

# ディープラーニングを用いた 下水管渠点検情報検出システムの開発

## Development of Detection System Based on Deep Learning for Inspection Information of Sewer Pipes

岩下将也\* 山口 治\*\*

### 要 旨

下水道管渠の老朽化に伴い、その維持管理に求められる点検業務の範囲が拡大している。点検業務の効率化を図るため、展開広角カメラを利用した画像点検によって現地調査を省力化している。しかし、その結果、事務所内での画像の目視調査量が増大しており、目視調査をいかに迅速に行うかが課題となっている。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。検出性能を評価した結果、管内の取付管や接合部について 90%以上の性能で検出ができるようになった。また、AI による検出速度は、管渠延長約 30m に対し 15 秒程度であり、迅速な管構造と損傷検出が可能となった。

キーワード：下水道管渠、詳細調査、展開広角カメラ、管構造、損傷、ディープラーニング

### 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 km<sup>3</sup>あり、その多くは人が入れない内径 800mm 未満の小口径の管渠である。これらの管渠の点検業務では、専用のカメラを備えた自走する撮影機によって撮られ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いない。そのため、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かつ低コストとなる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、業務効率化を目的として下水管渠の点検情報の事前検出システムを構築した。本稿では、そのシステムの概要と性能について紹介する。

は多いものの、管の汚れなどがあるため、損傷の確実な判定は困難であり、軽度の損傷は視認対象とされないことが多い。

「詳細調査」では、管を事前に洗浄し、異常箇所とその程度を判定する。日進量はスクリーニング調査と比べて少なくなるものの、具体的な補修計画や長期的な維持修繕計画を検討する上では、詳細調査によってより確実な損傷の判定をしていく必要がある。

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。従来から行われている直視・側視カメラ調査は、首振り式のレンズを搭載したカメラ機器を地上の調査員が操作して管内を撮影し、現地でモニタリングしながら損傷を記録する。この方法は、損傷箇所ではカメラ機器を一時停止させる必要があるため、現地での作業時間が増加する点が課題となっていた。また、損傷の判定が現地の調査員の技術力に依存する点、現地に着任させる調査員の調整が必要な点など、マネジメントの観点からの課題もあった。

### 2. 下水管渠点検情報検出システムの概要

#### 2.1 既往の点検業務の種類と課題

下水管渠内部を点検する業務は、表-1に示す2種類がある。「スクリーニング調査」は、未洗浄の管から迅速に異常箇所を把握する。1日当たりの調査量（日進量）

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 

\*技術研究所環境研究グループ \*\*東日本支社リニューアル技術部

対して、展開広角カメラ調査は、現地撮影の合理化が図られた手法となっている。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、広角レンズを備えたカメラを入れ、管渠内部を等速で進みながら内部を撮影する。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、画像による目視調査を進めていく。

事務所内での目視調査では、展開画像から、まず管渠の取付管と接合部を確認し、それらを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を判定する。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ないことから、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。1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倍の効率化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、事務所内での画像目視の業務が溜まりやすくなる。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て、展開画像の目視業務の効率化が新たな課題となっている。

### 2.2 下水管渠点検情報検出システムの機能概要

下水管渠点検情報検出システム（以下、本システム）は、図-1の破線ルート（青色表示部分）で示すように、展開画像の目視調査の際に管構造と損傷を自動的に検出し、管構造、損傷の確認の際に、その検出結果を参照できる仕組みとなっている。

図-2に管構造の検出を例とした管理ソフトとの連携関係を、図-3に管理ソフトの画面に表示された事前検出結果を示す。これまで、調査員は画像点検時に管理ソフト上の画像表示機能と記録機能を用いて目視と記録を行ってきた。本システムは、管理ソフトのJPG画像出力機能を用い、展開画像のJPGデータをAIによって処理し、管構造、損傷のデータを事前検出する。検出結果を管理ソフトの記録情報として渡すことで、調査開始の段階でソフト画面にシステムが検出した記録情報が表示される。調査員は画面に表示された事前検出の結果を見ながら、調査を開始できるため、検出記録に損傷の判定結果等の追加情報を加え、検出結果を修正するなどして調査を進めることができ、従来の管理ソフトの操作性を踏襲した効率的な業務ができる仕組みとなっている。

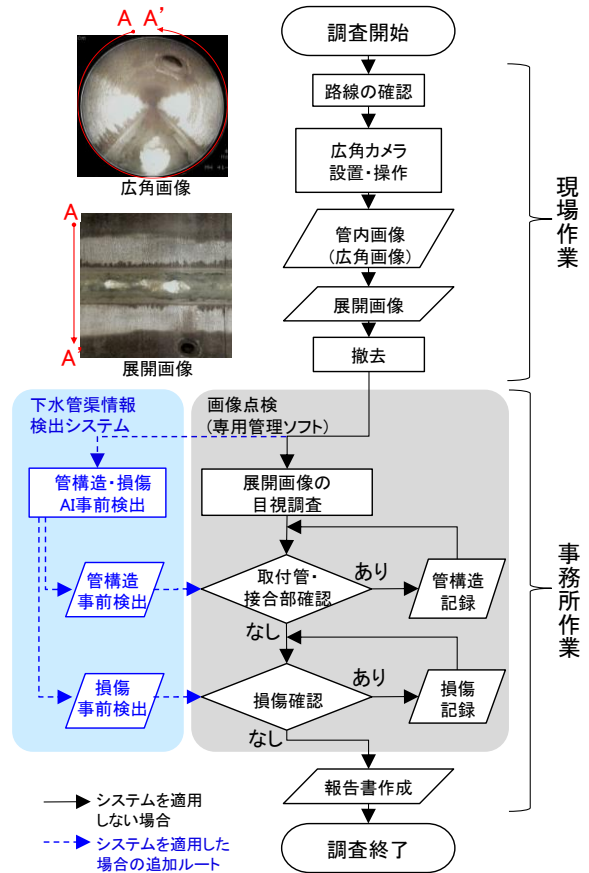


図-1 展開広角カメラ調査のワークフローとシステムの適用範囲

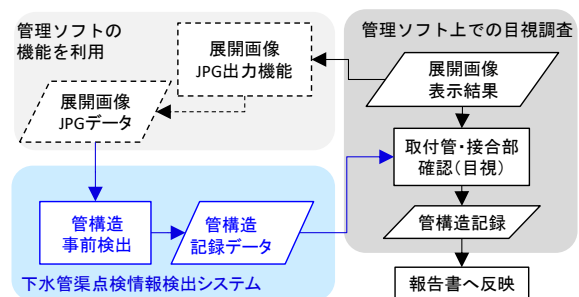


図-2 管理ソフトとの連携データフロー

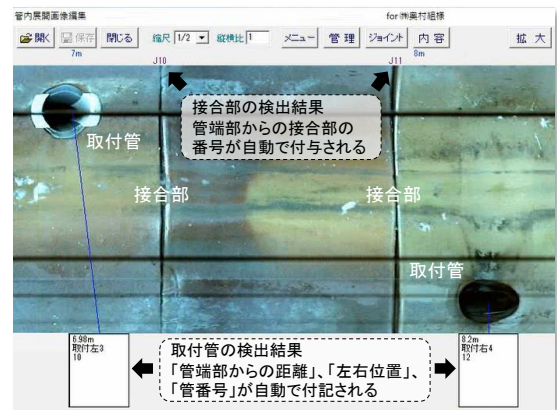


図-3 管理ソフト画面に表示された事前検出結果



図-4 展開画像上の検出対象

### 2.3 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-4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。管渠の損傷には、この他にも「腐食」、「たるみ」、「継手ズレ」、「取付管の突出し」、「油脂の付着」があるが<sup>2)</sup>、これらの損傷については、機能を拡張して今後、開発していく予定である。

## 3. システム構築とその性能

### 3.1 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-5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。

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、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。




図-5 予測モデルの学習と性能評価の流れ




図-6 画像認識タスクの種類<sup>3)</sup>

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てモデルの予測性能を確定する。

以上が大まかな流れであるが、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

画像認識技術は、図-6に示す3種のタスクに大別され、認識方法に応じてアノテーション作業が異なる。

「画像分類」では、画像の中に事象（図例の、犬、人、羊）があるかどうかを判断する。「物体検出」では、画像の中の事象を矩形で囲い、事象の種類と同時に位置を判断する。「セグメンテーション」では、画像の中の事象を画素ごとに判断し、事象の形状までを得る。画像分類 < 物体検出 < セグメンテーション、の順でアノテーション作業負担、検出時間が増えるため、対象に応じて必要十分な画像認識タスクを選ぶことが肝要である。

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あり、一定数があることから、展開画像を縦方向に長い画像に細分化し、それらの細分化画像を画像分類タスクとして検出し、検出の迅速化を図っている。

b. 教師データ

システム構築に使用した教師データのラベル数を表-2に示す(接合部は、細分化された画像の数を示している)。教師データの元となる画像は、下水道管渠の管理者である自治体からの承諾を受け、展開広角カメラ調査で実際に収集されたものであり、調査員の意見を踏まえながらアノテーションによってラベルを付加した。

c. ネットワーク構成とハイパーパラメータ

ディープラーニングによる画像認識では、画像情報(RGB情報の平面分布)をネットワーク状に伝播させ、ラベルの持つ特徴を抽出・分類する。このネットワーク構造によって予測性能が異なり、認識タスク別に様々なネットワークが用意されている。本システムでは物体検出に Faster R-CNN<sup>4)</sup>、画像分類には ResNet50<sup>5)</sup> を用いている。いずれも応用例が豊富にあるネットワークである。

さらに、検証段階での性能向上として、別の事象の学習をネットワークの一部で部分的に済ませる転移学習の有・無、学習データを画像変換してデータ量を増やすデータ拡張の有・無をパラメータとして、その有効性を検証した。転移学習、データ拡張はいずれも性能を向上させる結果となったことから、最終的な予測モデルにおいてもこれらの手法を採用している。

d. 評価方法

検出した結果とラベルの対応に応じて、表-3に示す混同行列を用いて評価する。展開画像内に部位・損傷のラベルと予測結果が存在する場合を TP、展開画像内に部位・損傷のラベルのみ存在し、予測結果が存在しない場合を FN、展開画像内に部位・損傷のラベルが存在せず、予測結果のみが存在する場合を FP、展開画像内に部位・損傷のラベルと予測結果が存在しない場合を TN として、各展開画像をこれらのいずれかに分類する。

分類された集計結果を元に、(1)式、(2)式、(3)式を用いて recall、precision、F 値を求める。

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

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

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

recall は再現率とも呼ばれ、予測結果にどれだけ取り漏らしが無いのか、その割合を示す。本システムの目的が

表-2 教師データのラベル数

	管構造		損傷		
	取付管	接合部	破損・クラック	侵入水	その他
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

表-3 混同行列の考え方

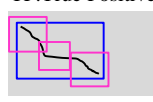

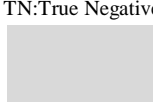
アノテーションラベル \ 予測結果	事象有り	事象無し
	事象有り	TP: True Positive 
事象無し	FP: False Positive 	TN: True Negative 

表-4 予測モデルの性能

	管構造		損傷		
	取付管	接合部	破損・クラック	侵入水	その他
コンクリート管					
recall	98.9%	91.4%	43.1%	81.3%	69.0%
precision	91.1%	76.0%	33.8%	40.8%	35.7%
F値	94.8%	83.0%	37.9%	54.3%	47.1%
陶管					
recall	99.0%	97.7%	72.0%	89.7%	78.3%
precision	95.0%	97.4%	56.4%	51.8%	34.2%
F値	97.0%	97.5%	63.3%	65.7%	47.6%

点検前の情報検出であることから、recall が高いことは特に重要である。precision は適合率とも呼ばれ、予測結果にどれだけ正しいものが含まれているか、その割合を示す。F 値は recall と precision の調和平均を取った総合評価指標であり、予測モデルの純粋な性能として参照する。いずれの指標も0~100%の範囲を取り、大きいほど性能が高くなる。

3.2 検出性能

表-4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%を越えており、取り漏らしが少ない結果となった。precision、F 値も概ね90%以上であり、高い性能で検出できている結果となった。事前検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。




図-7 教師データラベル数とF値の関係

一方、損傷については、管構造と比較すると性能が低い結果となっている。recall は概ね 70%程度の性能が得られているものの、precision は 30~55%程度となっており、事前検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、事前検出後も注意が必要な性能である。

### 3.3 性能の考察

図-7に、物体検出タスクにおける教師データのラベル数とF値の関係を示す。全体の傾向としてデータ数が多いほどF値が上がる傾向が見取れる。ただし、陶管における破損・クラック（青色白抜き○）の結果を見てわかるように、損傷については教師データ数が多くとも、管構造と同等の性能にはならない可能性が高い。理由として損傷が管構造と比べて画像が複雑であることが考えられる。

図-8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、特徴が明確で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-9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、全体に広がるよう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、1-a-ii）。また、表面が荒れた状態や線状の汚れを破損・クラックと誤検出している事例（1-b-i、1-b-ii）等が見られる。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（2-b-i、2-b-ii）や、取付管からの流水跡を誤検出している事例（2-b-iv）等があった。その他侵入物では、クラックを木根の侵入として誤検出した事例（3-b-ii）等が見られた。

損傷は目視調査する調査員によって判断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。

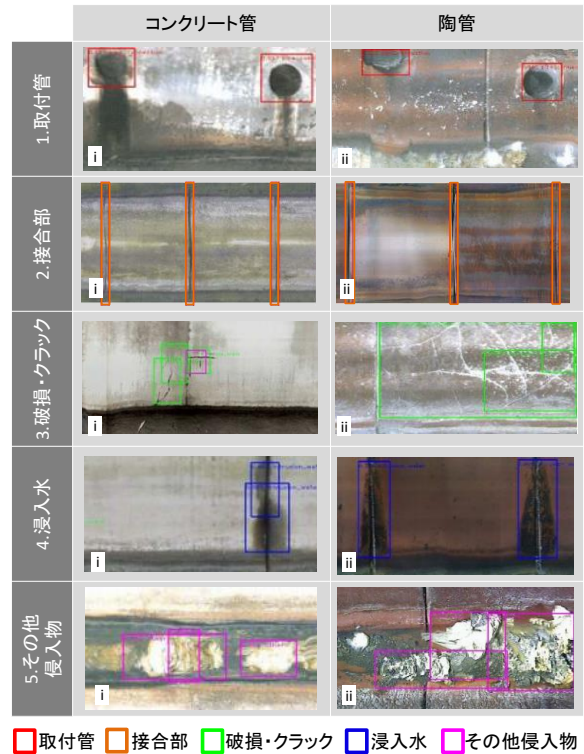


図-8 正しく検出できた事例

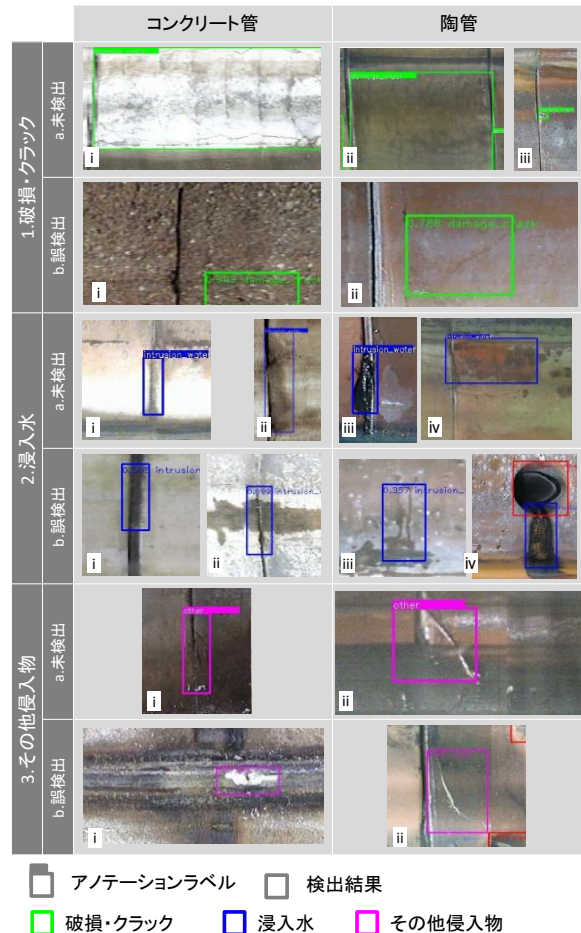


図-9 損傷の未検出・誤検出事例



図-10 検出時のシステム画面

### 3.4 検出速度

構築した AI をもとに、マンホール間の 1 スパン（約 30m）の管構造情報と損傷情報の検出を行ったところ、所要時間 15 秒であった。短時間で管構造と損傷を検出できるため、調査技術者はこれまでのように、全延長を網羅的に確認する必要がなく、作業量の軽減が見込める。

図-10 に、検出時のシステム画面を示す。検出の際は既往ソフトで静止画を出力し、その後、本システムでの操作は、管の登録だけでよく、後は図-2 のデータフローに即して検出・記録が行われるため、操作時間はほとんど発生しない。

### 4. まとめ

下水管渠の詳細調査の効率化を目的として、展開広角カメラに適用可能な点検情報の事前検出システムを開発した。本システムは以下の特長を備えたものとなっている。

- i. 管構造として、「取付管」、「接合部」の検出、損傷として「破損・クラック」、「浸入水」、「モルタル・木根の侵入」を検出できる
- ii. 点検業務をする上での既往の管理ソフトと連携した操作性の高いシステムとなっている

また、本システムの性能検証をした結果、以下の結果が得られた。

- i. 管構造の検出性能は非常に高く、画像上の取付管、接合部の recall 90%以上で検出できる
- ii. 損傷の検出性能は、管構造と比べると低下し、recall は 70%程度にとどまる
- iii. 検出速度は管渠 30m で 15 秒となっており、画像点検業務の事前情報検出システムとして業務効率化に寄与できる

### 5. あとがき

今後は、本システムを実際の業務に展開し、業務効率化の程度や新たな課題について確認していく予定である。また、損傷については、性能向上に向け、管渠の調査済み画像を収集していくとともに、この他の損傷（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。

下水道管渠の事後保全型維持管理から、予防保全型維持管理への転換に向け、本ソフトを活用した点検の効率化を進め、下水インフラ管理の基盤強化および機能維持に貢献していきたい。

#### 【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）」、2020
- 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）」、2015
- 3) Li Liu, Wanli Ouyang, et al, “Deep Learning for Generic Object Detection: A Survey”, International Journal of Computer Vision, 2020,
- 4) S. Ren. et al, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, arXiv, 2015
- 5) K.He. et al, “Deep Residual Learning for Image Recognition”, arXiv, 2016.