

## 護岸ひび割れ検出 AI の高精度化に向けたひび割れ分布に基づくデータ増強

八千代エンジニアリング株式会社 正会員 ○吉田龍人, 藤井純一郎, 天方匡純

### 1. はじめに

インフラ老朽化の対策として、維持管理の効率化が急務となっている。効率化の達成に向けて点検 AI 開発のニーズは高まっているが、AI の教師となる大量の異常データの収集は困難で、AI 導入の障壁となっている。本研究では、護岸のひび割れ検出 AI の作成を題材に、データ増強によって少ないデータでより効率的に学習を行う手法を検討する。特に独自のひび割れ評価法によってひび割れの写った画像のみを増強したときのモデルのひび割れ検出精度の違いを検討し、その結果についてまとめる。

### 2. 護岸画像のひび割れ検出とその課題

図-1 に解析対象である護岸画像を示す。この画像はドローン自律飛行によって 6000×4000px の解像度で撮影したもので、概ね 2mm/px を満足している。斎藤<sup>1)</sup>らはこうした画像を縦横 224px のメッシュ状にクロップしたもの教師にして学習させたモデルで、高精度なひび割れ自動検出が可能となることを示した。本研究では斎藤らの手法に準拠しつつ、データ増強によって高精度なモデルを作成する手法を検討する。

ひび割れ検出 AI の学習において、ひび割れの px (正例) とそれ以外の px (負例) の不均衡は大きな課題である。老朽化の激しい図-1 であっても正例は画像の 1% 以下であり、効果的なデータの前処理が必要とされる。一般に不均衡データの学習時には、オーバーサンプリングとアンダーサンプリングの 2 手法が前処理として用いられるが、本研究では少ない正例データを増強する目的で、オーバーサンプリング手法に着目する。

### 3. 並進によるデータ増強

深層学習において、教師データに微小な変化を与えて、疑似的にデータ量を増強する手法は一般的である<sup>2)</sup>。画像の並進はデータ増強の 1 手法であるが、並進を行うと画像が変位した分だけ情報量の損失が増える。そこで、本研究ではメッシュの区切り位置を縦および横に 112px ずらして再度クロップすることで、情報量を

維持したまま疑似的に並進を可能とするデータ増強を行った。ただ、単にクロップ位置をずらすだけでは、ひび割れの写っていないデータも同時に増える。そこで、再度クロップした画像に対してひび割れ分布を評価し、評価基準値として設定した閾値を満たす画像のみを教師データに加える手法を検討した。

ひび割れ分布はラベル画像に対するラベリング処理によって取り出した個別のひび割れ要素ごとに評価した。各要素に対して、要素の面積、要素を構成する個別のピクセルの平均値および標準偏差を軸ごとに算出した。ひび割れ評価の算出結果例として図-2 に元のデータセットにおけるひび割れ分布の評価結果を示す。なお、平均値は小さなひびの影響を無視するため、面積が 650px 以上のひび割れのみで評価した。これらの図より、護岸画像に正例が極めて少ないとや、布積みの護岸の特性により、横に伸びるひび割れの数が卓越していることが示された。この評価手法によって、クロップ位置をずらして再度クロップした画像を評価し、面積が 650px 以上のひび割れを持つ画像だけを教師データとして加えた。ここで 650px の閾値は、十分に大きいひび割れを取り出す目的で定性的な判断に基づいて設定した値である。既往の手法では 6000×4000px の画像 50 枚から、合計 12532 枚の画像が生成されたが、本手法を適用することで 14688 枚となり、17.2% の画像を増強することができた。



図-1 護岸画像

キーワード Augmentation, Segmentation, AI, 護岸, ひび割れ

連絡先 〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー 八千代エンジニアリング(株) TEL 03-5822-6843

#### 4. 学習結果

前章で示した 14688 枚の増強ありデータセットと、12532 枚の増強なしデータセットを使って、同条件下で学習を行い、モデルの精度を比較した。図-3 に学習曲線を示す。学習曲線においては、卓越する負例に影響して、増強なしのモデルの方が良い accuracy および loss となった。未学習の画像に対してひび割れ検出を行った例を図-4 に示す。図より増強なしのデータセットを作成したモデルに見られた画像上部の過検出が、増強ありのデータセットで作成したモデルは抑制されていることが分かる。実際に 17 枚の未学習画像のひび割れ検出結果から PR (Precision-Recall) 曲線を算出した結果において、AUC が 0.439 から 0.453 へと向上し、mIoU は 0.362 から 0.386 となった。以上より本研究で用いたデータ増強技術は、データの不均衡の解消により学習曲線の見かけの精度は悪化するが、モデルの精度向上に効果があったと判断した。

#### 5. 最後に

本研究では、画像の並進とひび割れ分布の評価によってデータを増強する手法を検討し、データセットの増強の有無がモデルの精度に与える影響を調べた。その結果、増強によってモデルの精度が向上することが示された。今後は本手法によって何%の正例教師画像を削減できるかを明らかにするとともに、ひび割れの分布による推論精度の違いを調査し、より効果的にデータ増強を行う手法を検討する必要があると考える。

#### 参考文献

- 齋藤彰儀, 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.
- Connor Shorten, Taghi M. Khoshgoftaar: A survey on Image Data Augmentation for Deep Learning, Journal of Big Data 6, 60, 2019.

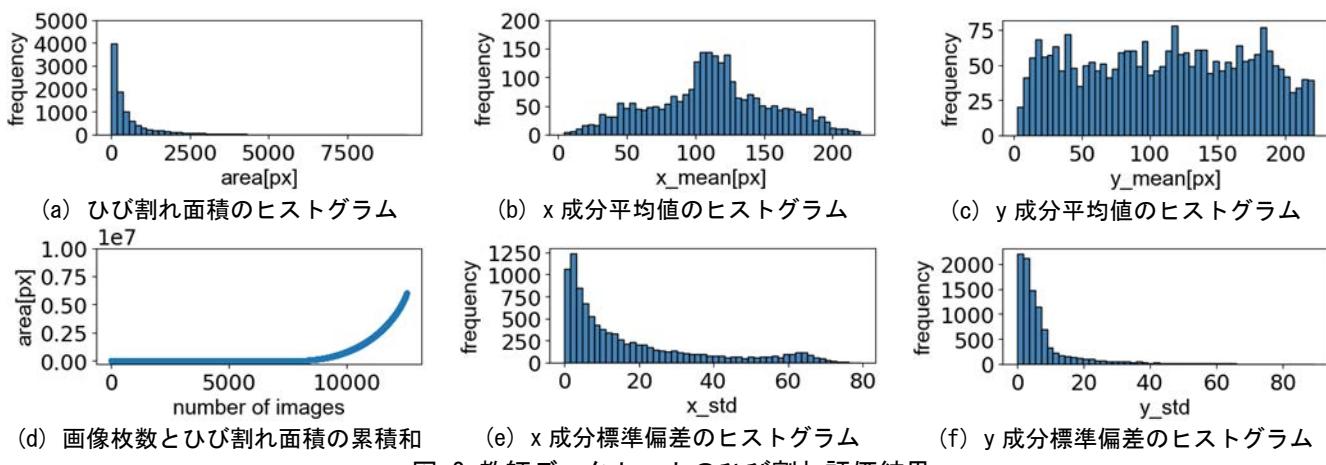


図-2 教師データセットのひび割れ評価結果

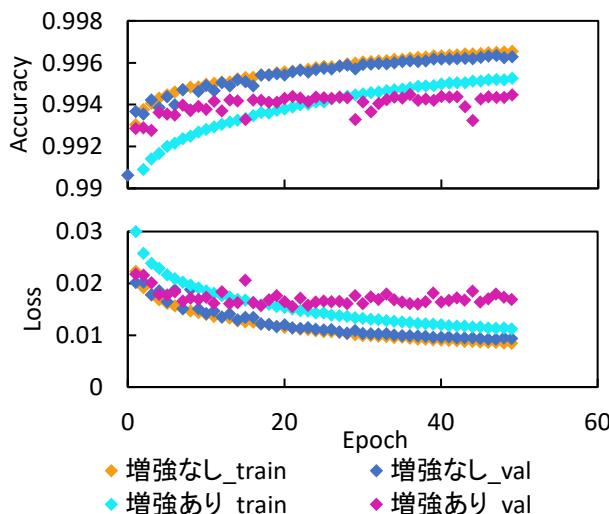


図-3 学習曲線

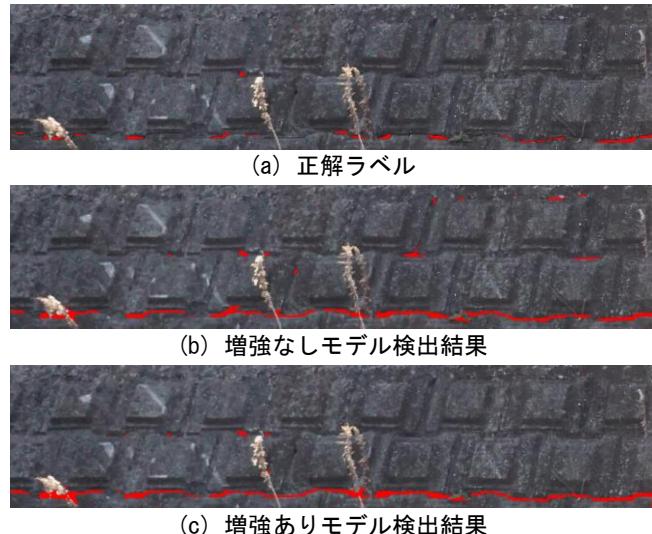


図-4 未学習画像のひび割れ検出結果