

AI を活用した下水道管渠の点検効率化 に関する分析

諏訪 太紀¹・藤生 慎²・森崎 裕磨³・福岡 知隆⁴・吉倉 麻衣⁵

¹ 学生会員 金沢大学大学院 自然科学研究科地球社会基盤学専攻 (〒920-1192 石川県金沢市角間町)

E-mail: s.taiki@stu.kanazawa-u.ac.jp

² 正会員 金沢大学准教授 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: fujiu@se.kanazawa-u.ac.jp (Corresponding Author)

³ 正会員 金沢大学特任助教 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: morisaki@staff.kanazawa-u.ac.jp

⁴ 正会員 金沢大学博士研究員 融合研究域融合科学系 (〒920-1192 石川県金沢市角間町)

E-mail: tfukuoka@se.kanazawa-u.ac.jp

⁵ 学生会員 金沢大学大学院 自然科学研究科環境デザイン学専攻 (〒920-1192 石川県金沢市角間町)

E-mail: m.yoshikura@stu.kanazawa-u.ac.jp

現在、我が国における下水道管渠の総延長は約 490,000km となり、膨大なストックを抱えている。また、標準耐用年数である 50 年を経過する下水道管渠の割合は今後加速度的に増加していく。一方で、我が国では地方自治体の財政難や少子高齢化、人口減少により、財源・人材・技術の三つの不足が問題となっている。このような状況下で膨大な下水道管渠に対して、均等に調査を行うことは困難である。したがって、ストックマネジメント計画を策定し、少ない現地調査結果をもとに、現地調査を実施していない下水道管渠の緊急度の推定を行い、優先度付けを行った上で、施設の点検・調査、修繕・改築を実施することで、下水道管渠における維持管理の最適化を図る必要がある。そこで、本研究では、下水道管渠の点検結果を活用し、下水道管渠における緊急度分類モデルの構築と評価を行った。

Key Words: Machine learning, sewage pipe, Inspection efficiency

1. 序論

現在、我が国の下水道普及率は 2020 年度末で、約 80.1%¹⁾、全国下水道管渠の総延長は 2020 年度末で約 490,000km となり、膨大なストックを抱えている。また、2020 年度末において、標準耐用年数 50 年を経過した下水道管渠の延長は約 25,000km (総延長の 5%) であり、10 年後は 82,000km (17%)、20 年後には 19,000km (39%) と今後急速に増加する (図-1)²⁾。下水道管渠は置かれている環境下から交通による荷重やコンクリートの微生物腐食が発生するなど、劣化の要因が時間依存のものにとどまらず、老朽化の進行が他の構造物と比較して早い。さらに、2020 年には下水道管渠の老朽化が起因した道路陥没事故が 2700 件も発生しており、老朽化は重大な社

会問題をも引き起こす²⁾。このような事態を未然に防ぐためにも、点検及び修繕・改築を適切に行う必要がある。現在、下水道管渠の点検は目視及びテレビカメラ調査によって行われているが、2018 年度の調査延長は目視とテ

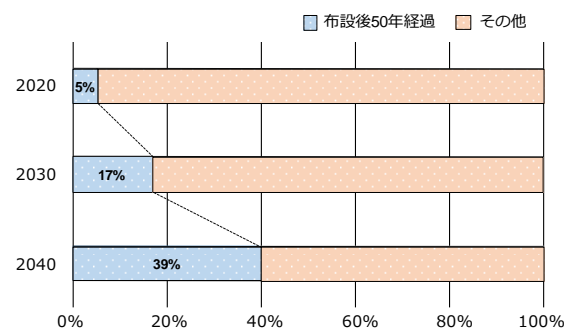


図-1 布設後 50 年以上が経過する下水道管渠の割合¹⁾

レビカメラによるものと合わせてわずか 6,686km (総延長の 1.4%³⁾) であり、このペースでは全下水道管渠を一巡調査するのに 72 年もかかり、適切な維持管理が行えない。加えて、我が国では、地方自治体の財政難や少子高齢化、人口減少により、財源・人財・技術の三つの不足が問題となっている。このような状況下で、膨大なストックに対して、均等に調査を行い、さらに修繕・改築を行うことは困難である。

したがって、ストックマネジメント計画を策定し、少ない現地調査結果をもとに、現地調査を実施していない下水道管渠を含めた全管渠の各スパンについて緊急度の推定を行い、優先付けを行った上で、施設の点検・調査、修繕・改築を実施し、下水道管渠における維持管理の最適化を図る必要がある。

本研究では、機械学習手法による下水道管渠における緊急度分類モデルの構築を行う。より具体的には、国土交通省・国土技術政策総合研究所(国総研)が公開している管渠劣化データベース(以下、国総研 DB)⁴⁾を使用し、「管齢」や「土被り」など、調査を行わず取得可能なデータから下水道管渠のうちコンクリート管における各スパン毎の緊急度(表-1)を予測するモデルの構築を行う。本研究では、機械学習のうち、アンサンブル学習モデルとして代表的な XGBoost, LightGBM, Random Forest の三種類のモデルの構築と評価を行った。なお、使用データ及び、分析手法に関する詳細は随時、記述する。

2. 既往研究の整理と本研究の位置づけ

本章では、本研究の目的に沿い、下水道管渠を対象とした健全度の予測並びに管理の優先度に関するスクリーニングを行っている研究、点検結果を活用し健全度の推定を試みている研究について整理を行い、それを踏まえた上で本研究の新規性について述べる。

(1) 既往研究の整理

2011年9月、国土交通省国土総合研究所より下水道事業へのアセットマネジメント導入支援を目的とし、管渠の劣化データで構成される国総研 DB が公開された。松宮ら⁵⁾は、国総研 DB を活用した健全度予測式の推定や

表-1 下水道管渠の緊急度区分

緊急度	緊急度区分
I	速やかに措置が必要
II	簡易な対応により必要な措置を5年未満まで延長可能
III	簡易な対応により必要な措置を5年以上に延長可能
IV	劣化なし

改築事業量予測を定量的に行っている。しかしながら、提案された健全度予測式は説明変数として敷設年数のみを使用しており、管種や管径、取り付け管の本数などの差による健全度の違いを考慮することは出来ていない。また、自治体全体の改築事業量予測などには適しているが、具体的にどこにどの程度の損傷を有した下水道管渠が存在するかといった細かい単位での予測をすることは不可能である。

藤生ら^{6),7)}は国総研 DB を使用し、DB から取得可能な質的データ及び量的データを差分関数に変換することで、情報量低減を防ぎ、これに対して線形判別分析を適用することで、個々の下水道管渠スパンに対して、緊急度 I, II から構成される劣化の大きい集合である 0 群と緊急度 III, IV から構成される劣化度の小さい集合である 1 群の判別を行っている。

貝戸ら⁸⁾は、下水道管渠に対する目視点検データを用いて、管渠の劣化過程を混合マルコフ劣化ハザードモデルで表現し、劣化速度の異質性に関するベンチマーク分析を行い、個々の管渠の異質性パラメータを推定し、推定値と管渠の位置情報からデュアル・カーネル密度分析を援用し、劣化速度の空間的劣化異質性分布を評価した。さらに、空間的劣化異質性分布に基づいて、相対的に劣化速度が速い管渠が密集する重点管理区域をスクリーニングするとともに、シミュレーションを通して管渠の改築更新施策を提案した。

大竹ら¹⁰⁾は、橋梁の定期点検結果において、部材毎に設定されている多数の細目項目の判定結果を用いて主成分分析を行い、第 1 主成分を部材の総合的な健全度とすることで、離散量として与えられる各点検項目の判定結果に対して、橋梁間で差別化が容易な連続量として取り扱い、同時に、第 2 主成分の情報から、対策の最適実施時期や広報が異なる劣化機構の違いにより橋梁群を層別できることを示した。

南ら¹¹⁾は、コンクリート床版に着目して、橋梁の定期点検の結果より、ひび割れの形状・規模、漏水・遊離石灰の有無などの情報を損傷図から定量的に抽出し、抽出された情報から損傷度、損傷の発生要因の推定を行うモデルを Random Forest を用いて構築している。

(2) 本研究の位置づけ

本研究の主目的は、下水道管渠を対象とし、その健全性(緊急度 I-IV)をテレビカメラ調査等によって取得される管渠内部の損傷状況を説明変数として使用せず、管齢や管径、土被りなど調査を行わず取得可能なデータからスパン単位での下水道管渠の緊急度に関する 4 クラス分類のモデルの構築を行うことである。前節で挙げた既往研究^{6),7)}は、4 つのカテゴリが存在する緊急度に対して、それらを損傷の多い群と少ない群の 2 群に設定し、

表-2 使用するデータの概要

No.	項目名称	項目説明
1	事業分類	公共
2	自治体	所属自治体仮名称
3	管径 (mm)	管の内径
4	延長 (mm)	スパンの延長
5	スパン内の管本数	スパンを構成する管の数
6	取り付け管本数	スパン内の取り付け管の数
7	布設年度	布設された年度
8	調査年度	調査が実施された年度
9	管齢 (年)	管の供用年数
10	管種	管の種類 (陶管,コンクリート管等)
11	道路種別	国道, 都道府県道, 市町村道の区分
12	歩車道	歩車道の区分
13	排水種別	合分流の区分
14	土被り (m)	上流側と下流側の土被りの平均
15	緊急度	緊急度 I -IV

判別を行っている。本研究では、4クラスの分類モデルを構築することでより詳細な下水道管渠の損傷の分類を行うことが有意な点である。社会基盤施設の点検結果を活用し、機械学習手法によって、健全度を分類するアイデアは既往研究¹¹⁾にもみられるが、下水道管渠を対象としているものは存在しない。下水道管渠を対象としている点が本研究の新規性である。加えて、下水道管渠が埋設構造物であることから、大半の管渠に対して、点検を実施することが出来ない自治体が存在する。本研究では、点検を必要とせず取得可能な変数により緊急度の分類を行うモデルを作成する。したがって、財政的に点検を実施することが困難な自治体に対しての技術展開へのハードルが低く、これが本研究の有用な点であると言える。

3. 使用データの概要

本研究では、解析データとして国総研 DB を使用する。国総研 DB は 2011 年に国総研下水道研究部下水道研究室が、下水道事業へのアセットマネジメント導入支援を目的とし、目視調査またはテレビカメラ調査を面的に実施している都市から収集した約 10.5 万スパンの管渠劣化データベースとして公開した。その後、2017 年に更新が行われて約 24.9 万スパンに拡充された Ver.2 が公開された。加えて、Ver.2 では「下水道維持管理指針 実務編 2014 年版」に準拠する緊急度判定結果情報 (表-1) が新たに追加された。さらに、2021 年にデータの拡充が行われ、約 30.8 万スパン分の管渠劣化データである Ver.3 が公開された。本研究では、Ver.3 を使用し、緊急度分類モデルの構築を行う。国総研 DB には目視調査或いはテレビカメラ調査から判定された緊急度の他に、管径や路線延長、取り付け管の本数、布設年度などの諸元と管の腐食 (劣化の程度に応じて a-c にランクづけされている) や、上下方向のたるみ、管のクラック、管の継手ズレなどの調査によって取得された管渠内部の損傷状況の大きく分けて 2 種類のデータが存在している。前章で述べたように、本研究で構築する分類モデルは調査を行わずとも取得可能なデータから緊急度を分類するモデルであるため、本研究では、管渠内部の損傷状況に関するデータは使用しない。それらを除いた本研究で対象となるデータの概要を表-2 に示す。

4. 機械学習手法に基づく緊急度分類モデル

(1) 使用する機械学習モデル

本研究では、緊急度の分類モデルにアンサンブル学習モデルとして代表的な手法である XGBoost¹²⁾, LightGBM¹³⁾, Random Forest¹⁴⁾の三種類のモデルを使用し

た。

アンサンブル学習とは、複数の弱学習機を組み合わせることでより精度の高いモデルを構築する手法であり、代表的な手法にバギングとブースティングがある。本研究で使用する Random Forest は決定木とバギングを組み合わせた手法であり、XGBoost, LightGBM はブースティングを組み合わせた手法である。

Random Forest はランダムに選ばれた学習データ及び説明変数から構築される複数の決定木の結果を合わせてクラス分けを行うアルゴリズムである。概念図を図-2 に示す。一方で、XGBoost, LightGBM は図-3 に示す通り、学習時に決定木を直列に作成し、それまで作成した決定木の予測値を新しい決定木の予測値に加える事で、モデルの精度を改善する手法である。

本研究では、機械学習のライブラリである Scikit-learn を使用し、前述した各モデルの実装を行った。また、機械学習モデルにおいては、学習に先立って設定を行うハイパーパラメータが存在する。本研究では、各モデルについて Scikit-learn におけるデフォルト値を使用した。

(2) 使用変数について

本研究では、表-2 に示す通り国総研 DB より、管路内部の劣化状況を除いたデータを使用する。国総研 DB は全ての項目に対して、データが存在するわけではなく、いわば虫食い状態となっている。また、4 ランクある緊急度 (表-1) のうち、最も損傷の程度が大きく、速やかな措置が必要とされる緊急度 I のデータが他の緊急度のデータと比較して、非常に少量である。そのため、本研究では、緊急度 I のデータを可能な限り削除しないよう

変数選択を行った。本研究で使用する変数を表-3に示す。また、前述した通り本データは、各緊急度毎でデータ数の偏りが大きい。国総研 DB より本研究で使用するデータ(表-3)をフィルタリングし、欠損値を除去した各緊急度クラスにおけるデータ数の内訳を図-2に示す。

(3) 不均衡データの整形

前節で述べた通り、本研究で使用するデータは緊急度 I のデータ数が非常に少量であり、データ数に大きな偏りが存在する。機械学習モデルの構築において、不均衡なデータを学習に使用する場合には、データ数の多いクラスに分類を行うことで見かけ上の精度が高くなるため、分類において重要な特徴を学習するのではなく、見かけ上の精度が向上するような学習が行われることが懸念される。そのため、本研究では、最もデータ数の少ない緊急度 I のデータ数に、他のクラスのデータ数を合わせるようにデータをランダムサンプリングすることでデータの整形を行った。また、サンプリングの方法によって、分類性能に差が生じる可能性があるため、本研究では 100 回ランダムサンプリングを行い、各データセットに対してモデルの構築を行った。

表-3 モデルに使用する変数

変数名	単位	データ例
管径	mm	300m
管長	m	10.5m
管齢	年	30年
土被り	m	10.5m
スパン内の管本数	本	5本
取り付け管本数	本	10本

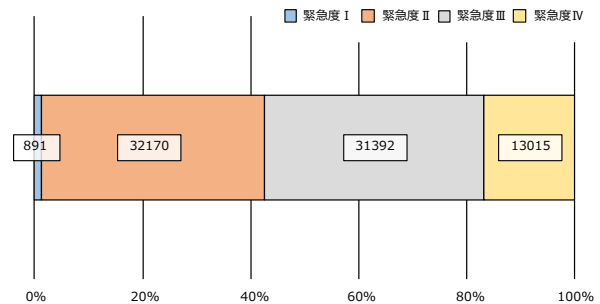


図-2 使用データにおける緊急度別データ数の内訳

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$F - measure = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (3)$$

5. 緊急度分類モデルの評価

本研究では、各機械学習手法に対して、前章で述べた 100 回のランダムサンプリングによって作成したデータセットに対して、k 分割交差検証法を適用し、モデルの評価を行う。k 分割交差検証法では、図-3 に示す通り、作成したデータセットを k 群に分割し、分割されたデータセットのうち、k-1 群を学習、残りの 1 群をモデルの検証に使用する。この手順を k 回繰り返す、各イテレーションにおける評価値の平均値をモデルの評価値とする。本研究では分割数を k=5 とした。表-4 に本研究で定義する混合行列を示す。本研究では、各モデルにおける分類性能の評価指標として各クラスの再現率 (Recall) の平均値であるマクロ平均再現率 (Macro-Average Recall)、各クラスの適合率 (Precision) の平均値であるマクロ平均適合率再現率 (Macro-Average Precision)、各クラスの F 値 (F-measure) の平均値であるマクロ平均 F 値 (Macro-Average F-measure) の三つの指標を用いる。各クラスにおける再現率、適合率、F 値は其々、表-4 に示す混合行列によって定義される値より、以下の式(1)から式(3)によって算出される。適合率は分類モデルが対象クラスに分類した数のうち、どれだけ正しく分類されているかを示す指標である。再現率は、対象クラスのうち、実際に分類モデルが正しく分類出来ているかを示す指標である。F 値は、再現率と適合率のバランスを示す指標であり、両値の調和平均をとったものである。

各モデルにおける、k 分割交差検証の結果を図-4 に示す。なお、各分類モデルにおける性能指標はランダムサンプリングによって作成した 100 セットの均衡データに対して、k 分割交差検証法を適用した結果の平均値である。各モデルにおけるマクロ平均再現率・マクロ平均適合率・マクロ平均 F 値はどれも 0.5 程度であり、結果として、僅かではあるが、XGBoost による分類モデルの性能が最も良好であった。しかしながら、マクロ平均適合率が 0.5 程度であることは半分程度分類結果が外れていることを示している。本研究で使用した説明変数は主に下水道管渠の諸元に関するものであるため、諸元情報のみでは、高精度で分類を行うことが難しいと考えられる。したがって、外力に関する説明変数を取り入れる必要があり、これは今後の課題である。

6. 本研究のまとめ及び今後の課題

本研究では、今後、老朽化した下水道管渠の割合が加速

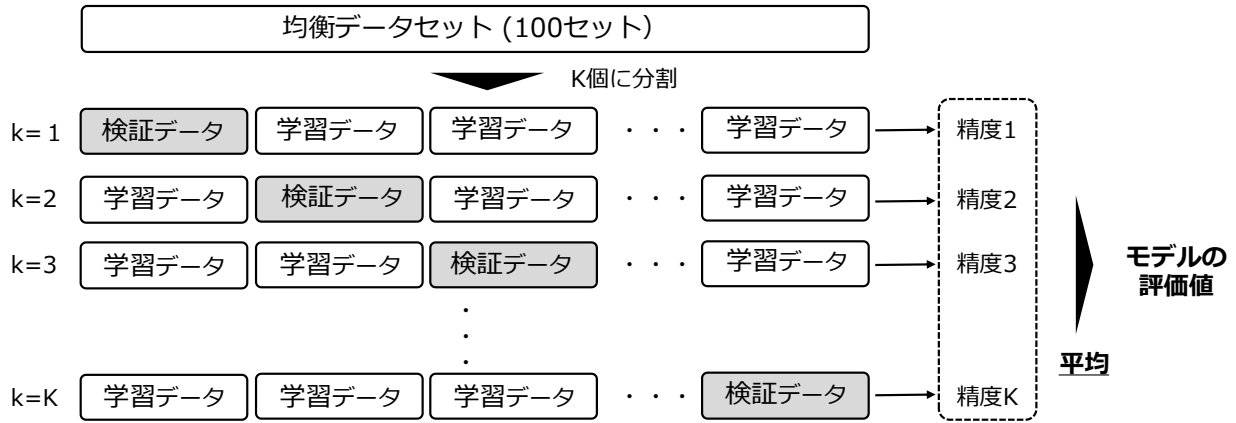


図3 k分割交差検証によるモデル評価の概要

度的に増加する状況に対して、適切な維持管理を実現するためのアプローチとして、国総研 DB より下水道管渠内の損傷状況を取り除いた、管齢や管長などの諸元を用いることで、テレビカメラ調査や目視などによる内部の損傷状況を確認せずとも緊急度の予測を行う手法を構築した。緊急度の予測手法には機械学習のうち、アンサンブル学習の代表的な手法である、XGBoost, LightGBM, Random Forest を採用した。また、入力データにおいては、データの性質上、最も損傷の程度が大きい緊急度Iのデータが非常に少量であるため、データの偏りが存在し、分類モデルを適切に構築することが難しいという問題が存在した。本研究では、ダウンサンプリングを行うことでこの問題を解決した。ダウンサンプリングによって整形を施したデータセットに対して、k 分割交差検証法を適用し、分類モデルの評価を行った結果、各モデルにおけるマクロ平均再現率・マクロ平均適合率・マクロ平均 F 値はどれも 0.5 程度であり、結果として、僅かではあるが、XGBoost による分類モデルの性能が最も良好であった。しかしながら、マクロ平均適合率が 0.5 程度であることは半分程度分類結果が外れていることを示しており、下水道管渠における諸元情報のみでは高精度で分類を行うことが難しいという示唆を得た。

今後の課題として、本研究では、各モデルにおいて設定するハイパーパラメータについて、Scikit-learn におけるデフォルトの値を使用しているため、グリッドサーチやランダムサーチを用いて、適切なハイパーパラメータの設定を行う必要がある。

また、本稿、第 1 章で述べた通り、水道管渠は置かれている環境下から交通による荷重やコンクリートの微生物腐食が発生するなど、劣化の要因が時間依存のものにとどまらない。本研究では、主に下水道管渠における諸元情報を特徴量として与えており、時間依存による劣化のみ考慮していると考えられる。今回使用した国総研 DB はデータの特性上、地点情報が与えておらず、周辺

表-4 混合行列

		予測クラス	
		該当クラス	その他
正解クラス	該当クラス	TP (True Positive)	FP (False Positive)
	その他	FN (False Negative)	TN (True Negative)

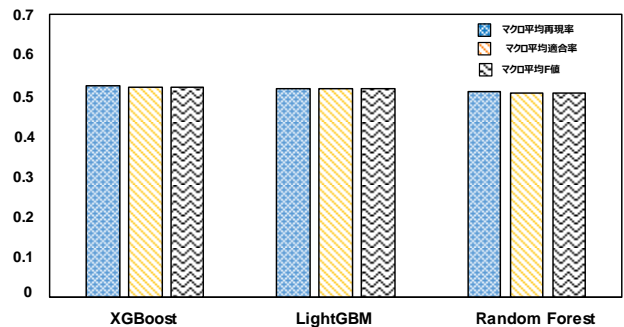


図4 各モデルにおける分類性能指標

の環境情報を考慮することが困難であった。今後、地点情報付きの点検結果の取得を行い、交通量や降雨量などの外力に関する特徴量を考慮することでモデルの分類性能の向上を図る。

参考文献

- 1) 公益社団法人日本下水道協会 HP：都道府県別の下水処理人口普及率， https://www.jswa.jp/wp2/wp-content/uploads/2021/09/R03_penetration-rate.pdf, 2022年9月15日閲覧。
- 2) 国土交通省 HP：下水道の維持管理， https://www.mlitt.go.jp/mizukokudo/sewage/crd_sewage_tk_000135.html, 2022年9月15日閲覧。
- 3) 日本下水道協会：平成 29 年度版下水道統計，電子ファイル「H29_02-2 管路施設(各種作業).xlsx」, 2022年9月15日閲覧。

- 4) 国土交通省 国土技術政策研究所 下水道研究部 下水道研究室 HP, <http://www.nilim.go.jp/lab/ebg/rekka-db.html>, 2022年9月20日閲覧.
- 5) 松宮洋介, 吉田敏章, 深谷渉, 福田康雄: 下水道管渠におけるストックマネジメント導入に関する検討調査, 「国土交通省国土総合研究所平成 22 年度年報」国土交通省国土総合研究所下水道研究部下水道研究室
- 6) 藤生和也: 布設年度と管齢の多重共線性を解消する方法の研究, 下水道協会誌, Vol.56, No.682, pp.118-126, 2019.
- 7) 藤生和也, 佐藤克己, 森田弘昭: 下水管渠劣化に関し量的データを差分関数に変換して線形判別分析に使用する手法の提案, 下水道協会誌, Vol.57, No.696, pp.72-82, 2020.
- 8) 藤生和也, 佐藤克己, 森田弘昭: 下水管渠劣化に関し質的及び量的データを差分関数に変換して線形判別分析に使用する手法の提案, 下水道協会誌, Vol.58, No.699, pp.84-94, 2021.
- 9) 貝戸清之, 篠崎秀太, 鎌田敏郎, 前川波奈江, 山中明彦: 下水道管渠の空間的劣化異質性に着目した重点管理区域スクリーニングと改築更新施策, 土木学会論文集 F4 (建設マネジメント), Vol. 77, No.1, pp.115-134, 2021.
- 10) 大竹雄, 流石堯, 本城勇介, 村上茂之, 小林孝一: 統計的手法を用いた橋梁点検データベースに基づく橋梁健全度評価に関する基礎的研究, 土木学会論文集 A2 (応用力学), Vol. 67, No.2, p.I_813-I_824, 2011.
- 11) 南貴大, 藤生慎, 福岡知隆, 高山純一: コンクリート構造物のひび割れ画像を用いた健全性の診断支援に関する基礎的研究, 土木学会論文集 D3 (土木計画学), Vol. 76, No.5, p.I_297-I_304, 2021.
- 12) Tianqi, C. and Carlos, G.: XGBoost: A Scalable Tree Boosting System, *In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'16)*, pp. 785-794, 2016.
- 13) Guolin, K. et al.: LightGBM: a highly efficient gradient boosting decision tree. *In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*, pp. 3149-3157, 2017.
- 14) Leo, B.: Random forests, *Machine learning*, Vol.45, No.1, pp. 5-32, 2001.

ANALYSIS OF THE EFFICIENCY OF SEWAGE PIPE INSPECTION USING AI

Taiki SUWA, Makoto FUJII, Yuma MORISAKI, Tomotaka FUKUOKA and
Mai Yoshikura