

ディープラーニングを用いた 高速道路の路面劣化予測モデル

橋本 申¹・吉井 稔雄²・坪田 隆宏³・全 邦釘⁴

¹非会員 愛媛大学 工学部環境建設工学科 (〒790-8577 愛媛県松山市文京町3)
E-mail:hashimoto.shin.14@cee.chime-u.ac.jp

²正会員 愛媛大学大学院 理工学研究科 (〒790-8577 愛媛県松山市文京町3)
E-mail:yoshii@cee.chime-u.ac.jp

³正会員 愛媛大学大学院 理工学研究科 (〒790-8577 愛媛県松山市文京町3)
E-mail:t.tsubota@cee.chime-u.ac.jp

⁴正会員 愛媛大学大学院 理工学研究科 (〒790-8577 愛媛県松山市文京町3)
E-mail:chun@cee.chime-u.ac.jp

道路舗装は車両の快適・安全な走行を担うなど、道路交通を支える重要な基盤であり、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。路面性状測定データを利用して路面劣化予測を試みる取り組みは数多くなされているが、ディープラーニングを用いた予測モデルは十分な検討はなされていない。そこで本研究では、ディープラーニングを用いて路面劣化予測モデルを構築し、RMSEを用いて重回帰モデルとの比較を行うことで、予測再現性を定量的に評価した。その結果、ディープラーニングによって従来より高い再現性を持つモデルを構築することができる可能性が示された。また、本研究で構築したモデルは空間移転性を有していなかったが、その一因として過学習が起きていることが確認された。

Key Words : pavement, rut depth, neural network, deep learning

1. はじめに

日本の公共インフラは、1960年代の高度経済成長期に整備されたものなど、その老朽化が深刻な問題となっている。しかし一方で、国家予算に占めるインフラ事業費は減少傾向にあり、適切な維持管理が求められている。

こうした状況にあるインフラの中でも特に道路舗装は、雨天時の道路の泥濘化や乾燥時の砂塵を防止することで車両の走行快適性を維持し環境を保全することや、路面の平坦性や透水性を維持し適度な滑り抵抗性を持たせることで車両通行時の安全性を確保すること、また適切な構造や舗装材料を用いることで騒音・振動を減らしつつ良好な道路景観を創出することなど、社会において重要な役割を担っている一方で、常に車両による活荷重を受けていることから、他のインフラ構造物等と比べて寿命が10年～20年と短く、継続的かつ高頻度の保守点検を要する。さらに、近年では車両の大型化や交通需要の増加に伴って、建設当初の想定よりも早く劣化が進行してき

ていることから、補修を要する地点や将来の劣化進行を把握した上で、より効率的に補修を行うことが求められる。

これまで、路面舗装の劣化速度・劣化予測に関する研究は、複数時点で行われた路面性状調査の値を比較した上で、外れ値と考えられるデータを除外する手法がしばしば取られてきた。しかしこの手法には、例えば調査手法・機器・基準の変化等によって生じる真の変動量とは異なる測定誤差が結果に大きく影響を与え、かつ特定の値を除外したことによって予測値が実際より過大・過小に見積もられてしまうといった問題が存在する。

また、近年情報科学の急速な発展により、ディープラーニングを用いた研究が分野を問わず広く行われつつある。路面劣化予測においても、機械学習やニューラルネットワークを用いた研究がかねてより行われているが、ディープラーニングを用いた手法はまだ十分な評価がなされていない。

そこで本研究では、劣化変動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した上で、路面劣化予測モデルを構築する。また、ディープラーニングによるモデルと従来手法によるモデルの予測再現性を定量的に比較することで、ディープラーニング手法の有用性を評価する。

2. 先行研究

(1) 主な先行研究

路面性状測定車が登場して以降、大量の路面性状データを得ることができるようになり、それを利用して将来の路面性状を予測する試みが数多くなされてきた。

阿部・飯野¹⁾は、わだち掘れ量と道路の共用年数関係について、測定機器の開発技術的問題から生ずる真値との「開発時に許された測定誤差」、測定機器の距離計・地図上の距離・実際の距離等の差から生ずる「距離のずれに伴う誤差」、測定機器の違いから生ずる「測定装置間の誤差」の3種の誤差を考慮した上で、統計的に分析を行い、測定データにはいくらか誤差が含まれるものの定量的解析に十分耐えうるものであると結論づけた。しかし、同一地点のわだち掘れの変化量に傾向が見られないことや、変化量より測定誤差の方が大きいと考えられることから、わだち掘れ量を毎年測定してもそのデータから経年変化を得ることはできないと指摘した。

重原²⁾は、ニューラルネットワークによるわだち掘れ予測モデルを開発した。シグモイド関数を活性化関数とした3層（隠れ層数1）全結合順伝播型で、IC区間・構造物種別・車線種別・舗装種別・累積大型車交通量を説明変数として、わだち掘れ量を予測するネットワークを構築し、北陸地方の高速道路データを用いて10000エポック学習したところ、予測値と実測値が十分一致したモデルを開発することができたとした。その予測から、盛土と切土でわだち掘れ量に差はないことと、密粒度アスファルト舗装よりもポーラスアスファルト舗装の方がわだち掘れが早く進行することを示した。

奥田ら（2016）³⁾は、ディープラーニングによってわだち掘れ量・ひび割れ率・平坦性を予測するモデルを開発した。ユニット数100の隠れ層10層を含む12層全結合順伝播型で、舗装種別・大型車交通量・路床支持力・最新補修工法・供用期間・調査年度・構造物種別・交差点有無・道路幅員・前回調査値を説明変数として、わだち掘れ量・ひび割れ率・平坦性のいずれかを予測するネットワークを構築した。その結果として、学習に用いたデータとは異なるデータに対して予測モデルを適用し、予測値と実測値の平均二乗誤差と相関係数で評価し、また予測値と実測値の散布図から値の大きい区間ほど過小評価する傾向があることを示した。

奥田ら（2017）⁴⁾は、リカレントニューラルネットワ

ークモデルを用いて、より現実的な精度評価を行うための新たな学習手法を提案した上で、時刻情報を含む路面性状データから予測モデルを構築した。従来、時刻情報を持つデータから予測モデルを構築する場合は全ての時刻のデータをパラメータ推定に用いていたが、実運用に際しては観測不能な将来の予測を行う必要があることから、データのある時点で分割して早い方のデータのみをパラメータ推定に用いる手法を提案した。その上で、従来手法と提案手法それぞれのモデルの予測性能を比較し、従来手法では予測性能が過大評価され、提案手法ではより現実的なモデルの評価が可能であることを示した。

大窪⁵⁾は、空間統計学の手法を用いて抽出した劣化速度の速い区間に対して、一般化線形混合モデルを用いて劣化速度に影響を与える要因を分析した。四国地方の高速道路を対象として、まず、ひび割れ率・わだち掘れ量・IRIの変化速度に関してMoranのI統計量を計算し、空間的自己相関が生じている、つまり劣化速度が速い区間が隣接しているホットスポットおよび劣化速度が遅い区間が隣接しているコールドスポットを抽出した。ひび割れ率のホットスポットに対して、一般化線形混合モデルによって交通量・降水量・凍結防止剤散布量・表層厚・基層厚・構造物種別・路線が劣化速度に与える影響を分析した。その結果、降水量が有意に劣化速度を速め、また構造物種別に関しては盛土・切土区間で劣化速度が有意に速いという結論が得られた。

(2) 先行研究の問題点

同一地点におけるわだち掘れ量の値は、補修がない限り年々上昇するはずであるが、調査データにはそれに反する値が記録されていることがある。従来の研究では、しばしばこのような例をデータの誤りとして除外する方法がとられてきた。例えば重原らはわだち掘れ量が「極端に減少している」データを除外しており、奥田ら（2017）⁴⁾は複数時点間における調査値の変化量分布の上下5パーセントを外れ値として除外している。大窪らは、複数時点間における変化量を目的変数にしており、補修が行われていないにもかかわらず路面性状が改善している区間は全て除外している。このような、値の変化量から一部の区間のみを人為的に除外する手法は、単年で見た場合の測定値の分布が偏るなどして、予測モデルが過大あるいは過小に路面性状値を見積もる危険性がある。

また、将来の補修計画策定に向けた予測モデルを構築する際には、その予測精度の評価が不可欠である。しかし従来の研究では、その評価が十分に行われていないことがある。例えば重原らの研究では、モデルの実測値と予測値が「よく一致した」としているのみで、定量的な評価は行われていない。また、全てのデータからパラメ

ータの推定を行い、同じデータを用いてモデルの評価を行っているため、分析対象路線全体のおおまかな傾向は予測できても、短い特定1区間や学習していない別路線の予測には不向きである可能性がある。奥田ら（2016）³⁾は、パラメータの推定に用いたのとは別のデータに対して、モデルによる予測値との平均二乗誤差と相関係数を算出することによって、予測性能の定量的な評価を下している。しかしその値を一見しただけでは、そのモデルがどの程度優れているのか判断し難い。

(3) 本研究の位置づけ

先行研究には、データの処理方法とモデルの評価方法という2つの問題があることを指摘した。

本研究では、最新の路面性状調査値のみをデータとして利用し、前回調査ではなく補修時点を劣化変動の起点として扱うことによって、複数時点の調査値を用いることによる系統誤差の影響を排除する。また、値の上下を元にした外れ値除去処理は、予測値の過大・過小評価につながる可能性があるため、行わない。予測モデルの評価には、パラメータ推定に用いたのとは別のデータに対する平均二乗誤差と相関係数を算出し、かつ従来手法による予測モデルと比較することで、その再現性を定量的・定性的に評価する。

3. 研究概要

(1) 研究指針

本研究では、供用期間を主要因として将来の路面性状値を予測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。さらに、構築したディープラーニング手法の有用性を検証するために、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。

(2) 用いる変数

本研究では、各路線の各0.1kpを1区間として分析を行い、路面劣化に影響を与えそうな複数の要因から、当該区間の将来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。

(3) 予測再現性の評価方法

今回構築するモデルは、将来の路面性状値の予測を目的とする。よってモデルには、学習に用いた既知のデータへの再現性に加えて、学習していない未知のデータに対する高い再現性を有することが求められる。そこで本研究では、K-分割交差検証手法を用いて、モデルの予測性能を測る。本研究では、分割方法にランダムに分割する方法と、人為的に分割する方法とを用いて検証を行う。前者による検証では、全データを完全にランダムにK

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	
凍結防止剤散布量	
車線種別	
構造物種別	
舗装種別	

等分してサブセット群を作成する（以下，“ランダム分割検証”）。ただし、例えば、隣接区間の一方を学習用データ、もう一方を検証用データとした場合、両区間のデータ値が類似したものとなる可能性がある。そこでモデルの空間移転性を検証するために、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、後者の人為的に分割する検証では、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（以下，“路線別分割検証”）。

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。

4. 分析データ概要

(1) 分析対象区間

分析対象区間は、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路線のうち、西日本高速道路株式会社が管理する区間の上下線全路線である。

(2) 分析データ

本研究では、以下に示す路面性状データ、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。

a) 路面性状データ

路面性状データからは、各車線の0.1kp（100m）区間ごとのわだち掘れ量と、その計測を行った日付、その区間で今まで行われた補修の日付の情報が得られる。2012年度から2016年度までの5年分のデータがあり、路面性状調査は1年に1度行われているが、全区間が毎年調査されているわけではなく、路線ごとに3年に1度の頻度で調査が行われている。なお、1区間内でもわだちの深さは場所によって異なるため、区間内で複数回測定されたらう

ちの最大値を当該区間のわだち掘れ量と定義している。

データでは、複数時点間に補修が行われていないにもかかわらず、路面性状が改善されている区間が存在する。例として、高松自動車道の坂出JCT～善通寺IC間では、2012年度と2015年度にそれぞれ路面性状調査が行われたが、その間に補修が行われなかった241区間のうち233区間でわだち掘れ量が減少しており、2012年度調査と2015年度調査の間で、測定方法・基準等が異なっていたことが推測される。このように測定方法の差に起因すると考えられる誤差による影響を排除するため、本研究では、データの最新年である2016年時点で、各路線において最後に行われた最新の調査の値のみを用いる。

また、本研究では路面性状に影響を与える要因の1つとして、供用期間を用いる。路面性状が調査された日とその直前に路面補修がなされた日の間の日数を計算し、当該区間の供用期間とする。ただし、補修が1度も行われていない区間に関しては、開通日から調査日までの日数を供用期間とする。また、月のみで日付けが記録されていない補修日・調査日については、各月1日に行われたものとして扱うこととする。

b) 道路構造データ

道路構造データからは、各車線の0.1kp (100m) 区間ごとの曲率半径・縦断勾配・第1層の厚み・第2層の厚み・車線種別・構造物種別・舗装種別の情報が得られる。

構造物種別は、盛土・切土・橋梁・トンネルの4種類から構成されている。舗装種別は、密粒舗装・高機能舗装・コンクリート舗装の3種類から構成されている。なお、車線種別には、一般走行車線・追越車線の2種類だけでなく、登坂車線・付加車線・ゆずり車線等が存在するが、これらは数が少ないためいずれも一般走行車線として取り扱う。

c) 感知器データ

感知器データからは、各IC・JCT間の1時間単位の交通量・大型車交通量の情報が得られる。本研究では、2012年1月1日0時から2016年12月31日23時までの5年間のデータを用いて分析を行う。以下では、時間帯別に各区間の5年間の交通量および大型車交通量を集計し、それぞれを日数で除し、1日あたりの時間帯別平均通行台数を算出して、当該区間の交通量および同大型車交通量とする。ただし、データには、1時間あたりの交通量が0台あるいは未記載の時間帯が含まれるが、これらは機器の不具合によるものと考えられるため、0台あるいは未記載となっている時間帯とその前後1時間が含まれる日は一日平均通行台数の計算から除外した。

d) 路面環境データ

路面環境データとして、前期供用期間における各区間ごとの累積降水量と凍結防止剤散布量（使用塩重量）の情報をを用いる。累積降水量は、供用期間の月数で除して

表-2 変更パラメータ一覧

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

1ヶ月平均降水量を算出し、当該区間の降水量とする。なお、トンネル区間では路面が降雨にさらされることはないが、構造物種別でトンネル区間であることが説明されるため、値の補正は行わなかった。

(3) 分析用データベース

予測モデルを作成するにあたって、上記の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0.1kp (100m) 区間ごとに集計されているため、本研究でも各車線の0.1kp (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いるが、その間はどの0.1kp区間でも交通量が同じであるとして取り扱う。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。

5. ネットワークの検討

ディープラーニングによる予測モデルは、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その再現性が変化する。そこで、本章では、これらのパラメータの適切な組み合わせを求めするために、パラメータの組み合わせを変更した多数のネットワークを適用して、それぞれに学習を行い、再現性の比較検討を行う。

(1) 検討するネットワークパターン

各パラメータに設定する値を表-2に示す。なお、エポック数は1,000、最適化関数はAdam、損失関数はMSEとする。以下、隠れ層の数の別に検討結果を報告する。

a) 隠れ層 4層ネットワーク

隠れ層を4層に設定した場合には、ユニット数は、1, 2層目と3, 4層目が同数でかつ深い層ほど少なくなる組み合わせとし、表-3に示す15パターンを用いる。活性化関

表-3 隠れ層数4層のユニット数パターン一覧

パターン名	各層のユニット数	
	1,2層目	3,4層目
[100-100]	100	100
[100-50]	100	50
[100-20]	100	20
[100-10]	100	10
[100-5]	100	5
[50-50]	50	50
[50-20]	50	20
[50-10]	50	10
[50-5]	50	5
[20-20]	20	20
[20-10]	20	10
[20-5]	20	5
[10-10]	10	10
[10-5]	10	5
[5-5]	5	5

表-4 隠れ層数10層のユニット数パターン一覧

パターン名	各層のユニット数				
	1,2	3,4	5,6	7,8	9,10
[100~100]	100	100	100	100	100
[100~5]	100	50	25	10	5

数は、全てReLU関数のものと、そこから隠れ層の2層目
 或いは3層目のみをシグモイド関数に換えたものの3パ
 ターン、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する。

b) 隠れ層10層ネットワーク

隠れ層を10層に設定した場合には、表-4に示すように、
 隠れ層全てのユニット数が100のパターンと、深い層ほ
 どユニット数が少ないパターンの、2パターンを用いる。
 活性化関数は、全てReLU関数のものと、そこから10層
 ある隠れ層のうちのいずれか1層をシグモイド関数に換
 えたものの11パターンを用いる。したがって、隠れ層10
 層ネットワークでは、ユニット数2パターン×活性化関
 数11パターンの、合計22種類のネットワークモデルを学
 習し、各モデルの再現精度を比較する。

(2) 検討結果

図-1, 図-2には、ランダム分割検証による各モデルの
 再現性検証結果を示す。

隠れ層の数に関しては、4層と10層とでその再現性に
 大きな差異は認められなかった。この結果から、多数の
 パラメータを有する10層ネットワークよりも、パラメー
 タ数の少ない4層ネットワークの方が、より適した予測
 モデル構造といえる。

隠れ層のユニット数に関しては、4層ネットワークの

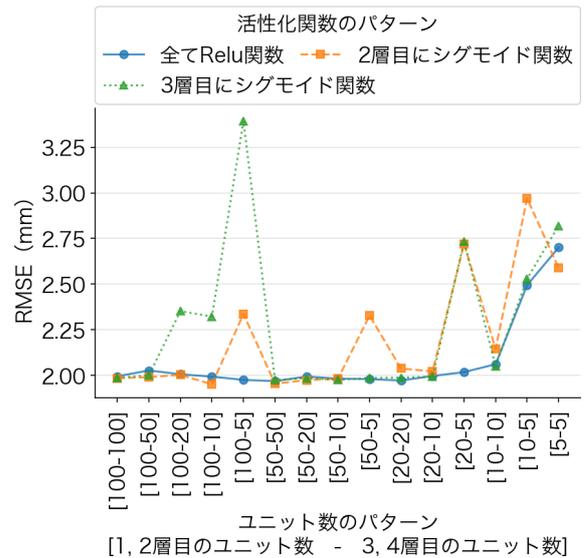


図-1 隠れ層数4層ネットワークの予測再現性比較

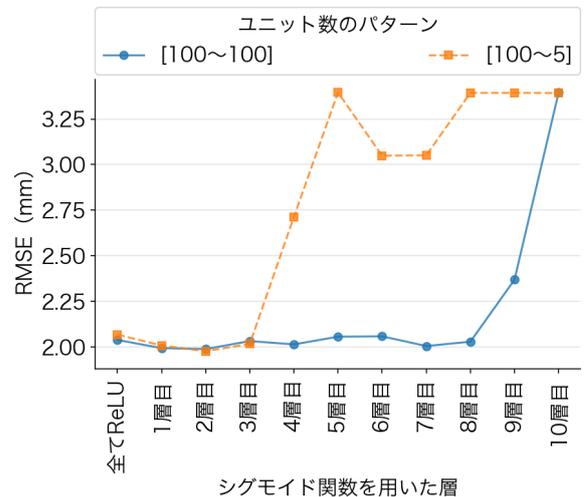


図-2 隠れ層数10層ネットワークの予測再現性比較

場合、一層目が20以下の構造では再現性が低下した。こ
 のことから、第一層のユニット数は20より多く設定する
 ことで高い精度を確保できると考えられる。

活性化関数にシグモイド関数を用いたネットワークの
 場合に、予測値に全て同じ値を出力するモデルが存在し
 た。これは、学習時に勾配消失が起きたためと推察され
 る。対して、ReLU関数はこれが発生しづらく、また単
 純な構造のため計算も早いという利点が知られている。
 したがって、本モデルにおいても、ReLU関数を用いた
 ネットワークを用いることとし、以下では隠れ層数が4
 層、ユニット数が全て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ディープラーニング
 手法によるモデル（以下、“DLモデル”）とし、重回
 帰モデルとの比較を行う。

表-5 モデル別 RMSE (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

表-6 路線別分割の各検証用データに対する RMSE

モデル	検証用データの路線			
	高松	松山	高知	徳島
重回帰	2.83	3.56	4.89	5.00
DL	3.34	5.22	7.67	5.57

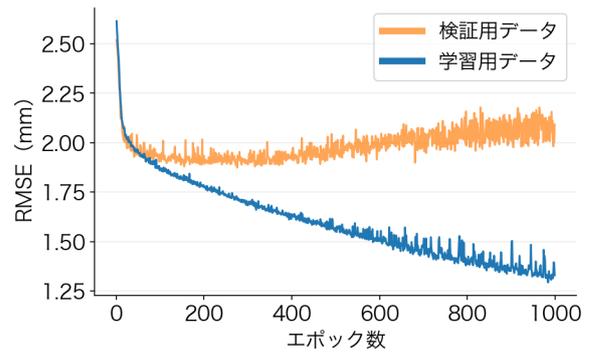


図-3 学習エポック数に伴う予測再現性の推移

6. DLモデルと重回帰モデルの比較

(1) 比較結果

DLモデルと重回帰モデルの再現性比較結果を表-5に示す。

ランダム分割検証においては、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、路線別分割検証においては、重回帰モデルがよDLモデルより優れた値を示した。また、両モデルとも、ランダム分割検証結果と比較するとRMSEが大きく上昇しており、空間移転性を有していないことが示された。

(2) 考察

路線別分割検証によって、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。この検証における、各検証用データに対する予測再現性(表-6)を確認すると、「大型車交通量が少ない」、「カーブ・トンネル・コンクリート舗装の区間が多い」、「降水量が多い」、さらには「わだち掘れが深い」といった他路線とは異なる特徴を有する高知自動車道のデータを検証用データとしたケースにおいて特に再現性が低下している。すなわち、教師データに使用した他の3路線との類似性が低い路線を検証用データに用いたことで再現性が低下したものと推察される。また、路面性状値に関して、本研究によるデータは、同一路線内で最新の調査結果のみを用いているが、異なる路線間では調査時期が異なるため、測定誤差の影響を路線間では排除しきれなかった可能性もあると考えられる。

さらに、DLモデルは、ランダム分割による検証では重回帰モデルよりも再現性が高かったのに対し、路線別分割による検証では、重回帰モデルよりも低い再現性しか得られなかったことから、DLモデルが過学習を行った可能性が考えられる。そこで、過学習の有無を検証するため、DLモデルのエポック数に伴うRMSEの推移を確

認した(図-3)。学習用データに対する再現性はエポックを重ねる毎に高くなっていくが、検証用データに対する再現性は、エポック数が200に近づいたあたりから学習を重ねるにつれて徐々に低くなっており、やはり過学習が起きていることが示された。

7. 結論

本研究では、四国の高速道路を対象として、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。測定誤差の影響を排除するため、モデルの目的変数には最新の路面性状調査値のみを使用した。

まず、隠れ層の数・隠れ層のユニット数・活性化関数の種類を変更した複数のネットワークを構築し、K分割交差検証を用いて検証用データに対するRMSEを算出し、予測再現性の高いネットワーク構造の検証を行った。その結果、隠れ層の数が4層・ユニット数が全て100・活性化関数が全てReLU関数の構造を最適と判断した。

次に、DLモデルの有用性を検証するため、従来手法である重回帰モデルとの予測再現性の比較を行った。その結果、重回帰モデルより高い再現性を有していることが示された。さらに、路線別にデータを分割して検証を行うことで、モデルの空間移転性を確認した結果、DLモデル・重回帰モデル共に空間移転性を有していないという結果が得られた。また、DLモデルがより低い再現性を示したため、エポック数に伴う再現性の推移を確認したところ、その原因の1つとして過学習が挙げられることが示された。

先行研究では、調査機器や施工方法などの要因・条件を説明変数に用いているものや、過学習を抑える手法であるドロップアウトを採用したネットワークを用いてモデルを構築しているものがある。これらによって、より高い再現性や、空間移転性を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

- 1) 阿部頼政, 飯野忠雄: わだち掘れ測定データの解析法に関する研究, 土木学会論文集, No.478/V-21, pp.117-123, 1993.
- 2) 重原大二郎, 西澤辰男, 中源達雄, 平野誠志: ニューラルネットワークによる北陸地方のアスファルト舗装わだち掘れ進行モデル, 土木学会舗装工学論文集, Vol.13, pp.25-30, 2008.
- 3) 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ワーク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.
- 4) 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.
- 5) 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(3), pp.95-103, 2018.

(2018.3.10)

A PAVEMENT DETERIORATION FORECASTING MODEL IN ENPRESSWAYS USING DEEP LEARNING

Shin HASHIMOTO, Toshio YOSHII, Takahiro TSUBOTA and Pang-jo CHUN