

トンネル照明灯具の劣化診断の精度向上に関する研究

愛媛大学 学生会員 ○奥村尚登 岩国市 非会員 村井遙己
愛媛大学 正会員 坪田隆宏 愛媛大学 正会員 吉井稔雄

1. はじめに

高速道路上には、安全で快適な交通空間を確保する為の各種の道路付帯設備が設置されている。これらの設備は経年劣化を伴うため、機能の維持管理や機器の落下事故を未然に防ぐ為、定期的点検が行われており、各トンネル照明取付具（以下“灯具”）の劣化状態は、表-1に示す5段階で評価されている。ただし、B+の判定基準は正式な判定区分ではなく、便宜上使用しているものであることに留意されたい。点検は主として近接目視で実施される為、点検コストが高いことや、点検者によって判定結果が異なることが課題として挙げられる。

このような背景を踏まえ、坪田ら¹⁾は、灯具画像から劣化診断を行うAIモデルの構築を行っており、データセットが極めて少ない場合においても診断精度が80%以上に達した。しかしこのモデルは、部材個別に着目できておらず、画像全体の中で最も状態の悪いラベル判定をその画像の判定結果として劣化状態を設定している。そこで本研究では、部材ごとに劣化状態を学習することで、より詳細な劣化診断モデルの構築を目指した。また、モデル構築に使用可能なデータセットが限られる場合には、データ拡張が精度向上に寄与することは知られているが²⁾、最適なデータ拡張倍率に関する知見は十分ではない。本研究では、データ拡張の倍率について感度分析を行うとともに、ラベル毎のデータ数の不均一を解消するような拡張方法についても検討し、精度向上を目指した。

2. データ概要

使用した灯具画像は合計 362 枚で、各画像には図-1 のように 1 つの画像に対して複数箇所のラベルが付与されている。そのラベルの総数は 1,175 箇所であり、ラベル別の内訳を図-2 に示す。最も多いラベルは B の 480 箇所である。その一方で B+ のラベルはその 1/4 にも満たない 101 箇所である。一般的に、高精度な AI モデルの構築には多量の学習用データを必要とする。そこで、本研究では学習用データに対してのデータ拡張を適用する。

データ拡張の具体的な処理方法として、元の画像に対して上下反転、鏡像反転、回転、および縮小操作を適用した。上下反転、鏡像反転については 50% の確率で起こるものとした。回転のパラメータ値は、 -30° ~ 30° の範囲で、縮小は 0.80~0.95 倍の範囲内でランダムに決定されるものとする。データ拡張の際には、以下に示す 2 種類の拡張方法を検討し、精度への影響を確認する。

(1) **単純拡張** 全ての学習データ画像の枚数を規定の倍率に拡張する。倍率は、2, 4, 8, 16, 32 倍の 5 通りを検討する。

(2) **B+重視拡張** 図-2に示すように、学習データ内のラベル数はB+の枚数が極端に少ない為、単純拡張を適用した場合であってもB+の判定精度向上に十分な枚数を確保できない可能性が考えられる。学習データ内のクラス毎のラベル数の不均衡を解消する為に、B+のラベルを含む画像をより高倍率で拡張する。

表-1 点検基準

判定区分	判定内容
OK	変状なし。
C	50%未満の白錆が発生。
B	50%未満の赤錆が発生。 50%以上の白錆が発生。
	80%未満の赤錆が発生。 ※正式な判定区分としては B 判定だが、B 判定の範囲が広い ため、B+という判定基準を便宜 上設定したもの。
A	全体に赤錆が発生。 ナット部に変形が発生。




図-1 点検基準

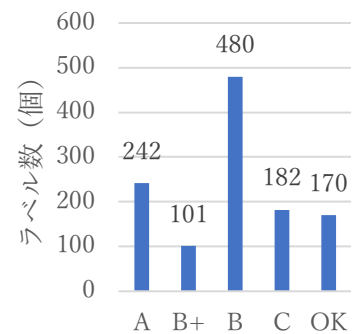


図-2 点検基準

3. モデル概要

本研究では、灯具の点検画像を用いて点検該当箇所を検出し、劣化健全度を診断するモデルの構築を行う。モデル構築には画像認識技術の一種であるYOLOv3を活用する。構築したモデルが未知のデータに適応するかを確認するため、画像は学習用データと検証用データに分割する。割合は9:1とし、それぞれ326枚、36枚にランダムで分割された。各データそれぞれのラベル数は1059枚、116枚に分割されている。まずは、学習用データを用いてモデルの構築を行う。その後、検証用データを用いてモデルの再現性を検証する。

4. 評価指標

本研究で構築するモデルの評価指標として、AP および mAP を用いる。一般的に物体検出の結果は TP, TN, FP, FN の 4 分類に整理でき、これらを用いて検出精度を評価する。本研究における TP とは学習データ内の部材をモデルが検出したこと、TN は学習データ内の部材ではない箇所をモデルが検出しなかったこと、FP は学習データ内の部材ではない箇所をモデルが検出したこと、FN は学習データ内の部材をモデルが検出しなかったことを表す。これらの分類から式(1)に示す適合率を縦軸に、式(2)に示す再現率を横軸に取ったとき、2つの関係性が PR 曲線として図示される。AP とは PR 曲線の下部面積で算出される。また、mAP は平均の適合率のことで、各ラベルの AP の平均を取った値を指す。

5. 結果

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1) \quad \text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

(1) 単純拡張

拡張をしない場合のmAPと各倍率で単純拡張をした場合のmAPを図-3で比較している。拡張倍率が1倍とは、拡張をしていない状態のことを指している。1倍のmAPは49.8で、拡張を行う場合は全ての倍率においてmAPが増加傾向にあることが分かる。特に、倍率が4倍のときmAPは59.0で、最も高い値を取った。また、倍率を増加させても、4倍をピークとしてmAPは減少していくことが確認できた。




図-3 単純拡張の倍率ごとのmAP

(2) B+重視拡張

(1)の結果を受けて、B+のラベルを含む画像を重視した拡張方法では、倍率を4倍に設定して結果を比較している。図-4は拡張方法ごとのAPを比較している。拡張方法によるAPの変化はあまり見られなかった。特に、B+ラベルのAPでは、単純拡張が21.2であるのに対して、B+重視拡張では16.7と減少している。これは、B+を重視した拡張方法では単純拡張と同程度の精度向上が見られなかったことを意味する。




図-4 拡張方法毎のAP比較

6. 結論と今後の課題

本研究では、既存の物体検出ソフトYOLOv3を活用して灯具の劣化診断を行った。対象データ数の少なさと不均一性を解消するため、2種類のデータの拡張を行い精度向上を試みた。その結果、単純拡張においては、精度向上が見られ、特に4倍時に最も高い精度を得た。一方で、B+のデータを重視した拡張においては精度の向上が見られず、データの拡張による精度向上には限界があることが分かった。

劣化診断モデルの精度向上の為に、点検画像データ数の拡充が必要であると考えられる。また、既定のパラメータ設定値を変更するアプローチでも精度向上を目指す。

謝辞：データは西日本高速道路エンジニアリング関西株式会社より提供いただいた。ここに謝意を表す。

参考文献

- 1) 坪田隆宏, 楊宇, 吉井稔雄: AI による高速道路トンネル照明取付具の劣化診断手法の開発, AI・データサイエンス論文集, Vol.2, No. J2, pp681-686, 2021.