

# 画像回帰モデルを用いた水位判読 AI の未経験水位への適用と

## 精度向上に関する検討

株式会社東京建設コンサルタント ○小島崇・早田研二・榮谷幸士・穴井大地

### 1. はじめに

画像を用いた水位判読は、量水標を用いる画像解析に基づく手法[1]が旧来より利用されている。近年では、様々な AI モデルを用いた試みも行われており、三宅らは YOLOv5 を用いたモデルが提案している[2]。水位判読に用いられる AI モデルには、大きく①回帰、②領域分割の 2 種類にわけられ、本稿では①回帰モデルについての検討結果を示す。

回帰モデルは、三菱電機の画像水位計測システム[3]に代表される様に、CNN(エンコーダ部)+DNN(回帰部)モデルなどがある。しかし、これらの AI モデル全般で共通して、「学習範囲内に目的変数の取りうる全ての値があることを前提とした内挿問題への最適化」であるために、未経験のイベント(データ)に対して、予測精度が保証できない課題がある[4]。

本稿では、未経験のイベント(水位)に対する適用性の向上と水位判読精度向上に関して、検討した結果を記す。

### 2. 水位判読システム概略

本稿では、図 1 に示す IR カメラ画像を用いた AI と画像解析(エッジ検出)を併用した水位判読システムの AI(画像回帰モデル)に関する検討結果を記す。

カメラは、10 分毎に 1 回(5 枚)タイムラプス撮影(IR 画像)を行い、クラウド上に構築した解析環境にアップロードされる。アップロードされた画像は、解析に必要な部分のみをトリミング、画像鮮明化(CLAHE)を行い、水位判読モデル(AI, エッジ検出)の入力画像となる。AI モデルから水面位置(pixel 座標)を求め、水面位置を中心にガウシアンカーネルを作成し、エッジ検出で得られた輝度勾配と掛け合わせ、補正された水面位置(pixel 座標)が得られる。最後に、座標変換(pixel 座標と水位の相関式)を行い、水位(観測所ゼロ点基準座標)を取得するものである。

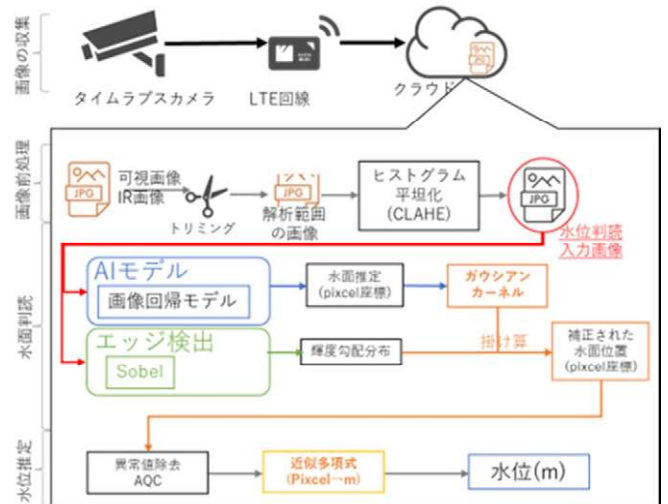


図 1 水位判読システム概要

### 3. 高精度化と未経験洪水への適用

#### 3.1 適用対象

本システムは、河川のコンクリート護岸を対象としている。水位判読を行うにあたり、カメラに対して護岸が正面に位置し、水際線がほぼ水平になる画角となっている事が望ましい。本稿では、図 2, 3 に示す 2 地点について検証を行った。観測水位および学習・検証・評価期間は図 4, 5 に示す。

#### 3.2 精度向上

AI モデルの高精度化には、いくつかの方法が考えられる。1つ目に、日光や影、雨や雪など自然の影響が精度に大きく影響を及ぼすため、画像の多様性を持たせる Data Augmentation を適用する。2つ目に、回帰モデルの答えは、期待値周辺に分布する事と、モデル・データによって誤差の分布が異なるため、アンサンブル学習や Boosting, Stacking が有用とされている[5]。3つ目に、未経験の事象(イベント)に対する拡張が考えられる。例えば、ダム流入量予測では、一言らは未経験規模の出水に対して、流出係数から、仮想的な降雨に対するダム流入量を設定し、学習データを作成している[6]。これは、水位判読モデルに




図2 水際線と評価範囲 (A地点: 昼間)




図4 A地点の水位と学習・検証・テスト期間

についても同様に、未経験洪水に対してデータを拡張する必要があると言える。4つ目に、AIモデルの高度化が考えられる。前原、藤井らは、ニューラルネットワークによる方法[7]からDNNに変更する事を試みている[8]。本稿では紙面の制約から、アンサンブル化と未経験洪水(水位)への拡張およびAIモデルの改良について説明する。

### (1) 推論のアンサンブル化

AIモデルによる水位判読では、画像上のノイズ・輝度分布、JPEG compression などにより、推論に誤差が生じる。またその誤差は、正解を中心に分布する事から、本システムでは、図2(緑枠)に示す様に、1枚の画像内に複数の評価範囲を設ける事で、1回の水位判読に対して複数回のAIモデルの推論を行い、誤差の低減を行っている。

具体的には、撮影された画像内に、矩形かつ同じ大きさの評価範囲を、水際線に対しておおむね平行かつ等間隔に配置する。評価範囲1つ1つを切り出し、AIモデルの入力画像とし、水際線のピクセル座標を求める。求められたピクセル座標と水位の関係は、評価範囲毎に関係式を作成し、水位に換算する。評価範囲毎の水位の平均と分散を求め、分散が閾値




図3 高水位データ作成例 (B地点: 夜間)




図5 B地点の水位と学習・検証・テスト期間

以内になるように、誤差が大きいものを順に棄却する事で、水位判読誤差の影響を低減している。

### (2) 未経験水位への拡張

本稿では水際線が流量に応じ鉛直方向に移動する特性と、護岸のテクスチャーが面的に大きく変わらない事から、図3に示す様に、評価範囲を下方に移動し、疑似的に高水位の画像を生成する事とした。

具体的には、観測水位が指定した値  $Hlim$  より高い画像に対して、図3で示した評価範囲(緑枠)を下方に設置すると、評価範囲内の水際線(赤線)の位置は評価範囲の上方に位置する。すなわち、高水位の場合の水際線の配置となる。

画像に対して、その時刻の水位(観測値) $Hwtl$  と、 $Hlim$  の大小関係  $if(Hwtl \geq Hlim)$  から、データ拡張を行うか否かを決定する。A地点:  $Hlim = 0.25(m)$ , B地点:  $Hlim = 0.60(m)$  とし、Trueの場合にデータ拡張を行う。評価範囲の基準となる左上, 右下のPixel座標を、水平方向のPixel座標  $x_p$ , 鉛直方向のPixel座標  $y_p$  を用いて、 $(x_{1p}, y_{1p}), (x_{2p}, y_{2p})$  とすると、評価範囲の変化量  $dw_p = W_p \times Random \times (k)$  とすることで、 $(x_{1p}, y_{1p} + dw_p), (x_{2p}, y_{2p} + dw_p)$  と求める事ができる。ここで、 $W_p$  は変化させる最大ピクセル数




図6 倍率の違いによる水位の比較(A地点)




図8 AIモデルの違いによる水位の比較(A地点)

(本検討では  $w_p = 25$ )であり,  $Random$  は 0 以上 1 未満の一樣乱数を表す.  $k$  は倍率であり, 上述の  $if(Hwlt >= Hlim) = True$  となる画像に対して,  $k$  回評価範囲を変えたデータを作成する.

### (3) AIモデルの改良

回帰モデルを用いた水面判読では, 入力画像から特徴量を抽出する過程(エンコード)において, 計算量・パラメータ量の観点から Convolution(畳み込み)を用いる事が一般的で, 効率的に特徴量抽出ができるとされていた. しかし, Transformer[9]の出現を機に Vision Transformer (ViT)など, エンコーダーに Transformer を用いる革新的なモデルが次々と発表されており, エンコーダを切り替える事で精度向上が期待される. 本稿では, Resnet101, EfficientNet v2, ViT の3つのモデルについて適用し, 精度検証を行った.

## 4. 結果と考察

本章では, 前述の2地点について, AIモデルを適用し, 3章(2) 未経験水位への拡張と, (3)AIモデルの改良の効果について, 水位判読結果から推論精度について比較した結果を示す.




図7 倍率の違いによる水位の比較(B地点)




図9 AIモデルの違いによる水位の比較(B地点)

### 4.1 データ拡張による未経験洪水への適用

ここでは, ViTモデルを用いて, 4章(3)で示したデータ拡張による効果を, 倍率  $k=0\sim 3$  について検証した. 倍率  $k=0$  は, 高水位への拡張を実施しない場合を意味する.

A地点の観測水位と, AIモデルによる推論された水位を倍率  $k$  毎に比較した図6に示す. 低水位においては, 倍率による差はほとんどなく, 観測水位を再現しているのに対し, 高水位時の結果では大きく差がでてい. 0倍は0.4m程度までしか推論できていないのに対して, 倍率を1,2,3と上げるに連れ, 高水位の再現性が高くなっている. 特に3倍は全体的に水位変化の再現性が高い結果となった.

B地点も同様に, 倍率  $k$  毎に観測水位との比較を図7に示す. A地点同様に, 高水位へのデータ拡張を行う事で, 学習範囲より高い水位に対して推論精度が向上する事が確認できた.

### 4.2 AIモデルと推論精度の関係

前述の通り, エンコーダに Convolution を用いる Resnet, EfficientNet と Transformer を用いる ViT について, 水位判読結果の比較を行った.  $k$  については, 各モデル共通で, A地点  $k=3$ , B地点  $k=2$  の場合の結



凡例：—— AI の推論結果(水際線, 直線近似)  
 \* AI の推論結果(評価範囲毎, 5枚の合成)




図10 誤判読の例(A地点:3/23 11:50)

—— Edge 検出による補正後(水際線, 直線近似)  
 \* Edge 検出による補正後(評価範囲毎, 5枚合成)



図11 高水位の水位判読結果(B地点:2/19 9:40)

果を図8,9に示す。

A地点の評価期間の結果から、ResNet, EfficientNet と比べ ViT は観測水位と良い一致を示しており、水位変動を適切に判読できている事が確認できる。しかし、図10に示す様に護岸が濡れている範囲で、水際を誤認識しており、評価範囲毎の AI の推論結果(\*印)もばらついている。ViT, EfficientNet どちらも、誤判読時には、AIモデルの評価範囲毎の推論結果はばらつきが大きくなっている事から、AIモデルの信頼性が評価できる可能性がある。

B地点もA地点同様の傾向があり、ViTは水位変動を適切に判読できている事が確認できた。評価期間の最高水位(学習範囲より高い水位)のViTによる水位判読結果の様子を図11に示す。この結果から、評価範囲全体で水際線を良好に判読できている事が確認できた。

## 5. まとめ

本稿では、水位判読システムの精度向上及び未経験の水位への適用について、検討結果を示した。ViTを用いたモデルは、Convolutionを用いたモデルに比べ、低水位、水位上昇時など全体を通して良い一致を示した。

未経験の洪水(水位)への適用策として、疑似的な高水位画像を教師データに追加した。これにより、学習期間の最高水位以上の水位を推論する事が可能になった。2地点について、同様の結果が得られたことから、新たな水位判読地点に対しても、高水位の画像が少なくても、推論できると考えられた。

今後観測システムとして運用を行うためには、多地点への展開と、水位判読の信頼性の定量的な評価手法など、検討が必要と考えられる。

## 参考文献

[1] 前原 秀明, 長瀬 百代, 服部 亮史, 平 謙二,

2016, 濁水位時の量水板画像を利用した CCTV カメラ映像からの水位計測方法, 写真測量とリモートセンシング, Vol. 55, No.1, pp. 66-68.

[2] 三宅 壮太, 石塚 正秀, 山本 高広, 玉置 哲也, 松岡 聡, 一見 和彦, 2022, YOLOv5 を用いた赤外画像の解析による水位計測システムの開発, AI・データサイエンス論文集, Vol.3, No.J2, pp.479-487.

[3] 芦田 泰, 画像式水位計測システム, 2021, 三菱電機技報, Vol.95, No.12.

[4] 小林 洋介, 渡邊 真也, 2021, 大雨災害時の北海道内ダム流入量予測へのスパースモデリングの適応とその評価, 北海道河川財団, 研究所紀要, Vol. 32, pp. 41-68.

[5] 坂口 大珠, 石田 桂, 横尾 和樹, 永里 赴義, 木山 真人, 尼崎 太樹, 2021, アンサンブル学習による河川流量推定における弱学習器に対する考察, AI・データサイエンス論文集, Vol. 2, No. J2.

[6] 一言 正之, 荒木 健, 箱石 健太, 遠藤 優斗, 2022, 深層学習を用いたダム流入量予測における学習データ拡張方法の提案—未経験規模の出水に対する適用性の向上—, 河川技術論文集, Vol. 28, pp. 67-72.

[7] 前原 秀明, 長瀬 百代, 口 倫裕, 鈴木 利久, 平 謙二, 2019, ディープラーニングに基づく CCTV カメラ映像からの水位計測方法, 写真測量とリモートセンシング, Vol.58, No.1, pp. 28-33.

[8] 藤井 美穂, 前原 秀明, 長瀬 百代, 口 倫裕, 鈴木 利久, 平 謙二, 2022, 深層学習による CCTV カメラ映像からの水位計測, 写真測量とリモートセンシング, Vol.61, No.3, pp. 127-128.

[9] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin, 2017, Attention Is All You Need, arXiv, 1706.03762.