

機械学習による画像処理に基づく外観画像からの鋼材腐食劣化度判定の試み

琉球大学・岐阜大学 正会員 ○ 蓮池 里菜
岐阜大学 正会員 木下 幸治

1. 目的

近年、インフラ構造物の老朽化が深刻な課題となっており、構造物の安全性および機能性を確保するために、定期的な点検や補修工事によるメンテナンスが重要である。このような点検作業の効率化やコスト低減に向け、ロボット技術等を用いた先端点検技術の開発が進められてきている。たとえば鋼橋では、劣化要因の一つである鋼材腐食の劣化度判定に対し、先端点検技術を用いて取得が可能な外観画像への画像処理技術の活用が検討されているものの、腐食部外観と劣化度の対応関係は腐食部の外観が曝される環境により異なるために、外観画像からの劣化度の判定には未だ課題が残る。

本研究ではこの課題に対し、腐食環境を変えた腐食促進試験を実施して得られた試験体の腐食部画像を教師データにした、機械学習をベースとした画像処理技術に基づく劣化度判定を試みた。

2. 腐食促進試験

試験体はSS400材(60mm×60mm×3mm)とし、黒皮をサンドブラストで除去したのち、三つの異なる暴露環境下で3%濃度の塩化ナトリウム水溶液への浸漬・暴露を繰り返す腐食試験を実施した¹⁾。環境は、

- (1) 三段階に暴露環境を変更。試験開始から74日目までは温度湿度の調整を行わない室内環境(10~30℃, 50~65%), 75日目から384日目までは温度は変更せず、湿度を塩化ナトリウムの吸湿限界湿度である74%以上²⁾へ変更することで腐食を促進する環境、385日目から490日目の試験終了まで、温度を40℃の高温とし更に腐食を促進する環境。
- (2) 試験開始から終了までの325日間、高温度(40℃)高湿度(74%以上)環境。
- (3) 試験開始から終了までの275日間、低温度(5℃)高湿度(74%以上)環境。

の三種類とした。試験体数は各環境でn=3とした。

図-1に、試験体の質量増加量および試験体外観の例を示す。図-1に示すように、腐食が進行した時点での試験体外観には、(a)腐食が急激に進行し局部腐食を生成、(b)質量増加量は最大だが局部腐食の面積は小さい、(c)全面的に腐食し局部腐食は生成していない、といった異なる特徴が現れた。




図-1 質量増加量および外観画像の例




図-2 FT-IR 分析結果の波形の例

外観画像と劣化度の関連を確認するため、試験体上に生成した腐食生成物であるさびに対しFT-IR(フーリエ変換赤外分光法)を用いた組成分析を実施し、その特徴の把握を試みた。分析は試験体表面のうち反面(30mm×60mm)を10mm角に区切り、KBr錠剤法によって実施した。図-2に環境(1)で生成したさびの、局部腐食部の地鉄付近(地鉄から300μm程度)二箇所を分析した波形の例を示す。塩化物に起因する活性さびであるβ-FeOOH²⁾の吸収帯のひとつである690cm⁻¹付近で吸光度が大きくなっていることから、β-FeOOHが存在していることが分かる。その他の試験体についても、試験終了時点で同様に分析したところ、局部腐食が発生した試験体では局部腐食部の地鉄付近にβ-FeOOHが集中して発生していることが分かった。また、表層付近ではβ-FeOOHは確認されなかったことから、局部腐食や全面腐食といった外観の違いに伴い組成も異なっているものの、外観に現れる表層と、腐食が進行している地鉄付近の組成は異なることが分かった。

3. 畳み込みニューラルネットワーク(CNN)を用いた腐食部画像の分類

畳み込みニューラルネットワーク(CNN)とは、画像の分類や検出を得意とする機械学習手法のひとつである³⁾。本研究では、画像分類においてその有効性が示

キーワード：画像解析、機械学習、腐食、鋼橋

連絡先：〒903-0213 沖縄県中頭郡西原町千原1番地 TEL: 098-895-8063

表-2 画像枚数と内訳

	環境	画像の枚数														
		Group 0			Group 1			Group 2			Group3			Group 4		
		Train.	Valid.	Test	Train.	Valid.	Test	Train.	Valid.	Test	Train.	Valid.	Test	Train.	Valid.	Test
元画像	環境(1)	4	1	1	-			9	2	1	-			6	1	1
増量後	環境(1)	28	6	2	-			56	14	2	-			37	9	2
	環境(2)	28	6	2	-			47	11	2	23	5	2	71	17	2
	環境(3)	28	6	2	56	14	2	85	21	2	28	6	2	-		

されている VGG19⁴⁾分類器を使用し、2. の腐食促進試験で得られた画像の分類を試みた。表-1 に質量増加量および外観に基づく教師データの分類基準を、表-2 に各分類先の画像の総数を示す。なお、本腐食試験では試験体数が少なく得られる外観画像数も少ないことから、各画像を水平・鉛直方向に反転、90°ずつ回転させることで、画像枚数を増量し6倍としている。

図-3 に CNN での学習過程の例を示す。右軸は損失 (Loss)、左軸は精度 (Accuracy)、横軸は学習の繰り返し回数 (Epochs) を示す。CNN では教師データ数が少ない場合などに、過学習が発生し、分類精度の低下を招く。過学習は図-3 中緑線の学習データに基づく損失と、青線の検証データに基づく損失の間にギャップが生じた際に発生しているとされる。図-3 より、今回の分類器の作成において画像枚数は多くは無いものの、過学習は発生しておらず、正常に学習が行われていることがわかる。表-3 に各環境で得られた画像を教師データとして、図-3 と同様に作成した分類器によるテスト画像の分類精度を示す。分類は、同じ環境から得られたが教師データに使用していない画像と、異なる環境から得られた画像に対して実施した。その結果、同じ環境から得られた画像に対しては 67~86%と比較的精度が高くなったが、異なる環境から得られた画像に対しては 38~62%と精度が低くなった。以上より、腐食鋼材の外観画像を表-1 で示した程度の段階に分類することは難しいと言え、特に他の環境で得られた画像に対する分類精度が低いことが分かった。

4. 結論

- (1) 異なる環境下で腐食促進試験を実施し、生成したさびの組成分析を実施した結果、局部腐食や全面腐食といった外観の違いに伴い組成も異なっているものの、外観に現れる表層と地鉄付近の組成は異なることを明らかとした。
- (2) 各環境で得られた腐食画像を教師データとした分類器では、同環境下から得られた画像に対しては判定精度が高い一方で、教師データが異なるために他の環境の腐食劣化度判定の精度が低いことを明らかとした。
- (3) よって、現状では、橋梁毎に CNN 分類器を作成し、経時的な変化を捉えながら劣化度判定を行うことが望ましいと考えられ、経時的な腐食画像の取得が必

表-1 教師データの分類基準

質量増加量	外観の特徴	室温/高温/高温高湿	高温高湿	低温高湿
Group 0 $x = 0$ [g]	初期状態。			
Group 1 $0 [g] < x \leq 0.3 [g]$	全体的に腐食、ただし地鉄が確認可。			
Group 2 $0.3 [g] < x \leq 5.0 [g]$	全面が腐食生成物で覆われている。			
Group 3 $5.0 [g] < x \leq 10.0 [g]$	局部腐食が生成し始める。			
Group 4 $10.0 [g] < x$	局部腐食が成長。			




図-3 CNN での学習過程の例 (環境(2))

表-3 分類精度

Test Data	分類器および精度		
	(1) 室温/高温/高温高湿	(2) 高温高湿	(3) 低温高湿
同環境	67%	86%	75%
異環境	38%	62%	62%

要といえる。

画像処理技術を活用した鋼材腐食の劣化度判定の今後の展望としては、腐食外観画像のみならず、さび層断面の厚さ・形状を教師データとした CNN 分類器の作成が考えられる。

参考文献

1) 蓮池里菜, 木下幸治, 畑佐陽祐: 塩化・非塩化混合凍結防止剤による腐食生成物の組成に基づく検討, 鋼構造年次論文報告集, 第 26 巻, pp.762-767, 2018. 2) 三木千壽, 市川篤司: 現代の橋梁工学, 数理工学社, pp.44-54, 2004. 3) 岡谷貴之, 深層学習 (機械学習プロフェッショナルシリーズ), 講談社, 2015. 4) Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, International Conference on Learning Representations 2015, 2015.