

目視点検の損傷画像による鉄筋露出セグメンテーションの転移学習

Eye-inspection Image-based Transfer Learning Rebar Expose using Semantic Segmentation

中島 道浩^{*1} 安野 貴人^{*1} 永富 大亮^{*1} 野田 一弘^{*1} 青柳 聖^{*1} 関口 斎治^{*1}
 Yasuno Takato, Nakajima Michihiro, Nagatomi Daisuke, Noda Kazuhiro, Aoyanagi Kiyoshi, Sekiguchi Seiji

^{*1} 八千代エンジニアリング株式会社
 Yachiyo engineering, Co., Ltd.

When civil infrastructures have been deteriorated, efficient and accurate diagnosis are required. Especially in municipalities, the shortage of technical staff and budget constraints on repair expenses have become a critical problem. If we can detect damaged photos automatically per-pixels from the record of the inspection record in addition to the 5-step judgment and countermeasure classification of eye-inspection vision, then it is possible that countermeasure information can be provided more flexibly, whether we need to repair and how large the expose of damage interest. Generally speaking, rebar exposure is frequently occurred, and there are many opportunities to judge repair measures. This paper proposes three damage detection methods of transfer learning which enables semantic segmentation in an image with low pixels using damaged photos of eye-vision inspection. In fact, we show the results applied this method using the rebar exposed images on the real bridges (143words).

1. はじめに

近年,土木構造物の劣化が進行しており,コンクリート構造物も多くを占める.特に地方自治体において,技術職員の人材不足に加え,維持管理費に占める点検費用の割合が多いことから,定期点検の効率化が喫緊の課題となっている.社会インフラの点検効率化を実現する手法として,ディープラーニングを適用する機会があり,既往研究が見られる.橋梁は,5 年に 1 回の近接目視点検が義務付けられており,損傷画像の蓄積がある[国交省 2014].点検調書に貼り付けた損傷画像の活用ができれば,過年度の定期点検データを劣化学習の入力に用いることが可能となる.従来の定性的な 5 段階判定に加え,損傷画像から損傷の程度を数値のスコアとして自動算出できれば,修繕対策をすべきか,修繕候補のなかで優先順位を考える対策情報として有用である.橋梁,建築物,プラント等のコンクリートひび割れ検出については,既往の研究がある.ひび割れは発生頻度が多く,教師画像を比較的生成しやすい.一方,剥離・鉄筋露出は,放置しておくと鉄筋の腐食が進行するため,ひび割れよりも構造物の健全性に与える影響が大きいと考えられる.しかしながら,剥離・鉄筋露出の検出モデルについては総じて就いたばかりであり,劣化学習の手法として確立しているとは言い難い.剥離は,目視点検の画質を用いることでは正確な検出が困難であるものの,鉄筋露出は,目視点検の画質を用いて劣化学習モデルを構築できる可能性がある.本稿では,近接目視点検の損傷画像を用いたコンクリート損傷の

セマンティック・セグメンテーション(以下,セグメンテーションと略す)を適用する実践的な手法を提案する.実際に,橋梁の損傷画像のうち,鉄筋露出に着目し,疎な損傷画像に対して本手法を適用した結果を示す.最後に,損傷検出モデリングの課題に言及する.

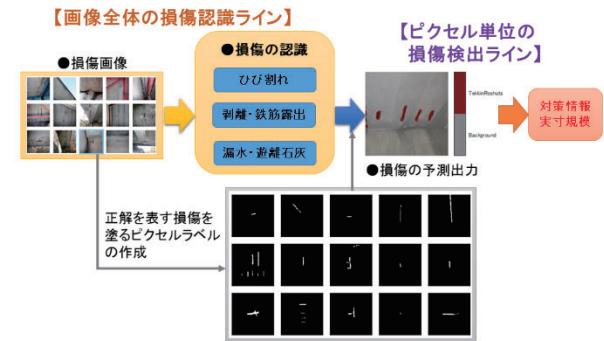


図 1 目視点検の損傷画像から認識と検出までの劣化学習ライン

2. 損傷検出の既往研究

2.1 インフラの損傷検出に関する既往研究

2002年より,橋梁の継続監視のために,ニューラルネットワーク(ANN)を用いた損傷検出の解法に関する研究の蓄積がある[Wu 2002][Chun 2015].最近,15年間に,ANNをはじめ,PCA, SVM, GA等の解法を用いた機械学習の損傷検出モデリングが多数行われている[Gordan 2017].2012年に,深い層の畠み込みニューラルネットワーク(CNN)が1,000クラス100万枚の画像分類において,高い精度を発揮する可能性[AlexNet 2012]が報告されてから,CNNの解法は,画像全体のラベル分類,物体検出,ピクセル単位のセマンティック

ク・セグメンテーションに対して、従来の解法よりも高い精度をもたらす研究が盛んになっている。土木構造物の損傷検出においても、道路舗装、建築物、橋梁のひび割れ、腐食を対象に、画像全体ラベルの損傷分類[Gopalakrishnan 2018][Ricard 2018]、損傷セグメンテーション[Hoskere 2017]の研究が見られる。734枚の損傷画像に対し、損傷なし、剥離のみ、鉄筋の露出（錆なし、錆あり）の4クラスの損傷セグメンテーションを行うため、深いCNNが適用されている[Guillamon 2018]。しかし、損傷クラスの内訳は、3つ目のクラスに510枚と偏り、訓練画像の歪みが否めない。損傷画像のサイズは、640 x 480から1,600 x 1,200まで多岐に渡る。このような様々な画像サイズの入力においても、FCNの3種類のCNNモデルを適用することにより、予測と真実の一致を表す指標 mIoU（クラス平均IoU）が、0.6～0.8の水準まで学習できることが示された。しかしながら、CNNの解法を駆使した損傷検出モデリングは、緒に就いたばかりであり、橋梁の損傷検出の汎用手法が確立されたとは言い難い。本稿では、橋梁の近接目視点検における損傷画像の特性を考慮した損傷セグメンテーションの実用的な手法を提案する。

表2 検出対象とする損傷と背景のピクセル単位の比較

208枚の鉄筋露出が映る損傷写真の例	損傷画像のピクセル総数	1枚当たり平均ピクセル数	1枚に占める割合
背景(Background)	63,683,619	306,171	98.9%
検出対象の損傷(ROI)	725,251	3,487	1.1%
1枚の合計	64,408,870	309,658	100.0%

2.2 目視点検の損傷画像の特性

本稿で対象とする橋梁の近接目視点検において鉄筋露出が映っている損傷画像208枚を通じて、損傷画像の特性を考察する。本特性に一般性は約束できないものの、損傷画像の活用の手掛かりとなると考える。ここで、剥離・鉄筋露出の一般的性状・損傷の定義は、コンクリート部材の表面が剥離している状態を「剥離」といい、剥離部で鉄筋が露出している場合を「鉄筋露出」という。5段階の評価区分は、a, b : 損傷なし, c : 剥離のみが生じている, d : 鉄筋が露出しており、鉄筋の露出は軽微である, e : 鉄筋が露出しており、鉄筋が著しく腐食又は破断している[国交省 2014]。表2に、検出対象とする損傷領域とそれ以外の背景の領域をピクセル

単位でカウントした集計値を示す。目視点検の画像は、撮影距離と画質が完全に統一できるとは限らない。1枚当たりの平均ピクセル数は、30.9万画素である。このなかに、対象とする損傷が占める割合は、高々1.1%に過ぎない。損傷画像の特性は、「損傷領域の占める割合が疎」である。

表3 対象とする損傷写真の画質分布

縦	横	1枚のピクセル総数	最小画素に対する倍率	枚数
378	504	190,512	1.00	163
540	720	388,800	2.04	12
852	1,113	948,276	4.98	33

表3に、208枚の損傷画像における画質サイズの内訳を示す。最小画素のものに対して、2～5倍のばらつきがある。縦横のサイズは、実際には13種類があり、それらを3つのグループに分けた場合の中央値で集計した。このように、損傷画像の特性は、「画像サイズの不均一性」である。現場の作業環境と使用するカメラの制約条件から、損傷との撮影距離は、厳密に一定距離が保持されるとは限らない。過年度の損傷画像を活用する場合、小さい画像サイズを含む、撮影距離が一定でない入力画像においても活用できる手法が求められる。今回、提案する転移学習の手法は、入力画像を縦横 224 x 224 にリサイズし、枚数の少なさを補強するために、+/-30度の回転をランダムに行い生成する。通常、画像分類モデルでは、検出対象が小さく遠目に移っている場合、ズームし画像の中央に位置するように切り出すことが多い。しかし、本稿で提案する損傷検出セグメンテーション・モデルは、畳み込みニューラルネットワーク（CNNと略す）の層を深く内蔵しており、畳み込み操作を繰り返すことで、検出対象が写る位置と大きさが端部に小さく映っていたとしても、損傷の特徴を柔軟に学習できることに利点がある。

3. 損傷検出モデル

3.1 損傷検出セグメンテーション・モデル

本稿では、セマンティック・セグメンテーションの転移学習手法として、FCN-Alex, FCN-VGG16[Long 2015], SegNet-VGG16[Badrinarayanan 2016]を適用比較する。本稿で用いる解法自体には新規性はないものの、1枚に占める検出対象領域の割合が疎である損傷画像に対して、適用可能な実用手法を見出すことを目的とする。FCN-Alexは、Ale

xNetの転移学習によるもので,その末尾の層までCNNを導入し,深さ23層を有する.次に,FCN-VGG16(16s)は,VGG16の転移学習によるもので,密なネットワーク構造で深さ47層を有する.SegNet-VGG16は,自動運転の物体認識に用いられる転移学習の手法で,深さ91層を有する.

本稿では,上記3つのモデルを適用し,計算実行時間,精度,予測出力を比較する.ハイパーパラメータの最適化手法は,損傷画像の疎な特性から,SGDMを用いると検出対象の勾配が消失しやすく,損失関数の改善が見られない問題が生じた.これを克服するため,RMSPropを採用した[Hinton 2012] [Mukkamala 2017].これは,疎な検出対象の勾配変化量を感度よく捉え,前回の更新量を適度に忘れて,勾配の変化量の平方根で除する誤差関数に特徴がある.数値計算では,更新量の重み係数を0.99と設定した.モデル全体の学習係数は,1E-5とし,ミニバッチを16と設定した.

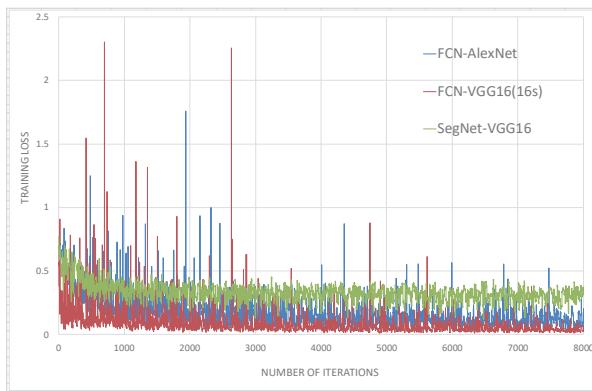


図2 鉄筋露出セグメンテーションの精度と損失関数の推移

4. 適用結果

4.1 転移学習の結果

106橋の近接目視点検における鉄筋露出の損傷画像208枚を対象にし,訓練・テストデータの使用率を,Train : Test = 95:5とした.図2に,鉄筋露出セグメンテーションの学習過程での損失関数の推移を示す.計算条件は,1エポック当たり832回で,10エポックで,計8,320回の反復計算を行った.FCN-VGG16の損失関数が深堀りし,低い水準で推移している.FCN-AlexNetは,FCN-VGG16よりも損失の値が高く推移している.しかし,2つのFCNモデルは,損失の分散が大きく,安定感に欠ける点が短所である.SegNet-VGG16の損失関数はやや高い水準だが,早期に上下変動が小さく推移し,学習過程の優れた安定性(Stability)が読み取れる.

表3に,各モデルの計算時間,精度,平均及び重み付きIoU

指標を示す.FCN-Alexは,129分と相対的に短い計算時間で学習できるが,IoU指標が高くはない.FCN-VGG16は,7時間40分の最長の計算時間を所要しているものの,ピクセル単位で損傷位置の真実と予測出力が一致するIoU指標が良好な水準にある.SegNet-VGG16は,平均mIoU=0.7757ならびに重み付きwIoU=0.9897と最高水準となっている.

表3 鉄筋露出セグメンテーションのモデルの指標比較

DNN モデル	計算時間	平均 mIoU	重み付き wIoU
FCN-AlexNet	129min.	0.5291	0.9639
FCN-VGG16(16s)	460min.	0.6662	0.9775
SegNet-VGG16	230min.	0.7757	0.9897

4.2 予測出力

以下では,上記のように鉄筋露出セグメンテーションを学習したモデルを用いて,目視点検のテスト画像10枚の予測出力を紹介する.図3と図4に,鉄筋露出が写るテスト画像に対する各セグメンテーション・モデルの予測出力を示す.

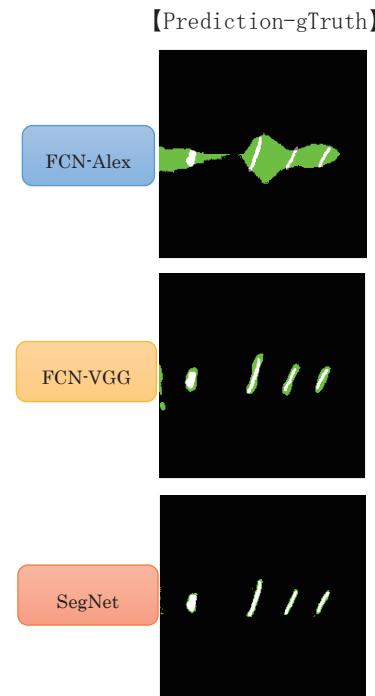


図3 学習した3つのモデルによる鉄筋露出予測(テスト出力1)上から3段に渡って,3つのモデルの予測出力を表す.左側は,目視点検の元の画像をベースに,背景を灰色で着色し,鉄筋露出の予測出力を茶色で着色した.右側は,予測と真実の一一致するピクセルを白色で表す.予測が真実以外に誤検出したピクセルは緑色で表す.真実が予測されずに漏れたピクセルはマゼンダ色で表す.FCN-AlexNetは,漏れなく真実の鉄筋露出(白色)を捉えており再現率が高いものの,その周り(緑色)の背景まで予測し,誤検出が増えて正解率が

低くなっている。FCN-VGG16(16s)の予測出力は、漏れなく真実を捉える点は変わらず、その周りの誤検出が改善されている。さらに、SegNet-VGG16 の予測出力は、漏れなく真実の鉄筋露出を捉えるとともに、その周りの誤検出はほとんどなく、再現率と正解率がともに3つのモデルのなかで良質な水準を達成している。同じ計算条件のもとで、SegNet-VGG16 は、より早くより高い精度で転移学習できる。

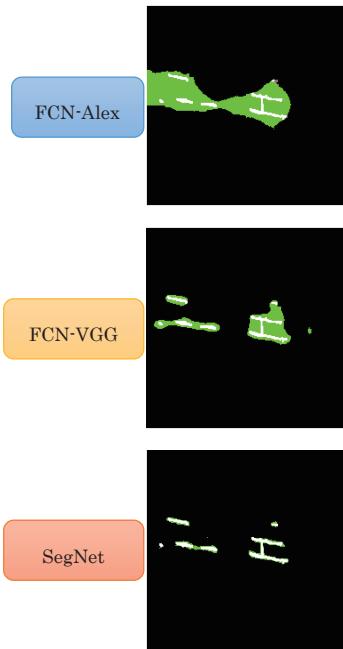


図4 学習した3つのモデルによる鉄筋露出の予測（テスト出力2）

5. おわりに

本稿では、近接目視点検で得られる損傷画像を用いて、セグメンテーションによる鉄筋露出を検出する3つの転移学習の手法を提案し、実際に、低画質の均一でない損傷画像に適用した。鉄筋露出の教師画像を作成し、ランダムにパッチを生成する前処理を施すことで、損傷画像の数とバリエーションを増すことができた。低画質の均一でない入力画像に対しても、転移学習により迅速に高い精度の学習が可能となった。FCN-AlexNet, FCN-VGG16 は、損傷を漏れなく検出する高い再現率(recall)を発揮したが、その周りに誤検出が生じて正解率(precision)に課題が残った。SegNet-VGG16 は、迅速に高い精度を発揮し、クラス平均の指標 mIoU が 77.57%、重み付きの指標 wIoU が 98.97% を達成した。4K 画質の均一な撮影条件でなくとも、従来の近接目視点検の画像を用いて、セグメンテーションを学習できることが示された。

本稿では、橋梁の近接目視点検における損傷画像を用いて、鉄筋露出の検出に着目した。橋梁の点検項目は、26 項目の基準がある[国交省 2014]。鉄筋露出の予兆となる「剥離」を

はじめ、「ひび割れ」「うき」等の損傷に関して、学習用データセット生成と損傷検出モデルの学習が課題である。これらは、鉄筋露出よりも纖細で、背景のコンクリートに埋もれ特徴が希薄である。目視点検を1次スクリーニングと位置づけ、要注意の損傷に着目した局所的な詳細調査として、高画質で撮影した損傷画像の劣化学習が課題となる。今後、バリエーション豊かに他の構造物にも、既存の蓄積した損傷画像を活用して、インフラ劣化学習の草分けに取り組みたい。

[謝辞] 数値計算で、藏本進一氏、福本拓司氏(MathWorks Japan)に実践的な情報を提供頂いた。感謝の意を表します。

参考文献

- [国交省 2014] 国土交通省道路局: 橋梁定期点検要領, 2014.6.
- [Wu 2002] Wu, Z., Xu, B., Yokoyama, K. : Decentralized Parametric Damage Detection Based on Neural Networks, Comput. Civ. Infrastruct. Eng., 17, pp.175-184, 2002.
- [Chun 2015] Chun, P., Yamashita, et al. : Bridge Damage Severity Quantification using Multipoint Acceleration Measurement and Artificial Neural Networks, 2015.
- [Gordan 2017] Gordan, M., Razak, H.A. et al. : Recent Development in Damage Identification of Structures using Data Mining, Journal of Solids and Structures, pp.2373-2401.
- [AlexNet 2012] Krizhevsky, A., Sutskever, I., Hinton, G.E. : ImageNet Classification with Deep Convolutional Neural Networks, in: F. Pereira, C. Burges et al.(Eds.), Advances in Neural Information Processing Systems, Vol.25, pp.1097-1105, Curran Associates, Inc., 2012.
- [Gopalakrishnan 2018] Gopalakrishnan, K., Gholami, H. et al. : Crack Damage Detection in Unmanned Aerial Vehicle Images of Civil Infrastructure using Pre-trained Deep Learning Model, Int. J. for Traffic & Transport Engineering, 8(1), pp.1-14, 2018.
- [Ricard 2018] Ricard, W., Silva, L. et al. : Concrete Cracks Detection based on Deep Learning Image Classification, MDPI Proceedings, 2, 489, pp.1-6, 2018.
- [Hoskere 2017] Hoskere, V., Narazaki, Y. et al. : Vision-based Structural Inspection using Multiscale Deep Convolutional Neural Networks, 3rd Huixian International Forum on Earthquake Engineering for Young Researchers, 2017.
- [Guillamón 2018] Guillamón, J.R. : Bridge Structural Damage Segmentation using Fully Convolutional Networks, Universitat Politècnica de Catalunya, 2018.
- [Long 2015] J. Long, E. et al. : Fully Convolutional Networks for Semantic Segmentation, CVPR, pp.3431-3440, 2015.
- [Badrinarayanan 2016] V. Badrinarayanan, A. Kendall, R. Cipolla, SegNet: Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, ArXiv:1511.00561v3, 2016.
- [Hinton 2012] G. Hinton, N. Srivastava, K. Swersky : Lecture 6d – A Separate, Additive Learning Rate for Each Connection, Slides Lecture Neural Networks for Machine Learning, 2012.
- [Mukkamala 2017] M.C. Mukkamala et al.: Variants of RMSProp and Adagrad with Logarithmic Regret Bounds, 2017.
- [Yasuno 2018] 安野貴人: 予測メンテナンスとインフラ劣化学習モデル, 第32回人工知能学会, 3Z1-04, 2018.

(2019.2.13)