

## VAE を用いたブロック単位での護岸の異常検知 Anomaly Detection of River Revetment in Block Unit Using Variational Auto Encoder

都築 幸乃 (八千代エンジニアリング) 吉田 龍人 大久保 順一 藤井 純一郎 山下 隆義 (中部大学)  
Yukino TSUZUKI, Yachiyo Engineering Co.,Ltd.  
Ryuto YOSHIDA, Yachiyo Engineering Co.,Ltd.  
Junichi OKUBO, Yachiyo Engineering Co.,Ltd.  
Junichiro FUJII, Yachiyo Engineering Co.,Ltd.  
Takayoshi YAMASHITA, Chubu University.  
E-mail: yk-tsuzuki@yochiyo-eng.co.jp

The management of river revetment is mainly carried out visually by engineers. There are many types in the deformation related to the functional depression of the river revetment. If these can be detected from revetment images, the efficiency improvement of inspection can be expected. Recently, VAE has been shown to be effective as an anomaly detection technology for uniform components. Since river revetment is formed by blocks of the same pattern, it is thought that anomaly detection in individual blocks is possible. This paper proposes the method for cropping individual blocks and the effectiveness of anomaly detection by VAE.

### 1. はじめに

現在の河川護岸の点検は、評価要領に従い技術者による目視点検が主体とされている。これには多大な労力が必要であり、その上現場での経験に基づいた適切な判断が求められる。しかし、豊富な経験を有する技術者を大量に確保することは困難になりつつある。このような背景から、近接目視と同等の情報が得られる、または目視点検を省力化する効率的な点検手法が期待されている。これに対し、既往研究では藤井らが深層学習を活用した河川護岸のひび割れ検出手法を提案している<sup>1)</sup>。しかし、護岸の機能低下に関わる変状には、ひび割れ以外にも欠損やエフロッセンス、陥没など様々な種類が存在する。これらのあらゆる変状を護岸画像から自動的に検出することができれば、点検の効率化が期待できる。さらに、変状の状態を定量的に評価することができれば、点検結果を評価区分ごとに分類する際の判断基準となり得る。

深層学習による異常検知は、医療での画像診断や工場での不良製品の検知など幅広い分野で使用されている。中でも Variational Auto Encoder(VAE)は、工業製品などの均一な部品に対する異常検知手法として有効性が示されている<sup>2)</sup>。河川護岸もほぼ均一なコンクリートブロックによって形成されていることから、一つのブロックを異常検知の計測単位として用いることが可能であると考えられる。そこで本研究では、護岸画像からブロックを個別に切り出し、そのブロック画像に対して VAE による異常検知を試みる。

本研究では、まずブロックの切り出し手法について検討する。ここではブロックが規則的なパターンをもつことに着目し、単純な物体検出手法であるテンプレートマッチングを用いて個々のブロック座標を推定する。次に、護岸点検における VAE による異常検知の適応可能性について検討する。正常なブロック画像と変状のある異常なブロック画像に対して VAE の入出力画像から異常スコアを算出し、正常データと異常データの識別が可能であることを示す。

### 2. ブロックの切り出し

テンプレートマッチングは、対象画像からテンプレート画像(対象画像から指定した部分画像)と最も類似する箇所を探索する処理である。画像間の類似性を表す評価尺度に



Fig. 1 Block coordinate (yellow points) detected by template matching and block coordinate (red points) obtained by interpolation

は様々なものが提案されているが、ここでは次式で与えられる正規化相互相関(ZNCC)を用いる。

$$ZNCC(x, w) = \frac{(x - \bar{x}, w - \bar{w})}{\|x - \bar{x}\| \|w - \bar{w}\|} \quad (1)$$

ここで $(x, w)$ はベクトル $x$ と $w$ の内積、 $\|x\|$ はノルム、 $\bar{x}$ は平均値である。ZNCC は画像をベクトルとみなして内積を計算するため、値がベクトルの長さに対して影響を受けない。さらに、計算過程で輝度値の平均値を引くため、比較する二つの画像領域の輝度値の平均値が異なる場合でも類似度が変化しない。このことから、ZNCC は輝度の変動に頑健な類似度算出手法とされている。屋外で撮影される護岸画像は日照条件の影響を受けることから、ZNCC によるパターンマッチングが有効であると考えられる。さらに、グレースケール化と平滑化処理を実行することでノイズに対する頑健なマッチングを行う。

護岸画像の中から任意のブロックをテンプレート画像とし、テンプレートマッチングによって検出されたブロックを左上端に黄色のマーカをプロットして Fig.1 に示す。結果から分かるように、植生などの影響により、テンプレートマッチングによって画像中のすべてのブロック座標を推定することは不可能である。そのため、マッチングしたブロック座標から抜けのあるブロック座標を推定する。同じ形状かつ大きさが同程度のブロックが並んでいることを前提とし、マッチングしたブロックのうち、隣り合うブロック間の距離がテンプレートとしたブロックの幅よりも長ければその間をテンプレート幅に従って補間する。補間した結果を Fig.1 に赤色のマーカで示す。補間により、すべてのブロックを切り出すことができた。

### 3. VAEによる異常検知

Variational Auto Encoder(VAE)は、入力データを低次元の潜在変数に圧縮する Encoder と潜在変数から入力データを再構成して出力する Decoder で構成される生成モデルである。VAEによる教師なし異常検知では、まず正常データのみを用いて VAE を学習する。学習を終えたモデルは異常部分について再構成を行うことができないことを利用し、再構成誤差が高いものを異常と判別することができる。VAEには様々なモデルが提案されているが、ここでは DIP VAE<sup>3)</sup>を採用する。

## 4. 実験

### 4. 1 学習データ

本研究では、変状がないことに加え植生や排水穴などが含まれないシンプルなブロック画像を正常データとして学習に用いる。データ拡張処理を行い、合計 23,354 枚の学習データを作成した。

### 4. 2 異常スコアによる識別

VAEによる異常検知の有効性を確認するために、正常データと異常データをそれぞれ 40 枚用意し、異常スコアによる識別について検討した。ここでは画像の類似度である ZNCC を用いて異常スコアを次式で求める。

$$\text{異常スコア} = 1 - \text{ZNCC}(x, w) \quad (2)$$

ZNCC は-1~1 の値をとり、値が 1 に近いほど画像が類似していることを表す。従って、ここでの異常スコアは 0~2 の値をとり、値が高いほど類似度が低い、つまり異常度が高いことを表す。正常異常データ別の異常スコアの度数分布を Fig.3 に示す。これより、異常スコアが 0.20~0.25 の区間に閾値を設けることで、大まかな識別が可能であると考えられる。

異常スコアの高い正常異常データと異常スコアの低い正常異常データを Fig.4 に示す。それぞれ左が入力画像、右が再構成された出力画像である。Fig.4(a)(b)より、一見正常に見えるブロック画像でも、再構成結果が不鮮明になる場合があることが分かった。これは、ブロック表面の汚れやコンクリートの色合いなど、正常データにおける多様性が原因であると考えられる。一方、Fig.4(c)(d)より、変状領域の大きさに伴って異常スコアが高くなっていることを確認した。このことから、変状の状態を定量的に評価することが可能であると考えられる。

### 4. 3 異常検知結果

前節の結果から異常スコアの閾値を 0.25 に設定し、護岸画像に対して異常なブロックを検出した結果を Fig.5 に示す。異常スコアが閾値以上のブロックを赤い枠で囲んでいる。Fig.5 では主に排水穴と排水穴からの漏水、エフロレッセンス、植生が含まれるブロックが異常として検出された。また、学習データとはコンクリートの色が異なる護岸下部のブロックも異常として検出された。

## 5. おわりに

本研究では、河川護岸画像からブロックを個別に切り出し、VAEを用いて変状の状態を定量的に評価する手法を提案した。ブロックの切り出しに用いたプレートマッチングは非常に単純な物体検出手法であり、実装は容易だがロバスト性が課題である。よりロバストな切り出し手法を確立するために、深層学習ベースの物体検出手法も検討する必要があると考えられる。また、切り出しにおいて検出




Fig. 3 Frequency distribution of anomaly score




Fig. 4 (a) Usual data with a low anomaly score, (b) Usual data with a high anomaly score, (c) Unusual data with a low anomaly score, (d) Unusual data with a high anomaly score



Fig. 5 Unusual blocks distribution (red square)

されないブロックはそもそも異常であるという推察が成り立ち、これについても検討したい。VAEによる異常検知では、正常データの多様性による再構成結果の揺らぎが課題である。今後は、頻出しない特徴を持つ正常データを入力した場合にも鮮明な再構成結果を出力するモデルを作る必要がある。また、ここでは画像の類似度を異常スコアに用いたが、異常スコアの妥当性について検討する必要がある。

## 参考文献

- 1) 藤井純一郎, 吉田龍人, 岡野将大, 天方匡純: 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, 人工知能学会全国大会論文集, 2021.
- 2) 立花亮介, 松原崇, 上原邦昭: 深層生成モデルによる非正規化異常度を用いた工業製品の異常検知, 人工知能学会全国大会論文集, 2018.
- 3) A. Kumar, P. Sattigeri and A. Balakrishnan: Variational Inference of Disentangled Latent Concepts from Unlabeled Observations, ICLR 2018 Conference Blind Submission, 2018.