

光学スペクトルの特徴波長に着目した耐候性鋼材のさび評価

山口大学大学院 学生会員○井上龍一

山口大学大学院 正 会 員 蓮池里菜 麻生稔彦

日本工営（株） 非 会 員 古木宏和

1. はじめに

耐候性鋼橋梁の維持管理には、さび状態の定期的な把握が必要である。これまでもデジタルカメラ画像に機械学習を適用したさび状態の評価方法が提案されてきた¹⁾が、さびには様々な色調があるため評価が困難な場合もある。本研究では、可視光以外の波長にも着目する必要があると考え、可視光と近赤外線の光学スペクトルにランダムフォレストを適用したさび状態の評価方法を検討する。従来の研究では、クラス分類の前処理として、クラス分類に有効な波長の選択や次元削減法によるスペクトル特徴の抽出が使用されてきた²⁾。本研究ではこれら 2 つの前処理を組み合わせた評価方法を検討し、その有用性を示す。なお、本研究では、維持管理上の対応を分けるさび厚 200-400 μm のさび（クラス A）とさび厚 400-800 μm （クラス B）のさびの分類を試みる。

2. スペクトルの測定方法と測定されたスペクトル

ハイパースペクトルカメラ（HSC）で耐候性鋼材表面の光学スペクトルを測定した。波長分解能は 7 nm で、波長 400-1000 nm の光を 204 バンドに分光したスペクトルが測定可能である。スペクトル測定の基準板には特定の光を吸収しない硫酸バリウム板を使用し、被写体の放射輝度値を基準板の放射輝度値で除すことで反射強度を算出した。

図 1 に実験風景を示す。実験の再現性を確保するために、光源以外は照度 0 Lux の室内でスペクトルを測定した。光源には、可視光から近赤外線までの幅広い波長域をもつハロゲンライト（500 W）を使用した。試験体全体を測定するために、HSC は試料から 20-30 cm 離して設置した。

図 2 に試験体の一例を示す。左は 15×7 cm、右は 7×7 cm の試験体である。試験体の端部のさび厚を測定することは困難であり、15×7 cm の試験体には貫通孔がある。そのため、スペクトルの測定範囲はそれぞれ 11×6 cm と 6×6 cm とした。本研究ではこの測定範囲を 1 cm 四方に分割し、1 つの試料とした。各試料の中心のさび厚を測定し、教師あり学習の正解データとした。クラス A は 263 試料、クラス B は 265 試料である。

図 3 にスペクトルの例とその一次微分を示す。両クラスとも、スペクトル曲線は波長 516 nm と 896 nm に極小値をもち、波長 796 nm に極大値をもつ。また、波長 569 nm と 694 nm の一次微分値はその周辺の波長の一次微分値よりも大きい。この傾向は、全ての試料でみられた。

3. スペクトルの前処理と分類器の構築

全波長のスペクトルは、さび状態の分類に必要な情報をもつ可能性がある。そこで、図 3 に示す波長の中から 2 クラス分類に有効な波長を選択した。図 4 に波長 516 nm と 694 nm における反射強度の箱ひげ図を



図1 実験風景






図2 試験体の例



(a) スペクトル



(b) 一次微分

図3 スペクトルとその一次微分

キーワード 可視光 近赤外線 波長選択 カーネル主成分分析 ランダムフォレスト分類器

連絡先 〒755-8611 山口県宇部市常盤台 2-16-1 山口大学工学部社会建設工学科 TEL 0836-85-9323

示す。波長 516 nm では箱の大きさや位置から 2 つのさび状態を区別できないが、波長 694 nm では箱の大きさや位置から 2 つのさび状態を概ね区別できる。図 3 に示す他の波長（569 nm, 796 nm および 896 nm）においても同様の傾向がみられた。従って、波長 569 nm, 694 nm, 796 nm および 896 nm を 2 クラス分類に有効な波長（特徴波長）と仮定する。

土壌中の栄養素のスペクトルについて、Qi ら³⁾は次元削減されたスペクトルを用いて分類器を構築することで過学習を防止できることを報告した。この方法は耐候性鋼材のさび状態の分類にも有効であると考えられるため、本研究でも測定されたスペクトルの次元を削減した。特徴波長における反射強度に次元削減法を適用し、抽出された第一、第二主成分を用いて分類器を構築する。次元削減アルゴリズムには主成分分析（PCA）が使用されることが多いが、PCA は非線形データに対応できない。そのため、PCA と非線形データにも対応可能なカーネル PCA（KPCA）を使用した場合の分類精度を比較した。

分類器は、2 クラス分類の教師あり学習アルゴリズムとしてよく使われる決定木のアンサンブル学習であるランダムフォレストを用いて構築した。学習データは各 180 試料、検証データは各 20 試料、残りの試料（クラス A が 63 試料、クラス B が 65 試料）をテストデータとして使用した。

4. 分類結果と考察

PCA を使用した場合の正解率は 64.8 %、KPCA を使用した場合の分類精度は 100.0 %であった。

図 5 に特徴波長における反射強度に対して PCA と KPCA を適用して得られた第 1、第 2 主成分を示す。KPCA を使用した場合の方が各クラスのデータ群の重なりが少なく、各クラスのデータをより明瞭に分離することができる。その結果、正解率が高くなると考えられる。一方、PCA を使用した場合は 2 つのクラスを明瞭に分離できないため、正解率が低い。

本研究では 4 つの波長を特徴波長としたが、感度分析によってどの波長が分類結果に影響を与えるか検討した。そのために、特徴波長の中から 3 つの波長を選び、再度分類器を構築した。なお、次元削減法には KPCA を用いた。その結果を表 1 に示す。波長 796 nm を使用しない分類器のみ正解率が若干下がるが、分類器構築のためには 4 つの波長が必要である。

5. まとめ

KPCA によって特長波長（569 nm, 694 nm, 796 nm および 896 nm）における反射強度から第一、第二主成分を抽出し、これにランダムフォレストを適用した分類器を構築した。この分類器によって、さび厚 200-400 μm のさびとさび厚 400-800 μm のさびは 100.0 %の精度で区別できる。

本研究は、JST 次世代研究者挑戦的研究プログラム JPMJSP2111 の支援を受けた。

参考文献

1) 蓮池ら：畳み込みニューラルネットワークを用いた耐候性鋼材腐食部劣化度判定の試み, AI・データサイエンス論文集, 2 巻, J2 号, pp. 813-820, 2021.

2) 横矢ら：ハイパースペクトル画像処理が拓く新しい地球観測, 人工知能, 29 巻, 4 号, pp. 357-365, 2014.

3) H. Qi et al.: Evaluating calibration methods for predicting soil available nutrients using hyperspectral VNIR data, Soil and Tillage Research, 175, 267-275, 2018.






図4 反射強度の箱ひげ図



(a) PCA



(b) KPCA

図5 第一、第二主成分

表1 感度分析

波長569 nmなし	100.0 %
波長694 nmなし	100.0 %
波長796 nmなし	99.2 %
波長896 nmなし	100.0 %