

特徴量を用いた過去動画からの参照画像抽出による配管外面の変化検知

Change Detection on Pipe Outer Surface via Reference Image Extraction from Past Video Using Feature Points

東京大学 ○清水進, 伊賀上卓也, ルイ笠原純ユネス

ENEOS 株式会社 大和尚也, 笠原清司, 伊藤裕之, 大東泰三, 田村直, 笹村晃伸, 加藤俊哉

東京大学 神田真司, 永谷圭司, 浅間一, 安琪, 山下淳

Abstract 本研究では, 巡回点検ロボットにより撮影された点検動画を用いた配管外面の変化検知手法を提案する. 巡回点検においては, 過去の正常な状態との比較により配管外面の変化を検知するため, 変化前後の動画の比較が変化検知には重要である. 提案手法では, 移動ロボット上のカメラにより撮影した動画から画像特徴量による比較画像ペアの抽出, 深層学習による変化検知を行った. 本手法は点検動画からの変化検知を 93.9% の精度で達成した.

1. 序論

石油精製・石油化学プラントでは, 原油や重油, 石油ガス等の資源を精製して燃料油, 合成繊維や合成樹脂等の石油製品・石油化学製品の製造を行っている. 当該プラントには, 原料や製品を輸送するために, 配管が広く使用されている. 配管は, 原料中の成分や雨水などの水分, 温度などの要因で内外面から腐食する可能性があり, 内部流体の漏洩や配管の破損などの異常につながるリスクがある. このような異常を検知するために, 当該プラントでは昼夜を問わず作業員による定期的な巡回点検が行われている. しかし, 熟練作業員の減少や作業員による点検の質のばらつきなどの課題があり, カメラを用いた変化検知手法について研究が盛んに行われている. さらに近年では, カメラを搭載した巡回点検ロボットによる自動巡回点検への注目が高まっている.

巡回点検ロボットを使用した当該プラントの巡回点検では, 通常状態と変化が生じた状態を見分ける必要があるが, そのためには通常状態と変化後の状態を比較すること, すなわち過去に撮影された通常状態の動画と現在撮影された変化後の状態の動画の差異を検知することが重要である. 巡回点検ロボットでこれらの動画を取得し, 変化検知を行う場合に課題となるのが, 動画間でカメラの位置姿勢が異なることである. 巡回点検ロボットはあらかじめ決められた経路で当該プラント内を巡回するが, 自己位置推定の誤差や地面の形状により点検ごとに通る経路がやや異なる. そのため, 比較する画像間の差分画像をとると, カメラ位置姿勢の変化により誤検出や検出漏れが発生するという課題があった [1].

カメラ位置姿勢の変化に頑健な手法として, Wang らによる AnoDFDNet がある [2]. この手法では, 変化が生じる前後で同じ領域を撮影した 2 枚の画像をペアとして入力すると, これらの画像で変化した部分を出力するネットワークが提案されている. しかし, この手法では入力画像ペアの決定方法に関する考慮がされていない. そのため, 過去の点検時に撮影された動画と現在の点検時に撮影された動画から比較に適切な画像ペアを選択して, 変化検知を行うことはできていない. そこで本研究では, 2 つの動画から入力画

像ペアを決定する方法を提案することにより, 点検動画の比較による配管外面の変化検知を達成する.

2. 提案手法

2.1 手法概要

提案手法の全体の流れを図 1 に示す. まず始めに, 巡回点検ロボットにより通常時と配管外面に変化が生じた際の点検動画を撮影する. これらの動画を比較することにより, 動画間で変化した部分を検知することが求められるが, 動画のどのフレームどうしを比較するのかが選択する必要がある. そこで, 本研究では 2 枚の画像の類似度判定手法により, 比較に適したフレームを選択する. このようにして得られた画像ペアを深層学習モデルに入力し, 画像間の変化を検知する. この手法により, 巡回点検時に撮影された動画から変化検知を実施することが可能である.

2.2 巡回点検ロボットによるデータ取得

石油精製・石油化学プラントの巡回点検において, 巡回点検ロボットは搭載したカメラによって配管外面の点検動画を取得する. この際, 通常時の配管を撮影した点検動画 (以下, 過去動画) と配管外面に変化が生じた際の点検動画 (以下, 点検対象動画) の 2 種類の動画を取得する. 次に点検対象動画から一定間隔でフレームを抽出し, 点検対象画像として取得する. 点検対象画像と過去動画の各フレームに対して, 画像類似度判定を実施し, 抽出された過去動画のフレームを参照画像とする. このようにして得られた点検対象画像と参照画像を入力画像ペアとする.

2.3 画像類似度判定による入力画像ペア決定

本研究では 2 枚の画像から類似度を判定し, 最も類似度が高い画像を入力画像ペアとする. 画像の類似度の基準として, 特徴量マッチングによりマッチングした特徴量の個数を用いる. 石油精製・石油化学プラントは屋外に存在するものも多く, そういった環境では明るさ条件の変化が大きいため, 明るさの変化にロバストな Accelerated-KAZE 特徴量を用いて, 特徴量抽出を行う [3]. 特徴量マッチングとしては, 2 枚の画像の特徴点群の中で互いにハミング




図 1 提案手法の流れ




図 2 移動ロボットによる実験の様子

距離が最も小さくなる特徴点を採用する。このようにして得られた特徴点の個数が最も多くなる画像のペアを入力画像ペアとする。

2.4 深層学習による変化検知

2枚の画像の変化した部分を検知する手法として、WangらのAnoDFDNetを用いる[2]。これはCNNとVision Transformerによる変化検知ネットワークであり、画像をペアとして入力することで、入力画像ペア間の変化を検知できる。このネットワークに、検知対象の変化の特徴を学習させることで、カメラ位置姿勢や照度条件といった検知対象でないものの影響に頑健な変化検知が可能である。

3. 実験

3.1 実験設定

実験の環境を図2に示す。実験は室内に構築した石油精製・石油化学プラントを模した環境で行った。配管には塩化ビニル製の配管を使用し、配管外面の変化は、黒色のビニールテープを配管表面に貼付し再現した。

本研究では、巡回点検ロボットとして、マニピュレータが搭載されたクローラ型移動ロボットとしてトピー工業製のS2-P1を用いた。カメラはNikon Z9、レンズはNIKKOR Z 24-70 mm f/4 Sを移動ロボットに搭載した。動画の解像度は3840×2160ピクセル、フレームレートは30 fps、焦点距離は24 mmとした。移動ロボットは配管に沿って約1.2 mの距離を0.015 m/sで直線状に動かして配管の動画を取得した。

提案手法の精度評価のために、提案手法と同じ参照画像を用いて訓練したオートエンコーダ(<https://github.com/Horizon2333/imagenet-autoencoder>)および、提案手法により選ばれた参照画像から、0.01 m刻みで最大0.04 m平行にずらした位置の過去動画フレームを用いて作成した入力画像ペアをテストデータとした場合の変化検知を実施した。オートエンコーダは参照画像の再構成誤差のヒストグラムからカーネル密度推定に基づいて閾値を設定し、入力画像の再構成誤差が閾値以上であれば変化が生じた画像と判定した。また、提案手法については1ピクセルでも変化が検知された画像を変化が生じた画像と判定した。

3.2 学習用データの生成

点検対象動画から729枚の点検対象画像が取得された。これらの点検対象画像と参照画像のペアを作成し、504ペアの訓練データと検証データ、225ペアのテストデータに分割した。訓練データと検証データは8:2の比率で分割し、401ペアの訓練データ、103ペアの検証データとした。深層学習モデルの訓練、検証に用いた入力画像ペアは、参照画像と点検対象画像が同じ領域を撮影していることを確認するために、手動でペア決めを実施した。テストデータは提案した類似度判定手法によりペア決めを実施した。

4. 結果・考察

差分画像と提案手法による変化検知の結果を図3に示す。差分画像では、カメラ位置姿勢の変化により配管や窓枠のエッジ部分などを誤って検知しているのに対し、提案手法は変化した部分のみを正




図 3 変化検知の結果比較

(左から参照画像, 点検対象画像, 差分画像, 提案手法による変化検知, Ground truth)

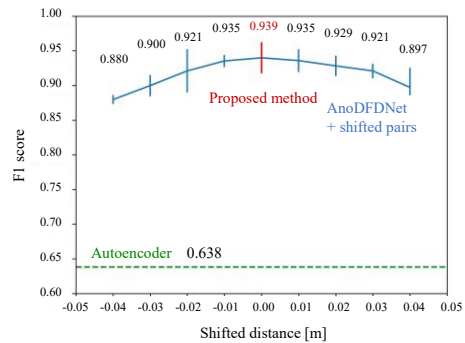


図 4 F1スコアの比較

(横軸: ずらした距離, 縦軸: F1スコア)

しく検知できており、カメラ位置姿勢の変化に強い配管外面の変化検知ができていたことが確認された。

F1スコアによる精度評価の結果を図4に示す。提案手法はオートエンコーダよりも高いF1スコアで変化検知を達成したことが確認された。提案手法の精度がオートエンコーダに比べ高い理由としては、移動ロボットによる点検動画のみではオートエンコーダの学習に十分なデータが取得できなかったことが考えられる。このことから、移動ロボットによる巡回点検においてはオートエンコーダよりも提案手法が適していることが確認された。

また、位置をずらしたテストデータを用いた場合との比較では提案手法での入力画像ペアが最も高い精度で変化を検知できていることが分かった。これから、画像類似度判定による入力画像ペア決めの有効性が確認された。

5. 結論

本研究では、深層学習による配管外面の変化検知のための画像特徴量に基づく類似度判定手法を提案した。室内に構築した模擬プラント環境において移動ロボットを用いた配管データセットを作成し、深層学習による変化検知モデルの訓練を行った。オートエンコーダや位置をずらした場合との比較により、提案手法は入力画像のペア決めを適切に実施し、点検動画の比較による変化検知を達成できることが確認された。

今後の課題としては、移動ロボットの自己位置推定結果を加えた入力画像ペア決定手法の構築や、実際の点検経路を模したより長距離経路での実験、屋内環境よりも照度条件の変化が大きいの実際の石油精製・石油化学プラントでの屋外実験などが挙げられる。

参考文献

- [1] Richard J. Radke, Srinivas Andra, Omar Al-Kofahi, and Badrinath Roysam, "Image Change Detection Algorithms: A Systematic Survey", IEEE Transactions on Image Processing, vol. 14, no. 3, pp. 294-307, 2005.
- [2] Zhixue Wang, Yu Zhang, Lin Luo, and Nan Wang, "AnoDFDNet: A Deep Feature Difference Network for Anomaly Detection", Journal of Sensors, vol. 2022, 2022.
- [3] Pablo F. Alcantarilla, Jesús Nuevo, and Adrien Bartoli, "Fast Explicit Diffusion for Accelerated Features in Nonlinear Scale Spaces," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 34, no. 7, pp. 1281-1298, 2011.