

腐食および鉄筋露出を対象とした損傷検知システムの開発

長岡工業高等専門学校

○齋藤 快

長岡工業高等専門学校専攻科 学生会員

小林 瑚伯

長岡工業高等専門学校

正会員

井林 康

1. はじめに

国内では2m以上の道路橋が72万橋以上存在し、平成26年度からは5年に一度の目視点検が義務付けられているが、点検業務を行う技術者が慢性的に不足しており、近年画像認識AIを活用した橋梁点検の効率化が期待されている。本研究では、画像から損傷領域を推定し、知識や経験が不足している点検従事者に対しての視覚的支援及び、時系列ごとの損傷面積変化の推定を行うことを目的として、道路施設点検データベース xROAD(クロスロード)の点検調書から、橋梁の損傷画像を取得し、それを元にセマンティックセグメンテーションを用いた損傷検知システムの開発を行った。

2. セマンティックセグメンテーション

2.1 概要

セマンティックセグメンテーションは、画像内の全画素にラベルやカテゴリを関連付けるディープラーニングのアルゴリズムであり、本研究では腐食及び鉄筋露出の判定に用いる。

2.2 教師データの作成

本研究では、データセットに用いる損傷画像の収集に、国土交通省が構築しているデータプラットフォームの xROAD¹⁾を用いるが、損傷が確認された橋梁を指定し、画像をダウンロードすることができるため、データセットの作成の効率化が図れる。

xROADから収集した損傷画像は、LabelMeというアノテーションツールでラベル付けを行い、画像処理ライブラリであるOpenCVとPythonを用いてマスク画像を出力する。収集した損傷画像とマスク画像は128×128ピクセルにリサイズし、それぞれを入力画像、正解画像として教師データを構成する。

教師データは十分な枚数を確保できなかったため、いわゆる水増しによるデータの拡張を行った。拡張手法には、水平反転、回転、ぼかしを用いてデータ

数を9倍に拡張した。教師データは腐食、鉄筋露出共に300枚作成をしたため、データセットは学習用のTraining dataに250枚を9倍に水増しした2250枚、検証用のValidation dataに50枚用いた。

3. 各学習の条件と結果

3.1 学習方法

学習モデルの構築には、ソニーのNeural Network Consoleを用いた。U-Net, ResNet, FCNの3つの構造が異なるネットワークを設計し、各カテゴリにおける評価結果の比較を行う。各ネットワークの学習回数は100回、損失関数はBinary Cross Entropy、活性化関数はSigmoid関数で統一し、FCNとU-Netでは最大値プーリングと最大値逆プーリングを用いた。ネットワークの構造のイメージを図-1に示す。

FCN(Fully Convolutional Network)は、セマンティックセグメンテーションに特化したネットワークであり、本研究では、畳み込み層、プーリング・逆プーリング層で構成した。畳み込み層は、フィルタを用いて画像の特徴を抽出し特徴マップを作製する層である。プーリング層では特徴マップから最大値を示すインデックスを抽出し、逆プーリング層では最大値を取ったインデックスに基づいて解像度の拡大を行う。

U-Netはエンコーダ・デコーダ層を持つネットワークである。エンコーダ層は畳み込み層とプーリング層、デコーダ層は畳み込み層と逆プーリング層で構成される。また、エンコーダ層とデコーダ層はスキップ接続で連結されており、FCNではプーリング層を通過することで失われる空間的な情報を、解像度を保ったままデコードに伝搬することができる特徴がある。本研究では、エンコード層が2層から8層までの評価結果を比較する。

また、コンクリート表面の損傷を検出する研究にはResNetをベースとしたネットワークが用いられており²⁾、高い性能を示している。本研究では、多層

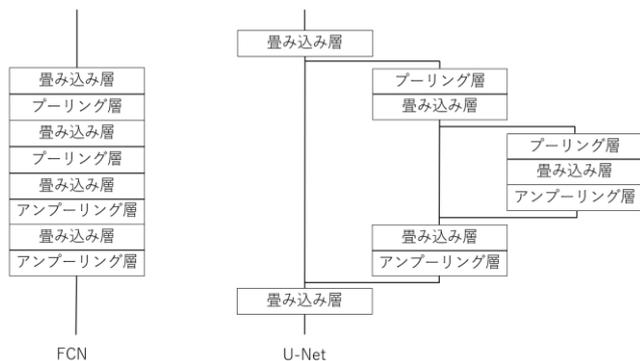


図-1 ネットワークの構造のイメージ

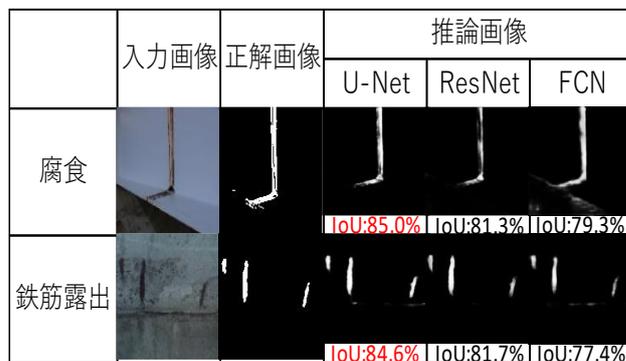


図-2 各ネットワークの推論画像の例とIoU

化に適している特徴から50層のResNetを用いた。

3.2 評価指標

本研究では、時系列ごとの損傷面積の変化を推定することを目的としていることから、評価指標として損傷の輪郭を判定できるIoUを用いた。

$$IoU = \frac{A \cap B}{A \cup B}$$

Aを正解画像の該当した領域、Bを推論画像の該当した領域とし、 $A \cap B$ は、2つの領域の共通部分を表し、 $A \cup B$ は、2つの領域の和集合を表す。

3.3 評価結果

各ネットワークの抜粋した推論画像の例とIoUを図-2に示す。ここで、U-NetのIoUは、最も高い結果となった層の値を用いており、腐食では7層、鉄筋露出では4層の値である。腐食と鉄筋露出の2つのカテゴリの推定において、全てのネットワークが75%を超える結果となり、ある程度の損傷領域の推定はどのネットワークでも行えることが分かった。中でもU-NetのIoUが最も高い結果となった。U-NetとFCNのネットワークの構造の大きな違いは、スキップ接続の有無である。FCNではプーリング層を通過することで失われる空間的な情報を、U-Netはスキップ接続により、デコード層に伝搬することができ、画像の位置情報や細部の情報と、プーリングによって特徴を抽出した情報と組み合わせて学習したことでIoUが高くなったと考えられる。また、U-Netの各層の評価結果を表-1に示す。U-Netの推論において、腐食と鉄筋露出は共通してエンコード層が4層以上のものが高いIoUを示したことから、本研究で対象とした2つのカテゴリにおいてはエンコード層を増やし、より多くの特徴を学習することで

表-1 U-Netの各層におけるIoU

	2層	3層	4層	5層	6層	7層
腐食	78.3%	82.0%	82.3%	82.9%	84.3%	85.0%
鉄筋露出	79.7%	81.4%	84.6%	84.5%	84.0%	83.7%

IoUが向上する傾向があることが分かった。

4. まとめと今後の展望

本研究ではセマンティックセグメンテーションを用い、xROADから収集した損傷画像から損傷検知システムを作成した。作成した3つのネットワークは全てIoUが75%を超える結果となり、本システムは点検従事者に対する視覚的支援及び、時系列ごとの損傷面積変化の推定に対して有用であると考えられる。中でも最も高いIoUを示したU-Netは計算効率が高いため、遠隔臨場によるリアルタイムでの点検支援を行えることが期待される。また、平面画像から、時系列ごとの損傷面積変化の推定を行うには、同一の画角から撮影した画像を用いなければならない問題があるため、今後は平面画像を3次元データに変換し、推論を行えるようにシステムを改良していきたい。

参考文献

- 1) 全国道路施設点検データベース (xROAD)
<https://road-structures-db.mlit.go.jp/>
- 2) 青島 互佐ら：深層学習によるセグメンテーション手法を用いたコンクリート表面の変状領域の検出, AI・データサイエンス論文集1巻J1号, 2020