNNモデルを開発することで、ブルーシートの有無、つまり屋根被害の有無を95.05%で予測分類することができた。今後、行った実験結果からモデルと学習データに改良を加え、実際の災害時に運用できるほどに精度を高める予定である

Key Words : 罹災証明書, 航空写真, 深層学習, 画像認識, Open Street Map

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

(1) 研究背景

a) 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⁾。

b) 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ー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) 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。

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。

3. 先行研究と本研究の位置づけ

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)から建物ポリゴンの頂点の位置座標を取得し、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。そして、本研究では図-1のように、OSMの建物ポリゴンの頂点の位置座標を用いて建物の外接四角形から建物以外の部分を黒く塗り、建物のみを画像の分析対象とした。

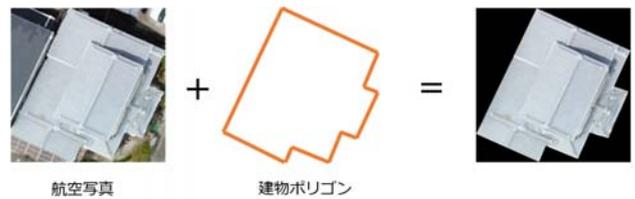


図-1 航空写真のトリミング作業

こうすることで、屋根以外の道路や地面などからの不必要な情報をできる限り取り去ることができ、誤った学習・予測を防ぐことが期待できる。

坂田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、坂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を用いて地震災害時の被害の規模、全体像を把握するシステムを屋根損傷家屋把握システムと定義する。

(1) システムの構成

発災から時間が経ち、雨などの悪天候が予想されると、屋根被害があった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、このブルーシートの有無を判別することとする。

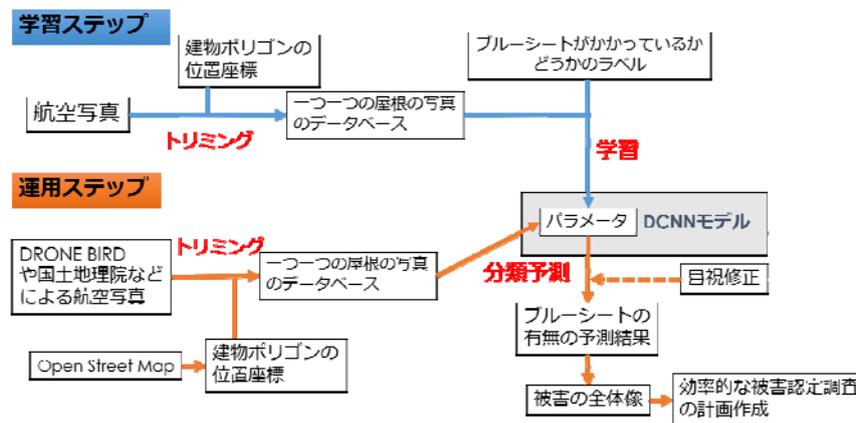


図-2 屋根損傷家屋把握システムの構成

しかし、一般的に地震災害時に瓦屋根以外のスレートなどの屋根は損傷が生じにくいいため、壁や基礎などに被害はあるが、屋根には被害がない家屋が存在することが考えられる。よって、本システムが把握する屋根損傷家屋の数、つまりブルーシートがかかっている家屋数は必ずしも建物に被害があった家屋数と一致するわけではない。したがって、本システムを用いた後、全体に対する瓦屋根家屋の割合からおよその被害の規模を算出しなければならない。

本システムでは、図-2のように地震発生前に被害を判別するためのDCNNを作る(パラメータを決める)学習ステップと地震発生後にそのDCNN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。

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座標を使って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、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、学習ステップで作上げた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。

(1) 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座標が必要である。

a) 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シスマッパーズ・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に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のものとは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。

b) 建物ポリゴンの頂点の位置座標

DRONE BIRDを運営しているクライシスマッパーズ・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り、本システムの運用ステップにおいてOSMから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。

5. DCNNモデルの構築と評価

(1) 用いるDCNNモデル

DCNNモデルは重みや閾値などの学習ステップの更新対象となるパラメータとは別に、層の幅や深さ、パラメータの数などのそのモデルの構造や学習方法を決定するハイパーパラメータがある。画像認識において最も精度の良いモデルは一概に存在せず、どのような画像認識タスクを行うかによって、精度の高い予測ができるモデルが異なってくる。また、各タスクに適したモデル構造の決め方、つまりハイパーパラメータの決定の方法は現時点では解明しておらず、モデルを作ってはその精度を確認するという試行錯誤を繰り返し、精度の高いモデルを作ってきた¹⁶⁾。さらには、設定すべきハイパーパラメータの数は多く、モデルの構造の種類は多次元に存在することから、すべてのモデルの精度を検証することは不可能である。そこで、本章では世界的な画像認識コンテストのILSVRCで用いられたAlexNetを用いて精度を評価し、本システムに適したモデルを構築する。

AlexNetは2012年のILSVRCで優勝し、深層学習(DCNN)のアルゴリズムの精度が従来の機械学習のアルゴリズムの精度を超えた初めてのモデルである。2013年以降のILSVRCでは、AlexNetより層数が多くなり、複雑となった深層学習(DCNN)のモデルが優勝している¹⁷⁾。ILSVRCでは1,000個のクラスで分類予測を行っており、本システムで行う2クラスの分類と比べて、はるかに層数が増えた複雑なモデルが必要であると考えられる。一般的に層数が増え、パラメーターが増えすぎたモデルは表現力が高くなり過学習を起こす可能性がある¹⁸⁾。また、過学習を起こさないにしても、精度は頭打ちとなり、無駄に計算量が増え、学習時間が長くなる。つまり、ILSVRCで優勝した最新のより複雑なモデルはILSVRCでは高い精度を出す、本システムでの分類予測では過学習を起こしたり、無駄な計算時間を要したりする可能性がある。以上のことを考慮し、本システムではILSVRCで優勝したDCNNモデルのうち、最も層数が少なく単純な構造であるAlexNetを用いた。

(2) 使用するデータ

データセットには、学習ステップでパラメータを更新する際に用いる「学習用データ」、学習回数を設定するための「検証用データ」、モデルの精度を評価する「評価用データ」の3種を用いる。

一般的に学習回数が多すぎると過学習を引き起こす可能性がある¹⁹⁾。この過学習を抑制するために、検証用データで精度が落ちていないかを確認し、過学習が起きた時点で学習を止めた。

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のものを利用した。

本システムでは、建物の屋根やブルーシートのかかり方などに地域特性がないと仮定し、評価用データにも学習用データ、検証用データと同じ地域の茨木市の航空写真を用いた。

また、実際の災害時ではドローンの位置精度が正確でなかったり、地図を描く人によってマッピング技術に差があったりすることから、OSMの建物ポリゴンと航空写真の建物を完全に一致することは困難であり、多少のずれが生じることが予想される。このことから、本章で用いる建物ポリゴンのデータも多少のずれが生じているが、修正せずにそのまま学習を進めていくことにする。

(3) 評価基準

運用ステップにおいて、DCNNモデルで予測した分類に多少の誤差が生じていた場合、図-2のように人の目視点検による修正が可能であればより正解率が高くなる。表-1の混同行列で示されるA、Dは正解のデータであり、修正されるのは不正解のB、Cのデータである。地震災害時、一般的にブルーシートがかかっている屋根(A+C)よりブルーシートがかかっている屋根(B+D)の方が比較的数が多い。それに伴ってブルーシートがかかっていると予測するデータ(A+B)よりブルーシートがかかっていると予測するデータ(C+D)の方が数が多いと予想される。よって、ブルーシートがかかっていると予測したデータ(C+D)の中からCのデータを見つけ出し、修正するのは困難である。一方でブルーシートがかかっていると予測したデータ(A+B)の中からBのデータを見つけ出し、修正するほうが時間や労力の面から現実的に実行しやすい。このことから、第一に目視作業による修正が困難なCのデータはできるだけ数を減らさなければならない。加えて、修正を行うBのデータが少ないことがより望ましいと考えられる。

表-1 分類予測の混同行列

	ブルーシートがかかっている	ブルーシートがかかっていない	合計データ数
ブルーシートがかかっていると予測	A (正)	B (誤) DCNNで予測分類後 人の手によって修正	少ない
ブルーシートがかかっていると予測 できるだけ 少なくする	C (誤)	D (正)	多い
合計データ数	少ない	多い	

本研究では評価基準として全体のデータに対する正解データの割合である正解率ではなく、ブルーシートがかかっている屋根をブルーシートがかかっていると予測で

きた割合である再現率を用いる。A,B,C,D のデータ数を a,b,c,d とすると正解率 accuracy と再現率 Recall は以下の式 (1a),(1b)の通りである。

$$\text{accuracy} = \frac{a + d}{a + b + c + d} \quad (1a)$$

$$\text{Recall} = \frac{a}{a + c} \quad (1b)$$

一般的にブルーシートがかかっているデータ数の方が多いため、ブルーシートがかかっていると予測する傾向を高め、A のデータ数を増やすより、ブルーシートがかかっていると予測する傾向を高め、D のデータ数を増やすほうが、正解率は上がる。このことから、評価基準として正解率を用いると、ブルーシートがかかっていると予測する傾向が高いモデルが高く評価されるが、D のデータと同時に C のデータも増え上記の意図に反することとなる。以上のことから評価基準として再現率を用いることとする。

また、ブルーシートがかかっている屋根をブルーシートがかかっていると予測できた割合を式(1c)のように特異度 Specificity とする。

$$\text{Specificity} = \frac{b}{b + d} \quad (1c)$$

(4) 初期実験

学習に用いる 2 枚の航空写真を航空写真 A、航空写真 B とし、航空写真 A は学習用データと検証用データに、航空写真 B は評価用データに用いた。学習用データとしては航空写真 A のうち約 8 割に当たるブルーシートのかかった屋根画像（以下、「ブルーシート有」とする）を 307 枚、かかっている屋根画像（以下、「ブルーシート無し」とする）を 2186 枚、検証用データとしては航空写真 A のうち約 2 割に当たるブルーシート有を 76 枚、ブルーシート無しを 546 枚、評価用データとしては航空写真 B のブルーシート有を 169 枚、ブルーシート無しを 2702 枚使用した。

その結果である混同行列は表-2 のようになった。

表-2 初期実験の混同行列

		実際分類	
		ブルーシート有	ブルーシート無し
予測分類	ブルーシート有	112	59
	ブルーシート無し	57	2643

表-2 から正解率は 95.56% と非常に高い値であったが、特異度の 97.82% と再現率の 66.27% には大きな乖離が見られた。

この理由は、学習用データと検証用データに用いたブルーシート有のデータ数とブルーシート無しのデータ数に大きな隔たり（約 1 : 7）があったため、不均衡データ問題が起こったことであると考えられる。不均衡データ問題とは学習用データのクラス間でデータ数に偏りがあると、モデルがデータ数の多いほうに分類予測を行う傾向に陥ってしまい、予測精度が低下する問題である²⁰。この実験の場合、学習用データと検証用データのクラス間のデータ数の偏りから、モデルがブルーシート無しと予測する傾向が高いと全体の正解率が上がると学習してしまったと考えられる。

(5) 不均衡データ問題解消へのアプローチ

この不均衡データ問題を解消するために、航空写真 A の中のデータを左右反転と 90 度、180 度、270 度回転を行い、データ数を 2×4=8 倍に増やすデータ拡張を行い、学習用データと検証用データのブルーシート有の数をブルーシート無しの数とほぼ同数とした。学習用データのブルーシート有を 2448 枚 (306×8)、ブルーシート無しを 2450 枚、検証用データのブルーシート有を 616 枚 (77×8)、ブルーシート無しを 611 枚 (235+47×8) とし、その結果は表-3 のようになり、正解率は 88.61% と初期実験よりは下がったが、再現率は 83.43% に上がり、不均衡データ問題はほぼ解消できたと言える。

表-3 クラス間のデータ数をほぼ同数としたときの混同行列

		実際分類	
		ブルーシート有	ブルーシート無し
予測分類	ブルーシート有	141	299
	ブルーシート無し	28	2403

(6) データ拡張

精度をより向上させるため、航空写真 A の画像データのコントラストを変換したものを作り、学習用データと検証用データの量を約 2 倍にし、さらにデータ拡張を行った。学習用データのブルーシート有を 4896 枚 (306×8×2)、ブルーシート無しを 4900 枚 (2450×2)、検証用データのブルーシート有を 1232 枚 (77×2×8)、ブルーシート無しを 1180 枚 (238×2+44×2×8) とし、同じ条件で実験を行った結果、混同行列は表-4 のようになり、再現率が 93.49% に上がったことがわかる。

表-4 コントラスト変換によるデータ拡張後の混同行列

		実際のカテゴリ	
		ブルーシート有	ブルーシート無し
予測分類	ブルーシート有	158	194
	ブルーシート無し	11	2508

(7) システムに適した層数の検証

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が、パラメータが増えすぎると過学習を起こす可能性があるため、適切な層数を選択しなければならない。

適切な層数を調べるために畳み込み層 5 層、全結合層 3 の計 8 層からなる AlexNet²¹⁾の構造（畳み込み層の数）を変化させ、同じ条件で実験を行った。その結果は表-5のようになった。

表-5 AlexNetの層数変化による実験結果

DCNNモデル	再現率	特異度	正解率
AlexNet5	79.88%	90.75%	90.11%
AlexNet6	81.07%	93.67%	92.93%
AlexNet7	82.25%	94.60%	93.87%
AlexNet(8)	93.49%	92.82%	92.86%
AlexNet9	92.31%	92.93%	92.89%
AlexNet10	93.49%	91.97%	92.06%
Res-AlexNet11	89.94%	94.12%	93.87%
Res-AlexNet12	78.80%	96.71%	96.65%

DCNNモデルの項目の「AlexNet」に続く数字はそのモデルの層数を表している。

ここで畳み込み層8層、全結合層3層を持つAlexNet11は図-3のように学習用データと検証用データの正解率がほぼ変化しない状態になった。

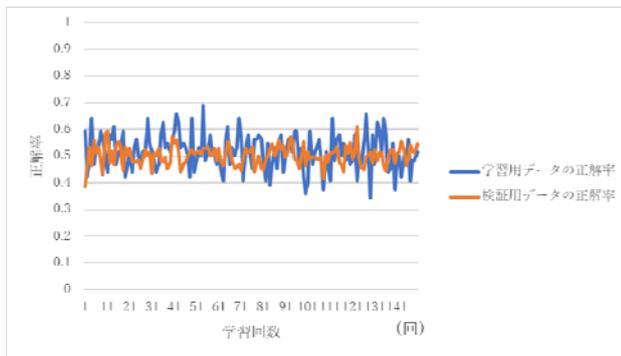


図-4 AlexNet11の正解率の推移

層が深くなると、過学習を起こすことに加えて、パラメータの更新がうまく働かなくなる。正解率が変化しなかったのはこのことが原因であると考えられる。図-5は AlexNetと AlexNet11の入力層から数えて 1 層目の畳み込み層のある重みパラメータの変化を表している。この図-5からわかるように、AlexNet11はパラメータの更新がうまく行われておらず、重みの値がほとんど変化していない。

2015年のILSVRCで優勝したResNetが持つshortcut connectionsという技術はこの問題を解決し、より多い層を持ったDCNNモデルを作ることを可能にした²²⁾。このshortcut connectionsは図-6のような構造であり、これを AlexNet11, AlexNet12に付け加えたものを表-5のRes-AlexNet11, Res-AlexNet12とする。

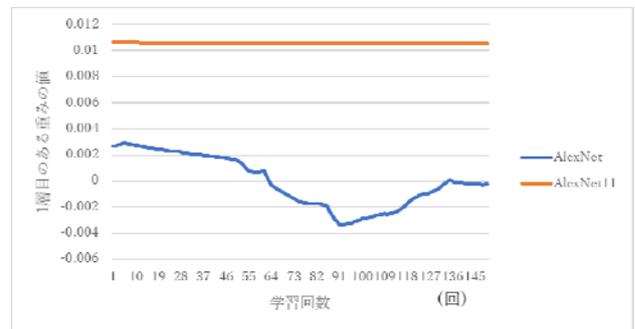


図-5 AlexNetと AlexNet11の重みの変化

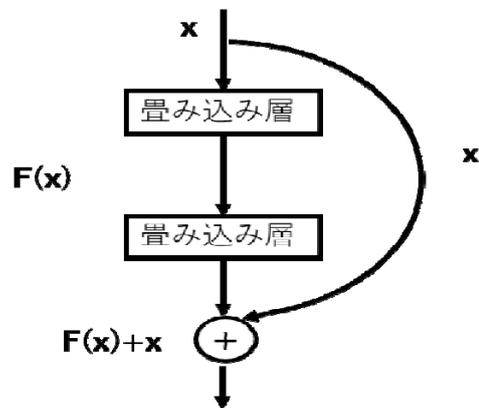


図-6 shortcut connectionsの構造

表-5の結果から、AlexNet(8)つまり、元々の AlexNet と AlexNet10 が最も再現率が高かった。このうち特異度を比べると AlexNet(8)の方が高く、本システムに適した層数は8層であることがわかる。

(8) バッチサイズとドロップ率の設定

1回の学習に用いる画像のデータ数をバッチサイズといい、精度に影響を与えるハイパーパラメータの一つである。また、AlexNetは過学習抑制のため Drop Out 層と

いうものを用いており、そこで使用される Drop 率もその一つである。このバッチサイズと Drop 率を変化させ、同様に実験を行ったところ、バッチサイズ 80, Drop 率 0.2 のとき最も精度が良くなり、その結果は表-6 のように再現率 97.04%, 特異度 94.93%となった。

表-6 バッチサイズ 80, Drop 率 0.2 のときの混同行列

		実際のカテゴリ	
		ブルーシート有	ブルーシート無し
予測分類	ブルーシート有	164	137
	ブルーシート無し	5	2565

(9) トリミングを行わなかった場合との比較

トリミングを行わず、建物以外の部分も写した画像データで同様に学習・予測を行った結果、再現率は 86.39%, 特異度は 93.60%となり、ともに低下することがわかった。トリミングを行わなかった場合、図-7 の右の画像のように、学習・分類対象ではない隣の屋根のブルーシートが写ることで、画像内にはブルーシートがあるがラベルはブルーシート無しがつけられる。このようなギャップが誤った学習・予測を行い、精度が低下したと考えられる。

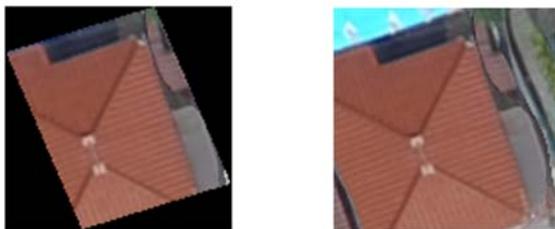


図-7 トリミングを行った画像（左）と行わなかった画像（右）

(9) まとめ

最も精度が高かった場合、表-6 のように再現率 97.04%, 特異度 94.93%となったが、ブルーシート有をブルーシート有と予測できる割合である適合率は 54.49% (164/301) と低く、DCNN で予測分類後に人の目視作業による修正が必要であると考えられる。このとき、全体の 10.48%にあたる 301 枚のブルーシートがかかっていると予測分類した画像を人の目視修正を行うことで、正解率は 99.82%まで上昇することがわかった。

図-8 は DCNN で予測分類した結果を航空写真上に可視化したものであるが、これからもブルーシートがかかっているのかかかっていないのかかかっていると間違っ

が多く存在することがわかる。



図-8 分類予測の航空写真上への可視化（青：実際のブルーシート有, 赤：予測のブルーシート有）

また、図-9 はブルーシートがかかっているのかかかっていると間違っ

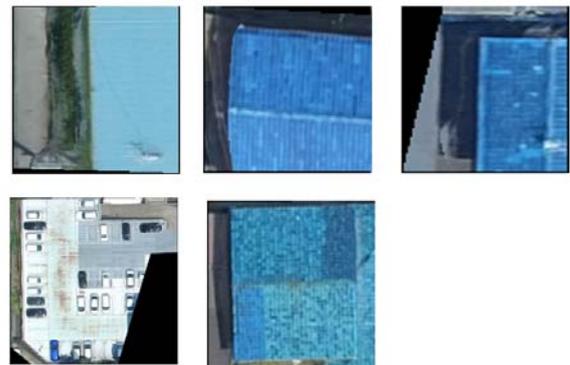


図-9 ブルーシートがかかっているが、かかっていると間違っ

た。図-10 はブルーシートがかかっているが、かかっていると間違っ



図-9 ブルーシートがかかっているが、かかっていると間違っ

また、トリミングを行わなかった場合、精度が低下することから本システムにおけるトリミングの有用性がわかった。

6. 今後の展望

今後は、分類予測の精度をさらに向上させるため、DCNN モデル、学習データに改良を加える予定である。DCNN モデルを開発する際、交差検証などを行い、より正当性の高い精度の検証を行わなければならない。学習データは量を増やすことに加えて、DCNN モデルが間違えやすいブルーシートの面積が小さい画像や青い屋根画像を多く入れたり、ずれを小さくしたりして、精度を高めなければならない。

また、他の地域でも分類予測の精度を調べ、DCNN モデルの汎用性を確かめなければならない。

本システムは主に瓦屋根を持つ被害家屋の把握を行っていたが、全体の被害規模を把握するには、それ以外の屋根をもつ被害家屋数の推定方法が必要になる。

そして、航空写真を提供する DRONE BIRD の活動可能地域や、ドローン飛行開始までにかかる日数などから、本システムが地震災害時にどのくらい実用的であるかを検討していく予定である。

参考文献

- 1) 内閣府：被害認定とは
<http://www.bousai.go.jp/taisaku/pdf/higai_nintei.pdf>,
最終アクセス日：2019/1/20
- 2) 内閣府：罹災証明書の概要
<http://www.bousai.go.jp/taisaku/hisaisyagyousei/pdf/risai_syouseisyo_gaiyou.pdf> , 最終アクセス日：2019/1/20
- 3) 内閣府：平成 30 年 3 月改訂の概要,
<<http://www.bousai.go.jp/taisaku/pdf/h3003kaitei.pdf>>
最終アクセス日：2019/1/20
- 4) 産経新聞：【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>>, 最終アクセス日：2019/1/20
- 5) 北海道新聞：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?ret=n_hokkaido> ,
最終アクセス日：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>> ,
(最終アクセス日：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 回土木計画学研究会発表会・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) 坂田 知彦：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)>,(最終アクセス日：2019/1/20)
- 10) 堀江 啓, 重川 希志依, 牧 紀男, 田中 聡, 林 春男：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>, 2005/5/27, (最終アクセス日：2019/1/31)
- 11) 堀江啓,牧紀男,重川希志依,田中聡,林春男：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>, (最終アクセス日：2019/1/31)
- 12) 国土交通省 国土地理院：空中写真 | 国土地理院
< <http://www.gsi.go.jp/gazochosa/gazochosa41006.html>> ,
(最終アクセス日, 2019/1/31)
- 13) DRONEBIRD：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/>>,(最終アクセス日：2019/1/20)
- 14) CrisisMappers Japan：CrisisMappers Japan
< <http://crisismappers.jp/about.html>> ,
(最終アクセス日：2019/1/19)
- 15) 麻生 英樹：多層ニューラルネットワークによる深層表現の学習 「Deep Learning(深層学習)」[第 2 回] 人工知能学会誌 vol.28,4,2013,pp.649-659
- 16) 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」, pp.171
- 17) ILSVRC：ImageNet Large Scale Visual Recognition Competition (ILSVRC)
<<http://image-net.org/challenges/LSVRC/>>
(最終アクセス日：2019/3/9)
- 18) 斎藤 康毅：ゼロから作るDeep Learning pythonで学ぶディープラーニングの理論と実装, pp.167,pp.189,pp.195pp.190-191, オライリージャパン, 2016
- 19) Lutz Prechelt：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> , (最終アクセス日：2019/3/9)
- 20) Haibo He,Member,IEEE,and Edwardo A.Garcia：Learning from Imbalanced Data,IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING,vol.21,No.9,pp.1263-1284,2009.9

- 21) Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton : ImageNet Classification with Deep Convolutional Neural Networks
 <<https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>>
 (最終アクセス日 : 2019/3/9)
- 22) Kaiming He Xiangyu Zhang Shaoqing Ren Jian Sun : Deep Residual Learning for Image Recognition
 <<https://arxiv.org/pdf/1512.03385.pdf>>,
 (最終アクセス日 : 2019/1/30).
- (?.?.? 受付)

SPECIFYING HOUSE WHOSE ROOF IS DAMAGED USING ARIAL PHOTO BY DEEP LEARNING IN EARTHQUAKE DISASTER

Fujita Shono, Michinori Hatayama

Issuing disaster certificate which is used to decide contents of victim's support need accuracy and rapidity. However issuing disaster certificate have took a long time in earthquake disaster so far. So, government need more efficient issuing disaster certificate mechanism. And accuracy of image recognition by DCNN which is one of deep learning is improving remarkably in recent years.

In this study, Damage Roof House Specifying System to grasp a big picture view of earthquake damage by DCNN using aerial photo and building polygon data on GIS was developed. As a result, Judgment weather house is covered with blue sheet or not with 95.05% accuracy by the system was achieved. In the future work, Improvement of DCNN model and data for deep learning to raise accuracy of judgment to use the system in actual earthquake disaster is planned.