

深層学習を用いた配管内画像からの欠陥箇所の検出 Detection of Defects from Images in Pipes Using Deep Learning

精密工学専攻 11号 大山暁
Akira Oyama

1. 序論

下水管は環境保全・衛生維持のための重要な役割を果たすインフラである。しかし近年、その耐用年数である 50 年を経過した配管（老朽管）が増加している。このような管は、漏水や道路陥没などに代表される重大な事故の原因となるため、下水管内の定期的な検査が必要となっている。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が行われている[1][2]。このロボットは頭部にカメラを搭載しており、下水管内の映像を取得することができる。

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。圧送管は従来の下水管に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こともあり、その検査はその検査手法が確立されていない。また、圧送管はその材質によって生じる欠陥が異なり、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。この変形や錆を画像から検出し、その画像上の位置を求める必要がある。

近年の深層学習の発展に伴い、工業製品の検査などの異常検知分野への実用化が活発に進められている[3][4]。異常検知問題では、異常データは正常データに比べてその数が非常に少ないため、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た教師なし学習を行い、正常から逸脱したものを異常とみなす手法がよく用いられる。したがって、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。

以上より、本論文では映像を用いた圧送管内の鋳鉄管に付着した錆の検知に着目し、深層学習のモデルである Variational AutoEncoder (VAE) [5]を用いる。この VAE を用いて異常検知を行うことで錆の検出を行う。また、Residual Network(ResNet)[6]を用いて異常箇所の推定も行う。

2. 提案手法

2.1 提案手法概要

本論文の提案手法の流れは以下のとおりである。まず初めに、ミミズ型ロボットが撮影した画像のうち正常画像(錆のない画像)を VAE で学習する。次に、学習した VAE を用いて入力画像の異常度を表すスコアを計算し、異常検知を行う。また、VAE の入力画像と出力画像それぞれを ResNet に入力し、中間層を抽出することで異常箇所の推定を行う。



Fig.1 Earthworm Robot[1][2]

VAE で異常検知を行う際には異常画像に対する再構成が崩れてしまい、画像上のどこが異常箇所なのかわからなくなってしまうことがある。そのため、VAE のみならず ResNet を用いて異常箇所の検出を行う。

2.2 VAE を用いた錆の検知

本論文では、VAE を用いて配管内部に付着した錆の検知を行う。VAE は図 2 のように通常の AutoEncoder(AE)にベイズ推論の枠組みを取り入れたネットワークである[5]。

AE は、入力画像を表す特徴(潜在変数)を Encoder によって次元削減することで取得し、その潜在変数を用いて Decoder によって入力画像を復元するニューラルネットワークである。これに対して VAE は、Encoder によって取得した潜在変数に確率分布を仮定することで潜在変数の平均や分散を出力する。この平均と分散を用いて Decoder によって画像の復元を行う。

本論文では入力画像と VAE で得られた出力画像との差分を取ることで異常検知を行う。




Fig.2 Variational AutoEncoder

2.3 ResNet を用いた異常箇所推定

本論文では ResNet を用いて異常箇所の推定を行う。ResNet は図 3 に示すモデル構造をしており、層が非常に深いことが特徴の一般物体認識用の畳み込みニューラルネットワークである[6]。一般的にニューラルネットワークは層が深いほど精度が高くなるが、極端に多層化した際には、微分の積が小さくなりすぎてしまい、勾配消失問題が発生してしまう。ResNet は入力のショートカットを設けて従来の出力との残差を計算することでこの勾配消失問題を解消し、非常に深いニューラルネットワークを効率的に学習できるようにしたモデルである。

本論文では、VAE の入力画像と出力画像のそれぞれを学習済みの 50 層の ResNet である ResNet50 に入力し、それぞれの中間層の 1 層目を抽出する。そして、入力と出力の中間層の差分を取ることで異常箇所の推定を行う。

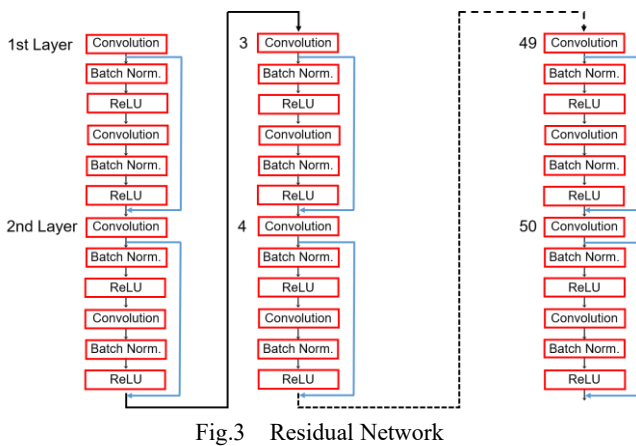


Fig.3 Residual Network

3. 配管内部の錆を模したデータの作成

異常検知のための学習及び実験を行うには圧送管内の画像が必要となるが、圧送管内のデータを収集することは現時点では難しい。そこで本研究では、圧送管を模した 2 種類のデータを作成し、現在撮影できている約 10 分の圧送管内の動画と併せて実験に用いる。

1 種類目は、市販の塩化ビニル管の内面に様々な色の丸いシールを張り付けたデータである(データセット A とする)。シールの貼ってある箇所を異常、張ってない箇所を正常とする。作成したデータの例を図 4、図 5 に示す。正常データは模様のない管のため比較的異常検知を行いやすいと考えられる。

2 種類目は、透明なパイプに新聞紙を巻き付けてその上にシールを貼ったデータである(データセット B とする)。こちらもデータセット A と同じくシールの貼ってある箇所を異常、張ってない箇所を正常とする。作成したデータの例を図 6、図 7 に示す。1 種類目と比べて模様が複雑であり、異常検知の難易度としては高いと考えられる。

最後に、圧送管内の実データをデータセット C とする。ただし、このデータセットには鑄鉄管は存在せず、具体的な欠陥箇所や欠陥がするかどうか不明であるため、管同士の繋ぎ目や横穴などを欠陥と見なして実験を行う。また、正常データは繋ぎ目や横穴のないデータとしている。正常データ例と異常データ例を図 8、9 に示す。




Fig.4 Image example (Dataset A, normal data)




Fig.5 Image example (Dataset A, anomaly data)




Fig.6 Image example (Dataset B, normal data)

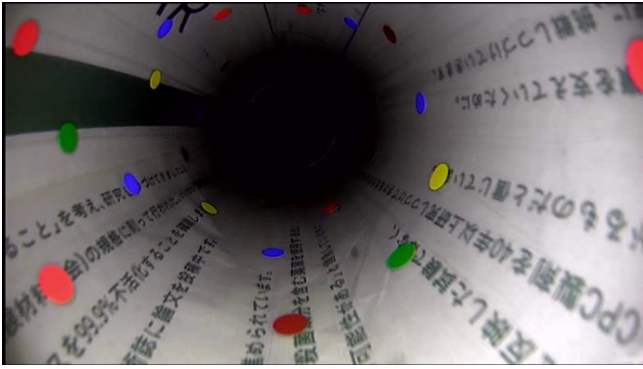


Fig.7 Image example (Dataset B, anomaly data)




Fig.8 Image example (Dataset C, normal data)



Fig.9 Example image (Dataset C, anomaly data (seams are considered anomaly))

4. 異常検知および異常箇所推定実験

4.1 実験概要

上記の提案手法を用いて配管内の異常検知および異常箇所推定実験を行った。データは3章で述べた3種類のデータセットをそれぞれ用いて実験を行う。学習データの数はデータセット A は約 3000 枚、データセット B は約 10000 枚、データセット C は約 18000 枚であり、それぞれエポック数を

30 と 10 とした。潜在変数の次元は 32 次元とし、バッチサイズはデータセット A は 16、データセット B, C は 32 とした。また、ResNet50 は Pytorch[7]の学習済みモデルを用いた。損失関数は以下の(1)式を用い、最適化には Adam[8]を用いた。

$$L_{total} = L_{recon} + L_{KL} \quad (1)$$

$$L_{recon} = \sum \{-p \log q - (1-p) \log(1-q)\} \quad (2)$$

$$L_{KL} = \frac{1}{2} \sum (-2\sigma + \mu^2 + \sigma^2 - 1) \quad (3)$$

L_{total} : 損失関数, L_{recon} : 再構成損失, L_{KL} : KL ダイバージェンス, p : 入力画像の画素値, q : 出力画像の画素値, μ : 潜在変数の平均ベクトル, σ : 潜在変数の標準偏差ベクトル

4.2 実験結果

VAE の入力画像, 出力画像, その差分, および ResNet50 による異常箇所推定の実験結果を以下の図 10, 11, 12 にそれぞれ示す。画像は1段目から順に, 入力画像, 出力画像, 差分画像, ResNet の中間層である。差分画像と ResNet の中間層は, 色が青いほどその値が小さく, 赤に近づくほどその値が高い。また, 差分画像の画素値の合計で計算した異常度 (score) を表 1, 2, 3 に示す。表 1, 2, 3 の番号は図 10, 11, 12 の左から数えた番号である。

図 10 を見ると, 左から 1, 3, 4 番目の画像の VAE の再構成が特に崩れている画像が存在するのが分かる。表 1 を見てもこの 3 枚の異常度は高くなっている。これは学習データが足りない, もしくはハイパーパラメータの調整が足りないためだと考えられる。しかし ResNet の中間層を見てみると, VAE の再構成が崩れてしまっている場合であってもシールを貼った箇所を赤く強調している。このため, ResNet の中間層を用いて異常箇所推定を行うことは可能だと考えられる。

図 11 を見てみると, 1, 2, 3, 8 番目の正常データの場合の入力と出力の差分画像が全体的に青くなっていることが分かる。また, 4, 5, 6, 7 番目の画像の差分画像を見てみるとシールの貼ってある箇所付近の再構成が崩れているため赤く強調されているのが分かる。このことから, VAE の学習はデータセット A と比べるとよく出来ていると考えられる。これはデータセット B はデータセット A に比べて学習データの数が豊富なためだと考えられる。さらに, ResNet の中間層の抽出結果を見ると, シールを貼りつけた箇所を赤く表示しているが, 5 番や 7 番の画像のように一部誤判別している箇所や強調できていない箇所があることが分かる。これは VAE の再構成が崩れてしまっている箇所が存在しているためだと考えられる。また, 7 番のようにシールがカメラから遠い箇所にあると暗くなってしまうため暗い色のシールだと判別しにくいと考えられる。

図 12 を見ると, 学習データの数が豊富なため VAE の再構成が比較的良好な結果となった。表 3 を見ると異常データの最小 score は 195, 正常データの最大 score は 173 であるた

め、しきい値処理によって異常か正常化の判別は可能であると考えられる。




Fig.10 Experimental results of VAE and ResNet (Dataset A)

Table 1 Anomaly score (Dataset A)

Number	1	2	3	4
score	654	269	760	796
Number	5	6	7	8
score	294	285	304	273




Fig.11 Experimental results of VAE and ResNet (Dataset B)

Table 2 Anomaly score (Dataset B)

Number	1	2	3	4
score	172	145	118	435
Number	5	6	7	8
score	364	325	179	137




Fig.12 Experimental results of VAE and ResNet (Dataset C)

Table 3 Anomaly score (Dataset C)

Number	1	2	3	4
score	195	122	270	162
Number	5	6	7	8
score	418	173	135	238

5. 結論

本論文では、配管内部に付着した錆の検出およびその位置の推定手法を提案した。VAEの入力画像と出力画像の差分を取ることで異常検知を行い、ResNet50を用いて異常箇所の推定を行った。今後の展望は、より現実の圧送管の錆に近いデータを作成し実験を行うこと、異常検知および異常箇所推定の精度をより高めていくことである。

参考文献

- [1] Yuki Mano et al.: “Development of High-speed Type Peristaltic Crawling Robot for Long-distance and Complex-line Sewer Pipe Inspection,” Proc. of IROS, 2018.
- [2] Hiroto Sato et al.: “Proposal for Pipeline-Shape Measurement Method Based on Highly Accurate Pipeline Length Measurement by IMU Sensor Using Peristaltic Motion Characteristics,” Proc. of AIM, 2020.
- [3] Yaxiang Fan, et al.: “Video Anomaly Detection and Localization via Gaussian Mixture Fully Convolutional Variational Autoencoder,” arXiv, 2018.
- [4] 立花亮介ら, “深層生成モデルによる非正規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
- [5] Diederik P. Kingma et al.: “Auto-Encoding Variational Bayes,” Proc. of ICLR, 2014.
- [6] Kaiming He et al.: “Deep Residual Learning for Image Recognition,” Proc. of CVPR, 2016
- [7] Adam Paszke et al.: “Pytorch: An Imperative Style, High-Performance Deep Learning Library,” Proc. of NeurIPS, pp.8024-8035, 2019.
- [8] Diederik P. Kingma et al.: “Adam :A Method for Stochastic Optimization,” arXiv, 2015.