

画像解析を用いたレール表面状態の異常検知手法の検討

東日本旅客鉄道株式会社 正会員 ○小松 佳弘 西藤 安隆 元好 茂 小西 俊之

1. はじめに

J R 東日本研究開発センターでは、設備管理業務の TBM(Time Based Management)から CBM(Condition Based Management)への転換を目指した研究開発を進めており、その一環として営業列車搭載型線路設備モニタリング装置の開発を進めている。

営業列車搭載型線路設備モニタリング装置は「軌道変位モニタリング装置」と「軌道材料モニタリング装置」の二つの装置から構成されている。そのうち軌道材料モニタリング装置は、3次元距離画像を撮影し、解析することでレール締結装置の脱落等を自動検知するとともに、保線技術者が確認するための濃淡画像を同時に取得する装置である¹⁾。ただし軌道材料モニタリング装置が取得する大量の画像データから目視で異常箇所を発見するためには多大な労力が必要という問題がある。

そこで本研究では軌道材料モニタリング装置で収録した濃淡画像から画像解析によりレール表面の異常を検知する手法の検討を行った。

2. レール表面の異常検知方法の開発

(1) 方法

首都圏線区の軌道材料モニタリング装置で撮影した濃淡画像を対象とした。なお画像サイズは1,024画素×5,000画素であり、1画素は1mmに対応する。事前に画像を保線技術者が確認し、不良箇所のラベル付けを行った後に検知方法の検討を行った。

本研究で対象とした不良は (a) 黒斑 (シェリング) (b) きしみ割れ (c) レール照り面の蛇行であり、それぞれの不良ごとに機械学習に基づく異常検知手法を検討した。またその他に1枚の画像内の局所的な異常領域を (d) その他の異常として検知する手法を検討した。



図1 対象とする不良の例 (左からきしみ割れ、シェリング、照り面の蛇行、その他 (溶接部凹凸))

(2) 異常検知ロジック

① シェリング

背景差分法によりシェリング候補となる領域 (黒斑) を検出した後、対象領域の特徴量を抽出する。分類に用いた特徴量は、大きさ、形状、コントラストと勾配方向のヒストグラム (HOG)²⁾ によるエッジ属性などである。抽出した特徴量を用いて、サポートベクターマシン (SVM)³⁾ によりシェリングと正常な場所を分類する。

② きしみ割れ

きしみ割れの検知はレール長手方向の一定の範囲内の画素の明るさの標準偏差および明るさの差を特徴量として抽出した後、SVMにより分類する。

③ レール照り面の蛇行

レール照り面の蛇行を検知するために周波数情報を抽出した。つまりレール長手方向 600 画素の範囲に対して高速フーリエ変換を行った結果を特徴量として用いて、ランダムフォレスト³⁾で分類する。

④ その他の異常

レール表面領域を長さ 200 画素ずつに分割し、各領域内の画素の明るさの平均値を比較し、外れ箇所 (平均+4σ 等) を「その他の異常」として検出する。

3. 画像解析の検証

2章と異なる線区でシェリングときしみ割れの精度の検証を実施した。検証用のサンプルは1,200枚であり、きしみ割れ箇所 15 箇所、シェリング 43 箇所を含む。検証の結果以下の課題が確認された。

(1) 判定精度

① きしみ割れの検出精度: きしみ割れ箇所は一定の精度で検出できた (86.7%) ものの偽陽性 (誤検出) が 55.7% となった。特にレール削正痕を誤ってきしみ割れとして検出している例が多く見られた。

② シェリングの検出精度: シェリングの検出率は 11.6% であり十分な精度を得られなかった。

③ その他: 周辺環境の状況 (日射など) によりレール表面領域を正しく抽出できないケースが見られた

(2) 画像処理速度

8,330 画像 (≒21km) の処理に 3,787 分を要した (182 分/km)。画像の目視確認に必要な時間は 50 分/km 程度であり、処理に大きな時間を要することが課題である。(※分析環境:

キーワード 画像解析, レール管理

連絡先 〒331-8513 埼玉県さいたま市北区日進町2丁目479番地 研究開発センターテクニカルセンター 048-651-2389

Intel® Core™i5-4590 CPU@3.30GHz, メモリ 8.00GB, windows7 64bit 版)

4. アルゴリズムの改良

検証結果から得られた上記の課題を踏まえて以下の通り改良を図った。

(1) レール表面領域の特定方法

距離画像を用いてレール表面領域を特定し、濃淡画像にマッピングした。その結果、周辺環境の影響を受けることなく安定してレール表面領域の検出が可能となった。また濃淡画像のみの場合に比べて処理速度が改善された。

(2) きしみ割れの検知

① レール表面領域の分割方法の見直し

レール表面領域を長さ 200 画素、幅 20 画素の窓に分割して分析した

② 特徴量の変更

きしみ割れの有無を判別する特徴量を見直した。特にレール削正痕との判別を行うため、レール長手方向に標準化離散フーリエ変換を行い画像の明るさの周波数情報を特徴量に含めた。




図2 改良したきしみ割れ検知アルゴリズムのフローチャート

(3) シェリングの検知

① 特徴量の見直し

シェリングの有無を判別するためにディープラーニングの適用を検討した。ただし、ディープラーニングにはシェリングの画像が大量に学習させることが必要となる。そこで大規模物体認識データセットを用いて学習させた学習済みの畳み込みニューラルネットワーク(CNN)を用いて特徴量を抽出する⁴⁾こととした。

② 分類器の変更

SVMとランダムフォレストの判定結果を組み合わせた結果をアウトプットとした。




図3 改良したきしみ割れ検知アルゴリズムのフローチャート

(4) その他

その他、処理速度の改善を図るため以下の改良を行った。

- ・ ソフトウェアのアーキテクチャの変更
- ・ 複数並列処理の実装

5. アルゴリズムの改良結果

改良したアルゴリズムの検証結果の例を以下に示す。

(1) 画像判定結果について

4750 画像 (シェリングが含まれる画像は 50 画像) について、シェリングの検出精度を検証した。その結果、シェリングとしての検出率は 42.0%、誤報率は 4.7%であった。ただし見逃したシェリングもシェリング以外の異常としてではあるものの、すべて検出していた (きしみ割れ: 26%, 照り面の蛇行: 24%, その他の異常: 8%)。機械学習を進めることでより精度を高めることが期待できる。

(2) 画像処理速度の比較

画像処理速度の比較結果を表1に示す。表から明らかにように処理速度を大幅に改善することができた。また表1の試験においては並列処理を実施しなかった。並列処理を行えばより高速に処理が可能と考えられる。

表1 画像処理速度の比較

	改良前 (分/km)	改良後 (分/km)	目視確認(参考)
試験1(171画像)	211.9	23.0	-
試験2(1202画像)	153.7	20.9	49.9
試験3(8330画像)	181.9	20.0	-

6. 今後の課題とまとめ

(1) 課題

モニタリング画像から軌道材料の異常を検出するための課題を以下に述べる。

① 画像の明るさのばらつきについて

・ 濃淡画像の明るさが画像ごと、収録カメラごとにばらつく傾向が少なからず見られた。この結果が判定の汎用性に影響を及ぼしていると考えられる。

② 訓練用データの取得

・ 機械学習による判定を行うために大量の正解データが必要である。そのため画像へのラベル付けに大きな労力が必要となる。また軌道材料の異常の多くは実際にはほとんど発生しないか、発見され次第修繕されるため十分な量の訓練データを得ることが難しい。

・ 解像度が約 1mm/画素のため、はく離に至らないきしみ割れ等について目視での判別が難しい。

(2) まとめ

軌道材料モニタリング装置により得られた画像を用いたレール表面の異常検知に取り組んだ結果、一定の成果が得られた。引き続き上記の課題に取り組み濃淡画像の活用の拡大に取り組んでいく。

【参考文献】

- 1) 葛西亮平他: 営業列車搭載型軌道材料検査装置の改良について, 鉄道工学シンポジウム論文集, No.19, 2015. 7.
- 2) N. Dalal, B. Triggs, Histograms of oriented gradients for human detection, Proc. of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 886-893, 2005.
- 3) 平井有三: はじめてのパターン認識, 森北出版, 2012.
- 4) 中山英樹: 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習, 電子情報通信学会音声研究会 7 月研究会, 2015.