# 機械学習による橋梁の損傷推定を想定した教師 データセットの生成

竿本 英貴<sup>1</sup>・宮本 崇<sup>2</sup>

 <sup>1</sup>正会員 産業技術総合研究所 活断層・火山研究部門(〒305-8567 茨城県つくば市東1-1-1 中央第7) E-mail: h-saomoto@aist.go.jp (Corresponding Author)
<sup>2</sup>正会員 山梨大学 大学院総合研究部工学域土木環境工学系(〒400-8511 山梨県甲府市武田 4-3-11) E-mail: tmiyamoto@yamanashi.ac.jp

近年,機械学習は土木分野で積極的に適用されている.機械学習が先行的に用いられる他分野では,それらの分野を代表するベンチマークやデータセットが存在し,用いる機械学習アルゴリズムの評価が一定の規準に基づいてなされている.ベンチマーク・データセットの存在は機械学習活用を促進するために重要と考えるが, 土木工学的なベンチマーク・データセットはほとんど提案されておらず,用いる機械学習アルゴリズムを統一的 に評価する状態に至っていない.本研究では,橋梁モデルに対するFEM解析を通じて橋梁の損傷推定に対する データセット(ノイズ・欠損を含まない)を4段階の難易度に分けて提案する.19の機械学習アルゴリズムに作成したデータセットを入力し,各アルゴリズムから得られた決定係数を基にデータセットの可否を評価した.

Key Words: Machine Learning, Benchmark, Dataset, FEM, Bridge, Damage Identification

# 1. はじめに

地震外力や腐食等の外的要因に基づく土木構造物の 損傷を機械学習によって自動的かつ定量的に評価しよ うとする研究が国内外で広く実施されている<sup>1)-3)</sup>.研 究内容の具体例として,コンクリートのひび割れや変 状の検出<sup>4)-6)</sup>,道路舗装の損傷検出<sup>7),8)</sup>,橋梁部材の損 傷検出<sup>9)</sup>や損傷原因・補修工法の推定<sup>10)</sup>などが挙げら れ,一定の成果が得られている.

一般に,機械学習のアルゴリズム評価や機械学習の 活用を促進するためには,ベンチマーク・データセット の存在が必要不可欠であり,先行的に機械学習が導入 された分野では,各分野の特徴を有するベンチマーク・ データセットが広く公開されている.例えば,画像認識 の分野では,数字の0から9に対する手書き文字画像 (28 ピクセル四方,グレースケール)を7万枚(学習用 教師データ6万枚,テスト用1万枚)収録した MNIST データセット<sup>11)</sup>が広く知られており,画像分類のベン チマークとして用いられている.

一方,土木分野で公開されているベンチマーク・デー タセットはほとんどない.コンクリート作成時の組成 (セメント量,高炉スラグ量,水量等)と圧縮強度に関 するデータセット (1030 供試体分)<sup>12),13)</sup> やコンクリート のひび割れ有り無しの画像セット (合計約 2100 枚)<sup>14)</sup> が 公開されている程度に留まっている.土木構造物の形 態が橋梁,トンネル,道路など多岐にわたることや設 置される地域によって環境が大きく異なること,デー タ取得に多大なコストがかかる等の理由でデータセッ トの公開・普及が進んでいないと推察するが,土木分 野において機械学習活用をさらに促進するためには土 木分野の特徴を有する良質なベンチマーク・データセッ トを構築し,整備・公開していくことは重要な研究課 題の一つと考える.

この課題に対し、本研究ではプラットトラス橋の有 限要素解析を利用して部材レベルでの損傷推定のため のデータセット構築を試みる.数値解析を用いること で、データの欠損やノイズ混入が無いという意味で良 質なデータを取得できる上、一定回数以上の解析を実 施することで機械学習タスクに必要十分なデータ数を 確保できるという利点がある.

本論文の構成は以下のとおりである.第2章でデー タセット生成に用いるプラットトラス橋の有限要素モ デルと機械学習タスクで用いる4種類のデータセット について説明する.第3章では生成したデータセットが ベンチマークとして適切であるかどうかを機械学習ア ルゴリズムを通じて検討するための方法論と,検討に 用いた19種類の機械学習アルゴリズム(以下,アルゴ リズムと表記)について述べる.続く第4章ではアルゴ リズムの適用結果を示し,作成したデータセット4種 類のうち2種類がベンチマークとして適切であること を決定係数の観点から示す.また,各アルゴリズムの 決定係数と学習時間の観点から,今回の機械学習タス クに適したアルゴリズムについても言及する.第5章 でまとめと今後の展望を述べる.



図-1: プラットトラス橋モデル

# 2. プラットトラス橋モデルの損傷推定のための機械学習用データセットの生成

データセットの生成は,(1)橋梁モデルの斜材・垂直 材のうちの1部材または2部材を選定し,任意の程度 損傷させる,(2)25ton級ラフテレーンクレーン車(以 下,クレーン車)の輪荷重をあらかじめ定めた地点に作 用させて14個の格点での鉛直変位を静解析によって求 める,(3)クレーン車の位置座標,14個の鉛直変位,各 部材の損傷度をセーブする,というサイクルを所定の 回数 (ここでは 10000 回) 実施して生成する.以下,用 いた有限要素モデル,輪荷重の設定方法,損傷の表現 方法について述べる.

# (1) プラットトラス橋の有限要素モデル

図-1に用いたプラットトラス橋モデルを示す. モデ ルは支間長 40 m, 全幅員 7 m, トラス高 5 m のサイズ であり, 箱型鋼材を採用した上弦材・下弦材および斜 材・垂直材, H型鋼材を採用した床桁, コンクリート床 版から成る. 各種鋼材の断面寸法は図-1中のとおりで ある. ここでは, 鋼材のヤング率を 200 GPa, 鋼材の ポアソン比を 0.3, コンクリートのヤング率を 25 GPa, コンクリートのポアソン比を 0.2 と設定した. このモ デルは FEM ベースの汎用工学ソフトウェア COMSOL Multiphysics の解析例として公開されているもの<sup>15)</sup>を ベースに, 後述の 25ton 級クレーン車の輪荷重および 各部材毎の健全率をパラメータとして著者らが追加実 装したものである.

今回,鋼材は梁要素,コンクリート床版部はシェル 要素でそれぞれモデル化しており,モデル全体として 582本の梁要素と1248面のシェル要素からなる.ここ では簡単のため,全ての要素は弾性体と仮定している. 空間座標の原点は図-1中で鉛直変位 w4 が計測される 格点に設置しており,x軸は橋軸方向,y軸は橋軸直交 方向,z軸は鉛直方向にそれぞれ対応させた.なお,コ ンクリート床版はzがゼロの面として表される.境界 条件として,x=-20mの位置をピン支持,x=20mの位 置をローラー支持(x方向のみ変位を許容)と設定した.

#### (2) 輪荷重の設定

プラットトラス橋モデルに作用させる輪荷重は 25ton 級クレーン車を想定しており,4つの輪荷重を4つの集 中荷重としてモデルに作用させる.クレーン車の車両 中心位置 (xc, yc)を x 軸方向に 3 通り (xc: -10 m,0 m, 10 m), y 軸方向に 3 通り (yc: 2.5 m, 3.5 m, 4.5 m) 設定 し,クレーン車がこれらの 9 箇所の候補うちのどこか に設置されるものとした.なお,輪荷重の大きさおよ び輪荷重の作用位置については,横山らの研究<sup>16)</sup>を参 考にして設定した (前輪: 68.1 kN,後輪: 64.9 kN).

図-2 に輪荷重の大きさおよび輪荷重作用位置と車両 中心位置 (xc, yc) との位置関係を示す.本研究では (xc, yc) は以下の 9 組 (単位は m) のいずれかとなるように設 定している (一様乱数で決定). (-10, 4.5), (0, 4.5), (10, 4.5), (-10, 3.5), (0, 3.5), (10, 3.5), (-10, 2.5), (0, 2.5), (10, 2.5).

#### (3) 部材の健全率に関する設定

本研究では、部材毎に損傷に関するパラメータを設定する.ここでの損傷は、剛性低下によって表現する. すなわち、部材番号iの無損傷状態でのヤング率を $E_{i0}$ 、剛性低下を 1.0以下の係数 $h_i$ として、損傷を考慮した部材iのヤング率 $E_i$ を次式で表わすこととする.

$$E_i = h_i E_{i0} \tag{1}$$

当然ながら、 $h_i$  が 1.0 の場合は部材番号 i の部材は無 損傷状態にある.以降、 $h_i$ を健全率と呼ぶことにする. 本研究では、斜材・垂直材の1部材または2部材をラ



図-2: 輪荷重の大きさおよび輪荷重作用位置と車両中心 位置 (xc, yc) との位置関係



図-3: 斜材・垂直材の部材番号 (1-26)

ンダムに選定し、選定した部材についての健全率 $h_i$ を 変化させて損傷を考慮する. 健全率には下限値を設定 し、下限値を様々に変化させた各場合についてデータ セットを作成している. 具体的には、次の9通りにつ いて検討した.  $0.1 \le h_i \le 1.0$ の場合,  $0.2 \le h_i \le 1.0$ の 場合,  $0.3 \le h_i \le 1.0$ の場合,  $0.4 \le h_i \le 1.0$ の 場合,  $0.5 \le h_i \le 1.0$ の場合,  $0.6 \le h_i \le 1.0$ の場 合,  $0.7 \le h_i \le 1.0$ の場合,  $0.8 \le h_i \le 1.0$ の場 合,  $0.9 \le h_i \le 1.0$ の場合. この理由は、下限値を小さくし て健全率の取りうる範囲を広くすることで、後の損傷 推定に関する機械学習タスクの難易度を変化させるこ とができると考えたことに依る.

斜材・垂直材の部材番号 (1-26) は図-3 のとおりで, x 軸に沿って部材番号が大きくなるように設定した.後 の機械学習による損傷推定では,図-3 中に示す橋梁中 央部の垂直材 (部材番号 13 および 15)の評価結果に言 及するため,部材番号 13 と 15 がどの部材に対応する のかを示しておく.

理解の助けのため,部材番号9と10の健全率をとも に0.1(他部材は無損傷)とした場合の変位分布を図-4に 示す.ここでは車両中心位置(xc, yc)を(0, 2.5)として橋



(a) 部材番号9と10の健全率を0.1とした場合の鉛直変位分布 (クレーン車は(xc, yc)=(0, 2.5) に設置)

(b) y=0 および y=7 のライン上での鉛直変位分布の比較

図-4: 健全率を低下させた場合の変位様式変化の一例

梁中央部 (yc=3.5) から紙面手前側に車両を1mシフト させている.部材番号9と10は図-4a中でそれぞれ破線 で表されている垂直材と斜材である.図-4bは, y=0お よびy=7のライン上での垂直変位分布を示している.ク レーン車をy=0 側にシフトさせていることおよびy=0 のライン上の部材 (9と10) に損傷を与えたことから, y=0のライン上での変位量が y=7の変位量に比べて大 きくなっている.なお,有限要素解析では図-4bの破線 で示すように,格点以外の変位を把握しているが,後 の機械学習タスクで用いる情報は,14 個の格点での鉛 直変位 (w1-w14,プロットで図示)のみである.

#### (4) データセット生成の手順

ここではこれまで個別に述べてきた項目を統合し,教 師データを生成する際の一連の手続を示す. 図-5 はデー タセット生成のフローチャートを表している. 有限要素 解析では, (1) クレーン車を想定した輪荷重の位置, (2) 損傷部材の選定・選定部材の健全率の設定、を計算実行 前に定めておく必要がある.まず,輪荷重を車両中心 位置 (xc, yc)を制御することで位置を確定する. xc は x 軸方向(橋軸方向)に3 通り(-10,0,10), ycはy 軸方 向(橋軸直行方向)に3通り(2.5, 3.5, 4.5)考え, x軸方 向に1通り、y軸方向に1通りそれぞれ一様乱数によっ て選定する.損傷部材は、図-3で示した26本の斜材・ 垂直材の中から1部材または2部材を一様乱数で選び 出し、選定した部材についての健全率を下限値から1.0 の範囲内の実数値として一様乱数によって設定する.2 部材選定する場合は、それぞれに異なる健全率を設定 する. なお, 健全率の下限値は, 0.1 から 0.9 の範囲内 を 0.1 刻みで変化させており、各下限値について 10000 回の有限要素解析を実施してデータを作成した. 健全



図-5: 教師データ生成のフローチャート

率の下限値が 1.0 に近い場合 (例えば 0.9 の場合) はア ルゴリズムが探索する健全率の範囲が小さく,良い探 索結果となることが期待できる.一方,健全率下限値

# 説明変数 (車両中心位置,鉛直変位)

ᄀᄼᄼ			ゆう ひょう いっちょう しょう しょう しょう しょう しょう しょう しょう しょう しょう し
I H'\	1251-25V	( 当1、水オ ( ) )*	伸子举口
- 23			(せエー)

No	XC	УС	w1	w2	• • •	w14	h1	h2	h3	h4	•••	h26
1	0	2.5	-1.6	-3.516	• • •	-1.132	1	1	1	0.179	• • •	1
2	-10	2.5	-1.838	-3.637	• • •	-0.564	1	1	0.615	1	• • •	1
3	-10	3.5	-1.297	-2.6	• • •	-1.008	1	1	1	0.191	•••	1
4	10	4.5	-0.647	-1.391	• • •	-1.95	1	1	1	1	•••	1
5	10	3.5	-0.615	-1.326	• • •	-1.955	1	1	1	1	•••	1
6	10	4.5	-0.724	-1.54	• • •	-1.987	1	1	1	1	•••	1
7	-10	4.5	-1.228	-2.412	• • •	-0.857	1	1	1	1	• • •	1
1	`_ <b>↑</b>	•	FEMから	求まる鉛	直変位(w	(1-w14)	損傷	部材数は1	または27	なので,ト	まとんど1	.0

/ 10000回実施 車両中心y座標 2.5, 3.5, 4.5のいずれか 車両中心x座標 -10, 0, 10のいずれか 損傷部材数は1または2なので,ほとんど1.0 この例は損傷部材数が1で健全率の下限は0.1の場合 0.1以上1.0以下の値が各行で1つ入力される

図-6: 機械学習に入力するデータの例 (Case-01 で健全率の下限が 0.1 の場合)

が小さい場合 (例えば 0.1 の場合) は探索範囲が広くなることで探索の難易度が高くなるものと推察できる.

今回は,輪荷重位置のバリエーションとして,橋軸方 向のみに変化する場合,橋軸方向に加えて橋軸直行方 向も変化する場合の2通りを考える.また,損傷部材の 部材数も1部材または2部材の2通りを考える.これ らの各組み合わせについて,損傷部材の健全率の下限 値を0.1から0.9まで変化させた(9通り).したがって, トータル36ケース(2通り×2通り×9通り)について 教師データ作成を実施しており,各ケース10000回の 有限要素解析を行っている.

以下,簡単のため輪荷重のバリエーションと損傷部 材の部材数のバリエーションに応じて,次のように名 称をつけた.

- Case-01:車両中心位置 (xc, yc) が x,y 方向ともに 変化して1部材のみ損傷するケース
- Case-02:車両中心位置 (xc, yc) が x 方向のみ変化 して1部材のみ損傷するケース (yc=3.5と固定)
- Case-03:車両中心位置 (xc, yc) が x,y 方向ともに 変化して2部材損傷するケース
- Case-04:車両中心位置 (xc, yc) が x 方向のみ変化 して2部材損傷するケース (yc=3.5と固定)

各 Case について,下限値が 0.1 から 0.1 刻みで 0.9 ま での各場合について 10000 回の有限要素解析を実施し ている.この結果,全教師データを作成するための有 限要素解析数は 360000 となる.

#### (5) 生成したデータファイル例

有限要素解析によって生成したデータを後述の 19 の アルゴリズムに入力し,各アルゴリズムについて k-fold クロスバリデーションを実施してアルゴリズムを評価 する. ここでは円滑な理解のため,アルゴリズムに入力す るデータファイルのデータの並び等,具体的な内容を 示しておく.

図-6は、アルゴリズムに入力するデータの一例 (Case-01 で健全率の下限が 0.1 の場合)を示している. 今回の機械学習のタスクは図-6中の薄い青で色付けさ れた 16 項目の説明変数 (車両中心位置 (xc, yc),鉛直変 位 w1-w14 から成る)をアルゴリズムに入力したとき, 薄い黄で色付けされた 26 項目の目的変数 (橋梁モデル の 26 部材の健全率 h<sub>1</sub>-h<sub>26</sub>)を出力する問題となる.

# 3. 機械学習による損傷推定

前章の方法で生成したデータが機械学習タスク(橋梁 部材の損傷推定)の教師データとして適切かどうかを評 価するには、当然ながらアルゴリズムに生成したデー タを適用して決定係数などの定量的な評価指標を通じ た議論が必要となる.また、単一のアルゴリズムのみ による評価ではなく複数のアルゴリズムによる評価結 果を比較・検討することでデータセットとしての適切 性をより正確に議論できると考える.ここでは、損傷 推定の機械学習タスクの詳細および比較・検討に用い た 19 種類のアルゴリズムについて述べる.

#### (1) 機械学習タスクと機械学習アルゴリズムの評価方法

多くのアルゴリズムが scikit-learn<sup>17)</sup> ライブラリ内で 実装されているため、これを利用することで効率的に 多くのアルゴリズムを用いた評価を実施できる. さら に、自動機械学習 (Automated Machine Learning: AutoML) ライブラリの一つである PyCaret<sup>18)</sup> ライブラリ で scikit-learn を制御することにより、ほぼ自動的に kfold クロスバリデーションを全てのアルゴリズムに適 用可能となる. なお, k-fold 値は 10(PyCaret のデフォ ルト値) とした. クロスバリデーションの結果として, 平均絶対誤差 (Mean Absolute Error: MAE), 平均2 乗 誤差 (Mean Squared Error: MSE), 平均2 乗誤差の平方 根 (Root Mean Squared Error: RMSE), 決定係数 (Coefficient of Determination:  $R^2$ ), 平均2 乗対数誤差の平方 根 (Root Mean Squared Logarithmic Error: RMSLE), 平 均絶対パーセント誤差 (Mean Absolute Percentage Error: MAPE), 学習時間 (Training Time: TT) の7項目の評価 結果がアルゴリズム毎に自動的にストックされ, テー ブルデータとして保存される.

今回の課題は多入力多出力(16入力26出力)の回帰解 析であるが、今回用いた PyCaret ライブラリは現時点で は多入力単一出力のみにしか対応していない. ここでは 16入力単一出力の回帰解析を部材の健全率毎に独立して 26部材分実施し、それぞれの部材健全率毎に予測結果が どの程度正確なのかを決定係数を用いて調べた.なお, 入力データについては標準化やスケール変換等の前処 理は一切行っていない.後で示すが,部材健全率毎に19 の機械学習アルゴリズムを評価しても、決定係数値が良 くなるアルゴリズムは限られる.なお, scikit-learn ライ ブラリでは多入力多出力の回帰 (MultiOutputRegressor 関数)が実装されているが、プログラム内部では今回実 施したのと同様、各目的変数について単一出力の回帰 解析が独立して行われる. また, 多入力多出力の回帰 解析は多層のニューラルネットワークで対処できるが, ネットワークの設計に一定の試行錯誤を必要とするた め、今回の取り組みでは検討していない. ニューラル ネットワークを用いた検討は、今後の課題とする.

ここでは決定係数 *R*<sup>2</sup> を評価指標として用いる.決定 係数 *R*<sup>2</sup> は,次式で定義される.

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \overline{y}_{i})^{2}}$$
(2)

ここで、nはテストデータの数、 $y_i$ は目的変数値(正解 値、今回は部材毎の健全率)、 $\hat{y}_i$ は回帰モデルによる推 定値、 $\bar{y}$ は、目的変数値の平均値である。決定係数は1 から回帰予測値の残差変動と目的変数値の変動の比を 引いたものであり、回帰予測結果が常に正解値と等し い場合は1.0となる。したがって、決定係数が1.0に近 いほど評価が高いと言える。なお、定義から決定係数 は負の値にもなり得ることに留意されたい。決定係数 がどの程度であれば精度の高い予測と言えるのかにつ いては、分野毎に異なる。一般に、決定係数値が0.8 や 0.9 以上のとき、精度の高い予測と評価される。 表-1: 検討した 19 種類の機械学習アルゴリズム

PyCaret での略称	Scikit-learn でのアルゴリズム名称		
ada	AdaBoost Regressor		
br	Bayesian Ridge		
catboost	CatBoost Regressor		
dt	Decision Tree Regressor		
en	Elastic Net		
et	Extra Trees Regressor		
gbr	Gradient Boosting Regressor		
huber	Huber Regressor		
knn	K-Nearest Neighbors Regressor		
lar	Least Angle Regression		
lasso	Lasso Regression		
lightgbm	Light Gradient Boosting Machine		
llar	Lasso Least Angle Regression		
lr	Linear Regression		
omp	Orthogonal Matching Pursuit		
par	Passive Aggressive Regressor		
rf	Random Forest Regressor		
ridge	Ridge Regression		
xgboost	Extreme Gradient Boosting		

# (2) 比較・検討に用いた 19 種類の機械学習アルゴリ ズム

今回比較した 19 種類のアルゴリズムを表-1 に示す. これらのほとんどは、Scikit-learn に含まれているが、い くつかのもの (CatBoost, LightGBM, XGBoost 等) は scikie-learn には含まれていないので PyCaret を使用す る前に別途インストールしておく必要がある.

紙面の都合上,全てのアルゴリズムについての説明を 記述することはできないため,今回の取り組みで性能が 高かった CatBoost, Extra Trees, K 近傍法, LightGBM の4つのアルゴリズムに限って以下に説明しておく.

CatBoost<sup>19)</sup>は、ロシアの Yandex 社が近年開発した決 定木による勾配ブースティング技術を元にしたアルゴ リズムで、カテゴリカル変数の扱いが優れているとさ れる.また、木構造を選択する際の独自のアルゴリズ ムが特徴的であり過学習を抑制するとされる.

Extra Trees (Extremely randomized trees)<sup>20)</sup> は複数の 木構造を構築し,それらのアンサンブルによって回帰を 行うアルゴリズムであるが,特徴量を2分割して木構造 を作成する際に用いる指標であるジニ係数(またはエン トロピー等)をランダムに選択することが特徴である.

K 近傍法 (K-Nearest Neighbors)<sup>21)</sup>は 1970 年代に提案 されたアルゴリズムである.考察の対象となる説明変 数の近傍にある K 個のデータのうち,最もユークリッ ド距離が近いデータの目的変数を考察している入力の 出力とするアルゴリズムである. K の値によって精度



図-7: 各部材の健全率に対する最良の決定係数値

が変化することが知られている (K が小さい場合はノ イズに弱く, K が大きい場合は精度が低下する). なお, Scikit-learn では K のデフォルト値は 5 となっている.

LightGBM<sup>22)</sup>は、Microsoft 社によって公開された木 構造に基づくアルゴリズムで複数の木構造を直列につ なげて精度を高めようとするものである。各木構造内 のノード数を削減できる工夫を導入していることと、木 構造内の分岐点を高速に探索できるようにしたことが 特徴である。また、LightGBM は機械学習のコンペティ ションで一定レベル以上の結果を残すことが多いこと に加えて処理速度が高速であるため、広く用いられて いる.

### 4. 結果と考察

#### (1) 部材毎に得られた最良の決定係数について

図-7は、Case-01から Case-04 について、健全率の 下限値を 0.1、0.5、0.9 とした各場合についての部材毎 の最良の決定係数値を示している.他の下限値のケー スについてもプロットできるが、表示が煩雑になるた めこれらのケースに限った.各プロットは 19 種類の機 械学習アルゴリズムのうちで最も決定係数が 1.0 に近 かった (評価が高かった)ものを描画しており、アルゴ リズム毎の比較とはなっていない (アルゴリズム別の比 較は次節で述べる).

この結果で重要なことは,最良の決定係数がどの程 度の数値となっているかである.仮にどの Case も全て の部材について決定係数が 1.0 近くとなっている場合, ここで作成したデータセットは難易度の観点 (難易度が 低すぎる) からベンチマークとしての意味をなさない. 逆に,総じて決定係数のレベルが低い (例えば 0.1 程度) 場合は損傷推定の難易度が高く,機械学習タスクとし ての問題設定が不適切と考えられる.以上の観点から, Case-01 と Case-02 はどの部材においても決定係数値 が 0.95 以上となっており,ベンチマークとしての適性 は高くない.ただし,データ数の間引きやノイズ付与な どの操作によって難易度を高めることは可能と考える.

一方, Case-03 と Case-04 は決定係数が 0.5 から 0.9 に満たない領域に一定数以上のプロットが存在してお り, ベンチマークとして適切であると考える. これら のケースについても各下限値について 10000 解析分の データを使用しているため, データを間引く等して必 要に応じてベンチマークの難易度をさらに高くするこ とが可能である. 以上の検討から, Case-03 と Case-04 はで用いたデータセットは, ベンチマークとして十分 活用できると判断した.

車両中心位置の y 座標 (yc) を y 方向について固定し ない Case-01・Case-3 と yc=3.5 に固定する Case-02・ Case-04 をそれぞれ比較することで,車両中心位置のバ リエーションが決定系数値に与える影響を検討できる. y 方向に車両中心位置を固定しない場合の方が変位分布 のバリエーションが増え,さまざまなケースを含めた 学習が可能となり決定係数値が高くなることが期待さ れるが, y 方向に車両中心位置を固定した場合との差異 は大きくない.今回の問題設定では,車両中心位置の 情報は w1 から w14 の鉛直変位に反映されており,yc 自体の決定係数に対する感度は小さいと考える.同様 の理由で,車両中心位置の x 座標 (xc) についても決定 係数に対する感度は小さいと推察できる.

下限値を 0.1 と設定したケースは下限値を 0.9 と設 定したケースよりも健全率の探索範囲が広くなるため, 問題の難易度が高くなると考える.図-7aでは下限値 0.1 のケース(黒丸プロット)が他の下限値に比べて決定 係数がわずかではあるが小さくなる部材が多く確認で き, 推察に対応した結果が得られている. 一方, 図-7b, 図-7c, 図-7dでは必ずしも下限値 0.1 のケース (黒丸 プロット)の決定係数値が小さいわけではない.後に示 すように, ほとんどの Case について木構造をベースと した機械学習アルゴリズムが最良の決定係数を算出し ていたため、これらのアルゴリズムに共通の特性が決 定係数に反映されていると考える.木構造をベースと するアルゴリズムは,入力データの標準的な前処理で あるスケール変換 (標準化・正規化) を実施しなくとも スケール変換を実施した場合と同等の性能を発揮する ことが知られている<sup>23)</sup>. 今回設定した探索範囲の大小 は,スケール変換可能であるため,スケール変換に自

動的に対応可能な特性が下限値の違いによらず近しい 決定係数値を算出したものと考える.

部材番号 13 と 15 は、どの Case においても決定係数 値が他の部材に比べて小さくなっている.これらの部 材は図-3 に示すとおり、モデル中央部の垂直材 (図-3) である.これらの部材を任意程度損傷させた結果得ら れるモデル中央部が大きく変位する様式は、部材番号 13 と 15 以外の部材を損傷させることでも同様の変位 様式が得られると推察できる.すなわち、得られた変 位様式から一意に損傷部材を同定できない状況のため これらの部材に対する決定係数が小さく出ていると考 える.また、境界近くの部材についても決定係数 0.5 か ら 0.6 程度となっているが、これらについても得られた 変位様式から一意に損傷部材を同定できない状況のた めであると推察できる.

#### (2) 最良の決定係数を算出したアルゴリズムの集計結果

図-8は、図-7で示した部材毎の最良の決定係数値を 算出したアルゴリズムについての集計結果を示してい る.集計は各 Case について下限値が 0.1 から 0.1 刻み で 0.9 の全 9 通り・26 部材分 (全 234 データ)に基づい て計数した.

図-8中で木構造に基づかないアルゴリズムは図-8aと 図-8b で確認できる K 近傍法 (図中では K Neighbors と 表記)のみであり,全ての Case で木構造に基づくアル ゴリズムが常に最良の決定係数値を数多く算出してい ることがわかる.

**図-8a**と**図-8b**では, Extra Trees と K 近傍法につい て一定数以上のカウントが認められる. Extra Trees は Random Forest<sup>24)</sup> など他のアルゴリズムに比べて相対的 に高バイアス・低バリアンスとなる傾向を示すことが報 告されている<sup>20)</sup>. データセットはノイズを含まない数 値解析によって生成されたため、Case-01やCase-02の ように損傷部材を単一とした取りうる状態のバリエー ションが少ない場合、類似の入力から得られる出力の バラツキは小さい (低バリアンス). このデータセット の特性と Extra Trees の低バリアンスとなる特性が合致 して Extra Trees の性能が高くなったものと推察できる. K 近傍法はそのアルゴリズムの特性上, テストデータの 入出力パターンに近しい入出力パターン学習データに 含まれている場合に高い性能を発揮する. 今回の事例 では、クロスバリデーションで用いた 1000 個のテスト データに似通った入出力パターンが 9000 個の学習デー タに含まれていたことを示唆している.また、入出力パ ターンのバリエーションが増加する Case-03 と Case-04 ではテストデータと学習データで類似の入出力関係が 含まれる可能性が小さくなるため, K 近傍法は高い性 能を発揮できていないと推察できる.



図-8:各 Case で最良の決定係数 (R<sup>2</sup>)を算出したアルゴリズムの集計結果

Case-03 と Case-04 では 3 種類のアルゴリズムのみ が現れており, CatBoost と LightGBM のカウント数が 大きい.特に CatBoost と LightGBM は他の事例でも高 い性能を発揮することが知られており,しばしば比較 されている<sup>25)</sup>.これらの Case では損傷部材数が 2 であ るため,取りうる状態のバリエーションが多く問題の 難易度が Case-01 と Case-02 に比べて高くなっている. この結果,性能に定評のある CatBoost と LightGBM の 評価が高くなったものと推察できる.

#### (3) 決定係数と学習時間の関係

Case-04 で下限値 0.1 ケースについて,各種アルゴリ ズムの決定係数値と回帰モデル作成に要した学習時間を 表-2 に示す.決定係数および学習時間は 26 部材の健全 率に対する回帰解析の算術平均によって求めた.表-2 中 のアルゴリズム名は,上から順に決定係数値が高かっ たものから並べている.決定係数が高いアルゴリズム が必ずしも学習時間が短いわけではないため,アルゴ リズム選定には決定係数と学習時間の両面からの検討 が好ましい.

この観点から、決定係数が 0.5 以上であったアルゴ

リズムを選び出し、横軸に決定係数を、縦軸に学習時 間をとってプロットしたものが図-9である. アルゴリ ズム評価の観点からは、決定係数が 1.0 に近く、学習時 間が小さければ小さいほど良いアルゴリズムと言える. CatBoost と LightGBM の決定係数の差はほとんどない が、CatBoost の学習時間は LightGBM の約 50 倍となっ ている. LightGBM に比べて CatBoost の学習時間が長 くなる傾向は、他の事例でも報告されており<sup>25),26)</sup>、学 習時間に関して得られたここでの結果は既往の研究結果 と整合する. 図-9で示した結果より、今回の教師デー タに対しては決定係数と学習時間の観点から LightGBM が素性の良いアルゴリズムと言える. Case-04 で下限 値が 0.1 のケース以外においても LightGBM の評価は 高い. 例えば, Case-01 で下限値が 0.4 のケースでは, Extra Trees の決定係数値が 0.988 に対し、LightGBM の 決定係数値が 0.954 とわずかに劣るものの、学習時間 の比較では Extra Trees が 0.366 秒となっているのに対 して LightGBM は 0.099 秒となっており,決定係数と 学習時間の観点から素性の良いアルゴリズムと言える. なお、LightGBM はほぼ全てのケースで決定係数と学 習時間の評価が高いことを確認している.

表-2: 各アルゴリズムの決定係数と学習時間 (Case-04 で下限値が 0.1 場合の 26 部材に対する平均値)

アルゴリズム	決定係数	学習時間 (s)
CatBoost	0.839	2.673
LightGBM	0.834	0.053
Extreme Gradient Boosting	0.790	0.242
Extra Trees	0.761	0.156
Random Forest	0.760	0.706
Gradient Boosting	0.728	0.295
Decision Tree	0.582	0.029
Bayesian Ridge	0.270	0.014
Linear Regression	0.270	0.018
Ridge Regression	0.268	0.013
K Neighbors	0.258	0.022
Orthogonal Matching Pursuit	0.140	0.013
Huber	0.016	0.070
Elastic Net	-0.002	0.013
Lasso Least Angle Regression	-0.002	0.013
Lasso Regression	-0.002	0.015
AdaBoost	-0.397	0.091
Passive Aggressive	-0.449	0.013
Least Angle Regression	-3,320.495	0.013

以上,各 Case について高評価であったアルゴリズム を示した.今回の機械学習タスクでは,Case によらず 木構造に基づくアルゴリズムの評価が高い結果となっ た.各アルゴリズムのハイパーパラメータは未調整で あるため,ハイパーパラメータ調整後の比較も行うこ とが望ましいが,これについては今後の課題としたい. いくつかの課題は残されるものの,今回示したように自 動機械学習によって多くのアルゴリズムを用いたデー タセットの可否判断が可能となることや,ハイパーパ ラメータを調整すべき素性の良いアルゴリズムの絞り 込みがほぼ自動的になされることの意義は大きい.

# 5. まとめと今後の展望

損傷部材を設定した橋梁モデルを用いて有限要素解 析を多数実施し,損傷部材推定に資する機械学習用デー タセットを生成した.生成したデータセットを 19 種類 の機械学習アルゴリズムに適用し,橋梁部材の損傷推 定問題としてのベンチマーク適性を決定係数を用いて 評価した.

結果,損傷部材が単一の場合 (Case-01, Case-02) は, 一定数以上のアルゴリズムが決定係数 1.0 近くとなり難 易度が低いという観点からベンチマークとしての適性は 低いと判断した.一方,損傷部材数が2の場合 (Case-03, Case-04) は,決定係数値が0.5 から0.9 の範囲内で分布



図-9: 各アルゴリズムに対する決定係数と学習時間の関係

しており、ベンチマークとして適切であると判断した.

アルゴリズムの比較・検討の観点からは,木構造に 基づくアルゴリズムが多くの場合において高い性能を 発揮した結果となった.今回のベンチマークに対して は,決定係数と学習時間の観点から LightGBM の使用 が最適と判断された.本研究ではアルゴリズムのハイ パーパラメータは最適化していないため,今回得られ た傾向が他の問題にも当てはまるかどうかは不明であ る.しかしながら,今回のように自動機械学習を導入 することで,他の問題にマッチしたアルゴリズム選定 が容易に実施できると考える.

今後は,損傷部材数を増加させた場合のデータセッ ト作成を進め,一連のデータセットを整備した後にウェ ブサイトでの公開を目指す.並行して,ノイズを加え たデータセットについて今回と同様の機械学習タスク を実施し,得られる決定係数について検討する.

謝辞: 京都大学 古川愛子先生には構造物の損傷とその 逆問題に関して有益なご助言を賜りました.ここに記 して謝意を表します.

#### 参考文献

- 全邦釘:土木工学分野における人工知能技術活用のため に解決すべき課題と進めるべき研究開発, AI・データサ イエンス論文集, Vol.1, No.J1, pp.9–15, 2020.
- Avci, O., Abdeljaber, O., Kiranyaz, S., Hussein, M., Gabbouj, M., Inman, D.J.: A review of vibration-based damage detection in civil structures: from traditional methods to Machine Learning and Deep Learning applications, Mechanical Systems and Signal Processing, Vol.147, 107077, 2021.
- 3) Akinosho, T.D., Oyedele, L.O., Bilal, M., Ajayi, A.O., Delgado, M.D., Akinade, O.O. and Ahmed, A.A.: Deep learning in the construction industry: A review of present status and future innovations, Journal of Building Engineering, Vol.32, 101827, 2020.
- 4) 全邦釘, 井後敦史: Random Forest によるコンクリート

表面ひび割れの検出, 土木学会論文集 F3, Vol.71, No.2, pp.I\_1–I\_8, 2015.

- (成山傑, 松本高志: Deep Learning によるコンクリートの変状自動検出器の開発とWebシステムの実装, 土木学会論文集 A2(応用力学), Vol73, No.2, pp.I\_781-I\_789, 2017.
- 6) 青島亘佐, 中野聡, 徳永皓平, 中村秀明: 深層学習による異常検知手法を用いたコンクリート表面の変状検出, 土木学会論文集 A2(応用力学), Vol.75, No.2, pp.I\_559-I\_570, 2019.
- 7)前田絋弥,関本義秀,瀬戸寿一,樫山武浩,小俣博司:機 械学習とスマートフォンを用いた道路の損傷画像のリア ルタイム検出と修繕対応基準における各特徴量の重要度 比較,交通工学論文集, Vol.4, No.3, pp.A\_1–A\_8, 2018.
- 全邦釘,井後敦史,南免羅裕治;黒木航汰,大窪和明:車載 カメラにより撮影された舗装画像からのディープラーニ ングによるひび割れ率評価,土木学会論文集 E1(舗装工 学), Vol.73, No.3, pp.I\_97–I\_105, 2017.
- 9) 鈴木達也, 西尾真由子:橋梁定期点検における部材損傷度 判定への深層学習の適用に関する検討, 土木学会論文集 F3(土木情報学), Vol.75, No.1, pp.48–59, 2019.
- 10) 龍田斉, 横山広, 永見武司, 桝谷浩, 近田康夫, 山田宗明: 勾 配ブースティング決定木を用いた橋梁損傷原因および補 修工法の推定と分析, AI・データサイエンス論文集, Vol.1, No.1, pp.63–70, 2020.
- 11) LeCun, Y. and Corinna. C. and Burges, C.J.C.: MNIST handwritten digit database, http://yann.lecun.com/ exdb/mnist/(2021年7月30日閲覧)
- Yeh, I.C.: Modeling of strength of high performance concrete using artificial neural networks, Cement and Concrete Research, Vol.28, No.12, pp.1797–1808, 1998.
- 13) Yeh, I.C.: Concrete compressive strength data set, https://archive.ics.uci.edu/ml/ machine-learning-databases/concrete/ compressive/(2021年7月30日閲覧)
- 14) Qurishee, M., Wu, W., Atolagbe, B., Owino, J., Fomunung, I. and Onyango, M. : Creating a dataset to boost civil engineering deep learning research and application, Engineering, vol.12, No.3, pp.151–165, 2020.
- 15) COMSOL Multiphysics が公開しているプラットトラス橋 モデルのサイト: https://www.comsol.jp/model/ pratt-truss-bridge-8511 (2021 年 7 月 19 日 閲 覧)

- 16) 横山広,門寺将志, Tran Trung Le Hoang, Nguyen Nga Thu, 桝谷浩:道路橋床版耐荷性能評価への衝撃荷重載荷 試験の適用に関する研究,構造工学論文集 A, Vol.65A, pp.544–551, 2019.
- 17) Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, É.: Scikit-learn: machine learning in python, *Journal of machine learning research: JMLR*, Vol.12, pp.2825–2830, 2011.
- 18) Ali, M.: PyCaret: An open source, low-code machine learning library in Python, https://www.pycaret.org (2021 年 7 月 11 日 閲覧)
- 19) Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V. and Gulin, A.: CatBoost: unbiased boosting with categorical features, *Proceedings of the 32nd International Conference on Neural Information Processing Systems*, pp.6639–6649, 2018.
- 20) Geurts, P., Ernst, D. and Wehenkel, L.: Extremely randomized trees, *Machine Learning*, Vol.63, pp.3–42, 2006.
- Bentley, J. L.: Multidimensional binary search trees used for associative searching, *Communications of the ACM*, Vol.18, No.9, pp.509–517, 1975.
- 22) Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T-Y: LightGBM: a highly efficient gradient boosting decision tree, *Advances in Neural Information Processing Systems*, pp.3149–3157, 2017.
- 23) Choi, J. C., Liu, Z., Lacasse, S. and Skurtveit, E.: Leak-Off Pressure Using Weakly Correlated Geospatial Information and Machine Learning Algorithms, *Geosciences*, Vol.11, No.4, 181, 2021.
- 24) Breiman, L.: Random forests, *Machine Learning*, Vol.45, No.1, pp.5–32, 2001.
- 25) Essam, AI. D.: Comparison between XGBoost, LightGBM and CatBoost using a home credit dataset, *International Journal of Computer and Information Engineering*, Vol.13, No.1, pp.6–10, 2019.
- 26) Hancock, J. T. and Khoshgoftaar, T. M.: CatBoost for big data: an interdisciplinary review, *Journal of Big Data*, Vol.7, Article number. 94, 2020.

# GENERATING MACHINE LEARNING DATASETS ON DAMAGE IDENTIFICATION USING FINITE ELEMENT BRIDGE MODEL

## Hidetaka SAOMOTO and Takashi MIYAMOTO

Recently, machine learning has been actively applied to various problems in the civil engineering field. To further facilitate the use of machine learning in the civil engineering field, it is essential to have appropriate benchmark problems and training datasets with the characteristics of the civil engineering field. Nevertheless, such datasets have not yet been proposed sufficiently. In this study, using the finite element analysis, we propose fundamental datasets (no noise and no missing data) as benchmark problems for damage identification of bridge model, with four levels of difficulty. Then, we input the dataset into a total of 19 machine learning algorithms to assess the quality of the dataset using the coefficient of determination obtained from those algorithms. As a result of numerical experiments, the following points were found: For cases with a single damaged member, most of the algorithms have the coefficient of determination higher than 0.9, resulting in unsuitable benchmarks due to its simplicity. For cases with two damaged members, the coefficient of determination is distributed from 0.5 to 0.9, resulting in suitable benchmarks with appropriate difficulty.