

ディープラーニングによる都市間高速道路の路面劣化予測モデル

愛媛大学 非会員 橋本 申 愛媛大学 正会員 吉井 稔雄 愛媛大学 正会員 ○坪田 隆宏
愛媛大学 正会員 全 邦 釘 愛媛大学 非会員 堀口 睦美

1. はじめに

道路舗装は、路面の平坦性や透水性を維持することで車両の走行快適性や適度な滑り抵抗性を保持し、車両通行時の安全性を確保するなど、道路交通を支える重要な役割を担っている。一方で、車両による活荷重を受け続けるため、比較的早く劣化が進行することが知られており、将来の劣化進行度を把握し効率的に補修することが求められる。舗装劣化といった非線形性の高い事象の予測においては、従来型の統計モデルによる予測手法と比較して、ディープラーニングによる非線形回帰モデルの適用が効果的と期待されるが、十分な検討は為されていない¹⁾²⁾。そこで本研究では、舗装の供用期間を主要因とする路面劣化予測モデルを、ディープラーニングを用いて構築する。劣化進行の起点を道路路面補修時点とすることで、複数時点での調査結果を用いることによる系統誤差を排除する。また、構築したディープラーニング手法の有用性を評価する為に、従来手法による予測モデルを代表して重回帰モデルとの再現性比較を行う。分析対象路線は、四国の高速道路ネットワークを構成する高松自動車道・松山自動車道・高知自動車道・徳島自動車道の4路線とする。

2. 研究概要と分析データ

2.1 ディープラーニングモデルの構築

本研究では、分析対象路線を0.1kp、すなわち100m区間に分割した上で、路面劣化に影響を与えると考えられる複数の要因を用いて、当該区間の路面性状値を予測するモデルを構築し、その再現性を検証する。用いる変数は表1の通りである。構築するディープラーニングモデルは、全変数を入力値とし、路面性状値の一つであるわだち掘れ量を出力値とする全結合順伝搬の構造とする。モデル構築に際しては、隠れ層の数、各層のユニット数、あるいは活性化関数の設定の違いによって再現性が変化する。最適なモデル構造を探索する為に、本研究ではパラメータの組み合わせを変更した複数のモデルを適用し、それぞれに学習を行うことで、再現性の比較検証を行う。

2.2 再現性の検証

構築するモデルは将来の路面性状値の予測を目的とする。再現性の検証では、K-分割交差検証手法を用いてモデルの予測性能を評価する。分割方法にはランダムに分割する方法と、人為的に分割する方法の2種類を採用する。前者による検証では、全データをランダムにK等分して学習用データと検証用データを作成する（以下、“ランダム分割”）。後者の人為的に分割する検証では、本研究で扱うデータが4つの路線から構成されることを利用して、各路線が1つのサブセットとなるようにデータを4分割して検証を行うことにより、モデルの空間移転性を検証する（以下、“路線別分割”）。また、モデルの再現性評価に際しては、予測値と実測値の平均二乗誤差（以下、“RMSE”）を用いることで、予測再現性を定量的に評価する。

2.3 分析データ

本研究では、路面性状データ、道路構造データ、感知器データ、ならびに路面環境データを用いる。予測モデルを作成するにあたって、これら4つのデータを1つに統合し分析用データベースを作成した。感知器データを除いて、全て各車線の100m区間ごとに集計されているため、本研究でも各車線の100m区間ごとに集計・分析を行う。感知器データは、各IC・JCT間ごとに記録されており、その間の100m区間における交通量は同一であるとする。また、片側二車線以上の区間では、各車線の交通量は等しいものとして、等配分した値を各車線の交通量とする。また、これら4つのデータのうち1つでも情報が欠落している区間は分析対象から除外した。例

表1 変数一覧

説明変数	前処理
供用期間	正規化
交通量	
大型車交通量	
曲率半径	
縦断勾配	
路面第1層の厚み	
路面第2層の厚み	
降水量	ダミー変数化
凍結防止剤散布量	
車線種別	
構造物種別	
舗装種別	

として、道路幾何構造データは2010年の情報に基づいており、2015年に開通した徳島自動車道の徳島IC～鳴門JCTの区間が含まれていないことから、分析対象から除外した。除外後のデータは全13,653区間から構成される。

3. モデルの構築と精度検証

ディープラーニングによるわだち掘れ量予測モデルを構築では、最も高い再現性を持つモデルを探索する。使用したパラメータ値は表2に示す通りである。なお、学習に用いるエポック数は1,000、最適化関数はAdam、損失関数は平均二乗誤差 (RMSE) とする。検討の結果、隠れ層の数に関しては、4層と10層との比較で再現性に大きな差異が認められなかった為、パラメータ数の少ない4層ネットワークの方が、より適したモデル構造と考えられる。以下、隠れ層4層の場合のみに着目し、検討結果を報告する。

隠れ層を4層とし、ユニット数については1,2層目と3,4層目が同数で、かつ層が深くなるほど少なくなる組み合わせを15パターン用意した。パターン名はユニット数の組み合わせにより命名し、例えば、1,2層目のユニット数が100、3,4層目のユニット数が50の場合、パターン名は[100-50]として以下の説明に用いる。活性化関数については、全てReLU関数のケースを基本とし、そこから隠れ層の2層目あるいは3層目のみをシグモイド関数に換えたケースを加えた計3パターンを比較した。すなわち、ユニット数15パターン×活性化関数3パターンの計45種類のネットワークモデルについて学習を行い、各モデルの再現精度を比較した。

K-分割交差検証手法による各モデルの再現性を比較した結果を図1に示す。分割数K=4とし、データの分割方法はランダム分割とした。結果より、一層目のユニット数が20以下のモデルでは再現性が低下していることが分かった。また、活性化関数にシグモイド関数を用いた場合には、予測誤差が著しく大きくなるケースが存在した。従って、以下では隠れ層数は4層、ユニット数は全て100、活性化関数は全てReLU関数のネットワークによる予測モデルを採用する。

最後に、ディープラーニング手法によるモデル（以下、“DLモデル”）と、重回帰モデルとの比較を行う。ランダム分割と路線別分割のそれぞれの場合における交差検証結果を表3に示す。ランダム分割による検証においては、DLモデルが重回帰モデルより優れた値を示しており、ディープラーニング手法によるモデルを用いることで、再現性が高くなる可能性が示された。一方、路線別分割による検証では重回帰モデルの方が優れた値を示しているが、ランダム分割による検証結果との比較において、両モデルともに高いRMSE値となり、低い再現性を示している。すなわち、両モデル共に空間移転性を有しないとの結果が得られた。

4. おわりに

本研究では、四国の高速道路を対象にディープラーニングによる路面劣化予測モデルを構築し、従来手法である重回帰モデルと比較することで、その予測再現性を定量的に検証した。K分割交差検証を用いて未知データに対する再現性の検証を行ったところ、重回帰モデルとの比較において十分高い再現性を有していることが示された。一方で、路線毎に分割交差検証を行うことで、モデルの場所移転性を確認したところ、DLモデルには場所移転性がないことがわかった。路面性状の調査機器による影響や施工方法の差異等の要因を説明変数に追加することにより、場所移転性をも備えたモデルの構築を目指すことが考えられるが、今後の課題としたい。

参考文献

- 奥田知之、黒須秀明、神武直彦：舗装維持管理効率化のためのニューラルネットを用いた路面性状値予測の検討、情報処理学会第78回全国大会 講演論文集, pp.45-46, 2016.
- 奥田知之、鈴木康豊、神武直彦：将来予測精度を考慮した舗装劣化予測モデルの精度評価手法の提案と検証、土木学会論文集 E1 (舗装工学), Vol.73(3), pp.I_229-I_236, 2017.

表2 モデルパラメーター一覧

パラメータ	値
隠れ層の数	4層, 10層
ユニット数	100, 50, 25, 10, 5
活性化関数	ReLU関数, シグモイド関数




図1 隠れ層数4層ネットワークの再現性比較

表3 モデル別の RMSE 値[mm]

モデル	データ分割方法	
	ランダム分割	路線別分割
重回帰	2.69	4.07
DL	1.99	5.45