

AIによる耐候性鋼材のさびの外観評価

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. はじめに

耐候性鋼材はその表面に緻密な保護性さびを生成して、さびの進行を抑制する。塗装を不要とすることで、維持管理経費が軽減される。しかし、設置環境によっては緻密な保護性さびが生成しないこともあるため、定期的な点検と健全度の評価が必要となる。セロファンテープ試験により、簡易的に評価することができる。さびの外観評価は表-1 に示す基準に従い、専門家が主観によって決定するため、評価にはばらつきが生じ得る。そこで、本研究ではAI(人工知能)による画像分類技術を用いて、セロファンテープ試験資料から得られるさび画像を分類し、判定する。

表-1 さびの外観評価と状態¹⁾

評点	さびの状態	状態
5	さび粒子は細かいが、均一性に欠ける	正常
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	要観察
1	さびは層状で厚いが、剥離がある	異常

2. AIの構築

2.1 AIの概要

本研究では、教師あり学習と呼ばれる手法でAIの構築を行う。図-1に教師あり学習(画像分類)の概要を示す。図中のデータセットとは、本研究においては、さび画像とその評点を一組として集めた、データ群のことを指す。データセットは、トレーニングデータと評価用データに分割する。トレーニングデータは実際に画像の判定を行う、学習モデルの作成に使用する。評価用データは、作成した学習モデルの分類精度を評価するために使用する。

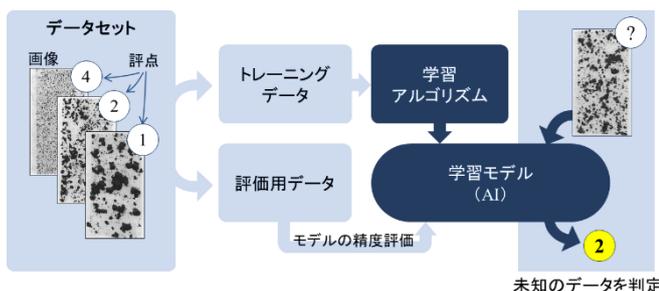


図-1 教師あり学習の概要

学習アルゴリズムとして、畳み込みニューラルネットワーク(Convolutional Neural Network, 以下 CNN)を用いる。CNNはディープラーニングの一種で、画像や動画の学習・分類に優れた学習アルゴリズムである。

2.2 データセットの作成・前処理

画像は、セロファンテープ試験資料のスキャン画像を用い、評点は、本学で外観評価を行った結果を用いて、データセットを作成する。また、さび画像に対して前処理としてトリミングとグレースケール化の処理を施し、データセットの画一化を図る。これは、最適な学習モデルを得るためには、データの特徴量の尺度が同じであることが要求されるためである。

データセットの作成・前処理作業の後、CNNでさび画像の学習を実施することで、学習モデルを得る。図-2に学習モデル構築までのフローを示す。

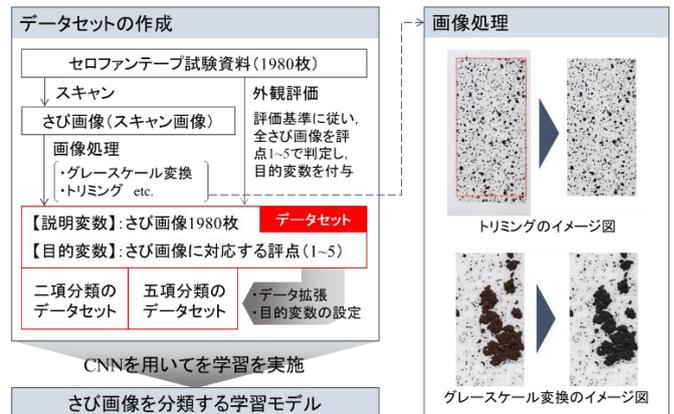


図-2 学習モデル構築までのフロー

また、学習モデルの作成にあたり、データ拡張を実施した。これは、データが少ない場合や新規でデータを追加することが困難な場合に、学習モデルの頑健性と分類精度を向上させることを目的として、使用するデータを増やす処理のことである。具体的には、画像に回転や反転等の処理を施す。

3. 学習モデルの分類精度

評価用データを用いて、学習モデルの分類精度を評価する。分類精度とは、評価用データにおける評点と学習モデルが判定した評点との一致率である。

五項分類: 「評点 1~5」に分類する学習モデルを作成する。ここでは、データ拡張なしとデータ拡張ありの 2 ケースを検

討する。表-3 に五項分類のデータセットの詳細と分類精度を示す。結果として、現状では分類精度 69%にとどまる。

表-3 五項分類のデータセットと分類精度

case	トレーニングデータ(枚)	評価用データ(枚)	分類精度(%)
5-1	1880	100	69
5-2	4500	100	55

二項分類：「正常」と「異常・要観察」に分類する学習モデルを作成する。データセットは、評点 1, 2(異常・要観察)を「危険錆」、評点 3, 4, 5(正常)を「安全錆」と定義する。これは、耐候性鋼橋の維持管理上最重要とされる、さびの外観評点 2 と 3 を判別するためである。二項分類では、8 ケースの学習モデルを検討する。表-4 に、二項分類のデータセットの詳細と分類精度を示す。いずれのケースにおいても分類精度が 9 割を超える結果が得られた。

表-4 二項分類のデータセットと分類精度

case	トレーニングデータ(枚)		評価用データ(枚)	分類精度(%)
	危険錆	安全錆		
2-1	20	140	160	91.9
2-2	60	420	160	93.1
2-3	100	700	160	94.4
2-4	140	980	160	94.4
2-5	220	1540	160	92.5
2-6	220	220	160	93.8
2-7	1540	1540	160	95.6
2-8	1540	3080	160	93.8

4. 学習モデルの妥当性

上記で得られた結果が、専門家の判定結果に対してどの程度合致しているのか、結果の妥当性を検討する必要がある。妥当性の検討には、既往の研究²⁾で扱われたさび画像 27 枚について、専門家 21 人が判定した結果を用いる。

4.1 二項分類の妥当性

各ケースにおける、専門家の判定結果と学習モデルが判定した結果の一致率を表-5 に示す。

表-5 二項分類の妥当性検討

case	AIと専門家の判定が一致した枚数(枚)	一致率(%)
2-1	17	63.0
2-2	19	70.4
2-3	19	70.4
2-4	18	66.7
2-5	16	59.3
2-6	24	88.9
2-7	25	92.6
2-8	25	92.6

表-5 より、トレーニングデータが多いケース(2-7, 2-8)では、一致率が 9 割を超える。以上より、専門家の判定を 9 割の精度で再現する学習モデルが作成できたと判断する。

4.2 五項分類の妥当性

ここでは、学習モデルに判定させた際に得られる各項目の分類確率の分布と、専門家による判定のばらつきを比較する。図-3(a)~(c)に比較結果の代表例を示す。横軸は 5 段階評価、縦軸は各評価の分布の割合を示す。

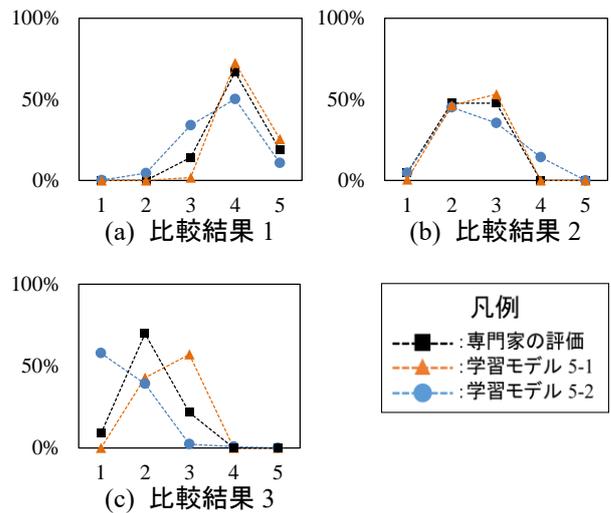


図-3 評価分布の比較結果

5. まとめ

本研究の結果から、AI の画像分類技術を用いた耐候性鋼材のさび外観評価における、自動判別の可能性が見出せた。二項分類では、9 割を超える精度で「危険錆」と「安全錆」を判定することが可能である。五項分類では、専門家の判定結果のばらつきを概観することが可能となった。しかし、一部のさび画像において分布傾向が整合しない状況があり、精度向上が求められる。

今後は、学習モデルの分類精度向上を目的に、教師データの最適化や他の学習アルゴリズムを用いた画像判定などを検討する必要がある。

謝辞

本研究は日本鉄鋼連盟の助成を受けて実施したものである。ここに記して深謝します。

参考文献

- 1) 日本道路協会:鋼道路橋塗装・防食便覧, 2005.
- 2) 森田千尋, 梅崎俊介, 山口栄輝, 松田浩, 武崎啓太:セロフアンテープ試験の画像解析による耐候性鋼材のさびの外観評価, 構造工学論文集 A, Vol.61, 2015.