

機械学習を用いた空中写真からの道路浸水被害箇所の特定

Identification of flooded roads from aerial photographs using machine learning techniques

山口 裕基¹⁾・藤本 龍虎²⁾・戸田 和之³⁾

Yuki YAMAGUCHI¹⁾, Ryuto FUJIMOTO²⁾, and Kazuyuki TODA³⁾

近年、大規模な水害による道路の浸水被害が多発しており、道路の被害状況を早期に把握できれば復旧活動の迅速化において有意であると考えられる。これまで行なわれてきた衛星画像や空中写真からの浸水道路の判別は熟練者が行なっており、これらの作業の自動化が期待されている。自動化については、従来のコンピュータを用いた解析手法もあるが、近年、AIによる手法が試みられている。本研究は、災害発生後の空中写真から道路の浸水被害箇所を迅速かつ自動的に特定することを目的とし、AI技術の導入を試みた。ResNet34を使用してセマンティックセグメンテーションを行い、画像中の浸水道路を判別した。その結果、浸水道路と併せて浸水していない道路も同時に学習させることによって、浸水道路の判別精度が向上することが明らかとなった。

Keywords: 深層学習, ResNet, Segmentation, 空中写真

I. 緒言

平成 30 年 7 月豪雨は西日本を中心に広範囲で記録的な大雨となった。6 月 28 日から 7 月 8 日にかけて総

連絡先：戸田和之 ktoda@cis.ac.jp

1)千葉科学大学大学院危機管理学研究科危機管理学専攻

Graduate school of Risk and Crisis Management,

Chiba Institute of Science Graduate School

2)株式会社 NBC メッシュテック

NBC Meshtec Inc.

3)千葉科学大学大学院危機管理学研究科

Graduate school of Risk and Crisis Management,

Chiba Institute of Science Graduate School

(2023 年 10 月 2 日受付, 2024 年 1 月 19 日受理)

雨量は、四国地方で 1,800 mm, 東海地方で 1,200 mm を超え、1 府 10 県に大雨特別警報が発表された¹⁾。国管理河川の 26 水系 50 河川、県管理河川の 138 水系 234 河川で氾濫危険水位を超過し、国管理河川の高梁川水系小田川で 2 箇所、県管理河川の 22 河川 35 箇所で堤防決壊が発生し、床上浸水 8,567 棟、床下浸水 21,913 棟の被害が生じた²⁾。

被災地域の道路にも浸水被害が発生し車両の通行が困難な状態となった。被災地域の道路は、災害発生直後から緊急車両や支援物資の輸送をはじめとする災害復旧に従事する車両が使用する。発災後の早い段階で車両が通行可能な道路を把握することが可能となれば、その後の復旧活動の迅速化において有意であると考えられる。通行可能な道路の確認には地上や上空からの

調査が必要である。被災地域上空からの画像を得る手段には、人工衛星や航空機がこれまで利用されてきた。これらは地表面を広範囲に撮影することが可能であるが、被災地域上空に雲があると地表面の撮影ができない。人工衛星は軌道の都合によって撮影時刻、撮影回数、撮影地域に制約がある。また、航空機は鮮明な空中写真の撮影が可能であるが、飛行高度に制約がある。一方で、近年は無人航空機（以下、ドローン）が空中写真の撮影に用いられている。ドローンは任意の時間に雲の影響を受けない低高度からの撮影が可能である。さらに、有人地帯での補助者なし目視外飛行（レベル4飛行）が2022年12月5日から可能になり、河川氾濫による浸水地域のような人間が立ち入ることが困難な場所であっても、自動操縦を利用すればリアルタイムに被災地域の画像を得ることができる。さらに、これらの技術が発展すれば災害の発生と同時に人間の手を介さずに自動的に発進しリアルタイムで道路の被害状況を撮影することも可能であろう。

しかし、現在、画像から浸水道路を判別する際は、熟練者によって空中写真からの目視判読が行われており³⁾、熟練者ではない者が迅速に判別することは困難であると考えられる。このことから、画像から浸水道路を迅速に判別する手法の開発が期待される。

コンピュータを用いた従来の解析手法では、浸水道路の色やコントラストなどの判断基準を人間が事前に設定することで判別が行われてきた。近年、機械学習をはじめとする人工知能を用いた手法が急速に発展してきた。機械学習では判断基準となる特徴量の閾値を学習により取得するが、深層学習（ディープラーニング）を利用すると、特徴量も人間が設定することなく学習により獲得する。また、学習過程には時間を要するが、学習後のモデルを用いると短時間で対象物の特定が可能となる。

このような考えに基づき、著者らは以前より深層学習を利用した災害画像の判別に取り組んでいる。平成30年に発生した北海道胆振東部地震では、山崩れ等の土砂災害が広い範囲で発生した。この災害に対する国土地理院が撮影した被災地域の空中写真から、災害の有無の判別に機械学習の画像分類を適用した。図1に示すように、空中写真的画像を分割、「災害あり」700枚と「災害なし」700枚の学習用画像を作成し、これらの画像を学習させた。学習に要した時間はノートパソコンで4時間程度であった。ただし、テスト用画像の判別予測は非常に高速で、140枚の判別でも数秒程度で終了した。判別精度も高く、9割の正答率で判別可能であることが分かった。ただし、この時に用いた「画像分類」という手法は、分割した画像内の災害の有無は判別できるが、どの箇所に被害が発生しているかを特定することはできない。これらの結果から、機械学習を適用することにより画像中

の被災箇所を迅速かつ自動的に把握できる可能性が示唆されたが、同時に、被災道路の特定には異なる手法を適用する必要があることも判明した。

被災道路の自動判別に関する研究は、久保ら（2021）の研究⁴⁾では、合成開口レーダ（SAR: Synthetic Aperture Radar）衛星から取得した被災前後の衛星画像に対して加色混合法によって被災道路の判別を試みている。しかし、被災前後2画像の色度や明度、彩度、撮影日時などの差異によって判別結果が異なる等の課題があることが示されている。三戸部ら（2022）の研究⁵⁾では、津波被災後に撮影された空中写真に対して深層学習によって地表物（瓦礫、植生、道路、建物、その他）の判別を試みている。しかし、複数の異なる地表物が混在する領域では地表物判定法に課題があることが示されている。このように、被災地域の衛星画像や空中写真からの浸水道路の判別は試みられているが、判別手法は確立されていないのが現状である。

そこで、本研究では災害発生後の空中写真から道路の浸水被害箇所を迅速かつ自動的に特定することを目的とし、その実現のためにAI技術の導入を試みた。

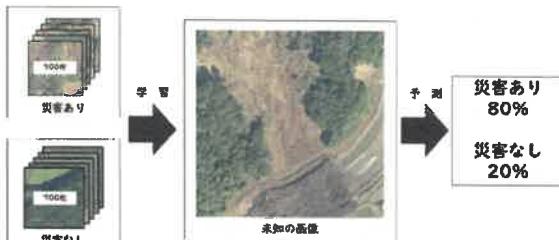


図1. 画像分類による災害有無の判別

II. 計算手法

表1に、本研究で導入した学習手法、および予測精度の評価指標をまとめた。本章では、これらの概要を説明する。

表1. 構築モデルに使用した手法

手法	使用手法
画像認識手法	セマンティックセグメンテーション
機械学習手法	教師あり学習
深層学習モデル	ResNet34, U-Net
誤差関数	Dice Loss
最適化手法	Adam

1. 画像認識

画像内の浸水道路を判別する手法にはセマンティックセグメンテーション (Semantic Segmentation) を用いた。セマンティックセグメンテーションは画像から物体の領域を検出でき、ピクセルの物体名 (クラスラベル) を出力する。各ピクセルに対してクラスラベルの確率が出力される。セグメンテーションでは画像内の領域やピクセルに対するクラスラベルをアノテーションと呼ぶ。本研究では被災地域の空中写真の画像から浸水道路のピクセルの判別を行った。

2. 機械学習

セマンティックセグメンテーションは教師あり学習に分類される機械学習である。予測確率はラベルごとに算出され、最も確率が高いラベルが予測結果として特定される。本研究では学習用画像に空中写真、正解ラベルに浸水道路や非浸水道路のアノテーションを用いた。

3. 深層学習モデル

画像内の浸水道路の判別には深層学習を使用した。深層学習モデルのアーキテクチャには ResNet34⁶⁾をベースとしてデコーダ部分に U-Net⁷⁾を使用した。図 2 に示すように、ResNet34 は入力層、中間層、出力層合わせて 34 層の深層学習モデルである。ResNet 以前の深層学習モデルでは層を増やした場合に生じた勾配消失や勾配爆発によってフィルタが更新されず予測精度が悪化する問題があったのに対して、ResNet はスキップ接続を追加することで解決している。ResNet34 は約 2100 万のパラメータ数を有しており、これらを更新し最適化することによって、複雑な物体が映る空中写真などに対しても高い予測精度が期待できる。本研究における選択は、これらの理由によるものである。

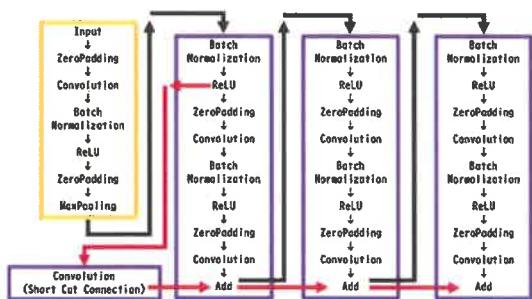


図 2. ResNet の入力層から Stage1 のモデル構成

4. 畳み込みニューラルネットワーク (CNN)

ResNet34 は畳み込みニューラルネットワーク (CNN : Convolutional Neural Network) を主要な構成要素としている。CNN は入力画像データにフィルタを用いて畳み込み (図 3)，さらにプーリング (図 4) を繰り返すことによって画像から特徴を抽出する。これらの方法によって、画像の上下左右の関係性を保持したままデータを扱うこ

とが可能となるため、本研究の目的に対する親和性が高い。

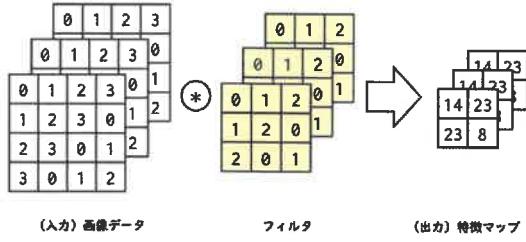


図 3. 畳み込み

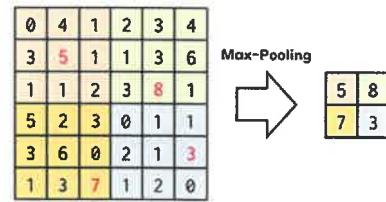


図 4. プーリング

5. 誤差関数

誤差関数は学習時に学習用画像に対する予測結果と正解ラベルとの誤差を求めるために用いられ、誤差が小さくなるようにフィルタが更新され最適化される。誤差関数にはいくつかの種類が存在するが、平均二乗誤差 (MSE : Mean Squared Error) や交差エントロピー誤差 (CE Loss : Cross Entropy Loss) が広く使用されている。しかし、本研究の判別対象のように予測したい対象ラベル (浸水道路) のピクセル数が画像全体のピクセル数に対して極端に少ない場合、これらの誤差関数では背景ラベルの誤差の影響を大きく受けてしまう。そのため判別対象ラベルの予測が外れているにもかかわらず誤差が小さく算出され、フィルタの最適化に妨げとなる。そこで、対象ラベルのみ着目して誤差を求める Dice Loss⁸⁾を採用した。Dice Loss (L_{DICE}) の計算式を以下に示す。

$$L_{DICE} = 1 - DC = 1 - \frac{2 \sum_{i=1}^N p_i \hat{y}_i}{\sum_{i=1}^N (p_i + \hat{y}_i)} \quad \dots (1)$$

p_i ：予測ラベルの確率 ($0.0 \leq p_i \leq 1.0$)

\hat{y}_i ：正解ラベルの確率 (0.0 or 1.0)

N ：ラベル数

6. 最適化手法

最適化手法は学習を効率的に行う手法であり、フィルタの更新量に関係している。代表的なものとして SGD, Momentum, Adam が広く使われている。今回は Adam を使用した。なお、Adam のパラメータは D. Kingma ら (2015)⁹⁾ が提案した値を使用した。

7. 評価指標

学習後に行った浸水道路の予測精度の評価にはF値(F-measure)を用いて評価した。一般的に予測精度の評価には正答率(Accuracy)が用いられる。しかし、本研究のように背景に対して浸水道路のピクセル数が少ない場合、背景の正答率が支配的となり、浸水道路の正答率が埋もれてしまう。そこで、ピクセル数の偏りに対する依存性が小さい評価指標としてF値を用いることとした。以下にF値の算出式を示す。

$$F = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad \dots (2)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$= \frac{\text{正しく浸水道路であると予測したピクセル数}}{\text{浸水道路の予測ピクセル数}} \quad \dots (3)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

$$= \frac{\text{正しく浸水道路であると予測したピクセル数}}{\text{実際の浸水道路ピクセル数}} \quad \dots (4)$$

F値は適合率(Precision)と再現率(Recall)の調和平均である。適合率と再現率はTP(True Positive), FP(False Positive), FN(False Negative)から求められる。図5に示されるように、TPは正しく浸水道路であると予測したピクセル(正答), FPは浸水道路と予測したが実際には浸水道路ではなかったピクセル(誤検出), FNは浸水道路ではないと予測したが実際には浸水道路だったピクセル(見逃し)を指す。F値は適合率と再現率を組み合わせることで誤検出と見逃しの両方を含めた評価指標である。F値が1に近いほど予測精度が高いことを表す。なお、TN(True Negative)は浸水道路ではないことを正しく予測したピクセルを指すが、F値には関係しない。

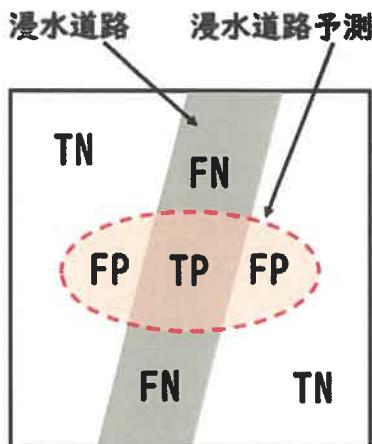


図5. 予測と正解の重なり

III. 画像の作成(前処理)

本研究では被災地域を撮影した国土地理院の空中写真に対して浸水した道路の判別を行った。対象は平成27年から令和元年の間に、豪雨被害にあった地域とした。撮影地域、災害名称および撮影日を表2に示す。

表2. 使用した空中写真

No.	撮影地域	災害名称	撮影日
1.	茨城県 常総市 坂東市	平成27年9月 関東・東北 豪雨災害	2015/9/11
2.	宮城県 大崎市	平成27年9月 関東・東北 豪雨災害	2015/9/12
3.	岡山県 倉敷市	平成30年7月 豪雨	2018/7/9
4.	埼玉県 都幾川流域	令和元年東日本 台風	2019/10/13
5.	千葉県 佐倉市 四街道市	令和元年10月の 低気圧に伴う大雨	2019/10/26

まず、学習用画像およびテスト用画像を作成した。空中写真的撮影範囲は国土地理院の推定浸水範囲図から判読し、浸水範囲を含む空中写真を画像サイズ512×512 pixelに分割した。次に、道路の色分けによる正解ラベル(アノテーション)を作成した。先の空中写真に地図を重ねて浸水した道路(浸水道路)のピクセルを赤色(RGB:255,0,0)、背景を黒色(RGB:0,0,0)、浸水していない道路(非浸水道路)のピクセルを青色(RGB:0,0,255)とした。作成したアノテーションの例を図6に示す。学習に用いた画像を学習用画像、学習後に予測精度の検証に用いた画像をテスト用画像と呼ぶが、本研究では学習用画像とテスト用画像を合わせて158枚作成した。

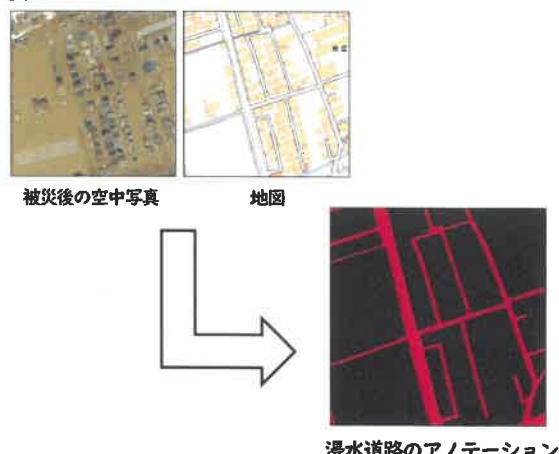


図6. アノテーションの作成方法

IV. 計算条件

本研究では、画像の学習方法を変えた4つのケースに対して計算を行った。計算条件と学習条件を表3に示す。

Case 1では、被災前の道路の特徴を学習するだけで浸水道路の判別はどの程度の予測精度なのか調べるために試行した。空中写真に被災前写真、アノテーションに非浸水道路のみを用いて、アノテーションの判別クラス数は非浸水道路と背景の2クラスで学習を行った。

Case 2では、浸水道路の特徴を学習して浸水道路を判別しようと考えた。空中写真に被災後写真、アノテーションに浸水道路を用いて、アノテーションの判別クラス数は浸水道路と背景の2クラスで学習を行った。

Case 3では、道路の浸水の有無を区別できれば誤認識を減らして予測精度が向上するのではないかと考えた。Case 2のアノテーションに非浸水道路を追加し、アノテーションの判別クラス数は浸水道路、非浸水道路、および背景の3クラスで学習を行った。

Case 4では、人間が被災前後の空中写真と地図から浸水道路を判別するときの手順を模擬して機械学習に適用できないかと考えた。Case 3に追加して空中写真に同一箇所の被災前写真、アノテーションに非浸水道路を追加し、アノテーションの判別クラス数は浸水道路、非浸水道路、および背景の3クラスで学習を行った。

通常、ランダムにフィルタの初期値やデータのシャッフルが行われるので、学習を実行するたびに学習推移や予測精度が異なる。本研究では、4つのケースでの学習推移や予測精度の比較を行うため、ランダムではなく固定として再現性を確保して学習を実行した。その他の学習条件については、4つのケースで同一とした。

表3. 計算条件および学習実行条件

計算条件		
学習ケース	空中写真	アノテーション
Case 1	被災前	非浸水道路
Case 2	被災後	浸水道路
Case 3	被災後	浸水道路 非浸水道路
Case 4	被災前 被災後	非浸水道路 浸水道路、非浸水道路

学習実行条件	
エポック数	1000 epochs
バッチサイズ	30枚

V. 結果と考察

前述の手法を用いて、作成した画像とアノテーションを学習させた。学習推移や予測精度をもとに考察を展開する。

1. 学習推移

各ケースの学習実行時の学習推移を図7に示す。縦軸は誤差、横軸はエポック数、青色の線は学習用データに対する誤差、オレンジ色の線は検証用データに対する誤差である。エポック数が増えるにつれて学習用データに対する誤差が減少しているが、検証用データに対する誤差は100エポック経過した前後まで下がった後には変化がないことがわかる。このことから学習が進みこれ以上学習しても予測精度は上がらない状態であると考えられる。

以上のことから、各ケースで使用した学習用画像に対する学習効果は収束していると考えられる。

2. 全浸水画像に対する予測精度の検証

空中写真的全域が浸水しているものを全浸水画像と呼ぶことにする。この全浸水のテスト用画像に対して、適合率、再現率およびF値による予測精度の評価を行った。この全浸水画像の予測結果を図8に示す。アノテーション（正解ラベル）の黒色は浸水道路の正解を、予測結果の赤色は浸水道路の予測を表す。なお、浸水道路の結果を比較するため、図中には浸水道路のみを描画しているので、白色は浸水道路以外の領域となっている。図より、各ケースの予測結果に差はあるが、定性的には予測精度の改善がみられない。そこで、予測結果をTP, FP, FNにそれぞれ色分けを行い、各ケースの比較を行った。色分けした予測結果を図9に示す。緑色はTP（正答）、オレンジ色はFP（誤検出）、オレンジ色はFN（見逃し）を表す。色分けされた画像から、正答に比べて誤検出や見逃しのピクセルが多いことが分かる。また、Case 1やCase 2に対してCase 3やCase 4は誤検出のピクセルが減少していることが分かる。このことから定性的には誤検出が減少していると推定される。次に、TP, FP, FNのピクセル数を各ケースで比較を行い、正答と誤検出がどの程度増減しているかを定量的に確かめた。

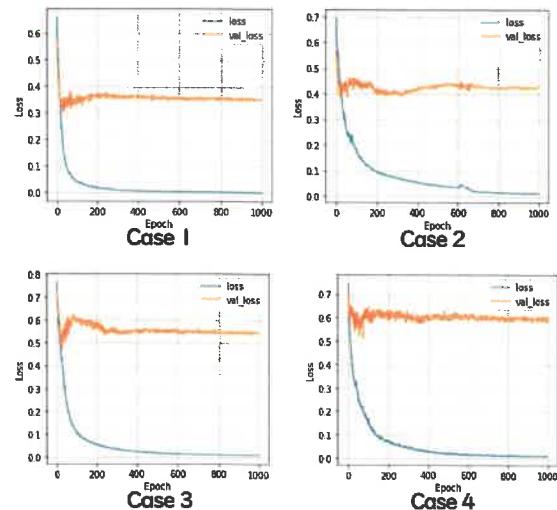


図7. 学習推移

図 10 に示すように、被災前の非浸水道路のみを学習した Case 1 に対して、被災後の浸水道路のみを学習した Case 4 は正答が 156 pixel 増加、誤検出が 14,195 pixel 減少している。定量的にも正答が増加し誤検出が減少していることが分かった。

適合率、再現率および F 値を用いて予測精度の定量評価を行った。図 11 に示すように、被災前の非浸水道路のみを学習した Case 1 に対して、被災後の浸水道路のみを学習した Case 2 の適合率は 1.76 ポイント改善、再現率は 7.66 ポイント悪化、F 値は 0.17 ポイント改善した。浸水道路を学習したことによって、浸水道路を判別できるようになり、誤検出が減少し適合率が改善したと考えられる。一方、浸水道路は特徴が少ないため、見逃しが増え再現率の悪化につながったと考えられる。その結果、F 値は改善しなかった。このことから、浸水道路を判別するためには被災前の非浸水道路のみや被災後の浸水道路のみを学習するだけでは浸水道路の予測精度は向上しないことがわかった。

Case 2 に対して、被災後の浸水道路と非浸水道路の両方を学習した Case 3 の適合率は 4.58 ポイント改善、再現率は 1.11 ポイント改善、F 値は 3.40 ポイント改善した。浸水道路に加えて非浸水道路を学習したことによって、浸水道路の誤検出が減少し適合率が改善したと考えられる。その結果、F 値が改善した。このことから、浸水道路を判別するには、被災後の浸水道路だけでなく非浸水道路も学習することで浸水道路の予測精度が改善することがわかった。

Case 3 に対して、被災前の浸水道路と被災後の非浸水道路と浸水道路を併せて学習した Case 4 の適合率は 2.72 ポイント改善、再現率は 0.03 ポイント改善、F 値は 1.39 ポイント改善した。このことから、被災後の道路と被災前の道路を併せて学習することで被災後の浸水道路の予測精度が改善することがわかった。

以上の 4 つのケースから、浸水道路の予測には被災後の浸水道路だけでなく被災前後の非浸水道路を併せて学習することが、予測精度改善に効果があると考えられる。

3. 一部浸水画像に対する予測精度の検証

全浸水画像だけでなく他の画像に対する予測精度の汎用性について検証した。空中写真の一部が浸水しているものを一部浸水画像と呼ぶことにする。この一部浸水と前節の全浸水を合わせた計 4 枚のテスト用画像に対して、平均適合率、平均再現率および平均 F 値による予測精度の評価を行った。予測結果を図 12 に示す。浸水道路のみを学習した Case 2 に対して、浸水道路と非浸水道路を学習した Case 3 は適合率が 8.15 ポイント改善した。しかしながら、テスト用画像 4 枚の平均 F 値は、Case 1 は 17.03 %、Case 3 は 16.83 % に対して、Case 2 は 10.97 %、Case 4 は 10.34 % であり、最も多くの画像を学習した

Case 4 は、被災前の非浸水道路のみを学習した Case 1 より悪化してしまっている。

前節の全浸水画像 1 枚に対して Case 4 が最も F 値が高いが、すべてのテスト用画像に対しては、F 値が最も低いという矛盾が生じている。これはテスト用画像によって予測精度のばらつきが大きく汎用性が低いことを示している。その原因は学習に用いた学習用画像の量が不足しているためと考えられる。

以上のことから、テスト用画像への汎用性を高めるためには学習用画像を増やす必要があると考えられる。

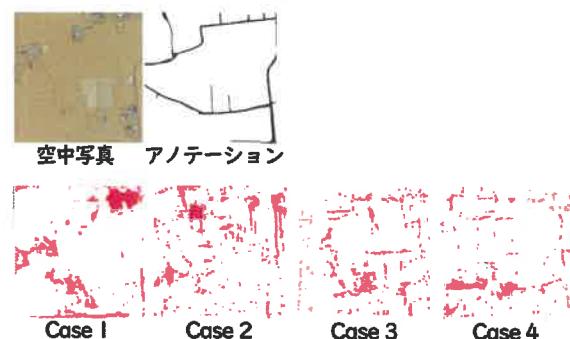


図 8. 全漫水画像の漫水道路の予測結果



図 9. 全漫水画像の予測結果の色分け

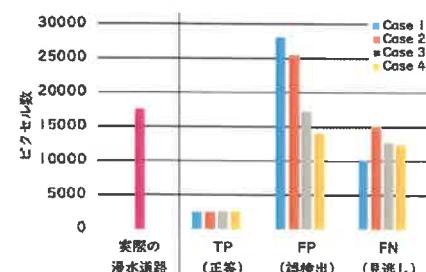


図 10. 全漫水画像のピクセルごとの予測精度

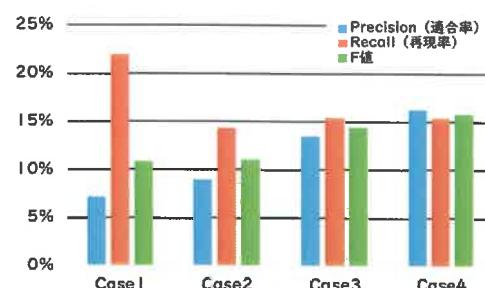


図 11. 全漫水画像の予測精度

4. 学習用画像に対する予測精度の検証

前節の考察から、十分な量の画像を学習し、汎用性を獲得した場合を想定して検証を行うこととした。十分な学習がなされた場合、過学習状態を除けば検証用画像への依存性は小さくなるはずである。本研究における学習枚数で過学習は考えづらいため、学習時に使用した画像を検証用として用いることにより、汎用性を獲得した場合が模擬できると考えた。なお、Case1 は非浸水道路のみのアノテーションを学習に使用しているため、浸水道路の予測精度の比較対象からは除外し、浸水道路を学習に使用した Case2, Case3, Case4 の 3 ケースで傾向の比較を行った。各ケースの平均適合率、平均再現率および平均 F 値を図 13 に示す。図より、Case 2 に対して Case 3 の平均適合率は 5.46 ポイント改善、平均再現率は 4.27 ポイント改善、平均 F 値は 4.57 ポイントの改善がみられた。適合率と再現率の両方が改善していることから、浸水道路だけでなく非浸水道路を同時に学習させることで、誤検知や見逃しが減少したことによって予測精度が向上する傾向にあることがわかる。また、Case 3 に対して Case 4 の平均適合率は 14.09 ポイント改善、平均再現率は 5.86 ポイント改善しており、平均 F 値は 9.97 ポイントの改善がみられた。こちらも同様に適合率と再現率の両方が改善している。特に適合率の改善つまり誤検出の減少が顕著である。一例として、図 14 と図 15 を示す。

図より、浸水道路のみを学習した Case 2 では誤検出は 23,973 pixel、見逃しは 10,537 pixel、正答は 2,810 pixel であったが、被災前後の非浸水道路も併せて学習した Case 4 では誤検出は 10,445 pixel、見逃しは 7,310 pixel、正答は 5,446 pixel に改善した。このことから被災地域の被災前の状況を学習に加えることで、人が被災前の道路の特徴を思い出しながら被災後の浸水道路を探し出すのと同様な効果が加わり、予測精度が向上する可能性が示された。

以上のことから、被災地域の被災後の浸水道路と非浸水道路に加えて被災前の状況を学習に加えることで、浸水道路の予測精度が向上する可能性が示唆された。

VI. 結言

本研究では、空中写真から道路浸水箇所を迅速かつ自動的に特定することを目的とし、深層学習を用いて予測を行なった。まず、豪雨災害の被災地域を国土地理院が撮影した空中写真から学習用とテスト用合わせて 158 枚の画像を作成した。次に、ResNet34 を使用して学習モデルを構築した。そして、学習用画像 4 ケースで学習し予測精度の評価を行った。

予測精度の評価から以下の知見を得た。

- ・全浸水画像の予測結果からは 4 つのケースには定性的には顕著な差はみられないが、F 値で比較すると浸水道路と同時に非浸水道路や非浸水道路と被災前道路の両方を学習すると予測精度が向上した

- ・浸水道路と非浸水道路の学習用画像を増やして学習できれば浸水道路の予測精度が向上する可能性がある

今回は人間が浸水道路を判別するプロセスを模して非浸水道路や被災前道路を同時に学習したが、被災前道路が学習に反映される効果的なロジックを取り入れることが出来れば、さらに浸水道路の予測精度が向上するであろう。

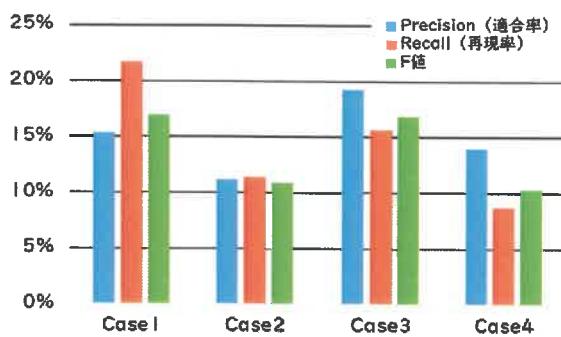


図 12. 全テスト用画像の予測精度

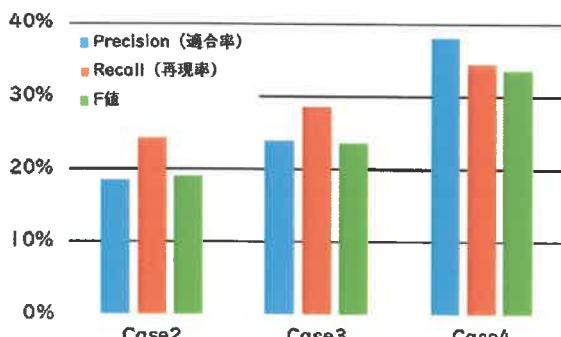


図 13. 学習用画像の予測精度

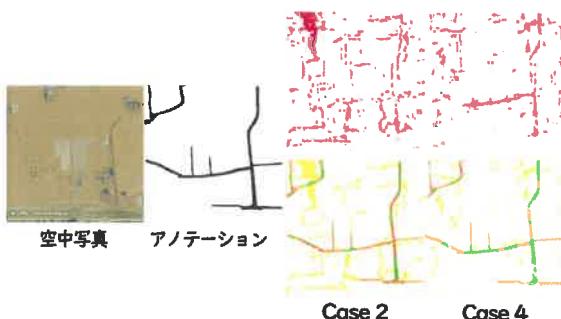


図 14. 学習用画像の予測結果と色分け

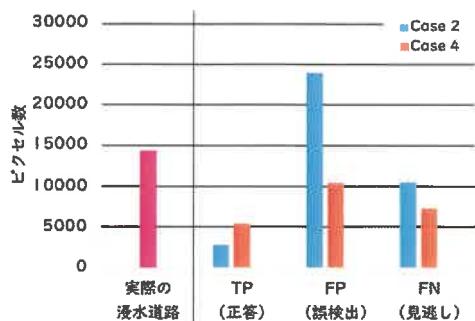


図 15. 学習用画像のピクセルごとの予測精度

参考文献

- 1) 気象庁：“災害をもたらした気象事例 平成30年7月豪雨（前線及び台風第7号による大雨等）”，2018.
<https://www.data.jma.go.jp/stats/data/bosai/report/2018/20180713/20180713.html>, (参照 2023-10-01)
- 2) 総務省消防庁：“平成30年度版消防白書”，2019.
https://www.fdma.go.jp/publication/hakusho/h30/items/h30_hakusyo_all.pdf, (参照 2023-10-1)
- 3) 国土地理院地理地盤活動研究センター地理情報解析研究室 岩橋純子：“浸水状況把握のリアルタイム化に関する研究”2020.
<https://www.gsi.go.jp/common/000223875.pdf>, (参照 2023-10-01).
- 4) 久保賛, 吉田秀典：“SAR画像を用いた豪雨災害時における道路被災箇所抽出に関する研究”, 土木学会論文集F6(安全問題), 77(2), I_33-43, 2021.
- 5) 三戸部佑太, 野村飛翔, 増田達男：“航空写真からの津波瓦礫判別におけるCNNの適用”, 土木学会論文集B2(海岸工学), 78(2), I_1045-1050, 2022.
- 6) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun：“Deep Residual Learning for Image Recognition”. In CVPR, 2016.
- 7) Olaf Ronneberger, Philipp Fischer, Thomas Brox：“U-Net: Convolutional Networks for Biomedical Image Segmentation”. Thomas Brox Lecture Notes in Computer Science 9351 234-241, 2015
- 8) Milletari.F, Navab.N, Ahmadi.S：“V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation”. In 3DV, 2016.
- 9) Kingma.D, Ba.J：“Adam: A Method for Stochastic Optimization”. In ICLR, 2015.