

画像によるレール継目部の異常抽出技術の基礎的検討

西日本旅客鉄道株式会社 正会員 ○渡邊 達郎
西日本旅客鉄道株式会社 正会員 藤原 武実
株式会社ニシヤマ 近藤 英記

1. はじめに

将来の労働人口減少を見据えた効率的な線路設備のメンテナンス体制の構築が喫緊の課題であり、特に多くの労力がかかる人力による線路の保守状態検査について重点的に検討している。今回、線路の保守状態検査の効率化、及び精度向上を目的として、車上から撮影した画像について機械学習技術を活用した線路の異常(設備故障)を抽出する手法を検討したのでその概要について以下に報告する。なお、本稿における線路の異常とは、レール継目部における継目板ボルト脱落を対象とした。

2. 線路画像データ習得の概要

機械学習に用いる学習データを取得するために、在来線高速軌道検測車(以下、「キヤ車」という。)の前頭部の右側に設置した1台のラインセンサカメラによって表-1の通り撮影を実施した(写真-1)。撮影の際には、写真-2のようにキヤ車走行前に継目板ボルト脱落状態を再現し、異常画像データの取得を行った。なお、カメラの画素数は2,048pix、撮影間隔は1.5mmとなっている。

表-1 車上撮影諸元

撮影日	天候	線名	撮影区間(往復)
2018.9.16	曇	小浜線	敦賀～東舞鶴
2018.9.17	曇	越美北線	南福井～九頭竜
2018.9.20	曇時々雨	高山線	猪谷～富山



写真-1 画像取得風景



写真-2 継目板ボルト脱落再現

3. レール継目部抽出機能の検討

継目板ボルトの脱落判定を行うための第1段階として、撮影した連続画像の中から継目部を自動抽出させる手法を検討した。連続画像を2,048×2,048pixに切出し、継目部と継目部以外の箇所を手作業で抽出し768×768pixの矩形でラベルをつける作業(以下、「タグ付け」という。)を実施した。これらのタグ付けされた画像データを入力値として継目部を自動的に抽出する機械学習モデル(以下、「自動判定モデル」という。)を構築し検討を行った。

(1) 機械学習手法

画像データ判定において、現在有用な結果が示されている畳み込みニューラルネットワーク(CNN)による機械学習(Deep Learning)手法を検討することとした。本稿においては様々な技術がある中、判定精度を重視し、Faster R-CNNとInception Resnet V2を組み合わせた物体検出技術を用いて自動判定モデルを作成し、線路画像からレール継目部の抽出を行った。

(2) 自動判定モデルの評価

タグ付けされた画像データを学習させた自動判定モデルにより検証データの判定を行い、結果の評価を行う。各データ数の内訳を表-2に示す。

また、自動判定モデルの性能評価については、表-3に分類される判定結果より得られる再現率と適合率を代表値として継目部抽出精度の評価を行う。(後述する4章の異常抽出についても同様)

表-2 学習・検証データ数

データ種別	継目部	継目部以外
学習データ	8,486	75,961
検証データ	4,480	38,440

表-3 性能評価に用いた指数(継目部抽出の例)

		自動判定結果	
		継目部	継目部以外
正解	継目部	A	B
	継目部以外	C	D

○再現率: $\text{継目部の抽出精度} = A / (A + B)$

$\text{継目部以外の抽出精度} = D / (C + D)$

○適合率: $\text{継目部と自動判定した結果の正答率} = A / (A + C)$

$\text{継目部以外と自動判定した結果の正答率} = D / (B + D)$

自動判定モデルによる継目部抽出結果を表-4に示す。継目部の抽出は、日照条件が曇・雨の悪条件のなかで、再現率96.3%、適合率97.9%と高い精度となった一方で、誤判定も存在した。今回抽出漏れとなったのは、図-1のような電柱の影や雑草等の介在物により継目部の特徴が失われる特異な箇所であった。また、抽出誤りについては、図-2のようなレール頭頂面のマーキングやレール傷等のレール頭頂部の特異な模様が原因となっていた。これらの誤判定は様々な学習データを揃え、学習させることで改善可能である。

表-4 継目部抽出の自動判定結果

		自動判定結果				再現率 【%】	適合率 【%】
		継目部		継目部以外			
正解	継目部	A	4313	B	167	96.3	97.9
	継目部以外	C	94	D	38,346	99.8	99.6

キーワード 機械学習 画像処理 継目部 異常抽出

連絡先 〒530-8341 大阪市北区芝田2丁目4番24号 西日本旅客鉄道(株) 施設部 施設技術室 TEL 06-6375-2156



図-1 継目部抽出漏れ例



図-2 継目部抽出誤り例

4. レール継目部の異常抽出機能の検討

レール継目部の異常抽出をする第2段階として、3章の手法により抽出されたレール継目画像から継目板ボルトの有無を抽出する手法を検討した。初めに、図-3のように継目画像の中から継目板ボルトのナットやボルト頭、継目板ボルトを撤去し脱落状態を再現した箇所(以下、「継目板ボルト穴」という)の3種を手作業でタグ付けし学習・検証データを作成した。次に、タグ付けしたデータを学習させ、継目板ボルトのナット、ボルト頭、継目板ボルト穴を自動判定する自動判定モデルを作成し、評価を行った。



黄枠：ボルト頭 緑枠：ナット 赤枠：継目板ボルト穴

図-3 タグ付けの一例

(1)機械学習手法

3.(1)と同様の手法を用いて継目画像から継目板ボルトの状態別に抽出を行った。

(2)自動判定モデルの評価

表-5に、学習および検証に用いたデータ数を示す。継目板ボルト穴については、ナット、ボルト頭と比較すると学習枚数が非常に少ないため、偏った学習となる恐れがある。そこで、継目板ボルト穴の明度、彩度、色相の値をランダムに変化させてナット、ボルト頭と同程度の数量に増加させ、学習させた。

表-5 学習・検証データ数

データ種別	ナット	ボルト頭	継目板ボルト穴
学習データ	約14,000	約20,000	181
検証データ	約7,000	約10,000	80

これらデータを学習させて自動判定モデルを作成し、検証データの判定を行い、結果の評価を行った。その結果を表-6に示す。ナットについては、他と比較すると画像から特徴を確認しやすいため、再現率、適合率ともに95%を超える結果となった。一方で、ボルト頭と継目板ボルト穴については、再現率、適合率ともに80%前後となった。その理由としては、日照条件の影響に加え、図-4.5に示すように、日照方向によってボルト頭と継目板ボルト穴の特徴が類似することが考えられる。

表-6 検出結果

種別	再現率(%)	適合率(%)
ナット	96.7	97.5
ボルト頭	77.7	86.0
継目板ボルト穴	84.3	79.5



図-4 特徴の類似(左:ボルト頭 右:継目板ボルト穴)

続いて、実運用を考えると、ナット、ボルト頭、継目板ボルト穴と細分化しても現地確認は継目単位で行うため、継目単位での評価を行った。その結果を表-7に示す。正常継目に関しては、4,194 継目中 3,523 継目を正常と判定でき、再現率は84.0%、適合率は99.9%となった。一方、異常継目については80 継目中 77 継目を異常判定でき、再現率は96.3%となった。しかし、正常継目を671 継目誤判定してしまったため、異常継目の適合率が10.3%と非常に低くなってしまった。これについては、日照条件が影響していると考えており、誤判定した671枚の画像は、明度が低いものが多く、継目板ボルトの特徴把握が困難であった。そこで、画像の明度が判定精度にどの程度影響するかを検討するため、画像毎に平均明度を算出し、4つのレベルに分類し、ナットとボルト頭の判定精度を検証した。その結果を図-5に示す。明度が高いほど再現率と適合率が高い傾向にあるため、営業列車での撮影により測定頻度が高くなれば日照条件を満たすデータを選択して解析することが可能となり、判定精度のレベルを確保することが可能となる。

表-7 継目単位での評価結果

		自動判定				再現率	適合率
		正常継目		異常継目			
正解	正常継目	A	3, 523	B	671	84. 0%	99. 9%
	異常継目	C	3	D	77	96. 3%	10. 3%




図-5 画像の平均明度毎の評価

5. まとめ

車両前頭部に設置したカメラで取得した線路の画像を用いて、継目板ボルトの脱落抽出手法について検討した。日照条件が良好でなく、外乱要因が含まれた状態でも、機械学習手法を用いることで、車両前頭部に設置したカメラで取得した線路画像から継目板ボルトの脱落状態を把握できる可能性があることを確認した。今後は、撮影条件や機械学習手法の最適化、多種多様な学習データの確保等によって、異常抽出の精度向上を図るとともに、対象物拡大検討等、実用化を目指して行く。