

転移学習 CNN に基づくコンクリート変状要因の外観判別用機械学習モデル

福井大学大学院 学生会員 ○松下 将大
 福井大学 正会員 鈴木 啓悟
 中日本ハイウェイ・エンジニアリング名古屋株式会社 正会員 五味 達矢
 中日本ハイウェイ・エンジニアリング名古屋株式会社 正会員 可計 皓規
 中日本ハイウェイ・エンジニアリング名古屋株式会社 正会員 鳥居 和之

1. 研究の背景と目的

近年、わが国では、ASR、塩害、凍害などの劣化の生じたコンクリート橋梁が確認されている。これら橋梁の安全性および機能性を確保するために、コンクリートの劣化現象を的確に評価し、適切なメンテナンスを行うことが重要である。また、2014年には道路法の改正に伴い、各種構造物の5年に一度の近接目視点検の義務化を受け、客観的かつ効率的な判断手法の構築が求められる。本研究は、転移学習 CNN と機械学習を用い、コンクリート橋梁の変状要因を画像から自動判断するための学習モデルを構築する。

2. 分類アルゴリズム

今回の研究では、ASR、鉄筋腐食(塩害を含む)、凍害の3分類モデルを構築する。画像の特徴抽出器には、ImageNetで事前学習したCNN(畳み込みニューラルネットワーク)を用いる。そのモデルには、著名な3モデル(VGG19, ResNet-50, EfficientNet-B0)を用意した。ここで、コンクリート橋梁の変状要因の判別において、外観の情報のみから判断することは困難であり、実際の点検においても、外観に加え、使用骨材や架設年代の情報、さらに必要に応じて詳細調査を実施し、総合的に判断している。これらを踏まえ、実装モデルでは、画像情報に加え、立地・骨材などの追加情報をベクトル特徴量に結合する。コンクリート変状画像は自然画像と異なり、画像勾配や輝度の特徴が小さく、分類が難しくなると考えられる。そのため、ベクトルの分類に多くの成果を上げている、ロジスティック回帰(LR)、サポートベクターマシン(SVM)、ランダムフォレスト(RF)を適用し、それらの精度を比較検証した。この実装モデルの概略図を図-1に示す。

3. 画像データの準備

3.1 前処理方法

画像データの前処理については、グレースケール化と輝度分布調整の2手法の適用を試みる。グレースケール化は、色調の違いによる誤判定を避けるために行う。グレースケール化には、コンクリート表面の色チョークに

よるマーク部を、相対的に明るくすることでひび割れと誤認することを避ける効果がある、RGB成分の最大値を輝度値とする最大値手法(RGBmax)を用意した。

輝度分布の調整として、適応的ヒストグラム平坦化手法(CLAHE)を用意した。この処理は、明るさを均一にし、ヒストグラムを平坦化することで、輝度値の偏りを防ぎ、画像のコントラストを調整する効果があり、時間帯によって明るさが変化する影響を低減できる。これら前処理の適用例を図-2に示す。

転移学習 CNN については、カラーの自然画像で構成される ImageNet を事前学習している理由で R, G, B の3情報を入力する必要がある。そのため、グレースケールの輝度値を R, G, B に等しく割りあててことで、3次元変換した。

3.2 画像の切り出し・拡張

画像データの切り出しについては、元画像から変状部分のみを手動でトリミングし、224×224pxの枠でランダムに切り取った。その切り取り枚数




図-1 実装モデルの概略




図-2 前処理の適用例

キーワード コンクリート橋梁 劣化原因判別 転移学習 画像処理 CNN 機械学習
 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 写真枚数と細断画像枚数

劣化要因	写真枚数 (train:val:test)	細断画像枚数			
		train	val	test	合計
ASR	319 (216:45:45)	4320	135	135	4590
鉄筋腐食 (塩害)	153 (154:32:32)	4312	128	128	4568
凍害	30 (15:4:4)	4200	120	120	4440
合計	547(385:81:81)	12832	383	383	13598

表-2 変数対応表

変数名	回答方法	変数名	回答方法
①撮影距離	0～4	⑤幅員	長さ(m)
②陸橋 or 河川橋	1, 0 (陸なら 1)	⑥構造種類	構造名 (桁部, 床板など)
③河川系統	川の名前	⑦架設年度	西暦(年)
④河川距離	距離(m)	⑧標高	高さ(m)

※撮影距離—0.超近接距離(10cm 付近) 1.近接距離(10cm~50cm)
2.中距離(50cm~100cm) 3.中距離以上遠距離未満(100cm~300cm)
4.遠距離(300cm~)

については、収集画像における劣化種類ごとの枚数に応じて、均等なサンプル数となるように選択した。また、学習データのみ、生成された複数枚画像のそれぞれに、回転処理(90°, 180°, 270°)を施すことで画像データを 4 倍に拡張した。

4. モデル構築と精度検証

モデルには、北陸地方における自動車専用道路の橋梁、一般道路橋の収集した画像、オンラインで収集した橋梁の変状画像をサンプルデータとして使用した。検証、テストデータについては、画像収集元の橋梁をランダムに選択した。その元画像枚数と生成画像データ数を表-1 に示す。分類器の各種ハイパーパラメータについて、LR(C=0.0001 ~ 1), SVM(kernel=rbf, C=0.0001 ~ 1, gamma=0.0001 ~ 1), RF(n_estimators=10 ~ 300, max_depth=3~20)で交差検証を行い、最も優れた精度となったパラメータを採用し、テスト検証を行った。また、このモデルの追加情報については、8 つのデータを名義尺度、順序尺度などの特性に応じ、OneHot 化、正規化して数値化した。ただしRFについては、構造上OneHot化、正規化の必要がないため行っていない。これら追加情報の変数対応表を表-2 に示す。

これらの条件で、モデルごとに精度検証をした結果を図-3 に示す。図-3 より、3 つの CNN モデルすべてにおいて、LR, SVM を使用した場合では、80%に近い精度で分類できることが分かり、そのうち、VGG19 の SVM モデルは 82.8%の精度と、おおむね良好に判定できることが分かった。また、RF を使用したモデルについては、




図-3 各種モデルでの精度比較




図-4 VGG19-RF モデルによる追加情報の特徴重要度

VGG19 以外では精度が減少することが分かった。これは、ResNet-50, EfficientNet-B0 ともに、出力される画像のベクトル特徴数が約 2000 個と多いのに対し、追加情報特徴数は 8 つとかなり少なく、アンサンブル学習におけるデータのバランスが良くない可能性があると考えられる。つぎに、RF モデルは特徴重要度を算出できる機能があり、今回は 76%の精度である VGG19 の RF モデルを用い、画像+追加情報の全重要度ベクトルから、追加情報のみを抽出(図-4)した。重要度の高い⑤幅員については、小規模橋梁の施工不良による鉄筋腐食の事例が訓練データに含まれるので特徴重要度が高まった可能性がある。⑧標高については、凍害のサンプルデータが、標高の高い場所に位置する橋梁のみとなっており、それらを分類するため重要であったと考えられる。

5. まとめ

転移学習 CNN による特徴抽出を行い、機械学習を分類器に用いることで、コンクリート外観変状の判別に良好な精度を有する学習モデルを構築できる。本研究では、学習画像 385 枚、テスト画像 81 枚について VGG19 と SVM により 82.8%の精度を記録した。また、RF を使用することで、ベクトル特徴量の重要度を調べることができた。しかし、現在は非常に少ないデータ数で学習を行っており、汎用性が低い可能性があるため、さらにデータを収集し、引き続き精度検証を行い、モデルの汎化性能を高める必要がある。