

## 画像処理に基づく腐食鋼板減肉レベルの評価

福井大学 学生会員 ○須藤 魁斗

福井大学 正会員 鈴木 啓悟

石川工業高等専門学校 正会員 前田 健児

福井大学 Wu Kai

### 1. 研究の背景と目的

地域別の腐食環境を評価する目的で、モニタリング鋼板を橋梁などに設置し、長期間曝露した後に、その腐食減肉量を計測する手法がある。この手法では鋼板回収後クエン酸水素二アンモニウム水溶液を用いて腐食層を除去するが、労力と時間を要する。腐食鋼板は腐食レベルに応じて外観に差異が生じる点に着目し、本研究は腐食鋼板の画像から腐食減肉レベルを判定することを目的とし、画像学習モデルを構築し、その精度を評価する。モデルの構築にはPythonを使用する。

### 2. 曝露試験

福井県下の15橋梁に対し、モニタリング鋼板を主桁に設置し、6ヶ月～24ヶ月の曝露期間を経て回収した。モニタリング鋼板の仕様を図1に示す。

回収したモニタリング鋼板に対し、写真撮影した後、濃度20%のクエン酸水素二アンモニウム水溶液で錆層を除去し、鋼板の質量(g)を小数点以下第4位まで測定し、曝露試験前の質量との差分から減肉厚さを式(1)より求める。

$$t = \frac{W}{A * \rho} * 10^3 \dots (1)$$




図1 炭素鋼板の詳細

$t$ =減肉厚さ(mm),  $W$ =腐食減量(kg),  $A$ =試験片の面積( $m^2$ ),  $\rho$ =7850( $kg/m^3$ )

### 3. データセットの生成

良好な学習モデルを構築するためにはサンプル数の多さが重要となる。深層学習の前処理として、用いる画像データを増強する。曝露試験で得られた腐食画像と減肉量データを利用してデータセットを生成する。生成する前の元の腐食画像は1600x1600ピ



図2 6分割交差検証概略図




図3 学習データサンプル

キーワード 腐食 深層学習 モニタリング鋼板

連絡先 福井大学 〒910-8507 福井県福井市文京 3-9-1 TEL : 0776-27-8596

表1 腐食レベル分類とデータ数

腐食レベル	腐食減肉量(mm)	学習データ	検証データ	テストデータ
0	非腐食	6(枚)	2(枚)	2(枚)
1	0.005 未満	6	2	2
2	0.010 未満	11	3	6
3	0.020 未満	6	2	2
4	0.030 未満	6	1	2
5	0.030 以上	12	3	5

クセルの画素数である。生成したデータセットを学習データとテストデータに分割する過程で、均一な腐食形態を持つ画像のみを学習データとして選択し、比較的不均一な腐食形態を持つ残りの画像をテストデータとして使用した。均一な腐食形態を持つ画像を小さなサイズに裁断することで、ラベルのミスマッチ問題を回避する。また、モデルの汎化性能を証明するため、検証用データも作成し、6分割交差検証を行った。本研究では、学習用データと検証用データの異なる組み合わせを6パターン用意し、6回学習を行い判定精度の平均を取った。6分割交差検証の概略図を図2に示す。

データ拡張のため、元の画像を400x400ピクセルの解像度のサイズに裁断した。各腐食レベルの学習データサンプルの一部を図3に、腐食レベルと減肉量の分類基準また、腐食レベル毎における元画像の枚数を表1に示す。各腐食レベルにおける学習用データと検証用データの枚数比を3:1にした為、元画像79枚を学習用データに47枚、検証用データに13枚、テスト用データに19枚と割り振った。データ拡張に際しては、学習用データのみ画像の回転、反転を施し、画像の裁断をすることで7990枚だった学習用データは47940枚まで拡張し、検証用データとテスト用データは画像の裁断のみを施してそれぞれ2210枚、3211枚とした。

#### 4. 深層学習モデルの構築

本研究では、深層学習の手法の1つで画像の特徴を抽出するのに特化したCNN(畳み込みニューラルネットワーク)を適用した。モデルを構築する上でCNNの代表的なモデルであるVGG16, ResNet, GoogLeNetのモデルを使用した。

#### 5. 結果と考察

交差検証の判定精度を図4に示す。交差検証の結果は6パターンの平均値であり、GoogLeNetを適用した場合に最も良い判定精度が生じ、どのモデルを適用しても判定精度70%を超える結果となった。また、テストデータに対する判定精度を図5に示す。

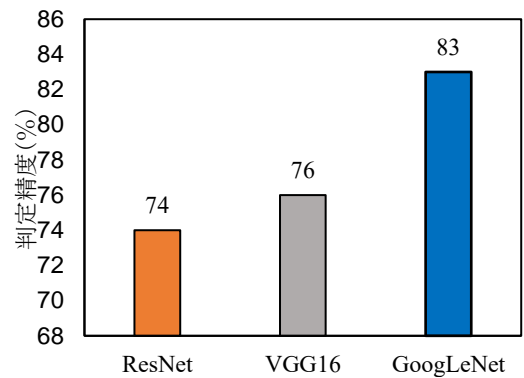


図4 交差検証の判定精度

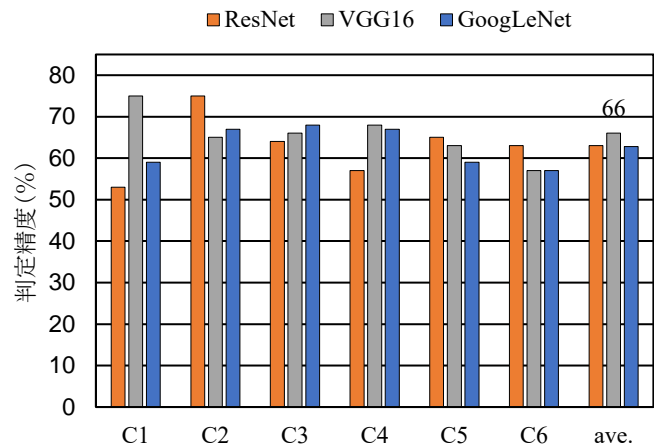


図5 テストデータに対する判定精度

C1~C6は交差検証の各データコンビネーションを表している。学習用データと検証用データの組み合わせにより、判定精度に大きく差が出た。6パターンの平均値を取ると、VGG16のモデルを適用した場合に、最も良好な判定精度が得られた。

GoogLeNetを適用した場合に、交差検証とテストデータの判定精度に差が大きく生じているのは過学習が発生している可能性がある為、パラメータチューニングが必要である。

#### 6. 今後の展望

少ないサンプル数で判定精度の向上が見込まれる転移学習を適用していく。

また、VGG16, ResNet, GoogLeNetのモデルでパラメータチューニングを行い、テストデータに対する判定精度を向上させていく。さらに、これらの分類判定結果を用いて腐食減肉量を定量化するプログラムを構築し、回帰分析を行っていく。

#### 【参考文献】

- 1) Kai Wu, Keigo Suzuki, Kenji Maeda : Thining Evaluation of steel Plates for Weathering Tests Based on Convolutional Neural Networks  
CORROSION, Vol.77, No.4, pp.469-479, 2021.4.