

ドローンを用いた洪水災害時の水没度検出手法

西村 侑花子¹ リズク ハマダ¹ 山口 弘純¹ 東野 輝夫¹

概要: 世界で最も深刻な被害をもたらす自然災害の1つが洪水であり, 例えば2019年の台風第19号により発生した豪雨では約8千棟の建物が水没している. こういった洪水災害時には, 道路や家屋, 車両の水害状況, 特に水没度を正確・迅速かつ広範囲に把握し, 適切な復旧支援計画を立てる必要がある. これに対し, 設置型の水位計は河川の水位計測を想定しており, 道路や住宅地の水没は考慮されていない. また, SNS やクラウドソーシングにより水没画像や映像を収集する手法では, 協力者や住民が接近困難な地域の情報収集は困難である. 本論文では, ドローンにより撮影された俯瞰画像から, 画像内の各住宅や車両の水没の水位を推定する手法を提案する. 提案手法では, オブジェクト認識用深層ニューラルネットワーク Mask R-CNN に転移学習を適用し, 限られた数の水害地俯瞰画像から浸水している家屋ならびに車両を認識する. また, 検出した浸水家屋ならびに車両の画像に対し, 事前に準備した水没度参照モデルを元にして推定した水没度をラベル付けし, VGG-16 ネットワークを適用して水没度を推定する. これらにより, 上空から撮影された広範囲の画像に映り込む各家屋や車両の水没度を迅速に推定することを目標とする. 実際の俯瞰画像を用いた評価の結果, 浸水家屋ならびに車両の検出精度は 73.42%, 水位推定誤差は 21.43cm であることを確認した.

Drone-based Water Level Detection in Flood Disasters

Yukako Nishimura¹ Hamada Rizk¹ HIROZUMI YAMAGUCHI¹ TERUO HIGASHINO¹

1. はじめに

世界中で台風と集中豪雨による洪水被害が深刻化している. 2020年1月, ブラジル南東部豪雨では44人が死亡し, 13,000人が洪水の影響を受けている [1]. また, ハリケーン Harvey は2017年にテキサス南東部とルイジアナ州南西部を襲い, 水害による家屋の損失は250億ドルを超えている [2]. 自然災害による被害からの迅速な回復を支援するためには, 情報技術により災害発生後の被害状況を即座に把握・分析し, 人命救助や物資支援, 道路や河川修復の緊急度判断等に活用することが望まれる.

そのような要求に対し, 画像解析に基づくアプローチがいくつか提案されている. Witherow らは [3] において, スマートフォンなどのモバイルデバイスにより撮影された画像から, 道路の浸水レベルを検出するための画像処理パイプラインを提案しており, Chaudhary らは [4] において, ソーシャルメディアに投稿された画像から水位を推定

する技術を提案している. Vitry らは既存の監視カメラシステムからの広域での浸水傾向を推定する手法を提案している [5]. これらのアプローチのほとんどは浸水の前後を撮影した画像の組が利用可能であることを仮定したり, 人間あるいは既設カメラによる撮影を前提としている. しかし, 特に台風や豪雨による洪水被害はその影響が広範囲にわたることが多く, かつ地上の道路交通網は遮断されることも多いため, 適用可能領域が限定されるといった課題がある. また, カメラを搭載したドローンで上空から現場映像を撮影し, 災害状況把握に活用する実事例が増えつつあるものの, 撮影した多数の画像や映像を人員が逐一確認し, その被害状況を判断・記録していくことは, 救助人員が不足しがちな災害発生直後においては現実的でない. したがって, 洪水災害の俯瞰画像から被災状況を表す意味ある情報を自動抽出し, 人間を支援する技術が望まれる.

本論文では, ドローンにより撮影された俯瞰画像から, 画像内で浸水している家屋や車両を検出し, それらの水没の水位を推定する手法を提案する. 提案手法では, オブジェクト認識用深層ニューラルネットワークである Mask

¹ 大阪大学 大学院情報科学研究科

R-CNN [6] を用い、限られた水没画像数から効率よく学習を行うため、転移学習を適用してネットワークを訓練する。また、典型的な住宅や車両の標準的な高さ情報を活用して画像内における住宅と車両の水位レベルを 50cm 毎でラベリングし、それらの水位を推定するニューラルネットワーク VGG-16 [7] に学習させ、Mask R-CNN で切り出した対象オブジェクトの水位レベルを推定するアプローチを採用している。実際の俯瞰画像を用いた評価の結果、水害を受けた家屋ならびに車両の検出精度 73.42 %、検出されたオブジェクトに対する水位推定誤差 21.43cm を達成できた。

2. 関連研究

災害復旧支援や被害状況把握における情報通信技術の活用事例は数多いが、本章では主に洪水被害の定量計測と自動理解の既存研究について述べる。

2.1 設置型センサーによる水位計測

水位測定専用センサーでは、主に圧力や気泡、浮力による測定や非接触ではレーダーを用いた測定が行われる。文献 [8] で提案されている自己較正型の水位計はミリメートルレベルの誤差で最大 150m の範囲での測定が可能である。また、Marin-Perez らは、Bluetooth 等の無線通信を介した水位情報を基地局に転送するための長寿命専用デバイスを開発している [9]。こういったデバイスは主に河川付近など洪水災害の危険性が高い領域を対象としており、住宅地や道路の水没状況把握用途には向かない。また、ハードウェアコストが軽減された場合も、広域への設置コストや維持管理の課題が残る。

2.2 既設監視カメラによる水位推定

Shi-Wei らは既存の河川監視カメラシステムを活用し、オブジェクト分離技術であるセマンティックセグメンテーションを適用して洪水災害を推定するアプローチを述べている [10]。同手法では、領域ベースのセグメンテーションを採用し、監視カメラでキャプチャされた観測エリアの洪水の危険性を自律的に推定する。Vitry ら [5] は、一般的な監視カメラによって取得されたビデオストリームから水位の変化を検出する方法を提案している。この手法では、各フレームにおいて水で覆われた領域のピクセルを検出し、連続するフレーム間でのそれらの変化から水位の変化を推定する。各フレームの浸水ピクセルを認識するために、深層畳み込みニューラルネットワーク (DCNN) である *U-net* [11] を利用したセグメンテーションを行う。スパマン順位相関において、DCNN から得られる浸水ピクセルと水位との相関は最大で 0.75 であることが示されているものの、相対変化のみを扱うために水位の絶対値は取得できない。

2.3 クラウドソーシングに基づく画像集約と洪水被害評価

Witherow ら [3] は、ユーザーが洪水時にモバイルデバイス (スマートフォンやドライブレコーダーなど) で撮影した道路画像から浸水領域を推定する手法を提案している。この手法では、浸水前後の差異を用いて浸水領域を抽出するため、各地点において、乾燥状態と浸水状態の両方の画像を必要とする。また、オクルージョンを生じるオブジェクトを自動で除去する方法も考案している。Chaudhary らは、Mask R-CNN [6] を用いて、地上から撮影された画像から浸水した人物、車、バス、自転車などのオブジェクト数を推定する方法を提案している [4]。この手法では、オブジェクト認識用の COCO データセット [12] を用いて水没したオブジェクトをセグメント化して認識し、水位推定のためのアノテーション手法を述べている。このモデルでは水位を 11 段階に分類することができ、実験では 10cm 未満の誤差を達成している。一方で、地上からの近接撮影映像であることから、被写体が明瞭かつ一定以上の大きさで撮影された高解像度画像を前提としているため、本論文で対象としている広域俯瞰画像に直接適用することは難しい。なお、水位測定の観点では、[4] の既存のモデルは測定可能水位が 170cm に制限されているが、日本で記録されている最大水位は約 350cm (2 倍) である。

2.4 空中からの洪水被害評価

前述のように、既存のシステムの多くは地上からの撮影画像を対象としているが、衛星からの空撮画像で洪水状況を分析するアプローチもある [13-15]。しかし、得られる情報はマクロスケールであり、かつリアルタイム性に関しては限界がある。本論文で提案するシステムは、災害復旧のための被害状況把握を目的としており、マイクロスケールの状況把握を目標とする。ドローンや UAV (無人航空機) により得られる広域カバレッジとデータの取得容易性から、範囲の限られた地上レベルの情報に比べて上空からの情報は有用である [16]。無人航空機で撮影した画像からオブジェクトを検出・追跡する研究は [17-19] をはじめ多数行われているが、水没オブジェクトを検出する手法は我々の知る限りまだ開発されていない。

3. ドローンを用いた洪水被害推定システム

3.1 システム概要

図 1 にシステム概要図を示す。提案システムは、オフラインでの学習ステージとオンラインでの判定ステージからなる。学習ステージで用いる画像は、水没度が異なるものや、洪水発生前の画像も収集するが、深層学習に十分な数量の洪水災害の俯瞰画像は一般に入手困難である。したがって、深層学習の訓練画像はデータ拡張により増加させる。このデータセットを用い、既存の訓練済みの R-CNN オブジェクト認識モデルを再学習させることで、家屋と車両

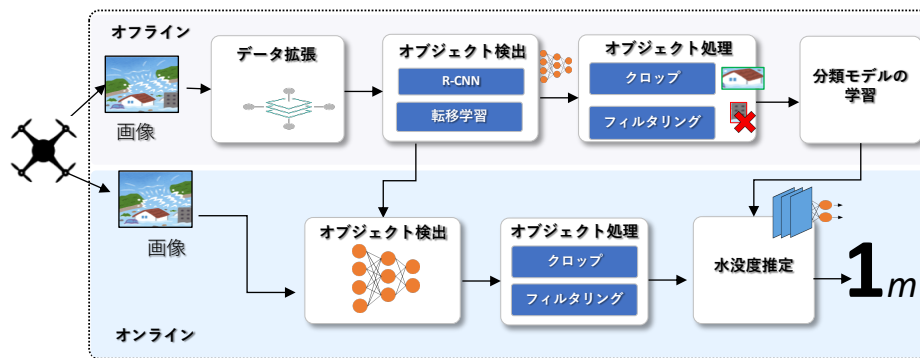


図 1 システム構成図

の物体検出モデルを構築する。次に、水没度決定モデルを用いて、マニュアルでアノテーションされたオブジェクト画像群を用い、VGG-16 ネットワークによる水没度分類モデルを構築する。判定ステージでは、ドローンによって撮影された画像に対し、オブジェクト検出モデルを適用し、画像内のオブジェクトを識別して位置を特定する。また、識別されたオブジェクトに対し、水没度分類モデルを適用してその水没度を判定する。

3.2 データセットの作成

3.2.1 訓練用空撮画像の選定

教師データとしては、撮影した高度、画像サイズ、および解像度の点で様々なデータを用いることで、多様な状況に対応可能なモデル構築を目指す。であるため、あわせて、適切な高さで取得された通常時（水没度 0）の空撮画像を Google Earth 等で取得するものとする。次に、高度から撮影されたことにより解像度が低い画像、および不鮮明な画像はあらかじめ除外し、一定の解像度でかつ適切な高度から撮影された画像のみを選別する。また、広域の撮影画像には一般的に学校、病院など住宅でない建物が多く含まれるが、これらは本システムでの検出対象とはしない。したがって、不要なオブジェクトを除外するために画像をトリミングし、データセット画像として家と車のみを含む画像を用意する。


3.2.2 アノテーション

本論文ではアノテーションおよびデータ管理プラットフォーム *supervisely* でアノテーションを行った。対象とする各オブジェクトに対し、ラベルとしてバウンディングボックス、オブジェクトクラス（家または車）、ならびにオブジェクトのピクセルを覆うマスク、の 3 つを与える。なお、オブジェクトのマスクは Mask R-CNN モデルを訓練するために必要であるが、提案手法においてはアノテーションの簡単のため、精度に影響を与えない範囲でバウンディングボックスの内部全体をマスクとした。図 2 にマスクの例を示す。

次に、各オブジェクトの水没度を 0m から 3m まで 0.5m



図 2 オブジェクトに対するマスクの指定例



家	車	水没度 (m)
2 階の最下部	—	3
1 階の天井	—	2.5
1 階の窓の上部	—	2
1 階の窓の半分	窓の上部	1.5
1 階の窓の下部	窓の下部	1
家の基礎の上部	タイヤのホイール上部	0.5
地面	地面	0

図 3 家と車の標準サイズと水没度モデル

幅でアノテーションする。ただし、水没度の真値を取得することは一般に困難であることから、本研究では画像内の家屋や車の標準的な大きさから詳細な水没度の真値を推定する。具体的には、図 3 に示すように、標準的な住宅ならびに車両の大きさを指標として水没度の判断基準を定義する。アノテーション例を図 4 に示す。

なお、他の建物による遮蔽やカメラの撮影角によっては水没度の目測が難しい場合がある。したがって、遮蔽されたオブジェクトの水没度は、(1) 屋根のレベルが同じ住宅・車は、同じ標高にあり、(2) 同じ標高の家・車は同じ水没度である、という前提で推測する。

3.2.3 データ拡張

画像データにおけるデータ拡張は、データセット内の画像を変換したものを生成することで、学習セットのサイズを恣意的に増加させる技術であり [20]、生成には画像のシ



図 4 アノテーション例




図 5 データ拡張結果の例

フト、反転、ランダム回転、ノイズ付加、明るさ調整、色付け、ズームなどの操作を適用する。本研究では、機械学習用の Python ライブラリ *imgaug* [21] を利用し、反転、ノイズの追加、明るさや色の調整などによるデータ拡張を行っている。図 5 に、データ拡張の結果の一例を示す。

3.3 Mask R-CNN の転移学習によるオブジェクト検出

オブジェクト検出モジュールは、画像から車や家を検出し、認識する役割を担う。このモジュールは、畳み込み層を介して与えられた画像から特徴抽出と物体検出をするために深層ニューラルネットワークを利用する。深層ニューラルネットワークでは、プロブ、エッジなどの低レベルの特徴を低レベルの層で抽出し、車や家などの高レベルのオブジェクトを高レベルの層で認識する。一般性を失うことなく、本論文では物体検出の目的で最も使用されているネットワークである Mask Region-based Convolutional Network (Mask R-CNN) [6] を採用した。Mask R-CNN からの出力は、検出および分類された車や家などのオブジェクトとそのバウンディングボックスである。

3.3.1 既存の学習済モデル

matterport 社 [22] では、COCO データセット [12] を用いた学習済の Mask R-CNN モデルを提供している。学習された COCO データセットは車オブジェクトのクラスを含むため、提供されたモデルは、図 7(a) に示すように、水没した車の一部を認識できる。一方、学習に使われたデータセットに含まれていない家のオブジェクトは、図 7(b) に




図 6 Mask R-CNN の構成図



(a) 車



(b) 家

図 7 [22] のモデルによる認識例

示すように、傘やボートのような他のオブジェクトとして認識され、そうでなければ検出もされない。また、COCO データセットに含まれる画像は、一般的に地上から撮影されたものであるため、学習済モデルは、本研究が対象とする空撮画像には対応しておらず、誤認識を多く生じる。したがって学習済の Mask R-CNN モデルはそのままでは利用できない。本論文ではこの学習済モデルを我々のデータセットで再学習させることでこの問題を解決している。

3.3.2 転移学習

Mask R-CNN を用いた転移学習プロセスの実装には、Matterport 社の Mask R-CNN ライブラリ [6] を利用した。データセットは 3.2 節で述べたものを用いるが、すべての画像は同じサイズにリサイズしておく。また、データセットは学習用とテスト用に分割しておく。

Mask R-CNN は、特徴ピラミッドネットワーク (FPN) [23] と ResNet [24] をベースに構築されている。入力画像から線や角などの単純な特徴を抽出するために、いくつかの畳み込み層で構成される ResNet を Backbone 層として採用している。その後、特徴ピラミッドネットワーク (FPN) を経由し、より具体的で複雑な特徴を抽出する。ここで抽出された結果は特徴マップと呼ばれる。次に、領域提案ネットワーク (RPN) [25] を適用し、対象オブジェクトが含まれている可能性の高い領域を示す関心領域 (RoI) を記録する。出力層では、記録した RoI 上の特徴マップの

みを参照し、オブジェクトの位置を特定して認識する。

学習では、入力画像サイズ、RoI 数、学習層、学習率、エポック数の 5 つのパラメータを主に定義する。表 1 に提案システムのパラメータを示す。これらのパラメータは以下の戦略に従って設定される。

すべての入力画像は、モデルネットワークの入力層に対応する同次元にリサイズする必要がある。このため、入力画像のサイズが大きい場合は計算量が多くなり、小さい場合は元々の高解像度画像に含まれる意味のある情報が失われてしまう可能性がある。そのため、画像サイズを最高解像度の半分程度の 512×512 ピクセルに設定している。また、RoI の数を決定するために、対象となるオブジェクトの候補を 1 つの RoI とする。空中画像では、1 つのオブジェクトの最小 Bounding box サイズは 4×4 ピクセル程度であったため、これに対応し、1 枚の画像に現れる可能性のある物体の最大数である 128 を RoI 数とした。

なお、転移学習を実行する際は、他の学習法と同様に、学習率やエポック数を調整し、過学習を回避しながら最適な精度を得る必要がある。経験的に学習率は 0.001、エポック数は 100 に設定した。

3.4 水没度推定

水没度分類モジュールでは、学習に用いる入力画像は、3.3 章で説明した物体検出モジュールの結果を基にクロップされたオブジェクトである。入力画像の生成方法、学習モデルの構成、およびそれに対応する学習方法については、以下で詳細に説明する。

3.4.1 入力画像の生成

オブジェクト検出モジュールから、データセットの各画像上に検出したオブジェクトと配置されたバウンディングボックスが得られる。水没度分類モデルの入力画像を生成するため、このバウンディングボックスを参照して、画像からオブジェクトをクロップする。クロップする範囲は、水没度推定結果に重要な影響を与える可能性のある周囲の情報を含めるために、バウンディングボックスよりもわずかに大きくしている。また、各オブジェクトは水没度を前述の方法でアノテーションする。

次に、情報が不十分な入力画像から不正確な水没度が推定されないように、高所から撮影された小さなオブジェクトが多い画像は除外する。この条件は、画像に含まれるオブジェクトのバウンディングボックスの平均サイズが画像サイズの α 倍よりも小さい場合である。なお、本システムで設定されている画像サイズに対するオブジェクトサイズの比率 α は、実験では 0.005 としている。

$$\frac{1}{num_{object}} \sum_{i=1}^{num_{object}} size_i < \alpha \times size_{image}$$

次に、各画像について、さらに情報量の多いオブジェク




図 8 VGG-16 モデルの構成

トのみをピックアップする。すなわち、画像全体から、バウンディングボックスの平均サイズより小さいオブジェクトを除外する。この条件は以下の通りである。

$$width < \frac{1}{num_{object}} \sum_{i=1}^{num_{object}} width_i$$

$$height < \frac{1}{num_{object}} \sum_{i=1}^{num_{object}} height_i$$

3.4.2 水没度モデルの構成

認識されたオブジェクト画像から水没度を推定するモデルとして、VGG-16 ネットワーク [7] を採用した。VGG-16 は、図 8 に示すようなアーキテクチャを持つ 16 層の畳み込みニューラルネットワークである。ネットワーク全体は、13 層の畳み込み層、5 層の最大プーリング層、3 層の全結合層の 21 層で構成されているが、そのうち、重みを含むのは 16 層のみである。

3.4.3 トレーニング戦略

利用した VGG-16 ネットワークは事前学習が行われていないため、十分な数の画像データを用意するために各オブジェクト画像をランダムに回転させ、データ量を 3 倍とした。

入力画像サイズ、損失関数、最適化関数、学習率、エポックを含むモデルのパラメータは表 2 のように設定した。入力画像サイズには、クロップされたオブジェクトの予想最大サイズである 128×128 ピクセルを設定した。オブジェクト検出モジュールと同様に、切り出したオブジェクト画像は、ゼロパディングを用いて同次元にリサイズする。学習パラメータについては、水没度推定はクラス分類として実行されるため、損失関数としてカテゴリ交差エントロピーを使用する。また、最適化手法として確率勾配降下法 (Stochastic Gradient Descent, 略して *sgd*) を選択する。これは、他の最適化関数 (具体的には Adam) と比較して、実験結果の精度が高いためである。それ以外のパラメータは、過学習と判断されないようにしつつ、高い検証精度を目指して、実証実験に基づいて決定した。具体的には、パラメータ調整処理で、50 エポックの間でより良い精度が得られるたびに、検証精度と重み変数を監視し、保存する。50 エポックの間に、それ以上精度が向上しない場合は、処理を終了する。

4. 評価実験

本章では、提案手法をオブジェクト検出と水没度推定の

表 1 オブジェクト検出ネットワークの訓練用パラメータ

学習率	RoI の数	学習させる層	入力画像サイズ	エポック数
0.001	128	Heads Layer	512*512*3	100

表 2 水没度推定ネットワークの訓練用パラメータ

学習率	最適化関数	損失関数	入力画像サイズ	エポック数
0.001	sgd	categorical crossentropy	128*128*3	300

表 3 画像の地域別枚数

発生場所	発生年	画像数
岡山	2018	6
長野	2019	4
宮城	2019	3
佐賀	2019	12
東京	2019	1
和歌山	2017	3
広島	2018	6
千葉	2019	5
沖縄	2018	1
高知	2019	3
福岡	2019	1
大分	2017	2
合計		47

2つの部分に分け、順に評価する。収集したデータは、洪水画像 47 枚と非洪水画像 5 枚である。表 3 に洪水の発生場所と発生年を示す。モデルの学習では、CPU に Intel(R) Xeon(R)@2.20GHz, GPU には Google Colaboratory 社の 16GB のメモリを有する P100-PCIE-16GB を使用した。

4.1 オブジェクト検出

収集した 52 枚の画像の中には、733 個のオブジェクト (420 軒の家と 313 台の車) が含まれる。オブジェクト検出モジュールを評価するために、80%の画像を学習用に、残りの画像をテスト用に分割している。評価指標には mean Average Precision (mAP), precision, および recall を採用した。

Average Precision(AP) は、precision と recall の両方の結果を組み合わせた指標である。AP の一般的な定義は、precision-recall 曲線の下での面積である。precision-recall 曲線は、異なる予測信頼度の precision(y 軸) と recall(x 軸) をプロットしたものである。この precision-recall 曲線の例を図 9 に示す。precision と recall の値は評価対象の数に依存する。モデルが偽陽性も偽陰性もなく真値に完全に一致する正確な予測をした場合、AP は 1.0 となる。すなわち、AP が 1 に近いほど誤差が少ないことを意味する。AP は以下で定義される。

$$AP = \int_0^1 p(r)dr$$




図 9 Precision-Recall 曲線

表 4 オブジェクト検出の結果

mAP	Average Precision	Average Recall
0.73	0.71	0.79

mAP は全画像の Average Precision (AP) の平均値であり、以下で定義される。

$$mAP = \frac{\#_of_images}{\sum_{i=1} AP_i}$$

mAP, 平均 precision, 平均 recall の結果を表 4 に示す。得られた Average Precision (AP) の平均値は 0.73 である。

AP の結果は、個々の画像に注目するとばらつきが大きい。図 10 では、AP 値に有意な差がある 4 つの結果をピックアップしており、それぞれ 84%, 74%, 66%, 22% である。precision と recall を比較した場合、平均的に recall の方が precision よりも高くなった。つまり、この検出モデルは、偽陽性の結果 (誤検出) よりも偽陰性の結果 (検出もれ) の方が少ない。したがって、検出モデルは、検出されたオブジェクトに多少の誤りが含まれていたとしても、ほとんどのオブジェクトを検出できていることを示す。図 11 に家と車それぞれのオブジェクトクラスの認識結果を示す。この結果から、車オブジェクトの平均精度と平均 recall の両方が家オブジェクトよりも高いことがわかる。これは、3.3.1 小節で述べたように、Matterport 社が提供する学習済モデルでは車オブジェクトは考慮されていたが、家オブジェクトは考慮されていなかったためだと考えられる。すなわち、車は事前学習と転移学習の両方で学習させた一方、

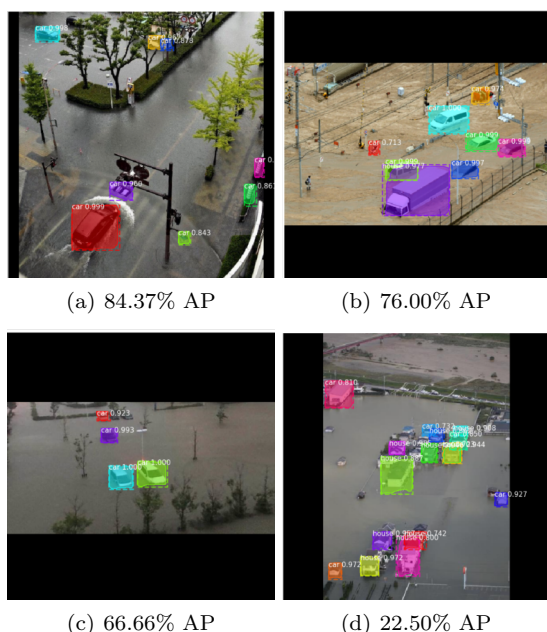


図 10 異なる AP の認識結果

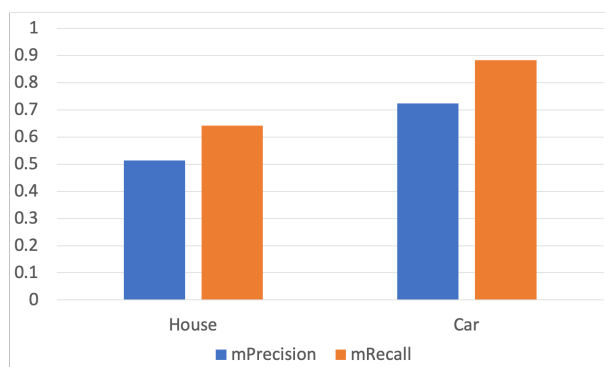


図 11 各クラスの Precision および Recall

家は転移学習でのみ学習させたためであるといえる。したがって、学習画像数が増えれば、家の検出精度も高くなると期待できる。

次に、バウンディングボックスの大きさに様々な閾値を設けた時の結果を比較すり。閾値は、 $\alpha \times 512 \times 512$ で計算され、 α は 0 から 0.03 の間で変化するオブジェクト-画像比である。各閾値に対する検出オブジェクト数、平均 precision, 平均 recall, mAP の結果を図 12 に示す。

全体的な傾向として、閾値が大きくなると、誤検出数は減少し、mAP は増加している。これは、高高度から撮影した小さな物体の方が低高度から撮影した物体よりも誤って検出されやすいことを意味している。したがって、適切なオブジェクトの大きさになるようドローンの飛行位置を調整することが高精度な認識結果につながると予想される。

ただし、 $\alpha=0.0175$, $\alpha=0.03$ とした時に精度が低下している。これは、閾値が真値のバウンディングボックスと検出されたバウンディングボックスの間にあることに起因している可能性がある。例えば、閾値の大きさが予測された

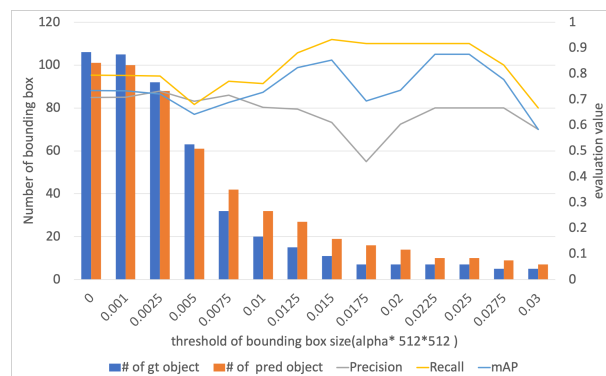


図 12 各閾値以上のサイズのオブジェクトの精度

バウンディングボックスよりも大きく、かつ同一オブジェクトの真値のバウンディングボックスよりも小さい場合、予測されたバウンディングボックスは評価対象に含まれず、偽陰性が増加する。逆に、閾値の大きさが予測されたバウンディングボックスより小さく、かつ、真値のバウンディングボックスより大きい場合には、真値のバウンディングボックスは評価対象から除外され、その結果偽陽性が増加する。

4.2 水没度推定

水没度推定では、前回の評価でオブジェクト検出ステップから切り出した 627 枚のオブジェクト画像を使用する。各クラスと水位に含まれるオブジェクトの数を表 5 に示す。水没度推定では、627 枚のオブジェクト画像のうち、80%を学習に、残りの 20%をテストに使用する。また、オブジェクト画像をランダムに回転させることで、データ数を 3 倍の 1881 個に増やした。表 6 は、3.4 章で説明した手順でテストデータをフィルタリングした結果である。 α には 0.005 を選択した。

本研究では、分類精度および水没度の真値と予測値の誤差で提案手法を評価した。また、水没度推定のみの精度を評価するために、モデルの入力画像は、オブジェクト認識フェーズで検出したバウンディングボックスではなく、その真値でクロップしたオブジェクト画像を用いた。その結果、提案手法は 57.14%の精度で水没度を分類し、水没度推定の平均誤差は 21.43cm であった。図 13 は、真値の各水没度に対する水没度推定の平均誤差を示したものである。1.5m 以上はデータが不足しており、評価できなかった。今後は、より多くのデータを収集して、提案手法の評価を行う必要がある。

また、オブジェクト検出結果でクロップした画像を用いた水没度推定の評価も行った。提案手法は、42.04%の精度で水没度を分類し、28.57cm の平均誤差で水没度を推定することができた。図 14 は各水位の誤差を示している。この結果から、検出されたオブジェクト画像を用いた水没度推定は、分類精度を低下させるが、水没度推定誤差には大

表 5 学習およびテスト用のオブジェクト画像数

合計	家	車	0m	0.5m	1m	1.5m	2m	2.5m	3m
627	366	261	120	207	134	77	7	81	1

表 6 バウンディングボックスの画像サイズに対する比率 (α) を変化させた場合の効果

α	画像数	総オブジェクト数	家の数	車の数	level	level	level	level	level	level	level
					0	0.5	1	1.5	2	2.5	3
0.1	0	0	0	0	0	0	0	0	0	0	0
0.05	0	0	0	0	0	0	0	0	0	0	0
0.01	4	6	6	0	2	3	1	0	0	0	0
0.005	11	14	10	4	5	8	1	0	0	0	0
0.001	11	14	10	4	5	8	1	0	0	0	0




図 13 バウンディングボックス真値を用いた場合の水没度誤差

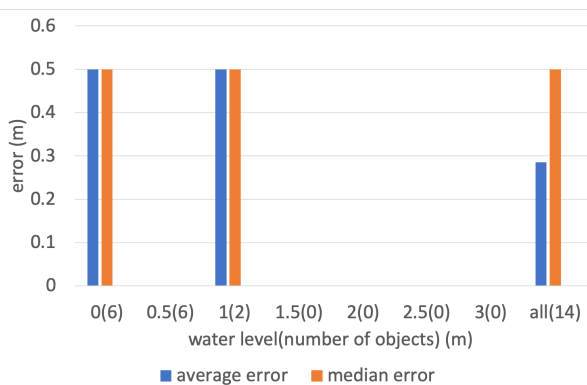


図 14 バウンディングボックス検出値を用いた場合の水没度誤差

きな影響を与えないことがわかる。そこで、物体検出により検出された物体画像を用いて学習したモデルと、真値の物体画像を用いて学習したモデルの2つのモデルをそれぞれ評価した。その結果、どちらのモデルも30cm以下の誤差で水没度を推定することができ、家や車の大きさに比べ、十分に小さい値であった。したがって、提案手法は水没したオブジェクト検出ならびにその水没度において、妥当な精度を達成することができたといえる。

5. まとめと今後の課題

本研究では、ドローンから入手可能な水害現場の俯瞰空撮画像から水没した家および車を検出し、その水没度判定する手法を定義した。具体的には、俯瞰画像のオブジェクト検出では、学習済の Mask R-CNN ネットワークに転移学習を適用し、73.42%の mAP を達成した。また、水没度推定では誤差 21.43cm の結果が得られている。今後の課題として、オブジェクト検出精度の低い家の空撮画像の追加による、オブジェクトの検出精度全体の改善が挙げられる。また、現段階では水没度推定において、単一の分類モデルを使用しているが、オブジェクトのクラス毎に別の分類モデルを作成することで、精度の改善が見込める。加えて、実用に向けて本システムのオンラインステージで、水没状況と実世界の位置情報をリンクさせることも課題である。

謝辞

本研究成果は国立研究開発法人情報通信研究機構 (NICT) の委託研究「データ連携・利活用による地域課題解決のための実証型研究開発」により得られたものです。

参考文献

- [1] Claudia Dominguez, Ana Melgar. Heavy rains and floods leave dozens dead in southeastern Brazil. <https://edition.cnn.com/2020/01/27/americas/rains-floods-minas-gerais-brazil-intl/index.html>. [Online; accessed 10-Jan-2020].
- [2] Jackie Wattles. Hurricane Harvey: 70% of home damage costs aren't covered by insurance. <https://money.cnn.com/2017/09/01/news/hurricane-harvey-cost-damage-homes-flood/index.html>. [Online; accessed 27-Dec-2019].
- [3] Megan A. Witherow, Cem Sazara, Irina M. Winter-Arboleda, Mohamed I. Elbakary, Mecit Cetin and Khan M. Iftekharuddin. Floodwater detection on roadways from crowdsourced images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging &*

- Visualization*, Vol. 7, pp. 529–540, 2018.
- [4] Priyanka Chaudhary, Stefano D’Aronco, Matthew Moy de Vitry, J Leitão, and J Wegner. Flood-Water Level Estimation from Social Media Images. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 4, No. 2/W5, pp. 5–12, 2019.
 - [5] Matthew Moy de Vitry, Simon Kramer, Jan Dirk Wegner, and João P. Leitão. Scalable Flood Level Trend Monitoring with Surveillance Cameras using a Deep Convolutional Neural Network. *Hydrology Earth System Sciences*, Vol. 23, p. 4621–4634, 2019.
 - [6] Waleed Abdulla. Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow. https://github.com/matterport/Mask_RCNN, 2017. [Online; accessed 3-Feb-2020].
 - [7] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition, 2014.
 - [8] Guilin Zheng, Hongyan Zong, Xiangtao Zhuan, and Lijuan Wang. High-Accuracy Surface-Perceiving Water Level Gauge With Self-Calibration for Hydrography. *IEEE Sensors Journal*, Vol. 10, No. 12, pp. 1893–1900, 2010.
 - [9] Rafael Marin-Perez, Javier García-Pintado, and Antonio Skarmeta Gómez. A Real-Time Measurement System for Long-Life Flood Monitoring and Warning Applications. *Sensors*, Vol. 12, No. 4, pp. 4213–4236, 2012.
 - [10] Shi-Wei Lo, Jyh-Horng Wu, Fang-Pang Lin, and Ching-Han Hsu. Cyber Surveillance for Flood Disasters. *Sensors*, Vol. 15, pp. 2369–2387, 02 2015.
 - [11] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *Proceedings of International Conference on Medical image computing and computer-assisted intervention*, pp. 234–241, 2015.
 - [12] Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár, and C Lawrence Zitnick. Microsoft coco: Common objects in context. In *Proceedings of Computer Vision – ECCV 2014*, pp. 740–755. Springer, 2014.
 - [13] Rajesh Kumar Pandey, Jean-François Cretaux, Muriel Bergé-Nguyen, Virendra Mani Tiwari, Vanessa Drolon, Fabrice Papa, and Stéphane Calmant. Water level estimation by remote sensing for the 2008 flooding of the Kosi River. *International Journal of Remote Sensing*, Vol. 35, pp. 424–440, 01 2014.
 - [14] Sheng Chen, Huijuan Liu, Yalei You, Esther Mullens, Junjun hu, Ye Yuan, Mengyu Huang, Li He, Yongming Luo, Xingji Zeng, Guoqiang Tang, and Yang Hong. Evaluation of High-Resolution Precipitation Estimates from Satellites during July 2012 Beijing Flood Event Using Dense Rain Gauge Observations. *PLoS one*, Vol. 9, p. e89681, 04 2014.
 - [15] Sandro Martinis, André Twele, and Stefan Voigt. Towards operational near real-time flood detection using a split-based automatic thresholding procedure on high resolution terrasar-x data. *Natural Hazards & Earth System Sciences*, Vol. 9, No. 2, 2009.
 - [16] Mark LaFay. *Drones For Dummies*. John Wiley & Sons, 2015.
 - [17] Arifin Futuhal, Daniel Ricky Arifandi, and Widiyanto Didit. Autonomous Detection and Tracking of an Object Autonomously Using Ar.drone Quadcopter. *Jurnal Ilmu Komputer dan Informatika*, Vol. 7, No. 1, pp. 11–17, 2014.
 - [18] Rito Yasuoka, Motoharu Sonogashira, and Masaaki Iiyama. An object recognition with photographs that was taken by a drone’ camera. *ELCAS Journal*, Vol. 3, pp. 85–87, 2018.
 - [19] Gaspare Maria, Enrico Baccaglini, Daniele Brevi, Marco Gavelli, and Riccardo Scopigno. A drone-based image processing system for car detection in a smart transport infrastructure. In *Proceedings of 2016 18th Mediterranean Electrotechnical Conference (MELECON)*, pp. 1–5, 2016.
 - [20] Connor Shorten and Taghi M. Khoshgoftaar. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, Vol. 6, pp. 1–48, 2019.
 - [21] Alexander B. Jung, Kentaro Wada, Jon Crall, Satoshi Tanaka, Jake Graving, Christoph Reinders, Sarthak Yadav, Joy Banerjee, Gábor Vecsei, Adam Kraft, Zheng Rui, Jirka Borovec, Christian Vallentin, Semen Zhydenko, Kilian Pfeiffer, Ben Cook, Ismael Fernández, François-Michel De Rainville, Chi-Hung Weng, Abner Ayala-Acevedo, Raphael Meudec, Matias Laporte, et al. imgaug. <https://github.com/aleju/imgaug>, 2020. [Online; accessed 01-Feb-2020].
 - [22] Inc Matterport. Matterport: 3D Camera, Capture & Virtual Tour Platform — Matterport. <https://matterport.com/>, 2020. [Online; accessed 24-Oct-2019].
 - [23] Tsung-Yi Lin, Piotr Dollár, Ross Girshick, Kaiming He, Bharath Hariharan, and Serge Belongie. Feature Pyramid Networks for Object Detection. In *Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017.
 - [24] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep Residual Learning for Image Recognition. In *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
 - [25] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 6, pp. 1137–1149, 2017.