

橋梁点検情報と地理空間情報を統合した教師データによる劣化進展判定 AI の構築

龍田 斉・原田 豊・貫井敬章・榮 洗希

Development of AI for Determining Deterioration Progress Using Supervisory Data Integrated with Bridge Inspection Information and Geospatial Information

Hitoshi TATSUTA, Yutaka HARADA, Takaaki NUKUI, Koki SAKAE

Abstract: Since the speed of deterioration of bridge components is related to the need for repair, it is necessary to monitor the speed of deterioration during periodic inspections. However, environmental conditions such as climate and surrounding topography, as well as the age of the bridge, are factors that contribute to the deterioration of the components. In this research, we combine the inspection data of bridges managed by Tochigi prefecture in previous years and the National Land Data, which is GIS data of climate and topography published by the Ministry of Land, Infrastructure, Transport and Tourism, as teacher data using GIS. The integrated data will be used to build an AI system that can estimate the progress of deterioration of bridges.

Keywords: 橋梁維持管理(bridge maintenance), 深層学習(deep learning), 機械学習(machine learning), 劣化進展予測(prediction of deterioration progress)

1. はじめに

全国の道路管理者が管理する橋梁は、高齢化が進み、約半数が予防保全の観点から措置を講ずることが望ましい状態にあり、約 1 割が早期に措置を講ずべき状態にある(国土交通省,2020)。このため、従来の対処療法的な修繕および架替えから、予防的な修繕および計画に基づく架替えへと円滑に転換することを目的として、栃木県では平成 20 年度から橋梁長寿命化修繕計画を策定し、橋梁の維持管理に取り組んでいる(栃木県,2012)。本計画に基づき、より適切かつ効率的に橋梁の修繕を実施するためには、橋梁部材の劣化進行の速さを定期点検で把握し、補修の要否を診断することが望ましい。しかし、部材の劣化進行の要因は、橋梁架設からの経過年数だけでなく気候や周辺地形などの環境条件も関連するため、部材毎に一律に劣化予測を行うと予測値からのばらつきが大きい。

一方、昨今の AI 技術の発展は著しく、様々な分野

で活用されており、土木工学分野においても AI を活用する研究が進められている。例えば、機械学習モデルの一種である LightGBM を用いて地形情報から工学的基盤深度を推定する手法を提案されている(田中, 2020)。また、深層学習を用いた物体検出モデルである YOLOv3 を活用して橋梁の点検調書から文字情報を抽出する手法も提案されている(山根ほか, 2020)。

本稿では、橋梁長寿命化修繕計画の精度向上を目的として、栃木県が管理する橋梁の諸元および過年度点検データと、国土交通省が公開している気候や地形等の GIS データである国土数値情報とを、GIS を用いて AI を学習させるための教師データとして結合し、損傷劣化が進展する橋梁を判定する AI の構築を検討した。

2. 概要

検証にあたり、まず、教師データとして使用する橋梁データおよび国土数値情報の構成と、GIS による両データの結合方法を示す。続いて、上記データと本検討で構築する AI の構成を示す。本検討の AI は、深層学習のモデル「畳み込みニューラルネットワーク (Convolutional Neural Network(Yann et al,1995),

龍田 斉 〒102-0075 東京都千代田区三番町 6-3
大日本コンサルタント株式会社

E-mail: tatsuta@ne-con.co.jp

原田 豊 大日本コンサルタント株式会社

貫井 敬章 大日本コンサルタント株式会社

榮 洗希 栃木県県土整備部道路保全課

以下 CNN)」および機械学習のモデル「勾配ブースティング決定木(Gradient Boostin decision tree(Jerome, 2001), 以下 GBDT)」を組み合わせたものである。続いて、教師データを用いて学習した AI による損傷劣化進展の推定精度を示す。最後に、学習後の GBDT のモデルから AI への入力値である説明変数の重要度等を算出し、劣化進展の推定に影響が大きい説明変数を確認し、推定の妥当性を確認する。

3. 教師データ

教師データとは、AI への入力値である説明変数と、AI の出力値である目的変数のペアを多数用意したもので、本データを用いて AI に説明変数と目的変数の関係を学習させる。以下に、それぞれの変数の概要について述べる。

3.1. 目的変数

本検討の目的変数は損傷進展の有無である。具体的には、過去に2回以上点検を実施している橋梁を対象とし、最新点検において損傷が新規に発見されている橋梁や前回点検で発見された損傷が進行している橋梁を「損傷進展有り」とし、それ以外の橋梁を「損傷進展無し」とした。なお、栃木県は、平成27年3月に橋梁点検マニュアルを改訂し、点検手法が近接目視に統一された。このため、平成26年度以前の簡易点検は遠望目視で実施しているため、損傷進展の比較対象から除外した(表-1)。加えて、最新点

表-1 損傷進展の比較対象となる点検種別

	簡易点検	詳細点検
平成26年以前	× (遠望目視)	○ (近接目視)
平成27年以降	○ (近接目視)	○ (近接目視)

表-2 損傷進展の比較対象部材

工種	部材
上部工	床版
	主構
	床版・主構以外 (主要な部材)
下部工	躯体
	基礎
支承部	支承本体
	沓座

検の前に補修を実施している橋梁についても比較対象から除外した。また、損傷進展の比較対象部材は、損傷進展の比較が定期点検結果から定量的に実施可能な「ひろがり」を評価・記録する損傷が含まれている部材とした(表-2)。これらの方針に基づいて整理した結果、比較対象の橋梁かつ複数回点検が登録されている橋梁は876橋あり、このうち損傷進展が確認された橋梁は753橋、損傷進展が確認されなかった橋梁は122橋であった。損傷進展有無を地図上にプロットしたものを図-1に示す。図から損傷進展の有る橋梁は県内全域に存在することが確認できる。

3.2. 説明変数の内訳

3.1.で定義した目的変数予測するための説明変数、すなわち AI への入力値として、橋梁諸元、国土数値情報、損傷写真を用いた。各説明変数の概要を以下に示す。

3.3. 橋梁諸元

説明変数として用いた橋梁諸元を表-3に示す。上部工および下部工の諸元は橋梁単位に集約した。具体的には数値変数については、橋梁ごとに最小値、最大値、平均値に集約した。カテゴリ変数についてはカテゴリ別に列を設け、該当する場合は1、非該当は0とするワンホットエンコーディングを実施した。

3.4. 国土数値情報

説明変数を補間するため国土数値情報を追加する。

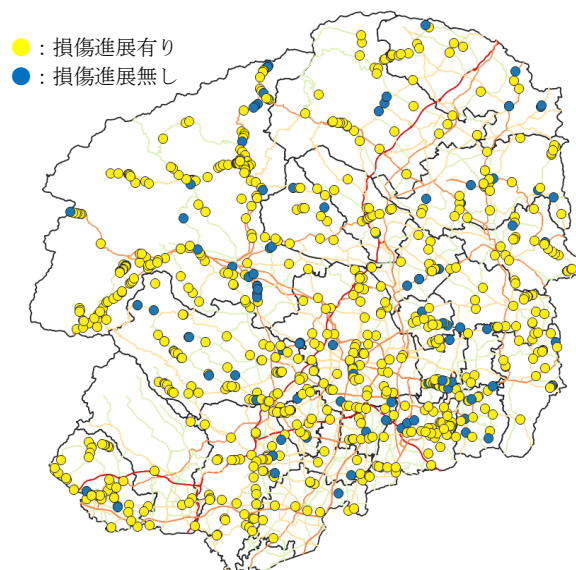


図-1 損傷進展の有無

表-3 説明変数として使用する橋梁諸元一覧

橋梁単位	上部工単位	下部工単位
事務所、路線、所在地、橋梁種別、橋梁区分、適用示方書、適用示方書1、設計活荷重、塩害対策区分、広域緊急、指定25t道路、施工業者、DID区分、家屋密集、バス路線、液状化PL値、活断層、地震動、都道府県、市町村、路面位置、橋梁進入区分、通学路、平面形状、歩道、第三者被害、等級、遮音壁、歩道添架、排水施設、現旧道、舗装種別、道路状況、平面位置、架替計画、拡幅の可否、河川道路名、上部工施工業者、下部工施工業者、環境区分、照明灯、歩道添架の可否、車道用防護柵、歩道用高欄、起点順、添架物、景観的配慮、歴史的価値、自専一般、占用物件、緯度、経度、架設年次YYYY、橋長、径間数、下部工基数、最大支間長、幅員、液状化PL値、地震動、AB方向幅員、BA方向幅員、制限荷重、橋面積、最小半径、横断勾配、左歩道、左路肩、車道、右路肩、右歩道、自転車、歩行者、河川流量、鋼重上部工、鋼重下部工、コンクリート体積上部工、コンクリート体積下部工、桁下空間、道路状況YYYY、小型車(台)、大型車(台)、合計(台)	交差物 構造形式 使用材料 主桁構造 床版形式 床版材料 床版防水工有無 径間長 主桁本数 主桁間隔 床版床版厚	基礎形式 躯体形式 躯体材料 支承形式 支承材質 支承条件 耐震補強橋脚 耐震補強落橋防止

国土数値情報は、物流拠点などの施設位置や気候に関する平年値、豪雪地帯の降雪情報等の地形・地域に関する有益な情報を有する。追加した国土数値情報およびその内容、追加方法は表-4に示す。同表の追加項目「施設」については、各橋梁から最寄りの各施設までの距離を算出し、説明変数として追加した。「雪害地域」については、各橋梁が雪害地帯の内か外かを説明変数として追加することに加えて、橋梁のうち雪害地帯内のものについて、最寄りの気象観測点の計測情報を説明変数として追加した。「気候」については、各橋梁を含むメッシュの気候情報を当該橋梁の説明変数として追加した。「地形」についても、気候と同様に、各橋梁を含むメッシュの地形情報を当該橋梁の説明変数として追加した。各国土数値情報のサンプルとして雪害地帯を図-2に示す。

3.5. 損傷画像

説明変数を補間するため橋梁点検時に記録された損傷写真を活用する。損傷写真はそのままでは表形式データに組み込むことができないため、画像分類のAIモデルであるCNNで加工する。具体的には、まず損傷画像とその画像に映っている損傷種類及び損傷等級(A~E)を教師データとしてCNNに学習させる。今回使用したCNNのモデルはEfficientNet-B0(Mingxing et al, 2019)を用いた。本モデルは精度を維持しつつモデルのパラメータを抑えたことが特徴で、教師データから損傷特徴を迅速に学ぶことが可

表-4 説明変数とする国土数値情報

追加項目	内容
施設	栃木県内の主要な施設の位置情報。具体的には、国・都道府県の機関、市町村役場および公的集会施設、市町村役場、公共施設、警察署、消防署、郵便局、医療機関、福祉施設、文化施設、学校、都市公園、上水道関連施設、廃棄物処理施設、発電施設_バイオマス、発電施設_一般水力、発電施設_太陽光、燃料給油所、ニュータウン、工業用地、研究機関、地場産業関連施設、物流拠点、集客施設。
雪害地帯	栃木県内で豪雪地帯として地域指定された領域および豪雪地帯内の気象観測点で計測した最深積雪(最大、平均)、最低気温(最低、平均)、平均風速(最大、平均)、累計降雪量(最大、平均)。
気候	栃木県内の過去30年間の観測値から1kmメッシュごとの平年値を推定・算出したもの。具体的には、年降水量、年平均気温(最高、最低、平均)、年最深積雪、年合計日照時間、年平均全天日射量。
地形	栃木県内の標高(平均、最高、最低)、最大傾斜角度・方角、最小傾斜角度・方角について250mメッシュ毎に整備したものの。

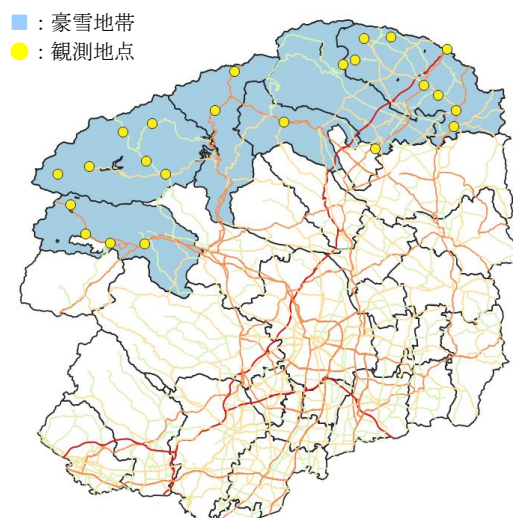


図-2 雪害地帯




図-3 UMAPによる次元圧縮の例

能である。学習は大量の画像データを扱うため、高性能な GPU や大量のメモリが必要となる。これを賄うため、産業技術総合研究所が提供する「AI 橋渡しクラウド (以下 ABCI)」を利用する。ABCI は複数の GPU, 数百 GB のメモリを積んだ計算ノードを安価に並列実行が可能なクラウド環境であり、本環境を利用することにより効率的かつ迅速に AI 構築を進めることが可能である。学習後、CNN の出力層に近い中間層の出力値を当該橋梁の特徴量として追加する。これは CNN が出力層に近づくにつれて分類対象の具体を学ぶ性質を利用するためである。抽出した中間層の出力値は、次元数が 1000 を超えているため、次元圧縮技術の UMAP(McInnes et al, 2018) を使用して 2 次元に圧縮する。UMAP は元データの特徴を保持して 2 次元空間に圧縮することが特徴である。図-3 に UMAP による Fashion MNIST 画像データセットの次元圧縮例を示す。図より各クラスが 2 次元平面上に分類されていることが確認できる。最後に、圧縮した出力値の X 成分, Y 成分を橋梁ごとに最大値, 最小値, 平均値, 合計値, 点検時最初に撮影されたもの, 最後に撮影されたものの 6 分類に集約して特徴量とした。

4. モデル

整理した損傷進展情報, 橋梁諸元, 国土数値情報および画像特徴量は, 前述の GBDT の学習データとして表形式のデータとして統合する。統合のイメージを図-4 に示す。GBDT はデータ分析コンペティションで精度の高さが証明されている手法で, 本手法により高精度に推論する AI の構築が期待される。

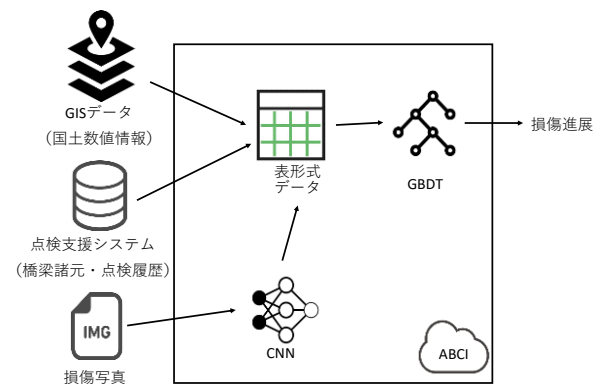


図-4 劣化進行推定 AI のイメージ

4.1. 勾配ブースティング決定木

定義した目的変数および説明変数のペアを表形式の教師データとして整理し, 損傷進展などを推論するモデルである勾配ブースティング決定木 (以下, GBDT) に学習させる。GBDT はアンサンブルモデルの一種で, 複数の決定木を作成し, 推論精度を高める点が特徴である。本検討では, GBDT として Catboost を採用した。Catboost は GPU に対応しているため産総研の ABCI のリソースを用いて迅速な計算が可能である。また, 日本語を列名に含む表形式データを用いても計算が正常実行できることが利点である。

4.2. 学習結果の精度確認方法

目的変数および説明変数のペアである教師データを用いて学習したモデルの精度検証方法とその結果を以下に示す。精度確認は交差検定で実施した。具体的には教師データを 4 つのグループに等分し, 3 つのグループを学習に, 残る 1 つのグループを精度の検証に用い, 全グループを検証で使用するよう 4

回繰り返して実施した (図-5). 各グループに含まれる目的変数のクラスの割合は層化抽出により分割前と同じ比率とした. 精度確認用の指標は F1 スコアを用いた. F1 スコアの定義を式 1 に示す.

$$F1_{score} = \frac{2TP}{2TP + FP + FN} \quad (式1)$$

式中の TP は正解値および推定値が「損傷進展有り」のデータの総数で, FP は正解値が「損傷進展無し」で推定値が「損傷進展有り」と推定したデータの総数, FN は正解値が「損傷進展有り」で推定値が「損傷進展無し」となったデータの総数である. F1 スコアは 1 に近い値ほど高精度であることを示す.

4.3. 学習結果の精度

損傷進展を学習したモデルの検証時の F1 スコアを表-5 に示す. 表からいずれのケースでも 0.94 以上であることがわかる. 図-6 に損傷進展に関して実測値と検証時の予測値を地図上に図示したものを示す. 図から AI は損傷進展有りと推定する確率が高いことが確認できる.

4.4. モデルの妥当性の確認

最後に参考として, 説明変数の重要度を学習後のモデルから SHAP 値で出力したものを図-7 に示す. SHAP(Scott,2017)は各説明変数の予測値への寄与度を示したものである. 図の縦軸は説明変数の寄与度で上位に位置する説明変数ほど目的変数に対する寄与が大きい. 図中の点の色は説明変数の値の大小を示し, 青から赤へと遷移するほど大きい値となる. 横軸は SHAP 値でプラスの値 (黒縦線より右側) は当該目的変数の推定に正の寄与を示し, マイナスの値は負の寄与を示す. 図から橋梁諸元と損傷写真 (UMAP) の寄与度が大きく, 国土数値情報や交通量は前述の 2 変数に対して寄与度が小さい. 個別の説明変数に着目すると, 「①架設年次が新しい橋梁ほど劣化進展無しの傾向が強い」「②(交通量)合計(台)

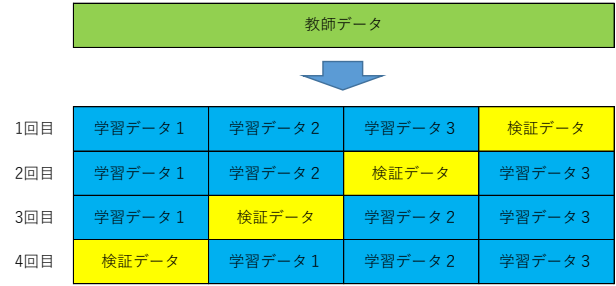




図-5 交差検定

表-5 交差検定の結果 (F1 スコア)

1回目	2回目	3回目	4回目	平均値
0.9459	0.9444	0.9417	0.9481	0.9450

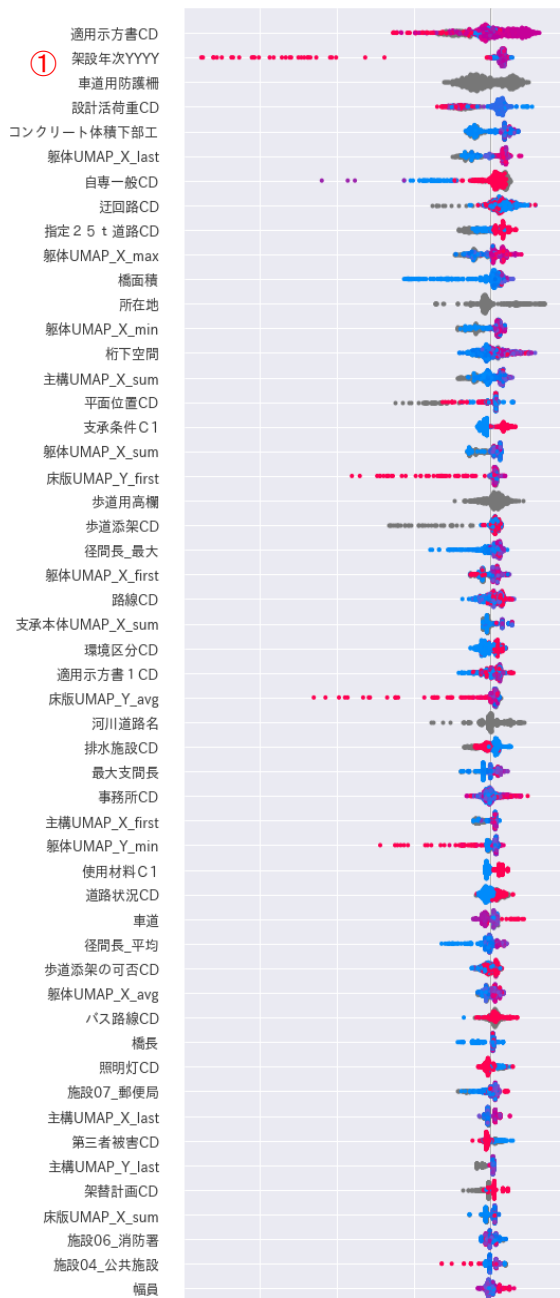


(a)正解値




(b)AIによる推定値

図-6 損傷進展 (正解および AI 推定値)



(a)上位1位から52位



(b)上位53位以降

図-7 劣化進展推定モデルにおける説明変数の重要度

が多いほど損傷進展有りとなる傾向が強い」「③各年度別最低気温（平均気温）が大きいほど損傷進展無し傾向が強い」等が確認できる。

5. まとめ

本検討では、深層学習の技術である CNN と機械学習の技術である GBDT を用いて、橋梁の損傷進展

の有無を推定する AI の構築を検討した。橋梁のデータのみを用いるのではなく、国土数値情報の GIS データを追加することによって、精度よく損傷進展の有無を推定する AI を構築することができた。

今後は、構築した AI を用いて損傷進展の有無により橋梁データをグルーピングし、グループごとに劣化予測を実施することにより、修繕計画の精度向

上を計る.

謝辞

本検討は栃木県県土整備部道路保全課よりデータ提供を受けて実施したものである. ここに記して謝意を表したい.

参考文献

- 国土交通省道路局, 2020, 「道路メンテナンス年報」, 2021/8/30 最終アクセス,
https://www.mlit.go.jp/road/sisaku/yobohozen/pdf/r02/r02_08maint.pdf.
- 栃木県県土整備部道路保全課, 2012, 「橋梁長寿命化修繕計画」, 2021/8/30 最終アクセス,
<https://www.pref.tochigi.lg.jp/h05/system/honchou/honchou/documents/1250574475210.pdf>.
- 田中浩平, 2020, 「機械学習モデルによる地形情報からの工学的基盤深度の推定モデル構築」, 土木学会論文集 A1 (構造・地震工学), 76(2), 411-423.
- 山根 達郎, 全 邦釘, 本田 利器, 2020. 「 Deep Learning を用いた橋梁点検調書からの文字情報抽出」, AI・データサイエンス論文集, J1, 71-77.
- Yann, L., Yoshua, B., 1995, Convolutional networks for images, speech, and time-series, The Handbook of Brain Theory and Neural Networks.
- Jerome, F., 2001, Greedy function approximation: a gradient boosting machine, Annals of Statistics, 29(5), 1189-1232.
- Mingxing, T and Quoc, L., 2019, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, In Proceedings of International Conference on Machine Learning, pp.6105-6114.
- McInnes, L, Healy, J, 2018, UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction, ArXiv e-prints 1802.03426.
- Scott, M. L. and Su-In, L., 2017, A Unified Approach to Interpreting Model Predictions, In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS' 17), pp. 4768-4777.