

橋梁の劣化予測に対する各種機械学習手法の精度比較

信州大学工学部 学生会員 ○河上栞奈

信州大学工学部 正会員 小山 茂

1. はじめに

橋梁の長寿命化対策には適切な維持管理が必要であり、そのためには劣化状態の把握が求められる。しかしながら、橋梁の劣化要因として考えられるのは、供用期間、交通量、橋の置かれた環境条件等様々である。また、現在日本では、現存する72万の橋梁の内約半数が老朽化していると言われていたのに対し、橋梁の点検、診断を行える技術者は慢性的な人員不足であり、劣化診断は必ずしも容易ではない。

そこで本研究は、データ構造が複雑な相互作用を持つため通常では予測困難な問題に対しても、データを学習することで規則性や法則性を見出し、予測することに優れている機械学習を手法として適用し、橋梁の劣化予測を試みる。ここでは、代表的な5種類の機械学習手法を用いて、橋梁の基本情報や位置情報、交通量などの公開されているデータから橋梁の劣化状態を予測し、その精度について確認した。

2. 研究手法

(1) 機械学習

機械学習とは、大量のデータをコンピュータが学習することで、データが有する法則性や規則性を導き出す手法である。機械学習で用いられるデータはクラスと特徴量の2種類から構成される。クラスはデータのカテゴリーを示し、予測したい目的変数である。特徴量はデータの特性を示す説明変数である。機械学習は、クラスと特徴量の関係を学習することで、学習器を構築する。構築された学習器に特徴量を入力すると予測されたクラスが出力される。

本研究では、サポートベクターマシン¹⁾(以下SVM)、ニューラルネットワーク²⁾(以下NN)、決定木³⁾、ランダムフォレスト⁴⁾(以下RF)、勾配ブースティング⁵⁾(以下GB)の5種類の機械学習手法を用いた。

(2) クラス

本研究では、表-1に示す平成31年に国土交通省が定めた道路橋点検要領⁶⁾の道路橋毎の健全性の診断の判定区分を用いた。判定区分は、健全度が高い順にI、

表-1 道路橋毎の健全性の診断の判定区分

区分		状態
I	健全	道路橋の機能に支障が生じていない
II	予防保全段階	道路橋の機能に支障が生じていないが、予防保全の観点から措置を講ずることが望ましい
III	早期措置段階	道路橋の機能に支障が生じる可能性があり、早期に措置を講ずべき
IV	緊急措置段階	道路橋の機能に支障が生じている、又は生じる可能性が著しく高く、緊急に措置を講ずべき

II,III,IVの4つの区分に分類されている。判定区分IVと判定される橋梁の数は僅少のため、本研究ではIVをIIIとして扱い、判定区分I,II,IIIのいずれかをクラスとして与えた。

(3) 特徴量

特徴量として32種類のデータを用いた。橋長、幅員、供用開始年、供用開始から最新の点検時までの年数の、計4データを道路メンテナンス年報参考データ集⁷⁾(2014年～2020年)から取得した。都道府県、市町村、緯度、経度の、計4データを社会資本情報プラットフォーム⁸⁾(道路-橋梁)から取得し、標高を地理院マップシート⁹⁾から取得した。また、道路種別、高規格道路、自動車専用道路、路線、管理者、車線数、指定最高速度、昼間12時間自動車交通量(小型車、大型車、合計)、24時間自動車類交通量(小型車、大型車、合計)、昼間12時間時間帯別交通量加重(上り、下り)、昼夜率、昼間12時間ピーク比率、大型車混入率、混雑度、混雑時旅行速度(上り、下り)、昼間非混雑時旅行速度(上り、下り)の、計23データを平成27年度全国道路・街路交通情勢調査¹⁰⁾より取得した。

32種類のデータはラベルエンコーディング処理を行い数値化した。数値化したデータは、さらに標準化を行い、特徴量として与えた。

表-2 機械学習に用いる橋梁データの内訳

	I	II	III	計
全道路橋	33855	48606	9958	92419
学習用道路橋	30458	43753	8966	83177
検証用道路橋	3397	4853	992	9242

(4) 解析対象と研究の流れ

本研究では、対象地域を全国とし、92,419基の道路橋に着目した。全橋梁のうち表-2のようにランダムに抽出した83,177基を学習用橋梁として、各機械学習手法の学習器構築に用いた。残り9,242基を検証用橋梁とし、構築された学習器に検証用橋梁の特徴量を入力することで、予測クラスを出力し、正解クラスと比較することで、学習器の性能を検討した。

3. 結果

評価指標として、正解率、加重平均適合率、加重平均再現率、加重平均F値を使用した。予測クラスと正解クラスが一致した割合を正解率、予測クラスごとに正しく予測できた割合を適合率、クラスごとの正解率を再現率として表した。F値は、各クラスの適合率と再現率の調和平均から算出した。加重平均適合率、加重平均再現率、加重平均F値は、適合率、再現率、F値を加重平均して算出した。

まず、各機械学習手法の評価指標を表-3に示す。全ての機械学習手法で評価指標が0.940以上となり、高い値で性能のよい学習器となっている。また、GBは全ての評価指標において最も高く、5手法の機械学習の中で橋梁の劣化予測において最も優れていると言える。

各機械学習手法の再現率を図-1に示す。全ての機械学習手法においてIIの再現率が高い水準となり、IIの予測に関しては優れていると言える。しかし、IIIの再現率が加重平均再現率よりも低い値となり、特にNNが最も差が大きく、IIIの予測に関しては他クラスと比較して信頼度が低い結果となった。

全ての機械学習において、高い予測精度が得られ、GBが橋梁の劣化予測において最も適切な手法である。更なる機械学習の性能向上を試みるために、クラスの内訳に偏りが無い橋梁データを使用することや、気象データ等の新たな特徴量の追加が必要であると考えている。

表-3 各機械学習手法の評価指標

手法	正解率	加重平均		
		適合率	再現率	F値
SVM	0.940	0.940	0.940	0.940
NN	0.947	0.947	0.947	0.947
決定木	0.967	0.967	0.967	0.967
RF	0.973	0.973	0.973	0.973
GB	0.974	0.974	0.974	0.974




図-1 各機械学習手法の再現率

参考文献

- 1) 山田 寛康・松本 裕治: Support Vector Machine の多値分類問題への適用法について, 情報処理学会研究報告自然言語処理.2001, Vol.2001, No.112, p.33-38
- 2) Francois Chollet. Python と Keras によるディープラーニング. 巢籠 悠輔監訳, 株式会社クイープ訳, 2018, 376p.
- 3) Aurélien Géron, scikit-learn, Keras, TensorFlow による実践機械学習 第2版, 下田 倫大監訳, 長尾 高弘訳, 2020, 798p
- 4) 波部 斉: ランダムフォレスト, 研究報告コンピュータビジョンとイメージメディア, 2012, Vol.2012, No.31, p.1-8
- 5) Tianqi Chen, Carlos Guestrin, XGBoost: A Scalable Tree Boosting System, KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, August 2016 p.785-794
- 6) 国土交通省. 「道路橋点検要領 平成31年2月」 <https://www.mlit.go.jp/road/sisaku/yobohozen/yobohozen.html> (最終閲覧 2022-12-10)
- 7) 国土交通省. 「道路交通メンテナンス年報」 https://www.mlit.go.jp/road/sisaku/yobohozen/yobohozen_maint_index.html (最終閲覧 2022-12-10)
- 8) G 空間情報センター. 「社会資本情報プラットフォーム (道路一橋梁)」 <https://www.geospatial.jp/ckan/dataset/ipf0101> (最終閲覧 2022-12-10)
- 9) 国土交通省国土地理院. 「地理院マップシート」 https://renkei2.gsi.go.jp/renkei/130326mapsh_gijutu/index.html (最終閲覧 2022-12-10)
- 10) 国土交通省. 「平成27年度 全国道路・街路交通情勢調査」 <http://www.mlit.go.jp/road/census/h27/> (最終閲覧 2022-12-10)