

移動ロボットによるプラント点検のためのオートエンコーダによる異常音検知

東京大学 ○藤田勇人, ルイ笠原純ユネス, 濱崎峻資, 神田真司, 永谷圭司, 山下淳
ENEOS 株式会社 笠原清司, 田中祐一, 福元誠悟, 加藤俊哉, 是永真泰, 星美咲
東京大学 浅間一

1. 序論

石油精製プラントでは、機器の老朽化あるいは予期せぬ不調による故障を防ぐため定期的なメンテナンスが必要となっている。多くの石油精製プラントでは、巡回点検は人の五感に頼っているのが現状である。近年、ロボット技術の発展とともに、巡回点検にロボットを導入しようという試みがなされてきている。石油精製プラントの巡回点検を移動ロボットにより行うことで、熟練者の減少への対処・点検の質の標準化などの実現が期待される。

一般のロボットによる点検は限られた点検箇所のみを目標としている。しかし石油精製プラントでは、あらかじめ定められた点検箇所以外にも異常が発生する可能性がある場所は多く、定められた点検箇所のみでの点検では不十分である。移動ロボットによる石油精製プラント内点検を実現するため、定められた点検箇所以外の場所でも起こりうる異常について、異常を検知し、異常の発生場所を特定することは不可欠である。

このようなロボットの走行中に異常を検知する方法として、マイクロホンを用いた音響データによる点検があげられる。プラント内では、回転機械の異常音やガス漏れの音などの異常が音響データによって検知される。本研究では、移動ロボットによってあらかじめ定められた点検箇所以外の異常音検知に取り組む。

異常音検知では、正常音と異常音をルールベースで識別するのは難しく、深層学習による手法が主流になっている。Yao らは複数のマイクロホンの情報を統合し、CNN により歯車の 4 種類の故障を診断している[1]。この手法では正常と異常の 2 クラスの教師ラベルが必要である。しかし石油精製プラントでは、異常は頻繁に発生するものではないため、異常の教師データを収集するのは困難である。すなわち、教師あり学習に不可欠な教師データを収集するのは難しい。そのため、正常音のみから学習し、異常音を判定する手法が主流となっている。Oh らはオートエンコーダを用いて、正常音の教師データのみで表面実装装置の異常音の識別手法を提案している[2]。

これらの先行研究では、マイクロホンと音源の位置を固定し異常音の識別を行っている。本研究ではマイクロホンを搭載した移動ロボットを想定しており、位置が一定ではない。そのため移動ロボットが動く点検経路の全ての位置で正常音の教師データが必要となるが、経路上全ての位置で十分な量の正常音の教師データを集めるのは非常にコストがかかる。この問題に対処するため本研究では複数の限られた箇所から取得した十分な量の正常音の教師データを用いて、点検ルート上の任意の地点で聞こえた音の正常・異常判定することを目指す。

2. 提案手法

2.1 問題設定

十分な量の正常音データを集めるには長時間かかるため、移動ロボットに搭載したマイクロホンだけでは不十分である。




図 1 短時間フーリエ変換とオートエンコーダ

そのため、移動ロボットのマイクロホンとは別に石油精製プラント内の特定の箇所固定マイクロホンを N 個配置し、それぞれ $m_1, m_2, \dots, m_N$ とする。また、移動ロボットに搭載されたマイクロホンを r とする。本研究では、簡素化のため音源の種類を 1 種類とし、正常音か異常音のどちらかが決まれば音源はすべて同じ音を出すものとする。また、石油精製プラント内では音は回転機械などの機器から発生するため、音源の位置もプラント内の設計図上から既知とする。音源は M 個存在し、それぞれ $s_1, s_2, \dots, s_M$ とする。

また、本研究では、音の距離と反射によって決まる音源とマイクロホン間の伝達関数は既知となる理想的な環境を考える。 i 番目のマイクロホン m_i と j 番目の音源 s_j 間の伝達関数は $A_{m_i s_j}(\omega)$ と表せる。

このとき、固定マイクロホン $m_1, m_2, \dots, m_N$ で取得した正常音データを用いて、移動ロボット上のマイクロホン r で取得した音に対して、正常音・異常音の判定を行う。

2.2 複数地点の音を用いた他の地点の音の復元

音源 s_j から鳴る音の周波数スペクトルを $S_j(\omega)$ と表す。マイクロホン m_i で聞こえる周波数スペクトルを $M_i(\omega)$ と表す。 $M_i(\omega)$ は、(1) 式のように伝達関数と音源の周波数スペクトルの積で表される。

$$M_i(\omega) = \sum_{j=1}^M A_{m_i s_j}(\omega) S_j(\omega). \quad (1)$$

異なる複数の位置の固定マイクロホンで音をとることで、(1) 式で表す音源の周波数スペクトルとマイクロホンの音の周波数スペクトルの関係の式が固定マイクロホンの数だけ得られる。固定マイクロホンの周波数スペクトルと伝達関数は既知で、音源の周波数スペクトルが未知なので、固定マイクロホンの数が音源の数より多ければ、解析的に音源の周波数スペクトル $S_j(\omega)$ が求まる。

音源の周波数スペクトルを全て求めた後に、マイクロホンの周波数スペクトルは(1)式により求まる。




図 2 実験設定




図 3 正常音と異常音の再構成結果

表 1 学習場所を変えたときの精度比較

学習位置	r	m_1	m_2	m_3	提案手法
F1 値	0.833	0.747	0.738	0.765	0.833
F2 値	0.797	0.751	0.745	0.758	0.797
AUC	0.874	0.800	0.792	0.811	0.874

2.3 オートエンコーダによる異常音検知

本研究では、正常音と異常音の判別のため、機械学習モデルとして正常音のみから学習できる図 1 のようなオートエンコーダを用いる。

オートエンコーダの入力の際に前処理として、短時間フーリエ変換を用いた。まず、音の時系列データに対し窓の幅が 1 秒の窓関数をかけ、複数枚の音の時系列データを作成する。それらに、フーリエ変換を施した複数枚の周波数スペクトルを作成する。これをオートエンコーダの入力データとする。

オートエンコーダは、エンコーダ部分で低次元特徴量に落とし、デコーダ部分で入力データの再構成を行う。学習時には、入力した正常音データと再構成した正常音データの誤差を小さくするように学習を行う。テスト時には、正常音と異常音の両方を入力し、再構成誤差が閾値より大きければ異常、小さければ正常と判別する。

3. 結果・考察

3.1 実験設定

本研究では、実験を行うためにシミュレーション環境である pyroomacoustics[3]を用いた。実験設定を図 2 に示す。

10m 四方の部屋を作成し、3 つの音源 s_1 , s_2 , s_3 をおいた。 s_1 の座標は(3, 7), s_2 の座標は(3, 3), s_3 の座標は(7, 5)とする。ロボットはその部屋の周上を巡回すると仮定した。経路上には 3 つの固定マイクロホン m_1 , m_2 , m_3 を置き、十分な量の正常音データを取得する。 m_1 の座標は(5, 10), m_2 の座標は(0, 5), m_3 の座標は(5, 0)とする。このとき、正常音データ取得していない未知位置 r での異常検出を行う。 r の座標は(10, 5)とする。

音源の音として、実際のプラントで取得した正常音と異常音を使用した。正常の状態と異常の状態の 2 種類を用意し、正常の状態は音源 s_1 , s_2 , s_3 が全て正常音とし、異常の状態は音源 s_1 , s_2 が正常音, s_3 が異常音とした。

3.2 正常音の再構成による異常音検知

正常の状態のときに r , m_1 , m_2 , m_3 の 4 ケ所で聞こえる音で学習したモデルそれぞれで、異常状態のときに位置 r での異常検出精度を比較し、学習時の位置とテスト時の位置が異なるときに異常検出精度の違いを調べた。評価指標として F1 値, F2 値, AUC を用いた。結果を表 1 に示す。実際に異常音検出を行う位置 r で学習したものが、F1 値, F2 値, AUC の全てで高くなっていた。このことから、学習時とテスト時の位置が異なるとき、異常検出精度が下がることがわかった。

次に、提案手法による異常音検出を行った。まず、3 つのマイクロホン m_1 , m_2 , m_3 から得られる 3 つの(1)式を用いて音源の音を再構成した。正常音と異常音の再構成結果を図 3 に示す。求めた音源を用いて r の位置の音をシミュレーションによって求めた。求めた r での正常音を学習データとしてオートエンコーダを学習した。

提案手法の結果を表 1 に示す。提案手法は、 r の位置でのデータを学習データとしたときと F1 値, F2 値, AUC の全てが等しくなった。異常検出したい地点以外の点を用いて、異常検出したい地点の学習データを作成できることがわかった。

全ての伝達関数が求まる理想的な室内環境では、音源の数と等しい数の固定マイクロホンで事前に正常音データを取得することで、音源の音が再現できることがわかった。そのため、室内の他の位置で高い検出精度で異常検出できると考えられる。

4. 結論

提案手法を用いることで、正常音を取得した地点でのデータを使って、移動ロボットなどに搭載されたマイクで正常・異常を判定することができた。

今後の展望として、実環境にこの手法を適用していくことを考えている。その際、ノイズを考慮した手法を考案する必要がある。

謝辞

本研究を進めるにあたり、東京大学先端科学技術研究センター矢入健久教授のグループのご研究を参考にさせて頂きました。心より感謝申し上げます。

参考文献

- [1] Yong Yao, Honglei Wang, Shaobo Li, Zhonghao Liu, Gui Gui, YaboDan and Jianjun Hu: "End-To-End Convolutional Neural Network Model for Gear Fault Diagnosis Based on Sound Signals", Applied Sciences, vol. 8, no. 9, article no. 1584, 2018.
- [2] Dong Yul Oh and Il Dong Yun, "Residual Error Based Anomaly Detection Using Auto-Encoder in SMD Machine Sound", Sensors, vol.8, no.5, article no. 1308, 2018.
- [3] Robin Scheibler, Eric Bezzam and Ivan Dokmanic Tomoki Toda, "Pyroomacoustics: A Python Package for Audio Room Simulation and Array Processing Algorithms", Proceeding of the 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP2018), pp.351-355, 2018.