

トンネル照明取付具の劣化診断の精度向上 に向けたデータ拡張方法の検討

奥村 尚登¹・村井 遥己²・坪田 隆宏³・吉井 稔雄⁴

¹学生会員 愛媛大学大学院 生産環境工学専攻 (〒790-0826 愛媛県松山市文京町3番)
E-mail:okumura.naoto.17@cee.ehime-u.ac.jp

²非会員 岩国市役所 (〒740-0017 山口県岩国市今津町1丁目14-51)
E-mail:haruki19980404@icloud.com

³正会員 愛媛大学大学院 生産環境工学専攻 講師 (〒790-0826 愛媛県松山市文京町3番)
E-mail:tsubota@cee.ehime-u.ac.jp

⁴正会員 愛媛大学大学院 生産環境工学専攻 教授 (〒790-0826 愛媛県松山市文京町3番)
E-mail:yoshii@cee.ehime-u.ac.jp

本研究では、高速道路に設置されているトンネル照明取付具の点検画像から、劣化状態を診断をするモデルの構築を行う。モデルの構築には物体検出ソフトのYOLOv3を活用し、対象画像内の点検箇所と同箇所の劣化診断結果の出力を行った。モデル構築後、未知のデータに対して診断を行い、その再現性を評価した。分析対象のデータはデータ数の少なさ、およびラベル数の不均一性という2つの特徴を有しており、それぞれの問題を解消するために2種類のデータ拡張を実施し精度向上を目指した。その結果、各ラベルのデータ数を一様に拡張した場合には精度向上が見られ、特に4倍に拡張した時に最も高い精度で予測した。その一方で、不均一を解消した拡張方法においては、同程度の精度の向上が見られなかった。

Key Words : 深層学習, YOLOv3, 照明灯具, 画像診断

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。これらの設備には常に経年劣化が伴うため、機能の保持や機器の落下等による事故を防止する目的で、道路管理者による定期点検が実施されている。本研究で扱うトンネル照明取付具（以下、“灯具”）についても定期点検が実施されており、その劣化状態をA（要補修）、B（変状大、継続観察）、C（変状小）、OK（変状なし）の4段階で評価し、予防保全に活用している¹⁾。予防保全の考え方では、灯具が要補修の状態に至る時期、すなわちB判定からA判定に推移するタイミングを把握することが重要となる。一方、B判定に含まれる灯具の劣化状態は多様な劣化状態が含まれ、数年の経過観察を経た後にA判定へ推移する灯具が存在する反面、1年以内にA判定まで劣化が急速に進展する灯具も存在する。このような状況を考慮し

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	B 30%未満の赤錆が発生。 全体に白錆が発生。
	B+ 70%未満の赤錆が発生。 (便宜的な区分)
A	全体に赤錆が発生。 ナット部に変形が発生。

て定期点検の現場では、A判定とB判定の中間に位置するB+という区分を便宜的に設けてB判定の灯具に対してきめ細やかな観察を行うことにより、A判定の状態に至る前の予防保全に努めている。したがって、表-1に示す通り、先述した4段階の劣化状態に加えて、便宜的に使用しているB+の点検基準を加えた5段階で各灯具の劣化状態を判定している。

現在の点検手法は近接目視を基本とし、図-1のように



図-1 点検の様子

点検者が高所作業のリフトに乗り、灯具一つ一つを目視で確認している²⁾。また、必要に応じて打音や触診などを組み合わせて実施している²⁾。この点検方法は、点検者の人件費等の点検コストが高いことや、劣化状態に判定結果に点検者の主観や経験による個人差の影響を排除できない点が課題として挙げられる。そこで、人の目を介さず、灯具画像から劣化を診断することが可能になれば、点検効率の向上や作業者の経験や技術に依存しない点検方法の確立に貢献できる。

近年AIや深層学習による画像認識は大きく進歩しており、高速および高精度の処理が可能な技術が登場している。また、その技術を活用したインフラ施設や取付部の点検、劣化診断への適応方法が開発されている³⁾。

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を使用する。

2. 研究概要

(1) 問題設定

灯具の劣化診断は必要に応じて打音検査や触診等の方法で総合的に実施されているものの、近接目視による腐食状況を含めた変状の判定が基本とされている。特に、灯具取付部材については水分や排気ガス中の化学物質が固着しやすいボルトやナット周辺において腐食による発錆が顕著である傾向が認められる。

このような背景を踏まえ、坪田ら³⁾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す。また、モデ

ル構築に使用可能なデータセットに限られる場合には、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³⁾、最適な拡張倍数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ことで、より最適な拡張を目指した。また、本研究で利用する点検画像データは、各劣化状態のラベル数が均一ではない。そのため、データ拡張を行う際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する。

本研究で構築するモデルは、点検者によって撮影された画像に基づく劣化診断を想定している。ただし、将来的には高所作業車に頼らず、ドローン等による撮影画像を用いた劣化診断への活用も想定可能なモデルの構築を目指す。

(2) モデル概要

本研究で構築するモデルでは、灯具取付部材のボルト部の検出と、同箇所の劣化診断を実施可能なモデルを構築する。すなわち、画像中の物体検出と分類を実施することが求められる。物体検出とは、対象画像内の劣化状態等の領域をBounding Boxと呼ばれる長方形の枠で囲み、クラス分類と信頼度を出力するものである。一般的に用いられるアルゴリズムは、深層学習の中でも画像処理系に適した畳み込みニューラルネットワークであるが、本研究ではYOLO⁶⁾のアルゴリズムを活用したモデルの構築を目指す。

YOLOは、Darknetから提供されているC言語で作成されたプログラムである⁶⁾。YOLOでは、入力画像を均等なグリッドに分割し、それぞれのグリッドに対して検出対象物の位置と信頼度を一度に出力するようにモデルを学習させることで、高速な物体検出を可能とした。YOLOの推論では、まず入力画像をS×Sグリッドセルに分割し、各セルに対してAnker Boxと呼ばれる複数のBounding Boxを持たせ、それらの信頼度(Confidence)を計算する。そして、閾値を超える信頼度を持つBounding Boxと対応するグリッドセルにおいて最も確率の高いクラス分類を出力する。YOLOの特徴は、単なる回帰として問題を解いているため処理速度が極めて速いこと、かつ背景と物体の識別精度が高いことが挙げられる。本研究では、YOLOの中でも、大きさの異なる物体に対しての検出精度に優れ、またインフラ点検への適用実績を有するYOLOv3⁷⁾を用いる。

3. データ作成

(1) データ詳細

本研究では関西の高速道路トンネルにおいて収集された合計362枚の灯具画像と、各取付部材の劣化状態の判




図-2 灯具画像例

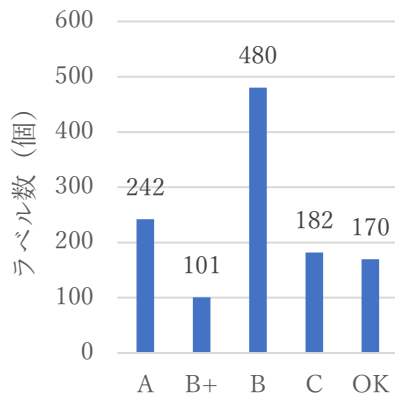


図-3 点検結果ごとのラベル数

定結果を紐付けたデータセットを用いて YOLOv3 の学習を行う。各灯具画像には図-2 に示すように、画像に存在する複数の部材に対して、部材位置と同箇所劣化状態を示すラベルが付与されている。そのラベルの総数は合計 1,175 箇所であり、図-3 に点検結果ごとのラベル数の内訳を示す。最も多い B のラベルは 480 箇所であり、B+ のラベルはその 1/4 にも満たない 101 箇所である。また、C、OK についてもそれぞれ 182、170 箇所と比較的少ないデータ数であることが分かる。一般的に、高精度な AI モデルの構築には多量の学習データを必要とする。そこで、本研究ではデータ分割後の学習用データに対してデータ拡張を適用する。

(2) データ拡張方法

本研究で使用する 362 枚の画像を、9:1 の比率で学習用とテスト用のデータセットに分割する。すなわち、326 枚の学習用データと、36 枚のテスト用データを使用する。学習用とテスト用のデータの画像に含まれるラベルの総数は、それぞれ 1059 箇所と 116 箇所である。このうち、学習用画像に含まれるラベル数は機械学習モデルの構築においては極めて少ないため、学習用データに対してデータ拡張を行う。データ拡張の具体的な処理内容は表

表-2 拡張の加工内容

項目名	処理方法
上下反転	50%の確率で上下反転
鏡像	50%の確率で鏡像反転
回転	ランダムに-30°~30°の範囲で回転
縮小	ランダムに 0.80-0.95 倍の範囲で縮小

-2で示す4項目である。これらの4項目をランダムに適用することにより拡張データを作成する。具体的には、上下反転は50%の確率で実行される。鏡像も同様に50%の確率で実行される。回転は-30°から30°の範囲で実行され、縮小は0.80倍から0.95倍の範囲で実行され、それぞれのパラメータ値は範囲内でランダムで決定する。なお、回転や縮小によって生じた画像の余白部については白色で補うものとする。

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。

a) 単純拡張

点検画像を規定の倍数枚に拡張する。検討した倍数は、2倍、4倍、8倍、16倍、32倍の5通りである。

b) B+重視拡張

図-3に示すように学習データの各クラスのラベル数は均一ではなく、特定のラベルが少ない問題がある。特に B+ は、データ数が最も少ないラベルであり、次にデータ数の少ない C や OK と比べても落下事故に影響する可能性が高い。本研究においては、B+ のラベルが含まれる画像をより高倍率で拡張する。その際に、学習用画像データを B+ ラベルを含む画像と含まない画像に分類し、それぞれのデータセットについての拡張倍率を決定している。具体的には、B+ ラベルを含む画像の拡張倍率が、B+ ラベルを含まない画像の拡張倍率の2倍となるように設定しつつ、拡張後の全体のデータ数が、単純拡張で最も高い精度が得られた拡張倍率のデータ数と等しくなるように設定している。すなわち、式(1)、式(2)それぞれを満たすような拡張倍率 a と b を用いデータ拡張を行う。

$$a = 2b \quad (1)$$

$$N \times n = N_B \times a + (N - N_B) \times b \quad (2)$$

ただし、

a : B+ラベルを含む画像の拡張倍数

b : B+ラベルを含まない画像の拡張倍数

N : 学習データ全体の画像枚数

N_B : B+ を含む画像枚数

である。

4. モデル構築

(1) モデルパラメータ

YOLOv3 では予測精度向上のため、各種パラメータを調整することができる。本研究では、モデルの精度に大きく影響すると考えられているアンカーボックス、最大学習回数のパラメータを調整した。その他のパラメータについては規定と同じ値を使用している。

a) アンカーボックスの変更

YOLOv3は80種類の物体検出および分類するために、大きさが決められた9種類のアンカーボックスが使用されている。既定のデータに対して、検出および分類に最適なアンカーボックスをあらかじめ設定しておくことで、予測精度の向上が見込まれる。本研究で使用しているデータセットに最適なアンカーボックスをk-means法によって求めた。k-means法とは、クラスタリングを行う手法の一種で、あるデータセットが与えられたとき、データを適当なクラスに分類した後、平均を用いてデータを割り振り調整させていく。

その結果、本研究で用いるYOLOv3では5種類の物体検出および分類をするために、4種類のアンカーボックスを使用するように設定した。

b) 最大学習回数の検討

YOLOv3 で定められている条件を満たし、最も適合した値は 20,000 回だった。したがって、最大学習回数を 20,000 回に設定し、深層学習を実行した。

(2) 評価指標

本研究では、評価指標としてAP (Average Precision) , mAP (mean Average Precision) を用いて診断結果の評価を行う。それらは混同行列から算出される適合率、再現率をもとに算出される。また、混同行列を決定するために必要な閾値はIoU (Intersection over Union) を基準に判断される。

a) 適合率 (Precision) , 再現率 (Recall)

精度を表す指標として、表-3 に示す混同行列を用いて検出結果を分類することが一般的である。それに加え、式(3)で示される適合率、式(4)で示される再現率などを用いてモデル精度の検証を行うことが多い。しかし混同行列において、本研究における TP, FN, FP は一般的な混同行列の定義と異なる。

TP は正解ラベルに対して予測ラベルが重なる場合の正解ラベルと予測ラベル両方に与えられる。FN は正解ラベルに対して予測ラベルが重ならない場合の正解ラベルに与えられる。FP は正解ラベルに対して予測ラベルが重ならない場合の予測ラベルに与えられる。

b) IoU(Intersection over Union)

IoU は予測ラベルが正解ラベルに対してどの程度重な

表-3 混同行列

		予測	
		正	負
実 際	正	真陽性 (TP)	偽陰性 (FN)
	負	偽陽性 (FP)	真陰性 (TN)

っているかを表す指標である。その値は式(5)に示すように、正解ラベルと予測ラベルの交わり部分の面積を、正解ラベルと予測ラベルの結び部分の面積で除して算出される。IoU の値には閾値を設定することで混同行列の分類を行う。本研究ではその値を 0.5 とした。

c) AP(Average Precision)

AP (Average Precision) とは平均適合率のことである。これは、適合率を縦軸に再現率を横軸にした時の関係を図示した PR 曲線の下部面積で算出される。この値はラベルごとに算出される。

d) mAP(mean Average Precision)

mAPとは各ラベルで算出したAPの平均を取った値である。

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$IoU = \frac{(T_Area) \cap (P_Area)}{(T_Area) \cup (P_Area)} \quad (5)$$

ただし、

T_Area : 正解ラベルの面積

P_Area : 予測ラベルの面積

である。

5. 結果

(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-4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す。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。

それぞれの拡張倍率において、ラベルごとのAPを図-5で比較している。B+やC, OKの判定について全体的にAPが低い。これは図-3で示した学習データが少ないラベル傾向と一致する。最もmAPが高かった4倍について、BやB+のラベルで高いAPを取っている。




図-4 単純拡張の各倍率の mAP




図-6 単純拡張の各倍率の mAP

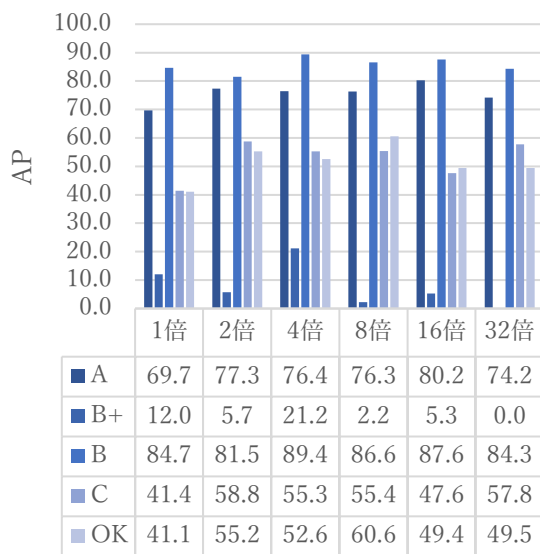


図-5 拡張方法ごとの4倍の mAP




図-7 単純拡張の各倍率の AP

(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する。表-4に拡張方法ごとのラベル数内訳を示す。

図-6は拡張方法ごとのmAP比較を示している。拡張方法による大きな精度の差は確認できなかった。図-7は拡張方法ごとのAP比較をしている。拡張方法によるAPの変化についても大きな差が見られなかった。B+ラベル

表-4 拡張方法ごとのラベル数内訳

	4倍拡張	B+重視拡張
A	836	996
B+	384	644
B	1,728	1,973
C	652	567
OK	636	241
計	4,236	4,421

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であった。これは、B+を重視した拡張方法では単純拡張以上の精度向上が見られなかったことを意味する。

6. おわりに

本研究では、高速道路に設置されているトンネル照明取付具の点検画像から、対象画像内の点検箇所と同箇所劣化診断結果の出力を行うモデルの構築を行った。また、分析対象データはデータ数量の少なさおよびラベル数の不均一性の2つの特徴を有しており、それぞれの問題を解消するため、2種類のデータの拡張を実施し、診断精度を向上を試みた。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単純拡張以上の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という知見が得られた。

劣化診断モデルの精度向上のために今後は画像データ数および点検結果データの拡充が必要であると考えます。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したい。

謝辞：本研究で使用した灯具の点検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) NEXCO 西日本：施設構造点検判定事例集 ver.2.1, 2016.
 - 2) 国土交通省道路局：道路トンネル定期点検要領, 2019.
 - 3) 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.
 - 4) 野村泰稔, 村尾彩希, 阪口幸広, 古田均：深層畳み込みニューラルネットワークに基づくコンクリート表面のひび割れ検出システム, 土木学会論文集 F6 (安全問題), Vol. 73, No. 2, I_189-I_198, 2017.
 - 5) 田畑佑, 党紀, 春日大二郎, Ashish Shrestha, 松永昭吾, 全邦釘：UAV 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証, 土木学会論文集 F4 (建設マネジメント), Vol. 74, No. 2, pp.I_62-I_74, 2018.
 - 6) Redmon, J., Divvala, S., Girshick, R., Farhadi, A.: You Only Look Once: Unified, Real-Time Object Detection, IEEE Conference on Computer Vision and Pattern Recognition, pp. 779-788, 2016.
 - 7) J. Redmon, A. Farhadi.: YOLOv3: An incremental improvement, IEEE conference on Computer Vision and Pattern Recognition, 2018.
- (2022.?.?受付)

DATA AUGMENTATION METHOD TO IMPROVE THE AI MODEL FOR DIAGNOSING THE DETERIORATION OF LIGHTING LUMINAIRE IN HIGHWAY TUNNEL

Naoto OKUMURA, Haruki MURAI, Takahiro TSUBOTA and Toshio YOSHII