

Deep Learning を用いた鋼構造物の素地調整時の除錆度判断に関する研究

松江工業高等専門学校 正会員 ○大屋 誠, 武邊 勝道, 広瀬 望

日鉄防食(株) 正会員 今井 篤実, 松本 洋明

金沢大学 諏訪 太紀, 愛媛大学大学院 学生会員 泉 翔太

1. はじめに

鋼構造物の維持管理において、塗装の劣化や異常さが確認された場合には腐食原因を排除することが好ましいが、原因の排除が難しい場合には補修塗装を検討することになる。耐候性鋼橋梁の補修塗装では、補修塗装の耐久性を向上させるために、塗装前にブラスト処理による素地調整程度 1 種¹⁾の下地処理が必須とされ、加えて素地調整後には付着塩分量が 50mg/m²以上になっている場合には、現場塗装を行う直前に水洗い等による十分な清掃を行わなければならないとされている。素地調整程度 1 種には ISO 規格²⁾があり、ブラスト処理後の基準として、鋼材表面状態とさび度及び除錆度が示され、補修塗装時に拡大鏡なしで、表面には目に見えるミルスケール、さび、塗膜、異物、油、グリース及び泥土がない状態とされている Sa 2 1/2²⁾以上の除錆度が求められている。塗装現場において、除錆度を目視で判定することは難しく、定量的な判断を支援する技術の開発が求められている。




図1 除錆度の判断システムの概要

そこで本研究では、Deep Learning を用いて、腐食した耐候性鋼材（さび度：Grade D²⁾）の素地調整時の除錆度の判断を支援するシステムの構築を試みる。システムの概要を図1に示す。本システムは、あらかじめ除錆度がグレーディングされた画像データを教師データとして Deep Learning により学習させ、未知の画像を4つの除錆度クラス Sa 1 1/2, Sa 2, Sa 2 1/2, Sa 3 に分類するシステムである。

2. 分類手法

(1) CNN 概要

本研究では、Deep Learning の手法の一つで、主に画像認識に利用されている畳み込みニューラルネットワーク³⁾(CNN: Convolutional Neural Network)を用いる。CNNは何段もの深い層を持つニューラルネットワークで、中間層として、畳み込み層とプーリング層の2種類の層を持つ特徴がある。

(2) 学習済みモデルの使用及びK-分割交差検証法

本研究では、教師用の画像数が少ないため、小さなデータセットを用いた Deep Learning に関して非常に効果的なアプローチとされている学習済みモデルを用いた特徴抽出を行った。学習済みモデルとして、画像認識で高い性能を発揮することが知られている Resnet50⁴⁾を使用する。なお、分類性能の評価は K-分割交差検証法³⁾により行った。K-分割交差検証法は、標本を K 群に分類し、K-1 群の標本を学習に用い、それらによって学習されたモデルを用いて残り 1 群を解析するといった手順を K 回繰り返すものであり、本研究では学習用画像枚数と解析用画像枚の比率を考慮し、K=10 とした。

3. CNN への入力画像

本研究では、全面がさびに覆われるとともに、鋼材素地面にかなりの孔食が認められる腐食した耐候性鋼材のブラスト処理後の画像データを用いる。分類にお

キーワード 耐候性鋼橋梁, 素地調整, 除錆度, Deep Learning

連絡先 〒690-8518 島根県松江市西生馬町 14-4 松江工業高等専門学校環境・建設工学科 TEL 0852-36-5268

て学習に用いる画像数が重要である．本研究を実際する上で、精度確保に必要な画像数を集めることはできなかったため、図 2 に示す手法により、画像データから 256×256 画素を切り出し、K-分割交差検証法による CNN に必要なデータセットを作成した．表 1 に、元画像の数と図 2 の手法により作成した各除錆度に対する画像枚数の一覧を示す．

4. システムの評価

本研究では、K-分割交差検証法 (K=10) によって、10 通りの解析を行い、その結果に対し、式(1)から(4)で定義される定量的な 4 つの指標⁴⁾を用いて CNN による分類システムの性能を評価した．

正解率 (Accuracy)= $\frac{(TP+TN)}{(TP+FP+TN+FN)}$ (1)

再現率 (Recall)= $\frac{TP}{(TP+FN)}$ (2)

適合率 (Precision)= $\frac{TP}{(TP+FP)}$ (3)

F 値= $\frac{(2\times\text{再現率}\times\text{適合率})}{(\text{再現率}+\text{適合率})}$ (4)

ここに、TP : True Positive ,TN : True Negative ,FP : False Positive, FN : False Negative であり、本研究では表 2 のように定める．表 3 に本研究で得られた結果を示す．

適合率は、陽性（本研究では Sa3 及び Sa2.5）と予測されたものが実際に陽性であった度を測定する指標で、1 に近いほど性能が高いといえる．再現率は、実際に陽性であるものが、陽性と予測された度を表す指標であり、適合率と同様に 1 に近いほど性能が高いといえる．一般的に性能評価の指針となることが多いのは、適合率と再現率の調和平均である F 値である．除錆度の判断において、良好な F 値を得ることができた．これは、CNN が画像の特徴を適切に抽出できているためであると考えられる．正解率の低下に寄与している要素として、同じグレードでも切り取った画像間で場所により凹凸に差があることによって、Sa2.5 の画像を Sa2 または Sa3 と誤判定したことが挙げられる．また、Sa2 の中で黒ずみの多いものが Sa1.5 と判定されるケースもあった．このことから CNN の判断材料は幾何学的な形状ではなく、凹凸の度合と色であると考えられる．

本研究では元画像のグレードが一様であると仮定し、教師あり学習により分類システムの構築を試みたが、

元画像に対し目視でグレードを判定しているため、元画像の中で異なるグレードが存在する可能性が考えられる．そのため、分類は行えているものの、正解ラベルが間違っていることが起因し正解率が低下している可能性が考えられる．一方、本解析結果より、CNN により画像内の除錆度のグレードの偏りの検出可能性が示唆された．




図 2 学習用データセットの作成手順

表 1 切り取りによる画像枚数の増加

	元画像	切り取り後
Sa 1.5	2	60
Sa 2	3	261
Sa 2.5	4	180
Sa3	4	431
合計枚数	13	932

表 2 クラス分類の混合行列

予測値 正解	Sa3	Sa2.5	Sa2	Sa1.5
Sa3	TP	FP	FP	FP
Sa2.5	FP	TP	FP	FP
Sa2	FN	FN	TN	FN
Sa1.5	FN	FN	FN	TN

表 3 CNN による分類性能の定量的な評価

正解率	再現率	適合率	F 値
0.9527	0.9685	0.9590	0.9638

参考文献

1) (社) 日本道路協会：鋼道路橋塗装・防食便覧，2014.
2) ISO 8501-1:2007：塗料及び関連製品を塗装する前の鋼被塗物の調整—表面清浄度の視感評価—第 1 部：未塗装鋼材及び旧塗膜全面剥離後の鋼材のさび度及び調整等級，2007.
3) Francois Chollet: Python と Keras によるディープラーニング, 株式会社マイナビ出版, 2018.
4) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun : Deep Residual Learning for Image Recognition, arXiv preprint arXiv:1512.03385, 2015
5) 全邦釘他：ディープラーニング及び Random Forest によるコンクリートのひび割れ自動検出手法, 土木学会論文集 F3, Vol.73, No.2, pp.I_297-I_307, 2017