

# 物体検出を用いた下水管画像の自動異常検知

鈴木昌弘<sup>†</sup>, 小河誠巳<sup>†</sup>, 松本浩樹<sup>‡</sup>

東京電機大学理工学部情報システムデザイン学系<sup>†</sup>, 前橋工科大学工学部システム生体工学科<sup>‡</sup>

## 1 はじめに

近年, 多くの下水管の老朽化が進んでいる. 日本における下水道管路は約 48 万 km に及び, このうち標準耐用年数 50 年を経過した管渠の延長約 2.2 万 km (総延長の 5%) にもなる [1]. 老朽化した下水道管の調査, 修復が必要であるが, それを行う費用, 作業員がともに足りていない. 下水道管の異常検知は, 下水道管の中に入りカメラを持ちこみ撮影する. その映像を人が確認し 50 種類以上の項目にチェックをつけていく. 実際に作業をするときは, 映像を瞬時に判断し異常の種類を決めていくが, 人間の集中力には限界があり, 長時間の作業で判断が鈍り, 間違った項目にチェックを入れてしまうかもしれない. このようなことから本研究では, 近年目覚ましい発展を遂げている物体検出を用いて, 下水道管画像の自動異常検知について検討する.

## 2 研究目的

データの提供は株式会社フジビットサービスから得た. 現在「異常あり」「異常なし」の二値分類に限定した, 異常検知では高い精度を出すことが出来ている [4]. しかし下水道管の保全作業の問題解決には, 複数の異常を判別できる手法が求められている. そのため本研究では, 58 種類ある項目 15 種類 (表 1 参照) に整理し, 自動で異常検知をすることを目的とする.

## 3 関連研究

関連する研究として, 下水道管の老朽化予想に関する研究がある [2]. 下水道管上にある, 道路の陥没に着目し, 下水道の老朽化や異常と道路の陥没の関係を調べ, 下水道管の老朽化の予測をしていく研究である. また道路の破損をリアルタイムに検出する研究がある [3]. スマートフォンで道路を撮影し破損を検知, 外部のサーバーに画像を送信, 画像を教師データとして学習. そして学習したモデルをスマートフォンでの破損検知に生かすというサイクルを回し, 精度の向上と自治体ごとの維持管理の指針とする. この研究で YOLO と言われる技術が使用され, 精度向上に大きく貢献している.

## 4 物体検出手法




図 1: YOLO のモデル

本研究で使用した物体検出法は YOLOv5 である. YOLO は既存の R-CNN などの手法に比べ「検出」と「識別」を同時に行うことによって処理速度が優れている. YOLO を図 1 を使い説明する. 大きく分けて三つの工程があり, まず画像全体をグリッド分割する. そして図 1 の中央上は Bounding box (以下 BBox) の中に物体があるかを「検出」する. 中央下の工程はどのような物体が存在するのか「識別」の予測確率を求める. この三つを掛け合わせることで信頼度スコアを得ることができ, 物体検出を素早く行うことが出来る.

## 5 YOLO で用いる画像の加工方法



図 2: 下水道管の元画像 図 3: labeling 加工画像

YOLOv5 で学習させていくにはまず, YOLO に対応した画像の加工が必要になる. 本研究では labeling を使用し, 学習データ画像を作成する. labeling は物体検出のデータセットを作成するためのアノテーションツールであり PASCAL-VOC 形式 YOLO 形式 CreateML 形式に対応している. 図 2 の画像中央部にはクラック (亀裂) が存在する. これを図 3 のように囲う事によって YOLO で使用するデータセットを作ることが出来る.

## 6 YOLO を使用した実験内容

表 1: 下水道管画像

データ種類	枚数	分類の種類
学習データ	18200	15
評価データ	2015	15
テストデータ	2241	15

labeling を使用して作成したアノテーション画像を用いて学習を行う。データは 8435 枚ある。本研究ではラベルの中にある「異常なし」「判別不能」「仕上げ不良」の 3 つを取り除いた。理由は、この 3 つのラベルは、下水道管自体を特徴量としてしまい、異常があったとしても、この 3 つのラベルを間違えて検出してしまう。3 つのラベルを取り除いた画像の枚数は 5614 枚になった。Data Augmentation を行い、画像を 90 度ずつ回転させた画像を作成し、画像の枚数を 22456 枚に増やした。表 1 より、学習データ 18200 枚、評価データ 2015 枚、テストデータ 2241 枚に分けて学習を行った。学習の回数は 100epoch 行い、損失関数を確認しながら、過学習しない回数で学習を行った。

## 7 実験結果

学習モデルの精度を出すために mAP[6] を使用した。mAP は各ラベルの AP の平均を求めたものであり、AP は Precision と Recall で表す。この二つの指標には IoU が必要になる。IoU は「予測された BBox(以下 PBBox)」と「実際の BBox(以下 GBBox)」がどれだけ重なっているかを表す指標である。この IoU に閾値を設定する事で、Precision と Recall を表す事が出来る。Precision は全ての PBBox の数のうち、正しく ( $\text{IoU} \geq \text{閾値}$ ) で検出できた数であり、Recall は全ての GBBox の数のうち、正しく ( $\text{IoU} \geq \text{閾値}$ ) で検出できた数を表す。そして縦軸に Precision、横軸に Recall とし、積分を用いて表したものが AP となり、各ラベルの AP の平均を求めると mAP が導き出せる。




図 4: mAP グラフ

IoU の閾値を 0.5 とした。図 4 より mAP が 74 % となった。下水道管の「たるみ」や「油脂付着」では 85 %

以上の精度が出ており、「石灰乳」や「侵入水」では正解率が 50 % にとどまった。精度が出ていない理由として挙げられるのは、異常が物体ではなく、背景として YOLO が認識している可能性がある。YOLO は強みとして、背景の誤検出が少ない。精度が出なかった「石灰乳」は範囲が広いカメラの取り方によっては、画像の 90 % 以上を占めている。そのため「石灰乳」など精度が出ていない異常は、物体ではなく背景として扱われているため精度が出ていないと考えられる。

## 8 まとめと今後の課題

本研究では、15 種類に整理した下水道管の異常画像を YOLOv5 を使用して物体検出し、74 % の正解率で下水道管の異常を検知出来ることを確認した。今後の課題は、回転以外の Data Augmentation の検討、物体ではなく背景として扱われている異常画像に対して、アノテーションの段階で特徴量をどのように扱うかなどを試していく。

## 謝辞

本研究の一部は、東京電機大学総合研究所研究 Q21J-02(研究課題番号) として行ったものである。

## 参考文献

- [1] 水管理・国土保全局下水道部, 「下水道の維持管理」国土交通省, 2020.  
[https://www.mlit.go.jp/mizukokudo/sewerage/crd\\_sewerage\\_tk\\_000135.html](https://www.mlit.go.jp/mizukokudo/sewerage/crd_sewerage_tk_000135.html), (参照 2021-11-25).
- [2] 亀田瞬 他, 「下水道管の老朽化予測に関する研究」, 日本大学生産工学部第 43 回学術講演会 (2010-12-4), 2010.
- [3] 前田紘弥 他, 「機械学習とスマートフォンを用いた道路の損傷画像のリアルタイム検出と修繕対応基準における各特徴量の重要性比較」, 交通工学論文集第 4 巻第 3, 2018.
- [4] 吉江勇亮, 小河誠巳, 松本浩樹, 「CNN を用いた下水道管画像からの異常判定」, 第 33 回 信号処理シンポジウム, 2018.
- [5] colabratry 公式, 「YOLOv5 Tutorial」, 2021,  
<https://colab.research.google.com/github/ultralalytics/yolov5/blob/master/tutorial.ipynb>, (参照 2021-11-25).
- [6] Tsung-Yi Lin, et al., 「coco Evaluate」, 2021,  
<https://cocodataset.org/#detection-eval>, (参照 2021-11-25).