

AI 画像解析による水位・流砂量の推定手法の検討

国土交通省 中部地方整備局 天竜川上流河川事務所 吉田桂治^{*1}, 岡本明^{*2}, 小澤朋晃, 室井亮人^{*3}
株式会社建設技術研究所 ○近藤圭悟, 井内拓馬, 家田泰弘, 清野真義, 中西宏彰
株式会社コルバック 吉村暢也, 遠藤哲雄

^{*1} 現 一般財団法人砂防フロンティア整備推進機構 ^{*2} 現 長野県 駒ヶ根市 ^{*3} 現 浜松河川国道事務所

1. 背景と目的

天竜川上流域では活発な土砂生産により、流砂観測設備の損傷が頻発しており、その維持に多くの費用を要している。流砂観測を継続するためには、低コストで維持可能な観測手法を確立することが特に重要である。

これまでに代替手法として、画像から水位・流砂量を推定するAI解析手法が検討されている¹⁾。既往検討では、水位や流砂量の推定について一定の精度が得られていたが、「流砂量=ウォッシュロード量+掃流砂量」としており、流砂量の内訳については評価されていなかった。既往検討以降、流砂量の内訳について検討を行ってきたが、掃流砂量の推定精度については低いままであった。一般的にウォッシュロード量は掃流砂量に比べて数オーダー大きく全流砂量に占める割合が高い。既往検討において流砂量の推定精度が高かったのは、ウォッシュロード量の推定精度が高かったためと考えられる。

そこで本研究では、AI画像解析による水位、ウォッシュロード成分、掃流砂成分の精度向上を目的として検討を行った。本稿では、与田切川地点を対象に検討した結果を報告する(図1)。



図1 与田切川地点におけるCCTVカメラ画像および流砂水文観測値

2. 手法

2.1 推定対象量の整理

既往検討では、流砂量のうちウォッシュロード成分についてウォッシュロード量(=ウォッシュロード濃度×流量)を推定対象としていた¹⁾。しかし、流量は水位-流量関係式から算出しており、別途推定対象としている水位を内在している。また、CCTVカメラ画像として視認可能であり、濁度計で計測されるのは、主に濁水の明暗や色調に対応するウォッシュロードの濃度である。以上より、本研究では、量ではなく濃度を推定対象とし、水位は独立した推定対象として扱うこととした。以上より、本検討では水位、ウォッシュロード濃度、掃流砂量をそれぞれ推定対象量とした。

2.2 使用データと前処理

CCTVカメラ画像(10分間隔)と、同地点の水位・ウォッシュロード濃度(濁度計)・掃流砂量(ハイドロフォン)の観測値(1分間隔)を用い、撮影時刻に対応する観測値を抽出して時刻整合した画像-観測値ペアを作成した。撮影欠損や観測欠損は無効として除外し、雨滴付着、強い反射、夜間の極端な黒つぶれ等、推定を不安定化させる「例外画像」は学習データから除外した。

2.3 推定対象出水の選定(中規模出水)

推定精度の評価にあたっては、出水時における各推定対象の変動傾向とピーク値の再現性を評価した。こ

こで出水は、「水位が所定の閾値以上(与田切川地点の場合0.4m)となる時間を基準に、その前後24時間を含む期間」とした(図2)。さらに、本検討では学習データの頻度が比較的高い規模に対して再現性を評価するため、以下により推定対象出水を設定した。1)各出水で目的変数毎の最大値を整理し中央値を算出。2)目的変数毎に中央値規模を観測した出水を推定対象出水とした。これにより、極端な小規模・大規模出水ではなく、実運用で想定される代表的な出水規模における検討となった。




図2 出水の定義

2.4 AI解析モデルと学習方法

基本モデルは画像のみを入力とする畳み込みニューラルネットワーク(CNN)とし、水位・ウォッシュロード濃度・掃流砂量をそれぞれ推定した(図3上段)。ウォッシュロード濃度・掃流砂量は値のスケールが小さく学習が進みにくい可能性があるため、入力(目的変数)をスケールアップ(例:ウォッシュロード濃度は1,000倍、掃流砂量は100倍のオーダー調整による学習安定化)した条件も比較した。

掃流砂量については、画像のみでは推定精度が低い要因として「掃流砂は底面付近を移動するため画像から掃流砂量の多少の判読が困難」であることと推察した。また、掃流砂量は掃流力に依存し掃流力は水深と勾配で決まる物理量であることを踏まえ、水深を補助特徴として組み込む手法を考案した。そこで、画像特徴(CNN)に加え、水位を説明変数として結合するマルチモーダル手法を導入した(図3中段)。さらに、単一時点水位は推定が水位変動に過度に依存しうするため、水位の履歴(上昇-下降の経路)を表現できるよう、時系列畳み込みネットワーク(TCN)で表現して結合するCNN+TCN構成を検討した(図3下段)。

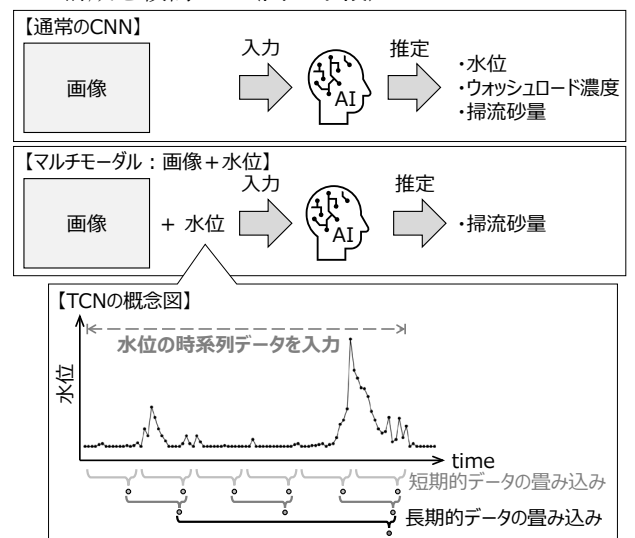


図3 AI解析による水位・流砂量等の推定イメージ

3. 結果と考察

3.1 水位推定

水位は、比較的高精度に推定可能であった。夜間の推定精度が低い傾向はあるが、学習対象を全期間とした条件が最も高い精度を示した(図4)。

3.2 ウォッシュロード濃度推定

ウォッシュロード濃度も一定の精度で推定可能であった。夜間の推定精度が低い傾向はあるが、学習対象を全期間とした条件が最も高い精度を示した。また、スケールリング適用(×1,000)により、全体的に推定値のバラつきが抑えられ、推定精度が向上した(図5)。

3.3 掃流砂量推定(画像のみ: CNN)

掃流砂量は、画像のみ(CNN)では改善の余地が大きい。学習対象を全期間とした条件が最も高い精度を示したが、水位およびウォッシュロード濃度と比べると全体として精度は低い。

3.4 掃流砂量推定(マルチモーダル)

画像+単一時点水位のマルチモーダル構成では、水位変動に推定が過度に依存し、高水位でも掃流砂量が小さい場合に過大推定となる傾向が確認された。また、低水位時の推定精度低下や、ピーク後に過大推定となる出水がみられた。

これに対し、画像+時系列水位(CNN+TCN)構成では、水位の時間的経路(上昇局面か下降局面か等)を特徴として学習できるため、ピーク付近の推定精度が向上し、推定のブレが少なくなる傾向が確認された。時系列長は長いほどピーク付近が安定化する一方、運用上のバランスも踏まえると、例えば36点(6時間)の系列長が最適条件の一つと考えられた。(図6)

3.5 総括(推定量別の最適方針)

推定量別に最も高い推定精度が得られた解析条件を表1に整理した。水位およびウォッシュロード濃度については、画像情報のみでも一定の精度で推定可能であり、学習対象を出水期間に限定することが有効であった。

一方、掃流砂量の推定では、画像単独ではピーク再現性に課題が残ることが確認された。これに対し、水位情報を補助特徴として組み込み、さらに時系列情報として与える(CNN+TCN)ことで、水位変動の経路を考慮した推定が可能となり、ピーク付近の再現性が改善した。

以上より、掃流砂量推定においては画像情報に加えて水位情報を適切に組み合わせる解析条件が有効であることが示され、非接触型観測への適用に向けた具体的な解析手法を整理することができた。

4. 今後の展開

夜間画像は、水位・ウォッシュロード濃度・掃流砂量のいずれにおいても日中より推定精度が低い傾向が確認されており、照度不足等の夜間特有の課題への対応が必要である。今後は、夜間出水時画像を含む学習データの拡充、画像品質確保のための撮影条件の改善、夜間画像に対する補正・前処理の導入を通じて、夜間推定の安定化を検討する。また、掃流砂量推定では水位情報の寄与が大きいことから、運用上は水位計観測値を基本としつつ、目的に応じて推定水位の活用も選択肢となりうる。非接触化によるLCC低減を図るためには、観測初期段階からAI解析に適した画像取得条件を考慮した観測体制の設計が重要である。

参考文献 1) 佐藤ら, 天竜川上流域における流砂量モニタリングについて, 砂防学会誌, Vol.78, No.1, p.35-40, 2022.




図4 水位の推定結果の例

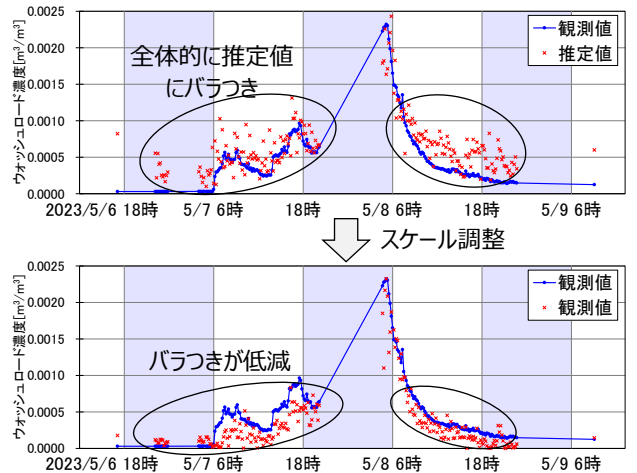


図5 ウォッシュロード濃度の推定結果の例

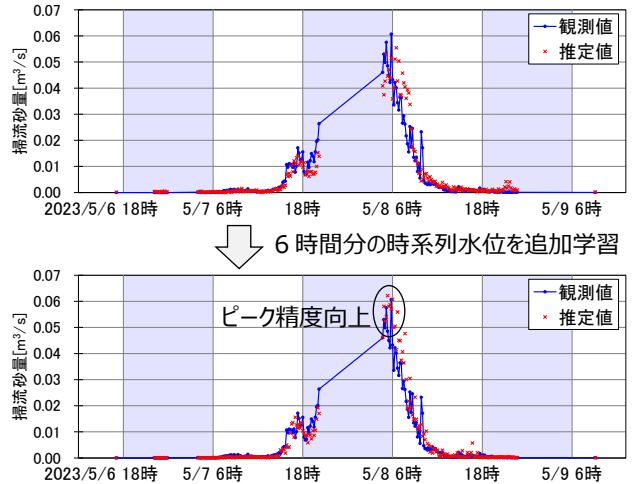


図6 掃流砂量の推定結果の例

表1 推定量別最適手法整理

項目	水位	ウォッシュロード濃度	掃流砂量
学習対象期間	全期間	全期間	全期間
スケールリング	不要	1,000倍を適用	100倍を適用
採用モデル	画像のみ(CNN)	画像のみ(CNN)	画像+水位の時系列(CNN+TCN, 36点=6時間)