

送変電設備の教師無し学習による異常検出技術

Unsupervised Anomaly Detection for Power Transmission and Substation Equipment

異常データが不要な機械学習

パターン認識タスクにおいては一般に大量の異常データの収集が難しいため、通常の教師有り学習を適用できないケースも多い。本研究では送変電設備を対象として、ラベル無しの正常データのみから識別モデルの学習を行う「教師無し学習」による異常検出について検討を行い、提案手法の有効性評価を行った。



執筆者
先端技術応用研究所
情報技術グループ
瀬川 修

1 背景と目的

将来の設備保守業務の自動化に向けては、コンピュータビジョンによる設備状態の把握が重要な要素技術になると考えられる。一般にパターン認識タスクにおいては、対象物体のカテゴリラベル付きデータを用意して識別モデルの教師有り学習を行うことが多い。しかしながら、一般に異常データを判別するタスクにおいては大量の異常データの収集が難しい上に、多様な異常状態を網羅的に定義すること自体が困難である。

このため、最近ではラベル無しの正常データのみから異常検出のモデルを学習する「教師無し学習」(Unsupervised-learning)のアプローチが盛んに検討されるようになった。本稿では送変電設備を対象とした教師無し学習による異常検出手法の概要と、提案手法の有効性評価について述べる。

2 問題設定

本研究で検討した対象問題は下記のとおりである。いずれも異常状態の画像が収集しづらいタスクである。

(1) 変電設備の異常状態の判別

変圧器等のオイルクーラーの配管継手からの漏油

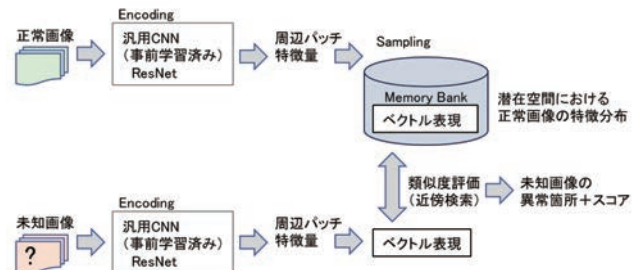
(2) 送電設備の異常状態の判別

送電線の落雷による溶痕

3 アルゴリズム検討

教師無し学習を用いた異常検出には、(1) 入力画像の特徴量を抽出し「正常状態の特徴分布」からの乖離度を評価する方法、および(2) 入力画像を何らかの生成モデルで再構成し、入出力画像の差分を評価する方法の2つのアプローチがある。本稿では(1)のアプローチ一つであるPatch Core [1]を用いた。

Patch Coreの概要を第1図に示す。同手法では、正常画像の特徴量を抽出し、正常状態の特徴分布を反映したベクトル表現のデータベース(メモリバンク)を構成する。この時、大量の画像データベースから事前学習された汎用CNNの特徴マップを利用するため、少量の正常データで学習した場合でも高い検出精度が期待できる。



第1図 Patch Coreの概要

Patch Coreの学習においては、前記CNNの複数の中間層の出力を組み合わせた特徴量を用いる。これにより、入力した正常画像から局所的な特徴を表すベクトル表現が獲得され、メモリバンクに保存される。


推論時には、学習時と同一のCNNを利用し、入力画像から局所的なベクトル表現集合を抽出する。そして、各ベクトル表現に対し K 近傍法により、メモリバンク内で類似したベクトル表現が選択され、それらとの距離が算出される。そして、各ベクトル表現に対する距離を統合することで、未知画像の異常スコアを得る。また、各ベクトル表現に対する距離をヒートマップとして可視化することより異常箇所のセグメンテーション結果を得る。

4 評価

Patch Coreのベクトル表現抽出用の事前学習モデルとしてWide ResNet50を用いた。評価指標には異常検出タスクで一般的なAUROC (Area Under Receiver Operator Characteristic Curve) を用いた。

(1) 変電設備の漏油箇所の検出

学習データとして、変電所設備のオイルクーラー配管継手の正常データ80枚(336×336にリサイズ)を用いた。評価データとして、正常データ10枚、画像加工により異常(漏油)を付加した模擬データ10枚の合計20枚を用いた。漏油の検出例を第2図に示す。同図から、異常検出モデルにより正確に異常箇所が可視化されていることが確認できる。異常検出のAUROCは100となり、少量の正常データで画角変化に対し頑健な異常検出が可能になった。



第2図 配管継手の漏油の検出例

(2) 送電線の落雷による溶痕の検出

学習データとして、ドローンで撮影した送電線の動画(MP4 HD)を0.5秒間隔でキャプチャした画像を利用した。また、映像の解像度の影響を調べるため、640×320と1920×1080の解像度で2パターンの検証を行った。計算量の観点から、両パターンでメモリバンクのサイズが同等になるようにデータサンプリングを行い、最終的に640×320の設定では220枚、1920×1080の設定では20枚の正常画像を学習データとして用いた。評価データとして、ドローンで撮影した別の送電線の動画(約6分)に画像加工によって径間に3箇所異常(溶痕)を付加した模擬データを用いた。このうち正常データは658枚、異常データは15枚であった。


ドローンで撮影された映像は、背景が動的に変化するため検出性能に影響を与える可能性がある。このため、入力画像に対しニューラルネットワークに基づく深度推定[2]を行い、閾値によるマスク処理によって背景を除去する処理を行った。

検出結果の例を第3図に示す。同図から、深度推定による背景除去により、正確に送電線のみが抽出され、異常検出モデルにより正確に異常箇所が可視化されていることが確認できる。異常検出のAUROCは解像度640×320で99.8、1920×1080で100となり、頑健な異常検出が可能なのことがわかった。解像度1920×1080の場合はわずか20枚という学習データで完璧に検出ができています。


評価データにおける異常スコアの時系列遷移を第4図(背景あり)、および第5図(背景無し)に示す。縦軸が異常スコア、横軸がフレーム番号、赤線が正解フレームである。これらと比較すると、背景ありの場合には正常時のスコアが安定せず、また正常と異常のスコア差が小さくなっていることが確認できる。よって、深度推定による背景除去を行うことにより、正常と異常の識別が容易になることがわかる。

ここで、第5図の横軸ID 270付近に着目すると、異常スコアが突発的に上昇している。これは、ドローン撮影時のピントが外れ、深度推定による背景除去が不正確となったことに起因する。これより深度推定の精度は検出性能に大きく影響するものと考えられる。


解像度640×320



解像度1920×1080




第3図 送電線の溶痕の検出例



解像度640×320

第4図 異常スコア(背景あり)赤が正解フレーム



解像度640×320

解像度1920×1080

第5図 異常スコア(背景無し)赤が正解フレーム

5 まとめ

本研究では、教師無し学習を用いた送变电設備の異常検出技術の検討を行った。その結果、変電設備の漏油および送電線の溶痕の検出について提案手法の有効性が確認された。今後の展開であるが、生成モデルによるアルゴリズムを検討すると共に、より広範な設備について検証を進めていく予定である。

参考文献

1. K. Roth et al., "Towards total recall in industrial anomaly detection", IEEE CVPR (2022).
2. R. Ranftl et al., "Towards robust monocular depth estimation: Mixing datasets for zero-shot cross-dataset transfer", IEEE Trans. PAMI (2020).