

CNN モデルのアンサンブルによる耐候性鋼材におけるさびの外観評価

九州工業大学大学院 学生会員 ○光野 正大
 横浜国立大学/大崎総合研究所 正会員 櫻井 彰人
 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、鋼材表面に緻密な保護性さびを形成することで、腐食の進展を抑制する。しかしながら、架設後の周辺環境によっては保護性さびが発生しない場合があり、定期的な点検及び健全度評価が必要となる。簡易的な外観評価手法として、セロファンテープ試験（表-1）があるが、その評価基準は必ずしも定量的ではなく、評価は容易ではない²⁾。そこで本研究では、セロファンテープ試験における5段階評価について、安全管理上の対応に則した3段階評価に定義しなおすことで3項分類問題にするとともに、複数CNNモデルによるアンサンブルを実施することで、簡便性と実用性を有する外観評価法を提案することを目的とする。

表-1 さびの外観評価と状態²⁾

評点	さびの状態
5	さび粒子は細かいが、均一性に欠ける
4	さびの平均外観粒径は1mm程度で細かく均一である。
3	さびの平均外観粒径は1~5mm程度で細かく均一である。
2	さびの平均外観粒径は5~25mm程度で細かく均一である。
1	さびは層状で厚いが、剥離がある

2.データセットの構築

本研究では、耐候性鋼橋28橋にて採取されたセロファンテープ試験の資料をスキャンした画像データ（以下さび画像）を用いる。各橋梁にて採取枚数は異なり、さび画像の全データ数は28橋の合計で1998枚である。

2.1 アノテーション

さび画像1998枚について本学にて独自にアノテーション作業を行った。作業時にはさび画像をモニター上に実寸大表示し、さび粒子の外観粒径を実際に測定して判定している。クラスラベルの定義については表-1を基に次の通りとした。C：平均外観粒径5mm以上のさび粒子が多数分布し明らかに評点1, 2であるもの。N：平均外観粒径5mm程度のさび粒子が存在するが微細な粒子も多く分布し評点2, 3の判定が難しいもの。

S：平均外観粒径5mm以下の微細なさび粒子が分布し明らかに評点3, 4, 5であるもの。作業後の各クラスラベルにおけるさび画像データ数を表-2に示す。

表-2 アノテーション結果

クラスラベル	C	N	S	合計
さび画像データ数	200	135	1663	1998

2.2 データ編成

画像分類問題では、分類対象の他に背景についても配慮する必要がある。そこで、資料採取場所に起因する背景への影響を排除するべく、画像データを橋梁ごとにまとめて管理しデータ編成を検討した。全データ数が1998枚と少なく学習モデルの検証時には5分割交差検証（図-1）を行うため、クラス間データ数分布を近似したグループを作成し、教師データを5グループ（各5橋）、テストデータを1グループ（3橋）と編成した。

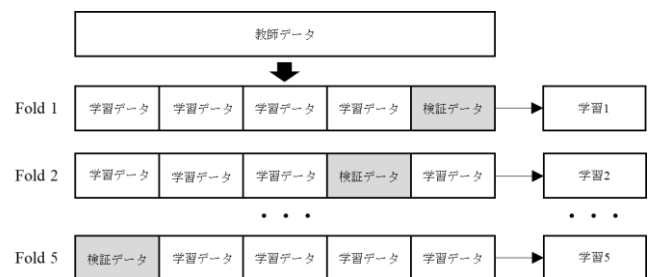


図-1 5分割交差検証

3.CNNモデルの構築および学習

畳み込み層構造が異なる3種のCNNモデル（a~c）を作成し、各モデルに対して2種類のPooling方法を採用して、6つの異なるCNNモデルを作成した。（表-3）

表-3 各モデルの層構造とPooling方法の組合せ

モデルNo	1	2	3	4	5	6
層構造パターン	a	b	c	a	b	c
Pooling方法	MaxPooling			AveragePooling		

学習に際して、学習データにおけるクラス間データ数分布の不均衡を解消するべく、データ数が少ないC, Nについては反転処理によるデータ拡張を実施しデータ数を4倍に増やした。各モデルにて、5分割交差検証を実施し、テストデータを分類した結果を表-4に示す。

表-4 テストデータ分類結果 (平均値)

モデルNo	1	2	3	4	5	6
分類精度	0.960	0.967	0.956	0.965	0.963	0.958
危険側誤判定数	0.8	1.8	3.2	3.6	5.0	6.0
層構造パターン	a	b	c	a	b	c
Pooling方法	Max Pooling			Average Pooling		

5分割交差検証によって作成された5ケースの平均分類精度はいずれのモデルについても非常に高く横並びの性能と見えるが、安全管理上許容されない危険側誤判定数に着目した場合、Max Poolingを採用したモデルにおいて誤判定数が少なく、より実応用場面に則した性能であると考えられる。しかしながら、本研究では所謂グレーゾーンとして判定の難しいさび画像をNと新たに定義しているため、本来危険側誤判定については可能な限り排除するべきである。

4.アンサンブルの実施

前述したように、各CNNモデルは単体でも高い分類性能を有する。しかしながら、モデル単体では分類性能向上に限界があった。そこで、分類性能向上のために、複数モデルによるアンサンブル(図-2)を実施した。

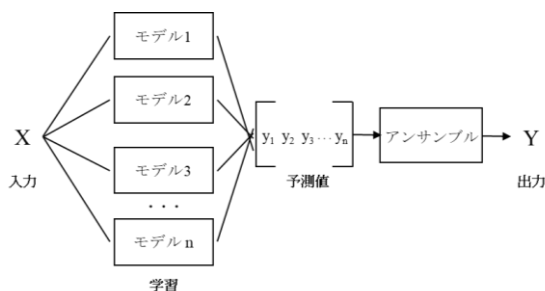


図-2 複数モデルによるアンサンブル

アンサンブルに際しては、同一データに対する分類結果の相関が低いモデルを複数選択する必要がある。そこで、作成済みの6モデルに対して相関が低い分類結果を示すCNNモデルを新たに3つ作成した。これにより相関を調査可能な分類結果数は、各モデルにおける5分割交差検証の結果をそれぞれ1ケースとして、計45ケースとなった。アンサンブルの実施にあたり、まず、45ケース中で危険側の誤判定が最も多い1ケース(No.28)を選択する。これに対して相関が低い4ケースを併せてアンサンブルを実施することで分類結果の補完を行い、分類性能の向上を目指した。(表-5)

表-5 抽出ケース間における分類結果の相関

ケースNo	28	5	21	35	45
28	1	0.931	0.916	0.927	0.942
5	0.931	1	0.981	0.972	0.972
21	0.916	0.981	1	0.972	0.963
35	0.927	0.972	0.972	1	0.982
45	0.942	0.972	0.963	0.982	1

抽出した5ケースによる学習結果の多数決アンサンブル実施結果を表-6に示す。表-6より、安全管理上許容されない危険側の誤判定を完全に排除することができたことが確認できる。分類精度についても0.980と、表-4に示すどのモデルよりも優れた結果となった。

表-6 アンサンブル後のテストデータ分類結果

ensemble		予測値		
		C	N	S
正解	C	27	0	0
	N	2	18	0
	S	0	2	149

また、アンサンブル実施時に抽出した5ケースについては、使用モデルや学習に用いた教師データグループの組み合わせが異なる点から、学習結果の独立性が高いと言える。(表-7)このことから、アンサンブルの結果について十分な汎化性能の確保ができたと考える。

表-7 抽出ケースにおけるモデルの独立性

ケース No	28	5	21	35	45
使用モデル No	6	1	5	7	9
学習に用いた教師データグループ No	1, 2, 4, 5	1, 2, 3, 4	2, 3, 4, 5	1, 2, 3, 4	1, 2, 3, 4

まとめ

本研究の結果から、さびの外観評価を実応用場面に則した3項分類に読み替え、複数CNNモデルによるアンサンブルを実施することにより、危険側の誤判定を排除するとともに、高い分類性能を実現することができたと言える。また、抽出した5ケースにおいては、使用モデル及び学習データの独立性が高く、単体のCNNモデルで分類精度を追求する場合に比べ汎化性能を確保できたと考える。しかしながら、アンサンブル検討時と最終的な評価時(表-6)で同一データを用いており過大評価の可能性が残されている。新規データを用いた評価を行うなど、今後更なる検証が必要である。

謝辞

本研究の一部は、日鉄エンジニアリングの助成を受けて実施したものである。ここに記して感謝致します。

参考文献

- 1) 山口栄輝ら：九州・山口地区における耐候性鋼材橋梁の実態調査，土木学会論文集A，Vol.62，No.2，pp.243-254，2006.
- 2) 公益財団法人 日本道路協会：鋼道路橋防食便覧，2014.
- 3) 川崎雄貴：AIによる耐候性鋼材のさびの外観評価，九州工業大学卒業研究，2019.