

(9) ディープラーニングを用いた 下水道管渠の点検情報検出システムの開発

岩下 将也¹・山口 治²

¹正会員 株式会社奥村組 技術研究所 (〒300-2612 茨城県つくば市大砂 387)
E-mail: masaya.iwashita@okumuragumi.jp

²正会員 株式会社奥村組 東日本支社リニューアル技術部 (〒108-8381 東京都港区芝 5-6-1)
E-mail: osamu.yamaguchi@okumuragumi.jp

下水道管渠の老朽化に伴い、維持管理に求められる点検業務の範囲が増大している。点検業務の効率化のため、展開広角カメラを利用した画像点検によって現地調査の省力化をしている。しかし、事務所内の画像点検業務が増大しており、さらなる効率化を進めるには、画像点検の効率化が求められている。そこで、展開広角カメラで撮影された管渠内部画像から、AIを用いて管構造と損傷を事前に検出する下水管渠点検情報検出システムを開発した。管内の取付管や接合部について、高い性能で検出ができるようになった。AIの検出速度も、管渠延長約30mに対し15秒程度となっており、迅速な管構造と損傷抽出が可能となった。

Key Words: *sewage pipe, tube structure, damage detection, deep learning*

1. まえがき

現在、全国で整備されている下水道管渠は、約48万km³あり、その多くは人が入れない内径800mm以下の小口径の管渠である。これらの管渠の点検業務には、専用のカメラを備えた自走する撮影機を用いた画像の目視が必要となるが、時間と費用がかかるため、十分に点検が進んでおらず、不具合が発生した後に対処する事後保全の維持管理を余儀なくされている。

さらに今後は、標準耐用年数である50年を経過する下水道管渠が増加することから、管渠破損等に起因する道路陥没等の発生リスクが高まっており、今まで以上に効率的で省コストな管渠の点検方法が求められている。

そこで代表的な管渠の点検手法の一つである展開広角カメラ調査を対象に、業務を効率化のための下水管渠点検情報を検出するシステム(以下、本システム)を構築した。本稿では、システム概要と性能について紹介する。

表-1 下水管渠内部の調査種類

	スクリーニング調査	詳細調査
目的	域内の管渠内部を効率的に調査 損傷がある管渠を抽出 詳細調査対象箇所を選定	管渠内部の損傷種類と程度を判定 改築・更新の判定
調査方法	管口カメラ、広角カメラ等 	直視・側視カメラ、広角カメラ等 

2. 下水管渠点検システムの概要

(1) 既往の点検業務の種類と課題

水管渠内部を点検する業務は、表-1に示す通り、未洗浄の管から迅速に異常箇所を把握する「スクリーニング調査」と管の事前に洗浄し、異常箇所とその程度を判定する「詳細調査」の2種類がある。具体的な補修計画や、長期的な維持修繕計画を検討する場合、より確実な損傷個所の特定が可能な詳細調査が必須となる。

詳細調査では、「直視・側視カメラ調査」と「展開広角カメラ調査」の2つの方法が実用化されているが、現在は、現地調査が簡便で日進量が確保できる展開広角カメラが普及しつつある。展開広角カメラ調査の一般的なワークフローを図-1に示す。調査対象の路線内に、広角レンズを配置したカメラを入れ、管渠内部を等速で進みながら管内を撮影する。撮影と同時に、画像処理技術を用いて広角レンズのゆがみを処理した側視状の画像(以下、展開画像)を生成する。現場では、これらの撮影結果や展開画像をモニタリングしながら、簡易的な損傷のチェックを行う。その後、詳細な点検のため、展開画像を事務所へ持ち帰り、目視調査を進めていく。

事務所内での目視調査では、まず管渠の取付管と接合

部を確認し、管構造として記録する。その後、管内にある損傷の種類とその程度の判定を行う。管構造と損傷の確認・記録は、パソコン上で稼働する専用の管理ソフトでシームレスに実施され、記録物は報告書としてまとめられる。

展開広角カメラを用いた調査では、現地での損傷の確認が最低限で済み、撮影機を停止させる必要も無いことから、効率的な現地調査が可能となり、現地調査員の技能に依存するばらつきも少なくなる。一日当たりの調査可能量（日進量）は、直視・側視カメラ調査が300mであるのに対し、展開広角カメラ調査は450mと言われており、1.5倍の効率向上が見込める手法である。

ただし、展開広角カメラ調査は、調査すべき画像を容易に取得できる性質上、事務所内の画像目視業務が蓄積されやすくなる。また、長時間の画像目視による集中力の低下なども問題となっている。詳細調査のさらなる合理化に向け、展開画像の画像目視業務の効率化が新たな課題となっている。

(2) 本システムの概要

下水管渠点検情報検出システムは、図-1の破線ルートで示すように、展開広角カメラ調査における画像目視による調査を効率化すべく、調査前に管構造と損傷を自動的に抽出する。これにより、調査員の画像目視業務の軽減が期待できる。

(3) 検出対象

本システムの検出対象の管構造、損傷の拡大写真を図-2に示す。コンクリート管と陶管の2つに対応しており、管構造は、「取付管」、「接合部」、損傷は、「破損・クラック」、「浸入水」、「モルタル・木根の侵入」を検出できる²⁾。

3. システム構築とその性能

(1) 予測モデル構築の流れ

部位と損傷の検出には、機械学習手法の1つであるディープラーニングを用いている。画像と検出対象の情報（以下、ラベル）を元に、ラベルの画像上の特徴を自動的に学習し、予測モデルを構築する。

図-3に予測モデルの学習と性能評価の流れを示す。最初に、検出したい部位・損傷を含む展開画像を用意し、専門の調査員の意見を聞きながら、部位・損傷の有無、その位置情報などを画像上にラベルとして付加する。この作業をアノテーションと呼ぶ。画像とラベルのセットを教師データとして、学習データ、検証データ、評価データの3つに、6:2:2の割合でランダムに分割する。

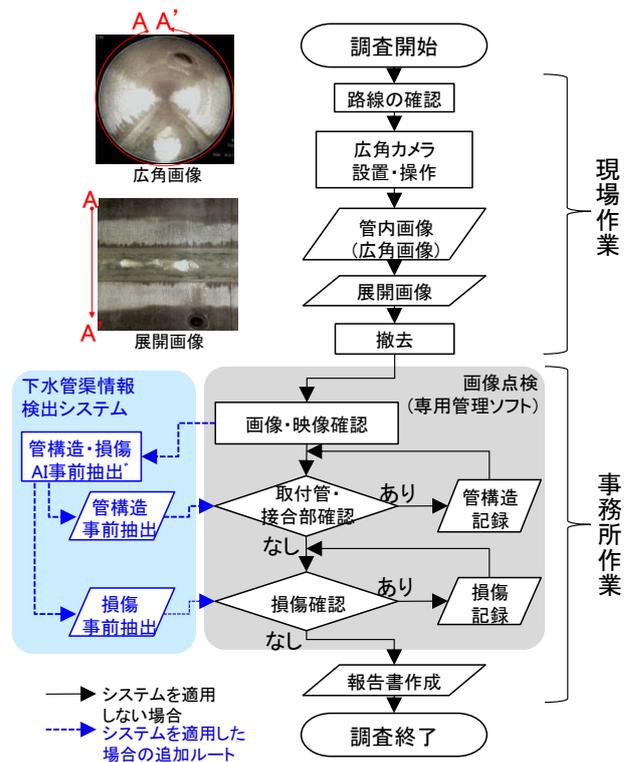


図-1 展開広角カメラ調査のワークフローと本システムの適用範囲



図-2 本システムの検出対象

続いて、学習データとラベルから予測モデルを構築する。構築された予測モデルに検証データの画像を入れ、予測結果と検証データのラベルを比較して、学習データ以外の画像でも性能を発揮すること（汎化性能）を確認する。この時、十分な性能が出ておらず、学習に調整の余地があると判断された場合、学習の条件（ハイパーパラメータ）をいくつか変え、再度学習を行い、検証データでの予測性能を高める。

再学習の試行を経て、これ以上の性能向上が見込めないと判断した場合、予測モデルを完成させ、最後に評価

データを用いモデルの予測性能を確定する。以上が大きな流れであるが、以下では具体的な検出方法、使用した教師データ、性能の評価指標などについて詳説する。

a) 検出方法

本システムでは、取付管と損傷3種の検出を物体検出にて行う。接合部は、検出対象がいずれも画像縦方向に長い線状であることから、矩形での抽出が困難と考えた。そこで展開画像を事前処理によって細分割し、各細分割画像を画像分類することで、接合の有無を検出する。

b) ネットワーク構成とハイパーパラメータ

本システムでは物体検出に、Faster R-CNN³⁾、画像分類にはResnet50⁴⁾を用いている。いずれも応用事例が豊富にあるネットワークである。転移学習およびデータ拡張手法を適用している。

c) 評価方法

検出した結果とラベルの対応に応じて、表-2に示す混同行列を用いて分類し、その集計結果から、(1)式、(2)式、(3)式を用いて評価をする。

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

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

$$\text{F-measure} = \frac{2 \cdot \text{recall} \cdot \text{precision}}{\text{recall} + \text{precision}} \quad (3)$$

なお、物体検出タスクの性能評価指標には、ラベルと予測結果の矩形面積の一致率に基づいたものも提案されているが、本システムの目的が点検前段階での抽出であり、面積の一致率を重視していないこと、損傷のような明確な境界が自明でない対象への適用に適さないことから採用していない。

(2) 検出性能

表-3に、評価データを用いて算出した性能を示す。管構造は、全ての項目において recall が90%以上を越えており、取り漏らしが少ない結果となった。Precisionも概ね90%以上であり、高い精度で検出できている結果となった。事前抽出の段階でほとんどの管構造の記録が済んでいるため、大幅な省力化が期待できる。

損傷は管構造と比較すると性能が低い結果となっている。recallは70%程度の性能が得られているものの、precisionは30~50%程度となっており、事前抽出結果の半分以上は、見直しが必要なものとなっている。中でも、コンクリート管の破損・クラックは、recallで43%、precisionで33.8%と最も低い結果となっており、事前抽出後も注意が必要な性能となっている。

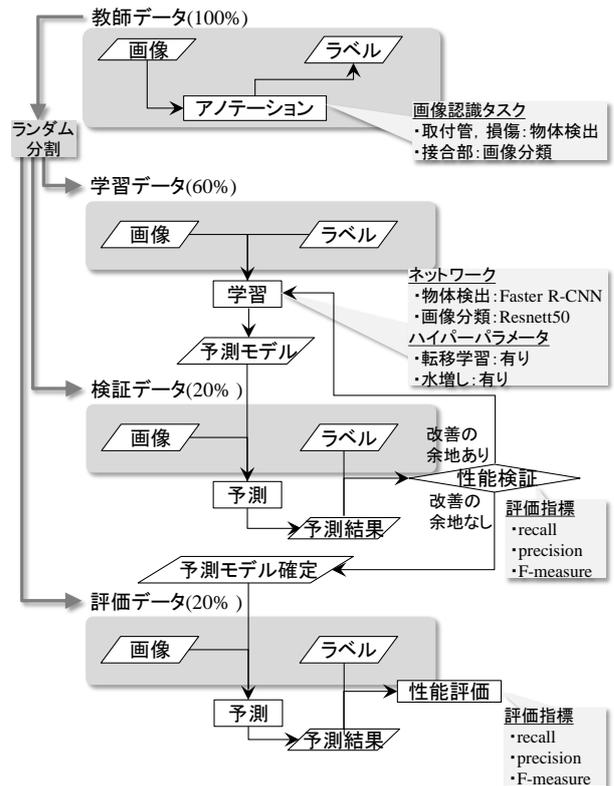


図-3 AI構築の流れ

表-2 性能評価方法 (混同行列)

予測結果 アノテーション ラベル	事象あり	事象なし
事象あり	TP: True Positive 	FN: False Negative
事象なし	FP: False Positive 	TN: True Negative

表-3 教師データと性能評価

	管構造		損傷		
	取付管	接合部	破損 クラック	侵入水	その他
教師データ					
コンクリート管					
学習データ	3,234	5,340	556	859	575
検証データ	989	1,781	221	307	220
評価データ	955	1,781	275	386	276
陶管					
学習データ	3,586	19,759	4,241	1,112	905
検証データ	1,297	6,584	1,404	382	330
評価データ	1,246	6,586	1,224	343	302
検出性能					
コンクリート管					
recall	98.9%	91.4%	43.1%	81.3%	69.0%
F-measure	94.8%	83.0%	37.9%	54.3%	47.1%
precision	91.1%	76.0%	33.8%	40.8%	35.7%
陶管					
recall	99.0%	97.7%	72.0%	89.7%	78.3%
F-measure	97.0%	97.5%	63.3%	65.7%	47.6%
precision	95.0%	97.4%	56.4%	51.8%	34.2%

(3) 性能の考察

図4に、コンクリート管と陶管の部位・損傷ごとの正しく検出できた事例 (TP) を示す。取付管、接合部は、特徴が少なく見た目にも判断しやすい画像であるが、損傷は、検出結果が幾重にも重なっているケースが多く、部位に比べ、特徴の境界が不明瞭であることがわかる。

図5には、損傷の未検出 (FN) , 誤検出 (FP) の事例を示す。破損・クラックは、画像全体に微細なクラックが走っている事例を検出できていない (1-a-i) 。また、表面の傷を、クラックとして誤検出している事例 (1-b-iv) も見られた。浸入水は、表面の汚れに似た微小の水の浸入を未検出 (2-a-i) , 浸入水に似た表面の汚れを誤検出している事例が多く合った (2-b-ii) 。その他侵入物では、木根の侵入をクラックとして判断した未検出例 (3-a-v) , その逆にクラックを木根の侵入とした誤検出例 (3-b-iii) 等もあった。損傷はアノテーションの段階で、調査員によって損傷判断の意見が分かれる事例も数多くあり、このような画像の複雑さが、学習の難しさの根本的な原因となっていると考えられる。

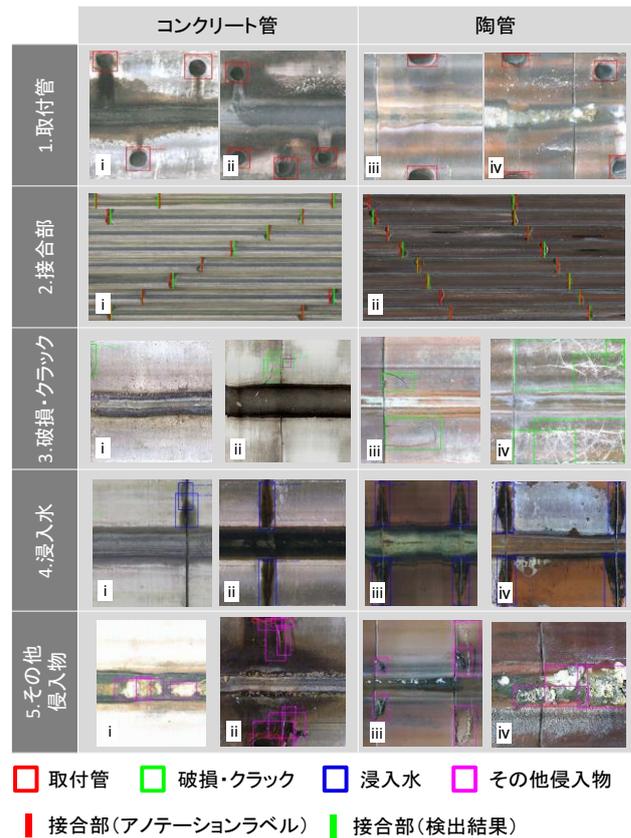


図4 正しく検出できた事例

4. まとめ

損傷については検出性能の向上、機能拡張に向け、管渠の調査済み画像を収集していくと共に、このほかの損傷 (取付管の接合不良や管渠のたるみ、腐食など) についても機能化を進めていく。長期的には点検業務自体の代替ができるよう損傷の程度 (ランク判定) も可能なシステムに拡張を予定している。

謝辞：本システムの開発に当たり、株式会社ジャストにご助力を頂いた。ここに記して感謝の意を表す。

参考文献

- 1) 国土交通省：維持管理情報等を起点としたマネジメントサイクル確立に向けたガイドライン (管路施設編) , <<https://www.mlit.go.jp/mizukokudo/sewage/content/001338706.pdf>>, (入手 2021.6.1) .
- 2) 国土技術政策総合研究所：スクリーニング調査を核とした管渠マネジメントシステム技術導入ガイドライン (案) , <<http://www.nilim.go.jp/lab/bcg/siryounn/tnn0876.htm>>, (入手 2021.6.1) .
- 3) Ren, S. et al. : Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks , <<https://arxiv.org/abs/1506.01497>>, (accessed 2021.6.1).
- 4) He, K. et al. : Deep Residual Learning for Image Recognition , <<https://arxiv.org/abs/1512.03385>>, (accessed 2021.6.1).

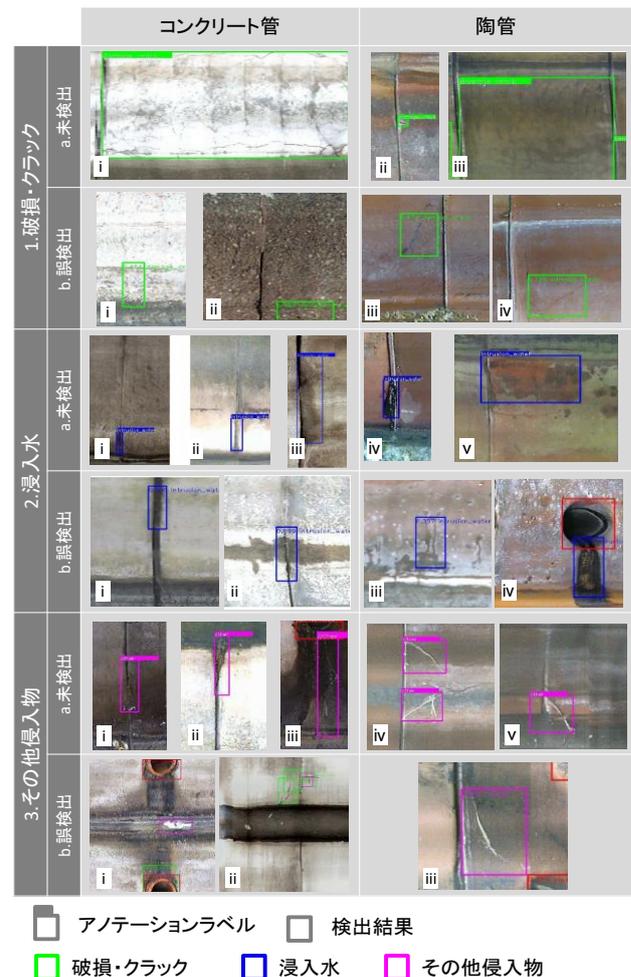


図5 損傷の未検出・誤検出事例