

## 深層学習を用いた照明器具の支持金物の腐食損傷検出におけるノイズの影響について

日大生産工(院) ○谷平 春人 日大生産工 矢野 耕也  
 日大生産工(院) 行木 靖人 日大生産工 豊谷 純 大前 佑斗  
 (株)NEXCO 東日本エンジニアリング 伊藤 正人 高橋 大樹

### 1. はじめに

道路等に代表される公共的なインフラの設備は、国や市区町村といった自治体の管理下に置かれており、高速道路のように高速道路株式会社法に基づいた特殊会社が管理することが多い。道路等の構造設備は人工的とはいっても、環境的に自然下に接する状況が殆どであり、また領域や面積も多岐にわたるため、点検作業は容易ではない。しかしながら、点検作業は使用者の安全を確保するために重要なものと位置づけられる。とはいえ、道路等の場合は24時間常に使用され続けていることが多いため、そのメンテナンスは必然的に夜間帯の作業になることが多く、条件的に不利な状況での作業になりがちである。特に照明においてはその設置位置から人による高所作業となり、かつその判断の多くが目視等に頼ることが多く、その判断にばらつきが生じることが考えられるため、客観的に判断されることが望ましいものである。また対象の規模や範囲が大きいことが多いため、時間やコストがかかったり、また人による判断の相違があつたりすれば見落としにつながることも起こりえる。そこで前報<sup>1)</sup>ではCNNを利用してマハラノビスの距離を求めることで、正常・非正常を含めたトンネル照明器具の交換必要性を一元的な尺度で示すことが可能となった。

ところで画像処理における問題は、前報<sup>1)</sup>でも同様であったが、Fig.1のような画像において、設置箇所の背景や照明の影響を受けてしまうことにあつ

た。目的はトンネル内照明の支柱や保持部分の腐食の程度を判断することにあるが、画像の撮影範囲や背景に依存してしまうため、さまざまな背景の影響を受けてしまう点に課題があった。またトンネル内の高所作業という、検査員にとって負担の小さな環境であることから、点検撮影時の構図にばらつきがみられており、対象を大きく撮影できたりやや離れていたりと画像の内容に不均一性があるため、これらの問題の解決が望まれていた。そこで本報では、第2章2.1でCNNの概略を述べ、2.2で(1)背景の削除、および(2)識別対象のサイズのある程度の統一化を行い、背景の影響等を極力避けるようにした。背景といつても単なるトンネル壁の時もあれば照明器具の配線の写り込み、またナトリウムランプの色被りやストロボの当たり具合、影といったさまざまな要因があるため、可能な限り対象部のみの情報を取り込むような処理を行い、改めてCNNのResNet18による処理を行って512次元のデータを得て、2.3で品質工学の方法を用い、rank0の画像を単位空間としてrank1～rank3のマハラノビスの距離を求め、ランクに応じて分類可能か否かの確認を行った。

### 2. 方法

#### 2.1 CNN および ResNet18 について

照明器具の支持金物部の腐食状態を判別するために畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)<sup>2)</sup>を用い

---

The Influence of Noise on Corrosion Damage Detection in Lighting Fixture Support Brackets Using Deep Learning

Haruto TANIHIRA, Koya YANO, Seito NAMEKI, Jun TOYOTANI, Yuto OMAE, Masato Ito and Daiki TAKAHASHI

た。CNN は主に画像認識や分類において利用されるディープラーニングモデルであり、畳み込み層、フィルター、プーリング層、パディング等から構成され、画像データの圧縮を行いつつ過学習の抑制を行う。

前回同様、今回も機械学習のオープンソースツールとして配信されている CNN の 1 つである (Residual Network(ResNet)) の中の ResNet18 を使用して識別対象のデータを処理し 512 次元のデータを得ることで、腐食の程度を識別した。ResNet の最大の特徴である残差接続により機械学習の精度の向上を可能とし、画像分類を行う上で高い性能を示すことができるものである。なお ResNet には層の深さにより Resnet18、ResNet34、ResNet50、ResNet101、ResNet152 が提唱されているが、本研究では元データの量が多くないことや、処理速度を勘案して ResNet18 を使用している。

## 2.2 特徴抽出と背景の削除

本研究では、先行研究<sup>1)</sup>にて課題となった背景等によるノイズの影響を最小限にするために、画像から照明器具を固定する支持金物部以外の背景領域の削除を行った。また、画像の条件を整えるために支持金物部の大きさと向きをある程度統一した。以下の Fig.1 は作業を行う前の元の各 rank0～3 の画像であり、Fig.2 は背景削除と、位置や向き、大きさ等の条件を整えた作業後の各 rank0～3 の画像である。照明器具の支持金物の腐食の程度と rank の対応であるが、腐食・損傷なしを rank0 とし、一部に錆が発生した状態を rank1、粗い錆が剥がれ落ちる箇所がある状態を rank2、層状に錆が剥離する部分が観察される状態を rank3 としてカテゴリ分けして、教師データとして用いている。また背景削除作業にはフリーソフトウェアでもある GIMP や Windows 標準アプリケーションであるフォトを利用してある程度自動で削除した後、微調整を手動で行った。



rank0



rank1

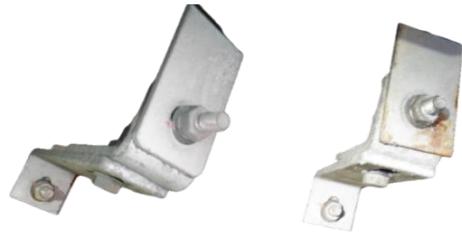


rank2



rank3

**Fig.1 作業前の各 rank の画像**



rank0

rank1



rank2

rank3

**Fig.2 作業後の各 rank の画像**

なお元画像は高所作業車から撮影されているために画像の大きさが必ずしも均一でないで、照明器具の支持金物の保持部をカバーし、極力背景が写り込まない程度に画像サイズを調整している。

## 2.3 マハラノビスの距離の導出

rank0 の 512 項目、サンプリングした 1184 データを用いて式(1)により単位空間を作成し、単位空間外の rank1、rank2、rank3 についてマハラノビスの距離  $D$  の 2 乗(以下、本研究ではマハラノビスの距離とする)を求めた。なお背景削除前の単位空間データ数は 1142、背景削除後のデータ数は 768 であるが、背景削除後でデータ数が変化している

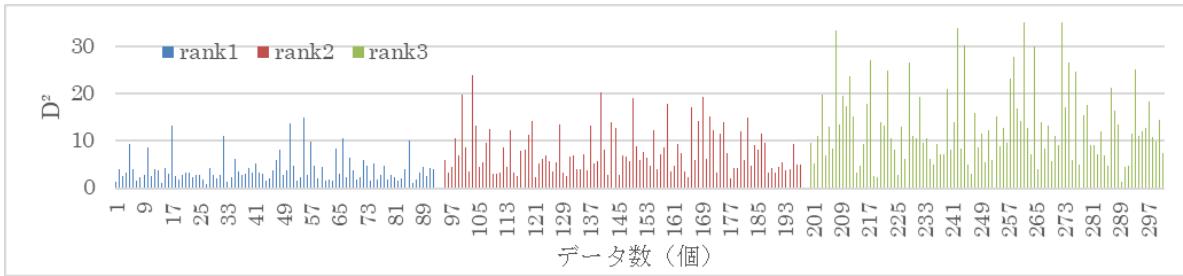


Fig.3 背景削除前の rank1～3 のマハラノビスの距離

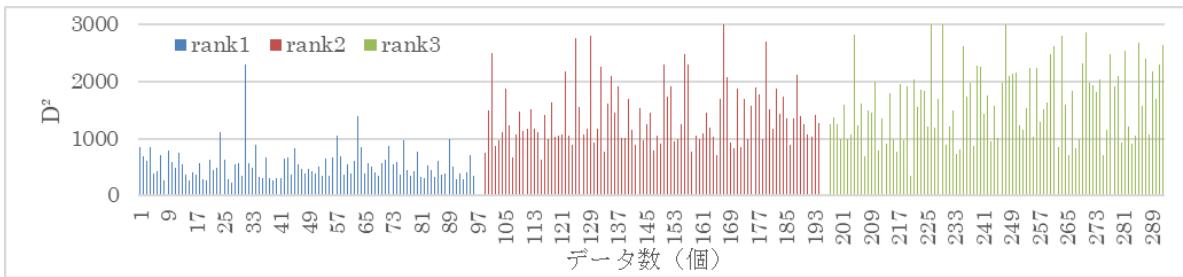


Fig.4 背景削除後の rank1～3 のマハラノビスの距離

のは、背景ばらつきを抑えるために画像を精査したためである。なおマハラノビスの距離を求める手順は以降も同様である。

$$D^2 = \frac{1}{k} \sum_{i,j} a_{ij} \left( \frac{x_i - m_i}{\sigma_i} \right) \left( \frac{x_j - m_j}{\sigma_j} \right) \dots \quad (1)$$

### 3. 結果

#### 3.1 rank1～rank3 のマハラノビスの距離

本研究は先行研究<sup>1)</sup>の課題点から、識別能力を向上させるために背景の削除に加えて、向き、大きさという条件の統一を行い、同様の手順にて識別を行った。rank0 の単位空間データは距離平均が 1 となるために除外し、背景削除の有効性の比較を行うために前回の背景削除を実施していない結果<sup>1)</sup>を Fig.3、2.2 に従った背景処理を施した rank1～rank3 の対象ごとのマハラノビスの距離を Fig.4 に示した。横軸は rank1～rank3 のそれぞれの照明器具の個体である。

Fig3 と Fig4 より、rank1～rank3 の平均値を Table1 に整理した。Table1 に示したように、距離の 2 乗の値で約 100 倍、すなわち 10 倍に識別感度が上がっていることが示唆された。

Table1 背景削除前後の各 rank の平均値の比較

	rank1	rank2	rank3
平均値(削除前)	3.97	7.78	13.09
平均値(削除後)	546.02	1397.26	1658.95

同様の検討を式(2)のような望大特性の SN 比  $\eta$  で比較を行い、Table2 に整理をした。望大特性の SN 比とは、特性値が大きい(=識別が良い)ほど高い値となる SN 比で、db(デシベル)単位で示され、この場合はマハラノビスの距離が大きくなるほど高い値で示されるものである。

$$\eta = -10 \log \frac{1}{l} \left( \frac{1}{D_1^2} + \frac{1}{D_2^2} + \dots + \frac{1}{D_l^2} \right) \dots \quad (2)$$

Table2 背景削除前後の各 rank の望大特性の SN 比(db)の比較

	単位空間n数	rank1	rank2	rank3
背景削除前	1142	4.47	7.48	9.34
背景削除後	768	26.63	30.9	31.37

なお削除前後の差を見ると、rank1 で 22.16(db)の差となり、これは倍率換算で 12.8 倍の変化である。同様に rank2 では 23.41(db)で 14.8 倍、rank3 で 22.03(db)で 12.6 倍の改善となっており、

Table1 の平均値での比較を裏付けていることになる。

#### 4. 考察

先行研究において CNN を用いて画像処理を行い、得られた 512 次元のデータからマハラノビスの距離を計算し、識別することについての有効性は論じられていたが<sup>1)</sup>、識別力の低さや、今回は前回の問題の原因として考えられた支持金属部以外のノイズによる影響を減らした場合の識別力の変化についての研究を行った。前項の結果の通り、背景を削除したことによって各 rank1～3において、削除していないものと比較してマハラノビスの距離の平均値は二乗で約 100 倍となった。これは望大特性のSN比でも同様であり、rank1～3 の  $\eta$  (db)の値が大幅に上昇している。ゆえに、背景をはじめとしたノイズが、照明器具の支持金属部の腐食状態の識別力について影響していたことが認められた。最も大きなノイズと考えられる背景は識別を行うにあたり大きな障害となっており、いかにこの影響を小さくするかが重要だということが確認できる。しかしながら、この大きなノイズが消えたことによって、識別を行う際に支持金属部だけに注視できることが可能になったため、除去できていないノイズに対してはさらに鋭敏になった。結果的に各 rank にて大きな外れ値がいくつか見られた。この原因として、支持金属部に当たるナトリウムランプ、その陰影、ストロボライト等が影響してしまったと考えられる。

また、CNN の畳み込み画像処理は ResNet18 で行ったが、出力された 512 次元の数値からどの画像が外れ値となったかは判別することは可能であるが、畳み込みで行われる一連の深層学習の処理のために具体的に画像のどの部分が外れているかを追うことができず、AI を用いた際のブラックボックス的問題が浮き彫りとなっている。

さらに、同条件で処理、計算を行ったとしても単位空間となる rank0 の学習データの変化により、距離の平均値が rank1<rank2<rank3 という結果

にはなるものの、外れ値となった画像やどれだけ距離として外れているかなど、これらが変化しているという現状であり、再現性という点についても課題を抱えている。この点は画像数や学習数の少ないことにも起因しており、畳み込みの学習回数を増やすことで精度向上が期待できるが、今後の解決すべき課題である。

#### 5. まとめ

照明器具の支持金物部の腐食損傷検出において、背景(壁面や配線など)が識別の妨げとなっていると考えられるため、その背景削除を行うことで有効性の検証を行った。

背景を削除することでマハラノビス距離は二乗で約 100 倍に増加し、つまり識別力が大幅に向上了ことになる。

しかし、照明条件(フラッシュ、ナトリウムランプ等)をはじめとした除去できないノイズの影響による外れ値が残存した。

また、CNN 処理はブラックボックス性があり、外れ値の原因追跡が難しいという問題がある。

本評価システムにはまだ再現性に課題があることが考えられるので、今後は学習データ拡充や処理精度向上が必要である。

#### 参考文献

1. 矢野耕也、行木靖人、豊谷純、大前佑斗、谷平春人、伊藤正人、高橋大樹、深層学習を応用した道路設備の腐食損傷検出方法の検討—CNN と MT 法の利用—、品質工学、33、4、(2025)、pp.24–32
2. A. Krizhevsky, I. Sutskever, G. E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, Vol. 25, pp.1097–1105, 2012