

D-6 線路設備モニタリングシステム の AI による判定可能性の検討 Study on Judgment Possibility of Rail Track Facility Monitoring System Using AI

指導教授 轟 朝幸

5026 岡 凌大

1. はじめに

近年、IT 技術の発展により、保守・メンテナンスで状態基準保全という、状態を常時監視する検査方法が進められている。鉄道では、車両に搭載しているカメラで軌道上を撮影し、規定された締結装置の脱落の有無を確認している。

しかし、締結装置に草や石が接触、もしくは被さっている場合、安全上は問題ないのに一次判定システムでは NG 判定となり、それらは人による目視確認作業（二次判定）が必要となる。その目視作業は膨大であり、AI 等の活用で効率化できないかが課題となっている。

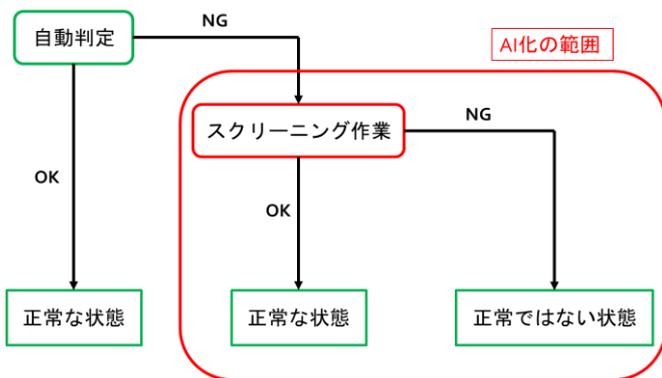


図-1 AI化の範囲

そこで本研究では、現システムでは、安全上問題のない NG 判定が、どのような状況によって影響があるのかといった傾向を明らかにする。また、NG 判定された画像の再判定を AI で実行できるか検証することを目的とする（図-1 参照）。

2. 既存研究の整理

半澤ら¹⁾の研究では、外観検査自動化システム実現に向け、多様な欠陥を検出する検出可能にする欠陥検出アルゴリズムを提案・適用している。466 枚の検査画像に適用試験を行った結果、従来の手法より高い精度を示した。また、ディープラーニングは十分な枚数の学習画像の確保が困難であった為、アルゴリズムによる外観検査の自動化を提案していた。

本研究の対象である画像も膨大であるため、ディープラーニング (AI) での解析が適切と考えている。また、本研究での自然物と締結装置脱落の区分の自動化はま

だ手掛けておらず新規性がある。

3. 使用データ

画像データは、株式会社日本線路技術から提供いただいた実際の現場で取得している軌道上の締結装置の画像である（図-2 参照）。

本研究で使用データは、一次判定で NG となったが目視判定では OK となった 875 枚、および目視判定でも NG となった 180 枚である。

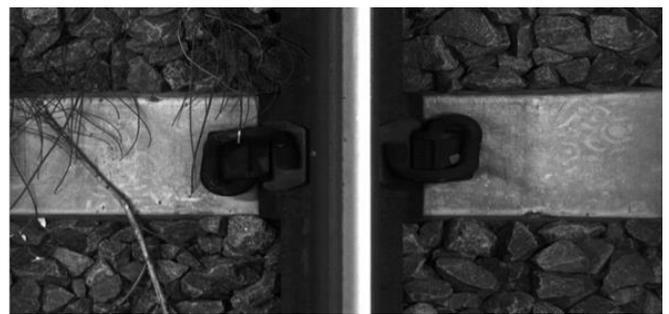


図-2 判定される範囲

4. 分析手法

4.1 誤判定要因の基礎分析

画像データを、表-1 のように状況ごとに区分していく。どのような状況下でどのように判定されるのか分かりやすくするためである。草の量および異物の被覆率は、目視および範囲面積に対する割合を算出する。範囲は、締結部を中心に縦横 176mm とする。バラストは縦横 40mm と仮定した。その結果、従来のシステムでは、被覆率 10%以下でも誤判定となることが明らかとなった。

また、目視判定において、NG 判定となるものは全てが締結装置の脱落および損傷であった。

表-1 異物・環境別の要因表

No	枕木	締結	目視判定	明暗	草(形状)	草(接触箇所)	石(量)	石(接触箇所)	NG理由 備考
1	PC	板ばね	○	暗	雑草	枕木・締結部	X	X	レールベース接触
2	PC	板ばね	○	暗	枝	枕木	X	X	レールベース接触
3	PC	板ばね	○	暗	枝	枕木・締結部	X	X	レールベース接触
4	PC	板ばね	○	暗	枝	締結部	X	X	レールベース接触・レールに沿って
5	PC	板ばね	○	暗	X	X	10%	枕木・締結部	
6	PC	板ばね	○	暗	X	X	50%	枕木・締結部	レールベース接触
7	PC	板ばね	○	暗	X	X	10%	枕木・締結部	
8	PC	板ばね	○	暗	雑草	枕木・締結部	X	X	レールベース接触
9	PC	板ばね	○	明	雑草	枕木・締結部	X	X	
10	PC	板ばね	○	明	枝	締結部	75%	枕木・締結部	レールベース接触・レールに沿って
11	PC	板ばね	○	明	枝	枕木・締結部	X	X	レールベース接触
12	PC	板ばね	○	明	枝	枕木・締結部	X	X	レールベース接触
13	PC	板ばね	○	明	X	X	10%	枕木・締結部	
14	PC	板ばね	○	明	X	X	50%	枕木・締結部	レールベース接触
15	PC	板ばね	○	明	X	X	50%	枕木・締結部	
16	PC	板ばね	○	明	X	X	50%	枕木・締結部	
17	PC	板ばね	○	明	雑草	枕木・締結部	X	X	
18	PC	板ばね	○	暗	X	X	75%	枕木・締結部	レールベース接触

4. 2 ディープラーニング

ディープラーニングの手法は、大量のラベル付けデータを学習用コンピュータに認識させ、のちに判定対象の画像を読み込ませ判定していく。分析手順を図-3に示す。

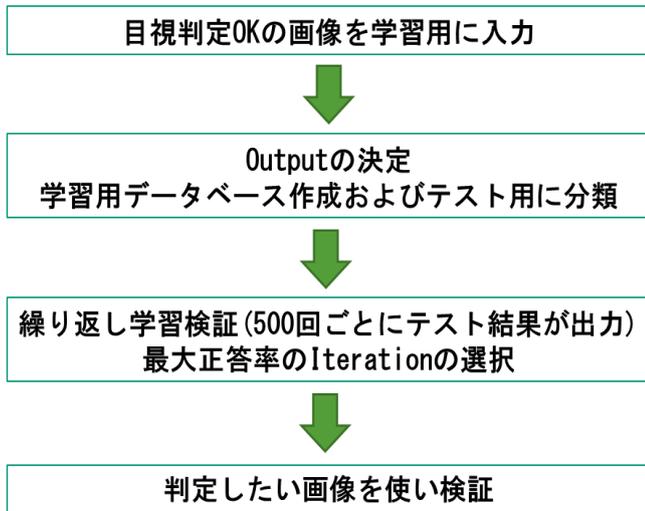


図-3 分析フロー図

5. 分析結果と考察

表-2 ファインチューニング結果

Iters	Seconds	Test Accuracy	Test Loss
500	206,457,528	0.99075	0.0117641
1,000	413,938,354	0.99075	0.00902212
1,500	619,251,634	0.99075	0.00792191
2,000	823,430,635	0.99075	0.0104724
2,500	1,027,651,729	0.99075	0.00785509
3,000	1,231,985,008	0.99075	0.00803694

学習用データベース作成のため、500回・1,000回・1,500回・2,000回・2,500回・3,000回の6パターンで繰り返し学習した。その結果、6パターン全てにおいてTest Accuracy (テストデータに対する分類の正答率)の値が、99.075%と高い精度となった。その中で、今回の判定検証では、Test loss (テストデータに対する損失関数)の値が最も低かった2,500回の結果を採用し、判定対象の画像データを検証する。

目視判定OK、NGともに、ランダムで計10枚の画像データを使用して検証した。結果は表-2に示す。

10枚全て目視判定通りの正確な結果となり、ディープラーニングでの検証が可能であることが分かった。ただし、Test Accuracyにおいて10枚に1枚が誤判定となる可能性がある。

表-3 判定結果

No	枕木	締結	目視判定	明暗	草(形状)	草(接触箇所)	石(量)	石(接触箇所)	NG理由	DP結果
826	PC	バンドロール	○	明	×	×	30%	枕木・締結部		○
818	PC	バンドロール	○	明	×	×	50%	枕木・締結部		○
766	PC	バンドロール	○	明	×	×	10%	締結部		○
36	PC	板ばね	×	暗	×	×	×	×	締結部脱落	×
23	PC	バンドロール	×	暗	×	×	×	×	締結部脱落	×
22	PC	板ばね	×	暗	×	×	×	×	締結部脱落	×
35	PC	板ばね	×	暗	×	×	×	×	締結部脱落	×
258	PC	板ばね	○	暗	枝	枕木・締結部	×	×		○
250	PC	板ばね	○	明	雑草	枕木・締結部	×	×		○
21	PC	バンドロール	×	明	×	×	×	×	締結部脱落	×

6. おわりに

本研究の結果では、ディープラーニングで概ね適切に判定出来たが、テストデータに対する分類の正答率が99.075%という結果であり、100枚につき1枚が誤判定という確率は、安全面を踏まえ考えると課題となる。

誤判定要因分析の結果では、従来のシステムであると、被覆率10%以下でも誤判定となることが明らかとなり、目視判定においてNG判定となるものは、全てが締結装置の脱落および損傷であった。

今後の課題としては、今回約1,000枚を基準にディープラーニングで実証したが、実用に向け、より高い精度の結果を得るには学習データおよび検査データの枚数を増やすことが重要である。また、雑草は様々な種類、形があり、ディープラーニングの学習用データベース作成時に未学習であると誤判定の可能性があるため、自然物のデータもより多く必要である。結果次第では、自然物と人工物の区別の基礎になり、導入の際の指標になるものと考えられる。

謝辞

本研究を進めるにあたり、株式会社日本線路技術の田口正智様、小林聡様には、画像データの提供、分析のご指導をいただきました。また、精密機械工学科の齊藤健准教授、黒澤先輩には、AIについてのご教授、システムの使用をさせていただきました。厚く御礼を申し上げます。

参考文献

- 1) 半澤雄希：AI技術による外観検査の自動化 Deep learning による事前学習型欠陥検出について、OMRON TECHNICS, Vol.51.003JP, pp.11-15,2018.