

# 画像認識によるロックフィルダム堤体点検の実用化に向けた一考察

## Study on Practical Application of Image Recognition for Rockfill Dam Embankment Inspection

藤井 純一郎\*<sup>1</sup>  
Junichiro Fujii

都築 幸乃\*<sup>1</sup>  
Yukino Tsuzuki

平嶋 智希\*<sup>1</sup>  
Satoki Hirashima

栗飯原 稔\*<sup>1</sup>  
Minoru Aihara

\*<sup>1</sup> 八千代エンジニアリング株式会社  
Yachiyo Engineering, Co., Ltd.

Rocks called ripraps are placed on the surface of rockfill dam embankments, and their inspection has been conducted by dam engineers through field surveys. The authors proposed an automatic detection method of weathered ripraps using deep learning object detection, enabling labor-saving inspection work and uniformity of inspection evaluation. In this study, a comparison was made between a case in which the proposed method was applied to the three weathering levels equivalent to the field survey, and a case in which the method was applied only to strong weathering, which has more distinct weathering characteristics and is important for dam management. Based on the results, a discussion of the practical application of the proposed method in dam management is presented, as well as future issues to be addressed.

### 1. はじめに

ロックフィルダムの堤体表面には内部のロック材を保護する目的で大きい岩塊であるリップラップ材が配置される。リップラップ材は乾湿繰り返しや凍結融解作用などにより風化が進行するため、その状況把握が必要となるが、現地調査による点検は作業量が膨大となる。また、ダム技術者による判断の個人差も課題となっている。そのため、多くのダムでは堤体全体の調査ではなく、観測対象のリップラップ材を少数抽出した上で定点観測[国土交通省 2013]を行っており、堤体全体の網羅的な調査を効率的に行うための手法が求められている。これに対し、著者ら[藤井 2022]はロックフィルダムの堤体点検の省力化および一律評価を目的として、UAV 自律飛行で取得した画像に対して深層学習による物体検出を適用する手法を提案したが、従来の現地調査を置き換えるには精度が不足していた。

本研究では、提案手法を現地調査と同等の 3 段階の風化区分に適用したケースと、より風化の特徴が明瞭でダム管理上も重要な強風化のみに適用したケースで比較を行った。その結果に基づき、提案手法をダム管理で実用化するための考察を加え、今後の課題について示す。

### 2. 既往研究と本研究

ロックフィルダムは巨大な構造物であり、堤体点検に要する膨大な作業量の問題から古くから画像を用いた記録が試みられてきた。[Robert 1996]は堤体を撮影した動画に対してエッジ検出により岩塊を分離し、リップラップ材の粒径分布を推定する手法を提案した。国内でも[小林 2008]は農業用ダムにおいて 1m 四方の調査地点の画像に対して、最尤推定法と最大事後確率を用いて二値化を行うことで岩塊を分離し、粒径分布を推定した。これらは堤体に近接した画像が撮影できる限られた範囲での適用に留まっている。また画像処理が RGB の画素値を直接的に用いているため、岩塊の色味や日照条件の違いに敏感という課題があった。また推定結果は画像内の粒径分布のため、個別のリップラップ材が劣化しているかは考慮していない。

一方で 2010 年代からは UAV が急速に普及し、ロックフィルダム堤体全体の高精細な画像が容易に取得できる技術的素地

が整った。[土江 2018]は UAV で撮影した画像を基に cm オーダーのオルソフォトを合成し、堤体全体のリップラップ材の岩種および劣化度を写真判読によりマッピングした。これにより劣化したリップラップ材の位置や分布を把握することが可能となった。ただし写真判読は画像処理ではなく目視により実施しているため、写真判読に要する作業量や個人の主観による判断の揺らぎに課題が残る。著者ら[藤井 2022]は UAV 空撮画像に深層学習による物体検出を適用することで、省力化および一律評価を実現したが、検出精度に課題が残っていた。

そこで、[藤井 2022]で提案された、ダム技術者による現地調査と同等の 3 段階の風化区分のリップラップ材を検出するモデルをベースとして、より風化の特徴が明瞭で、ダム管理上も重要な強風化のみを検出するモデルとの精度比較を行う。

### 3. 森吉山ダムでの実験

提案手法を秋田県の森吉山ダムにおいて適用した。森吉山ダムは 2012 年に竣工した中央コア型ロックフィルダムで、堤体高 89.9m、堤体長 786m と東北地方では最大規模のロックフィルダムである。豪雪地帯に位置し、厳しい自然環境にさらされるため、リップラップ材の風化が確認されている。これらは現時点でダム堤体の安全性に影響を及ぼすものではないが、風化の進行状況の把握が必要となっている。

#### 3.1 リップラップ調査内容

森吉山ダムではこれまで調査対象の 47 個のリップラップ材を定めて、毎年現地調査により定点観測を行っている。

従来の現地調査では、リップラップ材の風化状態は図 1 の新鮮を除く強風化/中風化/小風化の 3 段階に分類している。

#### 3.2 使用データ

本研究では堤体全体を UAV 自律飛行[石井 2020]で空撮し、SfM 解析により得られた 3mm/pixel のオルソフォトを用いた。ファイル容量が大きすぎるため、オルソフォトは縦 4000 × 横 6000pixel にメッシュ分割した。

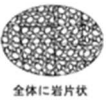









風化区分	形状	硬さと割れ目間隔	個数	モデル図	代表写真
強風化	全体的に岩片状	CIV~CV	11個	 全体に岩片状	
中風化	亀裂沿いに岩片状	BIII CIII~CIV (一部CV)	16個	 亀裂沿いに岩片状	
小風化	ひび割れ状 又は 亀裂沿いに 一部岩片状	BII~BIII CIII (一部CV)	14個	 亀裂が発達して ひび割れ状   亀裂沿いに 一部岩のみ片状	  
新鮮	塊状	BI~BII	6個	 塊状	

図1 リップラップ材風化区分



図2 オルソフォトの例

アノテーションはオルソフォトに対して、リップラップ材の現地調査を担当したダム技術者が写真判読により、堤体全体 613 枚の内 32 枚(約 5%の領域)について実施した。図 1 に示す強風化/中風化/小風化の 3 クラスに該当するリップラップ材を矩形で囲むように Bounding Box を作成した。

### 3.3 物体検出モデルの学習条件

本研究では物体検出モデルとして、最新のモデルではないものの、速度と精度を両立して適用実績も豊富な SSD[Liu 2016] を採用した。特徴量抽出は Imagenet データセットで事前学習済みの resnet-50 を利用し、損失関数は BCE、最適化関数は SGDM (momentum0.9)、ミニバッチは 32 とした。

また、教師データは 1000×1000pixel にクロップした上で、左右反転/上下反転/ノイズ付与/色調変換などをランダムに組合せて 8 倍に増幅し、学習データ 8:検証データ 2 に分割して学習を行った。結果として学習に用いた画像は 792 枚であった。

### 3.4 検出対象の風化区分の違いによる実験

検出対象とする風化区分を変えて、下記の 2 通りのケースで学習および推論を実施した。

- CASE1  
現地調査と同等の強風化/中風化/小風化3クラス
- CASE2  
ダム管理上重要で特徴量も明瞭な強風化のみ1クラス

#### (1) CASE1

学習結果および推論結果の概要を次項図 3 に示す。また、検証データでの精度を表 1 に示す。

前提として本研究の教師データは Ground Truth のオブジェクト数が強風化<中風化<小風化の順に多く、全体の約 82%を小風化クラスのオブジェクトが占めるインバランスデータである。今回はリップラップ材風化検出での初回の AI 画像認識の適用であり、特にクラス間の間引きや重み付けは行っていないため、学習は小風化クラスに大きく影響を受けている。そのため AP は小風化が最も高いが、それでも高々 32%であった。Precision と recall はクラス間で傾向が異なり、precision は強風化が高く、recall は小風化が高い結果であった。

ダム管理上重要な強風化の Recall が 26%と低いため、風化の見逃しの恐れが高いことがわかる。

表 1 CASE1 検証結果

項目	強風化	中風化	小風化
GroundTruth	199	517	3102
正検出 TP	44	173	1825
未検出 FN	127	344	1277
誤検出 FP	17	258	3365
precision	72%	40%	35%
recall	26%	33%	59%
AP	23%	18%	32%

#### (2) CASE2

学習結果および推論結果の概要を次項図 3 に示す。また、検証データでの精度を表 2 に示す。

誤検出の FP が大量に発生しているが、ほとんどは Confidence 値が低いものであるため、AP は 71%と CASE1 に比べて大幅に改善された。CASE1 で問題となる強風化の Recall の低さは、92.5%と高精度の結果となった。そのため、堤体全体の風化をほぼ網羅的に検出できることとなる。

表 2 CASE2 検証結果

項目	強風化
GroundTruth	199
正検出 TP	184
未検出 FN	15
誤検出 FP	27111
precision	0.7%
recall	92.5%
AP	71%

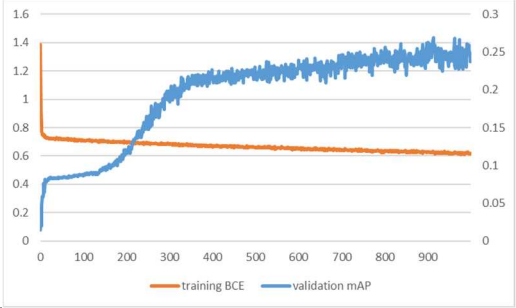
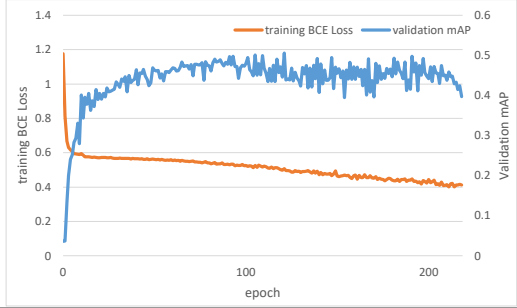
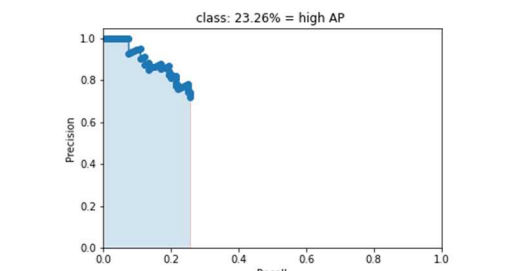
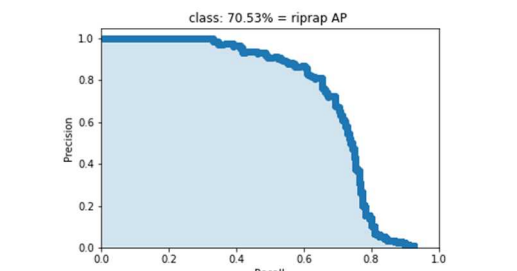

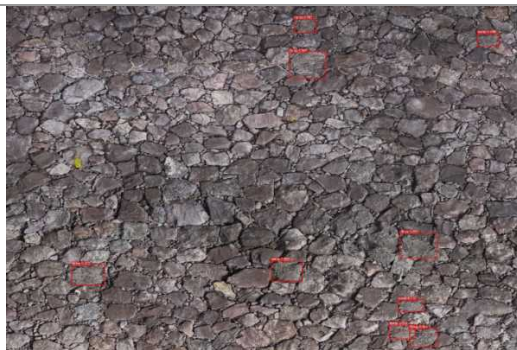

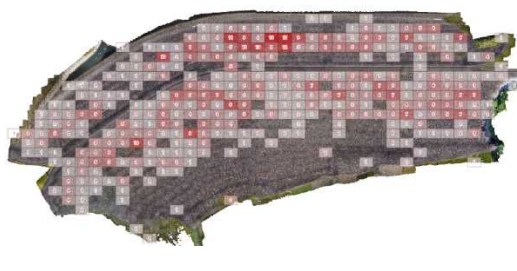
	CASE1	CASE2
検出対象	[現地調査と同等] 3 クラス(強風化/中風化/小風化)	[ダム管理上重要なクラスに絞り込み] 1 クラス(強風化)
教師データ	32 枚 オブジェクト数 3790(199/517/3102)	32 枚 オブジェクト数 199
学習曲線		
精度 AP 強風化 PR 曲線	32% (23%/18%/32%) 	71% 
検出結果 サンプル (メッシュ画像)		
風化検出数 強風化分布図 (conf0.5 以上)	29657 個(639 個/7290 個/21728 個) 	1005 個 

図3 ケース間比較

### 3.5 考察

ここでは両ケースに共通する強風化の学習結果・推論結果を基に考察を加える。

CASE2 の強風化のみ 1 クラスで学習した方が、大幅に精度が高い結果となった理由としては、教師データに人間の判読の揺らぎが少なかったためと考えた。教師データはダム技術者が

写真判読でアノテーションを行ったが、特に中風化か小風化か、小風化か風化なしかは、クラス判別に迷うリップラップ材が多かった。そのため、CASE1 の 3 クラスの学習においては AI がクラス間の境界線を明瞭に引けなかったのに対して、CASE2 の強風化は特徴が明確なため、写真判読に迷うことが相対的に少なく、結果として教師データの揺らぎが少なかったと考えた。



また、CASE1ではRecallが26%と、強風化全体の約3/4を見逃す恐れがあることが実用上の大きなネックであるが、CASE2ではRecallが93%まで向上し、強風化を見逃す確率が大きく減少できている。CASE2のPR曲線を見るとConfidence値が低い検出結果は誤検出を多く含むが、閾値を適切に設定することで、Precision0.8, Recall0.7程度が最も実用上適していると考えられる。一定の誤検出・未検出は残るが、堤体全体の強風化の分布状況は捉えられるため、CASE1に比べてダム管理の基礎資料として活用できる可能性が高まった。

本研究で得られた知見は以下の通りである。

- ロックフィルダム堤体点検に画像認識を適用する場合、従来のダム技術者による現地調査と同等の点検記録や精度(強風化/中風化/小風化3クラス)を求めるのは難しく、画像認識により現地調査を代替することは困難であった(CASE1)
- 現地調査を代替するのではなく、より簡易で画像認識に適したシンプルなタスク(強風化1クラス)を設定することで、堤体全体評価という画像認識のメリットをダム管理者に提供することができる(CASE2)
- ダム技術者による精緻な現地調査に比べると、精度は劣るものの堤体全体の風化の発生状況を面的に把握することを目的として、現地調査を補完するツールとしての活用が期待できる

なお、CASE1とCASE2の検出結果の強風化分布図を見比べると、強風化の個体はCASE2の方が多く検出されているが、分布の傾向は類似している。ただし、堤体下流面の下部のみ大きく傾向が異なり、CASE1のみで強風化が検出されている。CASE1の精度はCASE2に比べて大幅に劣るが、堤体下流面の下部は教師データが存在しない領域であり、現地調査も行われていないため、CASE1で検出された強風化が実際に強風化に該当するかは、今後ダム技術者による確認・検証を行うことが望ましい。

## 4. おわりに

### 4.1 本研究の成果

本研究では、ロックフィルダムの堤体点検において、画像認識を適用するための実験を森吉山ダムの空撮画像を用いて行った。ダム技術者による現地調査と同等のタスクではなく、画像認識に適した簡易なタスクに適用することで、大幅な精度改善が図れ、ダム管理に適用できる可能性を示した。具体的には強風化のみに特化した学習を行うことで、堤体全体の強風化の分布を面的に把握した。検出結果は、現地調査の補完としてダム管理のための基礎資料として活用が期待される。

### 4.2 今後の課題

#### (1) 判定基準の厳格化

リップラップ材の点検の場合、工業製品などと比べるとどうしても点検評価が定性的・主観的になる。そのため、AIで学習するための絶対的な正解(Ground Truth)を作成することが困難である。したがって、AIの精度はまだ向上の余地が残されており、今後の課題である。そのためには、教師データ作成における判断の揺らぎを抑え、より正確なGround Truthを作成した上で目標精度を定めて精度向上に取り組む必要がある。

これまでに蓄積された点検記録や、ダム技術者による目視判読にも判断の揺らぎがあるため、AIを適用する前にそれらを最小化するための判定基準の厳格化が求められる。今回の実験のCASE2では強風化のみを対象としたため、目視での判読が比較的容易であったが、それでも岩塊の一部のみ強風化の場合など、アノテーションに迷うものがあった。基準をより厳格に定義した上で、教師データ作成の際は複数人で作業を行い、判断が異なった場合には基準を見直すことが望ましい。これにより教師データの揺らぎが抑えられ、AIが決定境界を正しく引けることが期待できる。

#### (2) 複数ダムでの実証

本手法を他のダムで適用・検証することも課題である。ロックフィルダムはダム毎に用いる岩種や発生する劣化が異なるため、他ダムで学習したモデルを利用することは難しいと考える。当面はダム別に教師データを作成し、本手法で岩種の違いなどに対応するための知見を蓄積する必要がある。

## 謝辞

本論文を執筆するにあたり、国土交通省東北地方整備局能代河川国道事務所森吉山ダム管理支所より研究フィールドおよびデータ提供をいただきました。またダム管理者の視点から貴重なアドバイスを授かりました。厚く御礼を申し上げ、感謝の意を表します。

## 参考文献

- [国土交通省 2013] 国土交通省 水管理・国土保全局 河川環境課, ダム総合点検実施要領・同解説, 2013
- [藤井 2022] 藤井 純一郎, 平嶋 智希, 栗飯原 稔: ロックフィルダムの堤体点検への画像認識 AI の適用, 第 36 回人工知能学会全国大会論文集, 2022.
- [Robert 1996] Frederique Robert, Guy Lefebvre: Image processing for dam survey in civil engineering, Proc. SPIE 2785, Vision Systems: New Image Processing Techniques, 1996.
- [小林 2008] 小林 晃, 高橋 涼介, 青山 咸康, 渡部 大輔: 画像解析によるリップラップ材の現状把握, 農業農村工学会論文集 76(1), 35-44, 2008.
- [土江 2018] 土江 真吾, 砂子田 正和, 小畑 大作: UAV(無人航空機)を活用したフィルダムリップラップ材の劣化状況把握手法について, ダム工学 28(3), 159-166, 2018.
- [石井 2020] 石井 明, 菅原 宏明, 小篠 耕平, 天方 匡純: UAVの自律航行と空撮画像を活用したダム堤体点検の効率化・高度化に関する研究, 土木学会 AI データサイエンス論文集 2020 年 1 巻 J1 号, 613-622, 2020.
- [Liu 2016] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg: SSD: Single Shot MultiBox Detector, arXiv:1515.02325. 2016.