

講演3. AIを用いた走行騒音から不正改造車両の判定方法

環境研究部

※宝渦 寛之

1. はじめに

道路交通騒音に係る環境基準は緩やかな改善傾向にあるものの、幹線道路の沿線など一部の地域においては依然として厳しい騒音環境下にさらされている。このようななかで、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の意思によりマフラーを交換する等によって、道路運送車両の保安基準（以下、保安基準という。）に適合しない大きな騒音を発する車両が挙げられる。図1は、国土交通省の不正改造車110番への情報提供件数のうち、マフラー騒音が占める割合を示したものであるが、マフラー騒音の占める割合は、年々、増加傾向にあり、喫緊に有効な対策が必要な状況であることがわかる。また、近年のコロナ禍による相対的な交通量の減少や自粛疲れから、暴走行為を行う車両の増加も指摘されており、今後、さらに深刻な状況となる可能性もある。




図1 不正改造車110番の情報提供件数にマフラー騒音が占める割合¹⁾

このような車両の取締りは、保安基準の細目を定める告示別添38「近接排気騒音の測定方法」に定められている騒音測定試験（以下、近接排気騒音試験という。）によって実施される。試験にあたっては、車両を呼び止めて停止させ、エンジン回転計の取り付けや騒音計の設置を行い、試験法に則った操作をして試験を

行う。図2に街頭検査における近接排気騒音試験の様子と走行騒音の測定の様子を示し、図3に近接排気騒音試験と定常走行騒音及び加速走行騒音との関係を示す。図3より、走行騒音と近接排気騒音とは単純な相関が低いことがわかる。この理由としては、近接排気騒音試験と走行騒音では車両の状態や騒音測定位置が大きく異なるため、音源の寄与率が異なるためであると考えられる。



図2 街頭検査における近接排気騒音試験の様子と実走行の様子

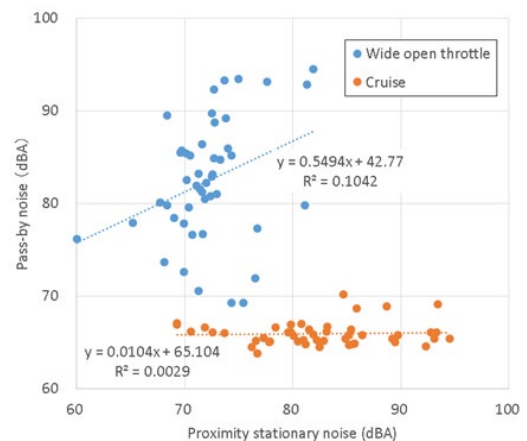


図3 近接排気騒音試験と走行騒音の関係

ところで、近年、様々な分野において、AI (Artificial Intelligence) の活用が進んでおり、従来技術では解決が困難であった多くの課題の解決に貢献している。AIを活用することによって、これまで困難であった走行騒音のみから不正改造車両を検出することが出来れば、より効率的な取締りを行うことが可能となると考

えられる。そのため、本研究では、深層学習により作成した AI モデルを用いて、走行騒音から不正改造車両を判定可能か検討した。本稿では、研究の第一段階として、対象を単独で走行する二輪車を対象に限定し AI の適用を検討した結果を報告する。

2. 深層学習による AI モデルの作成

本研究で扱うデータは騒音データであるが、AI は画像認識において多大な実績を有するため、騒音データを画像データに変換し、この画像データに対して教師あり学習の分類を行う AI モデルを作成した。AI モデルの作成においては、使用可能なデータセットが存在しないため学習データの測定を実施した。

2. 1. 騒音データの事前処理

図 4 に本研究にて採用した事前処理の概要を示す。ここでは、騒音計にて収録した騒音データについて、一定時間幅ごとに周波数解析を行い、横軸を時間、縦軸をスペクトル密度とする白黒の図を作成する。これらは、それぞれの図中の最大値で正規化を行った。ここで正規化を行った理由は、公道では騒音計を設置できる場所が限られるため、車両から騒音計までの距離が測定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、騒音レベルは考慮しない方がよいと考えられるためである。また、AI モデルの作成にあたっては、画像の変化量が大きな箇所が特徴量として保存されるため、各画像における特徴量を顕在化させる意味でも正規化は適切であると考えられる。

事前処理によって作成した図について、畳み込みニューラルネットワークを適用し、画像を”適法車両”、”不正改造車両”及び車両以外の音を想定した”その他”に分類した。なお本研究では、一つの画像の時間幅を 40msec とし、A 特性の周波数補正を行っている。

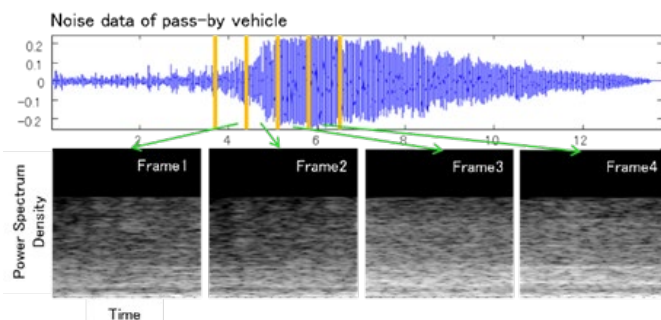


図 4 騒音データの事前処理方法

2. 2. 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは、畳み込み層、プーリング層、全結合層で構成される。畳み込み層では、特徴量の抽出を担っており、プーリング層では、畳み込み層で得られた特徴量を縮小してまとめるために用いられる。全結合層は、全てのノードが次のノードに結合されており、重みを用いて各分類の確率を計算する。本稿では、5 つの畳み込み層、3 つの全結合層、プーリング層に加え、ドロップアウト層、ソフトマックス関数から構成される AlexNet²⁾を使用した。ドロップアウト層では、過学習を防ぐためランダムに入力をゼロとし、ソフトマックス関数では、出力値を 0~1 の値に正規化する。図 4 に本研究で用いた深層学習の構成を示す。

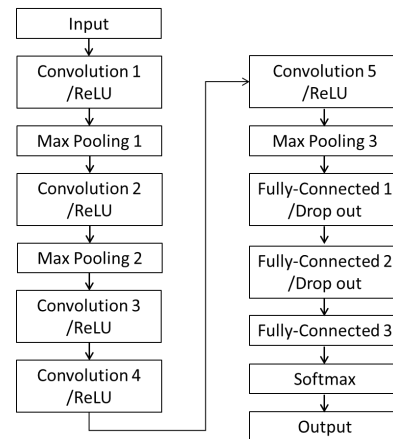


図 5 AI モデル作成のためのアルゴリズム

2. 3. 学習データの測定

一般的に、深層学習により AI モデルを作成する際には、既存のライブラリが使用される。しかし、本研究に必要なのは、近接排気騒音試験が規制値を超過する”不正改造車両”と規制値を超過しない”適法車両”の騒音データである。このようなデータセットは既存のものには存在しないため、テストコース上にて騒音測定を行った。試験車両は二輪車 3 台とし、それぞれの車両について、近接排気騒音試験の結果が規制値を超過するマフラーを 1 本ずつ用意し、純正マフラーとマフラーを交換した状態にて測定を行った。試験車両の走行方法は、車速、加速度、ギヤ位置等、任意とし、1 台ずつ順に測定を行った。得られた騒音データについて 2.1 に示した事前処理を行い、各分類について、それぞれ約 6000 枚の画像データを作成した。作成した画像データは、AI モデル作成のためのデータとして 80%使用し、残りの 20%は作成された AI モデルの

検証のために使用した。これらのデータの振り分けは、無作為に行った。

3. 学習データによる AI モデルの検証

深層学習では一般的に、“精度”と“損失”という観点にて、AIモデルの善し悪しを判断する。“精度”とは、正解か不正解かのうち、正解となる確率をあらわす。このような場合は、51%の確率で不正改造車と判定された場合も100%の確率で不正改造車両と判定された場合も同じ扱いとなる。一方、“損失”とは、予測値と実際の値の差を、関数を使用して評価するものであり、高精度なAIモデルであれば損失の値は小さくなる。

図6に、学習データを用いて50世代までAIモデルを作成した際の精度と損失を示す。また、学習データの結果はTrain、検証データの結果はValidationとして示す。この結果では、計算の初期段階から精度が高いモデルが作成されていることがわかる。また損失についても、計算の初期段階から低い値で安定していることがわかるが、30世代以降に値が増加する傾向となっており、学習データに対して過学習となっている可能性が考えられる。そのため、以降の検証においては、25世代目のAIモデルを用いることとした。




図6 AIモデルの精度及び損失

4. 公道を走行する車両の走行騒音による AI モデルの検証

前節で述べた検証は、得られたデータをランダムにAIモデル作成の学習用データと損失を計算するための検証用データに振り分けたため、完全に無関連のデータでの検証ではない。そこで、学習データと無関連なデータについて、作成したAIモデルの検証を行うべく公道にて二輪車の騒音測定を行った。公道での測

定は、暗騒音の低い山間部と暗騒音の比較的高い都市部にて実施した。

4. 1. 山間部での検証

学習データとは無関連のデータによってAIモデルの検証を行うため、山間部を走行する二輪車を対象とした街頭検査と並行して通過騒音の測定を行った。図7に走行騒音測定のための騒音計の設置場所と街頭検査実施場所の関係を示す。街頭検査は図の右下から左上へ走行する車両のみを対象としており、街頭検査実施場所より上流側にて、一般車両が通常走行している際の走行騒音を測定した。騒音計設置場所と街頭検査実施場所にはそれぞれ記録員が待機し、通過時刻と車両外観等から、走行騒音と近接排気騒音試験の結果を照合した。



図7 街頭検査場所と騒音計設置場所の関係

表1に、街頭検査員が判断した不正改造車/適法車の結果と、同時に取得した走行騒音に対しAIモデルを適用して判定した結果を示す。ここで示した各分類の確率は、車両が到来し通過するまでの騒音データに対する平均値である。検証の対象とした車両はいずれも学習データとは無関連な単独走行する二輪車は6台であり、そのうち5台を正しく予測している。いずれの車両も近接排気騒音試験の結果は規制値付近の値となっており、人の聴感では判定は困難であるが、AIモデルでは高精度に予測することができていることが確認された。

表1 山間部を走行する車両に対する検証結果

AIの予測した確率 [%]			AIの予測	街頭検査結果	近接排気騒音試験結果 [dB]
不正改造車両	適法車両	その他			
26.3	63.4	10.3	適法車両	適法車両	93
11.1	50.6	38.3	適法車両	不正改造車両	99
23.0	56.3	20.7	適法車両	適法車両	88
1.4	98.1	0.5	適法車両	適法車両	87
0.1	99.9	0.0	適法車両	適法車両	82
67.4	18.8	13.7	不正改造車両	不正改造車両	98

4. 2. 都市部での検証

次に都市部において、街頭検査と並行して測定を行った結果を示す。測定は、図7にて示した方法と同様に、街頭検査実施場所から離れた上流側の位置に騒音計を設置し、後に車両外観等から走行騒音と近接排気騒音試験の結果を照合した。表2に、合計20台の車両について測定を行った結果のうち、一部を示す。都市部で行った街頭検査はいずれも平日の昼間に行われたため、測定した全ての車両は、街頭検査員によるスクリーニングの結果、問題ないとされた車両であった。そのため、近接排気騒音試験を実施することなく適法車両と判定されている。一方、判定結果は、適法車両を不正改造車と誤判定することはなかったものの、適法車両をその他と判定することがあった。測定を行った20台のうち、正解率は60%であった。前項に示した山間部の測定では、暗騒音は極めて低くまた、車間距離は十分に取れていたため、作成したAIモデルの前提条件である単独走行する車両という点は十分に満たしていた。一方、都市部では生活騒音や突発音により暗騒音が高いことや車間距離が短いことによる他の車両の影響により、前提条件を十分に満たせず判定精度が低下したと考えられる。また山間部と比べて、都市部では対象車両の走行騒音と暗騒音の差が小さく、適法車両の特徴量として検出されなかった可能性がある。

表2 都市部を走行する車両に対する検証結果
(抜粋)

AIの予測した確率 [%]			AIの予測	街頭検査結果	近接排気騒音 試験結果 [dB]
不正改造車両	適法車両	その他			
0.5	99.1	0.4	適法車両	適法車両	実施せず
5.3	92.7	2.0	適法車両	適法車両	実施せず
12.4	37.1	50.4	その他	適法車両	実施せず
3.8	26.9	69.2	その他	適法車両	実施せず
3.5	76.1	20.4	適法車両	適法車両	実施せず
24.0	54.4	21.6	適法車両	適法車両	実施せず

5. おわりに

本稿では、研究の第一段階として、対象を単独走行する二輪車に限定してAIモデルを作成し、その検証を行った。その結果、前提条件を十分に満たす場合については、学習データとは無関連な一般の車両についても、車両情報や走行条件等の情報を与えることなく高精度に判定することができた。一方、暗騒音や他の車両の影響が混入すると考えられる都市部のような環境においては、精度の悪化が確認された。この対策

として、交通安全環境研究所がこれまでに開発してきた、マイクロホンアレイによる音源分離手法を活用することが考えられる。図8に、当該手法にて音源分離を行った結果の例を示す³⁾。図中の赤い領域が強い音源であることを意味しているが、この車両は改造がなく一定走行で走行していたため、前後のタイヤを別々の音源として捉えている。この音源分離手法を交通流へ適用して個々の車両騒音を分離し、本稿で紹介した手法を適用することにより、単独走行する二輪車という前提条件にとらわれず、交通流中から不正改造車両を検出可能なシステムを構築できると考えられる。交通安全環境研究所では、このようなシステムの実現に向けて、現在も研究を継続している。



図8 マイクロホンアレイによる音源分離結果の例

謝辞

本稿にて紹介した公道での測定の一部は、国土交通省殿のご協力により実施したものです。この場を借りて深く御礼申し上げます。

参考文献

- 1) 山崎孝章, “国土交通省における自動車の環境政策と国際基準調和について”, 交通安全環境研究所フォーラム2019講演概要集, (2019)
- 2) Krizhevsky et al., “ImageNet Classification with Deep Convolutional Neural Networks,” Proc. of Advances in Neural Information Processing Systems, (2012)
- 3) Houzu et al., “Development of Sound Source Localization System to Detect Noisy Vehicles from Traffic flow,” Proceeding of INTER-NOISE 2011, (2011)