

堤防及び河岸の効率的な監視技術の開発

研究予算：運営費交付金

研究期間：平 29～令 3

担当チーム：寒地河川チーム

寒地水圏研究グループ

研究担当者：大串弘哉、矢部浩規、前田俊一、
横山洋、大石哲也、島田友典、
岡部博一

【要旨】

国土交通省北海道開発局における河川の管理延長は約 2,000km あり、日々の監視のほか、洪水時に防災、減災を行うために、できうる限り異常個所をいち早く見つけ対応していくことが求められている。また、北海道の河川災害は、本州と比較し河岸侵食を伴う例が多く、水害を最小限に防ぐためにも侵食の初期段階で状況を把握する必要がある。そこで、CCTV から得られた画像を用いて、迅速な河岸侵食の状況把握を可能とする評価システムの開発を進めた。システムは、河岸侵食に対応する変状検知モデルで深層学習（ディープラーニング）により構築した。本モデルの構成を示すと共に、過去に生じた被災データに適用した検討結果について報告する。

キーワード：自然災害、河岸侵食、CCTV、深層学習

1. はじめに

平成 28 年 8 月の一連の台風による水害では、北海道において短期間に各地で洪水被害が相次ぎ、国管理区間だけでも 6 か所の堤防破堤が発生した。この水害では、被害の防止・軽減に貢献する堤防や河岸の侵食初期の状況把握ができず、河岸や堤防の侵食や、数百 m にわたる大規模な破堤幅も状況把握に時間を要した（写真-1）。また、復旧工事には、多大な費用と時間を要した。このような甚大な被害を防ぐため、被害状況を早期に把握し、被害の防止や軽減につながる準備・対策を確実に行うことが求められている。しかしながら、国土交通省北海道開発局（以降、北海道開発局）が管理する河川の管理延長は約 2,000km もあるうえ、河川管理者の人員も削減傾向で、全国と比較しても管理延長に対する人員が少ないため、出水時に防災、減災を行うだけの対応力が十分に確保できないのではないかと懸念されている。また、防災・減災を持続的に行う体制整備には、新たな投資を抑え、災害時の対応が職員への過度な負担増とならないような対応策も求められている¹⁾。

本研究の目的は、既存 CCTV を活用し、平常時から堤防・河岸等を監視することで、早期の施設異常把握を可能とし、被害軽減対策の効果を向上・促進させることにある。この達成には、CCTV 映像を自動で処理し、異常を検知できるようなソフトウェアの開発が欠かせない。



空知川での堤防決壊（国土交通省北海道開発局提供）



河岸侵食に伴う落橋

（国土交通省北海道開発局旭川開発建設部提供）

写真-1 河岸・堤防侵食の被害例

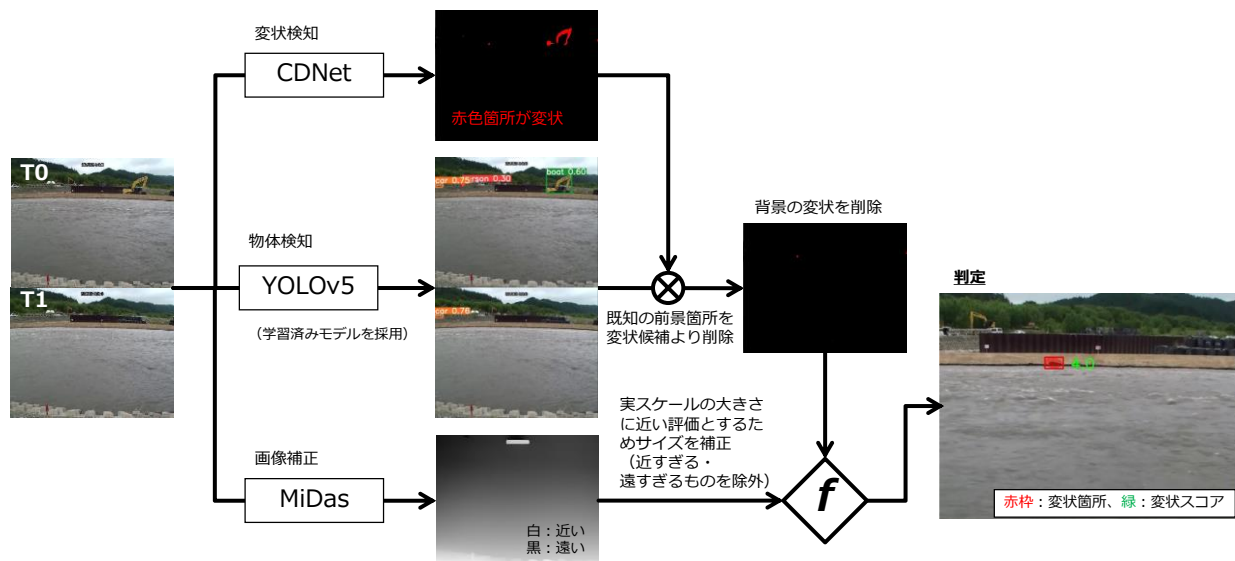


図-2.1 変状検知モデルの全体構成

開発当初は、河岸侵食の監視評価手法を背景差分により評価を行っていたが²⁾、侵食以外の情報も異常値とし抽出してしまう点など、複雑な事象に対する制御が難しかった。そこで、深層学習（ディープラーニング）に着目し、河岸侵食に対応する変状検知モデルの構築により精度を向上させた。ディープラーニングを用いた方法は、近年、AI分野でも目覚ましい発展を遂げている。この理由として、機械自身（プログラム）が与えられた課題に対して、データを学習する過程で適切なパラメータを調整することが可能であり、これを基にして解を求められるという点があげられる。したがって、最適なモデルを作るためには、プログラムの構成と同時に、どのように学習をさせるかが重要となる。ここでは、構築したモデルの内容と本モデルを過去に生じた被災データに適用した検討結果について報告する。

2. 開発したモデルの構成

2.1 全体構成

本モデルは3つの深層学習モデルを用いて構成されている（図-2.1）。それぞれ「変状検知」、「物体検知」、「画像補正」であり、「変状検知」のモデルは、2つの画像の変状箇所（例えば、5分前の画像と現時点の画像の違い）の抽出が得意なモデルとなっている。モデルの学習時には、堤防侵食の記録映像が少ないため、平常時の画像を学習画像として用いた。学習方法を工夫するため、分布外検知（OOD）^{例えば3)}とって学習し

ていないものを検知するように調整した。学習の過程では、正解と不正解を自作し学習できる自己学習型とした。ただし、構築した「変状検知」のモデルは、動く人や車も検出をするため、「物体検知」のモデルを追加することで、人や車などの既知情報を誤検知しないように工夫した。「画像補正」のモデルは、CCTVでとられた画像を実スケールの大きさに近づける工夫をした。この理由として、CCTVの映像は遠景画像を扱うことが多く、手前と奥とで実スケールに乖離が生じることにある。最終的に変状の判断には、変状箇所を特定し、奥行補正を行うことで変状スコアとして表すこととした。

2.2 変状検知モデル

2.2.1 変状画像の比較（CDNet⁴⁾の活用）

変状検知モデル（または異常検知モデル）には、様々な方法があるが^{5)~10)}、本モデルではCDNetを利用している。CDNetは、任意の2枚の画像の変状を検出することができるものである（図-2.2）。例えば、同図の場合、天気が変わっていても、新たな構造物が加わった箇所のみ検出が可能となっている。CDNetの構成は、異なる時期の画像から同じ画像の場所あわせを行うSLAMと、2枚の画像を選び出し、その2枚の画像から変状を検出する深層学習モデル（以降、変状検知モデル）の大きく分けて2つの構成となっている。ここでは、CCTVカメラが対象であるので、画角は固定の状態を基本とし、SLAM部分の実装は行っていない。

学習時には、あらゆる状況の変化（例えば、侵食の

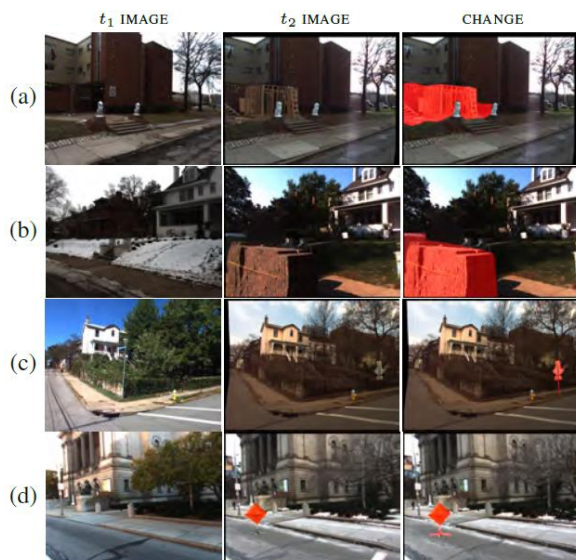


図 -2.2 CDNet による変状検出の一例⁴⁾

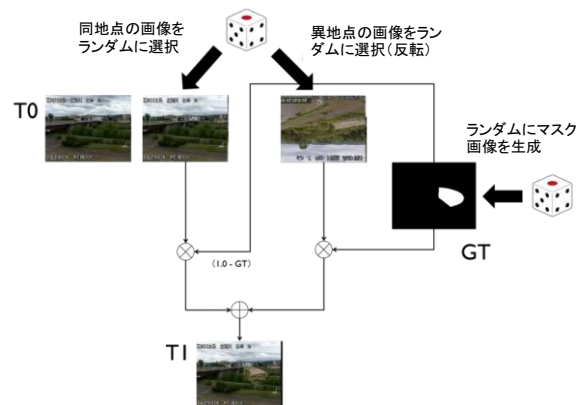
形態)を覚えておくことが困難である。そこで、学習のステップ毎に都度生成される合成画像間のランダムな変状を自己学習的に学び取ることができるような変状生成ルーチンを構築した。図-2.3に、構築した変状画像の自動生成ルーチンを示した。生成方法のステップは、以下のとおりである。

1. 同じ地点で、異なる時間帯の地点の画像をランダムに選び出し、同時に異なる地点から1枚選び出す。
2. マスク画像 (GT) を生成する。(図の例では、楕円に近い形に描画した例を示している)。
3. 3枚の画像をランダムクランプ、左右反転などデータ増強する。ただし、ランダムクランプ・左右反転については、同じ地点から選び出した2枚には同じ条件を適用する。
4. 同じ地点から選び出された2枚のうちの1枚について、異なる地点の画像をマスク画像の形状に合わせてペーストすることで、変状画像 (T1) を作成する。
5. 同じ地点から選び出された2枚のうち、合成していない画像が「T0」、合成を施した画像が「T1」、マスク画像が「GT (正解画像)」となる。

以上のステップで学習を行うが、簡便なアルゴリズムによって、様々な変状画像を自動で生成することができ、教師データの作成が容易となる。

2.2.2 フラクタル地形生成による多様なマスク画像生成

マスク画像については、フラクタル地形生成によるルーチンを用いた。フラクタル地形生成は、地形のフラクタルな特徴 (大局的に見た形状のパターンと局所



T0、T1 : 比較に用いる2枚の画像

GT : 変状の正解画像 (白 : 変状あり、黒 : 変状なし)

図-2.3 変状画像の自動生成ルーチン



T0、T1 : 比較に用いる2枚の画像

GT : 変状の正解画像 (白 : 変状あり、黒 : 変状なし)

図-2.4 フラクタル地形生成ルーチンによる変状画像の生成例

的に見た形状のパターンに類似性を感じさせている特徴)をランダム値の生成に組み込んだアルゴリズムであり、ゲーム等の仮想の地形の生成などに活用されている。ここでは、まず、フラクタル地形を生成し、ある標高の閾値と比較して高い・低いで二値化してマスク画像を生成するルーチンを構築した。作成したマスクは、画像比較 (T0,T1) を行う際に T1 で利用される。マスク画像は、正解画像 (GT) となり、変状の部分が学習可能となる (図-2.4)。

2.2.3 分布外検知 (OOD)

推論結果の自信の有無を推定する指標として OOD (Out-of-distribution ; 分布外) 検知と呼ばれる手法がある (図-2.5)。OOD には様々な実装方法があるが、ここでは図-2.6 に示すように、自信有り (P) と自信無し (c) を同時に予測して、自信無しの結果の大きさに応じてヒントがもらえるような構成とした。学習では、ヒントを得ながら正解かどうかの損失を最小化できるが、ヒントを使う分だけペナルティが与えられ、この両者のバランスをとるように行った。




図-2.5 OOD の一例³⁾

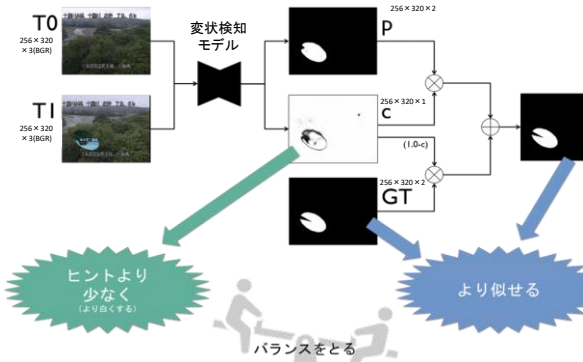



図-2.6 本検討での OOD の活用

変状画像は、自動的に生成される合成画像として用意するため、変状箇所が小さくなりすぎると変状と認識できない場合も十分想定される。この際、無理に微細な変化を教え込んでしまうと過学習のリスクが高まる。そこで、Pixel ベースに拡張して学習に組み込むこととした。ここで、図中の「c」が推論結果に対する各 Pixel での自信の大きさであり、自信があるほど白く、自信がないほど黒くなる。自信のないところはヒントを得られるが、ヒントを見ただけペナルティが課せられる。どれくらいまでヒントを見ることが許されるかは、データセットのエラーの起こりやすさ等の状況によって異なるため、実装ではこのバランスを自動調整できるようにスケジューリングの機構を実装した。


2.3 物体検知モデルによる既知の動体（人・車）の除去

誤検知の多くは、人や車によるものであったため、物体検知モデルを用いて人や車などの既知の物体を検出し、そのエリアの変状としての検知結果を例外処理する方針をとった。

物体検知モデルとしては、「YOLOv5 ver6」を利用した。YOLOv5¹¹⁾には、いくつかのバージョンがある。そこで、モデル自体の規模や学習時の画像のサイズ等から、最も高い性能をもつモデルの比較検討を行った(図-2.7)。CCTV 画像の車等の対象物はかなりサイズが小さいため、これらの検知を的確に行うには、モデルの大きさが大きくなるが、推論用画像のサイズに近い「YOLOv5x6」が最良であると判断した。



(a) 検知の様子



(b) 変状検知除去の様子

図-2.7 YOLOv5 による車の検知性能の差異

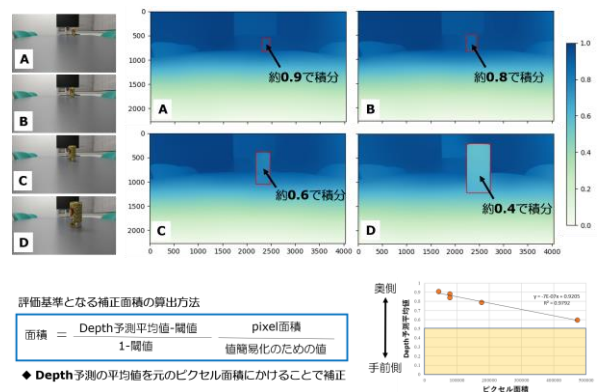


図-2.8 画像補正の方法-Depth 予測モデル「MiDaS」を用いたカメラとの距離を勘案した大きさの推定-

2.4 画像補正モデル

CCTV 画像は画面上の奥行きが幅広いため、変状が画面上のどこにあるかで変状の大きさの意味合いが大きく異なる。このカメラとの位置関係による変状の大きさをより的確にとらえるため、「Depth 予測モデル (画像補正モデル)」を用いることで、変状が画面上のどこにあっても、より実スケールに近い大きさの評価ができるような評価の計算式を検討した。なお、Depth 予測モデルは商業利用可能なライセンスの一つである MIT ライセンスのモデル「MiDaS¹²⁾」を採用した。Depth 情報を用いた大きさの補正は、同一の大きさのものについて位置をずらして撮影し、画面上の場所が変化しても同一の大きさとして評価できるように補正式を考案した(図-2.8)。この計算式を基に変状の大きさを評価することとした。

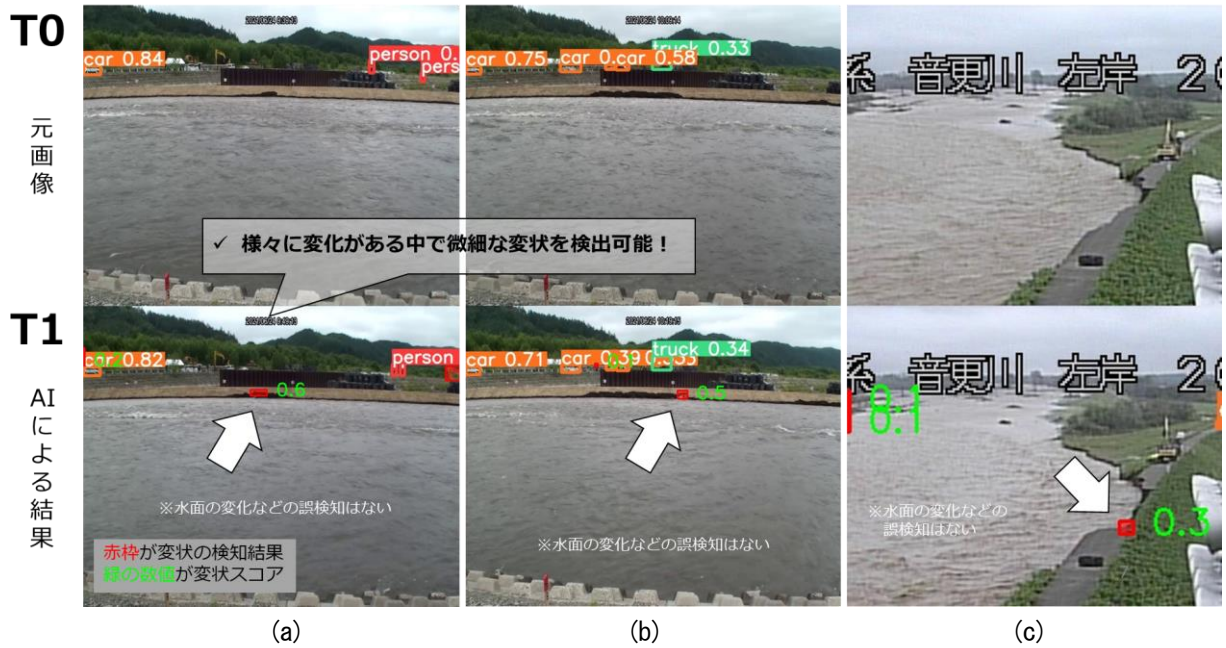


図-2.9 検知の様子

2.5 例外処理

上記で示したことの他に、誤検知を抑えるため、前処理の段階でいくつかの方法を工夫し、本モデルに組み込んだ。まず、複数の画像を平均することによって雨滴や蜘蛛の巣などの障害の影響を抑制した。なお、平均処理する場合には、車等を含めないようにするため、予め YOLO を用いて物体検知し、物体が検知されたエリアを平均処理に用いない処理を行っている。

また、画角の変化などの大きな変化に関しては「EdgeIoU (Edge 検出結果同士の IoU (類似度) < 5%)」を組み込むこととした。

3. モデルの適用と運用例

3.1 モデルの適用

図-2.9 に基準となる元画像と一定時間経過後の変化を変状検知により捉えた結果を示す。変状の箇所は、赤枠で示した箇所、緑の値が変状スコアになっている。

(a),(b)は、実験時の侵食の様子を解析したもので、(c)は、実河川での侵食経過の様子を解析したものである。また、(a),(b)については、元画像から 1 分間隔の変状結果例、(c)については元画像から 5 分間隔の変状結果例としている。

いずれの画像においても、誤検知に繋がるような水面の微妙な変化は検知されないことや、人や車などの動く物体についても物体検知モデルにより、検知を取り除いていることが分かる ((a),(b)のみ表示)。結論と

して、本モデルは、全く学習していない画像でも一定の精度で動作することが確認できた。

3.2 モデルの運用例

図-2.10 に、モデルの運用例について示した。ここで開発したモデルは、変状が生じるとアラートメールを配信できるようなシステムとなっている。このシステムは、画面上の変状スコアの合計値が設定した変状スコアの値 (しきい値) を越えるとメールが配信される仕組みとなっている。変状が検知されると自動的に変状の程度を確認できることに繋がるため、河川管理者がより迅速に情報を入手可能となる。現在、北海道開発局にて、運用中であり、災害軽減化を目指した活用が期待される。

4. まとめ

本研究では、河岸等の変状を検知するモデルを開発した。本モデルは、「変状検知」、「物体検知」、「画像補正」の 3 つのモデルで構成した。

「変状検知」モデルは、CDNet を利用し、2 つの画像の変状箇所 (例えば、5 分前の画像と現時点の画像の違い) の抽出に活用した。モデル学習時に、平常時の画像を学習画像として用いたため、普段学習していない状況を検知した際に変状と捉えられるように分布外検知 (OOD) を用いた。また、学習の過程で正解と不正解を自作し学習できる自己学習型とした。

これに「物体検知」のモデルを追加することで、あらかじめ想定される人や車のような既知の情報を誤検

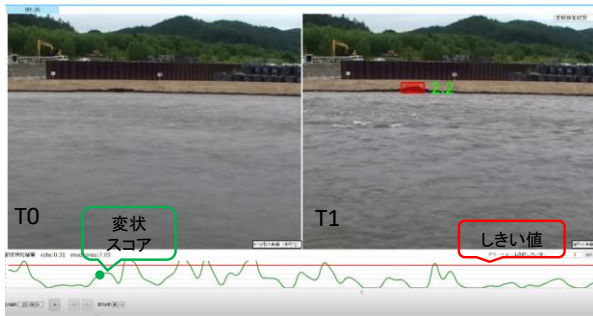


図-2.10 モデルの適用例

知しないように工夫した。さらに、「画像補正」のモデルにより CCTV 画像を実スケールに近づけるため補正を行った。最終的に変状の判断には、変状箇所を特定し、奥行き補正を行うことで変状スコアとして示した。

変状スコアは、あらかじめ任意に設定した閾値を超えた段階で、アラートメールが管理者へ配信されるシステムとした。本モデルを用いたシステムは、北海道開発局内にて試行的に運用されており、今後、運用を続ける中で、実際の河岸侵食データの蓄積により、モデルの強化が図られ、災害対応の迅速化・効率化にも繋がると期待される。

謝辞：本研究を遂行する上で国土交通省北海道開発局 帯広開発建設部より貴重な資料を提供していただいた。ここに記して謝意を表す

参考文献

- 1) 岡部博一、矢部浩規、田所登: 画像解析の河川管理施設の広範囲自動監視への適用、寒地土木研究所月報、Vol.770、pp.1-7、2017
- 2) 大石哲也、横山洋、島田友典、矢部浩規: CCTV を用いた画像解析による河岸・堤防侵食の変状検知とアラート配信に関する検討、寒地土木研究所月報、Vol.798、pp.18-24、2019
- 3) Terrance DeVries and Graham W. Taylor: Learning Confidence for Out-of-Distribution Detection in Neural Networks, arXiv:1802.04865v1, 2018
- 4) CDNet Pablo F. Alcantarilla, Simon Stent, German Ros, Roberto Arroyo and Riccardo Gherardi: Street-View Change Detection with Deconvolutional Networks, Autonomous Robots, Volume 42, Issue 7, pp.1301–1322, 2018
- 5) Ashley Varghese, Jayavardhana Gubbi, Akshaya Ramaswamy, and Balamuralidhar P: ChangeNet: A Deep Learning Architecture for Visual Change Detection, The European

- Conference on Computer Vision (ECCV) Workshops, pp. 129-145, 2018
- 6) Ken Sakurada: Weakly Supervised Silhouette-based Semantic Change Detection, <https://arxiv.org/pdf/1811.11985.pdf>, 2018
- 7) Joseph Z. Xu, Wenhan Lu, Zebo Li, Pranav Khaitan, Valeriya Zaytseva: Building Damage Detection in Satellite Imagery Using Convolutional Neural Networks, arXiv:1910.06444v1, 2019
- 8) Ryuhei Hamaguchi, Ken Sakurada, Ryosuke Nakamura : Rare Event Detection using Disentangled Representation Learning, <https://arxiv.org/pdf/1812.01285.pdf>, 2018
- 9) Enqiang Guo, Xinshe Fu, Jiawei Zhu, Min Deng, Yu Liu, Qing Zhu, Haifeng Li: Learning to Measure Change: Fully Convolutional Siamese Metric Networks for Scene Change Detection, <https://arxiv.org/pdf/1810.09111.pdf>, 2018
- 10) Lucas Deecker, Robert Vandermeulen, Lukas Ruff, Stephan Mandt, Marius Kloft: Anomaly Detection with Generative Adversarial Networks, ICLR 2018 Conference Acceptance Decision, 2018
- 11) Ultralytics YOLOv5: <https://github.com/ultralytics/YOLOv5> (accessed on 30 May 2022)
- 12) MDAS: https://pytorch.org/hub/intelisl_midass_v2/ (accessed on 30 May 2022)

DEVELOPMENT OF EFFICIENT MONITORING TECHNIQUES FOR LEVEES AND RIVERBANKS

Research Period: FY2017-2021

Research Team: River Engineering Research Team,
Cold-Region Hydraulic and Aquatic Environment
Engineering Research Group

Author: OGUSHI Hiroya
YABE Hiroki
MAEDA Shunichi
YOKOYAMA Hiroshi
OISHI Tetsuya
SHIMADA Tomonori
OKABE Hirokazu

Abstract: The Hokkaido Regional Development Bureau manages about 2,000 km of rivers, and in addition to daily monitoring, it is necessary to identify and respond to abnormalities as quickly as possible to prevent and mitigate disasters during floods. In addition, river disasters in Hokkaido are often accompanied by riverbank erosion compared to those in Honshu, and understanding the situation at the early stage of erosion could minimize flood damage. We should assess the situation at the early stage of erosion to minimize flood damage. Therefore, we developed an evaluation system that can quickly assess the situation of riverbank erosion using images obtained from CCTV. The system is a deformation detection model for riverbank erosion and was constructed using deep learning. We present the configuration of the model and the results of applying it to past damage data.

Keywords: Natural Disaster ; Riverbank Erosion ; CCTV; Deep Learning