

路面性状データを用いた舗装補修・修繕工法の使用可能年数評価手法の開発

長岡工業高等専門学校 学生会員 ○高嶋 冬依

長岡工業高等専門学校 正会員 込山 晃市

長岡工業高等専門学校 正会員 陽田 修

1. はじめに

平成 29 年に策定された舗装点検要領¹⁾には、国が管理する道路において、全路線、全車線を対象に 5 年に 1 回の頻度で舗装点検を行うことを基本とする旨が記載され、定期点検が実施されている。しかし、舗装の劣化は構造条件や使用環境条件など、劣化要因が一樣ではないため、点検データを劣化予測に活かすことができず、対処療法的な補修・修繕が行われているのが実状である。

本研究では、各補修・修繕工法が健全性を維持できる期間に着目し、補修・修繕工が健全性を維持できる期間を「使用可能年数」と表現し、ある補修・修繕工法で補修・修繕を実施した年から次の補修・修繕までの年数として定義する。道路区間毎に各種補修・修繕工法の使用可能年数を設定することができれば、実状に即した補修・修繕工法の選定が可能となり、適切な舗装修繕計画の立案が可能となると考えた。

そこで本研究では、新潟県内の国道 2 路線を対象に、道路管理者が保有する定期点検データと、補修履歴や除雪記録などの管理データおよび管理台帳の諸元データなど、それぞれが直接関係性を持たない多次元のデータを用いて深層学習を行い、区間毎に使用可能年数を推定することを目的とする。なお、本研究では、補修・修繕工法として、適用事例の多い「切削オーバーレイ工」を対象とした。

2. 研究の方法

2.1 入力データの抽出

本研究では、新潟県内の国道で行われた、平成 24～27 年度、29 年度～令和 2 年度の舗装定期点検データ（100m 評価。以下、点検データとする）と点検が行われた各路線の過去 5 回の補修履歴データを使用した。点検データおよび補修履歴データは路線 A と路線 B で直近の修繕を切削オーバーレイ工で行った区間を対象とした。なお、点検データには、交通量や沿道状況等のプロファイルを含んでいる。

表－1 に点検データと補修履歴データの中から入力データとして抽出した要素を示す。ここで、点検データに含まれていない劣化速度（ひび割れ率）は既往の研究²⁾から劣化速度（%/月）を算出した。

2.2 解析手法

本研究では Sony の NNC（Neural Network Console）を用いて使用可能年数を推定するモデルを構築した。表－2 にモデルの設定を示す。利用する深層学習モデルとしては入力層、中間層（3 層もしくは 4 層）、出力層で構成される全結合型モデルを構築した。中間層は 3 層、4 層それぞれで ReLU のみを使用したパターンと、出力層の 1 つ前の層に Sigmoid を使用したパターンの計 4 パターンを検討した。出力層にはデータセットの変数と正解データの二乗誤差を最小化する Squared Error を用いた。なお、使用可能年数については入力データと同様に、最大値と最小値にて 1 から 0 の間を取るように正規化処理を行い、推定結果には逆の手順での数値処理を行った。

表－1 入力データ

要素	処理
1.劣化速度（ひび割れ率） 2.大型車交通量（台/日） 3.敷設年度（年） 4.最新修繕・補修からの経年数（年） 5.除雪車出動回数（回/年） 6.平均気温（℃/年） 7.平均降雪量（cm/年） 8.平均降水量（mm/年）	正規化
9.沿道条件 10.舗装材料	ダミー変数化

表－2 モデルパターン・学習時の設定

種類			モデルパターン			
			case①	case②	case③	case④
中間層	活性化関数	1層目	ReLU	ReLU	ReLU	ReLU
		2層目	ReLU	ReLU	ReLU	ReLU
		3層目	ReLU	ReLU	—	Sigmoid
		4層目	—	Sigmoid	—	—
出力層			Squared Error			
ニューロン			128-64-1（3層）, 256-128-64-1（4層）			
バッチサイズ			64			
学習回数			100,300,500			
最適化方法			Adam			

キーワード 道路舗装、深層学習、切削オーバーレイ、使用可能年数

連絡先 〒940-8532 新潟県長岡市西片貝町 888 番地 長岡工業高等専門学校 TEL0258-34-9273

推定した使用可能年数については二乗平均平方根誤差（以下、RMSE）、決定係数（以下、 R^2 値）により評価をした。

3. 研究の結果

3.1 路線 A

表－3 に各モデルが出力した結果を示す。case①において、RMSE が 1.08 年、 R^2 値が 0.833 と最も良い結果が得られた。

図－1 に最も精度良く推定できた case①における実測値と推定値のプロットを示す。精度よく推定できていると実線上にデータが多く現れる。破線は舗装点検間隔である 3 年を±3 年で表したものである。図－1 から、推定結果のプロットは実線と破線の間に多く現れているため、点検間隔の観点からも精度良く推定できていると考えられる。しかし、推定値が実測値に対して、点検間隔である 3 年を超え過大評価をしている区間が存在した。過大評価をしている区間の傾向として、沿道条件が山地であり、除雪車出勤回数が極端に少ない傾向が見られた。除雪車が少ない区間は降雪量や大型車交通量が少ない傾向も見られ、劣化に影響を与える要因が他の区間に比べて少ないと考えられるため、実測よりも長い年数で推定してしまったと考えられる。

3.2 路線 B

表－4 に各モデルが出力した結果を示す。case①において、RMSE が 1.85 年、 R^2 値が 0.652 と最も推定精度の良い結果が得

られた。しかし、 R^2 値は 0.7 以下となり、それほど推定精度の良くない結果となった。これは、路線 B は豪雪地帯に属する区間が多く、地区によって降雪量の差が大きい。そのため、除雪車や降雪量だけでは降雪の差から生じる変化を考慮しきれず、推定が難しかったのではないかと考えられる。したがって、積雪量や凍結防止剤など説明変数の補填を行い入力データセットの構成を再検討する必要があると考えられる。

紙面の都合により、路線 B の推定結果を示すことはできないが、路線 B においても、推定結果のプロットは実線と破線の間に多く現れており、点検間隔の観点からは精度良く推定できていると考えられる。しかし、路線 A と同様に、過大評価をしている区間が存在した。過大評価をしている区間の傾向として、同じ実測値の区間と比較し降水量が多い傾向が見られた。これは、降水量が多い区間では、表層部のひび割れから雨水など、水分の浸入量が多いことが要因のひとつであると予想される。

4. まとめ

- ・ 深層学習により、実際の補修履歴データを用いて使用可能年数を推定できることが示唆された。
- ・ 路線 A において、 R^2 値が 0.8 を超え、比較的精度良く推定できていることが示唆された。
- ・ 路線 B は点検間隔の観点からは精度の良い推定ができていた。しかし、 R^2 値の結果から推定精度の向上が見込めると考えられ、入力データセットの再検討を行う必要があることが示唆された。

謝辞 本研究にあたり、国土交通省北陸地方整備局に協力頂いた。ここに記して謝意を表する。

参考文献


1) 国土交通省：舗装点検要領，2017
2) 大窪和明，全邦釘，橋爪謙治，藤田尚：道路舗装の劣化速度に関する探索的空間データ分析，土木学会論文集 E1(舗装工学)，Vol.74，No.3，pp.95-103，2018

表－3 RMSE・ R^2 値（路線 A）

モデル	学習回数	RMSE	R^2
case①	500	1.08	0.833
case②		1.11	0.817
case③		1.17	0.791
case④		1.15	0.795

表－4 RMSE・ R^2 値（路線 B）

モデル	学習回数	RMSE	R^2
case①	500	1.85	0.652
case②		1.87	0.639
case③		2.06	0.566
case④		2.12	0.531



図－1 路線 A の推定結果