

深層学習を活用した河川護岸の経年モニタリング手法の提案

Proposal of monitoring method for river revetment utilizing deep learning

藤井 純一郎^{*1}
Junichiro Fujii

吉田 龍人^{*1}
Ryuto Yoshida

岡野 将大^{*1}
Masahiro Okano

天方 匡純^{*1}
Masazumi Amakata

^{*1} 八千代エンジニアリング株式会社
Yachiyo Engineering, Co., Ltd.

The inspection of civil engineering structures such as river revetments has traditionally been carried out visually by engineers. Visual inspection requires a great deal of labor and is subjective to the engineer's judgment, resulting in inconsistent inspection records. In order to solve these problems, an inspection method that applies image recognition technology based on deep learning is being researched. However, for the maintenance and management of structures, image recognition results alone are not sufficient. It is necessary to convert these results into physical quantities that can be used as indicators to determine the health of structures, and to monitor the changes over time.

In this study, we propose a river revetment monitoring method based on the physical quantities of area, width, and length calculated for the crack detection results by deep learning. We also report the results of applying this method to actual rivers.

1. はじめに

都市部を流れる河道法面には、一般的にコンクリート護岸が張り巡らされ、老朽過程に応じた維持管理がされている[国土交通省 2019]。しかし、現時点では、技術者の目視情報を中心とする極度に人的資源に依存した主観的・定性的管理が主体となっており、客観的・定量的データに基づいた合理的な管理手法が求められている。そのため、筆者らは、深層学習を活用し画像からひび割れを自動検出・評価する手法を研究してきた。

本研究では、実際の河川護岸のひび割れを対象に、2時期の護岸画像に対してひび割れ面積・幅・長さの物理量を算出し健全度を評価する実験を行った。実験結果から、本手法を河川護岸のモニタリングに適用するための方策と課題について報告する。

2. 既往研究と本研究

2.1 河川護岸のひび割れ検出に関する既往研究

筆者らはこれまでに河川護岸のひび割れ検出を行う深層学習モデルを提案し検証を行ってきた[天方 2018] [斎藤 2019]。これらは検証対象の1時期の画像では比較的良好に一致し、画像に基づくひび割れ検出の技術的な可能性が示された。またひび割れ検出結果をもとに補修を行うかの診断を行うため、劣化の形状に加えて絶対的な位置と大きさを定量化する手法も提案し[吉田 2020]、河川管理の現場での実用に向けて研究が進められている。

これらの研究成果は1時期の護岸画像を対象として理論的な検証はできているが、現場に適用するための手法のロバスト性について、複数時期の撮影データを用いた検証がなされていない。特に、自然環境の影響を受ける護岸などの土木構造物では、日照条件や植生繁茂の状況が撮影の度に異なることが避けられない。また、護岸の維持管理に適用するためには、河川管理者が意思決定に使う管理区間単位でひび割れを定量評価し、その健全度を正しく経年モニタリングできることを実証する必要がある。

2.2 本研究の目的

本研究では、既存研究で提案されている手法を実際の河川管理に適用するための実証的研究である。具体的には下記の2点について実証を行った。

- ひび割れ検出のロバスト性
環境条件が異なる2時期の画像に対してひび割れ検出を適用し、ひび割れ検出のロバスト性を検証する
- 河川管理者向けの健全度指標
距離標区間単位での経年モニタリングのための健全度指標の算出を試行する

3. ひび割れ検出モデル

本研究では、ひび割れをピクセル単位で検出する必要があり、深層学習の画像認識手法[Aurelien Geron 2018]の一つであるSemantic Segmentationを適用した。用いるモデルは、既往研究[斎藤 2019]で提案されたFusionNet[Tran Minh Quan 2016]をベースにカスタマイズしたものである。オリジナルのFusionNetからの変更点は、入力画像サイズの変更、プーリング層の追加、活性化層とバッチ正規化層の入れ換え、残差結合から連結結合へ変更である。ハイパーパラメータも既往研究を踏襲した。

教師画像は、過去3年間に一定の区間を複数回撮影した護岸画像171枚を使用し、河川技術者がひび割れと判断した箇所を図1のようにピクセル単位でマーキング(青塗りの箇所)して作成した。教師画像は224*224ピクセルにクロッピングし、ランダムに学習データ8:検証データ2に分割して学習を行った。

学習によって得られた学習曲線を図2に示す。検証データのaccuracyおよびlossであるval_acc, val_lossが70エポックで概ね収束したことが確認できる。



図1 教師画像の作成例

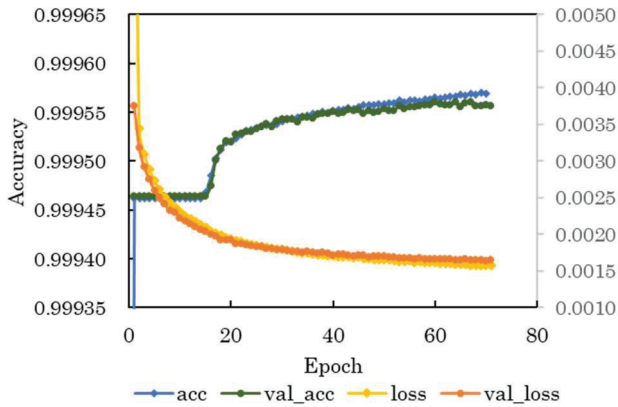


図2 学習曲線

教師画像に対する性能評価結果を表1に示す。本研究で対象とする護岸のひび割れは、画像全体に占める割合が1%にも満たないため、Accuracyは必然的に高くなる。それ以外の値は一般的に高い値とは言えないが、ひび割れのような細く小さい領域に対してSemantic Segmentationを適用する場合、ひび割れの周囲の数ピクセルを検出するか否かによるわずかな誤差で数値が多きく下がるのが要因である。

ひび割れ検出結果の例を図3に示す。IoUの値は低いものの、目視による定性的な評価としてはひび割れをよく捉えている。推論精度上の問題は少ないと判断し、本モデルを用いて以降の実験を行う。

表1 モデル性能評価結果

IoU	accuracy	precision	recall
0.330548	0.999542	0.441927	0.574629




図3 教師画像のひび割れ検出結果

4. ひび割れ検出のロバスト性に関する実験

4.1 実験手法

ひび割れ検出モデルを撮影時期の異なる2時期の護岸画像に適用し、日照などの環境条件の異なる画像に対するロバスト性を検証した。環境以外の撮影条件を固定するため、河川護岸をUAVの自律飛行により、同じ機材およびルートで2回撮影した。さらに風の影響でUAVが揺らぐ、またはピントが合わない影響を最小限に抑えるため、UAV空撮画像をSfM解析[[Tomasi, C 1992]]により2mm/pixelに固定した正射変換画像に変換して、2時期の画像アングルを揃えて実験に用いた。

2回の撮影の環境条件を表2に示す。1回目と2回目の撮影は同時期に実施したため、ひび割れの状態は変わらないと仮定し、2時期の検出結果がどの程度一致するかを確認した。

表2 撮影時の環境条件

	1回目	2回目
天候	曇り時々雪	曇り時々晴れ
日照の条件	影なし	(一部)影あり
護岸の条件	(一部)湿潤	乾燥

4.2 実験結果

画像毎にひび割れ検出結果の面積・幅・長さを算出したところ、画像によっては1回目と2回目の結果に大きな乖離が見られた。図4に検出結果が比較的一致した画像の検出結果の例を、図5に大きな乖離が見られた例を示す。また図6、図7に実際の画像を示す。

乖離した例においては、2回目の撮影に対して未検出のひび割れが多く見られ、その結果としてひび割れ面積が1回目の半数以下となっていた。ただし、検出前のオリジナル画像を目視で確認してもひび割れの映りが不明瞭となっているため、本現象は環境条件に対するモデルのロバスト性の問題ではなく、UAV撮影の不安定さによるものと考えられる。




図4 ひび割れ幅別累積面積(一致した例)


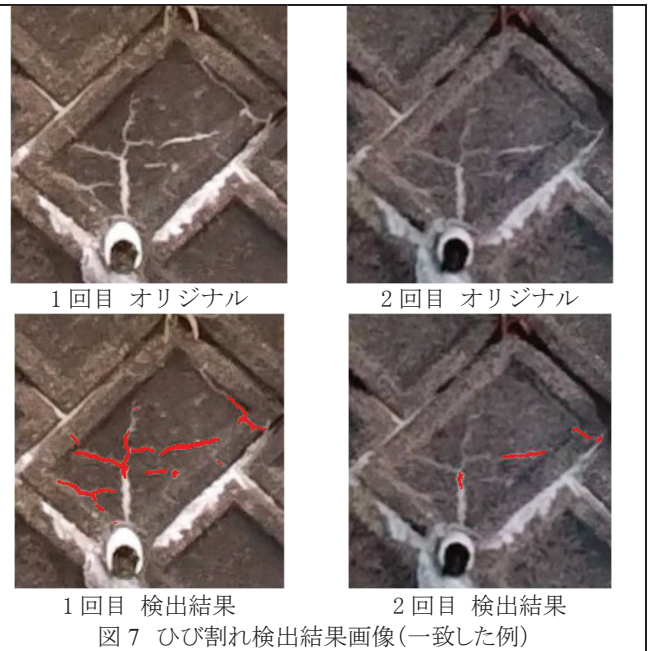



図5 ひび割れ幅別累積面積(乖離した例)

4.3 考察

本実験ではモデルのロバスト性による誤差よりも画像の解像度の違いによる誤差が大きい結果となった。画像の品質が統一されていれば、日照や護岸の乾燥/湿潤の状態によるひび割れ検出結果は比較的頑健であるといえる。

本実験ではSfM解析によりスペック上はピクセル分解能を固定しているが、UAVが護岸に近づいた区間と離れた区間で、目視で比較すると明らかに護岸に近づいた区間のひび割れの方がシャープに映っていることが確認できる。したがってひび割れ検出前にスペックとしての分解能だけでなく、ひび割れのエッジがどの程度鮮明に映っているかを事前確認することが必要となる。さらに実用上はこれらの画像精度管理は撮影現場で即座に実施できることが今後の課題である。



5. 河川管理者向け健全度指標に関する実験


5.1 実験手法

一般的に、河川は河口からの距離によって距離標が設置されており、河川管理者は距離標区間別に毎年点検結果の評価を行う。従来の目視による護岸点検では、距離標区間内で最もひび割れ幅が大きいもののみで評価を決定していた。それらはひび割れ以外の劣化も加味して、区間別の健全度評価(ABCD評価)となり、補修する区間の選定の基礎資料として使われる。

これらの健全度評価手法は、人ができることを前提に制度設計がされており、深層学習による画像認識で上述の評価を人と同等の精度(ひび割れ幅0.1mm単位)で実現するためには、近接で膨大な枚数の画像を撮影する必要があり現実的でない。一方で深層学習は、計測精度は画像のピクセル分解能に依存(本研究では2.0mm単位)するが、人では実現できないひび割れ面積・幅・長さの全量を客観的に抽出することが可能である。

そこで、深層学習によるひび割れ検出結果を用いて、実際の河川の距離標区間単位で評価することを試みた。評価対象は0.1mm単位の精度を求められない面積と長さとし、距離標区間をさらに細分した小区間ごとに、前章と同じ2時期の護岸画像に対しひび割れの定量評価を実施した。ただし、ひび割れ面積・長さを網羅的に記録した点検はこれまで実施されていないため、検証用に同区間をより高解像度のUAVで撮影した画像を用意し、その検出結果を真値と仮定して比較を行った。

距離標区間を1枚の画像とすると巨大な画像となるため、図8のように横幅20mピッチで分割してひび割れ検出を行った。



5.2 実験結果

距離標区間内の20mピッチのひび割れ面積と長さの検出結果を図9、図10に示す。




図9 区間別のひび割れ面積




図10 区間別のひび割れ面積

なお、28.2~28.3kmの区間で2回目の撮影に対するひび割れ検出結果が大きく乖離しているが、これは前章で考察したUAVが護岸から離れたために解像度が低下した区間であり、モデルの精度とは別の問題である。

まず、検証データを真値とした場合、撮影ごとの誤差はあるもののひび割れの多い区間/少ない区間は正しく把握できている。また、ひび割れ面積と長さでの評価結果を比較すると、ほぼ同じ傾向となった。グラフからは読み取れないが、検証データを真

値として 1 回目-検証データ, 2 回目-検証データ間の誤差率を求めたところ, 長さで評価の方が面積で評価する場合に比べて, 1 回目-検証データでは 1.1%, 2 回目-検証データ間では 0.5%の改善を確認できた。

5.3 考察

本実験により, 河川管理者が扱いやすい距離標区間単位でひび割れを客観的・定量的に評価が行えることを示した。本手法を経年的に適用することで, ひび割れが増加傾向にある区間を把握可能となる。

管理対象の指標としては, ひび割れ長さが面積よりも安定して評価できることが示唆された。理由としては, ひび割れのような細く小さい領域に Semantic Segmentation を適用しているため, IoU の値が上がりやすく, 画像の解像度によってひび割れ周辺部も検出する場合があります, 面積の方が長さより過大に評価するためと考える。

健全度評価として使うためには, 図 9, 図 10 に示したように, 区間別のひび割れの長短の傾向は捉えられても, 絶対的な長さの精度は十分でなく, 検証データと誤差がある。これには画像の精度の問題とモデルのロバスト性の問題の2つが絡んでいる。護岸は屋外の構造物のため, 毎回同じ環境条件で撮影はできないため, 画像の精度を完全に統一することは難しい。そのため, 図 11 に示すように, 本研究の提案手法は当面ひび割れの多い区間のフィルタリングに用い, 抽出された区間に対しては従来通りの人の目視による点検を併用して, 健全度を判定することが必要と考える。

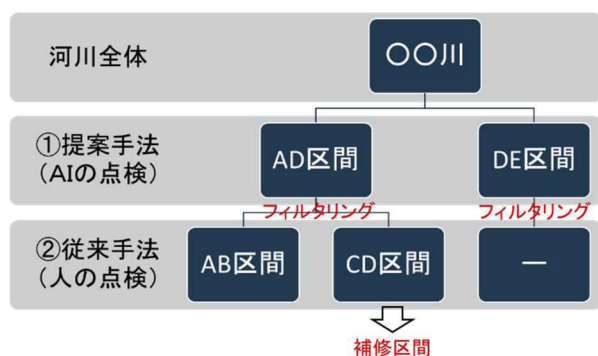


図 11 AIと人による点検の併用

6. まとめ

深層学習による画像認識を用いて, 護岸のひび割れ検出から健全度評価までを行う手法を, 実際の河川管理に適用するための実証的研究を行った。大きく下記の 2 点について実証を行った。

- ひび割れ検出のロバスト性
環境条件が異なる 2 時期の画像に対してひび割れ検出を適用し, ひび割れ検出のロバスト性を検証した。ひび割れ検出モデルは環境条件には比較的頑健であることが示された一方, 画像の品質統一が課題であることが明らかになった。
- 河川管理者向けの健全度指標
管理区間単位での経年モニタリングのための健全度指標の算出を試行した。20m ピッチ区間でのひび割れ面積・長さを網

羅的に算出し, 上記の 2 時期の画像と検証用画像に適用した。ひび割れ長さでの評価が, 相対的に精度がよいことが確認できたが, 健全度評価を行うための長さの絶対的な精度は不足している。そのため, 従来通りの目視による点検を併用して, 健全度を判定することが必要と考える。

今後の課題として, 画像の品質統一手法とその実施手順の確立が求められる。特に河川の現場で, UAVでの空撮を行う場合は, 後日の撮り直しが行えないため, 現場での品質確認が重要である。また, 今回は通常の GPS のみでの自律飛行により空撮を行ったが, GPS の誤差による画像品質のばらつきが, ひび割れ検出結果に大きな影響を与えることが明らかになったため, 今後は GPS の誤差を補正可能な RTK-GPS を用いた自律飛行を実施する予定である。

また, 実用化に向けた制度面の課題として, 本手法を前提とした点検および健全度評価のルール策定が必要である。現行の健全度評価手法は, 人ができることを前提に制度設計がされているため, 深層学習による画像認識を活用することを想定した新たな健全度評価手法を策定する。本研究で示したように, ひび割れ検出モデルの絶対的な精度は健全度評価を行うためには不十分のため, ひび割れが多い区間を絞り込んで, 従来通りの目視点検を行うなど, 人と AI の長所を組み合わせた健全度評価手法を実証していく。

参考文献

- [国土交通省 2015] 国土交通省 水管理・国土保全局: 河川砂防技術基準 維持管理編(河川編), 2015.
- [天方 2018] 天方 匡純, 吉田 武司, 藤井 純一郎: 深層学習方式を活用した河川のコンクリート護岸の劣化領域抽出, 第 73 回年次学術講演会, 土木学会, 2018.
- [斎藤 2019] 斎藤 彰儀, 上総 虎智, 平木 悠太, 天方 匡純, 吉田 武司: 深層学習によるコンクリート護岸劣化領域検出システムの開発, デジタルプラクティス Vol.10 No.2, 情報処理学会, 2019.
- [吉田 2020] 吉田 龍人, 藤井 純一郎, 大久保 順一, 天方 匡純: 護岸のひび割れ検出 AI の作成とオルソ画像を活用したひび割れ幅の評価, AI・データサイエンス論文集 1 巻 J1 号, 土木学会, 2020.
- [Aurelien Geron 2018] Aurelien Geron, 下田倫大, 長尾高広: scikit-learn と TensorFlow による実践機械学習, 2018.
- [Tran Minh Quan 2016] Tran Minh Quan, David G. C. Hildebrand, Won-Ki Jeong: FusionNet: A deep fully residual convolutional neural network for image segmentation in connectomics, arXiv:1612.05360, 2016.
- [Tomasi, C 1992] 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.