

下水道管渠における埋設環境を考慮した健全性の自動診断に関する分析

金沢大学大学院 自然科学研究科 地球社会基盤学専攻 学生会員 ○諏訪 太紀
金沢大学 融合研究域 融合科学系 准教授 正会員 藤生 慎
金沢大学 融合研究域 融合科学系 特任助教 正会員 福岡 知隆
金沢大学 理工学域 地球社会基盤学類 学生会員 山谷 佳史

1. 本研究の背景及び目的

わが国では、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¹⁾。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、下水道管渠等の老朽化は重大な社会問題を引き起こす要因となっている。このような事態を未然に防ぐためにも、点検及び修繕を適切かつ戦略的に行う必要がある。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%）であり、このペースでは全下水道管渠の一巡調査には 72 年を要する。したがって、現地調査を実施していない下水道管渠に対して、健全性の推定を実施し、優先付けを行った上で、点検・調査、修繕を行う必要がある。これまでに、筆者らは国土交通省国土総合研究所がアセットマネジメント導入支援を目的として公開している下水道管渠劣化データベース（国総研 DB）を使用し、深層学習手法の 1 つである、1 次元畳み込みニューラルネットワーク（1D-CNN）による緊急度分類モデルの構築を行っている²⁾。しかしながら、分類には主に管齢や管長、管径といった管の諸元情報のみを用いており、管路の埋設状況は考慮できておらず、分類性能を向上させるためには、下水道管渠が埋設されている環境を再現できるような追加の変数が必要であると結論付けている。本研究では、管路の諸元情報に加えて、管路位置における環境情報から、下水道管渠の健全性を推定する機械学習モデルの構築と評価を実施した。

2. 使用データ及び変数

本研究では、A 市で実施された下水道管渠の点検結果を用いて、機械学習手法によって健全性の推定を試みる。本データはビデオカメラ調査によって技術者により、健全性の評価が行われており、点検対象の下水道管渠における位置情報と健全性指標が収録されている。この位置情報を用いて、GIS により国土数値情報等から取得される環境データとの空間結合を行い、管路位置における環境情報を取得した（表-1）。また、本研究で推定を試みる管渠の健全性は、管渠における不良の程度によって、A（重度）、B（中度）、C（軽度）、D（健全）の 4 段階で診断が行われる。

3. 機械学習による分類モデルの構築及び評価

本研究では、アンサンブル学習モデルとして代表的な手法である XGBoost、Random Forest の 2 種類のモデルを使用した。本研究で使用するデータは図-1 に示す通り、健全性によってデータ数に偏りがある。機械学習モデルの構築において、分類カテゴリにおけるデータ数に偏りがある場合に、正しく学習が行われないことが懸念される。そのため、本研究では、最もデータ数の少ない RankA のデータ数に、その他の分類カテゴリのデータ数を合わせるため、ランダムサンプリングを実施し、データセットを作成した。このデータセットに対して、k-分割交差検証法を適用し、モデルの構築及び評価を実施した。本研究では、各モデルにおける分類性

キーワード 下水道管渠、機械学習、GIS、k-分割交差検証法

連絡先 〒920-1192 石川県金沢市角間町

金沢大学 自然科学 2 号館 7 階 2C719 TEL076-234-4914

表-1 本研究で使用する変数

項目	説明
管齢(年)	建設してから点検までの期間
管の長さ(m)	上流側マンホールと下流側マンホールの距離
管径(mm)	管の内径
取付管の数(本)	本管に接続されている取付管の本数
管路勾配(‰)	管路の勾配
管路機能	合流式幹線管渠or合流式枝線管渠or汚水幹線管渠or汚水式枝線管渠のいずれか
土壌区分	管路の位置における土壌の区分
表面地質区分	管路の位置における表面地質の区分
年間降水量(mm)	管路の属する1kmメッシュにおける年間降水量
年最深積雪深(m)	管路の属する1kmメッシュにおける年最深積雪深
用途地域区分	管路の位置における用途地域区分
平均傾斜角(度)	管路の属する1kmメッシュにおける平均傾斜角
平均管底高(m)	上流と下流における管底高(東京湾平均海面からの高さ)の平均




図-1 不良発生率ランク別データ数の内訳

表-2 XGBoost における分類性能

	Precision	Recall	F-measure
RankA	0.64	0.67	0.65
RankB	0.39	0.63	0.48
RankC	0.48	0.27	0.35
RankD	0.56	0.51	0.53
Average	0.52	0.52	0.50

能の評価指標として再現率(Recall), 適合率(Precision), F 値(F-measure)の三つの指標を用いる. 評価の結果, XGBoost の方が僅かに分類性能が高いという結果となった. ここでは, XGBoost の分類性能の結果を表-2 に示す. 表-2 より, 健全性の低い RankA, RankB は再現率の値が高く, 健全性の低い管渠の見逃しが少ない安全側の予測を行うことが可能であった.

4. 本研究のまとめ及び今後の課題

本研究では, より効率的な維持管理手法として機械学習を用いた健全性の推定を試みた. 下水道管渠の健全性を推定した結果, XGBoost による分類モデルが僅かではあるが, 分類性能が高いという結果が得られた. また, XGBoost による分類モデルは健全性の低い RankA や RankB の再現率の値が 0.6 以上と高いことから, 健全性の低い管渠の見逃し (RankA, B を誤って RankC, D と推定すること) が少ない安全側の予測を行うことが可能であった. 膨大な下水道管渠に対して, 点検対象の管渠をスクリーニングする上では, 健全性の低い管渠を見逃しなく, 推定することが重要であると考えられ, 本研究で構築した分類モデルは膨大な点検対象管渠から点検が必要な管渠をスクリーニングすることに対して有用であると考えられる. 一方で, 効率的にスクリーニングを行う上では, 健全性の低い管渠を見逃しなくかつ, 誤判定を最小化していく必要があると言える. 今後は, 本研究で考慮することが出来ていない交通量や人口密度, 周辺の建物情報などの人間の活動状況に関する変数を加えることで分類性能の向上を行う.

参考文献

- 1) 国土交通省 HP : 下水道の維持管理, https://www.mlit.go.jp/mizukokudo/sewerage/crd_sewerage_tk_000135.html,2023 年 3 月 15 日閲覧.
- 2) 諏訪太紀, 藤生慎, 森崎裕磨, 福岡知隆, 吉倉麻衣 : 1D-CNN を用いた下水道管渠における緊急度分類モデルに関する基礎的研究, AI・データサイエンス論文集, 3 巻 J2 号, pp.954-961, 2022.