

UAV 写真測量と深層学習を活用した 河道管理手法の研究

藤井 純一郎¹・吉田 龍人²・天方 匡純²・山下 隆義³

¹正会員 八千代エンジニアリング株式会社 技術開発研究所 (〒111-8648 東京都台東区浅草橋 5-20-8)
E-mail: jn-fujii@yachiyo-eng.co.jp (Corresponding Author)

²正会員 八千代エンジニアリング株式会社 技術開発研究所 (〒111-8648 東京都台東区浅草橋 5-20-8)

³非会員 中部大学 工学部情報工学科 (〒487-8501 愛知県春日井市松本町 1200)

我が国は、その国土に多くの河川を有し、点検・巡視などの河川維持管理業務の多くは目視により行われている。中でも頻度の高い河川巡視では巡視員が現場で異常の記録や河道の状況把握などを行っているが、その一部は UAV による写真測量と深層学習による画像認識を組み合わせて効率化できると考えられる。本研究では UAV 写真測量で得られたオルソ画像に対して、深層学習による画像認識手法の一つである **Semantic Segmentation** を適用し、河道内の砂州・樹木等の領域を分類する手法を提案する。深層学習モデルは撮影高度の異なる空撮画像を混合して学習を行い、高い精度の河道領域分類モデルを得ることができた。当該のモデルを地上画素寸法 (GSD) を変えたオルソ画像に適用する実験を行い、教師データと GSD が異なるオルソ画像に対しても汎用的に領域分類が行えることを確認した。

Key Words: 河川巡視, 河道管理, UAV, SfM, Semantic Segmentation, DeepLab-v3+

1. はじめに

従来、河川管理においては河川砂防技術基準 維持管理編 (河川編)¹⁾に基づき、河川技術者の目視により点検及び巡視が行われてきた。これらの河川維持管理業務には全国で膨大な労力がさかかれており、極めて人的資源に依存した管理がなされている。また点検・巡視記録は河川技術者の判断が含まれるため個人差が生じる場合があることも課題である。

これに対し点検・巡視を担う河川技術者は減少傾向にあり、労働力不足解消および技術の伝承のためには、IT を活用したデジタル化と自動化が喫緊の課題である。

一方、医学や製造業などの分野では従来目視に頼っていた人的作業を AI を活用して自動化や人の判断の支援を実現し成果を挙げている。AI による目視の代替としては深層学習モデルによる画像認識技術の進展が目覚ましく、比較的単純な画像分類のタスクでは AI が人の分類精度を上回ることが報告されている²⁾。

そこで本研究では深層学習モデルを活用した画像認識技術を河川維持管理に適用する。点検と巡視では頻度と求められる精度が異なり、頻度は巡視の方が高く精度は点検の方が高いため、まずは巡視を対象に AI を適用することが効率化の効果が高いと考える。河川巡視対象の項目は多岐に渡るが、画像認識と親和性が高く経年的な記録を残す意義が高い河道管理を対象とする。

また画像認識を用いて河道管理を行う場合、時系列で均質な画像を取得・蓄積することが条件となる。河川空間は一般的に上空が開けており、電線等の障害物も市街地と比べて少ないため、UAV (ドローン) の自律飛行に適した環境と言える。したがって本研究では UAV による写真測量を前提として、深層学習による画像認識手法の一種である **Semantic Segmentation** を適用することにより、河道管理に資する砂州・樹木・滯筋などの領域を自動分類および定量化する手法を提案し、長野県三峰川において実証を行った。

2. 既存研究と課題

空撮画像を用いた河道管理に関連する研究としては、大きく写真測量に関する研究と画像認識に関する研究に分けられる。

(1) 写真測量に関する技術

一般的な地図作成において航空写真測量は広く利用されている。従来は有人機による写真測量により地図作成が行われていたが、有人機の運用にはコストがかかり限られた航測会社のみが保有している。UAV による写真測量は、狭い範囲であれば低コストで迅速に高解像度の写真を取得することが可能であり、公共測量への適用が始まっている³⁾。また動画や静止画からカメラの位置を

推定し、被写体の3次元形状を復元する SfM 技術⁹⁾と組み合わせることで、空撮画像からオルソ画像と数値表層モデル (DSM) の生成も一般化しており、これらの機能を有するソフトウェアが市販されている⁹⁾。そのため、河川の図面作成や地形計測においても UAV による空撮画像を元にした写真測量が活用されている⁹⁾。

以上のように UAV 空撮から河川地形を把握することはすでに実用化されている。しかし座標値に基づき地形は把握できるものの、領域ごとの地物は自動で把握することは難しい。座標値の集合である点群データから地物のクラス分けを行う研究がされているが、建物や道路などの人工物は形状がはっきりしており分類が比較的容易なのに対して、河道などの自然形状は分類が難しい⁷⁾。

(2) 画像認識に関する技術

写真測量のアプローチとは別に、画像認識技術に基づき河道やその他地物の情報を判別する取り組みは古くから行われている。土地被覆分類はリモートセンシングの主要なタスクの一つであり、衛星写真や航空写真の画素値をもとに機械学習により領域分類を行う。この手法では広域を同じ条件で撮影できる場合には有効だが、撮影時間や天候の違いにより画素値が変わるとうまく分類できないという課題がある。

これに対して深層学習による画像認識は単純な画素値でなく、より高度な画像の特徴をとらえることが可能なため、明るさの違いなどに対して頑健な分類が期待できる⁸⁹⁾。画像全体の領域を分類する Semantic Segmentation に深層学習を適用するモデル¹⁰⁾が開発されて以来、様々な分野で活用がされてきた。

Semantic Segmentation の精度は一般に公開されたベンチマークデータセットで評価をされており、都市景観や道路景観のデータセットは存在し、それらのデータセットに対して近年は毎年最高精度のモデルが発表される状況にある。衛星画像や航空写真に対しても深層学習の適用の研究が進められており、特に建物検出については地図作成で汎用的に利用できる技術であることから研究が盛んにおこなわれており、ベンチマークデータを用いた国際的なコンペ¹¹⁾も行われている。

以上のように深層学習による Semantic Segmentation の技術は進展しているのに対し、その技術を河道内の領域分類に特化して適用した事例は見当たらない。また砂州や樹木といった河道内の領域分類に資するベンチマークデータも存在しない。

(3) 既存研究のまとめと課題

UAV 写真測量は実用化段階にあり、河川においても適用されているが、UAV 写真測量の結果から砂州・樹木などの自然地形の領域の判定を行うことは難しい。

深層学習方式による領域分類も実用化されているが、河道に特化したベンチマークデータはなく、それゆえ河道内の Semantic Segmentation モデルも開発されていない。

3. 本研究の提案手法

既存研究の課題を鑑み、本研究では日常的な河道管理に適用可能な手法として、UAV 写真測量と深層学習を組み合わせた河道領域分類手法を提案する。河道管理のためには砂州・樹木などはピクセル単位でなく座標や面積などでの定量的な把握が必要となるが、UAV 写真測量で作成したオルソ画像を用いることでこれを実現する。提案手法の処理の流れを図-1 に示す。

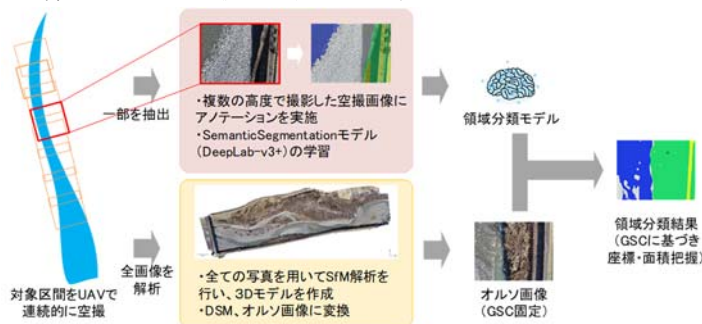


図-1 本研究の提案手法

ここで UAV の飛行高度は河川の大きさや上空の障害物などに依存し、空撮画像の地上画素寸法 (GSD) は統一できないため、実用面を考慮すると深層学習モデルの適用対象の画像スケールにはある程度自由度を持たせたい。すなわち一つのモデルで 1/2500 スケールの画像でも 1/10000 スケールの画像にでも適用できるような汎用性が求められる。

本研究では高精細な元画像で深層学習を行い、GSD を変えた複数のオルソ画像で領域分類を行う実験により手法の妥当性を検証した。

4. 深層学習モデルの学習

長野県の三峰川の空撮画像を用いて、河道内の領域分類を行う Semantic Segmentation モデルの学習を実施した。

(1) 使用データ

a) 空撮画像

深層学習モデルの教師データとして、三峰川流域を UAV で空撮した画像 200 枚を使用した。空撮画像は DJI 社製 Phantom4 Pro で撮影しており、画像の大きさはすべて横 4864px×縦 3648px である。撮影高度は 50m, 100m, 150m の 3 種であり、高度毎の枚数と GSD は表-1 の通りである。

GSD は機材のスペックから求められる理論値であり、UAV は風の影響などにより高度や画角が若干揺らぐため、厳密には GSD は画像ごとに異なる。

表-1 空撮画像仕様

撮影高度	枚数	GSD 理論値
50m	107 枚	1.37mm/px
100m	49 枚	2.74mm/px
150m	44 枚	4.11mm/px



図-2 空撮画像サンプル (高度 50m/100m/150m)

b) 領域クラスのアノテーション

河川巡視で把握すべき河道の状況としては「砂州堆積の状況」「樹木群の生育状況」などがある。河川巡視では測量レベルの精密な位置情報は求められず、日常的な巡視の中で目視レベルで判別可能な砂州堆積や樹木繁茂の進行を記録している。これらの目視レベルでの記録と同等の判別を行うために Semantic Segmentation モデルで求める領域分類の要件として以下を設定した。

- 低水路は砂州と水面の境界を正確に捉える
- 高水敷は樹木と草地を分けて把握する
- モデルの精度低下を防ぐため上記以外の微小な領域は分類しない

以上の方針に従い、本研究ではセグメンテーションの対象と色見本を表-2の5クラスとした。

表-2 セグメンテーションクラスとアノテーションの色

名称	色見本
低水路水面	
低水路砂州・高水敷裸地	
高水敷樹木	
高水敷草地・裸地	
道路・橋梁・護岸	

クラス定義に従って、200枚の全画像に対して目視によってアノテーションを実施した。アノテーション結果の例を図-3に示す。左から、空撮画像、アノテーション結果、空撮画像とアノテーション結果の重ね合わせである。図の上段は撮影高度 50m、中段は 100m、下段は 150m のものである。また、各クラスの出現頻度を撮影高度別に図-4に示す。空撮画像の全画素のうち、アノテーションによって各クラスと判定された画素の占める割合を示したものである。水面、道路のクラスは画像全体に占める割合が他の3クラスに比べて小さい。砂洲のクラスの割合は、撮影高度が 100m、150m の画像では 30% を超えているが、高度 50m の画像ではそれに比べて割合が小さく、約 23% である。

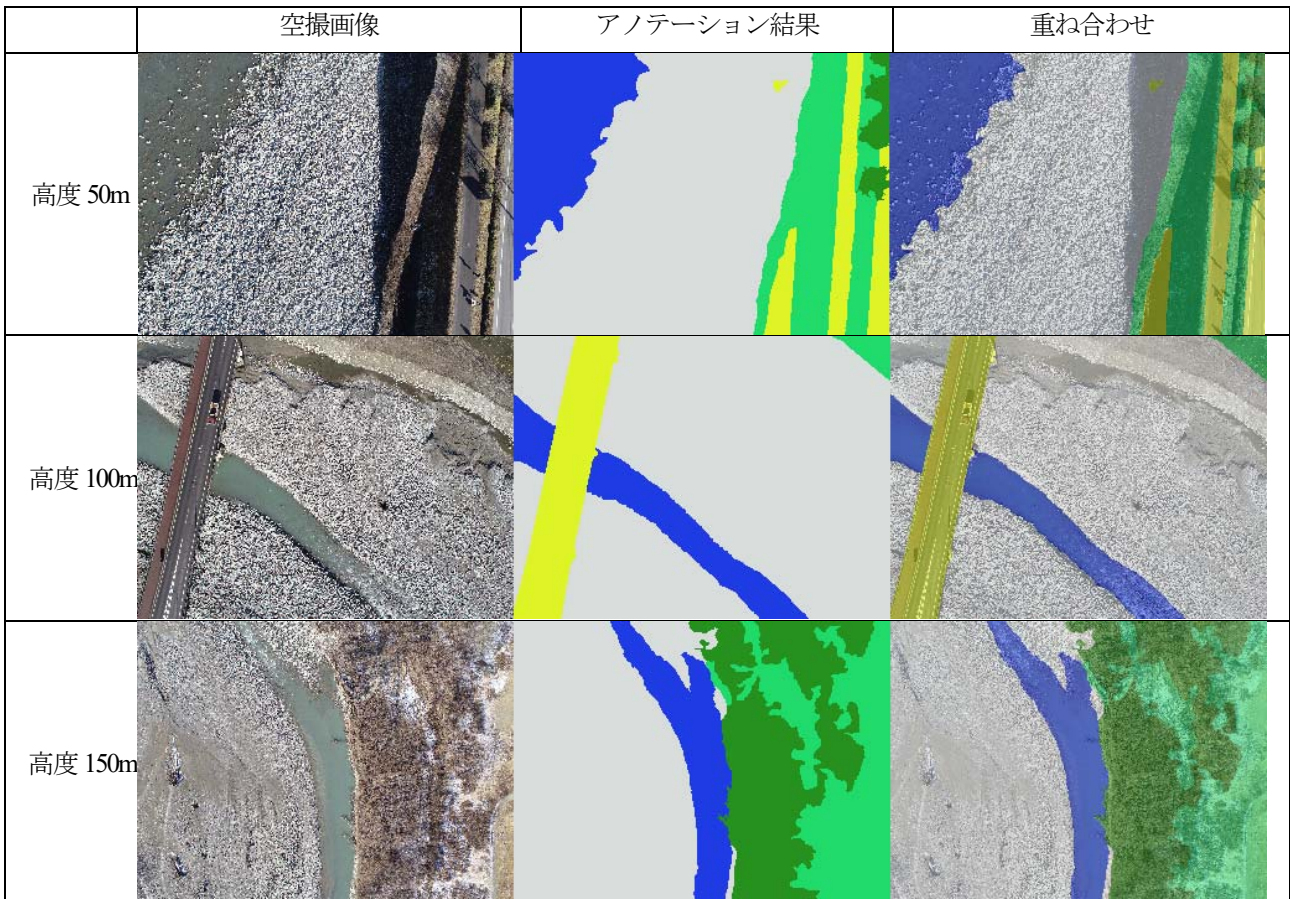


図-3 アノテーション結果の例




図4 空撮画像中に占める各クラスの割合

c) データ分割

200枚の画像を140枚、30枚、30枚にランダムに3分割し、140枚をモデルの学習用、30枚を学習中のバリデーション用、30枚をテスト用として用いた。データ分割の際には、撮影高度で層化し、各高度の画像が学習用、バリデーション用、テスト用に均等に分かれるようにした。なお、バリデーションデータは過学習を含むために学習の過程で損失を算出する用途で、テスト用データは学習済みのモデルの精度を評価する用途で利用した。

画像200枚の撮影高度の内訳と、データ分割の結果を表3に示す。

表3 データ分割の結果

撮影高度	学習用	バリデーション用	テスト用	合計
50m	75枚	16枚	16枚	107枚
100m	34枚	8枚	7枚	49枚
150m	31枚	6枚	7枚	44枚
合計	140枚	30枚	30枚	200枚

(2) Semantic Segmentation モデルの作成

a) 使用モデル

Semantic Segmentation モデルは多くのバリエーションが提案されており、精度は年々向上している。本研究では2018年に提案され、高精度なセグメンテーションを実現した Deeplab-v3^[11]を採用した。モデルの選定理由は以下の通りである。

まず Deeplab-v3+ は本研究着手時点で Semantic Segmentation の各種ベンチマークデータセットで最も分類能力の高いモデルの一つであった。また Deeplab-v3+ は Spatial Pyramid Pooling と呼ばれる、異なる大きさの受容野をもつ畳み込み層を並列に配置する構造の採用により、画像内の広い範囲の情報から局所的な情報まで多様な情報を抽出することを可能にしている。これにより撮影高度が異なる空撮画像にも汎用的に適用することが期待できる。さらに、ネットワーク全体を Encoder-Decoder 構造とすることによって、物体の境界をはっきりと推論でき

るようにしている。したがって本研究での要件である砂州・樹木の境界を正確に捉えることが期待できる。

b) 学習設定

モデルの実装、学習は深層学習フレームワーク Tensorflow を用い、著者らが公開しているものを用いた。基盤のネットワーク構造は Xception を用い、Pascal VOC 2012 データセット (20 クラス, 11530 枚) での事前学習済みモデルを用いて転移学習を行った。

モデル学習時の設定を表4にまとめる。

表4 データ分割の結果

損失関数(ロス)	カテゴリカルクロスエントロピー
最適化手法	SGDM
バッチサイズ	15
学習回数	20,000回
モメンタム	0.9
学習率	初期値は0.0001とし以下の式によって徐々に減少させた $0.0001 \times (1 - (\text{step}/20000))^{0.9}$
データ拡張	学習ステップごとに各画像を0.5倍~2倍のランダムな倍率で拡大・縮小し、500px×500pxのサイズにランダムにクロップ

c) 学習結果

学習中の損失の推移を図5に示す。学習データの損失は、学習時に使用した 500px×500px のパッチに対して計算している。バリデーションデータの損失は、元画像のサイズが大きいため、縦3分割×横4分割の12分割してから推論を行った結果を用いて算出した。

学習回数 20,000 回時点で損失はほぼ収束傾向にあるが、20,000 回までバリデーションデータの損失が緩やかに減少を続けているため、20,000 回時点の学習結果を本研究での河道の領域分類モデルとして採用することとした。

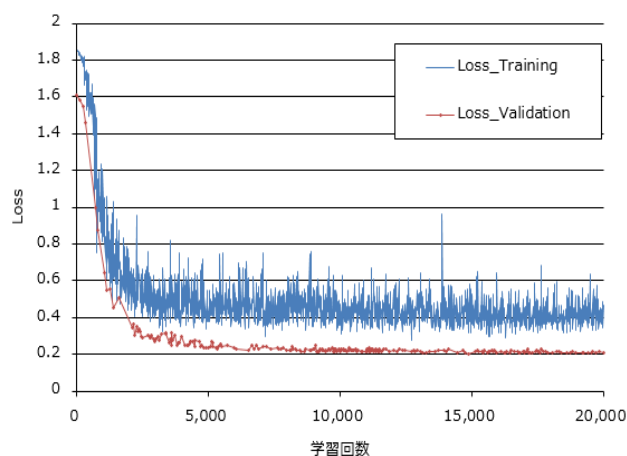


図5 学習曲線

d) 精度評価

セグメンテーション推論の精度評価を IoU (Intersection over Union, ピクセルの一致率を示す指標)を用いて行った。精度評価のための推論は、上述のとおり元の画像を12分割してから行った。クラス別に IoU を算出した結果を図-6 に示す。すべてのクラスでテストデータでの IoU が 0.8 を超える精度を得ることができた。




図-6 セグメンテーション推論のIoUによる評価結果

また定性的な評価を行うため、学習で用いていないテストデータに対する推論結果を目視で確認した。テストデータの推論結果の例を図-7 に示す。全般的には良好な分類結果が得られているが、以下の2点でアノテーション画像と推論結果で差異が見受けられた。

まず、本研究で用いた空撮画像が冬時期に撮影した画像のため、樹木が落葉しており地表面が映っていることから、樹木と草地の境界の形状が入り組んでおり、アノテーション画像と推論結果で差異が見受けられた。ただしそれらは人による目視でも迷う箇所であり、推論結果があながち間違いではないと考えられる。

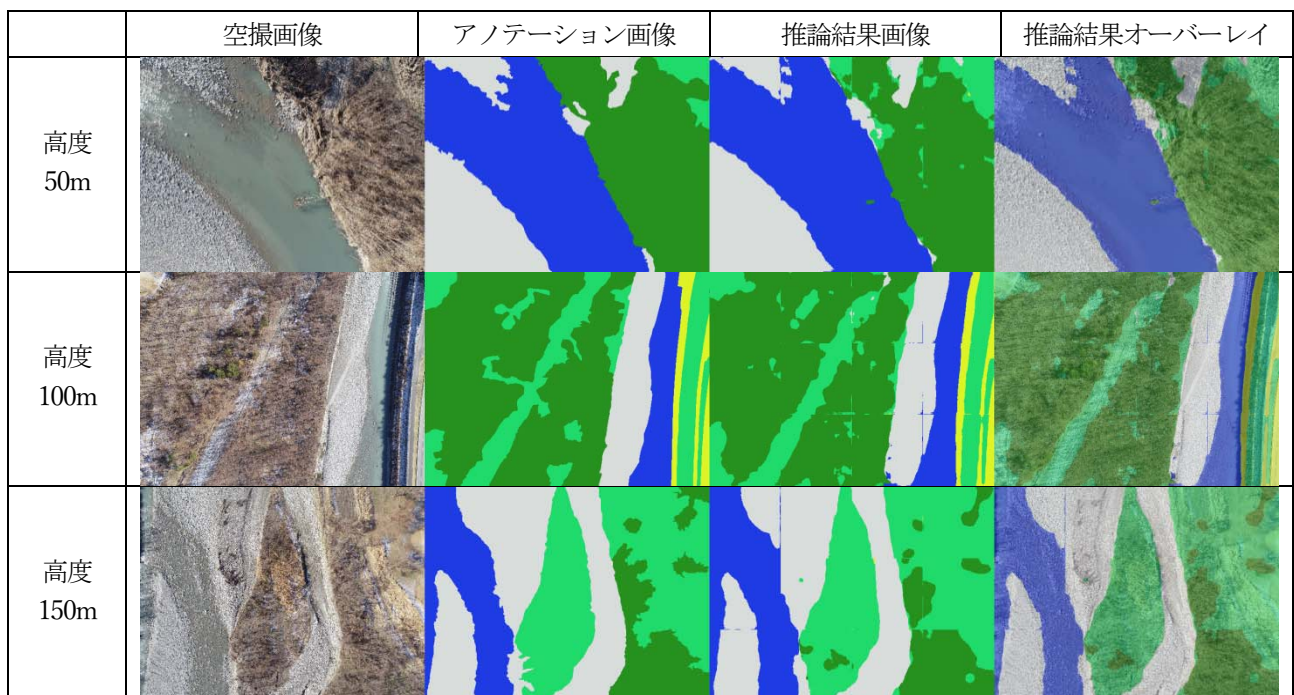


図-7 テストデータでの推論結果

また、テストデータは12分割して推論を行った後に結合を行っているため、分割の切れ目や境界付近で不連続な分類結果となる場合があり、アノテーションデータとの差異が発生する。しかしその領域は微細であるため問題ないと考え、本研究ではそのまま12分割する手法を採用することとした。

5. オルソ画像への適用実験

河川巡視における河道の状況把握に上記の深層学習モデルを適用できることを検証するため、三峰川のオルソ画像を利用して領域分類および各領域の定量評価の実験を行った。

(1) 使用データ

撮影した個別の空撮画像 559 枚をもとに、連続した河道の3次元形状を SfM 解析により再現した。なお、SfM 解析に用いた画像には深層学習モデルに用いた空撮画像 200 枚も含まれる。

作成した河道の3次元モデルを地表面に対して正射変換を行い、オルソ画像を作成した。地表の色や粒度などの特徴量は SfM 解析前の個別画像と類似しているため、Semantic Segmentation モデルの入力データとして利用可能であり、領域分類結果に固定尺度を与えることが可能である。図-8 にオルソ画像を示す。

なお本研究での実験では用いていないが、3次元モデルの標高値を画像化した DSM 画像も併せて作成している。DSM 画像はオルソ画像と同じ GSD で作成することにより、オルソ画像で分類した領域(面積)を体積に換算することが可能となる。図-9 に DSM 画像を示す。



図-8 オルソ画像




図-9 DSM画像

(2) 実験用画像セットの作成

オルソ画像に対する領域分類精度を確認するため、Ground Truth となるアノテーション画像と同じ画角でオルソ画像を切り出した。ただし空撮画像は UAV の揺らぎにより完全に真下を向けて撮影したものでなく、レンズの歪みも含んでいることから画角を完全にそろえることは不可能である。したがって目視によりアノテーション画像と画角をおおむねそろえた上でオルソ画像の切り出しを行った。

比較対象の Ground Truth は学習に用いていない各高度の代表画像 1 枚を選定し、その元画像とほぼ同じ画角となるオルソ画像を、高度の違いや砂州や樹木の大きさなどによる映りの違いに対する頑健性を確認するため、GSD を変えて 3 枚出力した。オルソ画像の GSD は砂州等の面積や体積換算に利用することを想定し、切りの良い 2/5/10cm/px とした。以上の処理により表-5 の実験用画像セットを用意した。

表-5 実験用画像の GSD [cm/px]

撮影高度	Ground Truth	領域分類 実験用画像			
		元画像	オルソ画像		
50m	1.37	1.37	2.00	5.00	10.00
100m	2.74	2.74	2.00	5.00	10.00
150m	4.11	4.11	2.00	5.00	10.00

(3) 領域分類の実験

上記で作成した 12 枚の画像セットに対して Semantic Segmentation モデルでの領域分類の推論を行った。

推論結果の比較は、先述の理由により画角は完全には一致しないため、IoU の算定はできないことから、各画像内の 5 クラスの面積割合での評価を行った。各高度の画像の領域分類結果を図-10 に示す。

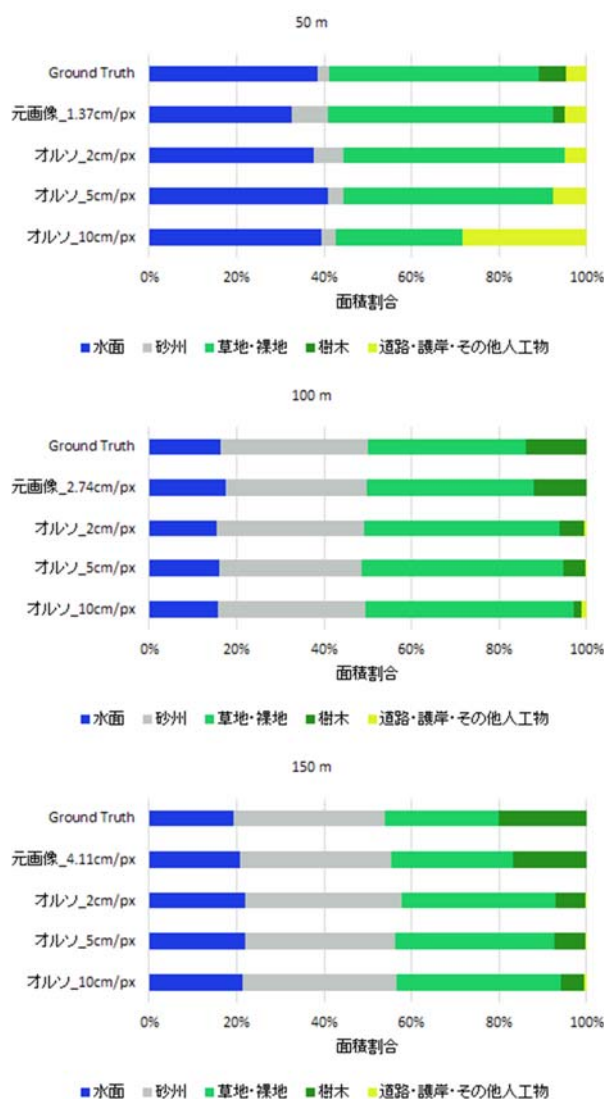


図-10 領域分類 実験結果

(4) 考察

a) 高度による違い

領域分類結果を見ると、高度 50m の場合が他の高度と比べて Ground Truth と実験用画像の推論結果の誤差が大きいことがわかる。実際の推論結果を図-11 に示す。オルソ画像だけでなく元画像でも同じ傾向であることから、SfM の影響だけでなく高度の影響があると考えられる。

高度 50m の画像は 100m・150m の画像に比べて高精細で 1 枚に映る範囲が狭い。そのため教師データの枚数も表-3 に示したように 50m のものが一番多いが、その分個別の画像で評価すると 1 枚 1 枚のばらつきが出やすい。

また SfM の影響も見受けられた。高度 50m の画像は特に元画像が高精細なため、水の分布範囲や樹木の繁茂状況の Ground Truth が精緻に行われているのに対し、SfM 画像は処理の特性上、樹木の枝などは十分に再現できないため若干ぼやけた画像となる。それゆえ高度 50m では Ground Truth とオルソ画像の誤差が顕著になると考えた。

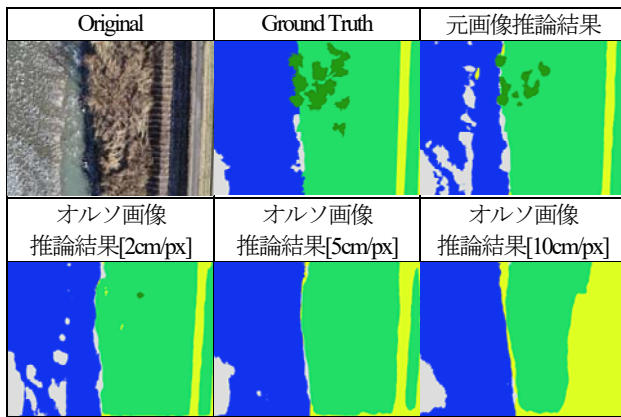


図-10 高度 50mの実験結果画像

b) オルソ画像の GSD による違い

各高度に対応した3つのオルソ画像については GSD が異なるだけで画像の範囲や色味は同じため、深層学習モデルがスケールに対する頑健性を十分に持っていれば、推論結果の面積割合はほぼ同じになることが期待される。

しかし高度 50m の場合の「道路・護岸・その他人工物」の面積割合が 10cm/px の画像だけ大きく異なる。深層学習モデルはデータ依存のため数理的な根拠は不明だが、下記の原因が考えられる。

- A) 教師データの GSD は 1.37~4.11cm/px であり、10cm/px は教師データから大きくスケールが異なる(約 2.5 倍の画像の粗さ)
- B) 「道路・護岸・その他人工物」クラスは他の4クラスに含まれない領域をまとめて1クラスとしているため、特徴量のばらつきが大きいこと
- C) 上記 2 つの理由が重なり、DeepLab-v3+ の Spatial Pyramid Pooling でもスケールの違いを吸収できなかったと考えられる

一方、高度 100m と 150m では全体的には GSD による差が小さいものの、「草地・裸地」と「樹木」の割合は 10cm/px の場合だけ若干異なる。これも上記 A) の教師データとのスケールの違いが理由と考えられる。

ただし今回実験に用いた画像は冬に撮影したため「草地・裸地」と「樹木」の境界が人による目視でも迷うものであった。そのため Ground Truth の精度にもばらつきがあったと考えられる。水面と砂州の領域分類結果は安定していることを見ると、領域ごとの特徴量が明瞭で Ground Truth の分類精度が高い場合は、今回のように教師データの GSD より 2.5 倍程度粗い画像で領域分類を行っても問題にならないことが示唆される。

6. おわりに

本研究では河川巡視業務への適用を念頭に、複数の河川に汎用的に適用できるスケールの異なる空撮画像に対

する河道の領域分類手法を提案した。提案手法は大きく「(1)河道領域分類モデルの学習」と「(2)河道領域分類モデルの推論」の2つの手順から構成される。本研究では各手順について以下の知見が得られた。

(1) 河道領域分類モデルの学習

深層学習による画像認識手法の一つである Semantic Segmentation を適用し、撮影高度の異なる教師画像を混合して学習を行い河道領域を 5 クラスに分類するモデルを構築した。Semantic Segmentation モデルのネットワークには Deeplab-v3+ を採用し、撮影高度に依らずすべてのクラスで IoU が 0.8 を超える精度の河道領域分類モデルを得ることができた。

(2) 河道領域分類モデルの推論

河川巡視業務での実用を考慮し、砂州や樹木の領域をピクセル数ではなく面積や高さで把握するために GSD を固定したオルソ画像で河道領域分類を行う実験を行った。本研究で学習した河道領域分類モデルは、教師データと GSD が異なるオルソ画像に対しても領域分類が行えることを示した。

分類精度は比較対象の Ground Truth の高度やクラスにより異なるが、領域の境界が明瞭で Ground Truth の分類精度が高い場合は、教師データの GSD より 2.5 倍程度粗い画像でも領域分類が精度よく行えることが示唆された。

(3) 今後の課題

本研究では複数河川で汎用的に適用できる手法を提案し、三峰川の空撮画像を用いて実証を行ったが、本手法の妥当性を確認するためには他の河川でも実証を行う必要がある。また GSD の違いについても、どの程度のスケールの違いまで吸収できるかはデータ依存のため、今後事例を増やして検証が必要である。

本手法を河川巡視業務に適用する場合は、領域分類だけでは実用上は不十分であり、領域分類結果から河川巡視で記録すべき「河岸の状況」「砂州堆積の状況」「樹木群の生育状況」などを抽出する必要がある。そのためには日常的に空撮を行い、河岸の移動、砂州領域の拡大・縮小や樹木繁茂状況の経時変化を自動的に抽出することが求められる。

このように河川維持管理業務の効率化・高度化を達成するには、深層学習技術だけでなく既存の技術やデータを組み合わせることが課題である。加えて AI の活用を前提とした業務フローの最適化なしには効率化・高度化の効果も限られる。

労働力不足は正に目前の問題である。本研究で提案した手法を実用化した上で業務フローに組み込み、河川維持管理業務全体の最適化を図ることが喫緊の課題である。

謝辞：本研究は国土交通省の革新的河川技術開発の一環として実施したものです。国土交通省水管理・国土保全局、および中部地方整備局にはプロジェクト全般でのサポートとフィールドの提供で多大なご協力を頂きました。ここに感謝の意を表します。

参考文献

- 1) 国土交通省：河川砂防技術基準 維持管理編（河川編），2015.
- 2) He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. : Deep residual learning for image recognition., In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), pp. 770-778, 2016.
- 3) 国土交通省：UAV を用いた公共測量マニュアル（案），2017.
- 4) Tomasi, C. and Kanade, T. : Shape and motion from image streams under orthography:a factorization method, Int'l.J.Computer Vision, 9(2), pp.137-154, 1992.
- 5) 近津博文, 小高明彦, 柳秀治, 横山大 : UAV 写真測量における三次元モデリングソフトウェアの性能評価, 写真測量とリモートセンシング, 日本写真測量学会, Vol.55, No.2, pp. 117-127, 2016.
- 6) 渡辺豊, 河原能久 : UAV を利用した空中写真の河川地形計測への適用性, 土木学会論文集 B1 (水工学), 土木学会, Vol.72, No.4, pp. I_1105-I_1110, 2016.
- 7) 須藤純一 : 航空写真と航空機 LiDAR を用いた密集市街地の建物境界線の自動抽出, 土木学会論文集 F3 (土木情報学), 土木学会, Vol.70, No.2, pp. I_123-I_132, 2014.
- 8) 岡谷貴之 : 画像認識のための深層学習の研究動向, 人工知能, 人工知能学会, Vol.31, No.2, pp. 169-179, 2016.
- 9) 藤吉弘亘, 山下義隆 : 深層学習による画像認識, 日本ロボット学会誌, 日本ロボット学会, Vol.35, No.3, pp. 180-185, 2017.
- 10) Long, J., Shelhamer, E., & Darrell, T. : Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), 2015.
- 11) DeepGlobe CVPR 2018 - Satellite Challenge, <http://deepglobe.org>.
- 12) Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. : Encoder-decoder with atrous separable convolution for semantic image segmentation, Proceedings of the European conference on computer vision (ECCV), pp. 801-818, 2018.

(Received June 30, 2020)

(Accepted July 31, 2020)

STUDY ON RIVER MANAGEMENT METHOD USING UAV PHOTOGRAMMETRY AND DEEP LEARNING

Junichiro FUJII, Ryuto YOSHIDA, Masazumi AMAKATA and Takayoshi YAMASHITA

Japan has many rivers in its land, and many river maintenance operations such as inspections and patrols are performed by visual inspection. Especially in frequent river patrols, personnel record anomalies and grasp the condition of river channels on site, while some of them can be made more efficient by combining UAV photogrammetry and image recognition by deep learning. In this study, we propose a method to classify regions such as sandbars and trees in river channels by applying Semantic Segmentation, which is one of the image recognition methods by deep learning, to ortho images obtained by UAV photogrammetry. The deep learning model was trained using aerial images with different shooting altitudes, and a highly accurate river region classification model could be obtained. We conducted an experiment to apply the model to ortho images with different ground sampling distance (GSD), and confirmed that general region classification can be performed even for ortho images with different GSD from training data.