

AIを用いたトンネル 照明灯具の劣化予測モデル

奥村 尚登¹・坪田 隆宏²・吉井 稔雄³

¹学生会員 愛媛大学 工学部環境建設工学科 (〒790-0826 愛媛県松山市文京町3番)
E-mail:okumura.naoto.17@cee.ehime-u.ac.jp

²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

³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

本稿では、高速道路トンネル内に設置されている灯具の劣化を予測する深層学習モデル（以下、“AIモデル”）を構築する。判定区分Cに分類される点検結果の灯具を対象とし、灯具の劣化速度に影響のある環境要因14項目を入力とし、次回点検時での劣化の進行の有無を出力とするAIモデルと、従来モデルの代表としてロジスティック回帰モデルを構築する。続いて、学習済みのモデルに対して、学習に用いていない未知のデータを入力して予測を行い、その再現性を評価する。その結果、AIモデルがロジスティック回帰モデルよりも高い精度で灯具の劣化を予測可能なことを示した。

Key Words : Artificial intelligence, Tunnel luminaires, Deterioration prediction

1. はじめに

高速道路上には道路利用者の安全性や利便性、快適性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灯具（以下“灯具”）についても、目視等による定期点検が実施され、表-1に示す四段階で各灯具の劣化状態を判定している。この判定方法は点検を実施した時点における灯具の劣化状態は把握可能である一方で、劣化の進行速度に関する情報を十分に有しているとはいえない。したがって、ある点検時においては構造的に問題がないと判定された灯具群について、次回点検時には思いがけず劣化が進行しており、計画的な補修や撤去の妨げになる可能性が懸念される。そこで、ある点検時に同じ劣化判定区分に分類された灯具であっても、次回点検時において悪い判定区分に遷移、すなわち劣化が進行するか否かを予測することが可能になれば、点検計画や補修需要に合わせた灯具を事前に準備できるという点で

表-1 点検基準

判定区分	判定内容
OK	構造的に問題ない。
C	劣化はかなり進行しているが、構造的に問題ない。
B	劣化が著しく進行しており、早急に補修が必要。
A	第三者に対し支障となるので、早急に撤去が必要。

有用であると考えられる。そこで本研究では、灯具の劣化速度に影響を与える環境要因を中心とした項目を入力として、灯具の劣化予測を行う深層学習モデル（以下、“AIモデル”）の構築を行う。環境要因には、トンネル内勾配やトンネル入口部からの距離など劣化速度に影響を及ぼす項目¹⁾を中心とした変数を用いる。

2. 既往研究

平川ら²⁾は、高速道路のトンネル灯具の劣化過程を混

合マルコフ劣化ハザードモデルで記述することを試み、劣化に影響を及ぼす環境要因を明らかにしている。その結果、トンネル入口部付近に設置されている灯具、トンネル内の勾配絶対値が 2.0%以上の位置に設置された灯具について劣化の進行が早い傾向があることが報告されている。しかし、分析対象の灯具は供用開始年がすべて同一であり、環境要因に供用年数の差異を考慮できていない。

前田ら²⁾は、トンネル系を単位としてその状態確率の動的変化をマルコフ確率過程上の時間変動として灯具の健全度予測をモデル化した。そのモデルを鋼板製とステンレス製それぞれでの健全度の推移を示すことでその有用性を示している。しかし、経済性や効率性に重きを置いているため、劣化予測で個別灯具の劣化予測は扱っていない。

南ら³⁾は数量化理論 I 類を用いてコンクリート桁に劣化を与える環境要因についての分析を行った。その結果供用年数によって劣化速度やそれに影響を与える要因が異なることを示した。しかし、分析対象区間が石川県で、劣化に影響を与えていたのは年最深雪量など、日本海の気候ならではの環境要因が多い。

対して、本研究では灯具の補修・撤去の計画策定に資することを目指し、個別灯具の環境要因を考慮した劣化予測モデルを構築する。また、劣化過程には各種環境要因が複雑に作用しあっていることが考えられるため、要因間の交互作用を反映可能な AI モデルによる劣化予測を行う。

3. 研究概要

本研究では入口からの距離、トンネル勾配など主とした環境要因14項目を用いて、次回点検時に劣化判定区分が悪化するか否かを予測するAIモデルを構築する。モデル構築に使用する環境要因は表-2示す通りであり、次章にて詳述する。さらに、構築したモデルの有用性を比較するために、従来手法による予測モデルとして、ロジスティック回帰モデルとの再現性の比較を行う。

(1) AIモデル

本研究で構築するAIモデルの概要を説明する。モデルは図-1に示すように入力層、中間層、出力層の3層からなる多層ニューラルネットワークを採用する。中間層は3層とし、各層のニューロン数を変更するなどモデルを複雑化することで、より高い精度で予測を行うモデルの構築を試みる。

(2) ロジスティック回帰モデル




図-1 多層ニューラルネットワークモデル構造

表-2 各種環境要因とその処理方法

項目名	処理方法
上下区分	ダミー変数化 (上り:1,下り:0)
車線区分	ダミー変数化 (追越:1,走行:0)
交通量 (百万台/年)	標準化
大型交通量 (百万台/年)	標準化
累積交通量 (百万台)	標準化
累積大型交通量 (百万台)	標準化
トンネル延長 (km)	標準化
供用年数 (年)	標準化
曲率 (/km)	標準化
トンネル内勾配 (%)	標準化
平均勾配 (%)	標準化
入口からの距離 (km)	標準化
坑口からの距離 (km)	標準化
海までの距離 (km)	標準化

構築したAIモデルの再現性を比較するため、従来手法のモデルであるロジスティック回帰モデルも構築する。回帰式は式(1)で表される。

$$p = \frac{1}{1 + e^{-(a_1x_1+a_2x_2+\dots+a_nx_n+b)}} \quad (1)$$

p : 劣化リスク a_n : 偏回帰係数 b : 定数項

4. 分析データ概要

(1) トンネル照明点検データ

取付金具の点検データは、13本のトンネルに設置されている 5,439 個の灯具の点検総計 36,265 回分ある。取付金具とは、灯具をトンネルに取り付けるための金具のことを指す。点検では 2010 年から 2018 年の 9 年間、特定の箇所のみを点検する抜き取り点検が 1 年に 1 度実施されている。ここで、設置日と点検日の日数の差を供用




図-2 点検回数ごとの灯具数

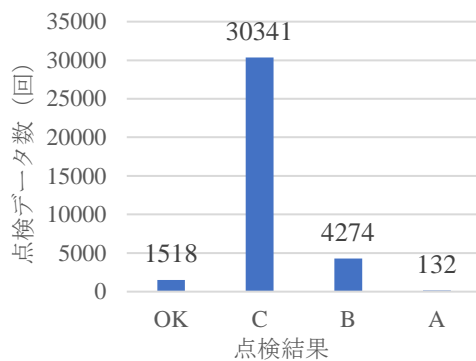


図-3 点検結果ごとの点検データ数

日数とし、365 で除した値を供用年数 (年) とする。図-2 示す通り灯具によって点検回数は異なっている。点検結果ごとの点検データ数は図-3 に示す。本研究ではデータ数が最も多い点検結果 C のみを分析対象とする。

(2) 道路構造データ

道路構造データとして、0.1kpごとに、上下区分、車線区分、トンネル延長 (km)、曲率 (km)、勾配 (%) が記録されている。ここで、勾配は灯具設置位置における勾配の他に、トンネル坑口間の平均勾配を算定し、いずれも進行方向を考慮しない絶対値を用いた。灯具は、坑口0m地点では設置されておらず、トンネル内で等間隔に設置されていると仮定し、設置位置を灯具個別に決定させた。その後、自動車がトンネルに侵入する側の坑口を入口とし、灯具の入口からの距離 (km) を算出した。また、設置されている灯具から近い側の坑口までの距離を坑口までの距離 (km) として算出した。海までの距離 (km) は地図上で同心円を描くツールを用い、トンネルの中央から最も近い海までの直線距離を0.5km単位で計測した値とした。

(3) 交通量データ

交通量 (百万台/年)、大型交通量 (百万台/年)、累積交通量 (百万台)、累積大型交通量 (百万台) は区間ごとの交通量データをもとに算出した。すべての点検年度において、2016年度の交通量データが交通量 (百万台/年)、大型交通量 (百万台/年) となっている。また、年間交通量を日数交通量、年間大型交通量を日数大型交通量に換算し、それぞれに灯具の供用日数を乗じたものを累積交通量 (百万台)、累積大型交通量 (百万台) として算出した。

(4) 環境要因の処理法

環境要因を入力データにする際、名義尺度の2項目はダミー変数化した。比例尺度のその他12項目は標準化処理を行った。環境要因のそれぞれ項目とその処理方法を表-2に示す。また、標準化は式(2)のように算出される。

$$z = \frac{x - \bar{x}}{s} \quad (2)$$

z: 標準化後の値 x: 処理前データ

\bar{x} : 平均 s: 標準偏差

5. モデル構築

(1) 学習用データと検証用データ

2011年度から2017年度に行われた点検結果において、判定区分がCとされた21,227回分のデータを学習用データと検証用データに分割する。2011年から2016年の環境要因14項目を含めたデータ18,622回分の点検データを学習用データとして、モデルの構築を行う。その後、2017年のデータ2,605回分の点検データを検証用データとして、モデルの予測再現性を検証する。

(2) AIモデルの構築

AIモデルの再現性は、そのネットワーク構造に依存するため、パラメータを変化させてより高い再現性をもつ構造の構築を試みる。本研究では、中間層のニューロン数、過学習を抑制するために有効なドロップアウト、学習データを何回繰り返して学習させるかを表すエポック数の3つに着目し、高い再現性を持つ値を順番に求めた。その結果、中間層のニューロン数は一層目から32, 16, 16とし、ドロップアウトは0.05とし、エポック数は200とした。

(3) ロジスティック回帰モデルの構築

AIモデルと同様に、学習用データを用いて灯具の劣化予測を行うロジスティック回帰モデルを構築する。その推定結果を表-3に示す。

表-3 各種環境要因とその処理法

項目名	係数	Z 値
定数項	-13.81	-8.76**
上下区分ダミー (上り:1,下り:0)	-0.03	-0.47
車線区分ダミー (追越:1,走行:0)	1.00	3.42**
交通量 (百万台/年)	5.03	3.38**
大型交通量 (百万台/年)	-6.79	-1.23
累積交通量 (百万台)	-0.09	-0.82
累積大型交通量 (百万台)	0.29	0.71
トンネル延長 (km)	0.03	0.36
供用年数 (年)	0.04	0.44
曲率 (km)	-0.04	-3.56**
トンネル内勾配 (%)	0.14	2.15*
平均勾配 (%)	-0.06	-0.77
入口からの距離 (km)	-0.34	-3.83**
坑口からの距離 (km)	1.23	7.45**
海までの距離 (km)	0.20	7.37**
逸脱度の差	272.7(df=14)	
残差逸脱度	6328.4	
サンプル数	18622	
** p<0.01, *p<0.05		

表-4 混同行列

		予測	
		劣化あり	劣化なし
実 際	劣化あり	真陽性 (TP)	偽陰性 (FN)
	劣化なし	偽陽性 (FP)	真陰性 (TN)

(4) 評価指標

本研究では、評価指標としてF値を用いて予測結果の評価を行う。

本研究で構築するモデルでは、次回の点検で劣化する確率を出力とする。この劣化リスクに閾値を設定することで「劣化あり」「劣化なし」の2値に分類できる。この時、表-4で示す混同行列を用いて予測の結果に対して実際の結果が一致しているかを示すことができる。真陽性 (TP) は実際に劣化した灯具を劣化したと予測できた個数、偽陰性 (FN) は実際に劣化した灯具を劣化しないと予測した個数、偽陽性 (FP) は実際に劣化していない灯具を劣化すると予測した個数、真陰性 (TN) は実際に劣化していない灯具を劣化しないと予測できた個数を指す。

式(3)で示される適合率 (Precision) は劣化ありと予測されたもののうち、実際に劣化した割合で算出される。式(4)で示される再現率 (Recall) は実際に劣化が発生したデータのうち正しく劣化したと予測した割合で算出される。ここで、適合率と再現率の調和平均を取ることで算出されるF値を式(5)に示す。本研究では、閾値を0.001




図-4 F値の比較

表-5 AIモデルの混同行列

		予測	
		劣化あり	劣化なし
実 際	劣化あり	38	78
	劣化なし	283	2206

表-6 ロジスティック回帰モデルの混同行列

		予測	
		劣化あり	劣化なし
実 際	劣化あり	58	58
	劣化なし	741	1748

ごとに変化させて、最大となるときのF値とその時の閾値を算出する。

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

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

$$F = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

6. 結果

2017年の点検データを学習済みのモデルに入力し、そのモデルが出力した結果について評価する。各モデルのF値を比較した図-4を示す。AIモデルのF値は0.174、ロジスティック回帰モデルのF値は0.127を取った。したがって、従来の手法である回帰モデルよりもAIモデルによる予測の精度が高いことが示された。AIモデルの精度が高くなった理由としては、要素間の交互作用を考慮できたことが考えられる。AIモデルによる混同行列を表-5に、ロジスティック回帰モデルによる混同行列を

表-6 に示す. AI モデルの閾値は 0.097, ロジスティック回帰モデルの閾値は 0.052 を取った.

7. おわりに

本研究では, 環境要因を用いて灯具の劣化予測を行う AI モデルの構築を行った. 構築した AI モデルと従来の手法であるロジスティック回帰モデルとの精度を比較し, AI モデルの予測精度が高いことが確認できた. 今後は点検結果の予測対象を B にしても同じ再現性を保てるかを検証する.

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.

ここに謝意を表する.

参考文献

- 1) 平川恵士, 水谷大二郎, 貝戸清之: 異質性を考慮したトンネル照明灯具の劣化予測, 照明学会誌 第 97 巻 第 11 号, pp706-714, 2013.
- 2) 前田典昭, 河村圭: 簡易動的マクロモデルによるトンネル照明設備の健全度予測, 土木学会論文集 F4, Vol. 71, No. 1, pp19-32, 2015.
- 3) 南貴大, 藤生慎, 中山晶一郎, 高山純一: 定期点検結果を用いた既存コンクリート桁の劣化速度に与える環境要因分析, 土木学会論文集 D3, Vol. 73, No. 5, pp323-330, 2017.

(2021.?.?受付)