GAN による配管内画像を用いた異常検知

Anomaly detection from images in pipes using GAN

〇学 湯本 茂樹(中央大学) 橘
モロ アレサンドロ(中央大学) パ
中村 太郎(中央大学) 正 梅

橘川 拓実(中央大学)パトハック サーサク(中央大学)正 梅田 和昇(中央大学)

Shigeki YUMOTO, Chuo University, yumoto@sensor.mech.chuo-u.ac.jp Takumi KITSUKAWA, Chuo University Alessandro MORO, Chuo University Sarthak PATHAK, Chuo University Taro NAKAMURA, Chuo University Kazunori UMEDA, Chuo University,

In recent years, the number of pipes that have exceeded their service life is increasing. Therefore, earthworm-type robots have been developed to perform regularly inspections of sewage pipes. However, inspection methods have not yet been established. This paper proposes a method for anomaly detection from images in pipes using Generative Adversarial Network (GAN). A model that combines f-AnoGAN and Lightweight GAN is used to detect anomalies by taking the difference between input images and generated images. Subtraction images is used to estimate the location of anomalies. Experiments were conducted using actual images of cast iron pipes to confirm the effectiveness of the proposed method.

Key Words: Infrastructure Inspection, Sewer pipe, Deep learning, GAN, Anomaly detection

1. 序論

下水道は公衆衛生の向上や水質保全のために重要なインフ ラ施設である.しかし,耐用年数である 50 年を経過した下水 管は約 2.2 万 km に達しており,これらは年々増加の一途をた どっている[1].クラックからの侵入水や硫化水素による管路 の腐食による老朽化は道路の陥没を引き起こす要因となる. 令和元年度には全国で約 2900 件の道路陥没事故が報告されて いる[1].このような陥没事故を未然に防ぐためには,配管の 内部を検査する必要がある.そのため図 1 のような配管検査 のためのミミズ型ロボットの開発や検査手法の検討が行われ ている[2].

本論文では、検査対象として下水管全体の 5~10%を占める 圧送管に着目する. 圧送管とは、ポンプにより下水を輸送す る下水管であり、従来の下水管と比べて地形の制限を受けに くく、比較的自由に管路を設定できる[3]. そのため検査手法 が確立されていない. また圧送管は材質によって生じる欠陥 が異なる. 塩化ビニル管は土圧によって変形し、鋳鉄管は管 内面に錆が付着する. これらの欠陥を画像から検出し、位置 を求める必要がある.

近年,深層学習の発展に伴い,工業製品の欠陥検査などの 異常検知分野への研究が盛んに行われている[4].一般的に異 常検知において,異常データは正常データと比較して非常に 少なく,教師あり学習を行うことは困難である.そのため正 常データのみを用いる教師なし学習を行い正常の分布から逸 脱したものを異常とする手法がよく用いられる.配管内部の 検査においても欠陥箇所を異常とした異常検知問題として解 決することが有効であると考えられる.大山ら[5]は Variational AutoEncoder(VAE)[6]と Residual Network (ResNet)[7]を用いて 配管内の異常検知を行う手法を提案した.しかし VAE には生 成画像がぼやけるという欠点がある.そのため異常箇所の推 定には至っていない.また,錆を模した自作データセットで 実験を行っており,実際の鋳鉄管画像による検証を行ってい ない.

本論文では,圧送管の中でも鋳鉄管の異常な錆の検出および異常箇所の推定を目的とする.具体的には深層学習の生成

モデルである Generative Adversarial Network (GAN)[8]を用いる. GAN の異常検知手法の一つである f-AnoGAN[9]と画像生成の モデルである Lightweight GAN[10]を組み合わせることで異常 検知と異常箇所の推定を行う.実際の鋳鉄管画像を用いた検 証により,有効性を確認する.



Fig.1 Earthworm Robot [2]



本論文の提案手法の流れを図 2 に示す. ミミズ型ロボット が撮影した画像のうち正常画像のみを GAN に学習させる. 次 に GAN のパラメータを固定して,同じく正常画像のみを Encoder に学習させる. 学習したモデルを用いて画像を生成 し,入力画像との差分をとる. 差分が小さい場合は正常,差 分が大きい場合は異常と判定する. 異常と判定された場合は 差分画像から異常箇所の推定を行う.

2.2 提案モデル

本論文では、f-AnoGAN と Lightweight GAN を組み合わせ たモデルを用いる.提案モデルを図 3 に示す.f-AnoGAN と は GAN を用いた異常検知手法の一つである.GAN には入力 を再構成する仕組みが存在しないが、Encoder を導入するこ とで異常検知を可能にしたモデルである.f-AnoGAN には WGAN[10]を用いられているが、学習に時間がかかるという 欠点がある.そこで WGAN の代わりに Lightweight GAN を 用いる.Lightweight GAN とは Generator に Skip-layer channel-wise Excitation module, Self supervised Discriminator を導入することで少量のデータ、短時間の学習 で高品質の画像を生成可能なモデルである.画像生成により 特化したモデルを用いることで、差分画像から細かい異常箇 所の推定の推定が可能になると考えられる.また、少量のデ ータでの学習に強くなることが期待される.Encoder には f-AnoGAN と同じく4層の ResNet を用いる.



2.3 異常度の算出

異常度の計算は入力画像と生成画像の差分を計算し,差分 画像の全画素の画素値を合計することで行う.求めた異常度 に対して閾値を設定することで正常か異常かを判断する.

3. 実験

3.1 実験概要

提案手法を用いて,実際の鋳鉄管画像に対して異常検知お よび異常箇所の推定実験を行った.学習データは実地鋳鉄管 正常画像約2200枚,新品鋳鉄管正常画像約2200枚の合計約 4400枚とした.学習データの例を図4,5に示す.テストデ ータは実地鋳鉄管正常画像50枚,新品鋳鉄管正常画像50枚, 実地鋳鉄管異常画像100枚の合計200枚とした.テストデー タの異常画像の例を図6に示す.学習データ,テストデータ の画素数はいずれも256×256にリサイズした.

評価方法には、AUROC(Area Under Receiver Operating Characteristic)を用いる. AUROC とは ROC 曲線が囲う下側 の面積の大きさである. 0 から1までの値を取り、1 に近づく ほどモデルの性能が良いことを表す. AUROC で評価を行う ため、異常度の閾値は設定しない.

GAN の iteration 数は 50000, batch size は 8 とした. Encoder の epoch 数は 500, batch size は 16 とした.



Fig.4 Image example (normal cast iron pipe)



Fig.5 Image example (normal new cast iron pipe)



Fig.6 Image example (anomaly cast iron pipe)

3.2 実験結果

実験結果を図7,8,9に、異常度のヒストグラムを図10に 示す.図7,8,9は左から入力画像,生成画像,差分画像と なっている.差分画像は色が青いほど差分の値が小さく,赤 いほど差分の値が大きいことを表す.図7は実地鋳鉄管正常 画像,図8は新品鋳鉄管正常画像,図9は実地鋳鉄管異常画 像に対する結果である.図10の異常度のヒストグラムは青の 分布は正常データ,オレンジの分布は異常データを表す. AUROCは0.986であった.

AUROC が 0.986 と高い値であったことから, テストデー タに対する異常検知は可能であると考えられる.

図7,8の正常鋳鉄管の生成画像を見ると、どちらも入力画 像に似た画像を生成している.このことから、新品と実地の どちらの正常画像が入力されても正常と判断可能であると考 えられる.

図 9 の異常鋳鉄管の生成画像を見ると、入力画像の異常箇 所が無いような画像を生成している. 差分画像を見ると、異 常箇所である白い箇所が赤くなっている. このことから異常 箇所の推定が可能であると考えられる.

図 10 の異常度のヒストグラムを見ると,正常と異常の分布 がある程度分かれている.一方で,一部分布が重なっている 箇所がある.これは一部の生成画像を正しく生成できなかっ たからである.原因としては Encoder の batch size が小さく, 特徴抽出がうまくできなかったことが考えられる.



Fig.7 Experimental results (normal cast iron pipe)





Subtraction image

Input image Generated image Fig.8 Experimental results (normal new cast iron pipe)







Generated image Input image Subtraction image Fig.9 Experimental results (anomaly cast iron pipe)



Fig.10 Histogram of anomaly score

4. 結論

本論文では、GAN を用いた配管内の異常検知手法を提案し た. f-AnoGAN と Lightweight GAN を組み合わせたモデルに 正常画像のみを学習させ、入力画像と生成画像の差分を取る ことで異常検知を行い、差分画像から異常箇所の推定を行う. 実際の鋳鉄管画像に対して実験を行い、AUROC が 0.986 と 高い値を示し、提案手法の有効性を確認した.

今後の展望として、より正しい正常画像を生成できるよう にモデルを改良することが考えられる.

謝辞

本研究の一部は国土交通省下水道応用研究プロジェクトの 資金によって実施された.

≹考文献

- https://www.mlit.go.jp/mizukokudo/sewerage/crd_sewerage_tk_0001 [1] 35.html
- Hiroto Sato, Yuki Mano, Fumio Ito, Takumi Yasui, Manabu Okui, [2] Rie Nishihama and Taro Nakamura, "Proposal for Pipeline-Shape Measurement Method Based on Highly Accurate Pipeline Length Measurement by IMU Sensor Using Peristaltic Motion Characteristics," Proc. of AIM, 2020.
- http://assouken.gr.jp/tokutyo.html [3]
- 立花亮介,松原崇,上原邦昭,"深層生成モデルによる非正 則 [4] 化異常を用いた工業製品の異常検知",第32回人工知能学会全 国大会論文集, 2018.
- 大山暁,佐藤広都,小菅海人,内山航輔,中村太郎,梅田和昇, "VAE を用いた配管内画像からの錆の検出," DIA2021 動的画 [5] 像処理実利用化ワークショップ, IS1-7, 2021.
- [6] Diederik P. Kingma and Max Welling, "Auto-Encoding Variational Bayes," Proc. of ICLR, 2014.
- [7] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, "Deep Residual Learning for Image Recognition,' Proc. Of CVPR, 2016.
- Ian Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. [8] Warde-Farley, S. Ozair, A. Courville and Y. Bengio, "Generative Adversarial Networks," NeurIPS, 2014.
- [9] Thomas Schlegla, Philipp Seebock, Sebastian M. Waldstein, Georg Langsa and Ursula Schmidt-Erfurth, "f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks," Medical image analysis, 2019, pp. 30-45. M. Arjovsky, Soumith Chintala and Léon Bottou, "Wasserstein
- [10] GAN." arXiv preprint arXiv:1701.07875, 2017.
- Bingchen Liu, Yizhe Zhu, Kunpeng Song and Ahmed Elgammal, [11] "Faster and Stabilized GAN Training for High-fidelity Few-shot Image Synthesis," arXiv:2101.04775v1 [cs.CV] 12 Jan 2021.