

(5) 深層学習を用いた下水道管きょにおける 損傷検出技術の精度向上に関する基礎的研究

竹内 大輔¹・野澤 正裕²・山岸 洋明³・梅原 喜政⁴
 肖 智 葳⁵・中畑 光貴⁵・松尾 龍平⁵・川崎 悠史⁵
 青木 大誠⁵・大上 航平⁵

¹正会員 株式会社日本インシーク ライフライン事業部
 (〒541-0054 大阪市中央区南本町 3-6-14 イトウビル 4F)
 E-mail:takeuchi128@insiek.co.jp

²正会員 株式会社日本インシーク ライフライン事業部
 (〒541-0054 大阪市中央区南本町 3-6-14 イトウビル 4F)
 E-mail:nozawa032@insiek.co.jp

³正会員 株式会社日本インシーク 技術研究所
 (〒541-0054 大阪市中央区南本町 3-6-14 イトウビル 4F)
 E-mail: yamagishi021@insiek.co.jp

⁴正会員 摂南大学講師 経営学部
 (〒572-8508 大阪府寝屋川市池田中町 17-8)
 E-mail: yoshimasa.umehara@setsunan.ac.jp

⁵学生会員 株式会社日本インシーク 技術研究所／関西大学大学院 総合情報学研究科

我が国では、標準耐用年数である 50 年を経過した下水道管きょの割合が急速に増加しており、管きょの効率的な維持管理手法が求められている。現状の点検業務では、CCTV カメラを用いて調査員が地上のモニターを確認しながら損傷の有無やその度合いを記録する手法が一般的である。しかし、目視にて損傷の有無を確認するため、時間と労力がかかる課題や調査員によって損傷の判定基準にばらつきがある課題がある。そこで、本研究では、深層学習を用いて管きょを撮影した動画像を解析することで、クラックと破損を自動で検出する手法を提案する。具体的には、高精度な検出の実現に向けて最適な学習データの前処理や拡張方法を考究する。

Key Words: sewer pipe, maintenance, error detection, deep learning, camera image

1. はじめに

我が国では、高度経済成長期に多くのインフラ設備が作られ、それらの老朽化が深刻な問題となっている。特に、管きょは総延長距離が約 48 万 km あり、そのうち標準耐用年数である 50 年を経過した管きょの割合が 20 年後には総延長の 35% になると予想されており、管きょの効率的な維持管理手法が求められている¹⁾。管きょ内の異常には、様々な種類が存在するが、特に、クラックや破損が総損傷数の大部分を占めており、道路陥没の発生原因の約 7 割に及ぶ²⁾。そのため、管きょの効率的な維持管理には、クラックや破損をいかに早期に発

見するかが肝要である。従来の点検業務では、CCTV (Closed-Circuit Television) カメラを用いた方法が一般的である³⁾。この点検方式には、調査員が現場で CCTV カメラを操作し、管きょ内を撮影すると同時に異常の発生を確認する「直視側視式」と、現場で目視点検を行わず、事務所にて異常箇所の詳細を確認する「展開図化式」がある。昨今では、現場における作業日数を短縮できることから「展開図化式」が普及⁴⁾している。しかし、「展開図化式」では、CCTV カメラで撮影した動画像から画像処理技術を用いて管軸方向に展開した画像（以下、展開画像）を目視で確認して損傷を判定するため、均一かつ定量的な評価が難しい。加えて、長大な管きょの展開

画像を目視で判定するため、多大な時間と労力を要する課題がある。そこで、本研究では、深層学習を用いて管きょ内を撮影した展開画像からクラックと破損を自動で検出する手法を提案する。具体的には、高精度な検出の実現に向けて、損傷ごとに最適な検出モデルの構築方法を考究する。

2. クラックおよび破損の検出モデルの構築方法

本研究では、深層学習を用いてクラックと破損を検出できるモデルを構築する最適な手法について、学習データのクラス設定や前処理、データ拡張の観点から追求する。

(1) 学習条件

本研究では、深層学習の一種でありロバストな物体検出能力を有する畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）である YOLO（You Only Look Once）v4⁹⁾を採用する。また、学習データは、展開画像に対して、アノテーションツールの1つである labelimg⁹⁾を用いて、図-1のようにクラックと破損部にラベルを付与して作成する。

(2) クラス設定

モデルに設定するクラス数は、クラスごとの学習データ数を変化させ、特徴の学習に影響を与えるため、検出精度への影響は大きいと考えられる。そのため、本研究では、クラックと破損をそれぞれ別に学習したモデル（以下、単体モデル）とクラックと破損を同時に学習したモデル（以下、多クラスモデル）を構築し、その精度を比較する。

(3) 前処理

本節では、図-2に示すとおり、損傷部の特徴を強調できる前処理を検討する。

a) 画像鮮鋭化

画像鮮鋭化とは、画像の輪郭部の境界のコントラストを強調することで画像を鮮明にする方法である。これにより、損傷箇所を鮮明に表示できるため、検出精度の向上が期待できる。

b) 適応的閾値処理による二値化

適応的閾値処理による二値化（以下、二値化）とは、画像中の画素ごとに異なる閾値を用いて各画素が閾値を上回っていると白、そうでなければ黒に変換する方法である。これにより、損傷箇所の輪郭を際立たせることができる。二値化には、代表的な方法である近傍の画素値の平均から一定値を引いた値を閾値とする方法を用いる。




図-1 学習データ生成例




図-2 前処理およびデータ拡張の種類

c) 平滑化した画像と元画像の差分

平滑化した画像と元画像の差分⁷⁾（以下、差分）とは、メディアンフィルタを適用して平滑化した画像と元画像との画素値の差分を取る方法である。これにより、色の変化が小さい箇所を除去できるため、損傷箇所のみを可視化できると考えられる。

(4) データ拡張

本節では、図-2に示すとおり、学習データの多様性を確保するために管きよの損傷検出に適した学習データの拡張方法を検討する。

a) 反転

反転とは、画像を上下左右に180度回転させる方法である。展開画像は、円形の管きよを展開した画像であるため、画像を上下左右に反転させた場合においても実在する見た目になる。そのため、本研究では、学習データを上下左右の計4倍にデータ拡張する。また、以降のHSV変換、コントラスト調整、シフト移動は、反転により拡張した画像を対象とする。

b) HSV変換

HSV変換とは、画像のH(色相)、S(彩度)、V(明度)の数値をそれぞれ変更する方法である。変換後の画像が実在しない見た目になることを防ぐため、Hは変換せずにSとVのみを変換する。本研究では、Vのみを2倍、0.5倍、Sのみを1.5倍した場合の3パターン試行する。

c) コントラスト調整

コントラスト調整とは、画像上の明暗差を変化させることで、損傷部と周囲の色の差を強調する方法である。調整時の倍率に大きな値を設定すると画像全体が白飛びして実在しない画像になるため、本研究では、倍率1.1、1.2の2パターンと、それらを組み合わせた1パターンの計3パターン試行する。

d) シフト移動

シフト移動とは、画像を上下左右に平行移動させる方法である。管きよ内の損傷は様々な箇所が存在するため、上下左右に平行移動した場合においても実在する見た目になる。本実験では、各方向に50pixelずつ移動させることで、4倍にデータ拡張する。

3. 実証実験

本実験では、2章で整理したモデルの構築方法について、各々の検出精度を確認することで、管きよの損傷箇所の検出に最適なモデルの構築方法を明らかにする。

(1) 実験概要

本実験では、まず、単体モデルと多クラスモデルの検出精度を比較することで、最適なクラス数を明らかにする。次に、最適なクラス数を採用したうえで、前処理とデータ拡張を適用してモデルを構築する。そして、構築したモデルの精度を比較することで、最適なモデルの構築方法を明らかにする。検出精度は、各モデルの検出結果と人手で作成した正解データを比較することで、適合

率、再現率、F値を算出して評価する。適合率とは、検出数に対する検出の成功数の割合、再現率とは、実際の正解の数に対する検出の成功数の割合、F値とは適合率と再現率の調和平均である。これは、情報処理分野においてシステムの検出精度を評価する一般的な評価指標であり、値が1に近づくほどそのシステムの精度が良いことを表している。

(2) 実験条件

本実験では、総延長距離1,029.29kmの鉄筋コンクリート管をCCTVカメラで撮影した展開画像を用いる。学習データは、展開画像から損傷箇所を撮影した画像を選定し、人手でアノテーションすることで作成する。評価データは、学習データと同じ現場で計測した展開画像から学習データと重複しないように選定する。学習と評価に用いた画像枚数とアノテーション数をそれぞれ表-1に示す。学習回数は60,000回とし、バッチサイズは64とする。最適なクラス数の検証では、単体モデルと多クラスモデルの2パターン試行する。また、最適な前処理とデータ拡張の検証では、前処理3パターン、データ拡張6パターン、最適な組み合わせ1パターンの計10パターン試行する。

(3) 結果と考察

単体モデルと多クラスモデルの検出精度を表-2に示す。表-2を確認すると、クラックと破損ともに多クラスモデルより単体モデルの方が高精度に検出できることがわかった。これは、対象ごとの学習データのアノテーション数に偏りがあるため、多クラスモデルではクラックや破損を正しく学習できなかったためと考えられる。以上より、クラックと破損の検出には、単体モデルが適していることがわかった。

次に、単体モデルに対して、前処理とデータ拡張を適用して構築したモデルの検出精度を表-3に示す。まず、クラックの結果を確認すると、シフト移動と反転を適用

表-1 実験に使用したデータの内訳

データ	対象	画像枚数 (枚)	アノテーション数 (枠)
学習 データ	クラック	358	1,839
	破損	313	797
評価 データ	クラック	277	306
	破損	253	266

表-2 単体モデルと多クラスモデルの評価結果

モデル	対象	適合率	再現率	F値
単体	クラック	0.703	0.356	0.473
	破損	0.942	0.244	0.388
多クラス	クラック	0.948	0.239	0.381
	破損	0.986	0.133	0.235

表-3 前処理およびデータ拡張の評価結果

対象	処理内容		パラメータ	画像枚数 (枚)	アノテーション数 (枠)	適合率	再現率	F 値
クラック	前処理	画像鮮鋭化	-	1,432	7,356	0.810	0.363	0.501
		二値化	-			0.800	0.275	0.409
		差分	-			0.767	0.324	0.455
	データ拡張	—	-	1,432	7,356	0.703	0.356	0.473
		HSV 変換	-	5,728	29,424	0.769	0.337	0.468
		コントラスト調整	1.1 倍	2,864	14,712	0.816	0.232	0.361
			1.2 倍	2,864	14,712	0.804	0.281	0.416
			1.1+1.2 倍	4,296	22,068	0.949	0.242	0.385
		シフト移動	-	7,044	35,404	0.896	0.507	0.647
	前処理+データ拡張	画像鮮鋭化+シフト移動	-	7,044	35,404	0.794	0.353	0.489
破損	前処理	画像鮮鋭化	-	1,252	3,188	0.867	0.466	0.606
		二値化	-			0.862	0.305	0.450
		差分	-			0.775	0.207	0.326
	データ拡張	—	-	1,252	3,188	0.942	0.244	0.388
		HSV 変換	-	5,008	12,752	0.928	0.289	0.441
		コントラスト調整	1.1 倍	2,504	6,376	0.874	0.338	0.488
			1.2 倍	2,504	6,376	0.864	0.263	0.403
			1.1+1.2 倍	3,756	9,564	0.964	0.301	0.458
		シフト移動	-	6,104	14,809	0.915	0.444	0.597
	前処理+データ拡張	画像鮮鋭化+シフト移動	-	6,104	14,809	0.889	0.451	0.599

したモデルが最も高精度であることがわかった。クラックには多種多様な形状があり、管きょ内の様々な位置に発生する特徴があるため、反転やシフト移動のような拡張が有効であったと考えられる。次に、破損の結果を確認すると、画像鮮鋭化と反転を適用したモデルが最も高精度であることがわかった。これは、画像を鮮鋭化することで破損部と破損以外の部分の差を明確にすることが可能になったためであると考えられる。また、表-3 網掛け部に示すとおり、クラックと破損に共通してシフト移動と画像鮮鋭化は有効な方法であることが確認できる。しかし、それらの方法を組み合わせたモデルでは精度が低下する結果となった。これは、複数の処理を適用したことで、実際のデータとの見目が乖離したため、正しく特徴を学習できなかったためと考えられる。

4. おわりに

本研究では、管きょ内の点検業務における調査員の目視判定作業の効率化・省力化のために、深層学習を用いてクラックと破損を検出する方法を提案した。そして、実証実験を通じて、展開画像からクラックや破損の検出に最適なモデルの構築方法が明らかとなり、一定の精度で自動検出できることがわかった。しかし、実用化を想

定すると、クラックや破損の検出漏れは道路陥没等の深刻な被害を招く恐れがあるため、更なる精度向上を図る必要がある。今後は、YOLOv4⁹⁾以外の様々な物体検出手法を試行して精度向上を図るとともに、クラックや破損などの損傷度合いを詳細に判定する手法を開発する。

参考文献

- 1) 国土交通省：下水道の維持管理，<https://www.mlit.go.jp/mizukokudo/sewerage/crd_sewerage_tk_000135.html>，（入手 2022.6.4）。
- 2) 竹内大輔，深谷渉，宮本豊尚，横田敏宏：下水道管路の異常と道路陥没の関係性，土木技術の総合情報誌，Vol.59，No.3，pp.30-33，2017。
- 3) 市川建設社：下水道管路施設の点検・調査「視覚調査」とは？，<<https://ichikawa-kensetsu.com/post-1521/>>，（入手 2022.6.4）。
- 4) 岩下将也，山口治：ディープラーニングを用いた下水道管渠の情報検出システムの開発，土木情報学シンポジウム講演集，Vol.46，pp.33-36，2021。
- 5) Bochkovskiy, A., Wang, Y. and Liao, M. : YOLOv4 : Optimal Speed and Accuracy of Object Detection, <<https://arxiv.org/pdf/2004.10934.pdf>>,（入手 2022.6.4）。
- 6) GitHub : tzutalin/labelImg, <<https://github.com/tzutalin/labelImg>>,（入手 2022.6.4）。
- 7) 藤田悠介，三谷芳弘，浜本義彦：画像処理によるコンクリート表面のひび割れ抽出法，非破壊検査，Vol.56，No. 7，pp.371-377，2007。