

②深層学習による異常検知を利用した走行音に基づく違法車両検出

環境研究部 ※尾崎 信利 宝渦 寛之

1. はじめに

道路交通騒音問題の中でも、住民感情を著しく損ねる存在として、自動車ユーザが自ら交換・改造したマフラーによって大きな騒音を発する車両が挙げられる。このような車両の取り締まりとして、街頭検査が実施されている。街頭検査では走行中の車両を呼び止めて停車させ、マフラー近傍に設置した騒音計でエンジン作動時の騒音レベル（以下、近接排気騒音）が規制値を超過するかを検査する。ここで本稿では、近接排気騒音が規制値を超過する車両を違法車両、超過しない車両を適法車両とする。近接排気騒音の検査は時間・労力を要するため、車両走行音から違法車両である可能性のある車両をスクリーニングできれば効率的な街頭検査に資すると考えられる。

交通安全環境研究所では、これまでに深層学習を利用した車両走行音に基づく違法車両の検出手法を開発・検討してきた。これまでの研究では、深層学習モデルに、学習データで適法/違法車両の走行音の特徴を学習させ、テストデータの走行音が適法/違法車両のどちらに近いかを判断させていた（教師あり分類学習）が、これには適法/違法車両の走行音データが同数程度必要であった。一方で、実際の道路交通状況を考えると、違法車両の走行音は適法車両に比べて入手機会が少ないため、学習データに含まれる違法車両の走行音データが不足し、学習が不十分となることで、検出精度が低下する可能性があった。

そこで本稿では走行音に基づく違法車両の検出を異常検知問題として取り扱う。すなわち、深層学習モデルに適法車両の走行音だけを学習させ、テストデータの走行音が適法車両のものにどの程度似ているかを判定させる。このアプローチにより、適法車両の走行音のみの学習データから、違法車両の検出が可能であるかを検証する。

2. 異常検知手法を利用した違法車両の検出

本稿の異常検知手法を利用した違法車両検出方法の概要を図1に示す。まず前処理として、車両走

行音を人の聴覚に基づいた音響特徴量を得るためにメルスペクトログラム変換し、変換結果をデータ毎に正規化することで走行音の周波数パターンを短時間ごとに可視化（画像化）する。ここで正規化する理由は、公道に騒音計を設置できる場所は限られていることから、車両から騒音計までの距離が場所によって様々となり、同じ車両が同じ条件で走行しても異なる騒音レベルとして測定されるためである。また学習時にはデータ拡張¹⁾（Data augmentation）処理も走行音データに適応した。前処理で得られた各走行音の2次元データをグレースケール画像とみなして、画像の異常検知をおこなう。本稿ではこの異常検知にDN2²⁾と呼ばれる深層学習モデルを用いた。DN2は、深層学習モデルによって抽出した正常データの特徴量がどのように分布しているかを学習段階で定義し、テストデータから抽出した特徴量が、学習段階で定義した特徴量の分布からどの程度乖離しているかの乖離度を算出する異常検知手法である。この乖離度は、大きいほ

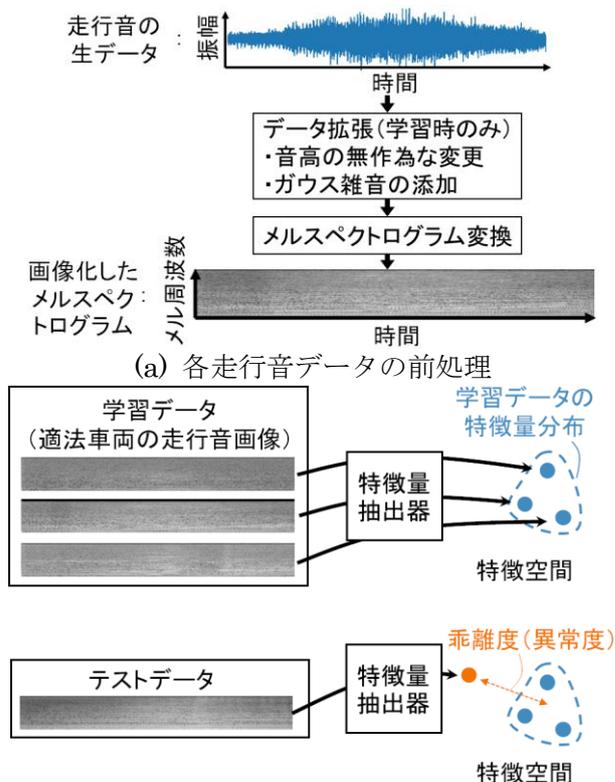


図1 違法車両検出方法の概要

ど対象のデータが正常データから離れていることを示しているため、異常度として取り扱われる。本稿の場合は、適法/違法車両の走行音をそれぞれ正常/異常データとし、異常度の大きいデータを違法車両として検知する。

3. 実験概要

3.1 走行音データの測定

本稿では、実験対象を単独で走行する二輪車の走行音とした。試験車両には型式の異なる2台の二輪車を用い、マフラーを交換することで、各車両の適法車両状態と違法車両状態の走行音を測定した。すなわち、適法車両状態では純正マフラー、違法車両状態では不正改造マフラーを装着した。また走行音は各車両状態で、テストコースを様々なパターンの車速、加速度、ギア位置で走行した時のものを測定した。

3.2 実験方法

上記の測定実験で得られた走行音データは、適法車両状態のものが合計42件、違法車両状態のものが合計64件であった。この走行音データのうち、適法車両状態から21件の走行音を無作為抽出して学習データとし、残りの走行音をテストデータとした。DN2により、学習データの特徴量の分布を定義し、テストデータ中の各走行音の異常度を解析した結果を評価した。この試行は無作為抽出による結果のばらつきを確認するために50回繰り返した。

4. 実験結果

DN2による解析結果の一例をヒストグラムとして図2に示す。図2では適法車両と違法車両の異常度の分布が完全に分離しており、図2において異常度の閾値を200とすると100%の精度で違法車両を検出できることがわかる。一般的に異常検知問題の解析結果は、正常データと異常データの異常度の分布が分離できているかを評価し、その指標にはAUC-ROCが用いられる。AUC-ROCは、1.0で正常/異常データの異常度の分布が完全に分離(図2のように精度100%の異常検出が可能)し、0.5で全く分離していないことを表す。DN2による解析を50回繰り返した結果をAUC-ROCのヒストグラムとして図3に示す。図3より、解析結果のほとんどのAUC-ROCが1.0と、DN2が非常に高い精度で

適法車両と違法車両の走行音を区別できていることがわかる。以上から、本稿の走行音データでは、深層学習による異常検知手法を用いることで、学習データに適法車両の走行音しか含まれていない場合でも、非常に高い精度で違法車両を検出できることがわかった。

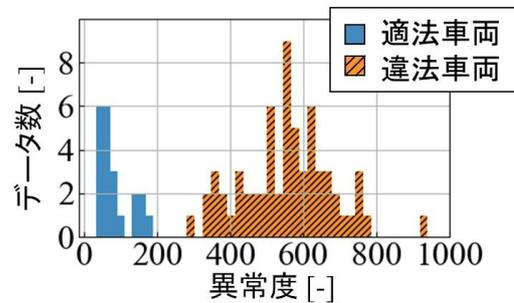


図2 DN2による解析結果の一例

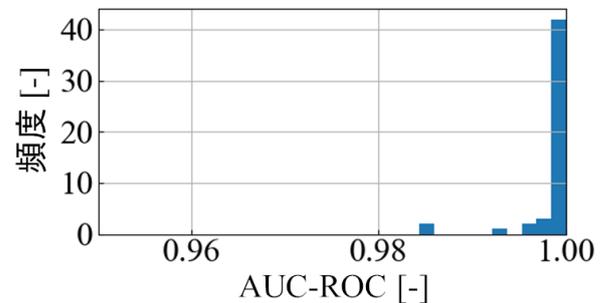


図3 DN2による解析を50回試行した結果

5. まとめ

本稿では、異常検知を目的とした深層学習手法を利用することで、適法車両の走行音のみで構成された学習データに基づいて違法車両を有効に検出できる可能性を示した。今後は、街頭検査に合わせた騒音測定を通じ走行音のデータ数を増やすことで、検出モデルの高精度化を目指す。

参考文献

- 1) J. Abeßer, S. Grollmisch and M. Müller, "How Robust are Audio Embeddings for Polyphonic Sound Event Tagging?", in IEEE/ACM Transactions on Audio, Speech, and Language Processing, vol. 31, pp. 2658-2667, (2023).
- 2) L. Bergman, N. Cohen and Y. Hoshen, "Deep nearest neighbor anomaly detection", arXiv preprint arXiv:2002.10445, (2020).