

DeepLabv3+を用いた橋梁腐食損傷のセマンティックセグメンテーション

埼玉大学 学生会員 ○劉 佳明
 埼玉大学 正会員 党 紀

1. はじめに

近年、橋梁インフラの老朽化が問題視され、適切な維持管理が求められ、土木構造物の5年に1回の定期点検が義務付けられた。さらに、橋梁保全業務にかかわる土木技術者の数は年々低下している。橋梁の点検作業において、UAV や AI などを活用する技術の開発は近年注目されている。特に、ひび割れなどの損傷と比べ、鋼製構造物の腐食損傷は、画像処理において、色の特徴や境界線が不明確な場合がため、損傷認識を行うためにまだ検討すべき課題である。本研究では、2018年開発された DeepLabv3+を用いて、腐食損傷の自動検出を試みた。さらに、ファインチューニングの使用により、境界線部分での検出精度を向上した。また、誤認識の問題を削減するため、アノテーションによるモデルへの影響、ハイパーパラメータの変更による精度の改善、背景写真の追加による誤認識問題の削減についても検証した。

2. DeepLabv3+によるセマンティックセグメンテーション

図-1 に示すように、DeepLabv3+モデルは、エンコーダ・デコーダ構造を持ち、Atrous convolution と Spatial pyramid pooling を利用し、境界線を正しく検出でき、広範囲に散布される腐食損傷にも対応できると思われる。

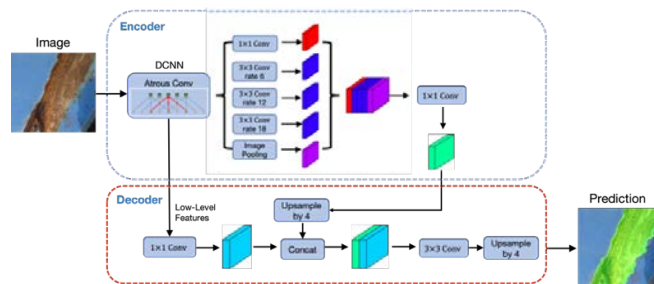


図-1 DeepLabv3+モデル

損傷画像は、橋梁定期点検調査書から腐食損傷の画像を収集し、UAV を使用した橋梁点検のビデオから、画像データに切り取ったものを利用した。画像に対してオープンソースの VGG Image Annotator (VIA) ツールを使ってアノテーションを行った。

はじめに、橋梁定期点検調査書から 1916 枚写真と 75 枚の 4K ビデオから 400×400 ピクセルにサイズ変更をした UAV 写真を混ぜて、合計 1991 枚の画像を利用し、モデルの評価を行った。比率は 8 : 2 で、訓練用 : 1592 枚、バリデーション用 : 399 枚に配分した。過学習を評価するため、191 枚の写真を用意し、モデルのテストをした。

通常のモデルと PASCAL VOC と SBD データセットで予め訓練し、ファインチューニングをしたモデルと比較を行った。バリデーションデータでの評価を見ると、ファインチューニングを用いたモデルは 3.11% mIoU を向上し、80.19% になった。テストデータでの mIoU は 77.36% であり、少し過学習が起こった。図-2 に示すように(緑は腐食)、(a)と(b)はバリデーションデータからの検出結果であり、(c)はテストデータでの検出結果である。ファインチューニングがある場合はモデルが正しく境界線を識別でき、(b)に示すように、人の手のような背景にも正しく識別できた。本研究では、Google Colaboratory pro を使って、コードを実行し、GPU は Tesla P100 である。テストデータセットでの処理速度は 18 FPS であり、4K サイズの写真を試したところ、0.2 FPS に落ちた。現場でリアルタイムの橋梁点検は困難であることが分かった。

3. 学習結果の最適化

(1) アノテーションの改善

キーワード 橋梁点検, 人工知能, 深層学習, UAV, DeepLabv3+

連絡先 〒338-5870 埼玉県さいたま市桜区下大久保 2 5 5 埼玉大学 建設構造工研究室 劉佳明 TEL 048-858-3005

前章で利用したテストデータは訓練・バリデーションデータと写真の選択やアノテーションの判断が違いため、新たなデータセットでは前回の訓練用写真とテスト用写真を混ぜて、モデルへの影響を確認した。合計2050枚の写真を、ランダムで1745枚を訓練用、305枚をバリデーション用、132枚をテスト用に再配分した。訓練用写真数が増えたが、逆に評価指標が低下した。アノテーションの精度は訓練データを通して、モデルに影響を及ぼすことが分かり、アノテーションの質は重要であるが分かった。

(2) ハイパーパラメーターの最適化

過学習問題を解消するために、ハイパーパラメーターの最適化を行った。Batch size を大きくすることにより、mPA が改善される傾向が見られた。Batch size の拡大によりデータセットの全体的な特徴を学習でき、mPA の向上につながったと思われる。また、Epoch 数を2倍することで、PA と fwIoU の向上の一方、mPA と mIoU の劣化が見られた。これは、精度が上がりやすい背景の部分影響が大きくなり、過学習の傾向が見られた。最後に、Epoch を2倍、Batch size を2倍すると、テストの mIoU は0.51%とわずかに上がって、77.87%になった。これにより Batch size の増加はモデルの過学習を抑えることが分かる。

(3) 背景写真の追加

背景の誤認識を減らすため、UAV から撮った写真を背景写真としてデータセットに追加した。5つの橋から10枚の写真を512×540ピクセルにサイズ変更し、合計108枚の画像を追加した。別橋梁の写真を使ってテストを行った。図-3に示すように、背景の誤認識が少なくなったことが分かった。

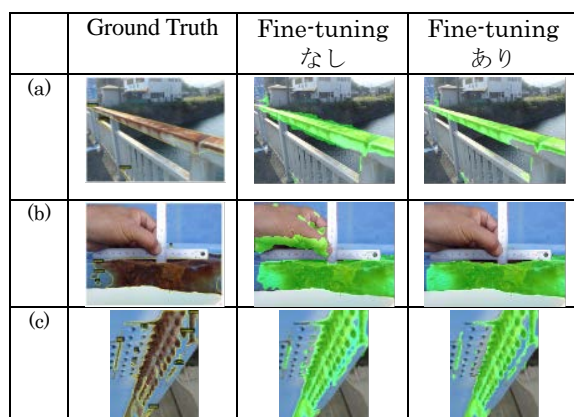


図-2 ファインチューニングの結果例

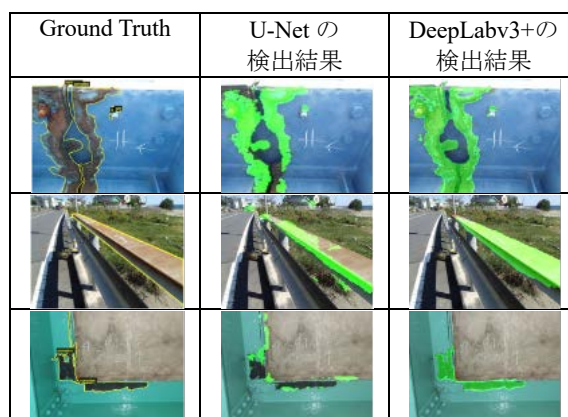


図-4 モデルの比較



追加前



追加後

図-3 背景写真の追加

(4) 既往モデルとの比較

図-4に示すように、境界線の検出、背景の検出、個体の検出は、DeepLabv3+モデルがU-Netモデルより優れることが分かった。

4. まとめ

本研究では、モデルの境界線の検出精度を向上できたが、背景の誤認識はまだ存在している。背景写真の追加やモデルの改良は今後の課題になる。人によるアノテーションの判断はモデルの精度に影響し、判断水準の統一などデータの質に関しても今後の課題である。

参考文献

・ Chen, L., Zhu, Y., Papandreou, G., Schroff, F., Adam, H.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, ECCV, 2018