

深層学習を用いた下水道管渠内面の損傷抽出に関する性能評価

EVALUATION OF DAMAGE EXTRACTION ON THE INNER SURFACE OF SEWER PIPES USING DEEP LEARNING

菅田 大輔*・古木 宏和*・一言 正之*・山口 智**
Daisuke SUGETA, Hirokazu FURUKI, Masayuki HITOKOTO and Satoshi YAMAGUCHI

In this study, a deep learning model was constructed to extract damaged areas with the aim of improving the maintenance and management of sewer pipes. Since the training data was limited to approximately 80 low-resolution images, image processing was applied to the training data augmentation in order to improve accuracy. A case study was conducted to verify the accuracy and to evaluate the performance of damage extraction. In the future, this technique could be used to quantify the scale of damage, repair locations, and area calculations, although there is a margin of error.

Keywords : *deep learning, sewer pipe, semantic segmentation, DeepLabv3+, data augmentation*

1. はじめに

老朽化した下水道管渠の維持管理のため、我が国の自治体では下水道維持管理指針(実務編)¹⁾に基づく点検及び調査を行っている。しかし、少子高齢化に伴う点検技術者数の不足により、作業に時間を要している状況である。そのため、技術者の経験・目視に頼る損傷判定をいかに省力化するかが課題となっている。

こうした課題を解決する手段の1つとして、深層学習を用いた画像認識が考えられる。深層学習を用いた画像認識は大きく分けて、画像分類²⁾、物体検出³⁾、セマンティックセグメンテーションがある。

下水道管渠内面の損傷抽出に深層学習を適用した先行研究として、竹内らの事例⁴⁾がある。これは画像中の損傷を矩形単位で、検出することを可能にしている。しかしながら、幅や長さの異なる任意形状を有する損傷の度合ごとの抽出は課題としている。一方、セマンティックセグメンテーションでは、画像内の物体をピクセル単位で検出可能である。そのため、任意形状を有する損傷の抽出タスクを物体検出よりもきめ細かく実施できる可能性がある。

以上を踏まえ、本研究では、下水道管渠内面の損傷をセマンティックセグメンテーションにより抽出する深層学習モデルを構築した。深層学習モデル構築にあたって使用した学習データは損傷の種類やランク毎に数量が一定ではなく、画像枚数も十分とは言えない状況であった。そのため、本研究では

損傷の有無を抽出対象とした。また、限られた数の学習データで性能向上を図るべく、学習データに画像処理(左右反転、コントラスト調整等)を適用し、データ拡張を行った。そのうえで、構築した深層学習モデルごとに損傷抽出の性能を定量的且つ定性的に評価した。なお、損傷診断の対象とした管渠は、法定耐用年数の50年を超過している陶管とした。さらに、損傷の調査画像は多くの自治体に導入されており安価な直視カメラで取得できる画像データを対象とした。また、深層学習モデルには、DeepLabv3+⁵⁾を適用した。DeepLabv3+とは、大きさや間隔の異なる複数の特徴マップを使用することで、広範囲且つ局所的に画像の特徴を捉えることが可能なセマンティックセグメンテーション用のモデルである。

2. 検討条件の整理

(1) 使用データ

下水道管渠(陶管)のスクリーニング調査画像データ、詳細調査画像データを使用した。スクリーニング調査とは、管渠内面を清掃せずに損傷の有無を確認する調査である。また、詳細調査とは、管渠内面を清掃し損傷ランク(a~c または健全、2.(2)にて詳述)を確認する調査である。なお、使用した画像データは全て損傷を含むもので、画素数は372,945画素(横705×縦529)、画像枚数は140枚である。

(2) 抽出対象

下水道管渠内面(陶管)に発生する損傷には、管の破損及び軸方向クラック、管の円周方向クラックなどが存在する。

* コンサルティング事業統括本部 中央研究所 先端研究センター

** コンサルティング事業統括本部 流域水管理事業本部
水環境事業部 上下水道計画部

2.(1)の使用データ中にも、これらの事象が含まれている。また、下水道維持管理指針によれば、これらはクラックの長さの程度に応じて a～c でランク付けされる(a ランクの方が管渠の健全度が悪く、c ランクの方が健全度の良い状態を指す)。例えば、円周方向のクラックでその長さが円周の 2/3 以上であれば、管の円周方向クラックの損傷ランクは a となる。以上を踏まえ、損傷判定を省力化するためには、損傷の種類やランクまでを細かく抽出できることが望ましい。

しかしながら、本研究で用いた使用データは、損傷の種類やランク毎に数量が一定ではなく、画像枚数も十分とは言えない状況であった。そこで、本研究では、損傷の有無を抽出対象とした。なお、検証対象の陶管は呼び径が 200mm であり、継ぎ手と継ぎ手の間隔は 660mm のものである。

(3) アノテーション方法

使用データの損傷領域にアノテーションを付与した(図-1 参照)。アノテーションとは、画像データ中の任意領域に情報(損傷)を付与することである。なお、損傷の判読は診断技術者の目視で行い、アノテーション用ソフトウェアには labelme を用いた。

(4) モデル構造

本研究に用いた DeepLabv3+の設定内容を表-1 に示す。

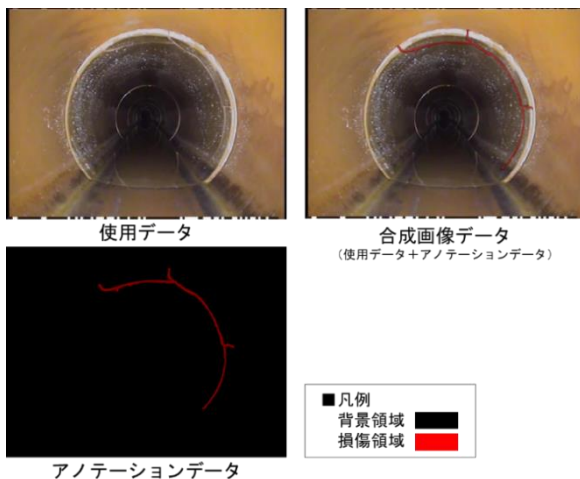


図-1 使用データに対するアノテーション付与のイメージ

表-1 DeepLabv3+の設定内容

項目	設定内容
バックボーンアーキテクチャ	resnet50
学習回数	700
出力スライド数	16
バッチサイズ	8
学習率	0.0001
クロップサイズ(正方形で規定)	256
評価頻度(n 学習に 1 回)	1

(5) 検討条件

検討条件を表-2 に示す。オリジナル画像のみ学習する検討条件 1 の他、抽出性能の向上を期待してデータ拡張を行った検討条件 2～6 を設定した。

1) 適用した画像処理とその理由

本研究では、左右反転、コントラスト低減及び強調、エンボス加工の計 4 種類のデータ拡張を取り上げた。

本研究で使用可能なデータ数は 140 と限りがあったため、データ拡張を行った。データ拡張に際し、選定した画像処理とその採用理由を次に示す。なお、画像処理を適用した画像のイメージは図-2 に示す通りである。

- 検討条件 2 の拡張画像は、左右反転とした。上下反転は、管路内の水面が画像上部に表示され、現実には存在しない画像となるため、生成していない。
- 検討条件 3 の拡張画像は、コントラスト低減を施した。検討条件 4 で採用したコントラスト強調とは異なる結果となるかを検証するためである。
- 検討条件 4 の拡張画像は、コントラスト強調を施した。オリジナル画像よりも明るさが増し、画像内のエッジ形状が強調される。これにより、オリジナル画像よりも損傷部位の視認性を高められる可能性があると考えた。なお、コントラスト強調にあたっては、アンシャープマスキング(鮮鋭化フィルタ)を適用し作成した。
- 検討条件 5 の拡張画像は、エンボス加工を施した。画像の凹凸を増し立体感を高めることで、損傷部位の輪郭線を強調できる。これにより、オリジナル画像よりも損傷部位の視認性を高められる可能性があると考えた。なお、エンボス加工に際しては、損傷部の輪郭線を強調しているエンボスフィルタを適用し作成した。
- 検討条件 6 は検討条件 2～5 の拡張画像を全て混在させたものである。単純なデータ量の水増しにより性能がいかほど高まるか確認したい狙いである。

表-2 検討条件

検討条件	画像枚数	分類
1	学習: 84 枚 検証: 28 枚 テスト: 28 枚	オリジナル画像
2～5	学習: 168 枚 検証: 56 枚 テスト: 56 枚	オリジナル画像 拡張画像(1 種類)
6	学習: 420 枚 検証: 140 枚 テスト: 140 枚	オリジナル画像 拡張画像(4 種類)

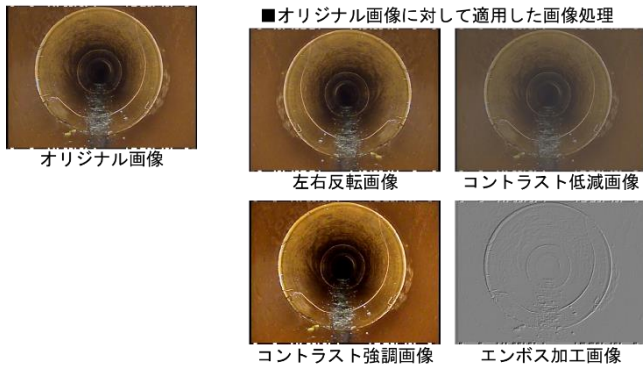


図-2 画像処理を適用した管渠画像(抜粋)

2) 学習及び推論の条件

検討条件 1 では、使用データの 8 割を学習データと検証データとし、4 分割交差検証を行った。残る 2 割はテストデータとした。また、画像処理の違いが推論性能にどのような影響を与えるか検証するため、テストデータを複製し、左右反転、コントラスト低減、コントラスト強調、エンボス加工による画像処理をそれぞれ適用した。

検討条件 2~5 では、検討条件 1 の学習データと検証データに加え、複製したデータ(検討条件 1 の学習データと検証データ)に画像処理を適用したデータをもとに、4 分割交差検証を行った。なお、適用した画像処理については 2.(5)1) に示す通りである。また、推論データは検討条件 1 で用意したものと同一である。

検討条件 6 では、検討条件 1 の学習データと検証データに加え、検討条件 2~5 で画像処理を適用したデータ(学習データと検証データ)を集約し、4 分割交差検証を行った。なお、推論データは検討条件 1 で用意したものと同一である。本節で述べた各種データの概要は次の通り。

- 学習データとは、損傷の特徴を深層学習モデルが学習するために用いるデータである。
- 検証データとは、学習時に深層学習モデルのハイパーパラメータを調整するために使うデータである。
- テストデータとは、学習後の深層学習モデルの汎化性能をテストするために用いるデータである。

3) 学習回数及び学習環境

学習回数は計算が収束する十分な回数として 700 回とした。検証データに対して最も損失値の小さいエポックの学習モデルで推論を行った。なお、学習に要した時間は、12th Gen Intel(R) Core(TM) i7-12700 2.10 GHz、NVIDIA GeForce RTX 3070、メモリ 32GB の計算機で、検討条件 1 の場合 1 時間程度、検討条件 2~5 の場合 2 時間程度、検討条件 6 の場合 6 時間程度であった。

3. 結果及び考察

(1) 評価指標に基づく推論器性能の整理

検討条件ごとの推論器の性能を表-3~表-8 に示す。表中の評価指標について、IoU (Intersection of Union) は、技術者判断による損傷領域と推論器が検出した損傷領域について、両者の共通領域を両者の和集合領域で除したものである。適合率は、損傷領域と検出した画素の内、正解データでも損傷領域である画素の割合を指す。また、再現率は、正解データの損傷領域である画素の内、検出結果においても損傷領域と判定した割合である。F 値は、適合率と再現率の調和平均を指す。また、推論器の性能は、交差検証で生成した 4 モデルの平均値としている。次に考察を示す。

1) 抽出性能の高い推論画像の種類

推論画像が正解画像を良く再現したのは、オリジナル画像もしくは左右反転画像であった。表-3~表-8 の塗りつぶし表現している推論画像が最も抽出性能の高かった画像種類である。当初は、コントラスト強調やエンボス加工の方が、オリジナル画像より損傷部の視認性を高められるため、抽出性能も高まるかと想定していたが、これらについては抽出性能に寄与しなかった。

以上より、画像の明るさがオリジナル画像と同じである、現実に存在しうる画像を入力の方が推論器の性能向上には寄与すると考えられる。

2) 推論性能の高いデータ拡張の種類

推論性能を高めるデータ拡張は左右反転であった。表-9 に、検討条件 1 の IoU を基準として、他の条件の IoU を整理した。表-9 の行は推論器への入力画像の種類である。表-9 において、抽出性能の高い推論画像の種類である、オリジナル画像と左右反転画像に着目すると、検討条件 2 の左右反転を適用したデータ拡張が優位であることが分かる。データ拡張により、現実に存在しうる(オリジナル画像と同じ明るさを有する)画像が学習データに含まれていること、オリジナル画像のみで学習した場合よりも学習データ数が増加していることが推論器の性能向上に寄与したものと考えられる。

表-3 検討条件 1 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	16.9%	24.7%	37.7%	27.8%
左右反転	17.1%	25.4%	37.5%	28.2%
コントラスト低減	16.4%	25.5%	33.1%	27.0%
コントラスト強調	15.4%	23.6%	34.5%	25.6%
エンボス加工	7.7%	13.6%	15.3%	13.4%

表-4 検討条件 2 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	17.5%	26.9%	36.5%	28.9%
左右反転	17.2%	26.4%	35.9%	28.1%
コントラスト低減	15.7%	25.2%	30.5%	25.9%
コントラスト強調	15.2%	25.9%	31.1%	25.5%
エンボス加工	7.6%	13.7%	16.2%	13.4%

表-5 検討条件 3 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	16.7%	27.6%	32.4%	27.4%
左右反転	17.1%	28.4%	31.8%	27.8%
コントラスト低減	16.6%	26.7%	33.4%	27.4%
コントラスト強調	15.8%	27.6%	30.3%	26.2%

表-6 検討条件 4 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	16.0%	25.6%	32.0%	26.4%
左右反転	16.3%	26.6%	32.0%	26.9%
コントラスト低減	15.3%	25.1%	31.2%	25.5%
コントラスト強調	16.0%	26.9%	30.5%	26.3%
エンボス加工	7.5%	14.1%	14.2%	13.2%

表-7 検討条件 5 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	15.4%	26.1%	30.5%	25.6%
左右反転	15.7%	26.1%	30.8%	25.9%
コントラスト低減	14.6%	26.5%	27.5%	24.2%
コントラスト強調	15.0%	25.0%	30.4%	25.0%
エンボス加工	13.8%	23.6%	27.8%	23.2%

表-8 検討条件 6 の推論器の性能

推論画像	IoU	適合率	再現率	F 値
オリジナル	15.6%	29.0%	27.5%	25.8%
左右反転	16.5%	30.2%	29.8%	27.0%
コントラスト低減	15.3%	28.7%	27.3%	25.4%
コントラスト強調	15.5%	28.7%	27.0%	25.5%
エンボス加工	13.8%	24.2%	26.0%	23.0%

表-9 検討条件ごとの IoU の比較

画像	条件 1	条件 2	条件 3	条件 4	条件 5	条件 6
オリジナル	0.0%	0.7%	-0.2%	-0.9%	-1.4%	-1.3%
左右反転	0.0%	0.1%	0.0%	-0.8%	-1.4%	-0.6%
コントラスト低減	0.0%	-0.7%	0.2%	-1.1%	-1.8%	-1.1%
コントラスト強調	0.0%	-0.2%	0.4%	0.6%	-0.4%	0.1%
エンボス加工	0.0%	-0.1%	0.6%	-0.2%	6.2%	6.1%

(2) 損傷位置の照合

前述までの検討で、入力画像は同じであっても、推論器の抽出性能は条件ごとに異なることを確認した。これにより、推論器ごとに抽出できる損傷の位置や長さにバラつきが生じている可能性がある。そこで、損傷位置の正解箇所と推論箇所を照合した。照合にあたって、テストデータを次の通り抽出した。

- 検討条件ごとに抽出性能の高い画像データと低い画像データを抽出した。

- 抽出した画像データのうち、IoU が最良の条件と最低の条件の差分値を取り、大きい順に並び替え、3 件ずつ画像データを抽出した。
- 推論器ごとに抽出できる損傷の位置や長さの比較を行うため、差分値の大きい画像データを抽出した。

1) 抽出性能の高い画像に関する考察

上位 3 位の画像データについて、損傷位置の照合を行った。具体的には、抽出性能が最も高かった推論器と最も低かった推論器の結果を照合した。照合結果を図-3～図-5 に示す。なお、正解画像と推論画像の赤く示された領域が損傷部位をそれぞれ示している。考察は以下の通り。

- 抽出性能の低い推論器であっても、損傷の全体形状を概ね抽出できていることが分かる。また、抽出できた損傷長さは、正解画像の損傷長さの約 5 割～6 割となった(表-10 参照)。なお、損傷長さの割合は、正解画像中の損傷の長さに対する推論画像中の損傷の長さの割合とした。また、表-10 の番号は図-3～図-5 の画像番号を示している。
- 抽出できた損傷幅は、2mm～2.5mm 程度であった。ただし、1mm に満たなく、人間でも判断に迷うような極めて小さな損傷(ヘアークラック)は抽出できていなかった。




図-3 上位画像の照合結果(画像番号 1)

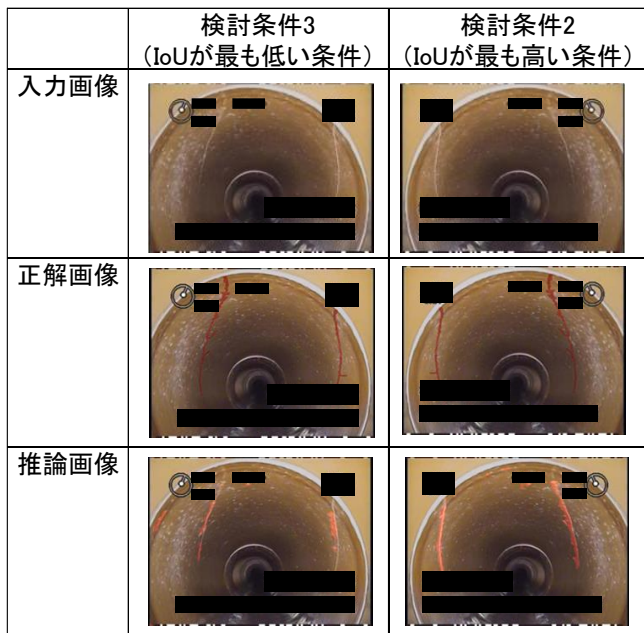


図-4 上位画像の照合結果(画像番号 2)

- 図-6 のケースでは、損傷幅が 6 ピクセルで構成されている場合、抽出できることが確認された。画像中の損傷幅の実スケールは約 1.8mm であるが、カメラの手前と奥で抽出できている領域が異なる。1 ピクセル単位の損傷長さは、手前が約 0.3mm/pix、奥が約 0.6mm/pix であった。抽出に必要な 1 ピクセル単位の損傷長さについては、本節 3) にて述べる。
- 図-7 のケースでは、損傷領域の大部分が破損しており目視による判断はしやすかったものの、深層学習モデルでは抽出できなかった。原因としては、破損を表す教師データ数が不足しているためと考えられる。
- 図-8 のケースでは、最良の推論器では損傷形状を概ね抽出できたものの、性能が低い推論器では水面付近の損傷領域の抽出ができなかった。エンボス加工によって、オリジナル画像よりも画像の明るさが低減したことで、水面付近の損傷の特徴を捉えづらくなったことが性能低下の原因と推察される。

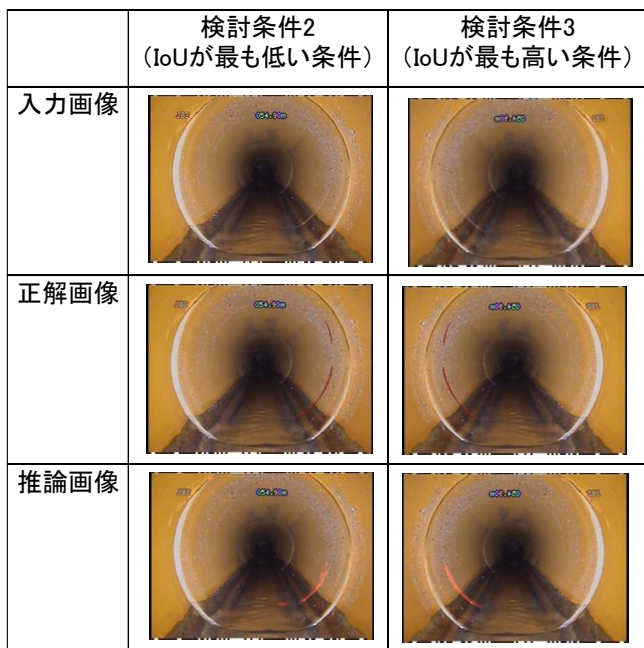


図-5 上位画像の照合結果(画像番号 3)

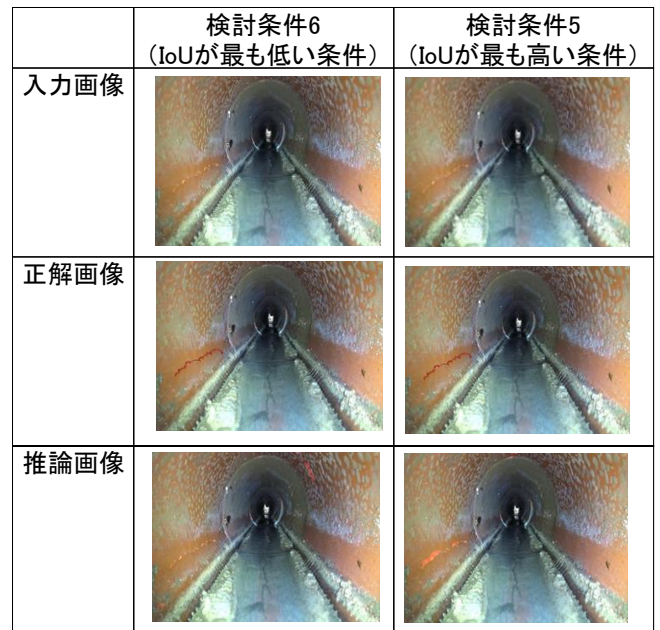


図-6 下位画像の照合結果(画像番号 4)

表-10 推論画像の損傷長さの整合率

画像番号	条件 1	条件 2	条件 3	条件 4	条件 5	条件 6
1	79.2%	60.2%	54.6%	68.5%	65.0%	66.2%
2	62.1%	43.2%	58.1%	53.6%	59.0%	62.1%
3	66.0%	74.4%	40.2%	53.1%	52.7%	65.0%
平均	69.1%	59.2%	51.0%	58.4%	58.9%	64.4%

2) 抽出性能の低い画像に関する考察

下位 3 位の画像データについて、損傷位置の照合を行った。照合結果を図-6~図-8 に示す。各画像の照合結果と考察は次に示す通りである。

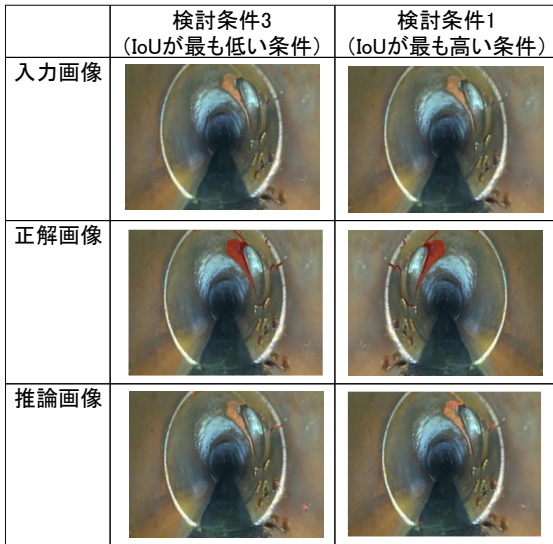


図-7 下位画像の照合結果(画像番号 5)




図-8 下位画像の照合結果(画像番号 6)

表-11 損傷を構成する画素数の整理

画像番号	損傷幅 (mm)	損傷規模 (mm/pix)	損傷を構成する 画素数
1	2.0	0.8	3
2	2.5	0.4	7
3	2.0	0.5	4
4	1.8	0.5	4
5	1.9	0.6	4
6	3.0	0.7	5

3) 1ピクセル単位の損傷長さ

損傷抽出の目安を定量化するため、損傷幅から1ピクセル単位の損傷長さを整理した(表-11)。なお、損傷の存在する管路断面に着目し、呼び径の実スケールと画素数を換算することで計算した。その結果、3~7ピクセルで損傷が表現されていれば抽出できる可能性が示唆された。なお、推論器で抽出することができなかったヘアークラックは、この画素数の条件を満たしていなかった。

4. おわりに

本論文では、下水道管渠内面の損傷抽出性能を評価するため、複数のデータ拡張を設定し、性能を比較した。その結果、以下の結論が得られた。

(1) 結論

推論性能の高い画像は、オリジナル画像もしくは左右反転画像であった。また、推論性能を高めるデータ拡張は左右反転であった。以上より、点検画像データの解像度が低く、且つ教師データ数が少ない場合でも、学習データの画像処理次第で、規模の大きな損傷は検出できる。これによって、技術者に委ねる判断のサポートツールになることが示唆された。なお、本論文での検証では、3~7ピクセル以上で損傷が表現されていれば抽出できる可能性がある。

(2) 今後の課題

本検討で構築した推論器は、ヘアークラックの抽出は困難であった。こうした損傷については、熟練の技術者であっても見落としてしまう可能性がある。そこで、微細な損傷を強調する超解像技術(VIS&TFC 技術)⁶⁾を用いて、学習データを事前に強調処理することによって、どの程度精度向上が見込まれるか検証を行う。

参考文献

- 1) 日本下水道協会:下水道維持管理指針(実務編)-2014-, 2014.
- 2) Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun : Deep Residual Learning for Image Recognition, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.
- 3) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi: You Only Look Once: Unified, Real-Time Object Detection, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 779-788, 2016.
- 4) 竹内大輔、野澤正裕、山岸洋明: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、第47回土木情報学シンポジウム、2022
- 5) Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F. and Adam, H.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, Proceedings of the European Conference on Computer Vision (ECCV), 2018.
- 6) 渡邊 大智、古木 宏和、宗像 俊、小島 尚人:コンクリート表面点検支援を目的とした画像特徴領域内外分類アルゴリズムの提案と実用化、土木学会論文集F3(土木情報学)、2021年77巻第2号、pp. 1-12