

画像判別技術を用いた水中河床材料の粒径評価

宮崎大学工学部
宮崎大学工学部

学生会員
正会員

新垣俊介
○入江光輝

1. はじめに

河床材料は水生昆虫や魚類のハビタットとして多面的な環境機能を果たすとともに、その粒径は出水時の掃流力を反映している。したがって、河床材料粒径の広域分布の把握が治水及び環境の観点から求められる。

河床材料調査の手法として一般的な面積格子法・線格子法・容積法などのフィールド法はふるい分けや粒径の直接計測に多くの労力と時間が必要で広範囲・高密度の調査は困難である。また、限られた面積のコドラート内のサンプリングで、空間代表性も問題となる。

近年、無人航空機(Unmanned Aerial Vehicle:以下、UAV)での空撮が注目を集め、災害調査や河川管理にも汎用されている。一方、画像解析や判別技術の発達は目覚ましく、ものづくりや医学など様々な分野で応用されている。そこで本研究では、UAVから広範囲の河床材料を撮影し量み込みニューラルネットワーク(Convolutional Neural Network:以下、CNN)を用いて粒径区分別にそれらの写真を分類¹⁾することを試みた。いくつかの既往の研究では各画像内に見られる礫や石を個々に抽出し、画面上で径を計測、粒度分布を得るまでを自動化した例²⁾が見られるが、本研究では実際の河川管理で必要な情報はそこまで精緻ではなく、より簡便に分類することが重要と考え、代表粒径のみを判別することを目指している。

2. 調査・解析手法

(1) 現地調査

現地調査は土砂移動が比較的大きい耳川水系西郷ダム下流の2つの領域を対象とした。2019~2021年にかけて両領域で計108地点(うち陸上部76地点、河床の見える浅い水中部32地点)で容積法により粒度分布を実測した。

河床においた0.5m×0.5mのコドラート内の河床材料をサンプリングし、現場でふるい分けを行って質量もその場で計測した。水中から採取した試料はその場で湿潤重量を計測するとともに、一部を研究室に持ち帰り、含水率を求めて(JIS A 1203)現場質量から水の質量を差し引いた。得られた粒度分布から中央粒径を求め、それを同地点の代表粒径とした。代表粒径の値に基づいて表-1に示す範囲で画像を各クラスに分類した。

空撮にはDJI社製Phantom 4 pro V2.0を使用した。前述の容積法のサンプリングで河床を攪乱する前に、コドラートを配置した地点が中央になるように10mの高さでホバリングして撮影を行った。その画像中央の1m×1mの



図-1 調査サイト

領域を画像判別の対象として抽出した。ただし、後述のCNNによる画像判別では、学習およびテストデータに河床の代表粒径が既知の画像データとして大量に必要となるため、画像中央の周辺についても1mメッシュで切りだし、陸上の画像についてはBASEGRAIN³⁾を用いて中央画像との粒度分布の類似性を確認した上でテストデータに追加した。水中の画像については目視で類似性を判断し、中央画像と同じ傾向があると思われる画像について中央と同じクラスとして分類し、学習データに加えた。

(2) CNNについて

本研究ではCNNにより画像判別を行うが、一からネットワークをチューニングするのではなく、既存のネットワークに判別を目指す画像を追加学習させる転移学習により判別精度を向上させた。精度の高い既存のネットワークはいくつか挙げられるがこれまでの実績⁴⁾からGoogLeNet⁵⁾に転移学習を施した。以下では判別精度を評価するためのテストデータを固定する一方、判別の際のカテゴリー数および学習データの多様性を変化させた場合に判別精度がいかに変化するかに着目しながら試行を繰り返した。

3. 結果と考察

(1) カテゴリー数について

既往の研究³⁾では陸上の材料を対象として3粒径域に分けて学習と分類を行い、95%以上の判別精度が得られた⁶⁾。本研究では水中の画像を含めるが、まずその陸上の試料のみで学習させたネットワークに水中の画像を判別させた。その結果、水中の画像を多く誤判別し、

表-1 分類基準と取得したデータ数

分類 粒径範囲(mm)	中礫 64~24.5	小礫・細礫 24.5~2	極粗砂・粗礫 2~
陸上	13	54	9
水中	10	12	10

表-2 CNNによる画像判別結果

分類数	3分類	6分類	5分類
判別精度	73.0%	51.3%	85.5%

その精度は大きく低下した(表-2の3分類). そこで, 粒径域3種×(陸上/水中2種)の計6種類としてネットワークに学習させて分類を試みたが, 精度はさらに大きく低下した. 特に一様に細粒分が広がる画像は水中であっても陸上であっても影がなく, 水の青色なども現れず目視での印象でも両者に大きな差が見られなかった. 他方, 粗粒分の場合には影の印象や水によって石表面が青みがかった印象を受けた. したがって, 類似性の高い細粒分の水中と陸上の画像を過度に分類しようとしてエラーが生じた可能性が高い.

次に細粒分(2mm以下)のみについてはあえて陸上か水中かは分類せず, 共通のカテゴリーとした(表-2の5分類). その結果, 3つの試行の中では最も高い分類精度を示した. これ以降の試行では中礫の陸上/水中, 小礫・細礫の陸上/水中, 極粗砂・細礫以下の5種類に分類することを目指し, CNNの学習とテストを行う.

(2) 水面波の多様性を考慮した学習データと精度

CNNは画像中に含まれる特徴的なパターンを抽出してその類似性から画像判別を行っている. 水中にある河床材料の画像の場合, 水面の波で作られているパターンと河床材料のパターンの重ね合わせで1枚の画像が構成されている. したがって, 水面の波は無視し, 河床材料によって作られるパターンのみに着目して分類されることが望まれる.

本研究ではCNNの学習データの与え方によって精度向上が図れるかを検討した. 河床材料の粒径は同種であるが, 水面の波の特性や強弱が異なる画像を学習に含めるか否か, 学習データを変更したCNNを複数準備した. それらを使用して同一の画像群の判別をテストし精度を比較した. 学習データから水面に波が含まれる画像を除いて学習させたCNNを基準とし, 初めに図-2左の①の細かい網目状の波を含む画像のみを追加した. 次に, それに加えて図-2の②のような波の弱い横波の画像を学習に追加, 最後に①、②に加えて瀬のような状態で波が立った画像を学習に追加し分類を行った.

その結果, 図-3に示すように波の種類を増やすほど判別精度の向上が見られた. しかし, ①+②+③で学習させた場合において誤判別された画像を見ると, 追加された③のパターンが多く誤判別されていた. 特に③は波というより底床の凹凸に依存した水面状態でランダム性が高く, 判別が難しかったものと考えられる. したがって学習データの枚数をさらに増やして多様な学習をさせることで改善される可能性がある.



図-2 学習に加えた波のパターン




図-3 CNNによる画像判別結果

4. おわりに

本研究では水中及び陸上にある河床材料をUAVから空撮し, CNNによる画像判別で粒径評価を試みた. 水中の河床材料の画像を学習データに含むことによって判別精度が向上することが確認でき, 細粒分以外は水中と陸上の画像を別カテゴリーとしたほうが精度よく分類できた. さらに, 水中にある材料の写真には水面にできる波が含まれるが, 学習の際にその波のパターンを多様に学習させたほうが精度が向上することが確認できた. ただし, 瀬のような水面の状態が一定のパターンを取らない場合に誤判別が生じやすかった.

今後河床材料調査の地点数を増やすことで様々な波のパターンを学習し適用できる範囲を増加させるとともに, 天候やカメラの設定が判別精度に及ぼす影響等について検討を行う予定である.

参考文献

- 1) 内田祐介, 山下隆義: 畳み込みニューラルネットワークの研究動向, 電子情報通信学会信学技報, PRMU2017-105, 2017
- 2) Detert, M., Weitbrecht, V.: User guide to gravelometric image analysis by BASEGRAIN, Advances in River Sediment Research, Fukuoka et al.(eds), pp.1789-1796, 2013.
- 3) Takechi, H.; Aragaki, S.; Irie, M.: Differentiation of River Sediments Fractions in UAV Aerial Images by Convolution Neural Network. Remote Sens., 13, 318, 2021