

## AI と画像処理によるレール電食の進行測定技術の開発

東京地下鉄（株） （正）○工藤 浩之  
森田 遼  
日本電気（株） 矢田 徹、高木 和久  
日本電気通信システム（株） 南條 正紀

## 1. はじめに

東京地下鉄（株）の線路の特徴として、営業線の約85%が地下構造物であり、その一部の区間では河川や濠等に近接しているため漏水が発生し常に湿潤状態となっている区間が多い。このような環境下ではレール電食が発生しやすく、電食の経時進行によりレール折損に至るケースもある。これらの区間は定期超音波探傷検査に加え、目視による電食詳細点検を実施し監視強化を行っているが、レール電食の進行速度に対して実施頻度が十分でないこと、検査員により判定結果にばらつきが生じていることが課題であった。

今回、将来的な人口減・就労人口減を前提とし、目視で行っていた電食詳細点検を「高頻度」、「高精度」、「効率的」に実施することを目的に、AI と画像処理を活用したレール電食進行測定技術を開発したのでその内容について報告する。

## 2. 開発コンセプト

従来レール電食はまくらぎと接触しているレール腹部直下の底部を超音波探傷により検知し、目視可能なレール底部側面を検査員の目視で検知していた。

今回は従来目視で確認していた範囲をカメラで撮影し、その画像から電食によるレールの腐食量を測定することにより経年による腐食量の変化を定量的に把握する技術を開発することとした（図1）。

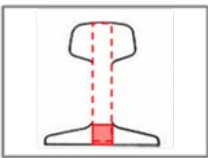

| 方法      | 検知範囲  | 手段                                | 頻度   |
|---------|---|-----------------------------------|------|
| 超音波探傷   |  | ・レール探傷車                           | 2回/年 |
| +       |   |                                   |      |
| AI 画像処理 |  | ・カメラ画像<br>(保守用車・線路設備<br>モニタリング装置) | 1回/月 |

図1 レール電食の検知範囲と手段

## 3. 画像の撮影

現在レール底部側面の電食の定量的な評価・判定として、腐食量の深さ、奥ゆき、幅を指標としている。この指標を画像上で確認するためにはレールを側面上方向から撮影することが必要であると想定した。またレール電食は発生地点が不規則であることから定点撮影ではなく、路線を走行しながらレール長手方向に連続して撮影することも必要と想定した。以上の点を考慮し、画像の撮影方法を以下2パターンにて検証した。

## (1) 保守用車による画像撮影

夜間作業時に日常的に使用している保守用車にカメラ装置を取り付けて撮影した。走行時の衝撃を吸収するためにカメラにジンバル装置を設置、不規則な走行速度に対するカメラ制御と地点把握のためにドップラーセンサーを設置することにより、画像解析に使用可能な高品質な画像を取得することが可能となった（写真1）。




写真1 カメラ装置及び撮影画像

## (2) 線路設備モニタリング画像の活用

当社千代田線では相互直通運転をしている東日本旅客鉄道常磐緩行線に搭載されている線路設備モニタリング装置にて試験的に千代田線管内の画像撮影を実施している。その画像からレール電食の検知が可能かを検討した結果、撮影画角、画像品質ともに十分活用できるものであることが確認できた。

キーワード： 電食 腐食 AI 画像処理 モニタリング

連絡先： 〒110-8614 東京都台東区東上野 3-19-6 東京地下鉄（株） 03-3837-7151

#### 4. AIによる判定モデルの作成

撮影した画像からレール電食を検知するために、AIを活用した判定モデルを複数作成・検討を行った。

##### (1) 分類による判定モデル

まずレール電食の発生が顕著であるレール締結装置付近を分析対象として画像を切り出し、あらかじめ電食の大きさを「大」、「小」、「無し」にラベル付けした教師データを学習させ、判定したい画像の電食の大きさごとに分類する判定モデルを作成した(図2)。この判定モデルの学習パラメータの調整を重ねた結果、94%正答率にまで精度を上げることが可能となった。

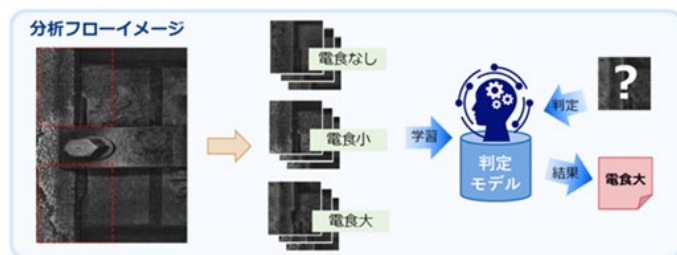


図2 分類の学習

##### (2) オブジェクト検知による判定モデル

分類による判定モデルでは対象外となっていた締結装置付近以外のレール電食及び様々な腐食形状に対応するために、撮影画像の電食部分を電食の大きさごとに手でマーキングした教師データを学習させ、広い画像範囲から複数のレール電食を同時に検知するモデルを作成した(図3)。この判定モデルの精度は90%正解率となった。

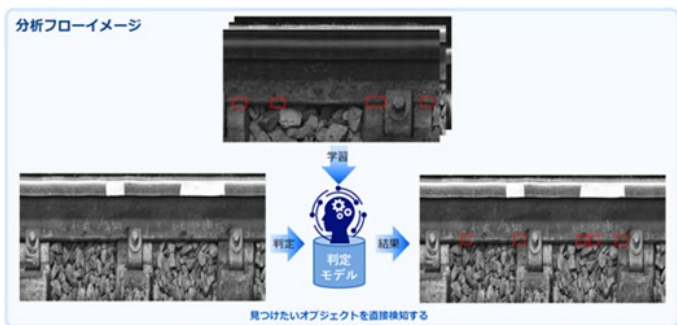


図3 オブジェクト検知

##### (3) 領域抽出による腐食量検知

レール電食を把握するためには腐食量を定量的に検知する必要があります。腐食量を画像上から計測するために、画像と手でマーキングした教師ラベルを用いて腐食の領域を抽出する判定モデルを作成した。このモデルにより抽出された領域の面積を計測することによ

り電食による腐食量をピクセル単位で計算することが可能となった(図4)。また計算した腐食量を時系列に整理することにより腐食の進行を把握することが可能となった(図5)。

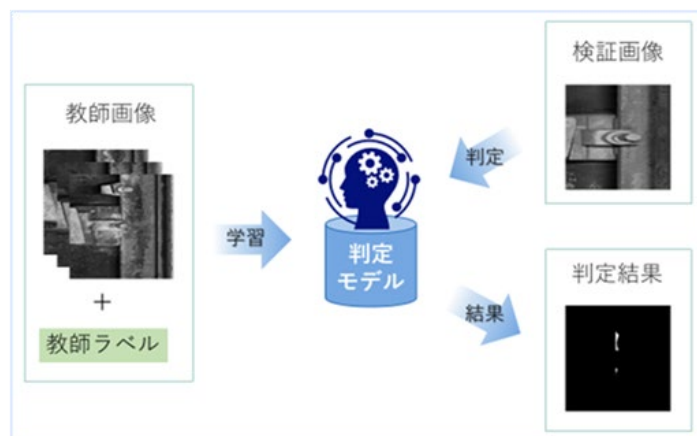


図4 領域抽出

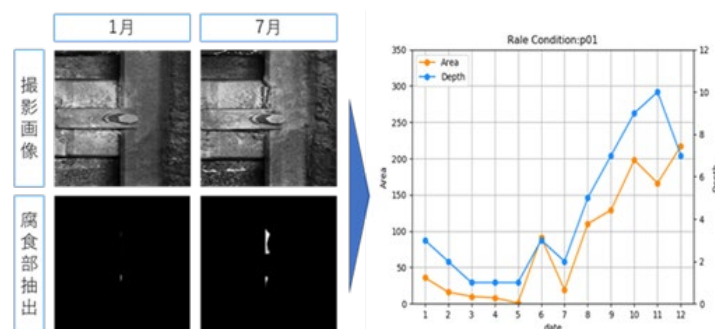


図5 レール電食の進行検知

#### 5. まとめ

AIによる各判定モデルを作成することにより、発生状況や腐食形状が不規則なレール電食に対して効率的かつ高精度な判定が可能となった。またこれらデータを高頻度に蓄積することにより進行度を把握することも可能となった。

今後は各判定モデルを用いた業務システムの開発を進めるとともに、得られたデータによる腐食の進行予測の開発を実施していく。また探傷データと有機的に連携させることにより、死角のないレール電食保守が可能になると考える。

#### 参考文献

・軌道構造による電食発生状況の一考察、土木学会第69回年次学術講演会、2014年、東京地下鉄株式会社 大澤純一郎他