

## 機械学習を用いた耐候性鋼材におけるさび外観評価レベル判別法の開発

八戸工業高等専門学校 環境都市・建築デザインコース 正会員 杉田 尚男

### 1. はじめに

耐候性鋼材の安定化さびの形成は環境の影響を受けやすく、そのため耐候性鋼材を採用した構造物は、施工後の点検・調査が必要である。しかし、目視で行う外観評価法は評価者主観によるバイアスが評価に影響してしまうという問題がある。その問題を解決するため、機械学習を用いた耐候性鋼材の腐食状況判別に関する評価モデルを開発する研究を行なった。学習モデルを作成する手法として、画像認識で代表的な CNN (Convolutional Neural Network) を用いて学習モデルの作成を行なった。また、パラメータチューニングによりモデルを最適化した。

### 2. 研究背景

これまで耐候性鋼材を採用した構造物の点検・調査には目視での調査が行われてきた。しかし、目視調査は費用増大や事故、評価者の主観により精度がバラついてしまうなどの問題点がある。そこで機械学習を用いた外観評価モデルを作成することで、一定で高精度な評価を担保できるものにするというモチベーションが本研究の背景となっている。

### 3. 研究内容

過去の研究では、精度が 30%~50%と低く実用的な学習モデルを作成することは困難であるとされていた。そこで本研究では、画像認識の分野で優れた性能を発揮している CNN を用いてより高精度な学習モデルを開発した。また、学習率を調整することでモデルを最適化した。

#### 3.1 畳み込みニューラルネットワーク (CNN) <sup>1)</sup>

CNN (Convolutional Neural Network) は、全結合層だけでなく畳み込み層とプーリング層から構成されるニューラルネットワークである。CNN の特徴として "合成性" "移動不変性" の 2 つが挙げ

られる。これらの特徴によって層の深いネットワーク構成は高レベルな特徴を学習でき、特徴を検知する物体が画像のどこにあっても精度に影響しない。

- 畳み込み層 (Conv2D)  
画像の特徴的な部分を抽象化する役割
- プーリング層 (Max-Pooling2D)  
平行移動に対する不変性を持たせる役割




図 1 CNN 概要

#### 3.2 モデル最適化

機械学習モデルの作成で最も重要なパラメータである学習率を最適化するアルゴリズムを組み込むことでモデル最適化を行った。本研究では Adam, SGD, RMSProp の 3 つの最適化アルゴリズムを用いた。

#### 3.3 本研究で実装した CNN

本研究では畳み込み層 4 層、プーリング層 2 層、全結合層 2 層の合計 8 層の CNN を実装した。また、中間層の活性化関数には LeRU 関数、出力層の活性化関数には Softmax 関数、損失関数は交差エントロピー誤差を用いた。

#### 3.4 さびの外観評価レベル

耐候性鋼材のさび層は、評価によって 1~5 のレベルに区分されている。(表 1 参照)

Key Words : 耐候性鋼材・ニューラルネットワーク・畳み込み型ニューラルネットワーク・機械学習  
連絡先 : 〒039-1104 青森県八戸市田面木字上野平 16-1 TEL・FAX : 0178-(27)-7313

表 1 さび外観評価の評価基準

	評価基準		評価
	さびの粒径	さびの色調	
レベル5	小さく均一	明るい	↑ ↓
レベル4	小さく均一	暗い	
レベル3	1~5mmで粗い	ぼらつきがある	
レベル2	5~25mm	剥離がある	
レベル1	25mm以上	層状剥離がある	

#### 4. 結果と考察

今回は学習モデルを”正解率”と”損失関数”の 2 つの指標で評価した。

##### 4.1 学習モデルの精度（正解率）

図 2 はモデルの学習過程における最適化アルゴリズムと精度変化を示したものである。はじめに SDG でモデル最適化を行ったが精度が激しく振動し学習が安定しなかった。この要因として学習率を 0.1 で固定していたことが挙げられる。パラメータ毎の勾配の大きさに差があるとパラメータの更新速度に大きな差がついてしまう。しかし勾配が小さいパラメータに合わせた学習率にすると振動が激しくなるため安定した学習ができないという欠点があった。

次に、SGD の欠点である振動を抑制するため RMSProp を用いて学習モデルを作成した。RMSProp は勾配の大きさに応じて学習率を調整する最適化アルゴリズムで、SGD よりも安定した学習を行うことができた。しかし、精度が 95% を超えてから振動し収束しなかった。

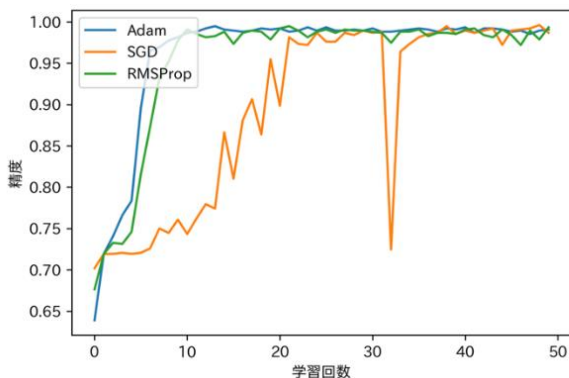


図 2 最適化アルゴリズムによる精度比較

より安定した学習にするために、RMSProp と勾配を移動平均する Momentum を組み合わせた Adam

を実装した。他の 2 つに比べ精度の収束が早く安定した学習モデルとなり、最終的な精度は 99.8% となった。

##### 4.2 学習モデルと損失関数

教師あり学習では、データセット  $(x, y)$  が与えられた時、パラメータ  $\theta$  が持つ関数  $f(x, \theta)$  の出力値が  $y$  に近くなるように学習を行う。この時、関数  $f$  の出力値と実際の  $y$  の値の差を関数と定義したものが損失関数である。

図 3 はモデルの学習過程における最適化アルゴリズムと損失関数の変化を示したものである。SGD と RMSProp と比較して、Adam は損失関数の出力値が小さく、0 付近で安定している。一般的に損失関数が小さいほど正確なモデルとされており、Adam を用いた学習モデルは損失関数の出力値が 0 に収束しているため正確なモデルであるといえる。

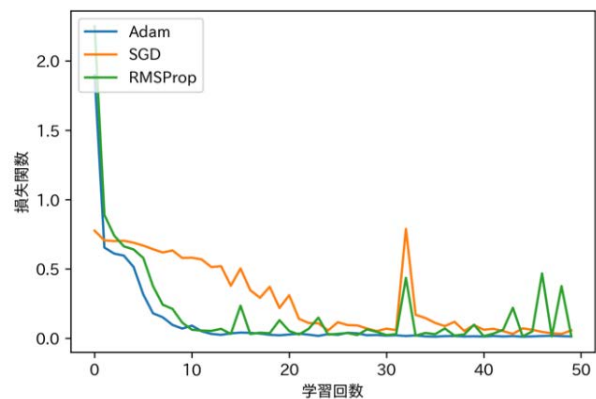


図 3 モデルの学習過程と損失関数

#### 5. まとめ

本研究では耐候性鋼材のさび評価をレベル 1~5 に分類するタスクにおいて、CNN 用いた学習モデルを作成し、学習率を決定する最適化アルゴリズムを比較検討した。従来の研究の課題である、学習が不安定、精度が低いといった点を、CNN を用いることで改善することができた。また、最適化アルゴリズムの検討については 3 つの手法を比較し Adam がこのタスクにおいて有効性が高いと確認された。

#### 参考文献

1) 中井 悦司, IT エンジニアのための機械学習理論入門技術評論社, 2015