

深層学習による耐候性鋼材のさび外観評価および評価用アプリケーションの開発

九州工業大学大学院 学生会員 ○川崎雄貴
九州工業大学大学院 正会員 山口栄輝

1. 研究背景および目的

耐候性鋼材は適度な乾湿を繰り返す環境下において緻密なさび層(保護性さび)を生成し、腐食の進展速度を抑制する。しかし、環境によっては保護性さびが生成しないこともあるため¹⁾、定期的な点検と健全度の評価が必要となる。評価手法の一つにセロファンテープ試験があるが、その外観評価基準²⁾は必ずしも定量的ではないため評価は容易でない。評価を専門家に外注することも経済的に困難な場合もある。本研究では、深層学習や機械学習による外観評価手法を提案し、さらにコスト削減と実用性向上のため評価用アプリケーションの開発を行う。

2. 手法概要

本学の既往研究ではさびを C:維持管理上注意が必要なさびと、S:現状問題のないさびの二項に仕分け、畳み込みニューラルネットワーク(CNN)を用いてさび画像を分類した。しかしながら、CをSと誤判定するような、維持管理上問題となるケースも確認された。そこで本研究ではCとSで点検者が判定に迷うさびをNとし、新たに分類項目を設けることで誤分類のリスク低減を図る。また本研究が検討する判定手法は3つあり、CNNによる画像分類、セマンティックセグメンテーション、粒子データによる分類である。画像分類ではCNNを用いてさび画像を学習しC、N、Sに分類する。セマンティックセグメンテーションはピクセル単位でクラス判定を行う手法であるが、これを用いて維持管理上注意が必要と考え得るさび粒子を検出する。粒子データによる分類は粒子解析で得たさびのデータを機械学習によって学習し、C、N、Sに分類するものである。




図-1 前処理の概要

3. 検討手法

3.1 前処理とデータセットの構築

本研究で扱うさび画像はテープ幅 50mm と 25mm のものがあり、それぞれ 1980 枚、150 枚である。これらの正規化を目的に、サイズが一律になるよう処理を施す(図-1)。全 2130 枚のさび画像について、本学で C、N、S に外観評価した結果を表-1 に示す。

3.2 画像分類

深層学習ライブラリは Keras を用いる。また、画像処理を施し学習用のデータを増やす「データ拡張」、学習済みのモデルを再利用して目的の分類項目に適合した重みに再調整する「ファインチューニング」を導入する。2 パターンでデータ拡張したデータセット(表-2)および、自作の CNN とファインチューニングを用いて構築した CNN を用意した。これらを組み合わせ 5 ケースで画像分類を検討する(表-3)。さらに各ケースで層化 k 分割交差検証を実施し、モデルの汎化性能を確認する。性能評価指標は混同行列から算出した適合率(予測したクラスのうち実際に正解だった割合)、再現率(正解に対して正しく予測できた割合)、正答率(正解と予測が一致した割合)である。

3.3 セマンティックセグメンテーション

U-Net を用いて維持管理上注意を要すると考えられるさび粒子を検出する。検出対象は、さびの外観評価基準²⁾を参考に検討したうえで、円相当径 5mm 以上のさび粒子とした。正規化した画像 282 枚を対象にラベリング処理を行い、学習に用いるデータセットを作成した。評価は IoU(正解画像と予測画像の一致率)を算出を行う。

表-1 外観評価結果 [枚]

テープ幅	C	N	S	計
50mm	238	73	1669	1980
25mm	0	6	144	150
計	238	79	1813	2130

表-2 データセットの構成 [枚]

Dataset	C	N	S	計
1	238	79	1813	2130
2	714	237	5439	6390
3	2142	2133	5439	6376

表-3 検討ケースの概要

Case	Dataset			CNN	
	1	2	3	自作	Fine-tune
1	○			○	
2	○				○
3		○		○	
4		○			○
5			○		○

キーワード: 耐候性鋼材, さび外観評価, 深層学習, セマンティックセグメンテーション
連絡先: 〒804-8550 福岡県北九州市戸畑区仙水町 1-1 九州工業大学 TEL 093-884-3110 FAX 093-884-3100

表-4 交差検証で得た性能評価指標の平均

Case	適合率(%)				再現率(%)				正答率(%)
	C	N	S	平均	C	N	S	平均	
1	88.4	0.0	95.4	61.3	86.2	0.0	99.6	61.9	94.6
2	93.2	36.0	96.8	75.3	80.6	40.4	98.2	73.1	94.0
3	88.0	54.8	98.2	80.3	95.8	28.0	99.2	74.3	96.0
4	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
5	99.8	97.8	100.0	99.2	100.0	100.0	97.8	99.3	99.2




図-2 検出結果の例

3.4 粒子データによる分類

既往研究で課題となっていた解析時の近接粒子結合の問題は、新たに粒子切断プログラムを構築することで解決を図った。また粒子解析プログラムを自ら構築し、ソフトウェアを用いずにさび粒子の最大径、円相当径、周囲長を取得。さらに統計情報として各項目の最大値、平均値、標準偏差を得た。機械学習手法の一つである「アンサンブル学習」を用いて9つのパラメータからC、N、Sの分類をおこなった。評価指標は画像分類と同様である。

4. 結果

表-4 に画像分類における各検証ケースの結果を示す。データ拡張とファインチューニングによる精度向上が確認できる。交差検証の分割ごとの結果に大きなばらつきはなく、汎化性能は十分にあると考える。Case 4 と Case 5 で 100%に近い精度が確認された。今後は本モデルを専門家に監修を依頼するなどして、判定に信頼性を持たせていく必要がある。図-2 にセマンティックセグメンテーションの結果の一部を示す。検証用データにおける IoU の平均は 73.9%となり、概ね良好な結果を得たと考える。粒子の分布状況が検出精度に影響を及ぼすことが確認できた。粒子データによる分類では、適合率と再現率が 95%を超える結果を得た。しかしながら、一部のさびで C を S と予測し、危険なものを判定し損ねるケースが確認された。それらの中には画像処理の過程で粒子を過剰に大きく評価するケースも確認されており、プログラムの改良が求められる。

画像分類は非常に高い精度でさびの分類を行えるが、判定根拠の特定は困難で説明性に欠ける。一方、セマン




図-3 アプリケーション画面（判定結果を表示）

ティックセグメンテーションによる検出や粒子解析は、精度は画像分類に及ばないが、さびの定量値を取得でき、判定根拠の追及が可能と考えられる。それぞれの手法にはメリット・デメリットがあり、互いに補い合うような特性である。本研究としては複数の判定手法の結果を鑑みて総合的に評価を下すことが今後必要であると考え。今後は各手法の精度向上を図り、取得した定量値を分析することで、外観評価の説明性を向上させることも課題と捉えている。

5. 評価用アプリケーション

以上までの3手法を実行できるアプリケーションを開発した。これにより特別な技術を必要とせず容易に評価が可能となる。さび採取後の A4 サイズのスキャン画像を自動でトリミングする機能も追加し評価者の負担を減らし、実用性向上を図った。判定時にすべき作業はさびのスキャンのみとなった。図-3 にアプリケーションの実際の画面を示す。

6. 結論

本研究は、深層学習や機械学習を活用した耐候性鋼材のさびの外観評価手法の提案し、画像分類では100%程度の精度、セマンティックセグメンテーションではIoU=73.9%、粒子データによる分類では97%程度の精度を示しており、概ね良好な結果を得た。また、各手法を容易に実行できるように評価用アプリケーションの開発に取り組んだ。これにより、当初の目的を達成したと考える。

参考文献

- 1) 山口栄輝ら:九州・山口地区における耐候性鋼橋梁の実態調査, 土木学会論文集 A, Vol.62, No.2, pp.243-254, 2006.4.
- 2) 公益財団法人 日本道路協会:鋼道路橋防食便覧, 2014.3.