

AI を用いたトンネル照明灯具の劣化予測モデル

愛媛大学大学院 学生会員 ○奥村尚登 愛媛大学大学院 正会員 坪田隆宏
愛媛大学大学院 正会員 吉井稔雄

1. はじめに

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.

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は十分に有しているとは言い難い。したがって、ある点検時においては構造的に問題なしと判定された灯具群が、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 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. 分析データ概要

データは、13 本のトンネルに設置されている 5439 個の灯具の点検総計 36265 回分である。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 度実施されているが灯具によって点検回数は異なっている。点検結果の内訳を図-1 に示す。本研究では、データ数が最も多い点検結果 C のみを分析対象とし、次回点検で劣化するか否か、すなわち判定区分が B もしくは A になるかの予測を行う。各データにはトンネル内勾配やトンネル入口部からの距離などの環境要因 14 項目がそれぞれ付随している。環境要因を入力データにする際、名義尺度の上下区分、車線区分の 2 項目はダミー変数化した。比例尺度の交通量、大型交通量、累積交通量、累積大型交通量、トンネル延長、供用日数、曲率、トンネル内勾配、トンネル内平均勾配、トンネル入口部からの距離、坑口からの距離、海までの距離の 12 項目については標準化処理を行った。標準化は式 (1) のように算出される。




図-1 点検結果の内訳

$$z = \frac{x - \bar{x}}{s} \quad (1)$$

z : 標準化後の値, x : 処理前データ,
 $\bar{x}$: 平均, s : 標準誤差

3. モデル概要

灯具の劣化を予測する AI モデルには多層ニューラルネットワークを用い、ディープラーニングによってパラメータを決定するモデルの構築を行った。

(1) 学習用データと検証用データ

2011 年から 2016 年の環境要因 14 項目を含めたデータ 18622 回の点検データを学習用データとして、モデルの構築を行った。その後、2017 年のデータ 2605 回の点検データを検証用データとしてモデルの再現性を検証する。

(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、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設定を変更させて高い再現性を有するモデルを順に特定した。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。

$$p = \frac{1}{1 + e^{-(a_1x_1 + a_2x_2 + \dots + a_nx_n + b)}} \quad (2)$$

p : 劣化リスク, a_n : 偏回帰係数, b : 定数項

(3) ロジスティック回帰モデル

AIモデルの再現性を比較するため、AIモデルと同様に、灯具の劣化予測を行う従来モデルのロジスティック回帰モデルを構築する。回帰式は式(2)で表される。

4. 評価指標

モデルの出力である劣化リスクに閾値を設定することで、次回点検時に「劣化あり」「劣化なし」の2値に分類することができる。表-2に示す混同行列を用いることで、モデルの予測が実際の結果と一致しているかを表せる。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ごとに变化させて、最大となるときのF値とその時の閾値を算出する。

5. 結果

2605 回分の検証用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、各モデルのF値を算出して比較した図-2を示す。AIモデルは閾値が0.097のとき、F値は0.174、ロジスティック回帰モデルは閾値が0.052のとき、F値は0.127を取った。したがって、従来手法のロジスティック回帰モデルより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。

6. 結論と今後の課題

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することで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』 p706-714, 2013.

表-2 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)

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

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

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




図-2 F値の比較