

深層学習を用いたコンクリート表面におけるひび割れ検知手法に関する研究

茨城大学大学院 学生会員 ○沈 海峰
茨城大学大学院 正会員 呉 智深

1. はじめに

近年、橋梁やトンネルなどのコンクリート構造物の劣化・損傷の顕在化が大きな問題となっており、そのような構造物に対して変状の早期発見を行い、適切に評価、記録を行なうことが強く求められている。しかし、点検技術者の数は十分ではない。これらの課題に対し、近年、急速に発展している AI（人工知能）を活用した建設現場の生産性革命（i-Construction）を推進している。

このような背景から、コンクリート表面を撮影し、深層学習によりひび割れを検出するという研究が広く行われている。横山らは畳み込みニューラルネットワークを用いて、コンクリート表面上の変状現象を与えられた画像の中から認識できる分類器を構築した、ひび割れを矩形領域として導出している¹⁾。しかし、損傷評価のためには画素単位でのひび割れ抽出も行いたいという需要も考えられる。

そこで、本研究では、コンクリート表面ひび割れの画像から画素単位でひび割れの検出精度を改善することを目的とする。Res-UNet 用いてひび割れ検出手法を提案する。作成したコンクリート表面ひび割れのデータセットを用いて、既存手法と比較することで、その有効性を評価する。

2. 提案手法

2.1 ネットワークの構造

U-Net の構造は第 1 図のように Encoder と Decoder の同じ大きさの層を結び付け、小さな層を下側にずらした U 字の階段状に変形した形をしている。Encoder と Decoder の同じ階層の層をつなげることで各層に情報を伝えることができるため、高い精度が得られる。本研究のネットワーク Res-Unet の構造は U-Net をベースに構築した。2 層以上の場合は、畳込み層である conv 層の代わりに、畳込み層を含む Residual Block (residual conv block) 層を入れた。層が深くなっても学習しやすくするためである。第 2 図に通常の構造と Residual Block を示す。

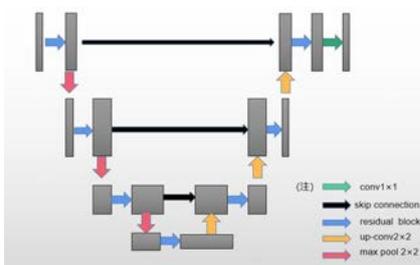


図-1 ネットワーク構造

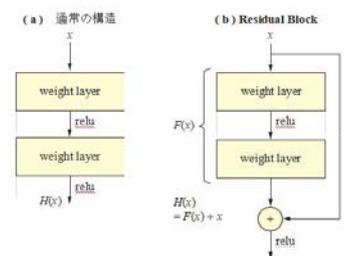


図-2 通常構造と Residual Block ²⁾

2.2 損失関数

学習に使用する損失関数は、タスクごとに出力された損失を重み付き和で算出して使用する。本研究では、セマンティックセグメンテーションタスクにおいて、クラス不均衡がある場合にもうまく学習出来るように、正解セグメンテーション画像と予想セグメンテーション画像の間の境界部分で損失関数を定義した Boundary Loss を導入する。また、Boundary Loss を Dice loss に加えて用いることで、Boundary Loss の精度を増すことが期待できる。

ひび割れ検出, 深層学習, セマンティックセグメンテーション, 画像解析

連絡先〒316-8511 茨城県日立市中成沢 4-12-1 茨城大学工学部 TEL : 0294-38-5151 FAX : 0294-38-5268

3. 評価実験

3.1 実験内容

本研究で提案する Res-UNet の有効性を検証するため、以下の 4 項目について比較の実験を行い、それぞれについて精度が向上しているか検討する。

1. U-net (baseline) +BCE loss(一般的な交差エントロピー損失)
2. Res-Unet +BCE loss(一般的な交差エントロピー損失)
3. Res-Unet+Focal loss
4. Res-Unet+BD loss (Boundary and Dice loss) (提案手法)

3.2 評価実験の設定

データセットは、コンクリート曲げ試験で撮影したデジタル画像を 60 枚 (画素数 6000×4000) に対し、300×200 px の範囲を切り出した小領域の画像を 328 枚得られた。また、データセットに多様性を確保するため、インターネット上から、様々なひび割れ写真を 300 枚入手し、それらもデータセットに追加した。画像データに対してアノテーションを行って教師データを作成する必要があるため、本研究では、Labelme を用いて教師データを作成した。評価指標にはスライスごとの Dice 係数、Recall、および Iou を平均した、mDice、MAR、mIou、を用いる。学習には ADAM を用い、バッチサイズを 8 として、0.0001 の学習率で 100 epoch 学習させる。

4. 実験結果

実験結果を表 1 に示す。U-net/ BCE Loss と Res-Unet/ BCE Loss 比較すると、MAR 以外の評価手法において Res-Unet による結果が高くなっていることがわかる。また、すべての評価手法において提案手法の Res-Unet/ BD Loss による結果が高くなっていることがわかる。Res-Unet/ BCE Loss と提案手法の Res-Unet/ BD Loss における MAR 比較と BD loss 用いて学習した提案手法は BCE loss より 6%ほど向上している。Recall が高いということは検出漏れを防ぐ性能が高いということである。

5. おわりに

本研究では、作成したひび割れデータセットを用いて提案手法を評価したところ、提案手法は比較的高い精度でひび割れを画素単位で検出することがわかる。また、BDLoss を導入することで Recall を高くし、検出漏れを防ぐ効果があることが示された。

今回、Res-UNet によりコンクリート表面ひび割れの写真から画素単位でひび割れ検出結果には、False-Positive となる予測が多いことが課題として残っている。今後、予測領域を精緻化することで False-Positive を減らし、より正確なひび割れ検出を行う手法を検討していく。

表 - 1 実験結果

手法	MAR	mDice	mIou
U-net/ BCE Loss	0.820	0.839	0.731
Res-Unet/ BCE Loss	0.802	0.848	0.742
Res-Unet/ BD Loss	0.882	0.868	0.760
Res-Unet/ Focal Loss	0.830	0.847	0.738

6. 参考文献

- 1) 横山傑, 松本高志: Deep Learning によるコンクリートの変状自動検出器の開発と Web システムの実装, 土木学会論文集 A2(応用力学), Vol.73, No.2(応用力学論文集 Vol.20), I_781-I_789, 2017.
- 2) 栗野友貴, 米倉一男, 宮澤優斗: 金属組織観察における深層学習を用いた画像認識技術の研究, IHI 技報 = Journal of IHI technologies 60 (1), 52-59 2020.