VAE を用いた配管内画像からの錆の検出

○ 大山曉†, 佐藤広都†, 小菅海人:, 内山航輔:, 中村太郎:, 梅田和昇:

○ Akira OYAMA[†], Hiroto SATO[†], Kaito KOSUGE[‡], Kosuke UCHIYAMA[‡],

Taro NAKAMURA[‡], Kazunori UMEDA[‡]

<要約> 本論文では、深層学習を用いて配管内部に存在する錆の検知を行う手法を提案する.近年、耐用 年数を経過した配管が増加しており、下水管の定期的な検査が必要とされている.教師なし学習のモデルで ある Variational Auto-Encoder を用い、入力画像と出力画像の差分を取ることで異常検知を行う.また、学習 済みの ResNet を用いて異常箇所の推定を行う.

<キーワード> 下水管, 深層学習, VAE, ResNet, 異常検知

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 路を設定できるため,圧送管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



図1 ミミズ型ロボット[1]

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.

以上のことを受けて、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]を用いた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.

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 は以下の図 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.



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 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.



図 3 : ResNet50 の構造

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 送管内部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). 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 め比較的に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).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鋳鉄管は 存在せず、具体的な欠陥箇所や欠陥がするかどう かも不明であるため、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.正常データ例と異 常データ例を図 8,9 に示す.

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 種類のデータをそれぞれ用いた実験を行う.学習 データの数はデータセット A, B ともに約 3000 枚, データセット C は約 18000 枚で学習し,それぞれ 30 エポックと 10 エポックで学習を行った.潜在変数の



図4:画像例(データセットA・正常データ)



図5:画像例(データセットA・異常データ)



図 6: 画像例(データセット B・正常データ)



図7:画像例(データセットB・異常データ)



図8:画像例(データセットC・正常データ)



図 9: 画像例(データセット C・異常データ(継ぎ 目を異常とみなす))

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 の学習済みモデルを用いた.

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.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の番号 は図 8,9の左から数えた番号である.

図8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 成がうまくいかない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.また、図9を見てみると、全体的に再構成 がぼけてしまっており、VAE の学習がうまくいって いないのが分かる. ResNetの中間層を見てもシール を貼った箇所を強調してはいるが,他の箇所も同時 に強調されているため分かりづらくなっている. こ の原因も学習データの不足によるものだと考えられ るため,より多数のデータを作成することが必要だ と考えられる.さらに図 10 を見ると,学習データの 数が豊富なため VAE の再構成が比較的うまくいっ た結果となった. 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.



図 10: VAE および ResNet による実験結果(データ セット A)

表1 各画像の異常度(データセットA)

番号/ラベル	1/異常	2/異常	3/正常	4/異常
score	654	269	760	796
番号/ラベル	5/異常	6/正常	7/正常	8/異常
score	294	285	304	273



図 11: VAE および ResNet による実験結果(データ セット B)

表2 各画像の異常度(データセットB)

番号/ラベル	1/正常	2/正常	3/ <mark>異常</mark>	4/異常
score	446	266	256	213
番号/ラベル	5/異常	6/異常	7/正常	8/正常
score	220	250	250	439



図 12: VAE および ResNet による実験結果(データ セット C)

表 3	各画像の異常度(デー	ータ	セッ	\mathbb{P}	C)
-----	------------	----	----	--------------	----

番号/ラベル	1/異常	2/正常	3/ <mark>異常</mark>	4/正常
score	195	122	270	162
番号/ラベル	5/異常	6/正常	7/正常	8/異常
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.

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.

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則化 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