

博 士 学 位 論 文

舗装劣化予測高精度化のための
リカレントニューラルネットワークを用いた予測手法の構築

2018年9月

慶應義塾大学大学院

システムデザイン・マネジメント研究科

奥田 知之

Doctoral Dissertation

2018

Deterioration Prediction Method using Recurrent
Neural Network for Improvement of Pavement
Prediction Accuracy

Tomoyuki Okuda

Supervisor Naohiko Kohtake

September 2018

Graduate School of System Design and Management,

Keio University

論文要旨

氏名	奥田 知之
主論文題名： 舗装劣化予測高精度化のためのリカレントニューラルネットワークを用いた予測手法の構築	
(内容の要旨) 舗装劣化予測モデルにより様々な舗装維持管理方策をシミュレーションし、最適な維持管理計画を選択することで舗装維持管理を効率化する事が可能である。しかし、舗装の劣化は様々な要因が複雑に関連する事から不確実性が大きい為、精度の高い劣化予測が難しい。それにより現状は現場技術者により補修工法や時期などの意思決定がされており、舗装劣化予測モデルによるシミュレーションが舗装維持管理の効率化に十分活かされていない。本研究の目的はそのような舗装維持管理の効率化に貢献するため、予測精度の高い舗装劣化予測モデルを活用した予測手法を構築し、有効性を検証することである。この目的を達成するため、本研究では以下の3点の取り組みを実施した。 まず、勾配消失問題、過学習などの困難な問題を解決したリカレントニューラルネットワークモデルによる舗装劣化予測モデルを構築、検証した。具体的には、川崎市で行われた路面性状調査の1998年～2015年間の実データを用いて従来のマルチレイヤーパーセプトロンや一般化線形モデルと予測精度を比較した。その結果、本研究で構築した舗装劣化予測モデルは異なる分布を持つひび割れ率、わだち掘れ量、平たん性の3つの路面性状値全てにおいて予測精度が最も高く、最大でモデル間の平均二乗誤差平方根の差は20%となった。一方、路面性状調査などの構造物点検時系列データは文章や音声などとは異なり、数十年に渡る長い時間スケールを持つ。そのため年代による基準、素材、点検方法などの変化があることで、過去と将来のデータが同じ母集団から生じた標本だと仮定できないことが多い。そこで、次にクロスバリデーションで元のデータを学習データと試験データに分割する際に、ある時刻で仮想的な過去と未来に分けるタイムスライスクロスバリデーション手法を構築し有効性を検証した。その結果、将来と過去のデータに異なる傾向があることにより、将来の予測精度を向上させるためには構築手法により将来に対する過適合の抑制が重要	

であるという知見が得られた。それにより将来の予測精度を向上することが出来たが、舗装の劣化の様により不確実性が大きい場合、予測精度に上限があることは明らかである。そのため、予測の誤差を定量化するため、ニューラルネットワーク全般に適用可能であり応用範囲が広い、計算量を抑えて信頼、予測区間を推定する手法を構築し、有効性を確認した。構築手法を用いる事で単一の予測値だけではなく、例えばある水準まで舗装の健全度が悪化するリスクなどを定量化することが可能であることを確認した。それにより単一の予測を行う舗装劣化予測よりも更に舗装維持管理効率化に寄与することが出来る。

構築した手法の実用的な観点からの妥当性をシミュレーションおよびインタビューにより確認した。まず補修費用のシミュレーションを 30 年分を行った結果、補修費用を含むライフサイクルコスト最適化の精度は舗装劣化予測モデルの予測精度に依存することを明らかにした。また、舗装維持管理関連業務に従事する技術者へのインタビューを通して、上述した 3 点の取り組みによる実用的な観点からの有用性を確認できた。

これらのことから、本研究で構築した予測精度の高い舗装劣化予測モデルを活用した予測手法が有効であることを確認し、今後の舗装維持管理効率化に寄与するものであることを示した。

SUMMARY OF DOCTORAL DISSERTATION

Name	Tomoyuki Okuda
Title :	
Deterioration Prediction Method using Recurrent Neural Network for Improvement of Pavement Prediction Accuracy	
Abstract:	
<p>It is possible to improve the efficiency of pavement maintenance by simulating various pavement maintenance measures by the pavement deterioration prediction model and selecting the optimum maintenance plan. However, since deterioration of pavement is highly uncertain since various factors are complicatedly related, it is difficult to predict deterioration with high precision. As a result, the current situation is finally decided by repair construction method, timing and so on by field technicians, and simulation by pavement deterioration prediction model is not sufficiently utilized to improve efficiency of pavement maintenance. The purpose of this research is to construct a prediction method that utilizes prediction model of pavement deterioration with high prediction accuracy and to verify effectiveness in order to contribute to the efficiency improvement of such pavement maintenance. In order to achieve this objective, this study carried out the following three efforts.</p> <p>First, we constructed and verified the pavement deterioration prediction model by the recurrent neural network model which solved difficult problems such as gradient decent problem and over fitting.</p> <p>Specifically, we compare prediction accuracy with conventional multi-layer perceptron and generalized linear model using real data of 1998 to 2015 years in the road surface survey conducted in Kawasaki city. As a result, the constructed method has the highest prediction accuracy in all three road surface survey values of crack rate, rutting depth, and roughness with different distribution and the difference in maximum difference of root mean square error between models is about 20%. However, the structure inspection time series data such as the road surface survey has a long time scale over several decades, unlike sentences, sounds and the like. Therefore, due to changes in criteria, material, inspection method etc. according to ages, it often can not</p>	

assume that past and future data originate from the same population. Then, when dividing the original data into learning data and test data by cross validation, time slice cross validation method which divided into virtual past and future at a certain time was constructed and verified the effectiveness. As a result, in order to improve future prediction accuracy, it was found that it is important to suppress overfitting for the future by constructed method due to different trend in future and past data. Although it was able to improve the prediction accuracy in the future, it is obvious that there is an upper limit on the prediction accuracy when the uncertainty is large like deterioration of pavement. In order to quantify the error of prediction, we constructed and verified a method to estimate the confidence and prediction interval of the neural network model with a small amount of calculation. Since this method is applicable to general neural network model, its application range is wide. Thus, it is possible to quantify not only a single predicted value but also the risk that the condition of pavement deteriorates to a certain level, for example. This makes it possible to contribute to the improvement of pavement maintenance efficiency more than the pavement deterioration prediction that makes a single prediction.

The validity of the constructed method from a more practical viewpoint was confirmed by simulation and interview. As a result of simulation of repair cost for 30 years, it was found that the accuracy of life cycle cost optimization including repair cost depends on prediction accuracy of pavement deterioration prediction model. In addition, through interviews with engineers engaged in pavement maintenance related work, we were able to confirm the utility from a practical point of view by the above three efforts.

From these facts, we confirmed that the prediction method using the prediction model with high prediction accuracy constructed in this research is effective, and showed that it contributes to the improvement of pavement maintenance efficiency in the future.

目次

論文要旨	i
SUMMARY OF DOCTORAL DISSERTATION	iii
目次	v
第1章 序論	1
1.1. 研究背景	2
1.1.1. 日本の公共インフラ維持管理に差し迫る危機	2
1.1.2. 舗装維持管理の効率化	3
1.2. 本研究の目的	10
1.3. 論文の構成	11
第2章 リカレントニューラルネットワークによる舗装劣化予測モデル	13
2.1. 舗装管理の現状	14
2.1.1. 舗装ストックと維持管理費の推移	14
2.1.2. 近年の舗装管理政策と維持管理の現状	16
2.2. 舗装劣化予測モデルの現状	23
2.2.1. 目的による分類	23
2.2.2. 維持管理計画のレベルによる分類	24
2.2.3. モデル化する変化量による違い	26
2.2.4. 数理モデルの種類による分類	26
2.2.5. 情報通信技術とニューラルネットワークモデルの変化	29
2.2.6. 先行事例	37
2.3. リカレントニューラルネットワークによる舗装劣化予測モデル	40
2.3.1. RNN モデルによる時系列データのモデリング	40
2.3.2. GRU モデル	42
2.3.3. RNN に対するドロップアウトの適用	43
2.3.4. ADAM	44
2.4. 手法の検証	45
2.4.1. 路面性状調査	45
2.4.2. 学習及び検証に用いたデータ	49
2.4.3. GLM のモデル選択	52
2.4.4. MLP と RNN のドロップアウト率を調整した学習結果	56
2.4.5. モデル間の予測精度比較	58
2.4.6. RNN によるパフォーマンスカーブ	59
2.5. 小括	64
第3章 舗装劣化予測モデルの将来予測精度評価方法論の構築と検証	65

3.1.	舗装劣化予測モデルの予測精度評価方法.....	66
3.2.	タイムスライスクロスバリデーション手法の提案.....	68
3.2.1.	パフォーマンスモデル.....	68
3.2.2.	従来手法のクロスバリデーションによるハイパパラメータの探索と過学習の 検証	68
3.2.3.	提案手法の必要性.....	71
3.2.4.	提案するクロスバリデーション手法.....	71
3.3.	提案手法の検証.....	73
3.3.1.	検証データ処理.....	73
3.3.2.	外れ値の除去.....	74
3.3.3.	従来手法との比較による検証.....	74
3.4.	小括.....	79
第4章	リカレントニューラルネットワークモデルの信頼区間と予測区間推定.....	80
4.1.	舗装点検データの外れ値検出手法.....	81
4.1.1.	外れ値と箱ひげ図.....	82
4.1.2.	Tukey g and h 分布を用いた外れ値検出方法.....	83
4.2.	信頼区間と予測区間.....	87
4.3.	NN モデルの信頼区間と予測区間の推定手法.....	88
4.4.	スナップショットブートストラップによる予測区間推定手法.....	90
4.4.1.	関連する NN モデル学習手法.....	90
4.4.2.	提案アルゴリズム.....	92
4.5.	適用事例.....	96
4.5.1.	RNN モデルによる時系列予測.....	96
4.5.2.	RNN のハイパパラメータ探索.....	97
4.5.3.	比較手法.....	97
4.5.4.	追加エポック数の検討.....	98
4.5.5.	検証に用いたデータ.....	99
4.6.	検証結果.....	101
4.6.1.	学習時間の比較.....	101
4.6.2.	予測区間の推定精度.....	101
4.6.3.	信頼区間と予測区間の推定結果.....	103
4.7.	小括.....	107
第5章	シミュレーションとインタビューによる実用的な視点からの妥当性確認.....	108
5.1.	補修費用のシミュレーション.....	109
5.2.	舗装維持管理技術者へのインタビュー.....	112
5.2.1.	インタビュー方法.....	112

5.2.2. インタビュー結果.....	112
5.3. 小括	116
第6章 考察	117
6.1. 他地域への適用可能性.....	118
6.2. 舗装劣化予測モデル以外の応用可能性.....	119
6.3. わだち掘れ量予測誤差要因の分析.....	122
6.4. データの密度や可用性に関する舗装維持管理業務への示唆.....	123
6.5. 本研究の特徴.....	125
6.6. 今後の課題	126
第7章 結論	127
Appendix A.....	130
参考文献	137
研究業績	144
謝辞	145

図表目次

表 2-1 舗装維持管理に関する近年の主要な法令改正	18
表 2-2 舗装の分類 ⁸⁾	19
表 2-3 道路種別ごとの維持管理の状況整理	21
表 2-4 NN モデルの主要な変化.....	31
表 2-5 ひび割れ率, わだち掘れ量, 平坦性の相互相関係数.....	49
表 2-6 使用した説明変数.....	50
表 2-7 各路面性状値の標準偏差.....	51
表 2-8 各路面性状値と確率密度関数ごとの AIC(太字は AIC 最小の分布).....	53
表 2-9 GLM の AIC 最小モデルで選択された変数.....	55
表 2-10 各モデルのハイパパラメータの設定値.....	58
表 2-11 各モデルの検証データに対する RMSE の比較.....	58
表 3-1 入力データ項目	73
表 3-2 モデルのハイパパラメータ	76
表 4-1 ハイパパラメータの一覧.....	97
表 4-2 説明変数.....	100
表 4-3 各手法の PICP.....	102
表 A-1 質問項目	130
表 A-2 インタビュー対象者 A の回答.....	131
表 A-3 インタビュー対象者 B の回答.....	133
表 A-4 インタビュー対象者 C の回答.....	135
図 1-1 様々な公共インフラと舗装(第 6 回メンテナンス戦略小委員会配布資料 ⁴⁾ を参考に著者作成).....	3
図 1-2 国の歳出と長期債務残高の推移(国土交通白書 2014 ¹⁾).....	3
図 1-3 舗装維持管理フロー	4
図 1-4 ライフサイクルコストに含まれる項目(舗装工学の基礎 ⁷⁾ p.256 図 7.5 より著者作成).....	5
図 1-5 舗装の層構造	5
図 1-6 予防保全の効果イメージ(国土交通白書 2011 ⁹⁾).....	6
図 1-7 ライフサイクルコストのトレードオフ	7
図 1-8 舗装劣化の不確実な要因	8
図 1-9 過大評価, 過小評価のイメージ	8
図 1-10 本研究の構成	12
図 2-1 舗装のストックと維持修繕費の推移 ¹⁸⁾	15

図 2-2 日本の道路種別と延長割合(道路統計年報 2017 ⁵⁾ を元に著者作成).....	15
図 2-3 市町村における土木部門職員数の推移 ¹⁹⁾	16
図 2-4 市町村における土木費の推移 ¹⁹⁾	16
図 2-5 管理瑕疵件数と意見・要望件数 ²⁰⁾	17
図 2-6 舗装維持管理のフロー ⁸⁾	20
図 2-7 パフォーマンスモデルと予測モデルの視点.....	23
図 2-8 クロスバリデーションのイメージ.....	24
図 2-9 有限要素法による舗装の変形 ³⁷⁾	27
図 2-10 離散化した健全度(condition state)の推移 ⁵⁰⁾	28
図 2-11 現状と将来の公共インフラ維持管理.....	30
図 2-12 神経細胞をモデル化したニューロン.....	32
図 2-13 MLP モデル.....	32
図 2-14 順伝播と逆伝播計算.....	33
図 2-15 シグモイド関数と正規化線形関数.....	35
図 2-16 ドロップアウトの概念図.....	36
図 2-17 表現力の例.....	37
図 2-18 重原ら ⁵¹⁾ の MLP モデル.....	38
図 2-19 Tabatabaee ら ⁵³⁾ の RNN モデルを用いた舗装劣化予測.....	38
図 2-20 RNN モデル.....	41
図 2-21 LSTM と GRU モデル ⁷⁰⁾	42
図 2-22 GRU モデル.....	42
図 2-23 予測精度の検証の流れ.....	45
図 2-24 路面性状の自動測定装置の例.....	46
図 2-25 ひび割れ率の求め方.....	47
図 2-26 舗装の横断形状図.....	48
図 2-27 平坦性測定センサの配置.....	49
図 2-28 各路面性状値の分布.....	53
図 2-29 わだち掘れ量 RNN モデルのエポックごとの MSE.....	56
図 2-30 各モデルのドロップアウト率ごとの MSE.....	57
図 2-31 路面性状値の平均値の予測.....	60
図 3-1 RNN モデルのハイパパラメータ決定フロー.....	69
図 3-2 過学習とハイバイアスの検知.....	70
図 3-3 従来手法と比較するためのデータ分割.....	75
図 3-4 D_{PT} に対する予測年数ごとの RMSE.....	77
図 3-5 D_{FT} に対する予測年数ごとの RMSE.....	77
図 3-6 D_V に対する予測年数ごとの RMSE.....	77

図 4-1 箱ひげ図.....	82
図 4-2 Tukey g and h 分布による代表的な指数分布の近似 ⁸¹⁾	83
図 4-3 アニーリングによる局所最適解の移動.....	90
図 4-4 Dynamic Evaluation の追加学習.....	91
図 4-5 スナップショットアンサンブルと提案手法の学習曲線の例.....	91
図 4-6 信頼区間と予測区間推定フロー.....	93
図 4-7 時系列情報の例.....	96
図 4-8 PICP80%の例.....	98
図 4-9 Annealing と Proposed の学習曲線.....	99
図 4-10 結合荷重パラメータ間のユークリッド距離比較.....	102
図 4-11 補修が無い区間.....	104
図 4-12 補修がある区間.....	104
図 4-13 補修の可能性のある区間.....	104
図 4-14 わだち掘れ量が大い区間.....	106
図 5-1 ひび割れ率のプロジェクトレベルシミュレーション結果例.....	109
図 5-2 ネットワークレベル累積補修費用シミュレーション結果例.....	110
図 5-3 舗装劣化予測モデルの必要性.....	113
図 6-1 トラヒックの推移(左:ブロードバンド, 右:移動体通信) ⁵⁵⁾	120

1

第1章 序論

* * * * *

まず日本における長期的な課題として、社会資本ストックの老朽化、維持管理予算の削減、自治体職員数の減少により、公共インフラの維持管理が年々困難になりつつある背景を説明する。その後、公共インフラの中でも寿命が短いため維持管理施策の頻度も高く、データの蓄積もされている舗装に注目し、舗装維持管理の現状と課題を分析する。次に、舗装維持管理を最適化するためには舗装劣化予測モデルが不可欠である事を説明し、本研究の目的を導く。

* * * * *

1.1. 研究背景

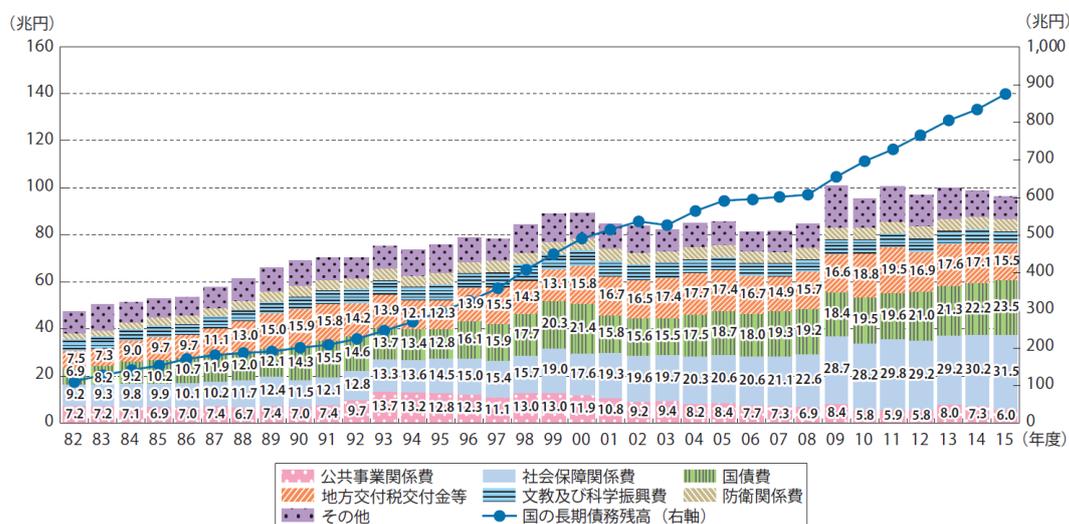
1.1.1. 日本の公共インフラ維持管理に差し迫る危機

日本の公共インフラは1960年代の高度成長期に急ピッチに進められたため、老朽化が進行している¹⁾。公共インフラの老朽化が深刻化している事を考えれば、維持管理予算を増額し、点検、補修、更新や新技術の開発を促進する必要がある。しかし、国土交通省社会資本整備審議会によると、直轄道路における新設、維持管理費用を含めた道路事業費は平成16年から平成25年までの間に約3割減少、そのうち維持管理費のみでは約2割減少している²⁾。この原因は、日本の人口減少、経済成長の停滞と密接に関係している。国勢調査及び国立社会保障・人口問題研究所によると、日本の総人口は2008年をピークに人口減少が加速し、近年の経済成長は0~2%程度であり、GDPの増加が鈍化している³⁾。それらに伴い、図1-2の国の歳出と長期債務残高の推移が示すように、社会保障費が大幅に増加する一方でGDPは増加しないため、長期債務が急増しており、維持管理費に予算を割くことが出来ない現状がある。従って、公共インフラの老朽化が深刻化すると同時に、高齢化及び人口減少が加速しているため、維持管理の効率化が非常に重要である。

図1-1の様に多様な公共インフラ⁴⁾の中で、舗装は最も基本的な公共インフラであり、ストック量(維持管理している資産量)が1,278,183.5kmと膨大で⁵⁾、あらゆる市民生活、産業活動に不可欠であり、被災時のライフラインとしても重要である。設計寿命が20年程度と他の公共インフラと比較し寿命が短く、点検や補修、更新も高頻度であるため、維持管理を効率化する事による効果が高い。また、インフラ長寿命化計画(行動計画)⁶⁾等で、インフラの属性、点検データのデータベース化が推進されている。しかし、現状多くの公共インフラで十分なデータの蓄積が無い中、舗装は既に1970年代に開始された路面性状調査により長期的な定量調査データが存在するため、データを用いた維持管理の効率化の適用事例として適する。



図 1-1 様々な公共インフラと舗装(第 6 回メンテナンス戦略小委員会配布資料⁴⁾を参考に著者作成)



(注) 歳出について、2014年までは決算額、2015年は当初予算額。
資料) 財務省「財政関係基礎データ(2016年4月)」、「財政統計」より国土交通省作成

図 1-2 国の歳出と長期債務残高の推移(国土交通白書 2014¹⁾)

1.1.2. 舗装維持管理の効率化

先述のような日本の現状から、公共インフラの維持管理を強化するために、2010年頃から関連する法令や舗装点検要領等が順次改正、策定されている。それらの法令で最も具体的な維持管理策を策定する舗装点検要領においても、点検結果からその都度維持管理施策を判断する対処療法的な維持管理となっている。また、点検方法、補修方法等の具体的な施策は多くが各舗装管理者に委ねられているため、各管理者独自の判断で維持管理を行っていく必要があり、効率化が容易ではない。

舗装管理者の維持管理業務の流れを図 1-3 に示す。

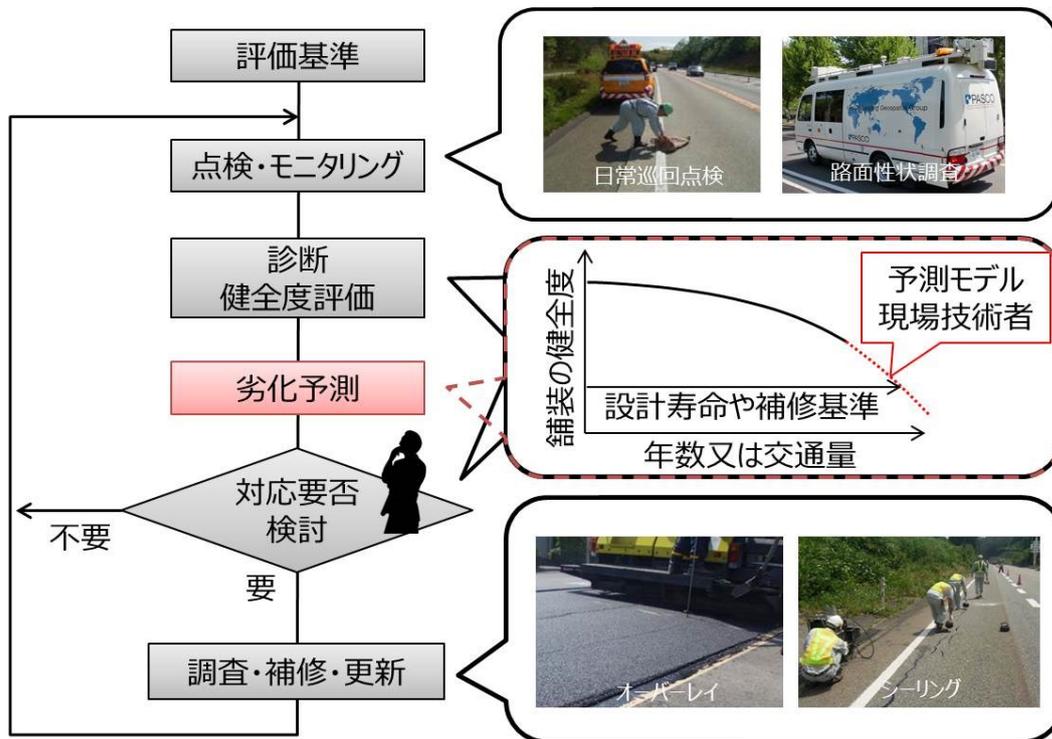


図 1-3 舗装維持管理フロー

最初に、国や地方自治体等の管理者ごとに評価基準を規定する。舗装の維持管理方針については、各管理主体が舗装維持管理計画や舗装長寿命化基本計画等の名称で公開している事も多い。それらの基準は次章で整理する近年の法令改正により、多くの舗装管理主体で近年更新されている。次に、それらの基準に則り点検、モニタリングを行い、舗装維持管理計画立案のための基礎データを収集し、その結果から現在の舗装の健全度を評価する。そして、それまで蓄積された過去のデータから、劣化予測モデル及び現場の技術者によって将来の健全度変化を予測し、劣化速度が特に早い箇所はより詳細な調査を行う事や、舗装を路盤から作り直す打ち替えを行う等の維持管理効率化に資する対応を計画、実施する。このような舗装維持管理の流れを効率化するという事は、舗装の状態を一定以上の水準に維持しつつ、ライフサイクルコストを最適化する事である。ライフサイクルコストとは、舗装の新設から維持管理していくために必要な全てのコストの総和の事である⁷⁾。ライフサイクルコストに含まれる項目を図 1-4 に示す。

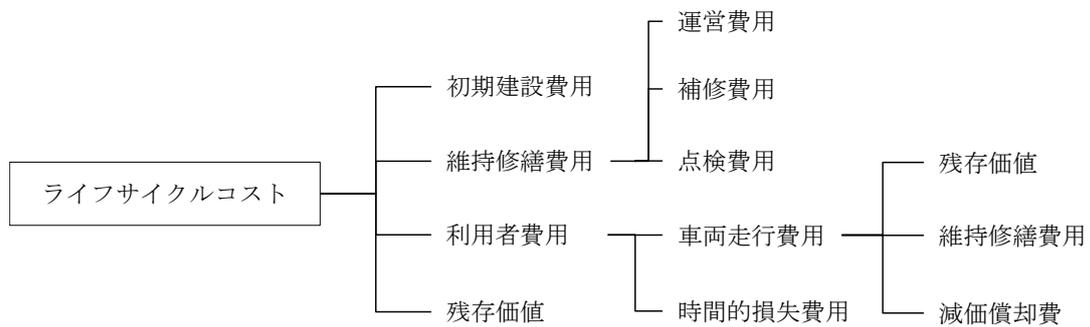


図 1-4 ライフサイクルコストに含まれる項目(舗装工学の基礎⁷⁾p.256 図 7.5 より著者作成)

例えば、予防保全(長寿命化)による補修費用の削減がある。舗装の場合、損傷が図 1-5 に示す表層側から進行して路盤まで損傷した場合、舗装を基層以下から作り直す必要があるため、補修コストは表層だけを補修する場合と比較し 3 倍程必要である⁸⁾。従って、舗装の破壊が深刻化する前に補修を行う予防保全を行う事で、機能不全に陥るまで損傷が進行してから対策を行う対処療法的な維持管理よりも長寿命化する事が可能になる⁹⁾。それにより、点検や補修コストが多少増加しても、図 1-6 に示すように長期的に見てライフサイクルを削減する事が可能である。



図 1-5 舗装の層構造

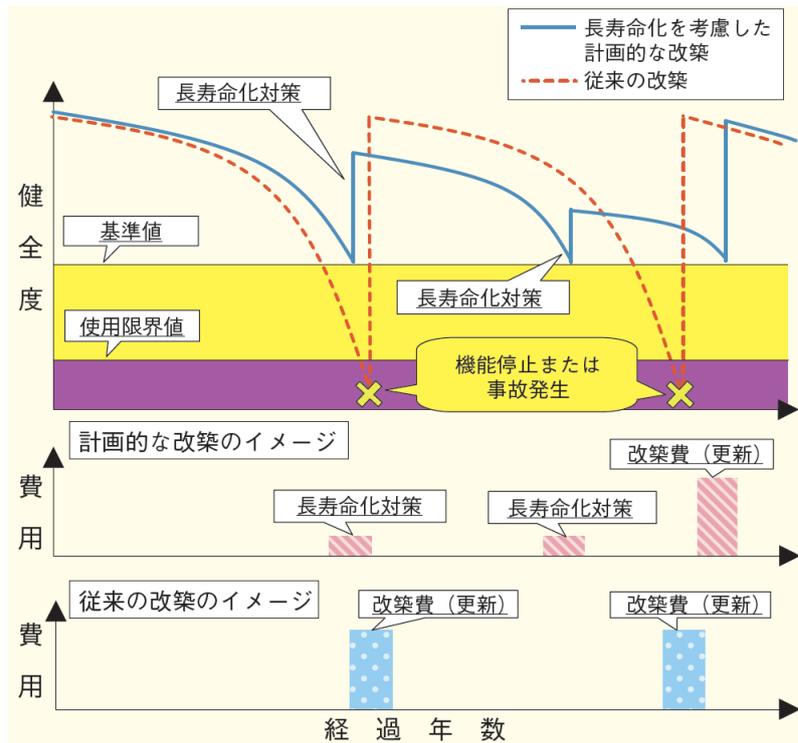


図 1-6 予防保全の効果イメージ(国土交通白書 2011⁹⁾)

一方で、長寿命化のために補修を必要以上に行うと、長寿命化によるコスト削減効果よりも補修費用の方が大きくなってしまふ可能性がある。他方で、必要以上の補修を行わないために、詳細な点検を頻度高く行うと、今度は点検コストの方が高くなる可能性がある。このように各種費用間には様々なトレードオフの関係が存在する(図 1-7)。

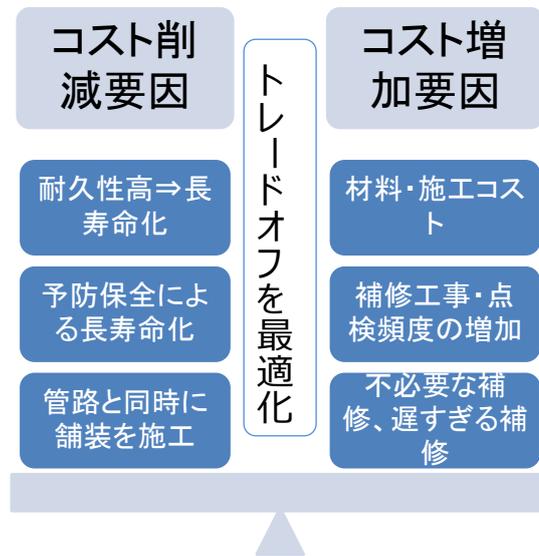


図 1-7 ライフサイクルコストのトレードオフ

ライフサイクルコストに含まれる各費用の算出は、舗装の健全度が完全に予測可能であれば、それぞれの費用は現在までに多くの実績があるため困難ではない。その費用の算出結果から、動的計画法(又はナップザック問題)^{10),11),12)}や、GA(Genetic Algorithm)^{13),14)}などの最適化手法を用いることでトレードオフを最適化する事が可能である。

しかし、問題は補修費用、利用者費用等は舗装の健全度に依存している点である。舗装の健全度に含まれる誤差が補修費用に与える影響について調べた Saliminejad ら¹⁵⁾によると、実データに含まれる誤差と同程度の正規分布に従う乱数を加えると、補修費の試算は 80%もの違いが発生する事を報告している。現実的には明らかに舗装の健全度を完全に予測する事は困難であるため、ライフサイクルコスト最適化の精度は舗装の健全度の推定精度、つまり劣化予測の精度に依存している。

しかし、施工後の舗装の劣化プロセスは非常に不確実性が高いため、舗装の健全度を精度高く予測する事は難しい。舗装の劣化プロセスの不確実性の例として、例えば図 1-8 に示すように環境条件の複雑さがある。素材、土質、地下埋設物等の各舗装区間に固有の属性や、職人による締固め等施工の質、地下水、日当たりや交通状況等の環境条件は、単位区間ごとに異なり、時間と共に変化する事がある。その様な要因が複雑に関係する事で、舗装劣化の不確実性(ばらつき)が大きい¹⁶⁾。また、それらの属性情報、環境条件や、舗装の健全度の調査を高精度、高頻度に、舗装の総延長 1,278,183.5km⁵⁾について行う事は予算制約の面から現実的ではない。更に、舗装の健全度に大きな影響を与える上下水道管等の各管路や送電線など舗装下設備の掘削、復旧工事や、苦情対応による小規模な補修工事等が行われる事があるが、それらの情報が整備されて利用可能である事は稀である。



図 1-8 舗装劣化の不確実な要因

もし舗装劣化予測の精度が低い場合、図 1-9 に示した様に真の舗装の健全度と劣化予測が乖離する事になる。観測誤差が無いと考えた時に得られる観測値を真の舗装健全度とすると、真の舗装健全度と乖離した精度の低い劣化予測を元に維持管理計画を立案した場合は、必要以上に補修を行うことで補修費用の増大、舗装の健全度が予測以上に悪化していることによる利用者費用が増大するなど、維持管理最適化の精度も低くなる。その結果、予防保全よりも事後取替のみ行う場合の方がライフサイクルコストは低いという可能性もある事になる。

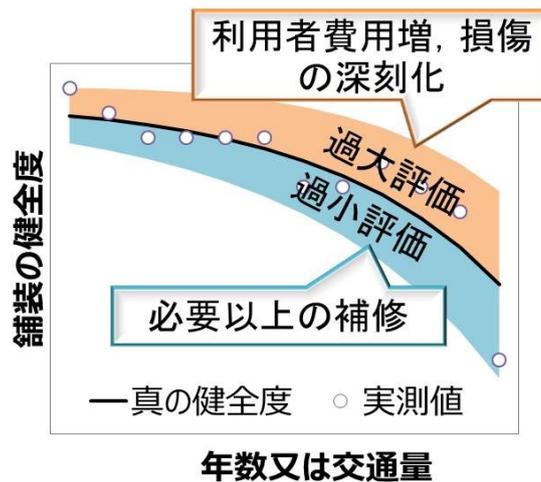


図 1-9 過大評価, 過小評価のイメージ

以上から、ライフサイクルコスト試算に用いる劣化予測モデルの予測精度向上及び、その予測精度を正確に評価する事が重要である。もし劣化予測の精度が高く、その評価が正

確であれば、3～5年に1度程度の定期点検間の健全度変化を補完し、日常巡視又は定期点検により現状確認の工数を削減、最適な補修タイミングや、補修工法の選定が可能になる。また、纏めて何区間か補修を行う事による補修単価低下効果や、管路と同時に舗装の補修を行う¹⁷⁾などのより広い視点からの効率化も可能になる。

1.2. 本研究の目的

前述の通り，日本における公共インフラ維持管理は危機が迫っており，維持管理の効率化が求められている．舗装維持管理効率化のためには，劣化予測モデルを用いて様々な維持管理方策についてシミュレーションを行い，その中から最適な点検，補修，更新等の対策とそのタイミングを決める事が有効である．

そのような舗装維持管理の効率化に貢献するため，本研究の目的は予測精度を向上した舗装劣化予測モデルを構築，検証することとした．

1.3. 論文の構成

ここまで 1 章では日本の現状から公共インフラの維持管理が問題になっている事を明らかにし、その中で舗装維持管理を効率化するための方策について論じ、本研究の目的を導いた。最後に本節で本研究の構成を述べる。

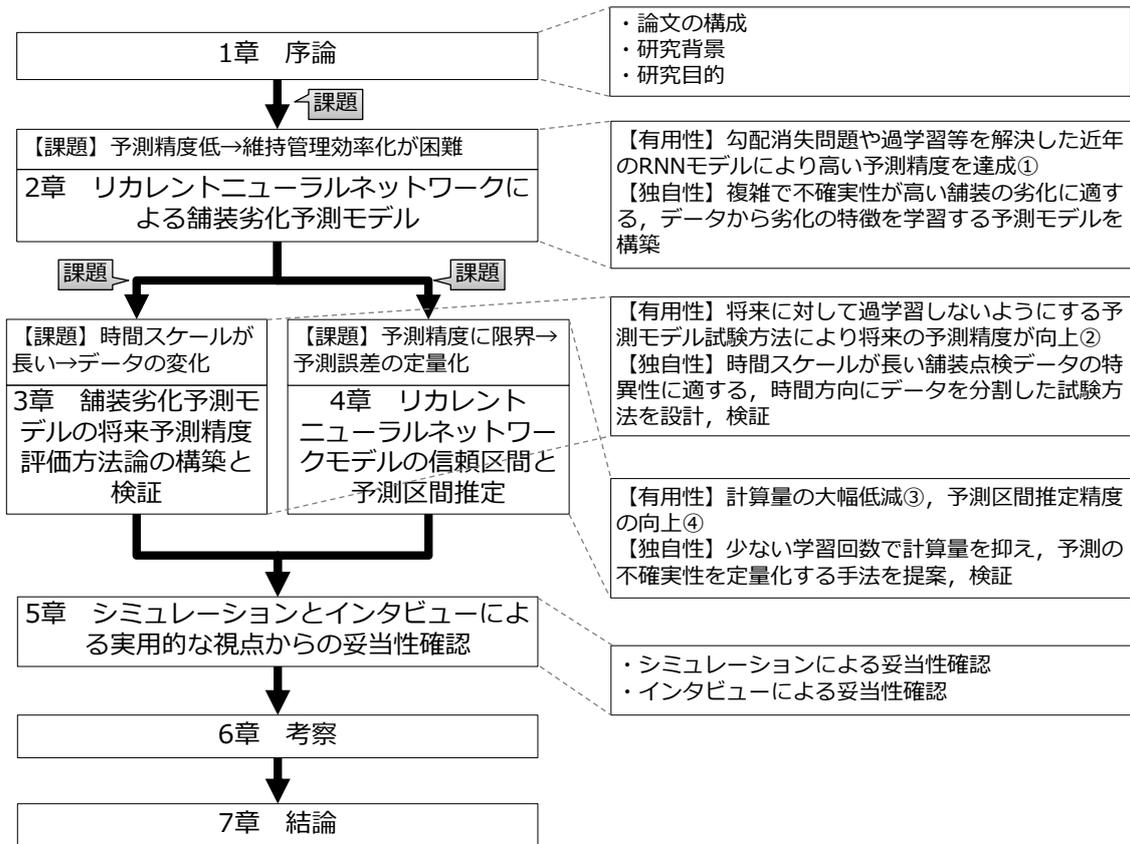
2 章では、舗装維持管理及び舗装劣化モデルの現状について整理し、時系列データであり、不確実性が高い舗装劣化予測に適した、リカレントニューラルネットワーク(RNN)による舗装劣化予測モデルを構築する。結果として重回帰モデルや通常のニューラルネットワーク(NN)モデルと比較し、RNN の予測精度が高くなる事を示す。

3 章では 2 章から明らかになった課題の 1 つを扱うための方法論を構築する。その課題は、舗装などの公共インフラは寿命が長い為、素材や工法、点検等の方法や基準が変化する事である。それによって、予測対象である将来のデータが現在までと同じ母集団から生じた標本と仮定する事は現実的ではない。その様な寿命が長い公共インフラに対する将来予測のより現実的な試験方法を論じる。

4 章は、2 章から明らかになった課題の 1 つである予測精度に限界がある事に対応するために、NN モデルの信頼、予測区間推定手法を構築する。ブートストラップ法を効率的に NN モデルへ適用する事で計算量を抑え、NN モデルの予測区間を推定する手法を提案する。

5 章ではそれまでに構築した手法についてより実用的な視点からの妥当性確認をシミュレーション及びインタビューにより行う。最初に補修費用が劣化予測モデルの予測精度に大きく依存する事から、ライフサイクルコスト試算と維持管理計画の精度も舗装劣化予測モデルの予測精度に大きく依存する事を示す。次に舗装維持管理業務に長年の経験がある技術者へのインタビューを通して、構築した手法の実用的な有効性を確認する。

6 章で本研究全体を通しての考察及び今後の課題、7 章で結論を論じる。



論文対応箇所

本文	査読論文
① 2.3節	舗装維持管理効率化のためのニューラルネットワークモデルによる路面性状値予測手法の提案と定量的評価：土木学会論文集F3 (土木情報学), Vol.74, No.1, pp.33-48, 2018
② 3.3節	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：舗装工学論文集E1(舗装工学) Vol.73, No.3, pp.229-236, 2017
③ 4.5.1項	ニューラルネットワークを用いたわだち掘れ深さ予測の信頼区間と予測区間推定手法：土木学会論文集F3 (土木情報学), Vol.73, No.2, pp.317-326, 2018
④ 4.5.2項	Tomoyuki Okuda, Kouyu Suzuki, Naohiko Kohtake : Non-parametric Prediction Interval Estimate for Uncertainty Quantification of the Prediction of Road Pavement Deterioration, IEEE ITSC2018 (発表決定済み)

図 1-10 本研究の構成

2

第2章 リカレントニューラルネットワークによる舗装劣化予測モデル

* * * * *

本章では、リカレントニューラルネットワークを用いた舗装劣化予測モデルを提案し、多層パーセプトロン、一般化線形モデルと予測精度の比較を行った。その結果、リカレントニューラルネットワークの予測精度が最も高い事が明らかになった。また、一般化線形モデル等の従来の統計モデルは用いるデータに対して事前にモデルを設計する必要があるのに対し、リカレントニューラルネットワークは異なる分布に属するひび割れ率、わだち掘れ量、平坦性からなる路面性状値の3要素を同じ構造のモデルで学習できることが解った。

* * * * *

この章では、舗装の単位区間ごとに予測可能なモデルとして、RNN モデルと MLP モデル、一般化線形モデル(Generalized Linear Model)の比較を通して RNN の優位性を確認する。また、実際の川崎市の幹線道路を対象とした路面性状調査により得られたデータを用いて提案モデルを検証し、舗装劣化予測に対する適性と課題を論じる。

2.1. 舗装管理の現状

本節では、舗装維持管理、舗装劣化予測モデルに関する先行研究の現状と課題について網羅的に整理し、現状の舗装維持管理に舗装劣化予測を用いた最適化が活かされていない事を示す。

2.1.1. 舗装ストックと維持管理費の推移

図 2-1 に舗装のストックと舗装維持修繕費の推移¹⁸⁾を示す。図から明らかなように、近年舗装のストック量の増加速度は低下しているものの、舗装維持修繕費は減少又は横ばいであり、維持管理の効率化が急務となっている。

次に、日本の道路の区分とその延長割合を図 2-2 に示す。合計約 122 万 km にも及ぶ延長のうち、80%以上は市町村が管理する市町村道である⁵⁾。図 2-3 に示した市町村における土木部門職員数と職員数の推移¹⁹⁾によると、職員数全体より土木部門職員数の減少率が高いことが解る。また、図 2-4 に示したように市町村における土木費¹⁹⁾は減少し続けている。規模の小さい市町村は予算、人材の確保が国よりも困難であるため、維持管理が困難であることが解る。

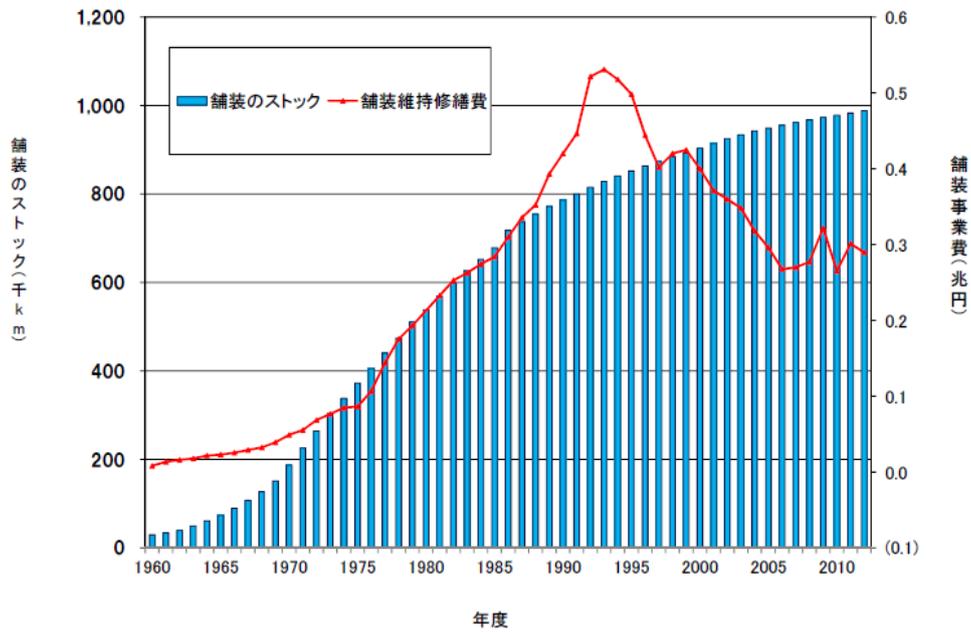


図 2-1 舗装のストックと維持修繕費の推移¹⁸⁾

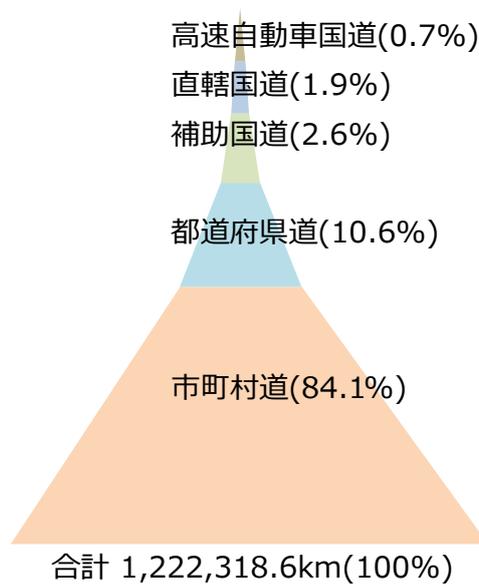


図 2-2 日本の道路種別と延長割合(道路統計年報 2017⁵⁾を元に著者作成)

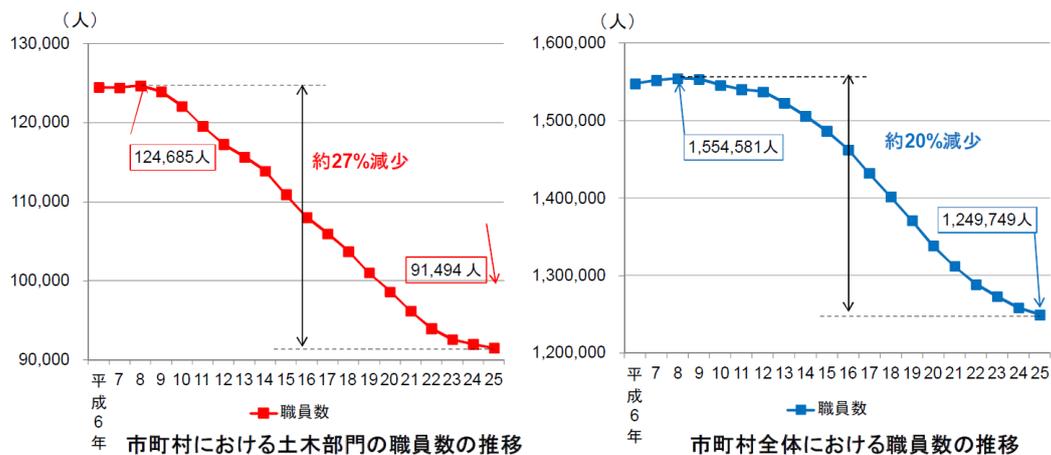


図 2-3 市町村における土木部門職員数の推移¹⁹⁾

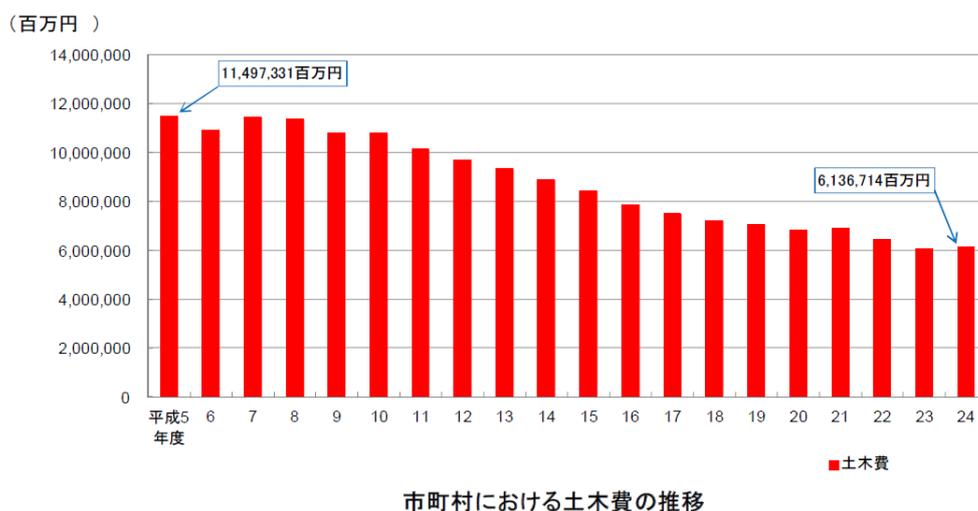


図 2-4 市町村における土木費の推移¹⁹⁾

この様に年々予算、人的資源による制約が厳しさを増しているのが現状であり、将来的にもその様な状況が急激に改善する事は考えにくい状態である。

2.1.2. 近年の舗装管理政策と維持管理の現状

先述の通り、日本の公共インフラ維持管理は困難な状況に置かれており、国政として維持管理水準を出来るだけ落とさずに効率化し、コスト削減するための対策を強化している。国道においてはその他の道路に先んじて維持管理効率化の試みが行われたきた。平成22年の「直轄国道の維持管理基準（案）」制定により、全国統一の維持管理基準が定められた。それまでは原則1日に1回の日常巡視を行っていたが、コスト削減のため平成22年は原則2日に1回に頻度が減少した結果、図2-5に示すように管理瑕疵件数や意見・要望件数が急

増した²⁰⁾。そのため、平成 25 年度からは交通量に応じて 1~3 日/回と変更された。これから解る事は、コスト削減のため単純に点検回数を減少させると、舗装管理者の管理責任が問われた瑕疵件数の増加リスクが増加するトレードオフの関係がある。従って、その様な施策によるトレードオフが本当に効率化に役立つのかをライフサイクルコストの試算を通して検討する必要がある事を表している。

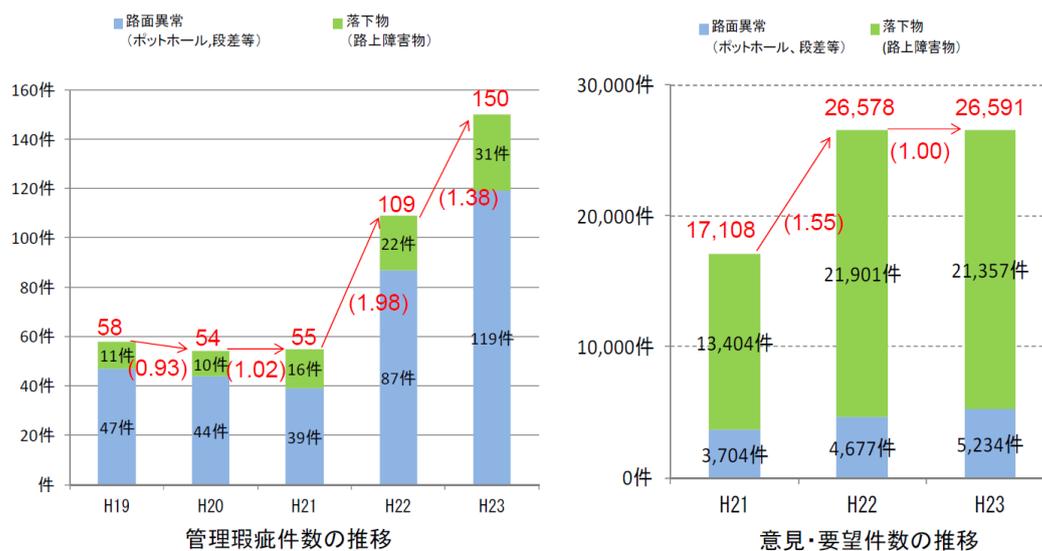


図 2-5 管理瑕疵件数と意見・要望件数²⁰⁾

また、公共インフラの維持管理の重要性が大きく注目されるきっかけとなった事件として、笹子トンネル天井版落下事故がある。平成 24 年 12 月 2 日中央自動車道上り線笹子トンネルで天井版が落下し、走行中の車を巻き込み 9 名の死亡者を出した。この事件を受け、利用者及び第三者被害防止の観点から平成 25 年 2 月より道路ストックの総点検が実施された。それにより、主に幹線道路の道路橋、トンネル、舗装、道路附属物(標識、証明、情報提供装置、横断歩道橋等)、法面、盛土、擁壁について緊急的に点検を行い、点検結果から管理主体ごとに緊急度の高い箇所の通行止めや補修を実施している。笹子トンネル天井版崩落事故以降の舗装に関連する主要な法令改正を表 2-1 に示す。

表 2-1 舗装維持管理に関する近年の主要な法令改正

年月	出来事	特徴
2012年12月	笹子トンネル崩落事故	
2013年2月	道路ストック総点検	事故を受けた緊急点検
2013年9月	道路法一部改正施行	点検の法定化
2014年7月	道路法施行規則一部改正施行	5年おきの近接目視点検義務化
2016年10月	舗装点検要領公開	分類ごとに管理

それに続き、平成25年9月2日施行の道路法一部改正において、地方道のうち大規模かつ複雑な構造物を国土交通大臣が地方公共団体が変わって改築、修繕できるようになるなど、道路ストックの8割以上を管理する地方の負担軽減や、道路に過大な負荷を与える重量制限違反車両の対策強化、予防保全の観点から道路点検を行うべきことを明確化する事等を定めている。

後者の平成26年7月1日施行「道路法施行規則の一部を改正する省令」により、基本的に近接目視点検を5年に1回行うことや、健全度を4段階で診断する事等、メンテナンスサイクルを確立するための方法や頻度が定められた。ここまでの法令では全ての道路構造物共通の法令として制定されている。それを元に、より具体的な各構造物の特性に応じた具体的な点検方法等については、構造物ごとの定期点検要領にて定めている。

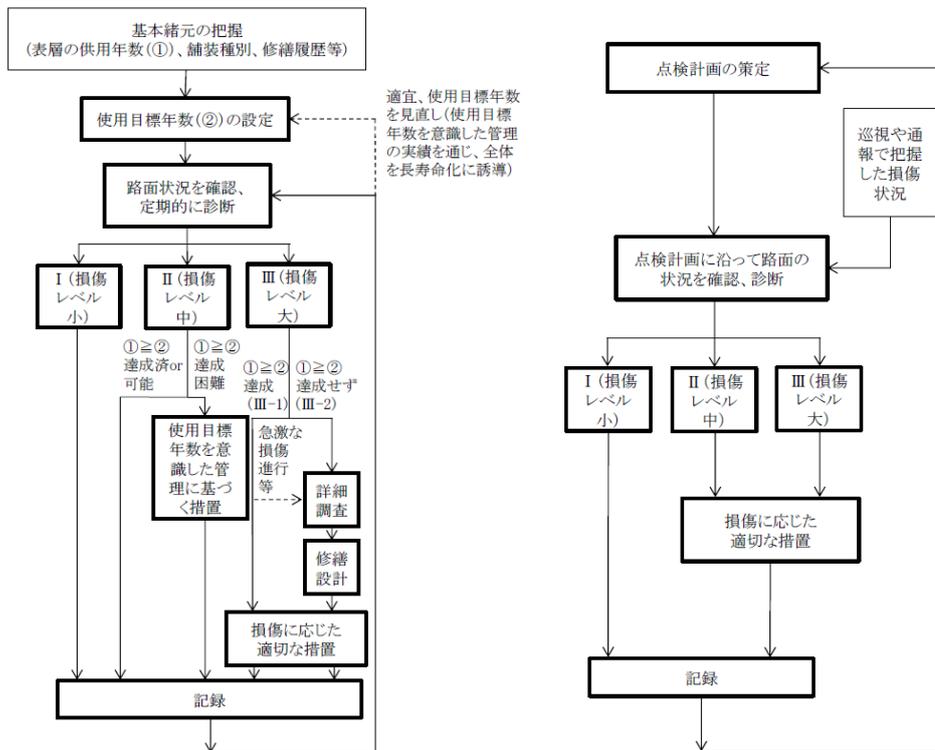
舗装の定期点検要領⁸⁾は平成28年10月に策定された。舗装の劣化速度は場所により大きな差があるため、表2-2に示すように道路を分類A～Dの4つに分類し、それぞれ要領に定められた方針で管理する事が定められた。実際にどの路線をA～Dに分類するかといった事や、点検方法、補修方法、日常巡視等の具体的な施策は各管理者に委ねられている。

表 2-2 舗装の分類⁸⁾

特性	分類	主な道路※2 (イメージ)	マネジメントのあり方
・高規格幹線道路 等 (高速走行など求められるサービス水準が高い道路)	A	高速道路	・表層等の適時修繕による路盤以下の層の保護を目的に、点検を実施 ・走行性、快適性を重視した路面管理の実施
・損傷の進行が早い道路 等 (例えば、大型車交通量が多い道路)	B	直轄国道 補助国道・県道	・表層等の適時修繕による路盤以下の層の保護を目的に、点検を実施 ・修繕サイクルを長くしていくため、早期劣化箇所の原因把握と適切な措置※3 や、使用目標年数を意識した管理の実施 ・走行性、快適性を考慮した路面管理の実施
・損傷の進行が 緩やかな道路 等 (例えば、大型車交通量が少ない道路)	C	政令市・一般市道	・基本的に長寿命であることから、各道路管理者が点検サイクルを定めて適切に管理
・生活道路 等 (損傷の進行が極めて遅く占用工事等の影響が無ければ長寿命)	D	市町村道	・巡視の機会を通じた路面管理

舗装点検要領の損傷の進行が早い道路(分類 A,B)及び損傷の進行が緩やかな道路(分類 C,D)ごとの維持管理フローを図 2-6 に示す。

図によると、2つのフローの基本的な流れは同じであるものの、分類 A,B は定期的な点検や、場合により詳細な調査の実施が決められているが、分類 C,D はそれらの点検、調査を実施するかしないか等も各管理者の判断に委ねている。またこれから解る事は、基本的には管理単位区間ごとに点検した結果により舗装の状態を診断し、それに応じて対策を行う対処療法的な維持管理である。



(a) 損傷の進行が速い道路(分類 A,B) (b) 損傷の進行が緩やかな道路(分類 C,D)

図 2-6 舗装維持管理のフロー⁸⁾

上記の道路法や舗装点検要領を元にして、各道路管理者が自身の管理する道路に対する維持管理計画を策定する。舗装点検要領⁸⁾やNEXCOの点検実施基準及び資格に関する検討委員会報告書²¹⁾、国土交通省 国道(国管理)の維持管理等に関する検討会²⁰⁾、第20回メンテナンス戦略小委員会²²⁾、NEXCO総研の設計要領第一集(舗装編)²³⁾等の資料から、各管理者の定期点検、日常巡視の頻度と、目標とされている管理水準を表2-3に整理した。ここで日常巡視は管理者が車上から目視し、場合によりその場で応急処置を行う様な点検の事で、定期点検はそれよりも詳細に近接目視又はそれに準じる路面性状測定車等で点検を行う事である。また、管理水準はそれ以上の健全度で舗装を維持するという目標値の事である。

表 2-3 道路種別ごとの維持管理の状況整理

道路種別	管理者	定期点検頻度	日常巡視頻度	管理水準(修繕水準)
高速自動車道	高速道路会社, 国	2~5年/回 ²¹⁾	交通量に応じ 2日~3.5/回 ²¹⁾	ひび割れ:20% わだち掘れ:25mm IRI:3.5mm/m ²³⁾
直轄国道	国	5年/回 ⁸⁾	交通量に応じ 1~3日/回 ²⁰⁾	ひび割れ:40% わだち掘れ:40mm IRI:8mm/m ⁸⁾
補助国道, 都道府県道	都道府県	分類 B:5年/回 ⁸⁾ 分類 C,D:管理者設定(5~10年/回)	管理者設定(毎日~なし) ²²⁾	ひび割れ率:20~40% わだち掘れ量:20~40mm IRI:8mm/m ⁸⁾
市町村道	市町村	管理者設定(5年~なし)	管理者設定(毎日~なし) ²²⁾	ひび割れ率:20~40% わだち掘れ量:20~40mm

舗装の維持管理はこの基準に基づき点検を行い、管理水準を上回る箇所を優先的に補修する事を基本として維持管理を実施する。舗装定期点検要領の分類 D に相当する市町村道では、定期点検を行わず、日常巡視のみで対応する事も多い。また、補修の優先順位や補修工法等は管理水準だけで決定する訳ではなく、大型車交通量、路線の重要度や現場技術者の意見、舗装の耐荷力を評価する FWD 試験等による詳細な調査、住民の苦情等を総合的に判断する。

舗装の点検要領 p.8 で言及されているように、路盤以下に損傷が発生した場合、路盤の再生を伴う舗装の打ち替えをする必要がある。その場合、表層だけを再生する切削オーバーレイと比較し費用は 3 倍、時間は 4 倍必要になる。従って、路盤以下に損傷が発生した場合を事後取替と考え、破壊が深刻化する前に補修する事前取替により、予防保全による舗装の維持管理効率化が可能である。路盤以下が損傷する原因の 1 つはひび割れからの舗装内部への浸水であり、それを防ぐためには表層のひび割れを早期に補修する必要がある。そのため、舗装点検要領では分類 A,B については使用目標年数を設定し、表層のひび割れ等の損傷が見つかった際には使用目標年数を超える期間の供用が可能なように適宜修繕を行うという方針が定められている。

その一方で、A~D の道路の分類や具体的な点検や診断、補修の方法や頻度等の維持管理実施は各舗装管理者に委ねられているため柔軟性が非常に大きく、各管理者の維持管理計画をそれらの法令や要領のみから効率化する事は容易ではない。そのため、舗装の予防保

全を実現するためには、点検から得られたデータから各管理者の意思決定を支援する仕組みが必要である。

しかし、例えば、岐阜県、新潟県、京都市、熊本県等が web 上で公開している舗装維持管理計画では、路面性状値や路線の重要度、苦情等を総合的に考慮するが、補修工法や時期などの決定は最終的に技術者の判断によって決定する事が記載されている。また熊本県の維持管理計画では、補修の維持管理基準に従って補修を行った割合は全体の 60%程度であり、その主な要因は次の 2 点であるとしている。

- I. 路面の損傷(ひび割れ、わだち掘れ)以外による損傷
- II. 路面性状値と現地の違い(局所的損傷で 100m 評価値に表現されない、路面性状調査の対象区間外(調査と反対の車線)での損傷など)

また、渡邊ら²⁴⁾は軽交通道路を管理する 10 の市町村の舗装管理実態を把握するためのヒアリングから、何れの自治体も実際は現場技術者の経験から補修工法や時期などの対応を決めているのが現状である事、富山ら²⁵⁾の調査では 8 割の自治体は現場技術者の判断による事、著者がある自治体に聞いた範囲でも同様に最終的には現場の判断としている。この様に、現状は舗装劣化予測に基づいて最適な補修工法や時期などの維持管理計画を立案してもその通りに実施されず、最終的に現場の判断により行われているのが実情である。

2.2. 舗装劣化予測モデルの現状

舗装劣化予測モデルの現状を分類，整理するため，4つの軸を定義する．1つ目は目的，2つ目は維持管理計画のレベル，3つ目はモデル化する変化量，4つ目は数理モデルの種類である．

2.2.1. 目的による分類

それまでに得られたデータから真の劣化過程を推定するモデルか，将来を予測するためのモデルかによってパフォーマンスモデル又は予測モデルに分類する事が出来る．図 2-7 にパフォーマンスモデルと予測モデルの視点を示す．

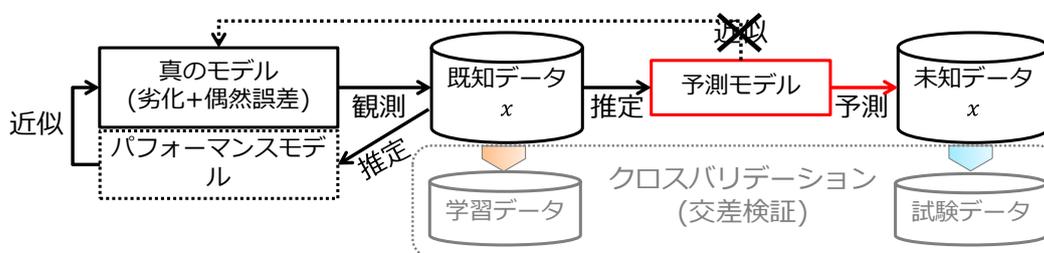


図 2-7 パフォーマンスモデルと予測モデルの視点

従来統計モデルは，真のモデルがあるとしてその分布を近似するモデル(パフォーマンスモデル)を構築するという考え方であった．この方法は実験室で得られるデータ等，環境条件が全て制御可能であり，影響を与える要因が観測可能である際には有効である．しかし，より現実的な問題では，実験室とは異なり，あらゆる環境条件が線形，非線形問わず予測に影響を与え，それらの条件が観測されているとは限らない．その様な場合，限られた観測可能な説明変数のみで真の分布を近似する事は不可能であり，モデルの本来の目的として未知のデータに対する予測性能を重視するという視点に立っているモデルが予測モデルである．このあたりの議論は小西ら²⁶⁾に詳しい．

I. パフォーマンスモデル

パフォーマンスカーブはデータに内在するばらつきを取り除き，大型車交通量又は経過年数を横軸に，縦軸に舗装の性能指標をプロットしたものとして用いられている⁷⁾が，パフォーマンスモデルという用語を明確に定義した文献は見当たらないため，本稿におけるパフォーマンスモデルをここで定義する．パフォーマンスカーブの定義から，用いる事が出来るデータを全て消費して，それらのデータに含まれるランダムなばらつきを取り除いた真のパラメータを推定する事で，モデルの仮定下における真の舗装劣化プロ

セスを推定する事を目的とするモデルをパフォーマンスモデルとする。例えば、ひび割れやわだち掘れ量といった性能指標について、説明変数の与える影響の重みをモデルのパラメータとし、それを既知のデータから推定する事で、劣化の要因分析に用いる事を目的とするモデルはパフォーマンスモデルである。

II. 予測モデル

既知のデータから求めた真のモデルの推定精度と予測精度は異なる事を指摘する必要がある。母集団から得られた標本である既知のデータは母集団に対して偏り(バイアス)があるため、既知のデータから求めたパフォーマンスモデルの推定パラメータも真のモデルに対して偏りがある。それにより、既知のデータと同じ母集団から得られた未知のデータに対して、パフォーマンスモデルにより予測する際にも偏りがある。その事から予測能力を評価したい場合、最尤法を用いる GLM 等では、その偏りを補正した AIC を用いる必要がある²⁶⁾。最尤法を用いない NN 等では、クロスバリデーションにより予測能力を評価する事が出来る。図 2-8 に示すようにクロスバリデーションは、得られた観測値からランダムに学習データと試験データに分割し、学習データのみをモデルの学習(パラメータ推定)に用いて、試験データでそれ以外のデータに対する予測能力の試験を行う方法である。学習データと試験データそれぞれは図 2-7 の既知データと未知データに相当する。

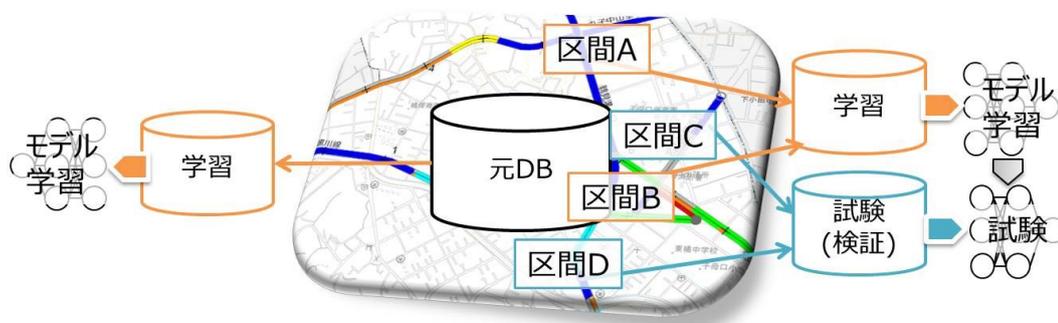


図 2-8 クロスバリデーションのイメージ

これらの事より、未知のデータに対する予測能力を高める事を目的としたモデルを予測モデルとする。

2.2.2. 維持管理計画のレベルによる分類

舗装維持管理計画に用いるシステムを舗装マネジメントシステム (Pavement Management System, PMS)と呼ぶ。このシステムでは、明確に区別されていない事も多いが2つの舗装維持管理計画のレベルがあり⁷⁾、それぞれに対応した劣化予測モデルが存在する。

I. プロジェクトレベルの維持管理計画

プロジェクトレベルの維持管理計画では、それぞれの管理単位区間ごとの維持管理施策を計画する。プロジェクトとは、各舗装区間に対する点検や補修等個別の工事の事を指す。これは、図 2-6 のフローを最適化する事に相当し、点検、補修等の施策をそれぞれの単位区間ごとに最適な維持管理計画を立案する。そのためには、単位区間ごとに様々な施策を行った場合の変化を劣化予測モデルで予測し、最適な施策を選択する必要がある。この事から、プロジェクトレベルの劣化予測モデルとは単位区間ごとに劣化予測するモデルの事を言う。

II. ネットワークレベルの維持管理計画

ネットワークレベルでは、それぞれの管理単位区間を対象にしたプロジェクトレベルとは異なり、舗装管理者の管理内（管内）にある全てのプロジェクトに対して、最適な予算の配分を決定する事が目的である。従って、その際には路線の優先順位や沿線住民の苦情、利用者費用等を考慮し、必要な予算計画を立案する。プロジェクトレベルの最適維持管理方策を元に、ネットワークレベルで最適な予算配分を決定する事から、ネットワークレベルのサブシステムがプロジェクトレベルと考える事が出来る。ネットワークレベルの維持管理計画効率化は動的計画法^{10),11),12)}や、MCDA(Multi-Criteria Decision Analysis)^{27),28)}等を用いた研究がある。この事から、ネットワークレベルの劣化予測モデルとは、データを大型車交通量等でグループ化し、そのグループ内の平均を予測するモデルの事を言う。

プロジェクトレベルで精度の高い予測が可能になれば、予測が容易な区間は点検頻度を下げる事や、破壊が深刻化する前に補修を行う事で長寿命化する予防保全を実現する事、他方でまだ補修が必要ない箇所の補修を先送りする事、管路工事等と同時に舗装工事を実施する事¹⁷⁾等により、維持管理コスト削減が可能になる。

マルコフチェーンモデル等の舗装劣化予測モデルでは、データを大型車交通量等でグループ化し、その中に十分なサンプル数が必要であるためグループをあまり細かく分ける事は出来ない。そのため予測はグループ全体の平均値となり、プロジェクトレベルを考慮せずにグループ全体の分布を確率として表す事で、ネットワークレベルの劣化予測と呼ぶこともある²⁹⁾。しかし、現実是个々の単位区間ごとに大きく異なるため、効率化にならない単位区間も多い。

ネットワークレベルはプロジェクトレベルの集合であるため、本来ネットワークレベルの予測精度にもプロジェクトレベルの予測が大きく影響する事になる。従って本研究では、ネットワークレベルの予算配分を決定する事に加え、実際の維持管理の現場における効率化に資するため、プロジェクトレベルの劣化予測モデルを対象とする。

2.2.3. モデル化する変化量による違い

舗装劣化予測モデルは、モデル化する対象の変化の違いにより、絶対モデル又は Absolute Model (谷口ら³⁰⁾における回帰モデル)と相対モデル又は Relative Model (又は Incremental Model)に分類する事が出来る^{31),32)}.

I. Absolute Model

前者の Absolute Model は舗装劣化プロセス全体を適当な抽象度でモデル化していると考え、新設後の劣化について観測値を用いずに任意の時刻の予測値を求める。Absolute Model は観測値を用いない事から、予測はモデルのパラメータ推定時に用いたデータに完全に依存する。そのため少しでも異なる特性があるデータに対する予測の信頼性が低い事や、新設からの履歴が一部でも不明であれば適用する事が容易ではない等の問題がある³²⁾.

II. Relative Model

Relative Model は、ある時刻の観測値が既知であるとして、それを元に次の時刻への変化をモデル化する。Relative Model では観測値を用いるため、一度も観測値が測定されていない新設路線等には適用できない。

例えば世界銀行により開発された PMS, HDM-4 に含まれる各種予測モデルの 1 つであるコンクリート舗装の劣化予測モデルは従来 Absolute Model であったが、信頼性に問題があったため、バージョン 2.09 以降では Relative Model に置き換えられるようにしている。本研究ではそれらの事から路面性状値の変化量を示す劣化速度をモデル化する Relative Model を用いて評価を行う。

2.2.4. 数理モデルの種類による分類

数理モデルの軸から見ると舗装劣化予測モデルは次の 3 種類に分類する事が出来る。

- I. 力学的モデル
- II. 統計モデル
- III. NN モデル

入力変数ベクトルを \mathbf{x} , それを用いて予測した出力ベクトルを \mathbf{y} とすると、予測を行うモデルの獲得は、与えられた学習用のデータ集合 \mathbf{S} を用いて、予測関数 $f_{\theta}: \mathbf{x} \rightarrow \mathbf{y}$ を獲得する事だと考える事が出来る。ここで、太字はベクトルである事を表し、 θ は f_{θ} の特徴を決定する特徴量パラメータベクトルである。これを用いて、3 種類の概要を整理する。

- I. 力学的モデル

多層弾性理論や図 2-9 に示すような有限要素法等により舗装にかかる外力や材料特性、気象条件から永久変形を予測する力学的シミュレーションによる手法^{7),33),34),35),36),37)}。この方法は、わだち掘れ量やひび割れ率等の予測する対象ごとの物理法則の考察から f_{θ} を一意に決定する事に相当する。従って実験室等の全ての変数が観測可能である理想的な条件下において、ミクロな視点で素材の変形を詳細に解析する事が可能であり、舗装設計等で活かされている。しかし施工後の道路において実験室と同等の条件を全ての舗装について観測する事は現実的ではないという課題がある³²⁾。

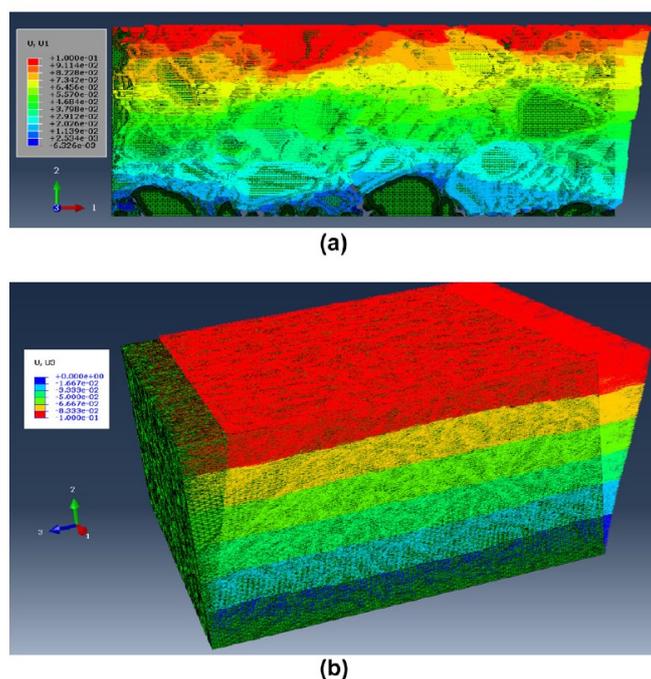


図 2-9 有限要素法による舗装の変形³⁷⁾

II. 統計モデル

統計モデルによる手法。舗装に対する調査履歴データに対して、線形・非線形回帰モデル^{38),39),40),41),42),43)}や、直線回帰モデルを複数繋げた形状の MARS^{44),45)}、図 2-10 に示した離散化した舗装の健全度分布の遷移をハザード関数により表すマルコフチェーンモデル^{10),46),47),48),49),50)}により、舗装劣化プロセスをモデル化する試みが行われている。この場合、ひび割れ率やわだち掘れ量といった各性能指標の劣化プロセスが各モデルの比較的単純な仮定に従う事を前提としている。統計モデルはデータをモデルに当てはめるという考え方で構築されており、その当てはまりの良さを尤度や AIC 等により測る事で評価する。この方法は予測関数 f_{θ} を専門家の知見を元に仮定した上で、 θ の値を S から推定し θ_s を得る事で予測モデルを構築する。また、この種類のモデルでは、舗装を例えば大型車交通量等でグループ化し、そのグループ内の平均値を予測するネットワークレベルの劣化予測モデルも

多い。特にマルコフチェーンモデルはグループ内のサンプル数が十分になれば確率分布を精度高く求める事が困難であるため、グループを細分化する事が出来ない。しかし現実的には、同じグループ内の区間でもそれぞれの区間の劣化は全く異なるという課題がある。

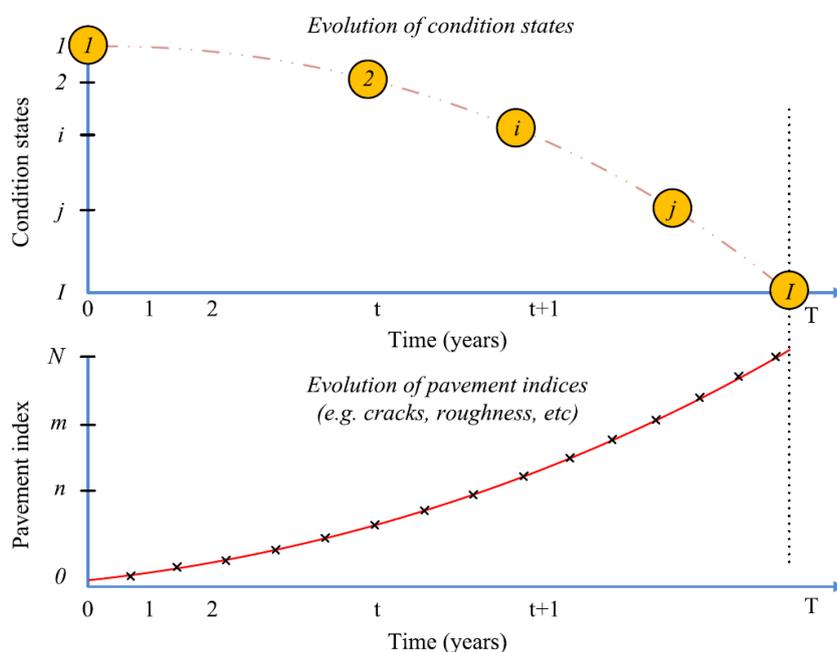


図 2-10 離散化した健全度(condition state)の推移⁵⁰⁾

III. NN モデル

NN モデルによる方法. NN モデルは人間の神経細胞間の接続をモデル化した f_{θ} を定義する手法である. その最小の構成要素は、図 2-12 に示す 1 つの神経細胞をモデル化したニューロンである. このニューロンを多層に接続する事で、最も基本的な NN モデルである多層パーセプトロン(multi-layer perceptron, MLP)として用いられる.

θ の値を S から推定し θ_s を得る事で予測モデルを構築する点は、統計モデルと同一である. NN モデルの特徴は θ が高次元で、普遍性定理と言われるあらゆる非線形関数を近似できる表現力(Capacity)が高いモデルである事が証明されているため⁵¹⁾、従来の近似関数を幅広く含む事である. それにより、統計モデルとは逆にモデルがデータに適合するという考え方であるため、逆にデータにモデルが適合し過ぎる過適合(過学習)を抑制する事が重要になる. 統計モデルの場合、 θ を劣化速度や各説明変数の重み等の特徴量とし、その値をデータから推定する事で、モデルの仮定下におけるデータの特徴を解釈する事がある. それに対し NN モデルの場合、データから特徴を学習するために、仮定を置き表現力を制限する事は通常行わない. そのため、統計モデルと同様に θ からデータの特徴を分析したい場合には、 θ が高次元で非常に複雑であるため容易ではない. しかし、各単位区間の予測結果や、そこか

らパフォーマンスカーブのようにある説明変数に対する目的変数の平均的な変化を示す事や、説明変数の値を徐々に変化させて出力との関係性を分析する感度分析は可能である。

NNモデルと統計モデルとの最も重要な違いは、統計モデルでは適用するデータに対して仮定を置く必要がある点である。例えば線形回帰モデルであれば、説明変数の線形結合により目的変数を表現できるという仮定で、マルコフチェーンモデルであれば、離散時間において現在の状態は、1つ前の状態のみに依存し遷移確率で変化するという仮定がある。そのような単純化した仮定にデータを当てはめる事で、モデルの表現力は大幅に制限され、パラメータの解釈は容易になるが、少しでも仮定に当てはまらない部分がある場合、予測精度が低下し、パラメータの解釈が正しくないという課題がある。例えば実験室において説明変数以外の条件を一定にして観測した場合には、重要な説明変数は全て観測されている事から、目的変数との関係性は明白であるため、比較的単純な仮定に当てはめる事が可能であろう。しかし、運用時のフィールドから計測されたデータの場合、日当たりや土質等の環境条件、舗装材の詳細な組成、施工の質、応急処置等の局所的な補修等の観測可能および不可能な変数が相互作用する事により、説明変数と目的変数の間には誤差が大きく非線形で複雑な関係が存在する可能性がある。そのような場合に、全ての関係性を従来のモデルの様に比較的単純な仮定に当てはめる事は困難であると考えられる。

一方でNNモデルは、先述の通りあらゆる非線形関数を近似できる表現力の高いモデルであるため、モデルがデータに対し適合すると考える事が出来る。そのため、例えばそれまでの全ての点検結果を考慮して単位区間ごとの劣化の特徴を把握し、次の時刻の予測を行う事が可能なRNNモデルや、全ての説明変数間の相互作用及び、それらの非線形な変化を考慮した自由度の高い予測をする事が出来る。従って従来のモデルには含まれないそのような関係を考慮する事で、非線形で複雑な関係がある運用時のフィールドから得られたデータにおいて、NNモデルは予測精度向上に効果があると考えられる。例えば音声認識タスクではRNNモデルを適用する事⁵²⁾、画像認識ではCNN(Convolutional Neural Network)モデルを用いる事⁵³⁾、NNモデルを用いない従来手法と比較し10%近く誤認識率が改善した事等、複雑な問題では精度が高い事が解ってきている⁵⁴⁾。NNモデルを用いた劣化予測モデルについては、次節で詳しく論じる。

2.2.5. 情報通信技術とニューラルネットワークモデルの変化

近年情報通信(Information and Communication Technology, ICT)技術の発展に伴い、IoT(Internet of Things)センサやビッグデータ、人工知能を現実の課題に適用する事による技術革新が進行している⁵⁵⁾。その様な新しい技術を舗装維持管理に取り入れるために、国としても舗装点検要領において、新技術による維持管理効率化を推奨している。また、新技術の開発を促進するための内閣府による戦略的イノベーション創造プログラム(SIP)により、インフラ維持管理・更新・マネジメント技術の研究開発を支援しており、人工知能、ビッ

グデータを活用したアセットマネジメントシステムの研究開発が課題として採用されている等、ビッグデータや人工知能を活用した公共インフラの維持管理効率化が期待されている⁵⁶⁾。それらの事では、多様なデータの増加、人工知能の発展により図 2-11 に示すような未来が来ることを想定している。道路に関する構造物は2014年から道路法により近接目視点検が義務化されているが、それらの点検結果データと同時に、リモートセンシング、プローブ、監視カメラや市民からの通報、IoTセンサ等のデータを統合し、最適な維持管理計画の立案に資する事が求められている。

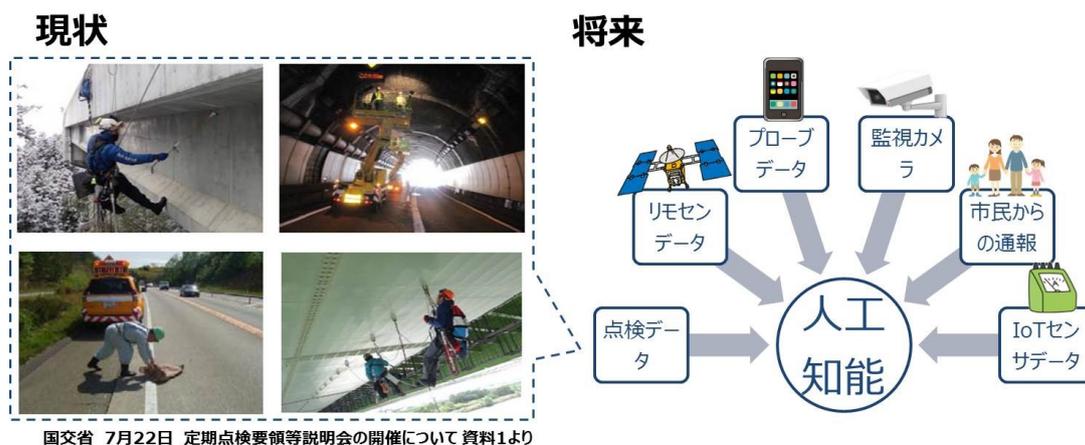


図 2-11 現状と将来の公共インフラ維持管理

人工知能の中でも特にニューラルネットワーク(Neural Network, NN)モデルは、画像認識、音声認識、翻訳、ゲーム AI 等において従来の様々なモデルを上回る精度を達成しており、ブレークスルーとして⁵⁷⁾注目されている。NN モデルの最小構成要素であるパーセプトロンが提案されて以降の主要な変化を表 2-4 にまとめる。

表 2-4 NN モデルの主要な変化

年	提案者	概要	課題
1958	Rosenblatt	NN の最小単位パーセプトロンを提案	学習アルゴリズム
1986	Rumelhart and Hinton ら	学習アルゴリズム逆誤差伝播法を提案	過学習 多層になると誤差が伝播しにくい
2010	Nair and Hinton ら	正規化線形関数により誤差を減衰せずに伝播	過学習
2012	Hinton ら	過学習を抑制するドロップアウト	

これらの研究により、NN モデルに存在した解決する事が困難であった課題を乗り越え、様々な分野で著しい成果を上げる事が可能になった。

2.2.5.1. パーセプトロン

NN モデルは 1956 年 Rosenblatt⁵⁸⁾により発表された、図 2-12 に示すパーセプトロンにより、現在の NN モデルの最小構成要素であるニューロンが提案された。パーセプトロンの出力 z は

$$z = g(a)$$

$$a = \sum_i \omega_i x_i \tag{2.1}$$

により得られる。ここで、 a は人の神経細胞が活性化する様子から類推し活性、 $g(x)$ は活性化関数と呼ばれる。しかし、Rosenblatt⁵⁸⁾が提案した当時は結合荷重パラメータの学習方法が確立されていなかったため、複数のニューロンを結合した際に上手く学習できない問題があった。

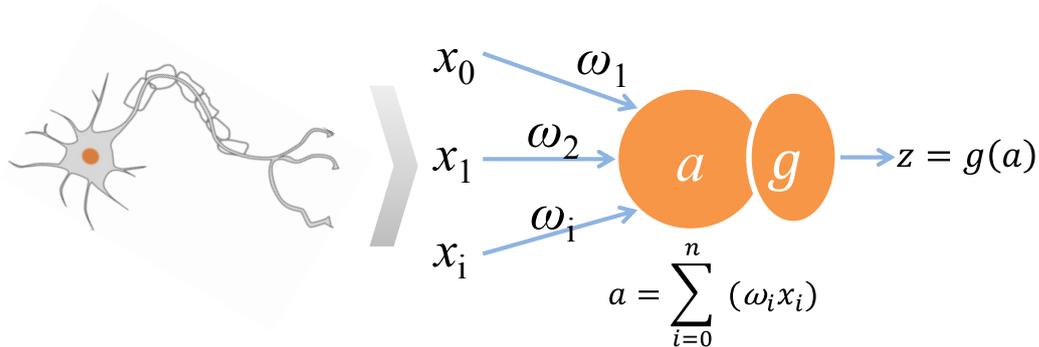


図 2-12 神経細胞をモデル化したニューロン

2.2.5.2. 逆誤差伝播法

そこで、1986年にRumelhart⁵⁹⁾らにより提案された逆誤差伝播法により、基本的な学習方法が確立された。それにより、ニューロンを多層に接続したモデルを学習する事が出来るようになった。ニューロンを多層に接続したモデルのうち最も基本的なモデルが多層パーセプトロン(Multi-Layer Perceptron, MLP)モデルである。ここでは図 2-13 に示した MLP モデルを例にして、順伝播及び逆伝播計算の手順を示す。

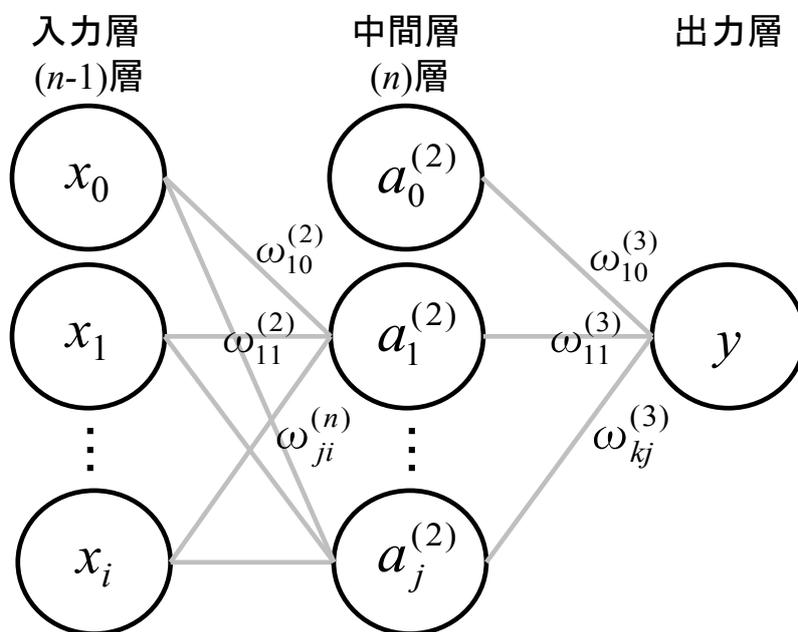


図 2-13 MLP モデル

MLP モデルは、図 2-12 のニューロンをネットワーク状に多層に接続したモデルで、ニューロン間の結合荷重パラメータ $\omega_{ji}^{(n)}$ を更新する事で学習する。 $\omega_{ji}^{(n)}$ は入力層から数えて $(n-1)$ 層 $(n = 1, \dots, N)$ の i 番目のニューロンから n 層の j 番目のニューロンへの結合荷重パラ

メータである。活性 $a_j^{(n)}$ は n 層目の j 番目のニューロンの状態を表す。なお、 $a_0^{(n)}$ に入力がない理由は定数項(バイアス項)に相当するためである。

x_i は任意次元数の MLP モデルの入力データ(説明変数)である。 $a_j^{(n)}$ は次式により計算される。

$$a_j^{(n)} = \sum_i \omega_{ji}^{(n)} z_i^{(n-1)} \quad (2.2)$$

$a_j^{(n)}$ に対して非線形活性化関数 $g(x)$ で変換した

$$z_j^{(n)} = g(a_j^{(n)}) \quad (2.3)$$

は $a_j^{(n)}$ を持つニューロンの出力であり、次層のニューロンの入力である。式(2.2)と式(2.3)を繰り返し適用する事により、ネットワークの全てのニューロンの出力を計算し、出力 y を算出する順伝播計算を行う。本章では連続値を予測対象としているが、出力層にソフトマックス関数を用いれば離散値への対応が可能である。

学習の際には y と教師データ d 間の誤差関数を定義し、誤差を出力層から入力層へと逆順に伝播する誤差逆伝播計算を行う。あるニューロンについての順伝播と逆伝播計算を図 2-14 に示す。

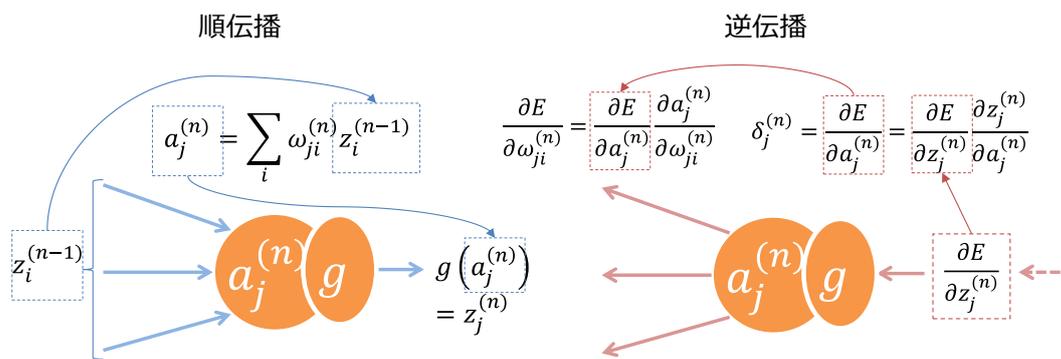


図 2-14 順伝播と逆伝播計算

図 2-13 において出力層に相当する $(n+1)$ 層のあるニューロンを $k(=1, \dots, K)$ で表し、誤差関数 E に MSE(Mean Square Error)を用いると、 E は次のように求められる。

$$E = \frac{1}{K} \sum_k (y_k - d_k)^2 \quad (2.4)$$

MSE に対して平方根を取り，単位を元に戻したものを RMSE(Root Mean Square Error)と呼び，平均的な予測誤差を表す値として，予測精度の評価の際に用いる。

学習により各結合荷重パラメータ $\omega_{ji}^{(n)}$ の更新量を求める際には，誤差関数 E の各結合荷重パラメータ $\omega_{ji}^{(n)}$ に対する傾き $\partial E / \partial \omega_{ji}^{(n)}$ を求め，学習による更新量とする。ここで簡便さのために

$$\delta_j^{(n)} \equiv \frac{\partial E}{\partial a_j^{(n)}} \quad (2.5)$$

を導入する。これを用いると， $\partial E / \partial \omega_{ji}^{(n)}$ は次式で求められる。

$$\frac{\partial E}{\partial \omega_{ji}^{(n)}} = \frac{\partial E}{\partial a_j^{(n)}} \frac{\partial a_j^{(n)}}{\partial \omega_{ji}^{(n)}} = \delta_j^{(n)} z_i^{(n-1)} \quad (2.6)$$

従って，全てのニューロンに対する $\delta_j^{(n)}$ が解れば，全ての $\omega_{ji}^{(n)}$ に対する更新量が求まる。 $\delta_j^{(n)}$ は微分の連鎖規則を適用する事で次のように計算できる。

$$\delta_j^{(n)} = g'(a_j^{(n)}) \sum_k \omega_{kj}^{(n+1)} \delta_k^{(n+1)} \quad (2.7)$$

これにより $\delta_j^{(n)}$ を出力層から入力層に向けて伝播させ，式(2.6)で求まる傾きを元に $\omega_{ji}^{(n)}$ を更新する事で，NN モデルは任意のデータを近似するように学習する事が出来る。

2.2.5.3. 正規化線形関数

ここまで前項の逆誤差伝播法により多層の NN モデルを学習できるようになった。しかし，深い層ほど学習が困難である勾配消失問題，学習データに適合し過ぎてしまう過学習の問題があった。まず，Nair ら⁶⁰⁾により提案された正規化線形関数(Rectified Linear Units, ReLU)が多層ネットワークにおける学習の困難さを軽減する事に成功した。正規化線形関数は次の式で表される。

$$g(x) = \max(0, x) \quad (2.8)$$

それまでは活性化関数 $g(x)$ には次式のシグモイド関数(図 2-15(a))が用いられることが多

かった。

$$g(x) = \frac{1}{1 + e^{-x}} \quad (2.9)$$

これは $g(x)$ の値が0~1の範囲に収まるため、次の層で前の層の出力の総和を取る際に値のオーバーフローを防げることや、確率として解釈する際に都合が良い、微分可能である等の理由による。しかし、 x が±の極値になると $g(x)$ の傾きは極めて小さくなる。その場合、傾きを利用して学習する逆誤差伝播法で学習が難しくなるという問題があった。そこで、ReLUは(図 2-15(b))に示すように0以上では常に傾きが一定であるため、多層ネットワークの学習の困難さを解消する事に成功した。

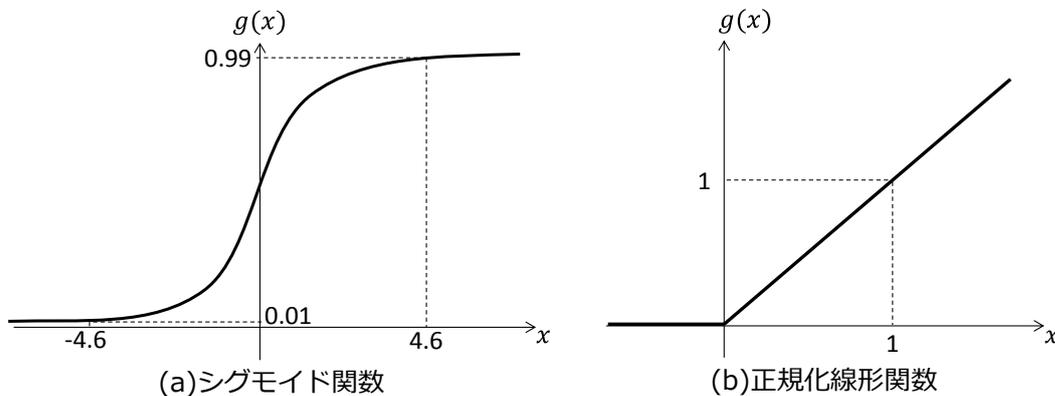


図 2-15 シグモイド関数と正規化線形関数

2.2.5.4. ドロップアウト

ドロップアウトは Hinton ら⁶¹⁾によって提案された、NN モデルの過学習を抑えるシンプルだが効果的な手法である。まず、学習時には図 2-16 に示すようにニューロン間の接続をランダムに一部無効化した NN モデルで、通常の NN モデルと同様に学習を行う。無効化する接続は、設定されたドロップアウト率 p に応じて、学習のたびにランダムに選定される。選定された接続の出力値を 0 にする事で、そのニューロンから次の層への入力を実質無効化する。学習後に予測を行う際には、全てのニューロン間の接続を有効にする。予測時には学習時より $1/p$ 倍ニューロン間の接続が増えている事を補償するために、各層から次の層への出力を全て p 倍する。なお、このドロップアウト率 p のような値は、NN の結合荷重パラメータの学習時に使用するパラメータであるためハイパパラメータと呼ばれる。

以上がドロップアウトの手法である。ドロップアウトの意図は、学習時にはランダムにニューロン間の接続を無効化することでネットワークの自由度を強制的に小さくし、過適合を避ける事である。また、予測時には全てのニューロンを使って予測を行うため、ネッ

トワークを複数独立に訓練し、それらの結果を平均する手法と同じような効果があると考えられている。

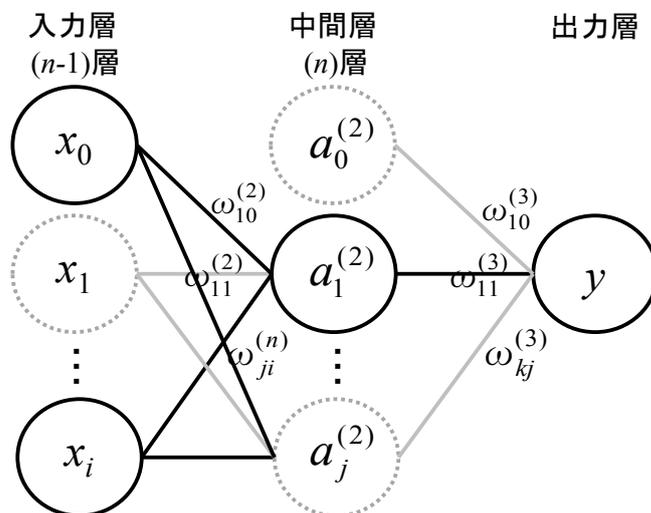


図 2-16 ドロップアウトの概念図

2.2.5.5. 従来の統計モデルとの違い

NN と従来の統計モデルとの最も大きな違いは、データから特徴を学習する点である。従来の統計モデルは、データをモデルにあてはめ、その当てはまりの良さを見てモデルを評価するという考え方であった。そのため、例えば誤差が正規分布に従う等、モデルで仮定した事に合わないデータの場合、モデルへの当てはまりが悪くなり、予測精度が低下する。一方 NN モデルではその様に事前に仮定を設ける必要が無くデータから特徴を学習するため、あらゆるデータに対して適用する事が可能である。このことは、NN モデルがあらゆる非線形関数を近似可能(普遍性定理)として理論的に証明されている⁶²⁾。表現力の例を図 2-17 に示す。任意のデータ(target data)があった際に、それを近似する関数を求めたい。単調増加の様な場合であれば、一次式(1 order)で十分近似できるが、このように不規則な変化をする場合には、一次式近似できない。この場合だと、5 次式(5 order)が最も形状を捉えて当てはまりが良く近似できていることが解る。従って、1 次式よりも 5 次式の方が多様な形状を近似でき、表現力が高い。

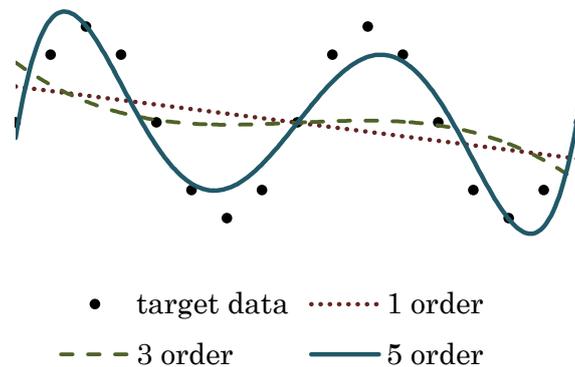


図 2-17 表現力の例

その一方で、学習に用いたデータに過適合する事で、学習に用いていないデータの予測精度が低下する過学習の恐れがある。初期の NN モデルは、過学習や効率的な学習アルゴリズムが欠如していた。しかし近年になり、過学習を検知して制御可能なクロスバリデーションや、過学習を抑制するドロップアウト、各種正則化手法が提案された事により先述のブレークスルーが可能になった。それにより、NN はデータから特徴を学習できるため、リモートセンシング、プローブデータ、IoT センサ等の急増するビッグデータを用いる事も容易であるという特徴がある。従って NN モデルを舗装維持管理に用いる事で、様々なデータを同時に用いて、公共インフラに対して適用する事が可能な、従来手法の予測精度を上回る予測モデルを構築できる事が期待できる。

2.2.6. 先行事例

Kirbas ら⁴⁵⁾は MLP モデル、非線形重回帰モデル、MARS(Multivariate Adaptive Regression Splines)により、PSI(Present Serviceability Index)という舗装の性能指標の1つを予測した結果を比較したところ、MLP モデルが最も観測値との相関が高いという結果が得られた。また重原ら⁶³⁾は、北陸地方の高速道路における路面性状値のわだち掘れ量に図 2-18 に示す MLP モデルを適用し、舗装の表層材料の種類と 4 つのインターチェンジ間ごとの平均的な変化を表すパフォーマンスモデルを構築した。

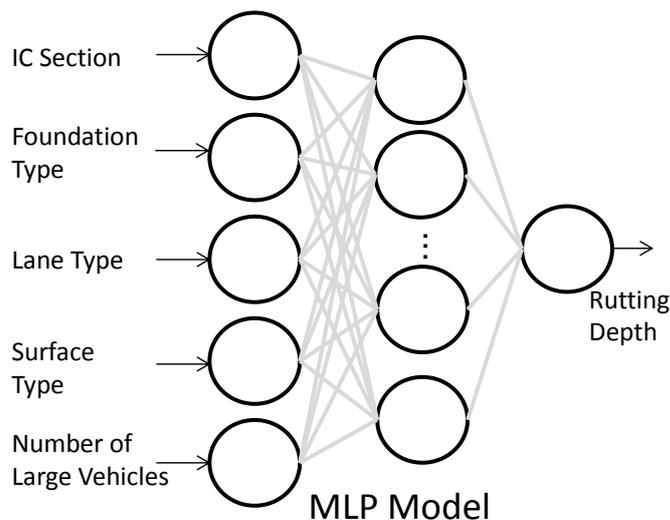


図 2-18 重原ら⁵¹⁾の MLP モデル

日本における類似研究として、堀木ら⁶⁴⁾は昭和 44 年～63 年までの継続的な調査履歴のある 18 区間について、MLP モデルの説明変数に舗装構造や大型車交通量等を用いて、MCI(Maintenance Control Index)のパフォーマンスモデルを構築した事例がある。この路面性状値を検証対象にした 2 事例ではパフォーマンスモデルとして MLP モデルを用いているが、NN モデル等の表現力の高いモデルは、学習データに過適合する事で非常に高い精度で学習済みのデータを再現(予測)できる一方、未知のデータに対しての予測能力が低下する過学習と呼ばれる問題が知られているため、予測モデルとして用いる必要がある。

Tabatabaei ら⁶⁵⁾は、RNN を舗装劣化予測に適用した事例として、アメリカ、ミネソタ州の 16 区間のテストサイトにおける PSI の履歴データに対して予測モデルを構築した。

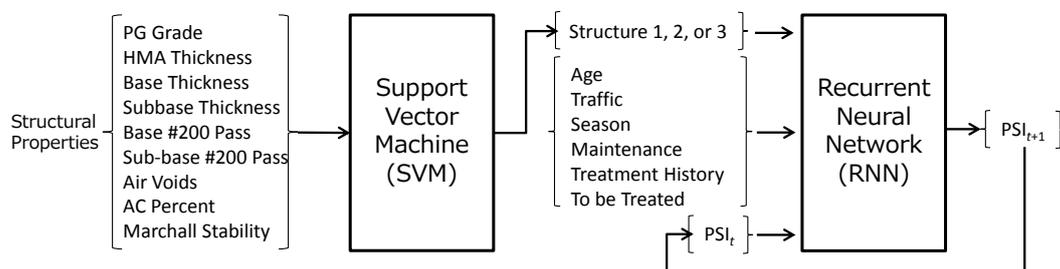


図 2-19 Tabatabaei ら⁵³⁾の RNN モデルを用いた舗装劣化予測

この研究では最も単純な RNN モデルが用いられており、勾配消失問題や過学習を解決ないし軽減した正規化線形関数やドロップアウト等の近年の手法が用いられていない。また、各路面性状値に対して RNN を適用した事例はない。他にもこれらの先事例では学習に用

いたデータ数が少ないため、大量のデータから特徴を学習する事が可能な NN モデルの利点が生かされていないという問題がある。NN モデルの元となるパーセプトロン⁵⁸⁾は 1958 年に提案された古くからあるモデルではあるが、計算機の処理能力向上や様々な発展型、予測モデルとして予測精度を向上するための過学習抑制手法の提案により、2012 年の一般物体認識テストにおいて従来手法を 10%以上上回る誤認識率⁵³⁾を記録した。それ以降急速に注目が高まった結果、NN モデルの新しい構造や学習手法等が提案され、様々な分野への応用が広がっている。しかし、本項で論じたように 2012 年以降に提案された手法を取り入れ、過学習を抑え、パフォーマンスモデルとしてではなく予測モデルとして路面性状値の予測に NN モデルを適用した研究はなく、本研究の独自性を構成する特徴の 1 つである。

2.3. リカレントニューラルネットワークによる舗装劣化予測モデル

提案手法の特徴は以下の通りである。

- I. パフォーマンスモデルとしてではなく，単位区間の予測モデルとして構築・評価する。
- II. 非線形性の高い複雑な特徴をデータから学習できるため，専門家の知見によるモデル化が不要である。
- III. 従来の統計モデルであれば，ひび割れ率，わだち掘れ量，平坦性からなる路面性状値のようにそれぞれの目的変数の分布や劣化プロセスが異なると考えられる場合，路面性状値ごとに適切に仮定したモデルを構築する必要がある。しかし NN モデルはデータから特徴を学習するためその様な必要が無く，モデルの層数，ニューロン数は同一で，連続値である各路面性状値を予測する。
- IV. 調査が行われていない時刻を予測した場合，観測値が無く定量的な精度評価が容易ではないため，次の調査時刻(およそ3年後)の値を予測し，精度評価する。
- V. MLP, RNN 両方に，過学習を抑制し予測精度を向上させるためのドロップアウト⁶⁴⁾および ADAM⁶⁶⁾を導入する。
- VI. RNN は過去の時系列を全て考慮し，現時刻の予測を行う。

この項では本章で提案する NN モデルの中でも基本的な MLP モデルと，過去の時系列データを全て考慮して予測を行う RNN モデルを用いた路面性状値の予測モデルの詳細を説明する。MLP モデル及び RNN モデルは Python を用いた NN フレームワークである Chainer⁶⁷⁾を用いて実装し，検証した。

2.3.1. RNN モデルによる時系列データのモデリング

通常路面性状調査は同じ区間に対して数年おきに行われるため，過年度の調査履歴データを全て考慮した上で予測をすれば，予測精度を向上できる可能性がある。NN モデルには，そのような時系列データをモデル化する事が出来る RNN モデルがある。図 2-20 に RNN モデルを示す。

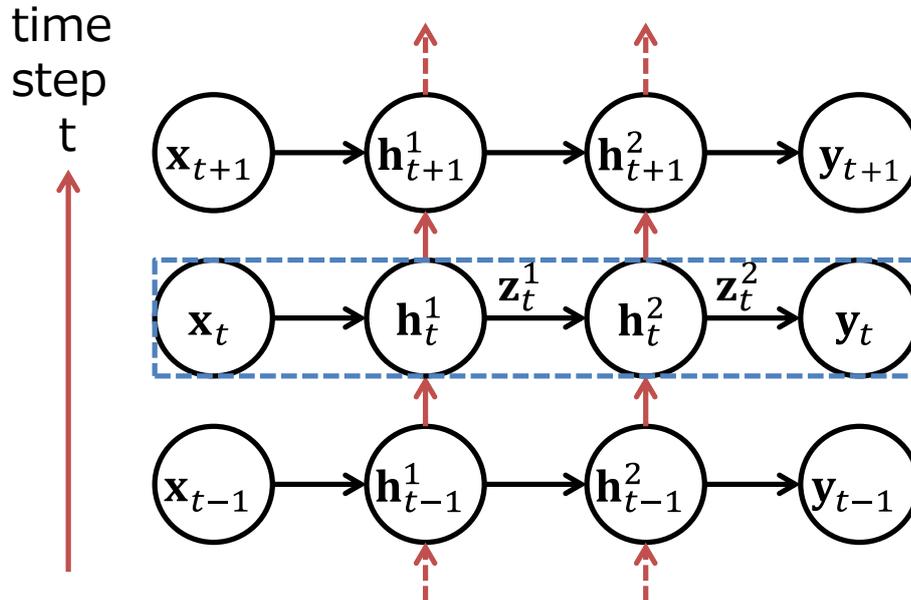


図 2-20 RNN モデル

MLP モデルを可変長の時系列データに拡張したモデルが RNN モデルであり、通常は音声や、文章等、時系列データのモデル化に使用される。本章で用いた路面性状値調査データは、同じ単位区間をおよそ 3 年おきに計測した時系列データであることから、RNN モデルを適用する事で過去の調査履歴を全て考慮して予測を行う事が可能になる。

図の破線で囲まれた部分が 1 つの時刻を処理する部分であり、この部分のみを用いた場合 MLP に相当する。図 2-20 は隠れマルコフモデルの様にも見えるが、隠れマルコフモデルは事前に仮定した 1~3 時刻前までの関係性のみを離散値でモデル化しているのに対し、RNN モデルは過去全てのデータとの関係性から、連続値の予測対象を回帰する事が可能である。

時刻 t における n 層の入力データベクトルを $\mathbf{x}_t^{(n)}$ 、出力データベクトルを $\mathbf{z}_t^{(n)}$ とする。また、RNN は現在の状態を次の時刻の自分自身に引き継ぐために、ニューロンの内部状態 $\mathbf{h}_t^{(n)}$ を持つ。 $\mathbf{h}_t^{(n)}$ は次式により求められる。

$$\mathbf{h}_t^{(n)} = g(\mathbf{W}^{(n)}\mathbf{z}_t^{(n-1)} + \mathbf{U}^{(n)}\mathbf{h}_{t-1}^{(n)}) \quad (2.10)$$

ここで $\mathbf{W}^{(n)}$ は同じ時刻内の結合荷重 $\omega_{ji}^{(n)}$ を (j, i) 成分に持つ結合荷重行列、 $\mathbf{U}^{(n)}$ は $\mathbf{W}^{(n)}$ と同様の時刻方向の接続に関する結合荷重行列を表し、これらは学習により更新されるが、時刻により不変である。 $\mathbf{h}_{t-1}^{(n)}$ から $\mathbf{h}_t^{(n)}$ への接続は、時刻 $t-1$ から t の自分自身への回帰的な接続である。これにより、理論的には 1 つ前の内部状態を通し、過去全ての時刻の内部状態を考慮して、現在の出力 \mathbf{y}_t を決定する事が出来る。

2.3.2. GRU モデル

GRU(Gated Recurrent Unit)⁶⁸⁾モデルはRNN を実現する方法の 1 つである. 従来 RNN には LSTM(Long Short-Term Memory)⁶⁹⁾が最もよく用いられていたが, 近年になり LSTM を改良し, より簡易にした GRU が提案された.

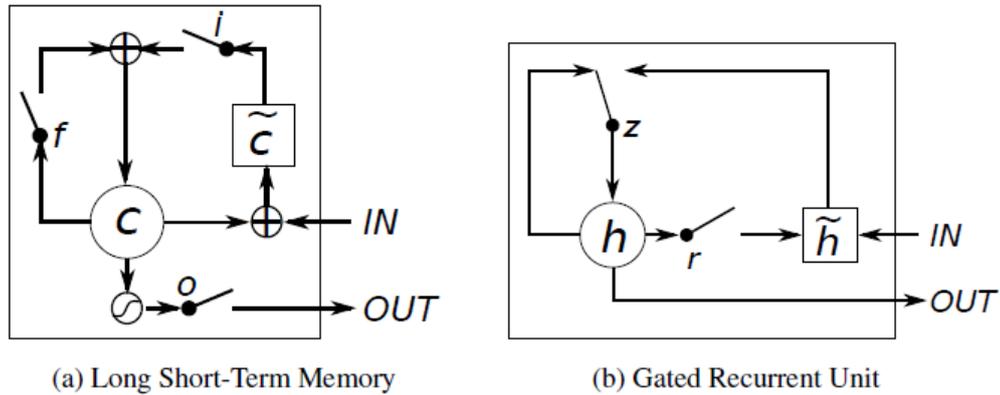


図 2-21 LSTM と GRU モデル⁷⁰⁾

GRU は学習に必要な計算時間が LSTM より短く, 精度は同程度との研究⁷⁰⁾があることから, 本章では GRU を用いた. GRU は RNN の内部状態を, 図 2-22 に示す構造で実装する.

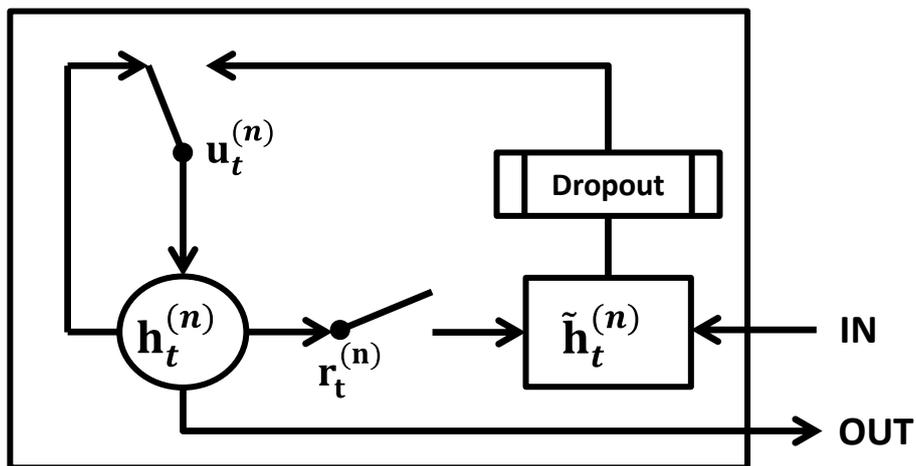


図 2-22 GRU モデル

内部状態 $h_t^{(n)}$ を更新する際に用いる $u_t^{(n)}$ と $r_t^{(n)}$ の 2 つのゲートを持つが, 4 つのゲートを持つ LSTM よりも簡易化されている. このゲートは次の式(2.11)~(2.13)で示すように現時刻の入力と 1 つ前の時刻の内部状態を重み付きで加算した値から, 1 つ前の内部状態をどの程度

予測に用いるかを決定する.

$$\begin{pmatrix} \mathbf{u}_t^{(n)} \\ \mathbf{r}_t^{(n)} \end{pmatrix} = \begin{pmatrix} \sigma(\mathbf{W}_u^{(n)} \mathbf{z}_t^{(n-1)} + \mathbf{U}_u^{(n)} \mathbf{h}_{t-1}^{(n)}) \\ \sigma(\mathbf{W}_r^{(n)} \mathbf{z}_t^{(n-1)} + \mathbf{U}_r^{(n)} \mathbf{h}_{t-1}^{(n)}) \end{pmatrix} \quad (2.11)$$

$$\tilde{\mathbf{h}}_t^{(n)} = g(\mathbf{W}_h^{(n)} \mathbf{z}_t^{(n-1)} + \mathbf{U}_h^{(n)} (\mathbf{r}_t^{(n)} \odot \mathbf{h}_{t-1}^{(n)})) \quad (2.12)$$

$$\mathbf{h}_t^{(n)} = (1 - \mathbf{u}_t^{(n)}) \mathbf{h}_{t-1}^{(n)} + \mathbf{u}_t^{(n)} \tilde{\mathbf{h}}_t^{(n)} \quad (2.13)$$

ここで σ はシグモイド関数, \odot はアダマール積を表す. $\mathbf{W}_u^{(n)}, \mathbf{W}_r^{(n)}, \mathbf{W}_h^{(n)}$ は同じ時刻内の結合荷重行列, $\mathbf{U}_u^{(n)}, \mathbf{U}_r^{(n)}, \mathbf{U}_h^{(n)}$ は時刻間の結合荷重である. GRU は式(2.13)により求められた内部状態 $\mathbf{h}_t^{(n)}$ がそのまま n 層の出力 $\mathbf{z}_t^{(n)}$ かつ $(n+1)$ 層目への入力であり, 出力層の場合は時刻 t の出力 \mathbf{y}_t である.

これ以降, GRU を用いた RNN の事を RNN モデルと呼ぶ. また, 過去の履歴を全て用いた場合と, 1 つの時刻の情報だけを用いた場合の比較をするために, 時系列データを学習・予測に使用しない sRNN(single timestep RNN)を構築した. sRNN は式(2.13)の時刻方向の接続である右辺第 1 項 $(1 - \mathbf{u}_t^{(n)}) \mathbf{h}_{t-1}^{(n)}$ を常に 0 にした場合に相当する.

2.3.3. RNN に対するドロップアウトの適用

RNN に対するドロップアウトは, MLP に対するドロップアウトと同様に, 全てのニューロンの接続に対して適用すると学習が進まなくなる事が知られている. RNN にドロップアウトを適用する手法は未だ確立されていないため議論の余地はあるものの, 本章では幾つかの自然言語処理タスクで最高の精度を達成した Semeniuta ら⁷¹⁾の手法を用いた. この手法では, 式の右辺第 2 項 $\tilde{\mathbf{h}}_t^{(n)}$ に対してのみドロップアウトを行う. ドロップアウトを適用して修正した式(2.13)は次のようになる.

$$\mathbf{h}_t^{(n)} = (1 - \mathbf{u}_t^{(n)}) \mathbf{h}_{t-1}^{(n)} + \mathbf{u}_t^{(n)} d(\tilde{\mathbf{h}}_t^{(n)}) \quad (2.14)$$

ここで $d(x)$ はドロップアウトを表し, 前項の説明の通り, 学習時にはドロップアウト率 p に応じてランダムに値を 0 にする. この手法によるドロップアウトは, 1 つ前の時刻の内部状態 $\mathbf{h}_{t-1}^{(n)}$ から現在の内部状態である $\mathbf{h}_t^{(n)}$ への接続である式(2.14)右辺第 1 項の $\mathbf{h}_{t-1}^{(n)}$ に対してドロップアウトを行わないため, 過去の情報をドロップアウトにより失わない事が特徴で

ある.

2.3.4. ADAM

NNモデルの学習は結合荷重パラメータの傾き(2.6)式で求めた値に対して、ドロップアウト率 p とは別のハイパパラメータである学習率 α を乗じて、結合荷重パラメータの更新量を決定する。従来は学習が進むごとに α が小さくなるように予め設定していた。その理由は、学習の初期段階には学習速度を上げるため、1回のパラメータ更新で大きく学習を進める。しかし逆誤差伝播法により誤差を減少させていき、最小値である局所最適解に近づいたときには、1回のパラメータ更新量が大きいと局所最適解を通り過ぎてしまうため、少しずつ学習を進める必要があるためである。ADAMは勾配の分散と平均から α を自動的に調整する。学習データ全てを1度学習後、検証データを用いて予測精度を1度評価するまでの1回の処理単位をエポックと言う。1エポック内で計算処理を高速化するために、複数のデータをひとまとめにして行列演算化した1回の処理単位をミニバッチと言う。なお、このエポック数とミニバッチで一度に処理するデータ数はハイパパラメータである。あるミニバッチ b ($b = 1, 2, \dots$)の時の結合荷重パラメータを全て並べたベクトルを \mathbf{w}_b とすると、次式により \mathbf{w}_b を更新する。

$$\mathbf{w}_b = \mathbf{w}_{b-1} - \alpha \frac{\hat{\mathbf{m}}_b}{(\sqrt{\hat{\mathbf{v}}_b} + \epsilon)} \quad (2.15)$$

ここで、 ϵ は分子が0に近づくことで計算が発散しないための定数で、誤差関数 E の結合荷重パラメータ \mathbf{w}_b に対する勾配ベクトルを $\mathbf{g}_b = \nabla_{\mathbf{w}_b} E$ とすると、 $\hat{\mathbf{m}}_b$ は勾配ベクトル \mathbf{g}_b の平均、 $\hat{\mathbf{v}}_b$ は \mathbf{g}_b の分散に相当する値である。 $\hat{\mathbf{m}}_b / \sqrt{\hat{\mathbf{v}}_b}$ は平均値の大きさと標準偏差の大きさの比を表す。従って結合荷重パラメータ \mathbf{w}_b の勾配ベクトル \mathbf{g}_b が大きな標準偏差を持ち、勾配の方向が不安定な時、 α が0に近づくように調整する。これは、局所最適解に近づくと更新量が小さくなるように自動的に調整する事に対応している。また、ADAMに関するハイパパラメータは Kigma ら⁶⁶⁾の推奨値を用いた。

2.4. 手法の検証

2章では、RNNと予測精度の比較のために、MLPモデル及び一般化線形モデル(GLM)を用いる。本章における検証の流れを図2-23に示す。

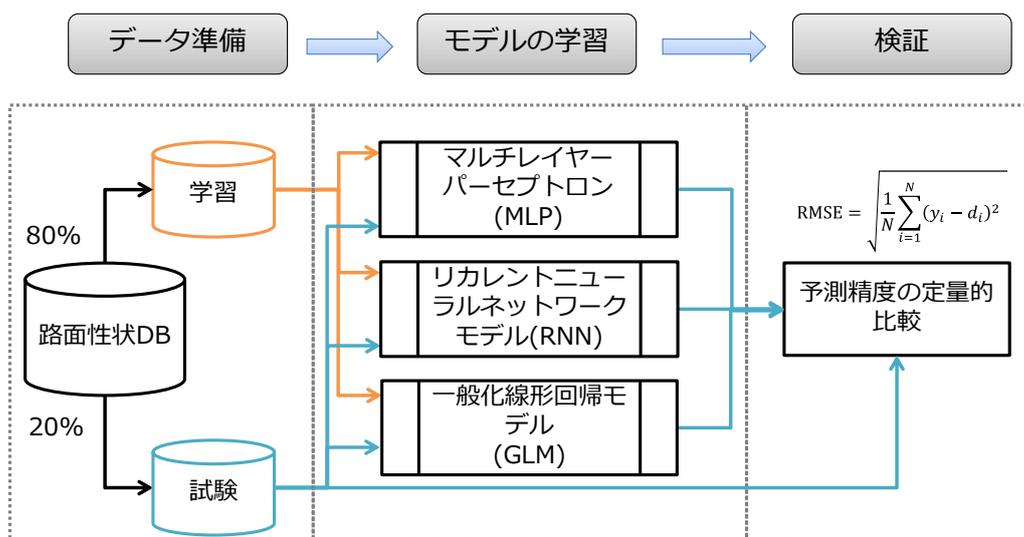


図 2-23 予測精度の検証の流れ

最初に、本研究全体を通して用いた路面性状調査で得られるデータについて説明する。

2.4.1. 路面性状調査

日本では1980年代から路面性状調査が行われてきた。路面性状調査は、舗装調査・試験法便覧⁷²⁾に従い、舗装表面のひび割れ率、横断方向の形状わだち掘れ、縦断方向の平坦性からなる路面性状の3指標を評価する事で、舗装表面の状態を定量化する方法で、値が大きいほど状態が悪い事を示す。路面性状調査は、図2-24に示すような路面性状の自動測定装置を用いて測定される。



図 2-24 路面性状の自動測定装置の例

この自動測定装置は(財)土木研究センターにより毎年検定試験を行っており、自治体の調査仕様書等で検定試験に合格している事を規定する事により精度保証とすることが多い。検定試験の合格精度は、わだち掘れ、平坦性は八千代製作所 KKR-3Y 等の手動式の装置で測定した結果と比較してわだち掘れ $\pm 3\text{mm}$ 、平坦性 $\pm 30\%$ である。ひび割れは人が現場で目視確認した 1mm 幅以上のひび割れが確認できる事としている。それら 3 指標の算出方法を次に示す。

I. ひび割れ率(Cracking Rate, CR)

まず図 2-25 ひび割れ率の求め方に示すように舗装表面画像に 0.5m \times 0.5m のメッシュをかけ、線状ひび割れ、面状ひび割れ、パッチングに分類してひび割れ面積を算出する。

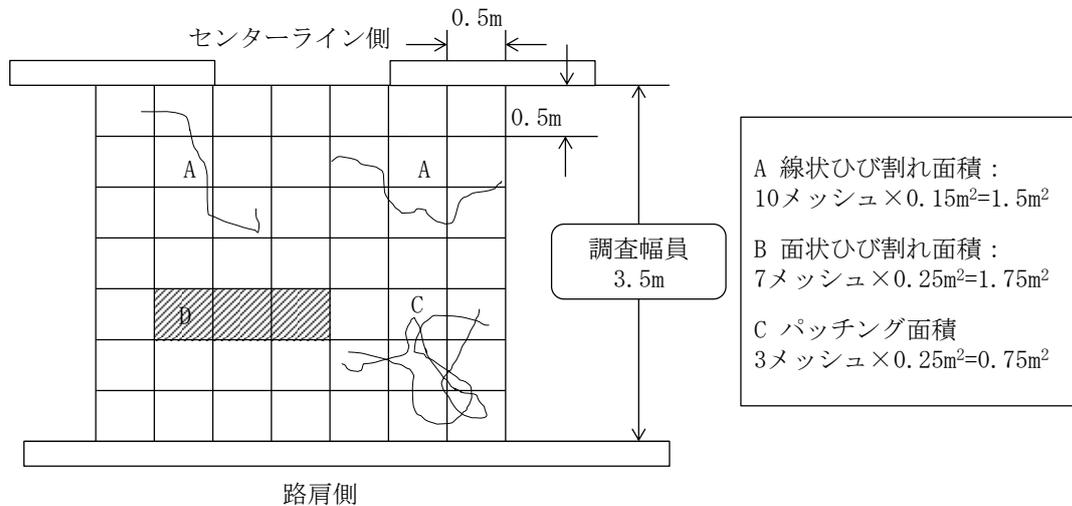


図 2-25 ひび割れ率の求め方

それにより得られたひび割れ面積から、アスファルト舗装の場合次式によりひび割れ率を算出する。

$$\text{ひび割れ率(\%)} = \frac{\text{ひび割れ面積(m}^2\text{)} + \text{パッチング面積(m}^2\text{)}}{\text{調査区間面積(m}^2\text{)}} \times 100 \quad (2.16)$$

ここで、ひび割れ面積(m²)=[面状ひび割れメッシュ数×0.25(m²)]+[線状ひび割れメッシュ数×0.15(m²)]である。

II. わだち掘れ量(Rutting Depth, RD)

わだち掘れ量は舗装の横断形状の評価値である。図 2-26 に舗装の横断形状図を示す。わだち掘れ量の定量化方法は幾つか種類があるが、本研究では路線を中心から左右 2 つに分け、それぞれの上にワイヤーを張り、ワイヤーから舗装面までの距離の最大値をわだち掘れ量とする。それにより求めた左右のわだち掘れ量 D1, D2 のうち大きい方をその箇所のわだち掘れ量とする。

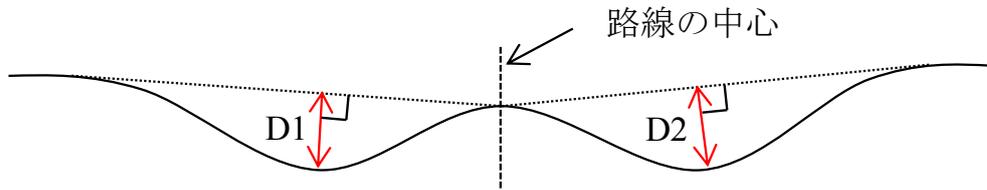


図 2-26 舗装の横断形状図

III. 平たん性(Roughness, RH)

平たん性は舗装の縦断形状の評価値である。図 2-27 に示すように自動測定装置に搭載された非接触距離計(Sensor1~3)により車両と舗装面との距離 $X1, X2, X3$ を測定し、次式により変位量 d の標準偏差を求める事で平たん性の指標値とした。

$$\text{変位量 } d(\text{mm}) = \frac{X1 + X3}{2} - X2 \quad (2.17)$$

$$\sigma = \sqrt{\frac{\sum d^2 - \frac{(\sum d)^2}{n}}{n - 1}} \quad (2.18)$$

ここで、 d : 変位量(mm), n : データ数, σ : 平たん性(mm)である。

また、平たん性の様に舗装の縦断形状の評価値として IRI(国際ラフネス指数)がある。これは平たん性値と相関がある事が明らかになっており、一例として次式で平たん性から変換して求める事が出来る⁷³⁾

$$\text{IRI} = 1.33\sigma + 0.24 \quad (2.19)$$

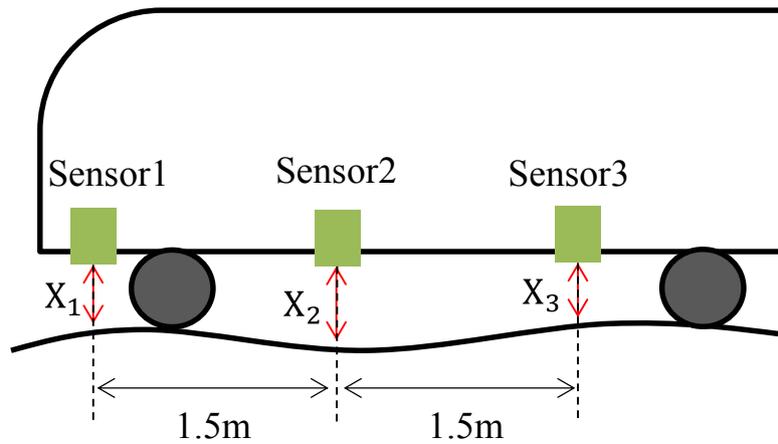


図 2-27 平たん性測定センサの配置

本研究で用いた川崎市の路面性状調査結果におけるひび割れ率，わだち掘れ量，平たん性間の相関係数を算出した結果を表 2-5 に示す．これによると相互相関係数は何れも 0.2 以下であり，それぞれの指標間には相関が無く，独立していることが解る．

表 2-5 ひび割れ率，わだち掘れ量，平たん性の相互相関係数

	ひび割れ率	わだち掘れ量	平たん性
ひび割れ率	1	0.15	0.19
わだち掘れ量	0.15	1	0.12
平たん性	0.19	0.12	1

2.4.2. 学習及び検証に用いたデータ

本章で検証に用いたデータは，川崎市が主に主要幹線道路をおよそ 3 年間隔で路線ごとに路面性状調査を行った履歴データのうち，平成 10 年から平成 27 年までの 17 年間分である．路面性状値は路面性状調査によって舗装面を評価し，ひび割れ率，わだち掘れ量，平たん性からなる路面性状値の 3 要素を舗装調査・試験法便覧⁷²⁾に従って算出することで得られる．本章では目的変数として各路面性状値を用い，3 要素それぞれの予測モデルを構築する．

川崎市の路面性状調査では，路面性状値を評価するだけではなく，舗装の補修履歴や交通センサスの大型車交通量等のデータを収集し，データベース化している．そのデータベースの中で使用したデータの概要を表 2-6 使用した説明変数に示す．川崎市のデータは基本的に 3 年間隔で調査が行われたデータを使用しているため，表 2-6 における「調査間隔」

の値は殆どが 3 である。また、観測値である前回調査時の路面性状値を説明変数に用いるため、そこからの劣化速度をモデル化する Relative Model である。

表 2-6 使用した説明変数

説明変数	前処理
補修後の経過年数	正規化
大型車交通量	
大型車累積交通量	
車道幅員	
前回調査からの経過年数	
目的変数と同じ項目の前回調査時路面性状値	
舗装厚	
CBR(路床の支持力比)	
前回調査から補修の有無	ダミー変数化
交差点の有無	
構造物(橋又はトンネル等)	
最新の補修工法	
計測装置の種類	

工事により調査が出来なかった等の理由により「調査間隔」が 3 年ではないデータは、用いたデータの 11,883 件中 561 件である。そのため、本章では実質的に 3 年後の予測精度を評価する。もし調査が不規則で行われていたデータを用いる場合には、「調査間隔」に学習データに存在する範囲で任意の値を与える事が可能である。なぜなら 2.(1)C.で述べたように NN モデルはあらゆる非線形な関数を近似する連続関数であるため、説明変数、目的変数に任意の連続値を取る事が出来るためである。例えば重原ら⁶³⁾は NN モデルのその性質を利用し、観測値が存在しない区間についても MLP モデルにより近似曲線を作成し、大型車交通量に対するパフォーマンスモデルとして用いている。また、3 年後を予測した結果から更に 3 年後を予測する場合は、前回調査時路面性状値に最初の予測結果を与える事で予測する事が出来る。

表 2-6 の補修後経過年数は最も近い補修時刻からの経過年数を意味する。一方、新設後の経過年数は説明変数に入れていない。その理由は、用いたデータは幹線道路が多いため、単位区間で新設の記録がある区間数は 102 件のみで、殆どの区間が欠損になってしまうためである。

路面性状値調査は、土木研究センターによって行われる「路面性状自動測定装置の性能確認試験」に合格した、規定の精度範囲内に収まる事が保証された装置によって調査されている。検定に合格した装置には幾つか種類があるため、計測装置の種類はその年の調査に使用した装置の種類を示す。ひび割れ率、平坦性は単位区間 50m ごとに集計されており、わだち掘れ量は 50m の平均値である。大型車交通量はその調査時刻で最新の交通センサスの調査結果を使用しており、大型車累積交通量は補修があった年から大型車交通量を積算した値である。最新の補修工法は最後に行われた補修工法(新設, 打ち替え, 切削カバー, オーバーレイ, 路上再生の何れか)を示す。

このデータに対し次の処理を行い、各モデルの学習・検証に使用した。

- I. 補修履歴に記録されていない占用工事等の影響により、補修履歴とデータに明らかに相違がある外れ値は削除した。具体的には、補修履歴は無いが 2σ 以上値が改善した区間と、補修履歴はあるが 2σ よりも値が悪化した路面性状値が存在する単位区間の履歴を、全て除外した。 2σ は路面性状値ごとに全てのデータから標準偏差を求めて 2 倍した値で、表 2-7 に示す。

表 2-7 各路面性状値の標準偏差

ひび割れ率(2σ mm)	わだち掘れ量(2σ mm)	平坦性(2σ mm)
10.28	6.4	2.343

- II. 補修後の経過年数が不明になるため、補修履歴又は新設の記録が存在しないデータを除外した。また、本研究で用いる予測モデルは **Relative Model** であり、前回調査時の路面性状値が必要なため、一度も調査されていない区間は除外した。
- III. 予測精度を評価するためには、学習に用いる学習データと、学習時には使わず検証時にのみ用いる検証データに分け、検証データに対する予測精度を評価するクロスバリデーションを行う。路面性状値の時系列情報を保持するため、単位区間ごとにグループ化し、そのグループをランダムに抽出するようにする。データベースソフトウェア PostgreSQL9.4.4 の random()関数により、単位区間数と同じ数だけ 0 以上 1 以下の一様乱数を生成し、検証データ 20%であれば、乱数が 0.2 以下の値を検証データとする。なお Postgres の乱数発生は線形合同法により乱数を求める POSIX の erand48 を Postgres に移植して用いている。それにより単位区間の 20%を検証データ、残りの 80%を学習データとした。
- IV. 表 2-6 に示すように、比例尺度のデータは平均値を減じた後に標準偏差で除算する正規化を行い、名義尺度であるデータはダミー変数化した。

これらの処理により、ひび割れ率、わだち掘れ量の学習データ数は 9,562 件、検証データ数は 2,321 件である。平坦性のデータは、平成 15 年以前は未調査のため欠損となっており、平成 16 年以降のデータを用いている。これにより平坦性のデータ数は学習データ数 7,722 件、検証データ数 1,495 件である。単位区間ごとの平均時系列数は約 3.8 である。

2.4.3. GLM のモデル選択

路面性状値の単位区間に対する回帰モデルとして従来からよく用いられており、比較的簡単な重回帰モデルを、正規分布以外の様々な指数型分布族の目的変数にも適用できるように拡張した GLM を提案手法と比較するためのベースラインとして用いた。

GLM は予測値として用いる期待値 $E(y)$ を次の一般式で表すモデルである。

$$L(E(y)) = \beta_0 + \sum_{i=1}^I \beta_i x_i \quad (2.20)$$

ここで、 $x_i (i = 1, \dots, I)$ は I 次元の説明変数、 β_0 は定数項、 β_i は各説明変数の重みパラメータである。 $L(x)$ はリンク関数と呼ばれ、本章では入力をそのまま出力する恒等リンク関数を用いている。説明変数の x_i には、表 2-6 使用した説明変数で示した通り前回調査時の路面性状値が含まれ、それを足し合わせていることから、**Relative Model** に分類される。また、正規分布では期待値の変化に伴い分布形状は変化しないが、歪がある分布では期待値の変化は分布形状の変化を伴うため、説明変数により分布形状が変化するデータのモデル化にも対応している。

GLM では説明変数中の欠損値は補完する必要があるが、欠損が 10%以上の割合になる CBR は GLM モデルでは使用しない事とし、その他の 10%以下の割合の欠損がある項目は平均値で補完した。また、前回の調査後に補修があった区間は全て除外し、補修の影響を含まないデータを用いた。その結果、GLM モデルで使用したひび割れ率、わだち掘れ量の学習データ数は 8,097 件、検証データ数は 1,952 件、平坦性の学習データ数は 5,386 件、検証データ数は 1,298 件であった。

2.4.3.1. モデル選択基準 AIC

パラメトリックモデルのパラメータを最尤推定により推定した時の予測能力を評価する方法として、AIC⁷⁴⁾が知られている。AIC は平均対数尤度を最大対数尤度で推定する事による偏りを修正した、平均対数尤度の不偏推定量で

$$AIC = -2\{(\text{最大対数尤度}) - (\text{最尤推定したパラメータ数})\} \quad (2.21)$$

により求める事が出来る。AIC は最大対数尤度と正負が逆であるため、値が小さいほど予測能力が高い。また、AIC は予測能力がより高いモデルを選択する方法であり、真のモデルを推定する方法ではない²⁶⁾。そのため、回帰モデルに適用した際には偏回帰係数は直感に反する結果になる事がある。しかし本章では予測精度の比較が目的であるため、AIC を用いて GLM のモデル選択を行う。

2.4.3.2. 各路面性状値の分布推定

各路面性状値は左右非対称な歪がある非負の連続分布であるが、それぞれ異なる確率分布に従う可能性がある。正規分布および、非負の分布を表す際によく使われるガンマ分布、ワイブル分布、対数正規分布に対して、各路面性状値の実際の分布との最尤推定によるフィッティングの結果を図 2-28 に、その最尤推定値の AIC を表 2-8 に示す。

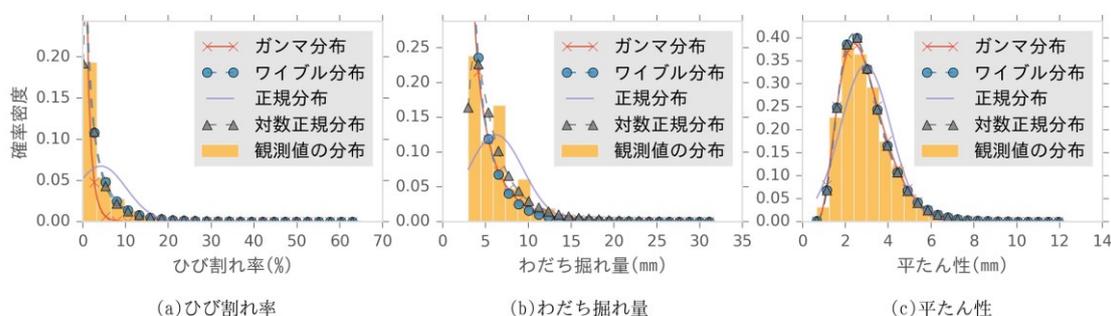


図 2-28 各路面性状値の分布

表 2-8 各路面性状値と確率密度関数ごとの AIC(太字は AIC 最小の分布)

確率分布	AIC		
	ひび割れ率	わだち掘れ量	平たん性
正規分布	48338	61296	24360
対数正規分布	35938	54110	22680
ガンマ分布	49523	5005	22718
ワイブル分布	33355	22076	22684

なお、正規分布以外の確率分布では、値が 0 である時の確率密度は定義されないため、ひび割れ率の値が 0 のデータは除き、残りの区間のみで最尤推定を行った。その結果 AIC が最も小さい分布は、ひび割れ率、わだち掘れ量、平たん性それぞれでワイブル分布、ガンマ分布、対数正規分布である。それらを GLM で最尤推定を行う際の確率分布として用いた。

2.4.3.3. AIC 最小モデルの選択結果

説明変数の組み合わせによって変化する AIC をそれぞれ求め、最も AIC の低いモデルを探索することで、最も予測能力が高いモデルを選択する事が出来る。本章では、目的変数 = (定数項) で表される一定モデルから探索を始め、使用可能な説明変数のうち、最も AIC が低下するものから追加又は削除し、AIC が低下しなくなった所でそのモデルを AIC 最小モデルとした。これにより構築した各路面性状値に対する AIC 最小モデルの標準化偏回帰係数と p 値を表 2-9 に示す。選択された殆どの説明変数が 1% 有意であった。また各路面性状のモデルはそれぞれ予測精度に影響を与える説明変数が異なり、幾つかの説明変数は全てのモデルで選択されなかった。例えば補修後経過年数の偏回帰係数が負になっているひび割れ率は、補修後経過年数が大きくなると、ひび割れ率の劣化速度が低下する事を示す。

また、わだち掘れ量の偏回帰係数は大型車交通量が多いほどわだち掘れ量の劣化速度が加速し、大型車累積交通量が多いほどわだち掘れ量の劣化速度が減速する事を示している。大型車交通量と大型車累積交通量は当然相関があるため、真のモデルを求める場合には多重共線性を考慮して除外する事が多いが、AIC は真のモデルを選択する方法ではなく予測能力が高いモデルを求める手法であるため、この様に相関の強い項目が逆の符号を持つモデルが選択される事がある。

表 2-9 GLM の AIC 最小モデルで選択された変数

前処理	目的変数	ひび割れ率		わだち掘れ量			平たん性		
	説明変数	標準化偏 回帰係数	p値	標準化偏 回帰係数	寄与率	p値	標準化偏 回帰係数	寄与率	p値
正規化	補修後経過年数	-0.004	<0.001	0.058		<0.001	0.094		<0.001
	大型車交通量	-	-	0.025		0.043	-0.049		<0.001
	大型車累積交通量	-	-	-0.062		<0.001	-0.035		<0.001
	車道幅員	-0.012	<0.001	0.036		<0.001	-0.069		<0.001
	前回調査からの経過年数	-	-	-		-	-		-
	前回調査時ひび割れ率	0.709	<0.001	-		-	-		-
	前回調査時わだち掘れ量	-	-	0.645		<0.001	-		-
	前回調査時平たん性	-	-	-		-	0.560		<0.001
	舗装厚	-	-	-0.014		0.092	-0.048		<0.001
	CBR(路床の支持力)	GLMでは使用しない							
ダミー 変数化	交差点	0.040	<0.001	0.011		0.137	-		-
	交差点手前	0.007	0.051	0.029		<0.001	-0.015		<0.001
	橋梁	-	-	-		-	-0.016		<0.001
	トンネル	-	-	-		-	-0.015		<0.001
	最新の補修工法(新設)	-	-	-		-	0.015		<0.001
	最新の補修工法(打ち替え)	0.012	0.015	-		-	-		-
	最新の補修工法(切削カバー)	0.023	<0.001	-		-	-		-
	最新の補修工法(オーバーレイ)	-	-	-		-	-		-
	最新の補修工法(路上再生)	0.014	0.517	-		-	-		-
	計測装置の種類①	-	-	-		-	-		-
	計測装置の種類②	-	-	-0.095		<0.001	0.018		<0.001
	計測装置の種類③	-	-	-0.021		0.005	-		-
定数項	0.177	<0.001	0.738		<0.001	1.594		<0.001	

2.4.4. MLP と RNN のドロップアウト率を調整した学習結果

ドロップアウトは過学習を抑制する効果がある一方、ドロップアウト率を大きくすると学習が遅くなる事が知られている。まず、わだち掘れ量に対する RNN のエポックごとの MSE の変化を、ドロップアウト率が 0 の場合と 0.3 の場合について図 2-29 わだち掘れ量 RNN モデルのエポックごとの MSE に示す。

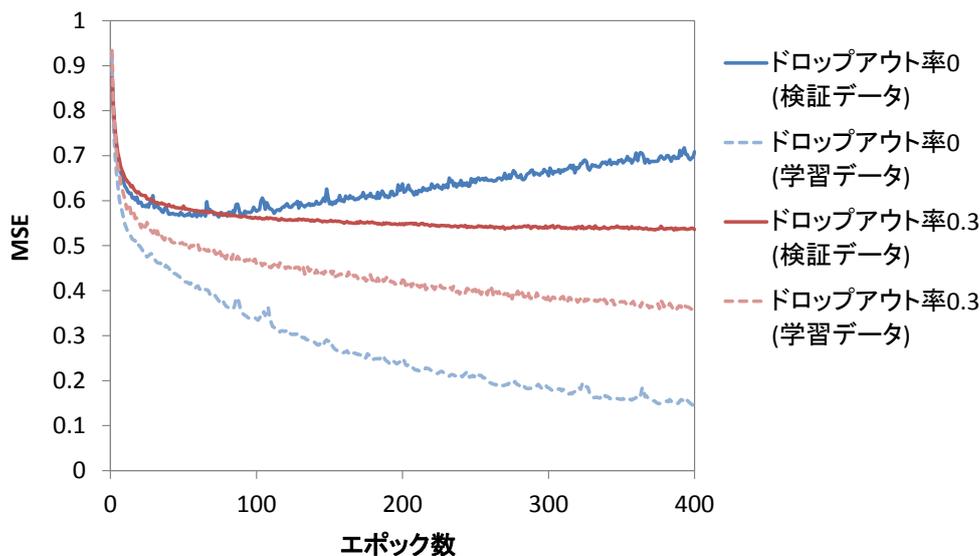
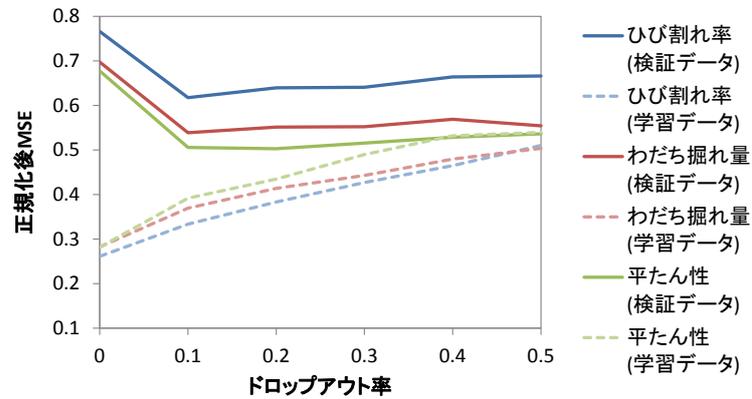


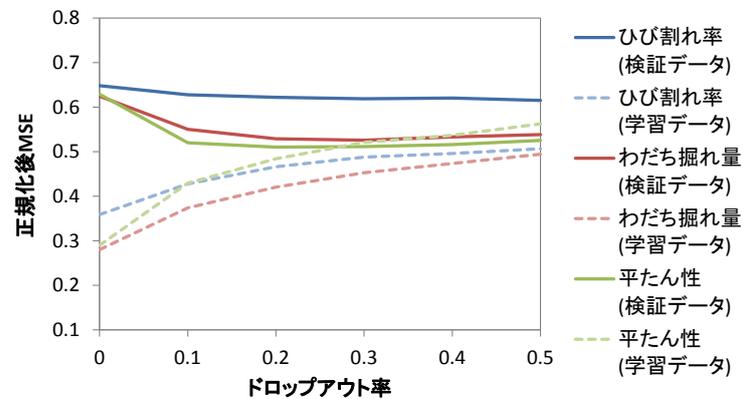
図 2-29 わだち掘れ量 RNN モデルのエポックごとの MSE

ドロップアウト率が 0 の場合は、学習が進行すると学習データの MSE は低下する一方、検証データの MSE は増加しており、学習するほど検証データに対する予測精度は低下してしまう事から、過学習に陥っていることが解る。一方、ドロップアウト率が 0.3 の場合は、エポックが進行すると検証データの MSE は低下又は横ばいであり、過学習が抑制されている。

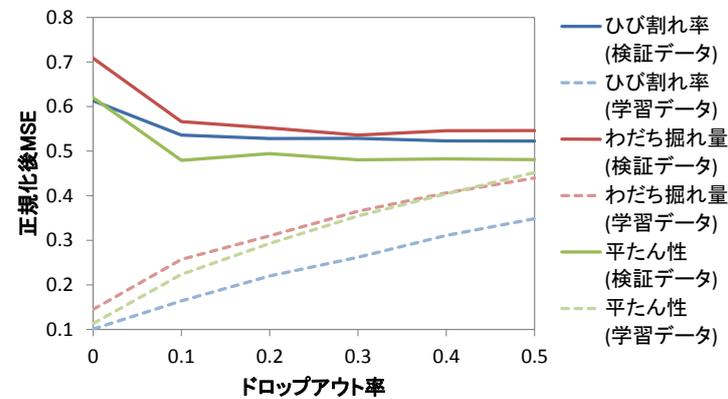
従って、ドロップアウトが過学習を抑え、予測精度を向上させるために非常に重要である事から、ハイパパラメータであるドロップアウト率について探索を行った。全くドロップアウトを行わない 0 から、半数の接続を無効化する 0.5 まで 0.1 刻みで変化させ、6 つのドロップアウト率についてそれぞれモデルを構築した。MLP, sRNN および RNN モデルの MSE を図 2-30 各モデルのドロップアウト率ごとの MSE に示す。なお、Intel Core i7 の PC で学習に掛かった時間は、RNN モデルがおおよそ 9 分、MLP モデルが 3 分である。



(a) ドロップアウト率ごとのMSE (MLP)



(b) ドロップアウト率ごとのMSE (sRNN)



(c) ドロップアウト率ごとのMSE (RNN)

図 2-30 各モデルのドロップアウト率ごとの MSE

ドロップアウト率0の場合と比較し、ドロップアウト率が0.1以上の場合は、MLP, sRNN, RNN 全てで過学習が抑制され、予測精度が向上している事が解る。ドロップアウト率が大きいほど検証データと学習データに対する MSE の差は小さくなり、過学習を抑制する効果が強くなる。この結果から求めた路面性状値ごとに最も予測精度の高いドロップアウト率を以降のモデル間の比較では用いた。モデルごとに最も予測精度が高いドロップアウト率

および、使用したその他のハイパパラメータは表 2-10 に示す。

表 2-10 各モデルのハイパパラメータの設定値

項目	MLP	sRNN	RNN
ドロップアウト率 (ひび割れ率)	0.1	0.5	0.5
ドロップアウト率 (わだち掘れ量)	0.1	0.3	0.3
ドロップアウト率 (平たん性)	0.2	0.2	0.1
学習率	0.001		
エポック数	400		
ミニバッチサイズ	100		
中間層数	2 層		
中間層の ニューロン数	70		

2.4.5. モデル間の予測精度比較

GLM, MLP, sRNN, RNN の 4 つのモデルで、路面性状値ごとに、調査履歴を考慮する事による予測精度の差を求めるため、最終的な各モデルの MSE の平方根を求め、正規化を元に戻す事で解釈しやすくした RMSE と、相関係数を算出した結果を表 2-11 に示す。

表 2-11 各モデルの検証データに対する RMSE の比較

路面性状値	GLM		MLP		sRNN		RNN	
	RMSE	相関係数	RMSE	相関係数	RMSE	相関係数	RMSE	相関係数
ひび割れ率(%)	4.62	0.64	4.04	0.69	4.08	0.69	3.74	0.74
ひび割れ率のGLMに対する RMSEの減少率(%)	-	-	0.13	-	0.12	-	0.20	-
わだち掘れ量(mm)	2.51	0.67	2.34	0.70	2.32	0.70	2.27	0.72
わだち掘れ量のGLMに対す るRMSEの減少率(%)	-	-	0.07	-	0.08	-	0.10	-
平たん性(mm)	0.88	0.60	0.83	0.65	0.85	0.62	0.78	0.71
平たん性のGLMに対す るRMSEの減少率(%)	-	-	0.06	-	0.05	-	0.12	-

RMSE は予測誤差を表す事から、値が小さいほど予測精度は高い。従って、予測精度は路面性状値の 3 要素全てで RNN>MLP>GLM の順に高い。sRNN については MLP と同様に調査履歴を考慮しない NN モデルであるため、sRNN と MLP 間の RMSE の差は小さく、過去

の履歴を考慮しない NN モデルによる予測誤差を示していると考えられる。最も RMSE が小さい RNN の、観測値と予測値間の相関係数はひび割れ率 0.74, わだち掘れ量 0.72, 平坦性 0.71 と強い相関が認められた。

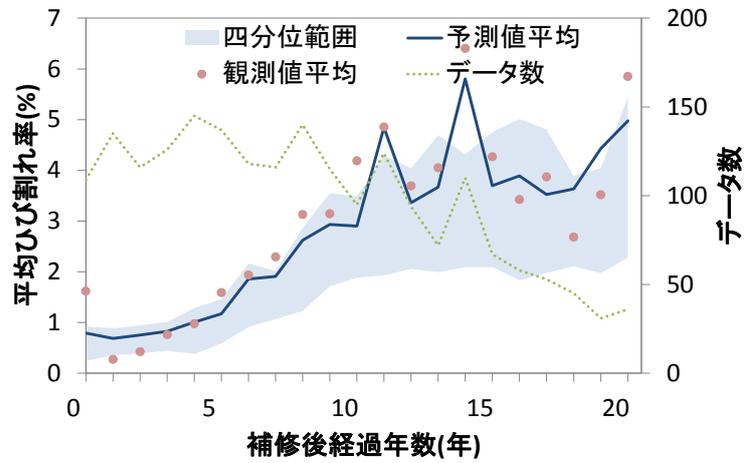
ベースラインである、目的変数と説明変数間の関係を線形と仮定する GLM に対して、非線形な関係や相互作用等を考慮できることによる MLP の RMSE の減少率は、ひび割れ率 13%, わだち掘れ量 7%, 平坦性 6% となり、ひび割れ率が最も RMSE が減少した。また、調査履歴データを考慮する事により RMSE が減少する分を反映した、MLP と RNN 間の RMSE の減少率の差は、ひび割れ率 7%, わだち掘れ量 3%, 平坦性 6% 程度であった。

非線形性および全ての相互作用を考慮する事と、過去の履歴を考慮する事による RMSE の減少率は、両方ともひび割れ率が最も大きく、結果として RNN により 20% 程度 RMSE が改善した。この理由として、ひび割れ率は最も非線形性の高い変化をすることが考えられる。ひび割れ率の値は補修直後には殆どが 0% になり、その後しばらくは 0% の状態が続く。しかし一度ひび割れが発生すると、そこから舗装内に水が浸入することや、応力集中により、急速にひび割れが広がる傾向にある⁷⁵⁾。従ってひび割れ率は非線形性の高い変化が予想される上に、過去のひび割れ率の変化により大きく変わるため、最もひび割れ率の予測精度が向上したと考えられる。

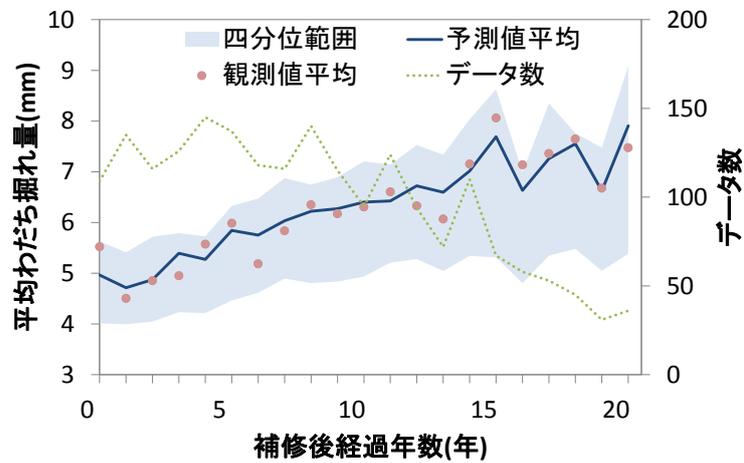
また、平坦性の相関係数は、全てのモデルにおいてひび割れ率、わだち掘れ量の相関係数と比較し 0.01~0.08 程度小さいが、これは平坦性のデータ数がひび割れ率、わだち掘れ量のデータ数よりも少ないため、十分に特徴を学習する事が出来なかった可能性がある。

2.4.6. RNN によるパフォーマンスカーブ

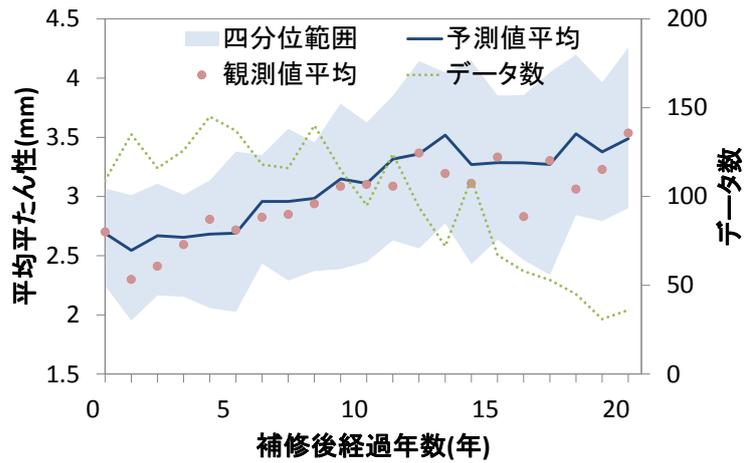
最も予測精度が高い RNN で、横軸に補修後経過年数、縦軸に各路面性状値の平均値をプロットしたパフォーマンスカーブに相当する曲線を図 2-31 に示した。四分位範囲は予測値の四分位範囲である。なお、ここで用いているデータは試験データでかつ補修後経過年数が 20 年以内のみの 2,042 件であり、各補修後経過年数当りのデータ数は約 30~100 件であるため、単位区間ごとのばらつきの影響を受けて平均値が滑らかになっていない。補修後経過年数が大きい長期間補修されていない区間は少ないため、経過年数が大きくなるとデータ数は急速に減少しており、その影響で平均値の信頼性が下がるため、ここでは 20 年までのデータを示した。



(a) ひび割れ率



(b) わだち掘れ量



(c) 平たん性

図 2-31 路面性状値の平均値の予測

これによると、学習に使用していない試験データでも観測値平均に近い予測が出来ている事が解る。(a)から(c)の各路面性状値で異なる点は予測値平均と四分位範囲のずれである。特にひび割れ率、次にわだち掘れ量のずれが大きく、一部のひび割れ率が特に大きい単位区間の影響を受けて平均値が正方向に偏る。その一方、平たん性は殆ど平均値と四分位範囲のずれがない。その様な路面性状値ごとに全く異なる分布を同じ構造のモデルで予測出来る事が解る。

一方で各路面性状値に共通する特徴として、補修の年に調査を行った場合に相当する補修後経過年数が 0 年の区間で、不連続に観測値が大きい。この原因は、調査年度と補修年度が同じ場合には補修後経過年数が 0 年になるが、本章で用いた補修履歴の記録単位が年度であるため、補修前後のどちらに調査が行われたのか不明である事による影響が大きい。このような偏りのある誤差はランダムなばらつきを表す偶然誤差ではなく系統誤差に分類される。路面性状値は値のばらつきに対する偶然誤差のばらつきが大きく⁷⁶⁾、偶然誤差と系統誤差を分離する事は困難である。その場合において系統誤差を減少させるには、系統誤差の原因を観測する必要があるが、過去のデータであるためそれは不可能である。

過去のデータに含まれるその様な観測されない要因は、特に新しい対策を行わない限り今後の路面性状調査結果にも含まれると考えられる。例えば補修が無いにも関わらず路面性状値が改善した区間は取り除いて解析する事例⁷⁷⁾もあるが、その様な場合一部に手を加えた観測値に対する予測モデルおよび予測精度であるため、実際に得られた観測値に対する予測精度を表すことにならない。そのため、本章では観測値に影響を及ぼす観測不可能な要因が他にも多数含まれる事を前提とし、予測精度を評価している事を注意する必要がある。表現力の低い従来のモデルでは、このような局所的な外れ値が全体の予測に影響するパラメータの推定に影響を与えるため、予測値全体に影響を与える可能性が高い。しかし、本章で用いた NN モデルは表現力が高いため、このような局所的な外れ値は局所的な予測値に影響を与えるのみである。実務で NN モデルを用いる際には、補修後経過年数が 0～1 年辺りの予測値を使わないようにするか、明らかな外れ値を補正する事が考えられる。後者の場合には、単位区間ごとに異なる管理の実情を反映した妥当性のある外れ値除去手法を各管理主体、管理事務所と十分に議論を行って合意し、妥当性のある外れ値除去処理を行う必要がある。

また、各路面性状値について観測値平均が単調増加とならず、増減している箇所がある。その様な箇所は A)観測値平均と予測値平均の偏りが合っている箇所(例えばわだち掘れ量の補修後経過年数 15 年)と、B)観測値平均と予測値平均の偏りが異なる箇所(例えばわだち掘れ量の補修後経過年数 7 年)に分類できる。A)の場合、その補修後経過年数に調査された単位区間の観測値にその偏りがある事を表しており、次に示す 2 点の要因が考えられる。

I. 本章で用いたデータは路線ごとに 3 年間隔で調査しているため、同じ補修後経過年数

のデータには同じ路線の単位区間が多く含まれる。そのため、路面性状値が特に悪い(又は良い)路線があった場合、それらすべてが同じ補修後経過年数であるため、平均値に大きく影響を与える事になる。

- II. A)の該当箇所はデータ数が急速に減少する補修後経過年数 10 年以降が殆どで、データ数が少ないため I.による偏りが平均値に影響を与えやすい。一方で B)の場合は、観測値平均と予測値平均が異なるため、予測できない年ごとの偏りがある事を示唆しており、次に示す 3 点の要因が考えられる。
 - I. 調査した年ごとに調査、解析の装置及び担当者が異なるため、年ごとに異なる偏りが生じる可能性がある。
 - II. 部分的に占用工事中のため未調査箇所がある事や、応急処置により局所的に補修された箇所、路線の改変により対象の単位区間自体が実際は異なっている事、等の可能性がある。
 - III. 調査を行う装置はレーザー等の光学機器を用いているため、調査した時の気象条件、舗装の状態によって偏りが生じる可能性がある。

I.による偏りを減少させるためには調査、解析処理の自動化を進め、厳格に規定する事が考えられる。しかし、その様な義務付けを行ったとしても、将来的により低コストで精度の高い調査方法、解析方法が現れ、その度に変更する必要がある上に、予算規模の異なる管理主体に対して一律に適用する事が難しい。従って、その様な厳格な規定より、計測装置や解析方法の情報に誤りが無い事のみを規定した上で、その情報を記録しておく事が重要である。提案手法はその様な詳細な情報を説明変数に加える事で、装置や解析方法の違いを考慮して予測を行う事が可能である。

II.については、占用工事や路線の改変等を無くすことは不可能であるため、その情報を詳細に記録し、モデルで扱えるようにしておくことが重要である。特に現在は 200m~50m 程度の区間内のデータを集約して単位区間としているが、現実的にはその中には様々な箇所が混在している。その様な比較的長い距離で単位区間を設けている理由は、従来の技術レベルでは 1m 等の短い距離で調査、記録を残す事が容易ではなかったためである。しかし、現在の技術レベルでは情報の取得、記録を自動化し、より詳細な短い単位区間で詳細な情報を蓄積する事は比較的容易である。提案手法はその様な詳細情報を説明変数に加える事で、単位区間の違いを考慮したうえで予測を行う事が可能である。

III.についても上記と同様に調査を行った装置の詳細、気象条件等の詳細情報を自動的に記録するようにしておき、それを提案モデルの説明変数に追加する事でそれらによる影響を考慮する事が可能になる。

この 3 点に共通する事は、従来と比較し現在の技術レベルではより詳細な記録の蓄積が容易になっているため、詳細なデータを自動的に収集、記録する事の重要性である。また、

データが記録されていても容易に利用できなければ意味がないため、それらのデータを横断的に同じデータベースに記録し、全ての情報を容易に参照できるようにする必要がある。それにより、提案手法は特徴をデータから学習できるため、その様により詳細なデータがある事で、劣化予測に対する影響を考慮する事が可能である。

2.5. 小括

本章では、舗装の効率的な維持管理計画策定のために、グループ化した路線の平均的な変化を示すパフォーマンスモデルではなく、単位区間の予測を行う予測モデルとして、路面性状値の3要素の予測手法を提案した。提案手法は予測精度を向上させるために、ADAM およびドロップアウトを導入した、最も基本的な NN モデルである MLP モデルと、時系列をモデル化できる RNN モデルの2つのモデルによる舗装劣化予測手法である。提案手法を川崎市の平成10年から平成27年の路面性状値の履歴に適用した結果、恒等リンク関数を用いた GLM モデルよりも、MLP モデルの方が予測精度は高かった。更に、MLP モデルよりも、RNN モデルを用いる事により、更に予測精度が向上することが解った。最も予測精度に差があった GLM モデルと RNN モデル間で、ひび割れ率における RMSE の減少率は、およそ20%であった。

結果として、ひび割れ率、わだち掘れ量、平坦性全てにおいて、RNN モデルを用いて過去の全ての履歴を考慮する事で、最も精度高く予測できることが明らかとなった。また、路面性状値の3要素の異なる分布を同じ構造のモデルで学習できることが解った。その NN モデルのデータから特徴を学習できるという性質から、本手法を様々な社会資本に対して適用する事や、近年注目されている IoT センサやプローブカーデータ等の多様なビッグデータを入力データに加えたモデル化も容易であり、精度の高い管理単位区間ごとの社会資本に対する将来予測が可能になる。

3

第3章 舗装劣化予測モデルの将来予測精度評価方法論の構築と検証

* * * * *

本章では、第2章の検証から得られた課題の1つを取り扱う方法論を構築、検証する。舗装等の構造物は寿命が数十年と長いためデータ取得期間が長期に渡り、データの時間密度が低いなど、リカレントニューラルネットワークモデルが通常適用される音声や文字データとは異なる特性がある。そのため、データ取得期間中に舗装材料、点検方法、法令等による変化が発生するため、過去のデータと将来のデータが同じ母集団に従うと考える事は現実的ではない。本章では、そのことを考慮してモデルの試験を行うタイムスライスクロスバリデーション手法を構築する。リカレントニューラルネットワークモデルに構築した手法を用いると、過学習を抑制する事で、将来に対する予測精度を向上できることが解った。

* * * * *

3.1. 舗装劣化予測モデルの予測精度評価方法

前章で論じたように RNN を用いた劣化予測モデルの有効性を確認できたが、点検の精度や記録されていない劣化要因等により予測精度の向上には限界がある。しかし、予測精度を精確に求める事ができれば、その精度範囲内のばらつきを許容する事で、単位区間に対する予測を用いた維持管理の効率化が可能になる。

しかし、舗装などの社会資本の点検データは期間が数十年と長期に渡り、時間スケールが長い。そのため、その間に舗装の素材、施工の要領や要綱、点検方法等が変化する。従って、過去と将来のデータが同じ母集団から生じたデータだと仮定する事は無理がある。予測精度の評価を第 2 章で用いた通常のカロスバリデーションで行った場合、長い時間スケールによる変化が原因の予測精度低下が反映されていない事になる。従って、通常のカロスバリデーションによる予測精度評価は予測能力を過大評価する事になる。その様なモデルによる予測結果を元に維持管理計画を策定した場合、効率化にならない施策を選択する可能性が高い。そのことはまた、現場技術者の感覚と劣化予測結果の乖離の要因でもある。更に、従来の劣化予測モデルでは定量的な予測精度評価が行われていないか、それぞれ異なる方法により評価されている。そのような場合、様々な劣化予測モデルのどの方法が最適か、判断が難しいという課題がある。この節ではこれらの点について着目し、舗装の単位区間に対する現実的な予測精度を評価する手法を提案する。

従来、マルコフチェーンモデルや重回帰モデルによる舗装劣化予測モデルは、パフォーマンスモデルとして構築されている。パフォーマンスモデルは、2.1 で論じたように全てのデータを学習データとしてモデルのパラメータ推定(学習)に用いて、大型車交通量か、補修又は新設後の経過時間に対して、評価単位区間を任意にグループ化したグループ全体の平均的な状態変化(パフォーマンスカーブ)を示すモデルである。そのため舗装の単位区間の予測には適さないが、グループ間の違いや、グループの平均的な変化の予測、中長期的な予測、説明変数の重みの程度を把握する事に用いられる。

それに対し多くの説明変数とパラメータを用いた、複雑で自由度の高いニューラルネットワーク(NN: Neural Network)のようなモデルでは、単位区間の予測を行う事が可能である。しかし、学習に使用したデータの再現は容易である一方、学習データに過適合する事で、未知のデータの予測精度が低下する過学習という問題がある。過学習を検知・抑制するために、学習データと試験データを分けるカロスバリデーション(Cross-Validation)による予測精度評価が行われる。

前者のパフォーマンスモデルは、全てのデータを学習に用いて、学習データの平均的なパフォーマンスを表現できる事に重点が置かれているため、学習に用いていない未知のデータに対する予測精度の評価は行われぬ。また、RNN 等の時系列予測モデルが主に適用

されている文字データや音声データが持つ時系列情報は、開始から終了までの相対的な時系列である。従って複数のデータ間が完全に独立しているため、学習データと試験データをランダムに分割する通常のカロスバリデーションで予測精度の検証が可能である。それに対し、本研究で対象とするような点検データの時系列情報は、全てのデータが現実の時間という絶対的な時系列情報を持つ。そのため、時系列点検データの予測モデルを実運用で用いる際には、ある時刻までのデータを学習し、そこまでの情報だけを元に、それ以降の時刻を予測する事になる。つまり、実運用上は予測を行う時刻の情報は一切学習していない状態で予測を行う必要がある。しかし、絶対的な時刻情報を持つ点検データでは、文字データや音声データのように通常のカロスバリデーションによりランダムに学習データと試験データに分割すると、精度評価を行いたい、予測する時刻の情報も学習する事になってしまう。

また、点検データの予測精度評価が劣化予測モデルにより異なると、どのような場合にどの劣化予測モデルが最適であるのか、相互比較が不可能であるという課題がある。それらの事から、舗装の単位区間に対する点検データ履歴を時系列データと捉え、モデル横断的に評価可能で、かつ現実的な将来の予測精度を評価する方法が必要である。

以上の問題認識から、本章は学習データと試験データを時系列方向に分離する手法により、点検データに対する現実的な予測精度を評価するタイムスライスクロスバリデーション手法を提案する。

3.2. タイムスライスクロスバリデーション手法の提案

本章で提案するタイムスライスクロスバリデーション手法は、舗装点検データの特性を考慮して、舗装劣化予測モデルの予測精度を求める際に必要なデータの分割方法を決定し、それを用いてクロスバリデーションを行う手法を提案するものである。従って予測する舗装点検データと予測モデルの種類は問わない事から、用いるデータを \mathbf{D} 、予測モデルを $\mathbf{y}(\mathbf{x})$ と抽象化して説明を行う。

3.2.1. パフォーマンスモデル

共通する時刻情報 $t (t=1,2,\dots,T)$ を持つ点検結果データの時系列を列方向に、舗装の単位区間 $i (i=1,2,\dots,I)$ を行方向に持つデータを全て並べた入力データ行列

$$\mathbf{D} = \begin{bmatrix} \mathbf{x}_{1,1} & \mathbf{x}_{1,2} & \dots & \mathbf{x}_{1,T} \\ \mathbf{x}_{2,1} & \mathbf{x}_{2,2} & \dots & \mathbf{x}_{2,T} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{I,1} & \mathbf{x}_{I,2} & \dots & \mathbf{x}_{I,T} \end{bmatrix} \quad (3.1)$$

があるとする。実際の点検データは、例えばある時刻に路線の延伸により増加した箇所はそれ以前の情報が無い等、全ての箇所共通する時刻情報を持つわけではないが、ここでは説明の便宜上このように示す。

2.1 で定義したパフォーマンスモデルは \mathbf{D} 全体を用いてモデルの学習を行う。 \mathbf{D} を学習する事で得たモデルの推定パラメータ (NN では結合荷重パラメータ) を並べたベクトルを \mathbf{w}_D とする。用いるモデルを予測関数として $\mathbf{y}(\mathbf{x})$ で表すと、パフォーマンスモデルは $\mathbf{y}(\mathbf{D}, \mathbf{w}_D)$ と書ける。これは、 \mathbf{w}_D の推定に \mathbf{D} を用い、パフォーマンスの予測精度評価も \mathbf{D} で行う事を表し、後述する過学習の抑制と現実的な予測精度の評価が困難である。

3.2.2. 従来手法のクロスバリデーションによるハイパパラメータの探索と過学習の検証

それに対し、NN モデルで行われる一般的なクロスバリデーション(従来手法)では、次のように行方向(単位区間方向)にデータを分割する。 $r\%$ を試験データ \mathbf{D}_T 、残りを学習データ \mathbf{D}_L とすると、

$$\mathbf{D} = \begin{bmatrix} \mathbf{D}_T \\ \mathbf{D}_L \end{bmatrix} = \begin{bmatrix} \mathbf{x}_{1,1} & \mathbf{x}_{1,2} & \cdots & \mathbf{x}_{1,T} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{l,1} & \mathbf{x}_{l,2} & \cdots & \mathbf{x}_{l,T} \\ \hline \mathbf{x}_{l+1,1} & \mathbf{x}_{l+1,2} & \cdots & \mathbf{x}_{l+1,T} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{L,1} & \mathbf{x}_{L,1} & \cdots & \mathbf{x}_{L,T} \end{bmatrix} \quad (3.2)$$

ここで、 $l = r/100 \times L$ である。

これらを用いて、検証で用いる NN モデルの場合のクロスバリデーションのフローを図 3-1 に示した。

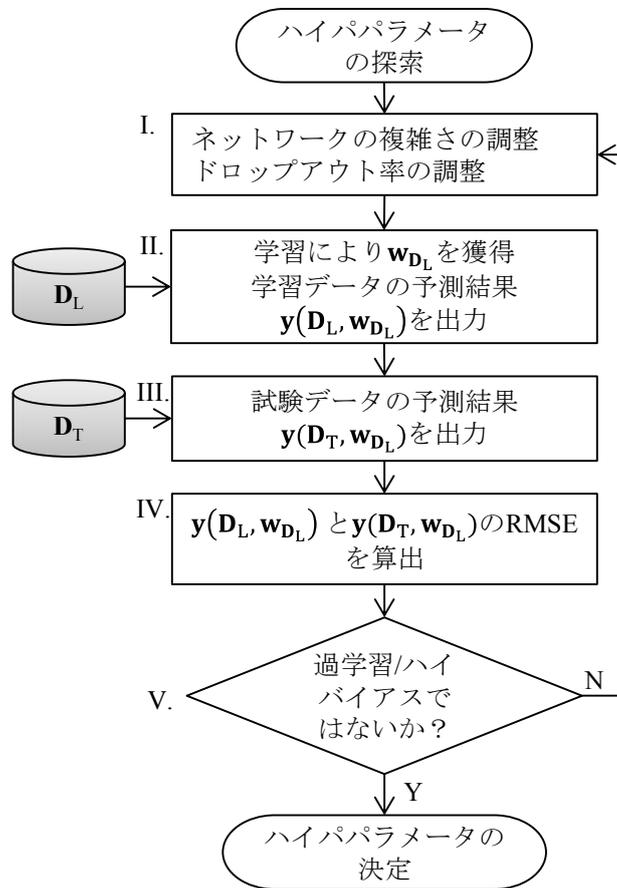


図 3-1 RNN モデルのハイパパラメータ決定フロー

- I. 学習に用いるハイパパラメータを決定する。過学習を抑制するのであれば、モデルの実質的な自由度を下げれば良いから、ニューロン数を削減するか、ドロップアウト率を上げる。そのように過学習を抑制し過ぎると、今度は予測精度が低下する(ハイバイアス)トレードオフの関係にあるため、過学習せず、予測精度が最大のハイパパラメータを探索する。

- II. まず \mathbf{D}_L を用いて結合荷重パラメータ行列 \mathbf{w}_{D_L} を推定(学習)する. 学習済みのモデルによる, 学習データの予測関数は $\mathbf{y}(\mathbf{D}_L, \mathbf{w}_{D_L})$ と書く事が出来る.
- III. 学習済みの結合荷重パラメータ \mathbf{w}_{D_L} を用いて, RNN モデルにより試験データの予測を出力する. 予測関数は, $\mathbf{y}(\mathbf{D}_T, \mathbf{w}_{D_L})$ である.
- IV. 予測精度を表す指標として学習データと, 試験データで別々に, 次の 2 乗平均平方根誤差(RMSE : Root Mean Square Error)を求める. 試験データの場合, RMSE は次式から求められる.

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{m=1}^M (y_m - d_m)^2} \quad (3.3)$$

ここで, $y_m (m = 1, 2, \dots, M)$ は $\mathbf{y}(\mathbf{D}_T, \mathbf{w}_{D_L})$ の予測値の 1 つ, d_m は y_m に対応した点検結果の実測値である. この RMSE は誤差を表すため, 値が小さいほど予測精度は高い事を示す.

- V. RMSE の結果から, 過学習及び予測誤差のハイバイアスは図 3-2 のように判断できる. 学習繰り返し回数が増加するほど学習データの RMSE は低下する一方, 試験データの RMSE が増加する場合, 過学習により予測性能が低下していると判断する. 過学習は発生していないが, 様々なハイパパラメータの下で学習を行った試験データの RMSE が, 相対的に高ければ, ハイバイアス状態だと判断する. もし過学習又はハイバイアスであれば, A. からもう一度処理を行う. それらの問題が発生していなければ, そのハイパパラメータを採用する.

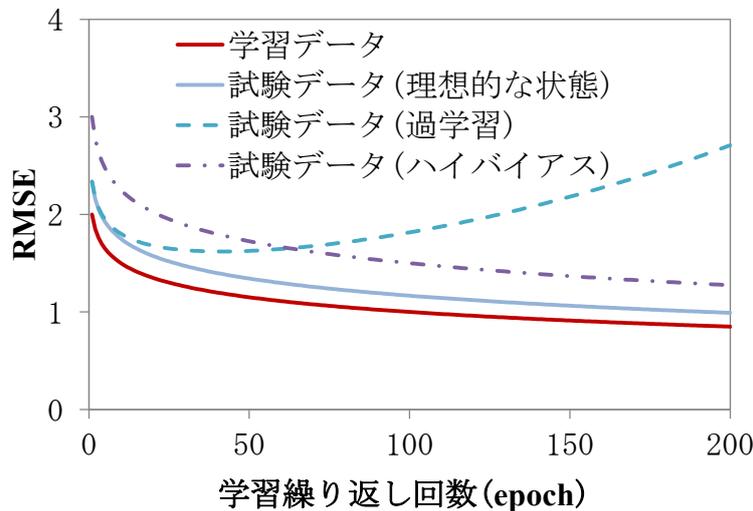


図 3-2 過学習とハイバイアスの検知

これにより決定したモデルの, 試験データに対する RMSE をモデルの予測精度とする.

なお, 実際は学習データと試験データは, それぞれのデータ内で学習毎にランダムに並

び替えるが、本稿では説明の簡単の為省略した。

3.2.3. 提案手法の必要性

提案手法の必要性は次の通りである。

- I. 点検データは全てのデータで共通する時刻情報を持つ。予測モデルの実運用時には、将来時刻の観測不可能な情報は完全に未知の状態、将来を予測する。提案手法で仮想的に過去のデータ \mathbf{D}_p と将来のデータ \mathbf{D}_f に分ける事で、より実運用に近い現実的な予測精度の評価を行う事が可能である。
- II. 仮想的な将来の時刻のデータを学習に用いる事が不適である理由は次の通りである。舗装の点検結果は、点検装置の変更、装置のキャリブレーションの状態、点検担当者の個人差等により系統誤差が変化する。また舗装の劣化自体が舗装の素材、交通量の変化、施工基準等により変遷する。将来を予測する上で、その様な観測不可能な変数の変化は現時刻で未知のはずである。それらの情報を含む将来のデータを学習すれば、予測精度は当然良くなるが、実運用上は不可能であるため、予測精度を過大評価する事がある。
- III. RNN モデルのクロスバリデーションは、前項で述べた通り学習データと試験データの RMSE よりハイパパラメータを調整し、過学習とバイアスのバランスが取れるようにする。将来予測に適用する上で、様々な未知の変化を含む将来の状態に対して最適なハイパパラメータを決定する必要がある。

3.2.4. 提案するクロスバリデーション手法

本章で提案するクロスバリデーション手法は、前項の従来手法が \mathbf{D} を行方向(単位区間方向)に分割して \mathbf{D}_L 及び \mathbf{D}_T を作成した事に対して、次のように列方向(時刻方向)に分割し、同様の評価を行うタイムスライスクロスバリデーションと称す。

$$\mathbf{D} = [\mathbf{D}_p \quad \mathbf{D}_f] = \begin{bmatrix} \mathbf{x}_{1,1} & \cdots & \mathbf{x}_{1,s} & \mathbf{x}_{1,s+1} & \cdots & \mathbf{x}_{1,T} \\ \mathbf{x}_{2,1} & \cdots & \mathbf{x}_{2,s} & \mathbf{x}_{2,s+1} & \cdots & \mathbf{x}_{2,T} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \mathbf{x}_{I,1} & \cdots & \mathbf{x}_{I,s} & \mathbf{x}_{I,s+1} & \cdots & \mathbf{x}_{I,T} \end{bmatrix} \quad (3.4)$$

ここで、 s は任意の時刻であり、用いるデータにより決定する。 s を仮想的に現在と考えると、 $t \leq s$ の \mathbf{D}_p は過去の点検結果データと考える事が出来る。従って、モデルは \mathbf{D}_p により学習を行い、精度の評価は仮想的な将来のデータ($t > s$)である試験データ \mathbf{D}_f により行う事で、実運用時に近い予測精度の評価が可能である。本提案手法のデメリットは、予測したい時刻以上の時系列数が必要である点である。例えば1年間隔で点検されており、5年後までの予測精度を評価したい場合、 $s = (T - 5)$ に設定する必要があるため、少なくとも5年以

上の点検時系列データが必要である.

3.3. 提案手法の検証

3.3.1. 検証に用いるデータの前処理

本節では前章と同様に川崎市の路面性状調査を検証に用いた。違いは表 3-1 に示すように、路面性状値の中でもわだち掘れ量のみを検証対象としている事と、前後 KP のわだち掘れ量及び、該当の単位区間の最大わだち掘れ量も説明変数に用いている事である。また、前章では用いた計測装置の種類は今回用いていない。その理由は、検証に用いる 2006 年以降に新しく用いられるようになった計測装置は、学習データとして用いる 2006 年以前には存在しないため、その傾向を全く学習できない。その場合、信頼性のある予測を出力する事が出来ないと考えられる事から、本章では用いない。

調査は殆どの単位区間において 3 年間隔で行われているため、予測を行う際には、ある時刻の実測値を元に、予測年数に指定された年数後の予測値を出力する。RNN は過去のデータを全て用いて現時刻の予測を行うため、予測する対象のその時刻までの履歴を全て用いて、予測年数後(3~9 年後)の予測を行った。

表 3-1 入力データ項目

説明変数	前処理
補修後の経過年数	正規化
大型車交通量	
大型車累積交通量	
車道幅員	
予測対象区間の平均わだち掘れ量	
前後KPの平均わだち掘れ量	
予測対象区間の最大わだち掘れ量	
前後KPの最大わだち掘れ量	
予測年数	
舗装厚	
CBR(路床の支持力比)	ダミー変数化
前回調査から補修の有無	
交差点の有無	
構造物(橋又はトンネル)	
最新の補修工法	

3.3.2. 外れ値の除去

補修された箇所とされていない箇所では当然分布が異なるため、補修の記録がある箇所と無い箇所を分け、それぞれで平均わだち掘れ量の年あたりの変化量の上下 5 パーセンタイルを除去した。処理後の学習・試験・検証に用いた点検結果データ数は 47,553 件である。外れ値除去後のわだち掘れ量データの平均値は 6.39mm, 標準偏差は 3.20mm, 25 パーセンタイルは 4mm, 50 パーセンタイルは 6mm, 75 パーセンタイルは 8mm である。なお、記録最小単位が 1mm であるため、1mm 単位のパーセンタイル値となる。

3.3.3. 従来手法との比較による検証

3.3.3.1. 従来手法と比較するためのデータ分割

舗装の設計寿命は通常 10 年であり、本章で用いた殆どの点検時系列データのサンプリング間隔は 3 年である。NN は連続関数であるため、実測値が存在しない時刻についても、学習している 9 年後までの連続値を予測年数に与える事により、近似曲線として予測できる。重原ら⁶³⁾はその性質を利用して限られたデータから大型車交通量に対するパフォーマンスカーブの近似曲線を求めている。しかし、点検が行われておらず実測値が無い時刻では予測精度の評価が不可能であるため、本章では実測値がある 3 時系列分、9 年後までの予測精度の評価を行った。従って最新の調査結果が 2015 年である事から、 s は 9 年前の $s = 2006$ とした。

本章のように 1 万件以上の十分なデータ数がある場合、学習データと試験データの分割は、予測精度のばらつきを抑え、かつ学習データも出来るだけ多く確保するために、試験データを 1~3 割、残りを学習データとする事が多い。本来は時系列方向に試験データ、学習データの 2 つに分割する前述の提案手法が良いが、ここでは一般的なクロスバリデーション(従来手法)と比較するため、図 3-3 に示すようにデータを 4 分割した。

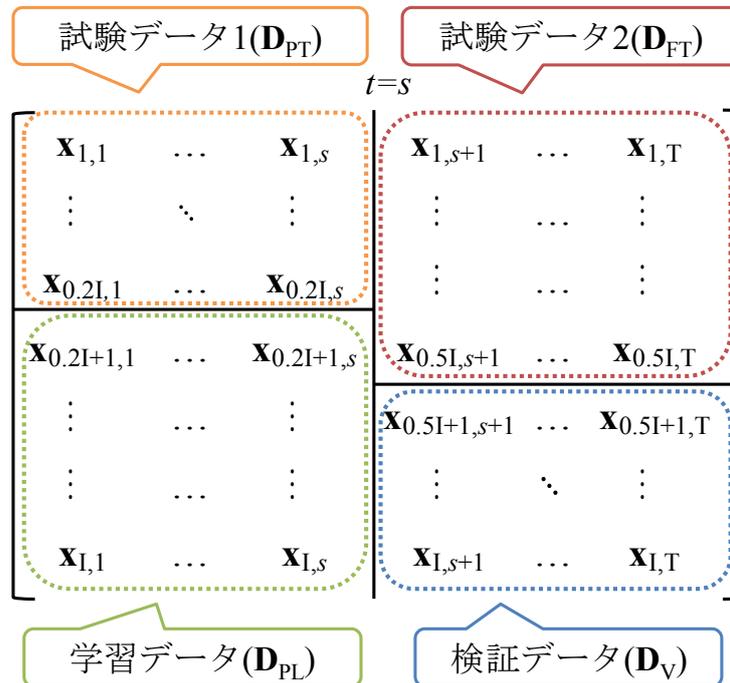


図 3-3 従来手法と比較するためのデータ分割

学習データ \mathbf{D}_{PL} は、 $t \leq 2006$ の条件下でランダムサンプリングされた 80%とした。従来手法と提案手法は全く同じ \mathbf{D}_{PL} を学習する。従来手法と提案手法の違いは試験データの違である。従来手法は試験データとして、 $t \leq 2006$ の、学習データに使用しない残りの 20%、 \mathbf{D}_{PT} を用いる。従って、 \mathbf{D}_{PT} に対する RMSE が従来手法による予測精度評価である。一方、提案手法は試験データとして、 $t > 2006$ のデータを 50%ランダムサンプリングした \mathbf{D}_{FT} を用いるため、 \mathbf{D}_{FT} に対する RMSE が提案手法による予測精度評価になる。それらとは別に、学習・試験時にも用いない独立した検証データ \mathbf{D}_V として、 $t > 2006$ の残りの 50%を用いた。

RNN モデルは前述の通りクロスバリデーションによりハイパパラメータが変わるため、従来手法の試験データ \mathbf{D}_{PT} を用いて構築したモデルを ModelC、提案手法の試験データ \mathbf{D}_{FT} を用いて構築したモデルを ModelP とした。

3.3.3.2. 従来手法と提案手法の比較

ModelC、ModelP のハイパパラメータを表 3-2 に、それらのモデルによる \mathbf{D}_{PT} 、 \mathbf{D}_{FT} 、 \mathbf{D}_V を予測した結果から算出した RMSE を、予測年数ごとに図 3-4～図 3-6 に示した。

学習の効率化のために、学習率を自動的に調整する効果がある ADAM¹²⁾を用いた。簡単のため中間層のニューロン数は 2 層の中間層で同一である。

表 3-2 モデルのハイパパラメータ

項目	ModelC	ModelP
学習率	0.002	0.002
学習繰り返し回数 (epoch)	100	100
ミニバッチサイズ	50	50
ドロップアウト率	0.5	0.5
中間層数	2層	2層
中間層の ニューロン数	30	7

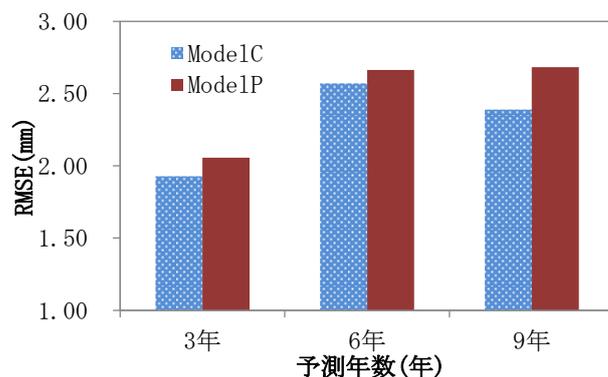


図 3-4 D_{PT} に対する予測年数ごとの RMSE

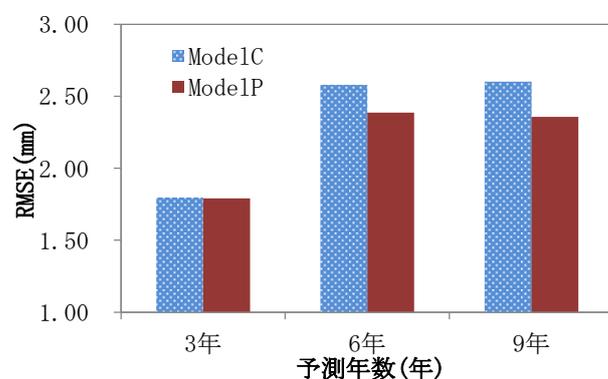


図 3-5 D_{FT} に対する予測年数ごとの RMSE

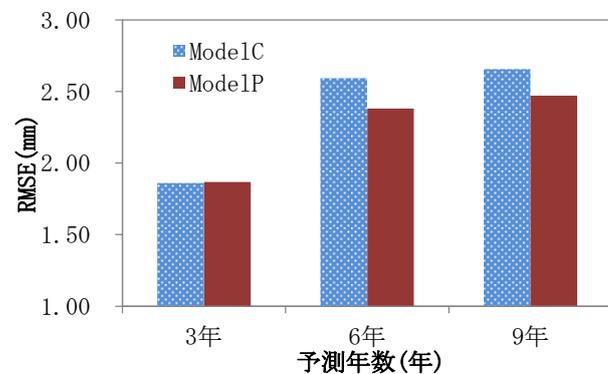


図 3-6 D_V に対する予測年数ごとの RMSE

なお、精度評価に用いる RMSE は、実測値と真値との差である測定誤差を含む。測定誤差の主因の 1 つとして、測定装置の違いによる機差がある。機差は、2 つの測定値間の平均的な差である偏り(Bias)と、差の標準偏差、ばらつき(Precision)に分けて考える事が出来る。ばらつきは予測モデルや平均化により減少させることが出来るが、偏りは減少させることが困難であるため、ここでは偏りについて考察する。阿部ら⁷⁶⁾は性能確認試験に合格した 2 つのわだち掘れ量測定装置間の偏りが 2.3mm である事を報告している。実際の測定値は多種の装置が混在している事、同一の装置であってもキャリブレーション状態によって変化する事から、より様々な偏りが生じる事を指摘している。また、わだち掘れ測定装置を保

有する TxDOT(Texas Department of Transportation)他 6 つの機関による測定結果と、6ft ストレートエッジ法によるわだち掘れ量実測値(GT : Ground Truth)間の機差について検証した FHWA(Federal Highway Administration)の調査報告⁷⁸⁾では、最も GT に近いとされる TxDOT(ASTM), Dynatest, Roadware の 3 機関の GT に対する偏りの平均値は 1.42mm である。阿部らにより検証が行われた 1993 年当時は、アナログフィルムにわだち掘れ形状を投影する方式であったが、FHWA の調査では、2000 年代後半に登場してきた INO 社の LRMS など、1 点の測定精度が $\pm 1\text{mm}$ 以内でより自動化された測定装置を用いた結果、わだち掘れ量の偏りが 1.42mm に抑えられたと考えられる。このことから、ModelP において図 3-4 の DPT よりも図 3-5 の DFT に対する RMSE の絶対値が小さくなっている要因は、新しいデータほどより高精度の装置を用いているためだと考えられる。

ModelP では、試験データである \mathbf{D}_{FT} に対する過学習を抑えるため、ハイパパラメータのニューロン数は ModelC と比較して 1/3 以下になった。これは、仮想的な現在時刻を $t = s$ とすると、 $t \leq s$ の情報から $t > s$ の予測をする事は、 $t \leq s$ を予測するよりも難しい事を反映している。この事から、RNN モデルにおいて将来予測のためのより過学習を抑制するハイパパラメータを探索する必要があると、3.2.3 III.の有効性が確認できた。

ModelC においては、実際に将来予測を行った際の精度である \mathbf{D}_{FT} 又は \mathbf{D}_{V} に対する RMSE より、 \mathbf{D}_{PT} に対する RMSE の方が小さいため、予測精度を過大評価する事になる。ModelC が予測精度を過大評価している量は、予測年数ごとに(\mathbf{D}_{PT} に対する RMSE) - (\mathbf{D}_{FT} に対する RMSE)を求める事により、本検証においては 0.26~0.33mm の範囲である。このことから、3.2.3 II.で指摘した従来手法では予測精度を過大評価する可能性がある事について確認できた。

また、それらの事から提案手法による予測精度評価に当る \mathbf{D}_{FT} の RMSE を評価した図 3-5 では、従来手法より実運用に近い、現実的な将来の予測精度の推定が出来たと考えられるため、3.2.3 I.が検証できた。他方で、将来を予測するのではなく、例えば近隣の路線の状態を予測する等、学習データと同じ時刻内の予測を行う場合は、従来手法を用いてハイパパラメータの決定を行った方が予測精度は高いと言える。

ほかにも、従来手法と提案手法の 6 年後と 9 年後の予測と比較し、3 年後の RMSE の差は大幅に小さい。これは、3 年後の RMSE が 6 年後、9 年後と比較し明らかに小さい事から解るように、予測が容易であるため、RMSE に含まれる測定誤差に対して予測誤差が相対的に小さく、差が出難いためだと考えられる。

さらに、図 3-5 の \mathbf{D}_{FT} に対する RMSE と、図 3-6 の \mathbf{D}_{V} に対する RMSE は殆ど差がないため、実用上は本章のように試験データと検証データを別に用意する必要は無く、学習データと試験データに時刻方向で 2 分割する提案手法で十分である事が解った。

3.4. 小括

この節では、時刻方向にデータを分割する事による、舗装の点検時系列データを用いた劣化予測に対する、より現実的な予測精度の評価を行う試験方法を構築した。構築手法では、実運用時の劣化予測で行われるように仮想的な過去のデータから将来のデータを予測してRMSEを求める事で、より実運用の劣化予測に近い評価が可能である事が検証できた。また、従来のクロスバリデーション手法では、データをランダムに分割する事で、学習データに含まれる時刻のデータで精度評価を行うため、予測精度を過大評価する可能性がある事が解った。他には、提案手法でハイパパラメータの調整を行う場合、現実的な将来予測の難しさから、従来手法よりも大幅に過学習を抑制する必要がある。RNN モデルでは、ニューロン数を 1/3 以下にする必要があった。

4

第4章 リカレントニューラルネットワークモデルの信頼区間と予測区 間推定

* * * * *

2章でRNNを用いた舗装劣化予測モデル及び、より現実的な予測精度の評価方法を提案した。しかし、舗装の劣化の様に不確実性が高い場合、劣化予測精度に限度がある事が明らかになった。その様な場合に予測が外れる事によるリスクを定量化するためには、予測精度の評価だけではなく、予測値と観測値間の差である予測誤差の分布を表す予測区間を求める事で、予測値と観測値が乖離する事によるリスクを知る事が出来る。本章では先ず予測誤差に含まれる外れ値を除去する事で、データに含まれる異常値の影響を減少させた後に、ブートストラップ法を効率的にリカレントニューラルネットワークモデルへ適用する事で、計算量を抑えながら精度の高い予測区間推定手法を提案する。

* * * * *

NN は点予測モデルであるため、予測の信頼性の推定が困難であるという弱点がある。舗装劣化予測の様に不確実性が高い場合、予測と実際の舗装健全度との差が大きい可能性が高い。もし予測よりも舗装の状態が悪い場合、事故発生率や旅行速度が計画より悪化するなどのリスクがある。逆にもし予測よりも舗装の状態が良い場合、余分な補修や点検を行うなどのリスクがある。通常の NN モデルは1つの値を予測する点予測であるため、その様なリスクを評価する事が出来ない。

予測の不確実性を定量化する事ができれば、各舗装管理者はそれらのリスクをコントロールした維持管理計画の立案が可能になる。従って、予測と観測値間のばらつきを知る事が重要である。

実運用下で得られる不確実性の高いデータの誤差分布は、対称な正規分布ではなく、歪がある又は裾の重い分布である事が多い⁷⁹⁾。そこで、本章ではノンパラメトリックな信頼区間(Confidence Interval, CI)、予測区間(Prediction Interval, PI)を推定する事が出来る、ブートストラップ法を用いた。ブートストラップ法の欠点は学習済みのモデルを大量に生成する必要があるため、計算量が膨大になる事である。提案手法では、通常の学習で得られたパラメータセット \hat{w} を初期値とする少数のエポック (n_{ae}) のみを追加学習することにより、少ない計算量でモデルを生成する。

提案手法(Proposed と呼ぶ)を川崎市,日本の主要道路の舗装点検データに適用した。その結果、計算量が通常のブートストラップ法と比較し 1/38 程度に抑えられることが解った。また、従来のブートストラップ法(Conventional と呼ぶ)を NN モデルに用いた際には、予測区間を過大評価する傾向があった⁸⁰⁾。その一方、提案手法はブートストラップ法により大量に生成した NN モデルのパラメータの局所最適解が Conventional より近いため、予測区間を過大評価せずに推定する事が可能である。一方 Proposed では、ブートストラップ法により生成された NN モデルのパラメータセットの距離が Conventional に比べて近いため、過大評価をしないで PI を推定することができる。

4.1. 舗装点検データの外れ値検出手法

本章では、RNN モデルによる舗装劣化予測モデルの予測区間推定を行うが、予測区間はモデルの予測値と観測値の差(残差)の分布であり、測定誤差等の観測値に含まれる様々な誤差を含む。観測値に含まれるその様な誤差の影響を軽減するため、予測区間を求める前に Bruffaerts ら⁸¹⁾で提案された Tukey g-and-h 分布を用いた外れ値検出手法により、測定ミスやデータ記録上のエラー等の可能性が高い異常値を除外する。

4.1.1. 外れ値と箱ひげ図

観測データの中で、大多数のデータから大きく離れた値が外れ値である。外れ値は、観測上の誤差やミスか、単に間違いではないが極端な値を取った事で生じたものである。本研究で用いる舗装点検データの場合、例えば補修の記録が無いにもかかわらず、地下埋設管の占有工事により路面性状値が大きく変化する事や、人的ミス等が考えられる。このような極端な値である外れ値はデータ解析の際に深刻な影響を与え、誤差の大きい結果を招くため、外れ値を特定し、調整する様々な手法が提案されている⁸²⁾。

そのうち広く用いられている方法が図 4-1 箱ひげ図に示す Tukey⁸³⁾により提案された箱ひげ図である。

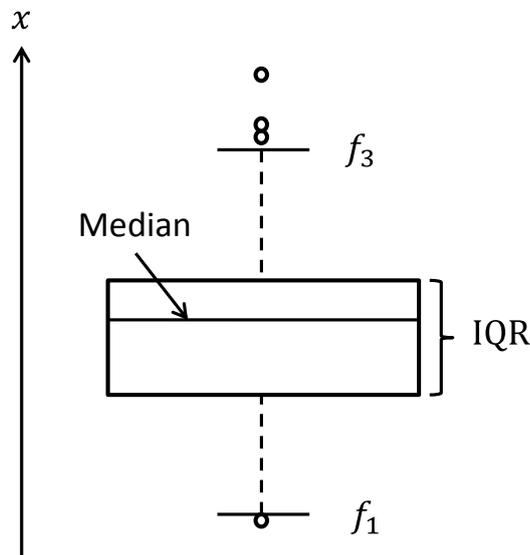


図 4-1 箱ひげ図

この方法は、4 分位範囲の推定値 $IQR = Q_{0.75} - Q_{0.25}$ を用いる。ここで、 $Q_{0.75}$ と $Q_{0.25}$ はそれぞれ第 3 四分位点と第 1 四分位点を表す。これを用いて、 $f_1 = Q_{0.25} - 1.5IQR$ と $f_3 = Q_{0.75} + 1.5IQR$ の範囲外を外れ値と判断する。この方法では、任意の外れ値の割合 α ($0 < \alpha < 0.5$) を検出したい場合は

$$c(\alpha) = \frac{z_{1-\alpha/2} - z_{0.75}}{z_{0.75} - z_{0.25}} \quad (4.1)$$

により任意%の外れ値検出閾値を求める事が出来る。ここで、 z_p ($0 < p < 1$) は標準正規分布の p 分位点を表す。例えば、 $c(0.05)=0.95$ の場合は、 $f_1 = Q_{0.25} - 0.95IQR$ 、 $f_3 = Q_{0.75} + 0.95IQR$ である。

この方法は、標準正規分布の場合は任意の外れ値検出割合を用いる事が出来るが、分布が歪んでいるか、裾が重い場合には α と外れ値の検出割合が一致しない、という問題がある。

4.1.2. Tukey g and h 分布を用いた外れ値検出方法

4.1.2.1. Tukey g and h 分布

そこで、Bruffaerts ら⁸¹⁾は Tukey g and h 分布を用いた外れ値検出方法を提案した。代表的な指数分布のカーネル密度推定と Tukey g and h 分布による近似を図 4-2 に示す。図によると、Tukey g and h 分布は歪があり、裾が重い幅広い分布でも精度よく近似出来る事が解る。

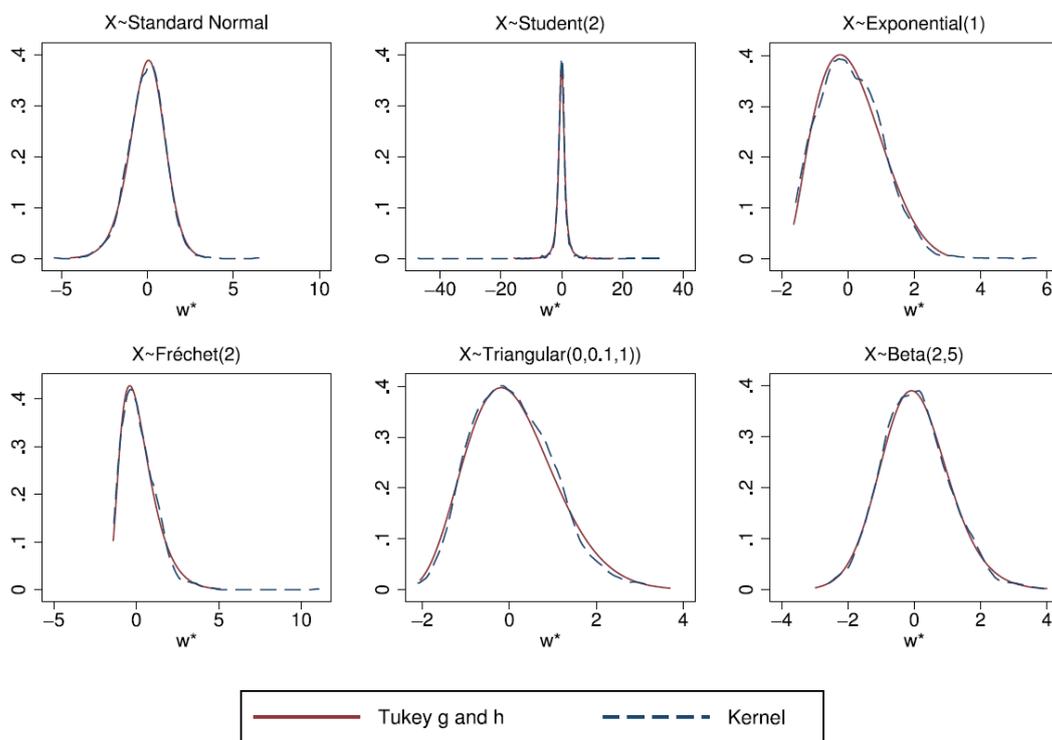


図 4-2 Tukey g and h 分布による代表的な指数分布の近似⁸¹⁾

Z を標準正規分布に従う確率変数、 g と h を定数とすると、Tukey g and h 分布に従う確率変数 Y は次のように得られる。

$$Y = \frac{1}{g} [\exp(gZ) - 1] \exp\left(\frac{hZ^2}{2}\right) \quad (4.2)$$

定数 g と h はそれぞれ、歪度と裾の重さを調節するパラメータである。この 2 つの定数は、 Y から得られた n 個の観測値 $\{y_1, \dots, y_n\}$ の p 分位数 $Q_p(\{y_j\})$ と $1-p$ 分位数 $Q_{1-p}(\{y_j\})$ を用

いて次のように推定する事が出来る.

$$\hat{g} = \frac{1}{z_p} \ln \left(-\frac{Q_p(\{y_j\})}{Q_{1-p}(\{y_j\})} \right) \quad (4.3)$$

$$\hat{h} = \frac{2 \ln \left(-\hat{g} \frac{Q_p(\{y_j\})Q_{1-p}(\{y_j\})}{Q_p(\{y_j\}) + Q_{1-p}(\{y_j\})} \right)}{z_p^2} \quad (4.4)$$

ここで, z_p は標準正規分布の p 分位数を表す. 外れ値として解釈する任意の分位数を p によって決める事が出来る.

4.1.2.2. 外れ値検出

上記の Tukey g and h 分布によりデータの分布を近似する事で, 歪のある裾の重い多様な分布に対して, 任意の分位数で外れ値を設定できる外れ値検出が可能である. 但しこの手法は1つの Tukey g and h 分布により分布を近似するため, 単峰性の分布にのみ有効であることに注意が必要である.

確率変数 X から観測された n 個の独立なデータを $\{x_1, \dots, x_n\}$ で表すとし, アルゴリズムの詳細を次に示す.

I. データを標準化する.

$$x_i^* = \frac{x_i - l_0}{s_0} \quad (4.5)$$

ここで $l_0 = Q_{0.5}(\{x_i\})$ と $s_0 = IQR(\{x_j\})$ はそれぞれ中央値と $\{x_1, \dots, x_n\}$ の四分位範囲を表す.

II. データが正の値になるようにシフトする.

$$r_i = x_i^* - \min(\{x_j^*\}) + \zeta \quad (4.6)$$

ここで, $\zeta > 0$ は微小値であり, $\zeta = 0.1$ を用いた.

III. II. で得られた値を $i = 1, \dots, n$ に対して 0 から 1 の間になるように標準化する.

$$\tilde{r}_i = \frac{r_i}{\min(\{r_j\}) + \max(\{r_j\})} \quad (4.7)$$

IV. プロビット変換を行う.

$$w_i = \phi^{-1}(\tilde{r}_i) \quad (4.8)$$

ここで, $\phi^{-1}(\cdot)$ は標準正規分布の累積分布関数を表す.

V. w_i を標準化する.

$$w_i^* = \frac{w_i - Q_{0.5}(\{w_j\})}{\text{IQR}(\{w_j\})/1.3426} \quad (4.9)$$

$\text{IQR}(\{w_j\})/1.3426$ は正規分布の σ に相当する.

VI. Tukey $T_{\hat{g}, \hat{h}^*}$ を用いて w_i^* の分布を決定する. \hat{g}, \hat{h}^* は歪度と裾野重さを表すパラメータ g と h の推定値で, (4.3)と(4.4)に, $\{w_1^*, \dots, w_n^*\}$ の分位数 $Q_{0.1}(\{w_j\})$ と $Q_{0.9}(\{w_j\})$ を用いて推定する.

VII. VI で得た Tukey $T_{\hat{g}, \hat{h}^*}$ 分布から, $\alpha, 1-\alpha$ ($\alpha \in (0,1)$)分位数である $\xi_{\alpha/2}^*$ と $\xi_{1-\alpha/2}^*$ を決定する. この α は任意の外れ値検出率であり, 本章では 0.1 を用いた.

VIII. VII で求めた $L_-^* = \xi_{\alpha/2}^*$ と $L_+^* = \xi_{1-\alpha/2}^*$ を用いて, 元のデータに対する外れ値検出の閾値 B_{\pm}^* を次のように求める事が出来る.

$$B_{\pm}^* = \left(\Phi \left(Q_{0.5}(\{w_j\}) + \frac{\text{IQR}(\{w_j\})}{1.3426} L_{\pm}^* \right) [\min(\{r_j\}) + \max(\{r_j\})] + \min\{x_j^*\} - \zeta \right) s_0 + l_0 \quad (4.10)$$

本章の信頼区間, 予測区間推定手法で用いるデータに対し, 上記方法により外れ値除去を行った.

4.1.2.3. 路面性状値データに対する外れ値除去

上述の Bruffaerts ら⁸¹⁾により提案された外れ値除去手法の, 本章における適用方法を述べる. 本研究で用いている路面性状値は時系列データであるため, 絶対値が変化する. そのため, 外れ値は差分を取った値 $\Delta y_t = y_t - y_{t-1}$ に対して検出した. ここで y_t はある時刻 t における路面性状値(わだち掘れ量)を表す.

また異常値を検出する対象として, 補修前後の整合性について注目した. 本章で用いた川崎市の路面性状データの場合, 補修の記録が年度単位である. 従って, 補修と路面性状調査が同年度に行われた場合, 調査が補修前に行われたのか, 後に行われたのかを判断する事が出来ない. 川崎市によると, 補修工事は年度の前半に行い, 例年調査が行われる年末には完了している事が多いという事である. これらの事から, 次の処理により補修記録の整合性を修正した.

- I. 補修と調査が同年度に行われているある区間 S において, 路面性状値が悪化する側の外れ値に該当する $\Delta y_t > B_+^*$ の場合, 補修が行われていない可能性が高い potential error1 と判断する.
- II. 同じ区間 S における次の調査時点の差分 Δy_{t+1} において, 補修の記録が無いにもかかわらず補修が行われている可能性が高い $\Delta y_{t+1} < B_-^*$ の場合 potential error2 とする.
- III. potential error1 かつ potential error2 の場合, 時刻 t の調査までに補修が行われていない一方で, 時刻 t から $t+1$ の間に補修が行われたことになる. 従って, 該当の補修年度を +1 する.

IV. 補修は同じ路線の幾つかの区間連続して行われている事が多いため、同時に行われた補修において 2/5 以上の区間が potential error1 かつ potential error2 に該当した場合、全ての該当区間の補修年度を+1 する.

上記により、調査が補修の前後どちらに行われたかが不明である事による外れ値を軽減する事で、次節で求める予測区間からその影響を軽減した.

4.2. 信頼区間と予測区間

ある目的変数の観測値と説明変数の組み合わせ $\{t(\mathbf{x}), \mathbf{x}\}$ があるとすると、観測値は次のように生成されると考えられる。

$$t(\mathbf{x}) = y(\mathbf{x}; \mathbf{w}) + \varepsilon(\mathbf{x}) \quad (4.11)$$

ここで、 $y(\mathbf{x}; \mathbf{w})$ は回帰モデルで \mathbf{w} はその真のパラメータ、 $\varepsilon(\mathbf{x})$ は誤差を表す。前提として $y(\mathbf{x}; \mathbf{w})$ は真のモデルを表現する事を仮定しており、予測モデルのパラメータを観測データにより推定する際には、真のパラメータ \mathbf{w} を近似した $\tilde{\mathbf{w}}$ を推定すると考える事が出来る。信頼区間はその推定精度を表し、

$$y(\mathbf{x}; \mathbf{w}) - y(\mathbf{x}; \tilde{\mathbf{w}}) \quad (4.12)$$

の分布で表す事が出来る。また、観測値と予測値間の差 $t(\mathbf{x}) - y(\mathbf{x}; \tilde{\mathbf{w}})$ の分布は予測区間であり

$$t(\mathbf{x}) - y(\mathbf{x}; \tilde{\mathbf{w}}) = [y(\mathbf{x}; \mathbf{w}) - y(\mathbf{x}; \tilde{\mathbf{w}})] + \varepsilon(\mathbf{x}) \quad (4.13)$$

と信頼区間を含む形で表す事が出来る。

予測区間は観測と予測値間の誤差分布を表すため、予測モデルのパラメータの推定精度を表す信頼区間より広い範囲を示し、観測値がどの範囲に収まるかを推定する事が出来る。信頼区間の示すパラメータの推定精度を実運用上用いる事は少なく、予測と観測値の信頼性を評価する方に興味がある場合が多いため、予測区間の方がより重要である。

4.3. NN モデルの信頼区間と予測区間の推定手法

NN モデルの予測区間推定方法は、デルタ法、Beysian, Mean and Variance Estimation(MVE)法、ブートストラップ法がある。Chryssolouris ら⁸⁴⁾や Hwang ら⁸⁵⁾は、デルタ法による NN モデルの予測区間推定手法を提案した。デルタ法は入力変数の平均、分散から近似的に NN モデルの平均、分散を求める方法である。予測区間を正規分布と仮定している事、一次のテイラー展開で NN モデルを近似する事、分散は常に一定としていることなどから、近似精度はあまりよくない事が知られる。

MacKay⁸⁶⁾や, Bishop⁸⁷⁾は、NN モデルのパラメータ分布推定にベイズ推定を応用したベイジアンニューラルネットワークを用いた場合の予測区間推定手法を提案した。この方法はベイズ推定によりパラメータ分布を求めているため、予測区間を正規分布と仮定し、パラメータの分散とデータの分散の和から予測区間のばらつきを求める事が出来る。

Nix ら⁸⁸⁾によって提案された MVE 法は、予測を行う NN モデルとは別に、平均と分散を求めるために専用の NN モデルを用いる。それにより求めた平均と分散から正規分布と仮定した予測区間を求める。MVE 法を発展させた、lower upper bound estimation(LUBE)法⁸⁹⁾は、MVE 法とは異なり誤差関数に PI の構築誤差を導入する事で、単一のモデルで予測値と PI を推定する事が出来る。これらの方法では NN モデルにより PI を推定するため、NN モデルの推定が正しくない場合、適切な PI が得られない事が考えられる。また、信頼区間を推定せずに直接 PI を求めるため、パラメータ推定のばらつきを定量化できない。

本章で用いるブートストラップ法は、元のデータの復元抽出を B 回繰り返して生成したブートストラップ標本を用いて、様々な統計量の推定を行う。Heskes⁹⁰⁾は、別々の NN モデルで $B=25$ 個のブートストラップ標本を学習し、25 個の NN モデルを構築した。次に 25 個の NN モデルの予測から予測の分散を求め、正規分布と仮定する事で信頼区間を推定した。予測区間の推定には独立した別の NN モデルにより予測の分散を推定し、正規分布と仮定した予測区間を推定した。その様に正規分布を仮定する事で、 $B=50$ 程度で分散を推定し、信頼区間、予測区間を構成できる。ブートストラップ法からパラメトリックな分布を仮定せずに直接信頼区間、予測区間を推定するためには $B=1,000$ 以上必要であり⁹¹⁾、それだけ計算量が増大する。そのため、上記の手法では正規分布を仮定する事で、少ない B で分散を推定し、予測区間を構成している。しかし計算コストを抑えることができれば、正規分布についての仮定は必要ない。そこで、計算量を抑える事で $B=1,000$ 以上のモデルを生成し、正規分布を仮定しないパーセンタイル法により区間推定を行う手法を次章で提案する。また通常のブートストラップ法では NN モデルを別々に学習する。それにより、得られた B 個の NN モデルのパラメータは離れた局所最適解に位置する。その様な B 個のモデルによる信頼区間の推定は、NN モデルの学習のランダム性から生じるばらつきを含むことになる。

従って、点予測のばらつきを過大評価する可能性がある。Khosravi ら⁸⁰⁾は従来のブートストラップ法を用いると、その他の手法と比較し予測区間を過大評価する事を指摘している。

一方提案手法は、NN モデルの学習のランダム性によるばらつきを予測区間に含まず、点予測を行うモデルのばらつきみを評価する。それにより B 個の NN モデルのパラメータ間の距離は通常のブートストラップ法と比較して近いため、過大評価する問題を解決できる。

4.4. スナップショットブートストラップによる予測区間推定手法

本章ではブートストラップ法を効率的に NN モデルの学習に適用する事で、大量のパラメータのブートストラップ推定値を生成し、それにより信頼区間、予測区間を推定するスナップショットブートストラップ法(SB 法)を提案する。

4.4.1. 関連する NN モデル学習手法

ブートストラップ法では元の説明変数の標本 X から B 個のブートストラップ標本 $\{X_1^*, \dots, X_B^*\}$ をリサンプリングし、それぞれについてモデルの推定結合荷重パラメータを求める。

区間推定を行う際には B は 1,000 以上必要であり⁹¹⁾、 B の数に比例して計算量が増加する。しかし、大量のパラメータを効率的に生成できれば、大幅に計算量を抑える事が出来る。複数の結合荷重パラメータを効率的に推定した事例の 1 つはスナップショットアンサンブル⁹²⁾である。この方法は、まず一度局所最適解に収束したモデルに、アニーリングを何度か行う。アニーリングは図 4-3 に示すように、一度局所最適解に収束している NN モデルに対し、学習率を急激に大きくして再び学習を行うことで局所最適解から脱し、より良い局所最適解を見つけるための方法である。

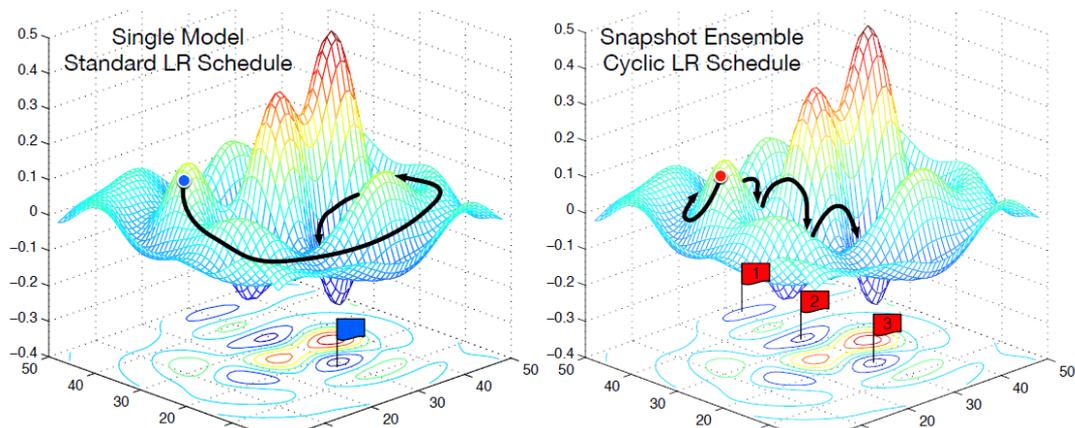


図 4-3 アニーリングによる局所最適解の移動

アニーリングの回数分得られた収束済みの結合荷重パラメータをスナップショットとして保存する。スナップショットアンサンブルは、それらのスナップショットをモデルアンサンブルに用いる事で、予測精度を向上させる事が目的である。この方法では別々に複数の結合荷重パラメータを推定した通常のモデルアンサンブルと比較して予測精度が向上する訳ではない。しかし、一度収束済みのパラメータからアニーリング後に学習を行う事で、

少ない計算量で複数の推定結合荷重パラメータを獲得する事が可能である。同様にすでに収束済みの推定パラメータを用いることで、少ないエポック数で精度向上を行う手法として、Dynamic Evaluation がある。

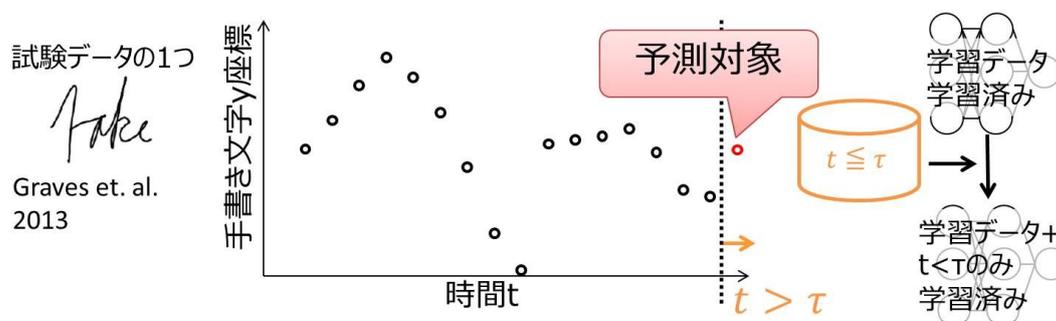


図 4-4 Dynamic Evaluation の追加学習

Graves ら⁹³⁾は、手書き文字予測の際に、既に学習データを学習済みの NN モデルに対し、検証データのある時刻 τ より後のデータを予測したいとする。検証データの予測したい時点より以前($t \leq \tau$)を 1 回だけ学習率 1 で学習する事により、 $t > \tau$ の予測精度を向上できる Dynamic Evaluation を用いている。

この 2 事例とも先に獲得した推定結合荷重パラメータに対して追加で学習を行っている点は同じである。提案手法はその考え方をブートストラップ標本の学習に適用する事で、計算量を削減する。提案手法とスナップショットアンサンブルの学習曲線の例を図 4-5 に示す。

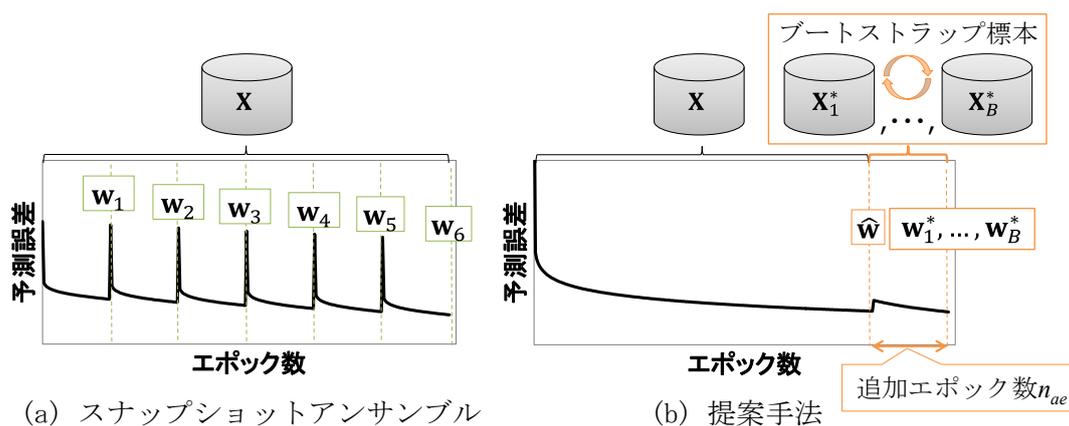


図 4-5 スナップショットアンサンブルと提案手法の学習曲線の例

提案手法は、元の標本 X で収束するまで学習して得たパラメータ \hat{w} を初期値として、追加エポック数 n_{ae} 分だけそれぞれのブートストラップ標本 $\{X_1^*, \dots, X_B^*\}$ について学習する。それ

により大量の結合荷重パラメータのブートストラップ推定量 $\{\hat{\mathbf{w}}_1^*, \dots, \hat{\mathbf{w}}_B^*\}$ を生成し, 信頼, 予測区間の推定に用いる. 提案するスナップショットブートストラップ手法の詳細を次で述べる.

4.4.2. 提案アルゴリズム

スナップショットブートストラップ法による信頼区間, 予測区間推定アルゴリズムの処理の流れを図 4-6 に示す.

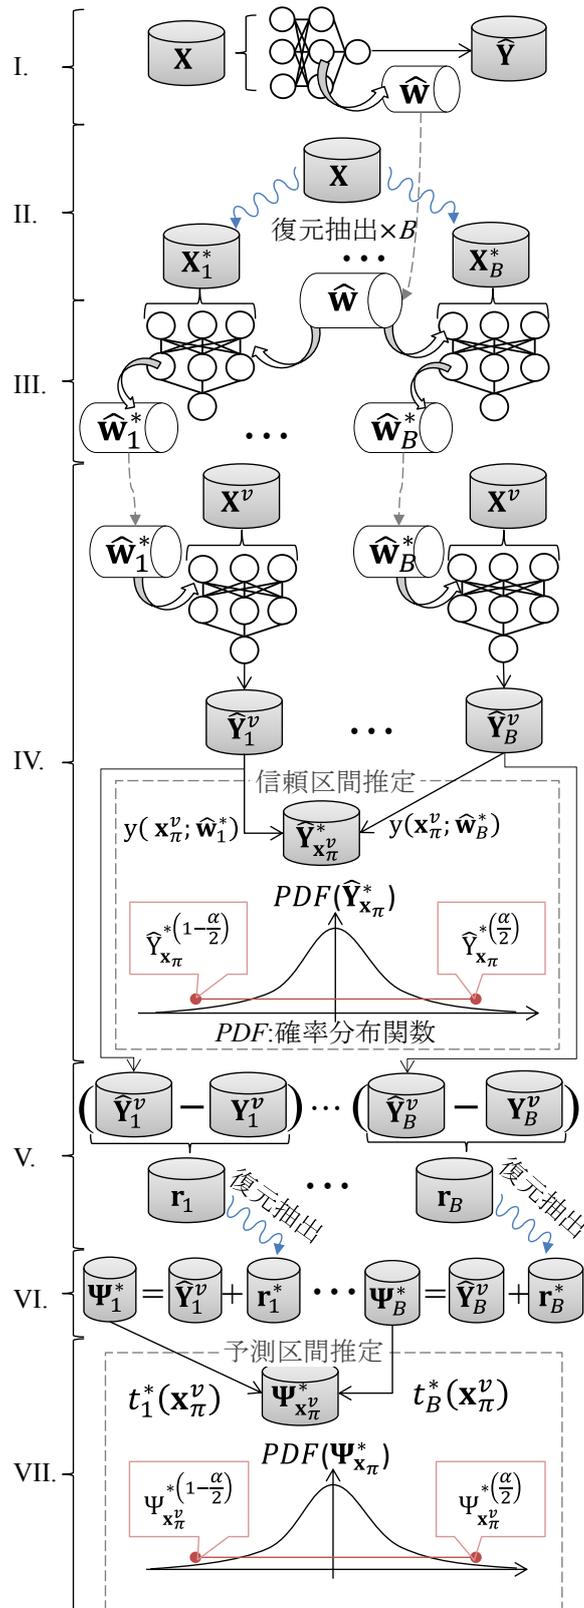


図 4-6 信頼区間と予測区間推定フロー

I. 点予測モデルの学習

$\mathbf{X} = \{\mathbf{x}_n | n = (1, 2, \dots, N)\}$ を学習データ集合, その要素 \mathbf{x}_n は説明変数(入力)データベクトルを表す. 同様に $\mathbf{X}^v = \{\mathbf{x}_m^v | m = (1, 2, \dots, M)\}$ を検証データ集合とする. 1つの NN モデルをクロスバリデーションにより学習し, 推定した NN モデルの最初のスナップショットを $\hat{\mathbf{w}}$ とする.

II. データのブートストラップ標本を生成

\mathbf{X} から B 回リサンプリングし, ブートストラップ標本 $\{\mathbf{X}_1^*, \dots, \mathbf{X}_B^*\}$ を生成する. なお, 本研究の場合は時系列情報のあるデータを用いるため, 全データをランダムに復元抽出すると時系列情報が失われてしまう. そこで, ブロックブートストラップを用いる. 時系列データをグループ化し, そのグループごとに復元抽出を行うことで時系列情報を保持する.

III. B 個の NN モデルを学習

I.で得た $\hat{\mathbf{w}}$ を B 個の NN モデルの結合荷重パラメータの初期値とする. その B 個の NN モデルについて, II.で生成したそれぞれの $\{\mathbf{X}_1^*, \dots, \mathbf{X}_B^*\}$ を入力に用いて n_{ae} エポック学習する. 学習により得られた B 個の $\{\hat{\mathbf{w}}_b^* | b = (1, 2, \dots, B)\}$ を, 結合荷重パラメータの SB 推定値とする. この n_{ae} エポックの事を追加エポックと称する.

初期値として既に収束済みの $\hat{\mathbf{w}}$ を用いているため, B 個のブートストラップ標本についてそれぞれ最初からモデルを学習するより収束が速く, 大幅に計算量を削減できる. この点が通常のブートストラップ法と異なる点である.

IV. 信頼区間を求める

予測の信頼, 予測区間を求めたいある検証データを $\mathbf{x}_\pi^v (m = \pi) \in \mathbf{X}^v$ とする. 結合荷重パラメータが $\hat{\mathbf{w}}_b^*$ であるモデルの予測を $y(\mathbf{x}_\pi^v; \hat{\mathbf{w}}_b^*)$ とする. それぞれの $\hat{\mathbf{w}}_b^*$ を用いて \mathbf{x}_π^v を予測した結果をブートストラップ予測 $\hat{\mathbf{Y}}_{\mathbf{x}_\pi^v} = (y(\mathbf{x}_\pi^v; \hat{\mathbf{w}}_1^*), \dots, y(\mathbf{x}_\pi^v; \hat{\mathbf{w}}_B^*))$ とする.

$\hat{\mathbf{Y}}_{\mathbf{x}_\pi^v}$ を小さい順にソートし, $0 < p < 1$ に対して p B 番目に小さい数値を $\hat{Y}_{\mathbf{x}_\pi^v}^{*(p)}$ と表す. $100(1 - \alpha)\%$ 両側信頼区間は次のように求まる.

$$\left[\hat{Y}_{\mathbf{x}_\pi^v}^{*\left(\frac{\alpha}{2}\right)}, \hat{Y}_{\mathbf{x}_\pi^v}^{*(1-\frac{\alpha}{2})} \right] \quad (4.14)$$

V. 残差のブートストラップ標本を求める

未知標本に対する残差を求めるため, 検証データを用いて残差を生成する. $\hat{\mathbf{w}}_b^*$ を用いて検証データを予測した結果を $\hat{\mathbf{Y}}_b^v = (y(\mathbf{x}_1^v; \hat{\mathbf{w}}_b^*), \dots, y(\mathbf{x}_M^v; \hat{\mathbf{w}}_b^*))$, $\hat{\mathbf{Y}}_b^v$ に対応した観測値ベクトルを \mathbf{Y}_b^v と表す. 残差 \mathbf{r}_b を次のように求める

$$\mathbf{r}_b = \hat{\mathbf{Y}}_b^v - \mathbf{Y}_b^v \quad (4.15)$$

上記により求めた \mathbf{r}_b をリサンプリングし, 残差のブートストラップ標本 \mathbf{r}_b^* を生成する.

VI. 目的変数のブートストラップ標本を求める.

$t_b^*(\mathbf{x}_m^v)$ をブートストラップ標本 b から求めた目的変数のブートストラップ標本とすると, $\Psi_b^* = (t_b^*(\mathbf{x}_1^v), \dots, t_b^*(\mathbf{x}_M^v))$ を次のように計算する.

$$\Psi_b^* = \hat{Y}_b^v + \mathbf{r}_b^* \quad (4.16)$$

Ψ_b^* を全ての b について計算し, $\{\Psi_1^*, \dots, \Psi_B^*\}$ を求める.

VII. 予測区間を求める.

予測区間を求めたい \mathbf{x}_π^v に対応する目的変数のブートストラップ標本を $\Psi_{\mathbf{x}_\pi^v}^* = (t_1^*(\mathbf{x}_\pi^v), \dots, t_B^*(\mathbf{x}_\pi^v))$ で表す. $\Psi_{\mathbf{x}_\pi^v}^*$ を小さい順にソートし, $0 < p < 1$ に対して pB 番目に小さい数値を $\Psi_{\mathbf{x}_\pi^v}^{*(p)}$ とする. $100(1 - \alpha)\%$ 両側予測区間は次のようになる.

$$\left[\Psi_{\mathbf{x}_\pi^v}^{*\left(\frac{\alpha}{2}\right)}, \Psi_{\mathbf{x}_\pi^v}^{*\left(1-\frac{\alpha}{2}\right)} \right] \quad (4.17)$$

この提案手法の特徴は, 予め学習済みの結合荷重パラメータ $\hat{\mathbf{w}}$ から各ブートストラップ標本について学習する事である. それにより, 別々に NN モデルの学習を行うより計算量を大幅に削減する事が可能である.

4.5. 適用事例

4.5.1. RNN モデルによる時系列予測

検証に用いる RNN モデルとして、前章と同様に従来の LSTM と比較し学習速度が速い GRU(Gated Recurrent Unit)⁷⁰⁾を用いた。本章では、時系列データ上の次の時刻を予測するだけでなく、複数の時系列を Graves ら⁹³⁾の方法を用いて予測した。具体的には、ある時刻 s 以前($t \leq s$)の観測値を元に、それ以降の時系列 $t = s + q$ を予測した。本章においてこの s は予測の初期値として用いる観測値の観測年であり、 q はそこからの予測年数に相当する。図 4-7 に一例として、2006 年の観測値を初期値($s=2006$)として、2009 年、2012 年、2015 年の予測を行う場合の時刻情報の関係を示した。

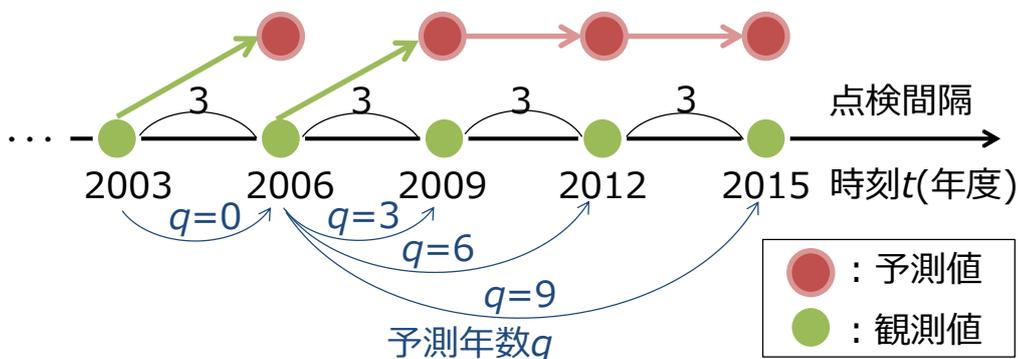


図 4-7 時系列情報の例

図 4-7 の状況下で $q = 3$ を予測する際には、入力として $t = s$ のわだち掘れ量の観測値を用いて、次の時刻 $t = s + 3$ のわだち掘れ量の予測値を出力する。それ以降の時刻($t > s + 3$)の予測は時系列予測として、説明変数の「予測対象区間の平均わだち掘れ量」を、前時刻の予測わだち掘れ量に置き換える。これにより、 $t = s$ の観測値を初期値として、 $t < s$ の観測値は用いず予測時系列を生成する。

それに伴い、 q が大きくなるほど予測精度が低下すると考えられる。従って、 $\hat{\mathbf{Y}}_{x_t^v}$ と \mathbf{r}_b^* 、 $\Psi_{x_t^v}^*$ を q ごとに別々に求め、 q ごとの信頼区間と予測区間を作成した。それ以外の学習テクニックとして、学習率を自動的に調整する ADAM⁶⁶⁾を用いた。また、過学習を抑制するドロップアウトを RNN モデルに対して適用する手法はまだ確立されていない。そこで、幾つかの言語モデリングタスクにおいて最高精度を達成した手法 Semeniuta ら⁷¹⁾の手法に基づきドロップアウトを用いた。

4.5.2. RNN のハイパパラメータ探索

提案手法はモデルの予測誤差には依存しない事から、必ずしも最低の予測誤差になるモデルを選択する必要はない。そのため、RNN モデルのハイパパラメータは次のように探索した。探索数を簡略化するため、RNN モデルの中間層(隠れ層)数は 2 で、各層のニューロン数は同じとした。ドロップアウト率を 0~0.5, 中間層のニューロン数を 5~50 の間で探索し、それ以外のハイパパラメータは表-1 の値を用いた。

表 4-1 ハイパパラメータの一覧

ハイパパラメータ	値
学習率	0.002
ミニバッチサイズ	100
ドロップアウト率	0.2
ドロップアウト率(時系列)	0.1
隠れ層数	2
1 層のニューロン数	15
エポック数	400
	10(Proposed)
追加エポック数	100(Annealing)
	None(Conventional)

4.5.3. 比較手法

本章では、点予測を行うある NN モデルのばらつきを推定する事が目的であり、遠い局所最適解の結合荷重パラメータをアンサンブルする事により予測精度を向上する事が目的とするスナップショットアンサンブルとは異なる。従って、遠い局所最適解を探索するためにアニーリングする必要はないと考えられる。そのことを検証するため、アニーリングなし(Proposed と呼ぶ)と、アニーリングあり(Annealing と呼ぶ)についてそれぞれモデルを構築した。

また、先述の通り通常のブートストラップ法を用いた場合、各パラメータのブートストラップ推定値は遠い局所最適解に達すると考えられる。そのことを検証するため、従来のブートストラップ法(Conventional と呼ぶ)でも信頼、予測区間を推定した。それらの手法を相互比較するための指標として、次の PICP を用いた。

$$\text{PICP} = \frac{1}{n_{test}} \sum_{i=1}^{n_{test}} c_i \quad (4.18)$$

ここで、 n_{test} はデータ数、 c_i は観測値が予測区間内にある場合 1、それ以外は 0 である。PICP の値と設定した信頼水準が近いほど、予測区間の推定精度が良いと評価できる。

この PICP は直観的に、予測区間に入っている観測値の割合である。例えば図 4-8 のように 80%予測区間を推定した場合、実際に試験データの観測値の 80%が予測区間内に入っている場合、PICP=80%となり、最も予測区間の推定精度が高いと言える。

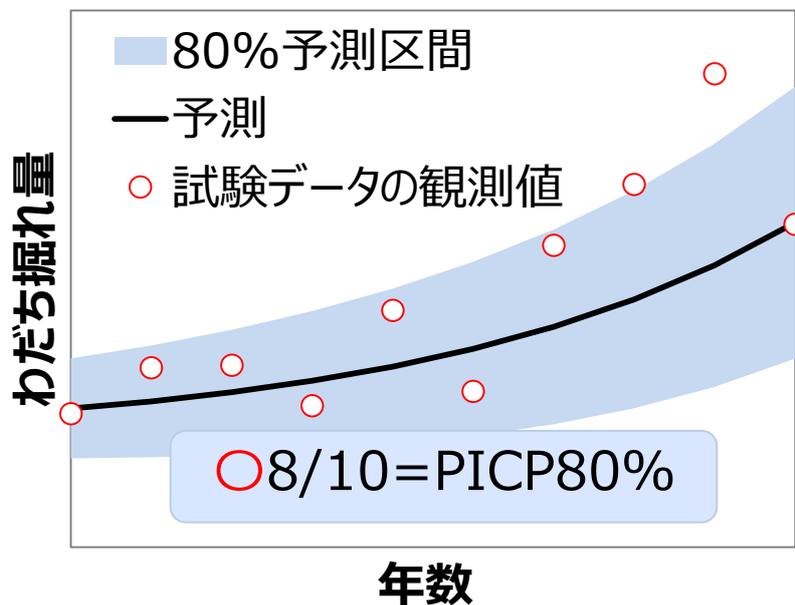


図 4-8 PICP80%の例

4.5.4. 追加エポック数の検討

アニーリングを用いたモデルの学習率は shifted cosine annealing⁹⁴⁾により次のように設定した。

$$\alpha(t) = \frac{\alpha_0}{2} \left(\cos\left(\frac{\pi n_e}{n_{ae}}\right) + 1 \right)$$

ここで、 n_e は現在のエポック数、 α_0 は学習率の初期値である。これにより 400 エポック学習済みのモデルに対して、追加で 100 エポック ($n_{ae}=100$)学習した学習曲線を図 4-9 に示した。

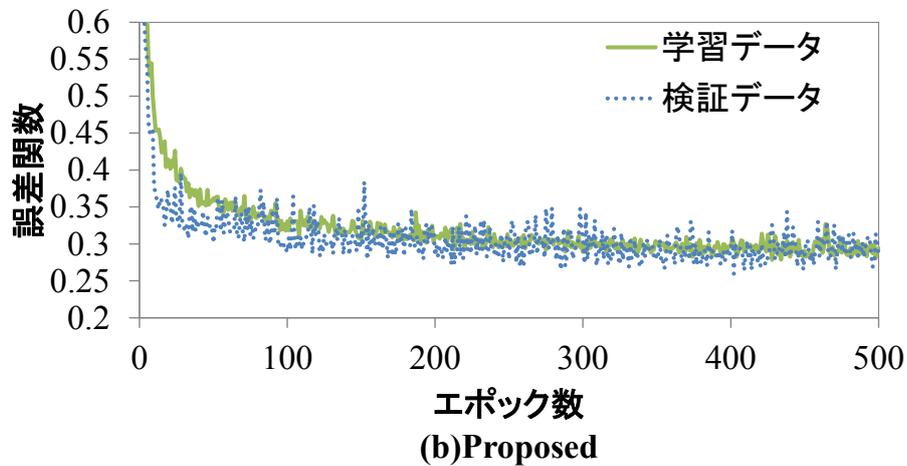
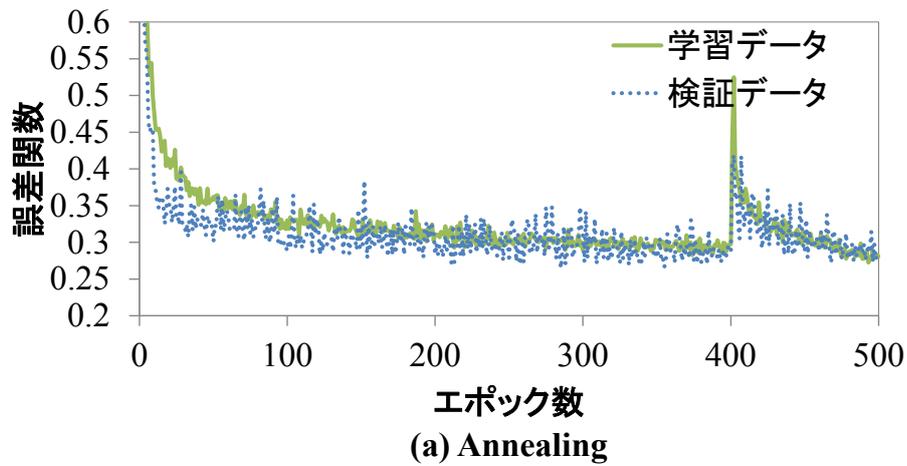


図 4-9 Annealing と Proposed の学習曲線

図 4-9(a)では、アニーリングすることにより急速に loss が増加した後 100epoch で元の水準まで戻っている。そのことから、Annealing の n_{ae} は 100Epoch とした。一方アニーリングを行わない図 4-9(b)の場合、loss は最後までほぼ一定である。100Epoch も学習する必要はない事から Proposed の n_{ae} は 10Epoch に設定した。

4.5.5. 検証に用いたデータ

本検証においてもこれまでと同様に川崎市の路面性状調査履歴を用いた。基本的にはこれまでと同様だが、本章で用いた説明変数を表 4-2 に示す。

表 4-2 説明変数

説明変数	前処理
補修後の経過年数	
大型車交通量	
大型車累積交通量	
車道幅員	
予測対象区間の平均わだち掘れ量	正規化
点検間隔	
舗装厚	
CBR(路床の支持力比)	
交差点の有無	
構造物(橋又はトンネル)	ダミー変数化
最新の補修工法	

クロスバリデーションのため、ランダムに全単位区間の20%を選択して検証データとし、残りを学習データとした。その際に、同じ単位区間のデータが検証データと学習データに分かれると、時系列情報が失われてしまう。そこで、単位区間のデータごとにグループ化し、グループ単位で検証データと学習データに分割した。全データ数は21,190件、学習データのデータ数は16,518件(3,833区間)、検証データは4,672件(1,053区間)であり、単位区間の平均時系列数はおおよそ5回分である。

また、アスファルト舗装の標準的な設計寿命が10年である事、殆どの単位区間において3年間隔で点検データが存在する事から、点検3回分、9年後までの予測区間を評価した。データは3年間隔であるため、 q は年を表すとすると $q \in \{3,6,9\}$ である。そのため、検証データにおいて最新の点検結果である2015年から9年前である2006年以前のデータを初期値として2006年以降を予測した。それらの前提により、次章の検証で用いるデータは次の条件を満たすデータに限定される。検証データでかつ、2006年より前から調査が開始されているかつ、継続して3年間隔で調査が行われているかつ、2006年以降のデータである。従って、検証データの更に一部に限定されるため、データ数は2,017件である。

4.6. 検証結果

4.6.1. 学習時間の比較

区間推定を行うには $B=1,000$ 程度必要とされているため、ブートストラップ標本の数(B)は1000を用いた. 表 4-1 のハイパパラメータで1エポックのみ学習する時間を u と表すと、通常のブートストラップ法では $400+(400 \times 1000)=400,400u$ の学習による計算時間が必要になる. しかし提案手法では最初のスナップショットを作成した後は、各ブートストラップ標本について 10 エポックのみ学習すればよい. 従って学習に必要な時間は $400+(10 \times 1000)=10,400u$ で済むため、通常のブートストラップ法と比較しておよそ $1/38$ の計算時間になる.

実際には学習前後にその他の処理も含まれるため厳密にこの計算時間が保証される訳ではない. 本章の実験設定下で Windows7, Xeon 3.60GHz の PC を用い 400 エポック学習するためにかかった時間はおよそ 745 秒で、1 エポック当りは 1.86 秒である. 通常のブートストラップ法を用いた際には 744,744 秒 \approx 8.6 日、提案手法では 12,870 秒 \approx 5.3 時間程度である. 従って本提案手法を用いる事で計算コストを大幅に削減し、容易に信頼区間と予測区間を作成する事が出来るようになる. それにより、計算量を抑える必要がある様々な場合に適用可能になる. 例えば IoT データや画像によりデータ量が多い場合や、入力データ次元が大きい場合や、様々な維持管理シナリオに基づき多様なパターンをシミュレーションする場合、データ随時得て更新するオンライン学習の場合などがある.

4.6.2. 予測区間の推定精度

提案手法の推定精度を検証するために、Proposed, Annealing, Conventional それぞれについて 90%から 10%まで、10%刻みで予測区間を作成し、それ PICP を求めた結果を表 4-3 に示す.

表 4-3 各手法の PICP

信頼水準	Proposed	Annealing	Conventional
90	90.43	90.95	91.16
80	80.04	81.49	81.64
70	70.27	72.08	71.82
60	60.34	61.74	61.38
50	50.05	50.78	51.29
40	39.66	40.95	40.18
30	29.42	29.73	30.77
20	19.54	19.54	20.48
10	9.72	9.41	11.48

それによると、信頼水準 90%~50%の間は、Proposed の PICP(%)が最も信頼水準に近く、推定精度が高いことが解る。しかしながら、Proposed 以外ではより過大評価する傾向があり、特に Conventional の過大評価が大きい。これは、 B 個のモデルのパラメータが遠い局所最適解に収束した事で、モデルの予測のばらつき、信頼区間を過大評価したためだと考えられる。その事を確認するため、点予測モデルと各ブートストラップモデルの結合荷重パラメータとのユークリッド距離の総和を算出した結果をボックスプロットとして図 4-10 に示す。

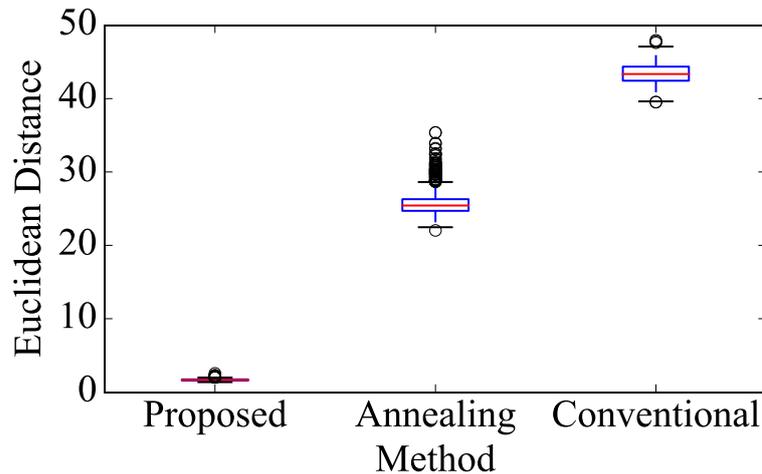


図 4-10 結合荷重パラメータ間のユークリッド距離比較

これによると明らかに Conventional > Annealing > Proposed 手法の順に局所最適解が点予測モデルから離れている事が確認できる。これは予測区間の過大評価の順と整合的である。Conventional では局所最適解の距離が遠い事で NN モデルの学習プロセスのランダム性によ

るばらつきが信頼区間に含まれるため、予測区間を過大評価すると考えられる。

一方、信頼水準 40%~10%の間では Proposed 及び Annealing は過小評価する傾向がある。この原因は、予測区間 40%~10%内に含まれるデータ点数が少ないためだと考えられる。先述の通り、検証で用いたデータは 2,017 件のみである。そのため、40%予測区間に含まれるデータ数は 806 件、10%は 201 件となり、信頼水準が小さいほど含まれるデータ数が少ない。データ数が少ない場合、極端な値が含まれない可能性が高いため、ばらつきを過小評価する傾向がある⁹⁵⁾。それにより、40%以下では予測区間を過小評価したと考えられる。一方、Conventional はデータ数が少ない事による過小評価よりも過大評価の方が大きいため、データ数が少なくても過大評価していると考えられる。

上記の様に、予測区間推定精度はデータ数や、ブートラップ標本数 B により異なる。本検証で用いたわだち掘れ量の将来予測の場合、1 章で論じた施工、環境、素材等の観測されていない劣化要因が含まれ、それらが将来どのように変化するのか予測する事は困難である。その様な不確実性に比較して数%程度の予測区間の誤差は小さいため、今回得られた推定精度で十分だと考えられる。しかし、本手法を適用する目的ごとに要求される推定精度は異なるため、それに応じて検証する事が重要である。

4.6.3. 信頼区間と予測区間の推定結果

提案手法による信頼水準 90%の信頼、予測区間と、観測値を図 4-11~図 4-13 に示す。

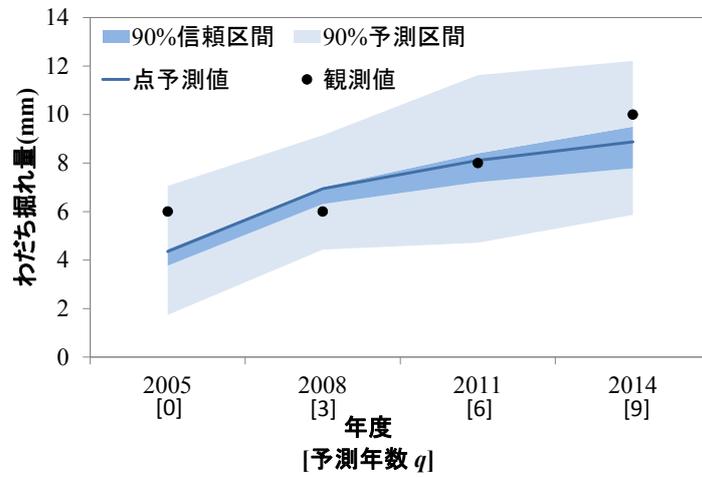


図 4-11 補修が無い区間

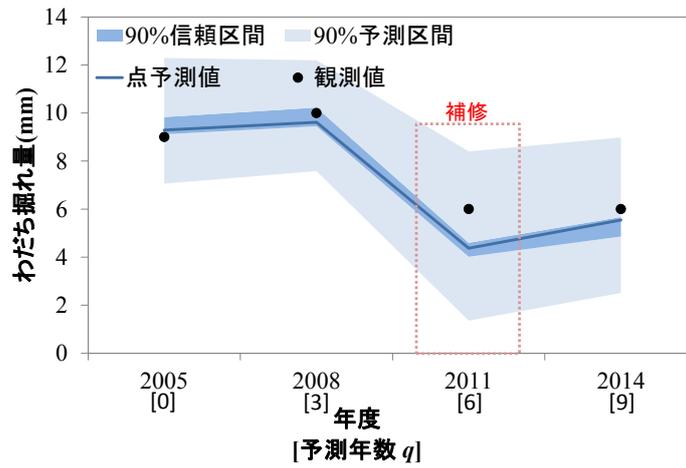


図 4-12 補修がある区間

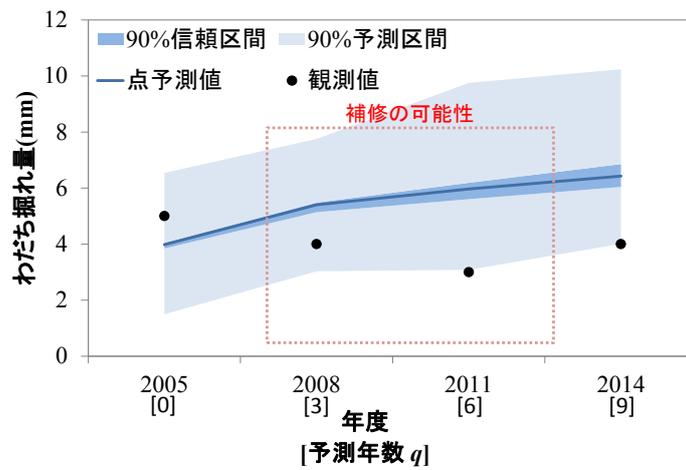


図 4-13 補修の可能性のある区間

図 4-11 は補修記録の無い単位区間の推定結果である。2005 年以前に同じ単位区間を点検した 4 回分の点検履歴データを用いて、3、6、9 年後を予測している。なお、便宜上予測の初期値となる時刻 $t = s$ の予測年数 q を 0 と表示している。予測年数が大きくなるにつれて徐々にわだち掘れ量が悪化していく様子が予測されている。同時に、予測が長期になるほど予測の不確実性が増す事を反映し、徐々に信頼区間が拡大することが解る。

図 4-12 は補修により大幅にわだち掘れ量が改善した単位区間を示している。予測と観測値は良く一致しており、補修があった場合、わだち掘れ量が改善する事をモデルが学習できていることが解る。また、補修後の 2011 年の信頼区間は非常に狭くなっている。これは、補修後のわだち掘れ量はおよそ 3~4mm になる事が多いため、補修直後の予測が容易になる事を示している。

図 4-11~図 4-13 の予測区間の幅は $\pm 3\text{mm}$ 以上である。そのため、わだち掘れ量が改善した観測値が得られる可能性を示している。しかし、舗装のわだち掘れ量は、補修が行われていないにも関わらず改善する事は考えにくい。従って、わだち掘れ量が改善する予測区間の主因は、測定誤差だと考えられる。測定誤差の要因の 1 つは、わだち掘れ測定装置の違いである。測定装置は検定試験を通過しているため、誤差 $\pm 3\text{mm}$ 以内である。しかし、装置ごとに誤差の傾向が異なる機差がある⁷⁸⁾。そのほかにわだち掘れ量が改善する要因として考えられるのは、苦情対応による応急処置や、舗装下の上下水道、電線等の埋設管の工事などがある。しかし、それらの情報は記録されていない、もしくは利用出来なかったため、本章では表 4-2 に示した記録のみ用いている。従って、その様な詳細な情報の不足が測定誤差として予測区間を広げる要因となっている。これらの事から、予測の不確実性を減少させるためには、予測モデルの改善も当然であるが、詳細な情報を記録し、同時に記録の可用性を向上する事が考えられる。また、提案手法を外れ値除去手法として用いる事で、記録に無い補修等の誤差要因の影響を軽減する事が考えられる。

図 4-13 は補修記録が無い箇所ではあるものの、観測値が予測区間の下限に達している。この様に予測区間から外れる箇所については、先述の通り埋設管工事等によりわだち掘れ量が改善されている等、記録にない事象により影響を受けている可能性が高い。提案手法はその様な箇所を外れ値として除去する手法としても用いる事ができる。

ここまでわだち掘れ量が最大で 10mm 程度と比較的少ない区間が多い。その理由としては、用いているデータが主に幹線道路の物で、川崎市の管理水準が高いためである。川崎市では、舗装の管理基準として MCI を用いている。MCI は、次の式から算出される。

$$\text{MCI} = 10 - 1.48C^{0.3} - 0.29D^{0.7} - 0.47\sigma^{0.2} \quad (4.19)$$

ここで、 C はひび割れ率、 D はわだち掘れ量、 σ は平坦性を表す。川崎市道路維持修繕計画によると、川崎市の路面性状調査を行っている幹線道路はおよそ 90%の路線の MCI は

5 以上である。これは殆どの路線で補修の必要が無い非常に良い状態で管理されている事になる。実際に、試験データでかつ、予測対象の 2006 年以降かつ、わだち掘れ量が 15mm 以上の箇所は 13 区間しか存在しなかった。その様な区間の 1 つについて、信頼、予測区間を推定した結果を図 4-14 に示す。

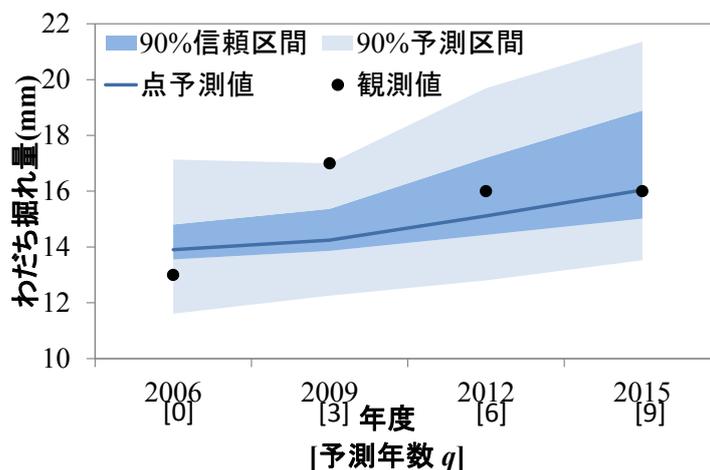


図 4-14 わだち掘れ量が多い区間

これによると、他のわだち掘れ量が小さい区間と比較して著しく信頼区間が広いことが解る。その理由はここで述べた通り、わだち掘れ量が大きくなる区間数が著しく少ないため、わだち掘れ量が多い時の劣化について十分な情報が無く、劣化予測の不確実性が特に高い事を反映している。そのため、NN モデルのパラメータを一意に決定する事が難しくなった結果、パラメータのばらつきを表す信頼区間の幅が広がったと考えられる。単一の予測値では不可能であったが、このように信頼、予測区間を定量化する事で、予測の信頼が低い箇所を検知する用途にも用いる事が出来る。

このようにデータ数が少ない場合、予測の信頼性が低下する事は統計や機械学習全般の問題ではある。しかし今後は、川崎市以外のデータも学習する事や、ビッグデータを活用する事でデータ数を確保する事により、信頼性を向上させる事が望まれる。

4.7. 小括

本章では、NN モデルにブートストラップ法を効果的に適用し、通常のブートストラップ法と比較して計算量を抑えて信頼区間、予測区間を推定するスナップショットブートストラップ手法を提案した。提案手法を RNN モデルによる川崎市のわだち掘れ量の予測に適用し、信頼区間と予測区間の推定が可能であることを確認した。また、計算量を抑えるだけでなく、通常のブートストラップ法における予測区間を過大評価する問題を解決できることが解った。

提案手法は計算量が大幅に抑えられる事で、複数の維持管理シナリオについて予測を行う際にも適用が容易である。また、精度の高い予測区間が得られたことから、それを外れ値検出に用いる事で、舗装のデータに含まれるような記録に無い補修箇所等を検知する事に役立てる事も可能である。更に、本手法を舗装以外にも橋梁、電力需給予測、株価予測等の不確実性が高いデータに対して適用する事で予測区間を推定し、信頼性の高い意思決定に役立てる事が期待される。

5

第5章 シミュレーションとインタビューによる実用的な視点からの妥当性確認

* * * * *

本研究では、これまでに構築した舗装劣化予測手法を用いて、補修費用のシミュレーションと、舗装維持管理関連業務に長年の経験がある技術者へのインタビューを通して、より実用的な視点から構築手法の妥当性確認を行う。

* * * * *

5.1. 補修費用のシミュレーション

本研究ではRNNを用いた舗装劣化予測モデルを提案した。舗装劣化予測モデルは、舗装の健全度変化をシミュレーションする事で、ライフサイクルコストを算出するために用いられる。ライフサイクルコストに含まれる項目は図 1-4 に示した様に多岐に渡るため、それらを算出するためには実態を詳細に調査して基礎データを収集する事が必要であり、一律に算出する事は難しい。そのためここでは、舗装劣化予測モデルによりシミュレーションする舗装の健全度に大きく依存する補修費用についてのシミュレーションを行う。

構築した舗装劣化予測モデルを用いて、4.5.1 と同様の方法で3年ごとに時系列予測を行い、30年後までのシミュレーションを行った。シミュレーションの対象はひび割れ率の変化を用いる事とした。その理由は、舗装の構造的な破壊に至る原因はひび割れ率が多い事、実際にひび割れは補修を決定する原因になる事が多いためである。川崎市が路面性状調査を行い管理している区間は幹線道路が主で、管理水準が高いため、川崎市道路維持修繕計画⁹⁶⁾によるとおよそ90%の路線のMCIは5以上である。それにより、ひび割れ率が15%以上に達するデータは、試験データ5,424件中、208件のみであった。その事から、ひび割れ率が15%を超えた場合すぐに打替えを行い、その次の調査までには打替えによる補修を行った結果、ひび割れ率が0になるとした。その様にしてシミュレーションを行ったある単位区間のひび割れ率変化を図5-1に示す。

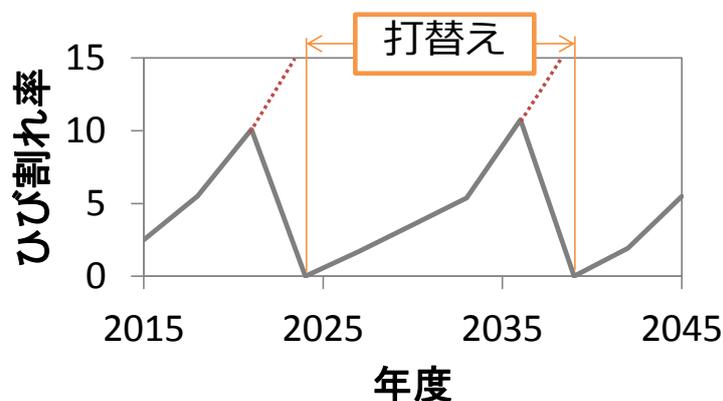


図 5-1 ひび割れ率のプロジェクトレベルシミュレーション結果例

図 5-1 はある単位区間についてのひび割れ率変化を示しているため、プロジェクトレベルの維持管理シミュレーションである。この図は3年間隔で予測した結果であるため、変化は断続的になっている。3年後にひび割れ率が15%を上回る場合、その次の調査までに補修を行ったとしているため、15%を上回る事は無い。また、劣化が比較的早い箇所であり、30年間の間に打替えによる補修が2回発生した。このように各単位区間のプロジェクトレ

ベルにおけるシミュレーションを積算し、単位区間を纏めて管理内の単位区間全体を対象とするとネットワークレベルになる。ここでは試験データのみを対象としているため、ネットワークレベル本来意味する管内全体に対しての維持管理シミュレーションではない事に注意が必要である。ネットワークレベルの累積補修費用の推移を図 5-2 に示す。

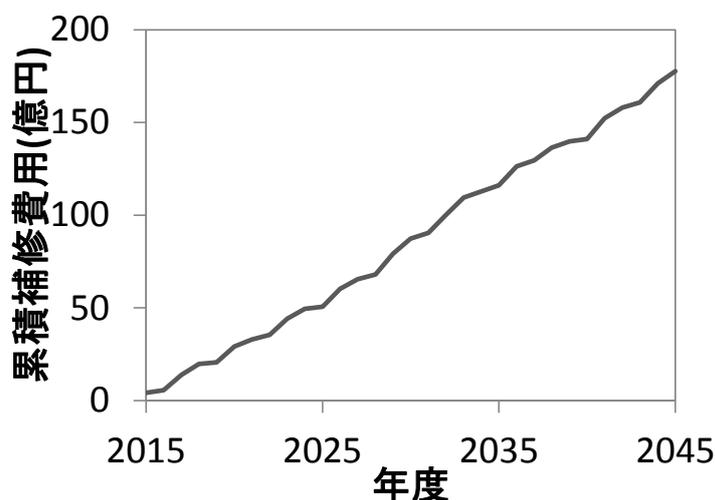


図 5-2 ネットワークレベル累積補修費用シミュレーション結果例

試験データにおけるネットワークレベルの補修費用を積算した結果、175 億円/30 年間であった。なお、打替えの補修費用を 1m^2 辺り 8,200 円として補修費用を算出した。

次に、予測精度による影響をシミュレーションするために、予測毎ごとに正規分布($\sigma=0.6$)に従う偶然誤差を加えて同様のシミュレーションを 100 回行い、補修費用の幅を算出した。ここで、 $\sigma=0.6$ は 2 章の GLM モデルと RNN モデル間の予測精度の差に相当する。その結果、30 年間の総計で 172~182 億円であり、ライフサイクルコストの試算は舗装劣化予測に大きく依存している事が解る。従って、最大で $182-175=7$ 億円程度の差があり、系統誤差は入っていない事、ひび割れ以外の要素は考慮していない事等により実際の誤差はより大きくなると考えられる事もあり、補修費の試算に予測精度が大きく影響を与えるという事が解る。従って、ライフサイクルコストに含まれる補修費用試算の精度は舗装劣化予測モデルの予測精度に依存する。そのことからライフサイクルコスト最適化(効率化)及び、維持管理予算の試算精度も同様に舗装劣化予測モデルの予測精度に依存していることが解る。

しかし、このような補修費試算を現実の維持管理状況と直接比較する事はできない。その理由は、実際の維持管理の現場では今回用いた路面性状データだけではなく、現場技術者が得られるあらゆる情報、例えば車線ごとの違いや占有工事、住民からの苦情等を考慮して決定しているためである。本研究で用いたデータにはその様な情報が含まれておらず、データベース中に存在する補修について、その補修を行った判断理由の情報も無いため、

実際の維持管理現場と同等の維持管理をシミュレーションする事が出来ない。それと関連して、舗装劣化予測は補修費以外にも、ライフサイクルコストに含まれる点検，運用，利用者の旅行速度やそれに応じた燃料消費量等の費用にも影響する。それらの費用についても実際の現場状況から現実的な算出方法を推定する必要がある。

5.2. 舗装維持管理技術者へのインタビュー

5.2.1. インタビュー方法

ここまで本研究で構築した手法が舗装維持管理に役立てる事が出来るのかを確認する事及び、舗装劣化予測が現状どの様に活かされているのかを確認する事を目的に、舗装維持管理業務に長年従事している技術者への半構造化インタビューを行った。

インタビューを実施する前に本研究の概要を説明した。その際に、本研究の特徴は次の2点である事を重点的に説明した。

- I. プロジェクトレベルで将来の予測精度が高い
- II. プロジェクトレベルで信頼、予測区間の推定が可能

質問の順番としては、最初にインタビュー対象者の舗装維持管理業務に関する経験を聞きだした。次に現状の舗装維持管理の課題や、路面性状調査の活用について尋ねた。次に上記の特徴がある本研究で構築した手法を用いる事で、舗装維持管理の効率化に貢献する事が出来るかを確認した。最後に、これから未来の舗装維持管理がどの様に変化していくかについて意見を頂いた。

インタビューの対象者は、株式会社パスコにおいて舗装調査、データ収集、分析、解析、コンサルティング等の国や自治体等の舗装管理者に対する舗装維持管理関連業務の経験が約30年のA、約20年のB、約10年のCの3名を選定した。インタビュー2018年8月7日に行い、各対象者のインタビューにかかった時間はA60分、B60分、C40分間程度であった。インタビューの場所は(株)パスコの本社ビル内で、内容は許可を取って音声を録音した。インタビューの質問項目及び、各インタビュー対象者からの回答はAppendix Aに記載した。

5.2.2. インタビュー結果

インタビュー結果を次の3つの観点から論じる。まず舗装劣化予測モデルが維持管理の現場でどのように用いられるかの必要性を整理し、次にそれぞれの必要性に対して妥当性を確認した結果を示す。最後に将来の舗装劣化予測モデルの応用可能性について論じる。

5.2.2.1. 舗装維持管理における舗装劣化予測モデルの必要性

舗装劣化予測モデルは舗装管理者の視点から見て大きく分けて3点必要性があるという。1点目は「1点目はプロジェクトレベルの、個別の補修箇所を選ぶために、劣化予測モデルを使う。例えば、わだち掘れ量が同じ2つの単位区間AとBがあるときに、5年後それぞれのわだち掘れ量がどうなるか、劣化予測結果から早く悪くなる方を先に補修を行う」た

めである。2 点目は、「ネットワークレベルの使い方。単位区間のブロックごとに、どの程度補修をすれば、管理レベルがどの様に変化するか、という事を推計するために用いる。逆に言えば、目的とする管理レベルを設定すれば、どの程度の予算を投入すれば良いのか、というシミュレーションができる」の様なシミュレーションを行うためである。3 点目は、「新工法、新材料の研究開発という使い方がある。新しい工法や材料を使った時に、どのような地域や交通条件下で、どうなるかを推計するために使う事が出来る。これらの 3 点が、精度のよい劣化予測モデルであれば、現場で使いたい、という事になる。」

この様な舗装劣化予測モデルの必要性は「ネットワークレベルとプロジェクトレベル、予測の長さ、短期的及び長期的で予測の使い方も異なってくる」ため、ネットワークレベルかプロジェクトレベルかという軸を上下にと、短期的か長期的という軸を横軸に取り、それらの 2 軸により舗装劣化予測モデルの必要性を分ける事が出来る。その関係を図 5-3 に示す。

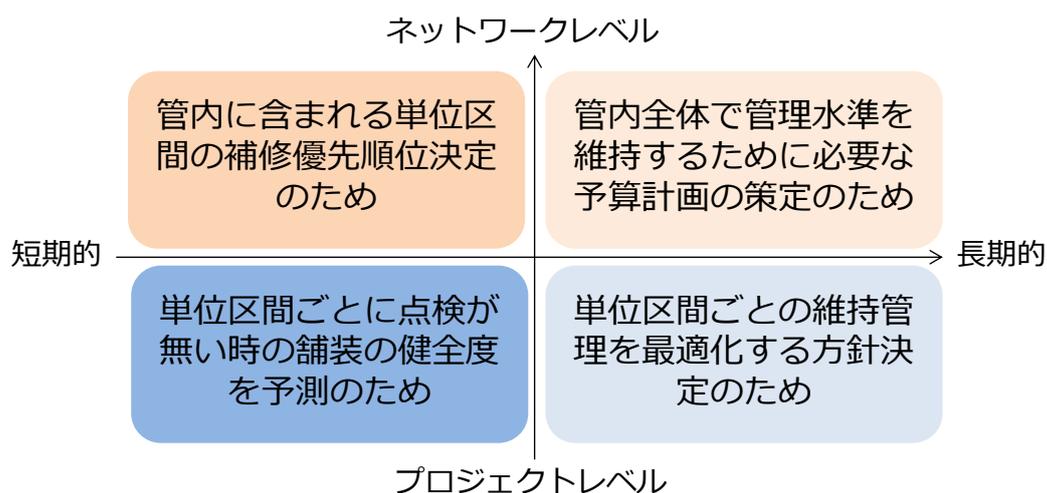


図 5-3 舗装劣化予測モデルの必要性

単位区間をグループ化し、そのグループ内の分布を予測するネットワークレベルの劣化予測モデルもある。しかし、2.2.1 で論じた通り、プロジェクトレベルはネットワークレベルのサブシステムでもあり、ネットワークレベルの舗装維持管理を最適化するために、本研究で構築したプロジェクトレベルの舗装劣化予測モデルのアウトプットを用いる事でプロジェクトレベルの維持管理計画の上でネットワークレベルの計画を立てる事が出来る。それにより、単位区間それぞれに最適な維持管理方策を立てる事はネットワークレベルの劣化予測モデルでは困難であるが、プロジェクトレベルの劣化予測を用いる事で可能であるため、より精緻な維持管理計画を立案する事が出来る。

5.2.2.2. 構築手法の妥当性確認

まず、短期的な舗装維持管理における予測精度向上の妥当性確認として、次のような回答が得られた。現在の予測精度だと「短期の予算計画で問題になるのは、計画を立てるけど、その通りに補修が出来ない事と、実際が予測通りにならない事がある」ため、構築手法の特徴である予測精度の向上により、「実際の現場の状況に乖離が少なくなるという事になるため、予測が確実に現場の状態を表す事になると、現場ではなくより上の方で持っている数値が、現場と同じになる。それにより、悪い所を確実にピックアップできるようになり、計画がより精緻なものになってくる」事が可能になる。「精度のよい劣化予測モデルであれば、現場で使いたい、という事になる」ため、構築手法の妥当性が確認できた。

また、より長期的な視点の舗装維持管理においては「当然、舗装劣化予測精度が向上する事で、維持管理に貢献できる。1, 2年後の予測はあまり変化しないから簡単かもしれないが、中長期的な予測はどんどん離れていくため難しい。その際に、どの程度の予算が必要かというシミュレーションが精度良くできれば、舗装に限らず、非常に重要」であり、長期的な必要性においても妥当性が確認できた。

著者は構築手法によりプロジェクトレベルで現場技術者の意思決定支援が出来る可能性を考えていたが、ここで確認できた妥当性、有効性は主にネットワークレベルの維持管理についてであった。今回のインタビュー対象者は補修などの「意思決定をしている訳じゃないから解らない」ため、その様なプロジェクトレベルや従来とは異なる新しい用途の可能性まで確認するには至らなかった。この点の確認は、実際に現場で意思決定を行う技術者へのインタビューを通して行う必要があり、今後の課題としたい。

その一方で、今回用いた路面性状調査データについて「発注者、管理者側が、データを取りつづける必要がある、という所についてどう考えるか。測定装置も同一ではない。そういった事も結構影響してしてくる」という課題が指摘された。しかし、今後は「今までの点検方法、センシング技術が高度化して、従来よりも安く大量にデータを取れるようになっていく」ため、それらのデータを用いる事でデータ取得コスト削減も可能になると考えられる。

また、構築手法のもう1つの特徴は、信頼、予測区間推定が可能である。その点についての妥当性は「長期的な予測については、確定的な予測で行うと少しずつ誤差が蓄積していくような事になるが、その場合は予測区間のように確率的に表す事で、より現実的に長期的に必要な予算を表せる」事にあると言える。

5.2.2.3. 将来の舗装維持管理における舗装劣化予測モデルの必要性

これからの舗装維持管理の課題として、「今までの点検方法、センシング技術が高度化して、従来よりも安く大量にデータを取れるようになっていくが、現状ではそれが十分に活

かせていない」事がある。これは2.2.5で論じたように、ビッグデータの活用が行われていない1事例でもある。本研究では路面性状調査のデータのみを用いているが、今後はリモートセンシングデータ、プローブカーデータ等のセンシング技術やIoT技術により得られるビッグデータを応用する事により、簡易かつ低コスト、高密度に点検データを取得する事が可能になり、それらのデータを用いた劣化予測モデルを用いる事でより精度の高い劣化予測が実現する可能性がある。本研究で構築した手法は多様なデータを用いる事が容易であるという特徴があるため、その様な場合における適用可能性が高いと言える。

5.3. 小括

本章では、シミュレーションとインタビューによる構築手法の妥当性確認を行った。先ずシミュレーションでは補修費用は舗装劣化予測モデルの精度に大きく依存している事ら、ライフサイクルコストの最適化(最小化)の精度も舗装劣化予測モデルの予測精度に依存する事が示された。

次に、舗装維持管理業務に対して長年の経験がある技術者 3 名へのインタビューから、舗装維持管理により予測精度の高い舗装劣化予測モデルが求められている事、その予測精度が高いほどより現実的な維持管理計画を策定出来る事から、ネットワークレベルにおける構築した舗装劣化予測手法の有効性を確認できた。

6

第6章 考察

* * * * *

本章では、これまでに述べた研究全体から得られた考察を論じる。研究全体を通して得られた知見として、舗装劣化予測の予測誤差要因や、構築手法の舗装以外への適性や、構築手法から得られる示唆として、維持管理業務全体のシステム化を進める事の重要性を考察する。

* * * * *

6.1. 他地域への適用可能性

本研究では、川崎市の路面性状調査により得られたデータを用いて舗装劣化予測モデルを構築した。このデータには次のような特徴がある。

- 対象は幹線道路のみで、生活道路のデータは含まない
- 3年間隔に、継続して調査されている
- 検定試験に合格した装置で調査されている

これらの事から、本研究で構築した舗装劣化予測モデルは、上記の特徴を持ち、気候条件が全く異なる積雪寒冷地等の地域でなければ、新しいデータを学習せずに、本研究で学習した結合荷重パラメータを用いてある程度の予測が出来る可能性がある。特に、第3章で論じた将来の劣化予測に適した方法を用いる事により、特に過学習を抑制した場合に適用可能性が高くなると考えられる。しかしこの点について、実際に追加検証する事が求められる。

その様な箇所には該当しない場合、構築したモデルをそのまま用いる事は困難である事が考えられる。その場合には、予測する地域のデータを用いてクロスバリデーションを行い、RNNモデルの結合荷重パラメータを学習する事は当然必要になる。予測対象である路面性状値について、検定試験に合格している等ある程度気象条件の違い、その地域の舗装材料の特徴等、地域特有の特徴を示すパラメータを新たに追加し、転移学習を用いる事で川崎市のデータを活かしつつ、新しい地域に適応したモデルを構築できると考えられる。この点に関しても、実際に他地域のデータを用いた追加検証が求められる。

6.2. 舗装劣化予測モデル以外の応用可能性

本研究では、近年大きく発展した RNN モデルの手法を導入した舗装劣化予測モデルを用いる事で、分布の異なる各路面性状値を対象として従来の単位区間に対する予測モデルである統計的な回帰モデルである GLM モデルや、より単純な MLP モデルと比較した際に精度高く予測できることが解った。GLM では、予め各路面性状値の分布の違いをデータの特徴の 1 つとして考慮し、モデルを設計する必要がある。しかし、RNN ではその様に用いるデータの特徴を考慮してモデルを設計する必要がない。その理由は、従来の統計モデルはデータをモデルに当てはめるという考え方であるのに対し、NN モデルはモデルがデータに適合するという考え方である。それにより NN モデルは過適合の恐れがあるが、ドロップアウトにより過適合を抑え、第 3 章で詳細を述べたようにクロスバリデーションにより過適合しないようにネットワークの自由度を調整する事で過適合しないモデルを構築する事が出来る。それにより、RNN モデルはそれぞれ異なる分布であるひび割れ率、わだち掘れ量、平坦性の分布を学習する事が出来た。

点検データにはランク評価のように離散値による評価も多い。その様な分類問題に適用する際には、次のソフトマックス関数を RNN の出力に用いる事で精度高く分類問題に適用可能であることが解っている。

$$y_k \equiv \frac{\exp(a_k^{(L)})}{\sum_{j=1}^K \exp(a_j^{(L)})} \quad (6.1)$$

ここで、 y_1, \dots, y_K は出力の数で総和は常に 1 になる。 $a_k^{(L)}$ は出力層 (L 層) の活性である。このソフトマックス関数は、画像の分類、機械翻訳等で幅広く使われている。

これらのことは、入力データとしても連続値、離散値問わず構築モデルを他の公共インフラ点検時系列データに適用できる可能性がある事を示している。本研究で用いた路面性状値は交通センサ等大型車交通量のデータが存在しない箇所がある等欠損が存在する事がある。公共インフラの点検データも同様に、全ての箇所で同じ点検や属性情報が完備されていない事が多く、欠損データが存在する。通常統計解析では欠損の存在はモデルの予測結果に大きな影響を与えるため、補完する必要がある。しかし、NN モデルは欠損データを欠損として学習する事で、自動的に欠損の扱いを学習する事が出来る。また、欠損の値を 0 としておけば、欠損の入力ユニットから伝達される値が 0 になるため、逆誤差伝播法による欠損ユニットに接続している結合荷重パラメータの傾きも 0 になり、その時だけ欠損の入力ユニットを単にない物として扱う事が出来る。そのため欠損データに強いという特徴があり、欠損データが存在する事が多い公共インフラ点検時系列データに適すとと言える。

このことは、ICT 技術の発展により蓄積されるデータ量が膨大となり、ビッグデータと呼ばれるデータの活用の観点からも重要である。近年スマートフォンのプローブデータや、車載センサ、監視カメラ、衛星リモートセンシング等のデータの蓄積、利用性が向上している。実際に図 6-1 に示すように、国内の通信トラフィックは加速的に増加しており⁵⁵⁾、ビッグデータは今後より質、量ともに増加していく事が予想される。公共インフラの劣化予測モデルについて言えば、一般の乗用車に搭載している様々なセンサ情報をプローブデータの 1 つとして集約して、それをを用いた健全度診断等に用いる事が出来る可能性がある。

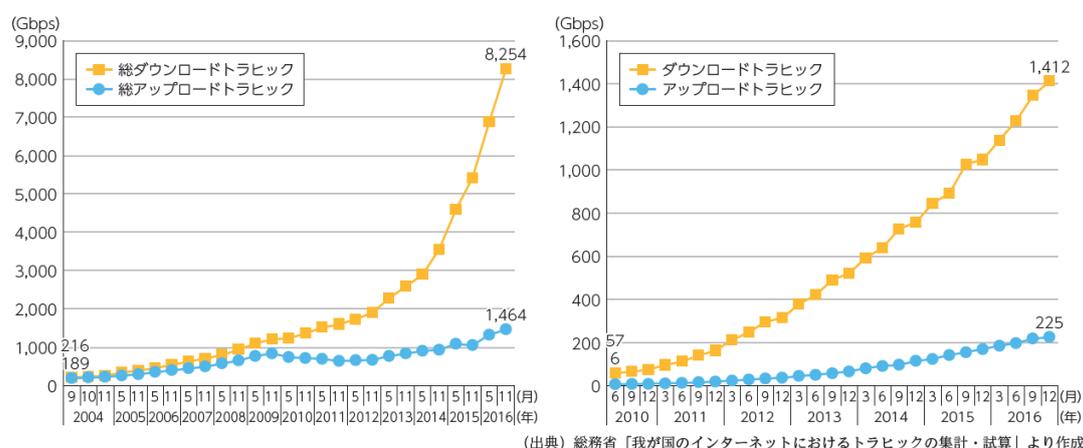


図 6-1 トラフィックの推移(左:ブロードバンド, 右:移動体通信)⁵⁵⁾

舗装劣化予測について言えば、自動車やスマートフォンのプローブデータに含まれる、加速度情報、旅行速度、ドライブレコーダー画像や、超小型衛星による高頻度な衛星リモートセンシングデータを用いる等の事が考えられる。それらのデータと共に、従来通りの点検データを正解データとして用いる事で、より密度の高い劣化予測が可能になる。

また、RNN モデルを用いた種々の研究の中でも、本研究は公共インフラという非常に寿命が長い物を対象にしている点に特徴がある。通常 RNN が用いられる音声データや機械翻訳等では、短期的でサンプリング間隔が短い時系列データであるのに対して、構造物の点検データは寿命が 10 年以上でサンプリング間隔も数年以上の単位と非常に長い時間スケールを持っている。その様な場合、第 3 章で論じたように、その長期間にわたる時間の間に法令、素材や点検方法が変化するため、過去のデータとこれから得られるデータの母集団が同じと仮定する事に無理がある。サンプリング間隔も長いため、同じ管理単位区間に対して、数千もの時系列データ点数を音声データや機械翻訳の様に確保できない等の特徴がある。

また、もう 1 つの特徴として、音声データや機械翻訳等の教師データには基本的に誤差が無いもしくは僅かだが、4.1 で論じたように公共インフラの点検データには大きな誤差が

含まれるため，事前に外れ値の除去及び，点予測値だけを用いるのではなく，予測誤差を定量化する事が実用上重要になる点である．本研究はその点にも解決策を提示し，第 4 章で提案した手法により，舗装管理者が各管理単位区間に対する予測誤差を確認する事が出来る．

6.3. わだち掘れ量予測誤差要因の分析

4.6 で示した予測区間により，本劣化予測手法による予測誤差を定量化，可視化することができた．それによると，わだち掘れの予測区間は±2～3mm 程度ある一方，データの極めて少ないわだち掘れ量が多い箇所以外の信頼区間は±1mm 以内であり，予測区間と比較して小さい．

予測誤差に含まれるモデル化誤差が少ないと仮定すれば，予測誤差には，次のような物が含まれる．装置の測定誤差，測定装置間の差である機差，測定業務が人的作業に依る事から人的ミス等を含む測定誤差や，測定，記録されていない事象によると考えられる舗装の健全度変化である．そのうち，わだち掘れ量測定装置の誤差については多くの研究があり，3.3 で幾つか考察している．その中でも比較的新しく，測定精度の高い装置間の比較を行った FHWA(Federal Highway Administration)の調査報告⁷⁸⁾によると，最も精度の高い3装置間でも 1.42mm 程度の偏りがある事が解っている．従って，わだち掘れ量に含まれる予測誤差は多くが装置の測定精度に起因すると考えられる．

6.4. データの密度や可用性に関する舗装維持管理業務への示唆

6.3 第4章で論じたように、本研究で用いた路面性状データには比較的大きな測定誤差が存在する。それにより、現在の健全度及び劣化予測精度に限界がある。本研究では、測定誤差の軽減は4.1でTukey g and h分布を用いた外れ値除去処理を用いているが、外れ値除去処理で除去不可能な誤差は必ず存在する。

その様な測定誤差要因を取り除くには、本質的にメンテナンス業務自体をシステム化、自動化を進める事で、維持管理業務を効率化すると同時に、詳細なデータを自動的に記録し、デジタルのデータベースとして保持する事で可用性を向上する事が重要である。

上述の様な大きな測定誤差が存在する要因の1つは、路面性状調査の管理単位区間が50m～200m程度と大きい事がある。実際はその管理単位区間内に様々な箇所が存在するはずである。その様に単位区間が大きい理由は、従来のデータベースでは密度の細かい大量のデータを扱う事が難しかったことと、測定時の位置情報の精度が低かったためである。しかしそれらの問題は現在では技術レベルの向上により解決しつつある。従って、例えば5mや1m等の細かい密度でデータを記録するようにする事で、単位区間内に含まれる不均一な変化についても劣化予測できるようになる。

他にも測定誤差の要因として、測定装置の精度の限界や、調査時の気象条件、測定装置による誤差の傾向などがある。これらの項目は、調査を行った時点の情報を自動的に記録するシステムを導入する事が好ましい。これは、機械調査だけではなく、日常巡視や近接目視点検等の際も同様である。

また、その他の測定誤差の要因として、舗装材料の違い、占用工事、日常巡視の際に発見したポットホール等のデータは、舗装工事を担う各土木事務所に記録があると考えられるが、その記録をデータベースシステムに登録してデジタルデータとして整備している事は少なく、利用できない事が上げられる。そのため、それらの情報は各事務所に存在するものの、管理方法も基準も異なる中で各事務所から最新の情報を集める事は困難であり、それらの情報が存在しても活かす事が出来ない状態である。それらの情報を活かすためには、点検業務自体の情報システム化を行い、点検の効率化と記録の自動化、可用性向上を行う必要がある。それにより、6.2で述べたように提案手法の説明変数にそれらのデータを追加した劣化予測モデルを用いる事で、予測精度の向上、ひいてはより最適な維持管理を実現する事が出来る。

例また、2.4.6において、各路面性状値の平均値の変化から、今回用いたデータの補修記録が年度単位であるため、路面性状調査の前後どちらに補修が行われたか不明である事により、補修後経過年数0～1年程度の所で明らかな異常値が見られることについて考察した。

それ以外にも、データからどのような路線を重視しているか、維持管理水準はどの程度かなど、川崎市の維持管理がどのように行われているのかを推定する事ができる可能性がある。

6.5. 本研究の特徴

本研究では, RNN モデルによる舗装劣化予測手法の構築とその検証結果について論じた. 本研究の独自性は次の 3 つの特徴から構成される.

- I. 過学習や勾配消失問題を解決した近年の RNN モデルにより, 川崎市という限られた地域における, プロジェクトレベルの舗装劣化予測手法を構築した. MLP 及び GLM モデル構築手法の予測精度を比較した結果, ひび割れ率, わだち掘れ量, 平坦性の 3 つの路面性状値全てにおいて構築手法の予測精度が高く, 最大で 20%程度予測精度の差があった.
- II. 舗装劣化予測モデルの試験方法として, 舗装劣化予測モデルは従来真の舗装のパフォーマンスを推定するパフォーマンスモデルとして構築されることが多かった事に対して, 本研究は将来を予測する場合は仮想的な将来を試験データとする事で, 過学習を抑え, 将来の予測に対する予測精度, 信頼性が高い舗装劣化予測モデルの試験方法を構築した.
- III. NN モデルの予測区間推定手法として, 特に舗装の様に劣化の不確実性が高い場合, 予測誤差の減少には限界があるため, 計算量を抑えて, 精度高く予測誤差を定量化する予測区間推定手法を提案した.

I.及びII.により, 将来の予測に対してより精度の高い予測が可能になった. それに加えて, III.により, 舗装管理者は各単位区間がある健全度に達するリスクを考慮する事を考慮して最終的な判断が出来るため, 従来の劣化予測モデルより更に維持管理計画立案に対し有効である. 従って, 実用的な観点から提案手法を舗装劣化予測モデルの 1 手法として実務に取り入れる価値がある. 特に, 予測の信頼性を表す予測区間推定手法は, 今後更に適用範囲が広がっていく NN モデルに共通して適用可能な手法であり, 応用範囲が広い. 従って, 舗装劣化予測の 1 手法としてだけではなく, ノンパラメトリックに計算量を抑え, かつ精度高く NN モデルの予測区間を推定する手法として普遍性が高い. 通常のブートストラップ法ではパラメータの初期値及び学習データは毎回ランダムに並び替えられる事によるランダム性を考慮してしまうため予測区間を過大評価する事, モデルの学習を最初から行うため計算時間が単純にブートストラップ標本数倍増加したという課題があった. 提案手法ではモデルを途中から学習を行う事によりそれら 2 つの問題を同時に解決できる事を示した点で学術的な観点から高い価値がある.

6.6. 今後の課題

本研究では川崎市の路面性状調査データに適用した。このデータはおよそ 3 年間隔で同じ単位区間を点検したデータであるため、データの時間密度が低い。道路管理者が行う日常巡視では、ポットホールや落下物等突発的に起こりうる事象に対して対策を行うため、本研究の範囲ではこれらの事象について対策を行う事は出来ない。しかし、それらの突発的事象についても、より時間密度の細かいそれら突発事象発生に関するデータがあれば、ある程度予測が可能であると思われる。それにより、日常巡視のタイミング、頻度、方法等についての効率化に寄与できる可能性がある。

また、川崎市以外の他地域への適合性についても課題がある。本研究ではクロスバリデーションにより、基本的に学習に用いていない単位区間で評価を行うため、寒冷地等の環境が全く異なる地域を除いてある程度の適合性がある可能性はあるが、その事を実際に検証する必要がある。

他にもモデルの面で改良する余地がある。例えばリモートセンシングデータや、気象データ、プローブデータを入力データに追加する事が考えられる。また、今回のモデルでは時刻変化を考慮しているが、空間方向の影響は考慮していない。そのため、ある単位区間の前後の区間や路線全体の影響を考慮したモデル化による精度向上が考えられる。それ以外にも、今回用いたひび割れ率、わだち掘れ量、平坦性の 3 つの路面性状値間の相関は低いため、相互に予測する事は簡単ではないと考えられるが、リモートセンシングデータ等を追加で用いることで予測が可能になればその 3 要素を全て調査する必要が無くなり、維持管理効率化に繋げる事が出来る事が期待できる。

また、ライフサイクルコスト算出にも課題がある。適切に利用者費用や割引率を設定する事、さらに言えば舗装だけではなく、地下埋設管やトンネル、橋梁の工事と同時に舗装の工事を行うなど、様々な公共インフラ含めたライフサイクルコスト最適化に資する維持管理を目指す必要がある。

インタビューは調査、ネットワークレベルの維持管理計画立案等の業務経験者に対して行う事は出来たが、プロジェクトレベルの意思決定を行っている現場技術者へのインタビューを行い、プロジェクトレベルの必要性、有効性を確認し、本手法を現場実装していく必要がある。

7

第7章 結論

* * * * *

経済成長の停滞や少子高齢化、公共インフラの老朽等の背景から、舗装維持管理の効率化が求められている。本研究を通して構築した手法の独自性を構成する3点の特徴を示し、検証、妥当性確認の結果を整理し、全体の結論を述べる。

* * * * *

少子高齢化、経済成長の停滞と同時に公共インフラの老朽化が深刻化しており、維持管理を効率的に行う必要がある。本研究では公共インフラの中でも最も基本的なインフラである舗装維持管理の効率化に着目した。現状の舗装維持管理は、沿道住民の苦情や路線の重要度等を技術者がその都度判断し、オーバーレイ等の補修や打ち替えを行う等、対処療法的に行われている。その様な舗装維持管理は、劣化予測モデルにより様々な施策を行った場合をシミュレーションしてライフサイクルコストを算出し、その中から最適な維持管理計画を選択する事で効率化が可能となる。そのライフサイクルコストに含まれる補修費用、利用者費用等各種費用は舗装の健全度に依存しているため、舗装の劣化予測が重要である。しかし舗装劣化の不確実性は非常に高い事から劣化予測精度が低いため、劣化予測に基づく維持管理計画の精度も低く、効果的に劣化予測を用いる事が出来ていなかった。本研究はその課題を解決するため、人工知能の分野で近年急速に発展した RNN モデルを用いた舗装劣化予測モデルを構築し、川崎市で行われた路面性状調査の実データを用いて検証を行った。本研究の独自性を構成する特徴は次の 3 点である。

まず、1 点目に従来の NN モデルに存在した勾配消失問題や過学習等の困難な問題を解決した近年の RNN モデルを用いる事で、単位区間に対する従来の舗装劣化予測モデルと比較して最大で 20%程度精度高く予測できる舗装劣化モデルを 2 章で構築した。また、RNN モデルはデータから特徴を学習する事が出来るため、ひび割れ率、わだち掘れ量、平坦性の異なる指標を同じ構造のモデルで予測できる事が明らかとなった。

2 点目に、時間スケールが長く、データの密度が低いという舗装点検データの特異性を考慮して、将来の予測精度に特化したクロスバリデーションを行う方法を 3 章で構築、検証した。その方法を用いる事で、過去のデータに対する過適合を抑えて、将来の予測に対してより予測精度が高く、信頼性のある予測を行う事が出来るようになる。

これら 2 点により、目的とした舗装劣化予測モデルの高精度化、特に実用上予測する将来の予測精度について精度向上が出来ることを確認した。しかし、記録されていない劣化要因や測定誤差により予測精度には限度があり、単一の予測値のみから精度の高い維持管理計画を立案する事は難しい。

そこで、3 点目に従来よりも大幅に計算量を抑えて精度の高い信頼、予測区間推定手法を 4 章にて設計、検証した。計算量が抑えられたことで様々なシナリオについて予測区間を推定する事も容易になり、例えば観測値の精度や予測が外れる確率を図示する事等に用いる事が可能である。それにより、舗装管理者は単一の予測値だけではなく、例えば設計寿命や維持管理水準以上に健全度が悪化するリスクを考慮して維持管理計画を決定する事が出来るため、従来の舗装劣化予測モデルよりも更に有用性が高い。

シミュレーション及びインタビューを用いて本研究で構築した手法に対してより実用に近い観点からの妥当性確認を 5 章で行った。30 年間の舗装補修費用のシミュレーションを

行い、舗装維持管理の効率化、即ちライフサイクルコストの最適化(最小化)の精度が舗装劣化予測モデルの精度に依存している事を示した。また、舗装維持管理関連業務に長年の経験がある技術者へのインタビューから、ネットワークレベルの維持管理計画立案において、舗装劣化予測モデルの精度向上により、より現実的な維持管理計画立案が可能になる事を確認した。

これらの事により、本研究は舗装劣化予測モデルの高精度化及び、計算量を抑えた信頼、予測区間推定手法を構築、検証、実用的な視点からの妥当性確認をしたものである。

Appendix A

5.2におけるインタビュー対象者3名に対する質問と回答を以下に示す。なお、質問の順番は、他の質問項目に関連する回答を頂いた際には、そのまま他の質問項目について聞き出すなど、話の流れに合わせているため、完全に下記の順番通りに行っている訳ではないが、出来るだけその順番に則り質問するようにした。

まず質問項目を示し、その後にそれぞれの質問No.に対応した3名の回答をそれぞれ示す。

表 A-1 質問項目

No.	質問内容
1	舗装維持管理に関連する業務内容とその経験年数を教えて頂けないでしょうか。
2	現状の舗装維持管理の課題は、どのような事があると思われますか。
3	地方自治体は国よりも道路延長が多く維持管理の負担が多いと言われていますが、それにより予算、技術者が足りないなどの事が実際に問題になっているのでしょうか。
4	補修、舗装構造等の意思決定はどのようにされているのでしょうか。
5	本研究の構築手法を用いる事で、管理者の意思決定及び、維持管理効率化に役立てる事が出来ると思われますか
6	近年、舗装維持管理効率化のための、新しい業務や取組事例等を教えて頂けないでしょうか。
7	将来の舗装維持管理効率化はどのようにになるとと思われますか。

表 A-2 インタビュー対象者 A の回答

質問 No.	回答内容
1	経験年数は約 30 年，データ収集，分析・解析，マネージメントシステムのデータ提供全て
2	今までの点検方法，センシング技術が高度化して，従来より安く大量にデータを取れるようになってきているが，現状ではそれが十分に活かせていない．近年，目視点検を義務化するようになってきているが，機械点検によりコスト削減(効率化になる)になる．それを今後はより生かしていくべきである．
3	<p>舗装だけで効率化は限界があり，公共インフラ全体をトータルで考えた方がいい．例えば共同溝を作る前に舗装の補修を行う意味はない．管理している公共インフラ全体として効率化する必要がある．</p> <p>社会貢献のために，市民等の舗装利用者のために，より良い道路を提供する事が最終的なゴールになるはず．自治体などの舗装管理者は，そのための業務を行っているに過ぎない．そのために，最終的には舗装の利用者に対して直接サービスを提供する事が考えられる．そのためには，だれが何をいつほしいのか，それを分析する事が必要．今後長期保証の一環として，今後より民間管理が増加すると思われるが，そこに対してサービスを提供するというが考えられる．</p>
4	自治体としては苦情，要望が大きい．川崎市等の幹線道路はまだ計画的に補修をする事はある．
5	<p>劣化予測の必要性は，管理者側と道路利用者側の視点があるよね．1つ目はプロジェクトレベルの，個別の補修箇所を選ぶために，劣化予測モデルを使う．例えば，わだち掘れ量が同じ 2 箇所 A と B あったとしたときに，5 年後それぞれのわだち掘れ量がどうなるか，劣化予測結果から早く悪くなる方を先に補修を行う．</p> <p>2つ目は，ネットワークレベルの使い方．単位区間のブロックごとに，どの程度補修をすれば，管理レベルがどの様に変化するか，という事を推計するために用いる．逆に言えば，補修量は目的とする管理レベルを設定すれば，どの程度の予算を投入すればいいのか，というシミュレーションができる．</p> <p>3点目は，新工法，新材料の研究開発という使い方がある．新し工法や材料を使った時に，どのような地域や交通条件下で，どうなるかを推計するために使う事が出来る．国交省では，契約上は長期保証という舗装工事の発注形態で，民間に舗装の維持管理を委託し，長期的な期間，管理者の設定したパフォーマンスを維持しなさい，という方法がある．そのために，保証期間中持たせる事をシミュレーションするという事に使える．</p> <p>道路管理者として，先の 3 つの点が，精度のよい劣化予測モデルであれば，現</p>

	<p>場で使いたい、という事になる。また、道路利用者の視点として劣化予測を使えるかどうかというのが、何らかのビジネス展開を昔から考えているが、難しい。</p>
6	<p>ホームページで社会資本の状態を公開するようにつつある。昨年度、国よりも土木学会が先行してインフラの健全度を公表した。そういうのを自治体が単独でやれば、今年は税金をどれだけ投入しました、管理レベルで現状はこれだけ悪い所がありました、去年と予算を10億減らしたらこうなりました、といった情報を住民に対して提供するという使い方ができる。</p>
7	<p>コンセッション事業の様に民間により何らかの維持管理基準を決め、それを長期的に維持する長期保証が今後はより広がっていき、50年、100年とその様な形で維持管理されるようになっていくと思う。現在の舗装管理者(自治体等)がその様な管理をするよりも、実際に工事を行う舗装会社が行った方が効率が良い。その方がよりライフサイクルコストを低減し、効率化する事に対してより強い動機づけができる。管理する民間業者によって効率が良かったり悪かったりするため、その競争によってより効率化できるのではないか。そのため、現在自治体などの管理者がやっている役割を民間が担うようになっていくのではないか。</p>

表 A-3 インタビュー対象者 B の回答

質問 No.	回答内容
1	経験年数は約 20 年，測量調査，データ分析，維持管理計画など
2	財政が厳しいから，効率的に直していかないといけない．やっぱりお金が少ない中で，適切に処理をして，計画的に直していかないと．
3	<p>国道は少なく，多分生活道路は 120 万キロくらいある．そのため，幹線道路じゃない場所は管理水準を低くしている．舗装の点検は量が多すぎるため，点検が義務になっていない．橋梁やトンネルは 5 年に 1 回が義務付けられているが，舗装は点検要領にも定期という文字はない．目安としては 5 年に 1 度など記載されている．生活道路なんかは 10 年に 1 度でもいい．</p> <p>また，維持管理水準が維持できない事で，近年は道路瑕疵件数が増加しているのは事実．お金が無くて瑕疵が増えてしまうから，廃道にしてしまうしかない．</p>
4	<p>場所による．例えば DID 地区だったら，市民要望もあるが，劣化している所を優先的に補修する．山地とか交通量の少ない所では，市民要望が出るまでは，どんなに悪くなくても補修しなくても良い．そのため，路線をグループ化して，管理方法をそれぞれ別々に設定する．今は予算制約が厳しくなっているため，山地などの交通量が少ない，悪くて放つといっても問題がない所は，そのような管理方法になっている．それにしても，シミュレーションや将来推計が無ければ，財政，住民に対しての説明ができないため，何れにせよ劣化予測によるシミュレーションは必要になる．</p>
5	<p>維持管理のやり方もいろいろあるため，一概には言えない．例えば何年か 1 回に調査をしている様な所であれば，その間の状態を予測する必要がある．ただし，それが殆ど劣化が進行しない，誤差の範囲内であればあまり意味はないのではないかな．</p> <p>ただし，中長期間に必要な予算がどの程度であるか，というものであれば，長期間の予測区間で設定できれば，より現実的に合う予算の範囲が表す事が出来る．単一の予測値だけだと，本当にその様になるか解らない．</p> <p>短期計画を立てる場合には，いつどの程度悪いかという事を示す必要がある．その場合には，確定的な単一の予測値によってかかる費用を算出する必要がある．</p> <p>ネットワークレベルとプロジェクトレベル，予測の長さ，短期的及び長期的で予測の使い方も異なってくる．長期的な予測については，確定的な予測で行うと少しずつ誤差が蓄積していくような事になるが，その場合は予測区間のように確率的に表す事で，より現実的，長期的に必要な予算を表せるのではないかな．管理者費用と，利用者費用(車両走行費用)がトレードオフの関係にある．管理者</p>

	<p>費用は、道路の状態が良いほど高くなり、逆に利用者費用は道路の状態が悪いほど高くなる。ライフサイクルコストの最小化は、その 2 つを合わせて最小の所を見つけない。現状は MCI を道路の状態を表す指標として用い、その最小を求めるようにしている。</p> <p>維持管理計画のシミュレーションは、自治体の予算計画立案のため、予算がこれだけだと、どれほど舗装の状態が悪くなるよ、という事を説明するために使ったりする。短期の予算計画で問題になるのは、計画を立てるけど、その通りに補修が出来ない事と、実際が予測通りにならない事がある。予測よりも実際が良かった場合は、計画より補修の優先順位を下げられる。全部予測通りにはならないため、計画を立てるけど、その様な所は自由度を持たせている。日本の場合、市民要望など、声の大きい人に左右されるところが大きい。</p>
6	<p>補修計画を立てる際に、基準を維持する為の理想形があり、それに対して予算制約を考慮した現実的なところを出すようにしている。管理基準値を満たせる理想形をだして、出来るだけ予算を確保する必要がありますよ、というようにしている。同様に、優先順位を付けて、劣化速度係数が速い所を先に補修する等の事はやっている。</p>
7	<p>地方自治体はお金も人もいないけど、ストック量が多い。そうするとやはりお金がない。そのため、ここは廃道にするなどが増える。橋梁は 4 判定だと通行止めになる。橋もその先に人がいない場合は必要ない。そのためにコンパクトシティを進めている。</p>

表 A-4 インタビュー対象者 C の回答

質問 No.	回答内容
1	経験約 10 年，舗装の調査，システム的なデータ作成，舗装維持管理者のコンサルティング
2	舗装は膨大過ぎるため，全てのメンテナンスを行う事は難しい。
3	舗装については膨大過ぎるため，全部をメンテナンスしていく事は出来ない。そのため，メリハリをつけるという意味で，交通量が多い所，幹線道路，緊急交通路，等に焦点を当てて，あとは事後保守でいいのではないかと思う。それでも未だ予算が足りないとなっている。
4	路面性状調査の発注形態として，管内全体のネットワーク調査と，舗装工事の対象箇所のみを行うスポット的な調査がある。前者は予算の計画が主な目的で，後者はどこを直すかを定量的に判断する根拠資料として用いる。もちろん，前者も工事の根拠資料としても使えるが，代表車線調査を行っているため，現実ではない。後者の業務はあまりやっていない。恐らくは舗装工事内でやっている。うちでやるばあいも，道路管理者が建築会社に舗装工事を発注し，その中で調査をやる事が多い。
5	<p>当然，舗装劣化予測精度が向上する事で，維持管理に貢献できる。1，2年後の予測はあまり変化しないから簡単かもしれないが，中長期的な予測はどんどん離れていくため難しい。その際に，どの程度の予算が必要かというシミュレーションが精度良くできれば，舗装に限らず，財政を管理する上で非常に重要だと思う。但し，全ての管理単位区間を予測するというのは現実的に難しい。路床の状態は CBR 等で測定されるが，ピンポイントの測定だし，すべての箇所が解る訳ではない。その様な状況で精度の高い予測が難しい。それでも，統計的な予測で，これまでの劣化する傾向が，何かの要因に依るか解れば，予測精度が上がっていくのではないかと考えられる。</p> <p>素人考えでは，それには大量のデータが無いといけないのではないかと思う。そのためには，元のデータが必要になる，という所が発注者，管理者側が，データを取りつづける必要がある，という所についてどう考えるか。測定装置も同一ではない。そういった事も結構影響してしてくるかと思う。もし，管理者側で管理やるので，投資し続けるのであれば，精度が向上すると思うので，舗装を管理する財政に対する説明責任として必要だと思います。</p>
6	舗装維持管理は，今後スマホにより振動を計測するような方法になっていくのではないかと。例えばバンプレコーダーがその様なデータを既に公開している。
7	ポットホールは発見次第別途穴埋めする必要があるが，それ以外は，本当にお金がない自治体は，スマホのデータで管理するのもいいのではないかと思う。

但し、データの出所が不明。なので、自分の市内のバスやタクシー、もしくは一般市民に装置(スマホ)を付けてもらって走ってもらうのはありだと思う。ひび割れは映像を取って置き、それを機械学習して著しく劣化している箇所を抽出する等が考えられる。

参考文献

- 1) 国土交通省編. : 第 I 部第 1 章 3 節社会インフラの維持管理をめぐる状況, 国土交通白書 2014, pp. 28–45, 2014.
- 2) 国土交通省 社会資本整備審議会 道路分科会 基本政策部会. : 資料 5 老朽化対策の本格実施について, 第 44 回基本政策部会, 2014.
- 3) 国土交通省編. : 第 I 部第 1 章 1 節我が国を取り巻く環境と社会経済状況, 国土交通白書 2017, pp. 2–12, 2017.
- 4) 国土交通省 社会資本メンテナンス戦略小委員会. : 第 6 回社会資本メンテナンス戦略小委員会 資料 6 各分野の点検の状況報告, 2013.
- 5) 国土国交省. : 道路統計年報 2017 表 2 道路現況総括表, <<http://www.mlit.go.jp/road/ir/ir-data/tokei-nen/index.html>>, 2017.
- 6) 国土交通省. : インフラ長寿命化基本計画 (行動計画), 2014.
- 7) 土木学会. : 舗装工学の基礎, 丸善出版, pp. 41–67, 2012.
- 8) 国土交通省 道路局. : 舗装点検要領, 2016.
- 9) 国土交通省編. : 第 II 部 1 章 6 節効率的・重点的な施策展開, 国土交通白書 2011, pp. 116–122, 2011.
- 10) Butt, A. A., Shahin, M. Y., Feighan, K. J., and Carpenter, S. H. : Pavement Performance Prediction Model Using the Markov Process, *Transportation Research Board*, , No. 1123, pp. 12–19, 1987.
- 11) 孔永健, and 福田正. : ネットワークレベル舗装修繕計画の最適化, *土木学会論文集*, Vol. 526, No. 29, pp. 79–84, 1995.
- 12) Zhou, B., Li, Z., Patel, H., Roshandeh, A. M., and Wang, Y. : Risk-Based Two-Step Optimization Model for Highway Transportation Investment Decision-Making, *Journal of Transportation Engineering*, Vol. 140, No. 5, pp. 04014007, 2014.
- 13) 服部洋, 古田均, 中津功一郎, 石橋健, and 三好紀晶. : 劣化予測における不確実性を考慮した橋梁維持管理計画策定システムの構築, *日本知能情報ファジィ学会 ファジィシステム シンポジウム 講演論文集*, Vol. 26, pp. 886–891, 2010.
- 14) Adelino, F., Antonio, A., and Luis, P.-S. : Probabilistic Segment-linked Pavement Management Optimization Model, *Journal of Transportation Engineering*, Vol. 128, No. 6, pp. 568–577, 2002.
- 15) Saliminejad, S., and Gharaibeh, N. G. : Impact of Error in Pavement Condition Data on the Output of Network-Level Pavement Management Systems, *Transportation Research Record: Journal of the Transportation Research Board*, , No. 2366, 2013.
- 16) Attoh-Okine, N. O. : Predicting roughness progression in flexible pavements using artificial neural networks, *Transportation Research Board Conference Proceedings*, 1994.

- 17) 谷本圭志, 杉本泰亮, 宮本慎也, 灘英樹, and 細井由彦. : 集合的維持管理方策に関するモデル分析—道路舗装と下水道管路を対象として—, *土木学会論文集 G (環境)*, Vol. 67, No. 6, pp. 83–91, 2011.
- 18) 国土交通省 社会資本整備審議会 道路分科会 道路技術小委員会. : 第 6 回道路技術小委員会 配布資料【3-2】, 2013.
- 19) 国土交通省 社会資本メンテナンス戦略小委員会. : 第 18 回社会メンテナンス小委員会 参考 2-2 市町村における持続的な社会資本メンテナンス体制の確立を目指して 参考資料, 2015.
- 20) 国土交通省 国道（国管理）の維持管理等に関する検討会. : 国道（国管理）の維持管理等に関する検討会とりまとめ, 2013.
- 21) 点検実施基準及び資格に関する検討委員会. : 点検実施基準及び資格に関する検討委員会 報告書, 2015.
- 22) 国土交通省 社会資本メンテナンス戦略小委員会. : 第 20 回メンテナンス戦略小委員会 参考資料 2 その他のアンケート結果, 2018.
- 23) NEXCO 総研. : 設計要領第一集（舗装編）, 2015.
- 24) 渡邊一弘, and 久保和幸. : 軽交通道路における舗装の管理実態及び損傷形態と構造的健全度, *土木技術資料*, Vol. 55, No. 3, pp. 22–25, 2013.
- 25) 富山和也, 川村彰, 藤田旬, and 石田樹. : 地方自治体の舗装維持管理実態を考慮した市街地道路の効果的な路面点検手法の開発, *土木学会論文集 F3 (土木情報学)*, Vol. 69, No. 2, pp. 54–62, 2013.
- 26) 小西貞則, and 北川源四郎. : 情報量規準, 朝倉書店, pp. 46–67, 2004.
- 27) Babashamsi, P., Golzadfar, A., Yusoff, N. I. M., Ceylan, H., and Nor, N. G. M. : Integrated fuzzy analytic hierarchy process and VIKOR method in the prioritization of pavement maintenance activities, *International Journal of Pavement Research and Technology*, Chinese Society of Pavement Engineering, Vol. 9, No. 2, pp. 112–120, 2016.
- 28) Castro-Nuño, M., and Arévalo-Quijada, M. T. : Assessing urban road safety through multidimensional indexes: Application of multicriteria decision making analysis to rank the Spanish provinces, *Transport Policy*, Vol. 68, pp. 118–129, 2018.
- 29) 小林潔司, 熊田一彦, 佐藤正和, 岩崎洋一郎, 青木一也, 小林潔司, 熊田一彦, 佐藤正和, 岩崎洋一郎, and 青木一也. : サンプル欠損を考慮した舗装劣化予測モデル, *土木学会論文集 F*, Vol. 63, No. 1, pp. 1–15, 2007.
- 30) 谷口聡, 伊藤正秀, 野村敏明, and 阿部忠行. : 舗装データベースを用いた供用性曲線作成手法に関する研究, *土木学会舗装工学論文集*, Vol. 8, pp. 99–106, 2003.
- 31) Wu, Z., Flintsch, G., and Ferreira, A. : Selection of pavement performance models for use in the Portuguese PMS, *International Journal of Pavement Engineering*, Vol. 12, No. 1, pp. 87–97, 2011.

- 32) Morosiuk, G., and Riley, M. : *Volume Six : Modelling Road Deterioration and Works Effects in HDM-4, Highway development & Management Series*, 2004.
- 33) 秋葉正一, 栗谷川裕造, and 佐藤弘史. : 多層構造を有する舗装用混合物の曲げ試験による弾性係数推定法とその適用について, *農業土木学会論文集*, Vol. 2002, No. 222, pp. 727–735, 2002.
- 34) Abu-Farsakh, M. Y., Gu, J., Voyiadjis, G. Z., and Chen, Q. : Mechanistic–empirical analysis of the results of finite element analysis on flexible pavement with geogrid base reinforcement, *International Journal of Pavement Engineering*, Vol. 15, No. 9, pp. 786–798, 2014.
- 35) Hadi, M. N. S., and Bodhinayake, B. C. : Non-linear finite element analysis of flexible pavements, *Advances in Engineering Software*, Vol. 34, No. 11–12, pp. 657–662, 2003.
- 36) Gajewski, J., and Sadowski, T. : Sensitivity analysis of crack propagation in pavement bituminous layered structures using a hybrid system integrating Artificial Neural Networks and Finite Element Method, *Computational Materials Science*, Vol. 82, pp. 114–117, 2014.
- 37) Coleri, E., Harvey, J. T., Yang, K., and Boone, J. M. : Development of a micromechanical finite element model from computed tomography images for shear modulus simulation of asphalt mixtures, *Construction and Building Materials*, Vol. 30, pp. 783–793, 2012.
- 38) 森修二, 岳本秀人, and 丸山紀美雄. : 積雪寒冷地における舗装メンテナンスに向けた路面性状予測について, *北海道開発土木研究所月報* No.598, 2003.
- 39) George, K. P., Rajagopal, A. S., and Lim, L. K. : Models for predicting pavement deterioration, *Transportation Research Board*, Vol. 1215, No. 1, pp. 25–32, 1989.
- 40) Madanat, S., and Ibrahim, W. H. W. : Poisson regression models of infrastructure transition probabilities, *Journal of Transportation Engineering*, Vol. 121, No. 3, pp. 267–272, 1995.
- 41) Salem, O., El-Assaly, A., and Abou-Rizk, S. : Performance prediction models of pavement highway network in Alberta, *Transportation Research Board 2003 Annual Meeting CD-ROM*, 2003.
- 42) Khattak, M. J., Landry, C., Veazey, J., and Zhang, Z. : Rigid and composite pavement index-based performance models for network pavement management system in the state of Louisiana, *International Journal of Pavement Engineering*, Vol. 14, No. 7, pp. 612–628, 2013.
- 43) Yu, C. H., Luo, D., Ding, W., Cohen, J., Small, D., and Islam, S. : Spatio-temporal asynchronous co-occurrence pattern for big climate data towards long-lead flood prediction, *Proceedings - 2015 IEEE International Conference on Big Data, IEEE Big Data 2015*, pp. 865–870, 2015.
- 44) Liu, L., and Gharaibeh, N. : Bayesian model for predicting the performance of pavements treated with thin hot-mix asphalt overlays, *Transportation Research Record: Journal of the Transportation Research Board*, Transportation Research Board of the National Academies, , No. 2431, pp. 33–41, 2014.

- 45) Kırbaç, U., and Karaşahin, M. : Performance models for hot mix asphalt pavements in urban roads, *Construction and Building Materials*, Vol. 116, pp. 281–288, 2016.
- 46) NAM, L. T., 貝戸清之, 小林潔司, and 起塚亮輔. : ポアソン隠れマルコフ劣化モデルによる舗装劣化過程のモデル化, *土木学会論文集 F4 (建設マネジメント)*, Vol. 68, No. 2, pp. 62–79, 2012.
- 47) Abaza, K. A. : Optimal Empirical-Markovian approach for assessment of potential pavement rehabilitation strategies at the project level, *Road Materials and Pavement Design*, Vol. 19, No. 3, pp. 1–22, 2016.
- 48) Anyala, M., Odoki, J. B., and Baker, C. J. : Hierarchical asphalt pavement deterioration model for climate impact studies, *International Journal of Pavement Engineering*, Vol. 15, No. 3, pp. 251–266, 2014.
- 49) Yang, J., Gunaratne, M., Lu, J. J., and Dietrich, B. : Use of recurrent markov chains for modeling the crack performance of flexible pavements, *Journal of Transportation Engineering*, Vol. 131, No. 11, pp. 861–872, 2005.
- 50) Lethanh, N., and Adey, B. T. : Use of exponential hidden Markov models for modelling pavement deterioration, *International Journal of Pavement Engineering*, Vol. 14, No. 7, pp. 645–654, 2013.
- 51) Hornik, K., Stinchcombe, M., and White, H. : Multilayer feedforward networks are universal approximators, *Neural Networks*, Vol. 2, No. 5, pp. 359–366, 1989.
- 52) Hannun, A., Case, C., Casper, J., Catanzaro, B., Diamos, G., Elsen, E., Prenger, R., Satheesh, S., Sengupta, S., Coates, A., and Ng, A. Y. : Deep Speech: Scaling up end-to-end speech recognition, *arXiv*, pp. 1–12, 2014.
- 53) Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L. : ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, Vol. 115, No. 3, pp. 211–252, 2015.
- 54) 松尾豊. : 人工知能の未来とデータ共有の新しい可能性, *情報管理*, Vol. 58, No. 8, pp. 597–605, 2015.
- 55) 総務省. : 平成 29 年版 情報通信白書, pp. 388–393, 2017.
- 56) 内閣府政策統括官 (科学技術・イノベーション担当) . : 戦略的イノベーション創造プログラム (SIP) インフラ維持管理・更新・マネジメント技術 研究開発計画, pp. 1–5, 2018.
- 57) 松尾豊. : ディープラーニングと人工知能の難問, *システム制御情報学会誌*, Vol. 60, No. 3, pp. 127–138, 2015.
- 58) Rosenblatt, F. : The perceptron: a probabilistic model for information storage and organization in the brain., *Psychological review*, Vol. 65, No. 6, pp. 386–408, 1958.

- 59) Rumelhart, D. E., Hinton, G. E., and Williams, R. J. : Learning representations by back-propagating errors, *Nature*, Vol. 323, No. 6088, pp. 533–536, 1986.
- 60) Nair, V., and Hinton, G. E. : Rectified Linear Units Improve Restricted Boltzmann Machines, *Proceedings of the 27th International Conference on Machine Learning*, , No. 3, pp. 807–814, 2010.
- 61) Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. R. : Improving neural networks by preventing co-adaptation of feature detectors, *arXiv*, pp. 1–18, 2012.
- 62) George, C. : Approximation by Superpositions of a Sigmoidal Function, *Mathematics of Control, Signals, and Systems*, Vol. 2, pp. 303–314, 1989.
- 63) 重原大二朗, 西澤辰男, 中源達雄, and 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.
- 64) 堀木賢一, and 福田正. : ニューラルネットワークによる舗装のパフォーマンスモデル, *土木学会論文集*, Vol. 1994, No. 496, pp. 99–102, 1994.
- 65) Tabatabaee, N., Ziyadi, M., and Shafahi, Y. : Two-Stage Support Vector Classifier and Recurrent Neural Network Predictor for Pavement Performance Modeling, *Journal of Infrastructure Systems*, American Society of Civil Engineers, Vol. 19, No. 3, pp. 266–274, 2012.
- 66) Kingma, D. P., and Ba, J. L. : Adam: a Method for Stochastic Optimization, *International Conference on Learning Representations*, pp. 1–13, 2015.
- 67) Tokui, S., Oono, K., Hido, S., and Clayton, J. : Chainer: a Next-Generation Open Source Framework for Deep Learning, *In Workshop on Machine Learning Systems at Neural Information Processing Systems (NIPS)* , Vol. 28, pp. 1–6, 2015.
- 68) Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y. : Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1724–1734, 2014.
- 69) Gers, F. : Long Short-Term Memory in Recurrent Neural Networks, *Lausanne, EPFL*, Vol. 2366, 2001.
- 70) Chung, J., Gulcehre, C., Cho, K., and Bengio, Y. : Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, *arXiv*, pp. 1–9, 2014.
- 71) Semeniuta, S., Severyn, A., and Barth, E. : Recurrent Dropout without Memory Loss, *arXiv*, pp. 1–11, 2016.
- 72) 日本道路協会編. : 舗装調査・試験法便覧第Ⅱ章, pp. 147–176, 2007.
- 73) 国土交通省 道路局. : 総点検実施要領 (案) 【舗装編】 , 2013.

- 74) Akaike, H. : A New Look at the Statistical Model Identification, *IEEE Transactions on Automatic Control*, Vol. 19, No. 6, pp. 716–723, 1974.
- 75) Karlaftis, A. G., and Badr, A. : Predicting asphalt pavement crack initiation following rehabilitation treatments, *Transportation Research Part C: Emerging Technologies*, Vol. 55, pp. 510–517, 2015.
- 76) 阿部頼政, and 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*, Vol. 1993, No. 478, pp. 117–123, 1993.
- 77) 宮崎文平, 加藤寛之, 小濱健吾, 貝戸清之, 風戸崇之, and 田中克則. : 膨大な路面性状調査データに基づく舗装補修施策の評価法の提案, *土木学会論文集 F4 (建設マネジメント)*, Vol. 71, No. 3, pp. 142–161, 2015.
- 78) 斎藤雅道, and 福田正. : 少数データによる舗装のパフォーマンスモデルの構築, *舗装工学論文集*, Vol. 1, pp. 181–186, 1996.
- 79) Tabatabaee, N., Ziyadi, M., and Shafahi, Y. : Two-Stage Support Vector Classifier and Recurrent Neural Network Predictor for Pavement Performance Modeling, *Journal of Infrastructure Systems*, Vol. 19, No. 3, pp. 266–274, 2013.
- 80) Simpson, A., Rada, G., Visintinelot, B., and Groeger, J. : Improving FHWA 's Ability to Assess Highway Infrastructure Health - Pilot Study Report Addendum Rutting Bias Investigation -, , 2013.
- 81) Ding, A. A., and He, X. : Backpropagation of pseudoerrors: Neural networks that are adaptive to heterogeneous noise, *IEEE Transactions on Neural Networks*, Vol. 14, No. 2, pp. 253–262, 2003.
- 82) Khosravi, A., Nahavandi, S., Creighton, D., and Atiya, A. F. : Comprehensive review of neural network-based prediction intervals and new advances., *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, Vol. 22, No. 9, pp. 1341–1356, 2011.
- 83) Bruffaerts, C., Verardi, V., and Vermandele, C. : A generalized boxplot for skewed and heavy-tailed distributions, *Statistics and Probability Letters*, Vol. 95, pp. 110–117, 2014.
- 84) Carter, N. J., Schwertman, N. C., and Kiser, T. L. : A comparison of two boxplot methods for detecting univariate outliers which adjust for sample size and asymmetry, *Statistical Methodology*, Vol. 6, No. 6, pp. 604–621, 2009.
- 85) Tukey, J. W. : *Exploratory Data Analysis*, , 1977.
- 86) Chryssolouris, G., Moshin, L., and Ramsey, A. : Confidence interval prediction for neural network models., *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, Vol. 7, No. 1, pp. 229–232, 1996.
- 87) Hwang, J. T. G., and Ding, A. A. : Prediction Intervals for Artificial Neural Networks, Vol. 92, No. 438, pp. 748–757, 1997.
- 88) MacKay, D. J. C. : The Evidence Framework Applied to Classification Networks, *Neural*

- Computation*, Vol. 4, No. 5, pp. 720–736, 1992.
- 89) Bishop, C. M. : Neural networks for pattern recognition, *Journal of the American Statistical Association*, Vol. 92, pp. 482, 1995.
 - 90) Nix, D. a., and Weigend, A. S. : Estimating the mean and variance of the target probability distribution, *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)*, Vol. 1, pp. 55–60, 1994.
 - 91) Khosravi, A., Nahavandi, S., Creighton, D., and Atiya, A. F. : Lower upper bound estimation method for construction of neural network-based prediction intervals., *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, Vol. 22, No. 3, pp. 337–346, 2011.
 - 92) Heskes, T. : Practical Confidence and Prediction Intervals, *Advances in Neural Information Processing Systems (NIPS)* , Vol. 9, pp. 176–182, 1997.
 - 93) Efron, B. : Better Bootstrap Confidence Intervals, *Journal of the American Statistical Association ISSN:*, Vol. 82, No. 397, pp. 171–185, 1987.
 - 94) Huang, G., Li, Y., Pleiss, G., Hopcroft, J. E., and Weinberger, K. Q. : SNAPSHOT ENSEMBLES: TRAIN 1, GET M FOR FREE, *ICLR 2017*, pp. 1–14, 2017.
 - 95) Graves, A. : Generating Sequences with Recurrent Neural Networks, *arXiv*, pp. 1–43, 2013.
 - 96) 川崎市建設緑政局道路河川整備部道路施設課. : 川崎市道路維持修繕計画, 2014.
 - 97) Loshchilov, I., and Hutter, F. : SGDR: Stochastic Gradient Descent with Warm Restarts, *arXiv*, pp. 1–16, 2016.
 - 98) Kysely, J. : A cautionary note on the use of nonparametric bootstrap for estimating uncertainties in extreme-value models, *Journal of Applied Meteorology and Climatology*, Vol. 47, No. 12, pp. 3236–3251, 2008.

研究業績

1. 定期刊行誌掲載論文（主論文に関連する原著論文）

- A. 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, 舗装工学論文集 E1（舗装工学）, Vol.73, No.3, pp.229-236, 2017
- B. 奥田知之, 鈴木康豊, 神武直彦：ニューラルネットワークを用いたわだち掘れ深さ予測の信頼区間と予測区間推定手法, 土木学会論文集 F3（土木情報学）, Vol.73, No. 2, pp.317-326, 2018
- C. 奥田知之, 鈴木康豊, 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モデルによる路面性状値予測手法の提案と定量的評価, 土木学会論文集 F3（土木情報学）, Vol.74, No.1, pp.33-48, 2018

2. 国際会議論文（査読付きの full-length papers）

- D. Tomoyuki Okuda, Kouyu Suzuki, Naohiko Kohtake : Proposal and evaluation of pavement deterioration prediction method by recurrent neural network, ICASMT 2017
- E. Tomoyuki Okuda, Kouyu Suzuki, Naohiko Kohtake : Non-parametric Prediction Interval Estimate for Uncertainty Quantification of the Prediction of Road Pavement Deterioration, IEEE ITSC2018 (発表予定)

3. その他の国際会議発表（ポスター発表）

- * Tomoyuki Okuda, Kouyu Suzuki, Naohiko Kohtake : Proposal of prediction of rutting amount by recurrent neural network, IIAI AAI 2017
- * Tomoyuki Okuda, Kouyu Suzuki, Naohiko Kohtake : Application of neural network model to pavement deterioration prediction to improve maintenance efficiency, CESUN 2018

4. 国内学会発表

- * 奥田知之, 鈴木康豊, 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, 第 78 回全国大会講演論文集, pp.45-46
- * 奥田知之, 鈴木康豊, 神武直彦：リカレントニューラルネットワークモデルによる路面性状値予測の検討, 土木情報学シンポジウム講演集 Vol.41, pp.159-162
- * 奥田知之, 鈴木康豊, 神武直彦：ニューラルネットワークを用いた劣化予測モデルの予測区間推定手法の提案, 土木情報学シンポジウム講演集 Vol.42, pp.231-234

謝辞

本研究論文は、慶應義塾大学大学院システムデザイン・マネジメント(SDM)研究科後期博士課程で行った研究成果をまとめたものです。本研究を行うに当たり、大変多くの方々よりご指導とご協力、そして励ましを頂きました。全ての方のお名前を記す事は出来ませんが、皆様から頂いたお力添えに深く感謝いたします。

主査及び指導教員の神武直彦教授には、2015年に入学して以来、研究活動や論文執筆のみならず、人生の先輩として研究者としての姿勢や考え方、社会人としての礼儀に至るまで幅広くご指導とご鞭撻を頂きました。神武研究室の多様性と、自由闊達な雰囲気、研究に対する支援体制は、研究を進めていく上で大きな支えとなりました。その様な素晴らしい環境を作り上げ、困難に直面した際には適切な助言を与えてくださいました。また、国内、国際学会やワークショップをはじめ、成長に繋がる多くの機会も与えて頂きました。心から感謝の意を表します。

また、博士学位審査にて副査をお願いいたしました、慶應義塾大学大学院 SDM 研究科附属 SDM 研究所の狼嘉彰顧問、同研究科の中野冠教授には、研究の方針からシステムエンジニアリング、用いるニューラルネットワークモデルに関してまで、幅広い視点から多様で有益な意見やご助言を頂き、深い議論を通して本研究の完成度が非常に高まりました。ここに記して感謝の意を表明します。

加えて、日本大学生産工学部土木工学科秋葉正一教授には、舗装、地盤の専門家としての観点から研究内容について有意義な議論をさせていただき、頂いた指摘やコメントは論文及び発表の質の向上につながりました。また、ご相談させていただいたときには研究の方針について前向きなご意見を頂き、研究を進める推進力となり、厚くお礼申し上げます。

神武研究室の中島円特任准教授には、研究の進め方や論文の書き方、社会人として SDM 研究科で博士を取得された先輩としても、いつも前向きな助言を頂き、研究を進めていくモチベーションに繋がりました。深く感謝いたします。

また、慶應義塾大学大学院 SDM 研究科附属 SDM 研究所の日比谷孟俊顧問には、日々の研究活動や Ph.D セミナーを通して、工学と文学の2つの博士号を取得されているなど非常に深くかつ幅広い研究経験から得られた示唆をご教授頂き、今後も研究活動を進める上で有意義な気づきを豊富に授けて頂きました。ここに記して感謝の意を表明します。

慶應義塾大学大学院 SDM 研究科の前野隆司研究科委員長をはじめ、谷口智彦教授、高野研一教授、春山真一郎教授、西村秀和教授、小木哲郎教授、当麻哲也教授、白坂成功教授、谷口尚子准教授には、研究発表会、講義や CESUN 等のイベントを通して SDM における基礎的な知識や考え方をご教授頂き、SDM の研究環境を使わせていただき、深く感謝いたし

ます。

本研究で用いた路面性状調査データをお借りした川崎市建設緑政局には、毎年何度か訪問させていただき、研究についての意見交換をさせて頂くとともに、維持管理現場の現実について教えていただきました。そのデータが無ければ研究を実施する事はできませんでした。この場を借りて深く感謝いたします。

本研究は著者が所属する株式会社パスコの国内留学制度により実施いたしました。最初に SDM 留学の話を頂いた坂下裕明顧問、五関利幸部長には、このような貴重な機会を頂いたことに深く感謝しております。これからも SDM 研究科で得られた広い視野や物事の考え方、様々な人との繋がり、専門知識は他では得難い経験であり、今後の社会人生活で最大限生かしていきたいと思えます。

また、SDM 入学当時パスコ総合研究所の橘菊生所長、嶋田忠男センター長、佐藤俊明部長、黒須秀明部長、前田近邦係長には、業務の調整から研究内容の相談、論文校正等、幅広くサポートとご理解をして頂いたことで本研究を実施する事が出来ました。厚く御礼申し上げます。

特に、ダイナミックマップ基盤株式会社業務推進部の鈴木康豊様には秋葉正一教授と川崎市緑政局を紹介いただくばかりか、各所との調整、研究相談など多くの面でお世話になり、鈴木様がいらっしゃらなければ本研究を遂行する事は出来ませんでした。心から感謝の意を記します。

また、神武研究室の秘書様方、特に水野久恵様、菅野彰子様には各種経費精算や会議室の手配など、私の不手際の際にも優しく対応策を考えて頂くなど、神武研究室の活動全体を通して支えて頂き、大変感謝しております。

研究室を卒業した博士課程の先輩方、防衛庁の岩泉大介様、NEC の大塚聡子様、ファイザーの中島庸介様には博士研究全体の道筋と研究活動の進め方、博士論文として纏める際の細かな注意事項まで助言を頂き、それにより博士研究を完成させる事が出来ました。深謝申し上げます。

また、一緒に研究を進めてきた神武研の博士、修士の OB, OG, 現役学生や研究員の方々、及び西村研の木下聡子様、中野研の佐藤みずほ様、当麻研の米田巖根様、元小木研の伊藤研一郎様、高野研の今仁武臣様、河村智行様、遠藤正之様とは、研究に関する物事のみならず、孤独になりがちな博士研究中でお互いに励ましあい、苦楽を共にし、様々な知見を共有する事で研究のモチベーションへと繋げる事が出来ました。厚くお礼申し上げます。