

機械学習を用いた振動解析による自動車の異常振動検知

橋本 渉[†], 廣田 雅春^{††}, 荒木 徹也[†], 山本 幸生^{†††}, 恵木 正史[†], 山村 洋市^{††††}, 栗脇 悠一^{††††}, 石川 博[†]

[†] 首都大学東京大学院 システムデザイン研究科 〒191-0065 東京都日野市旭が丘 6-6

^{††} 岡山理科大学 総合情報学部 〒700-0005 岡山県岡山市北区理大町 1-1

^{†††} 宇宙航空研究開発機構宇宙科学研究所 〒252-5210 神奈川県相模原市中央区由野台 3-1-1

^{††††} アイシン・エイ・ダブリュ株式会社

コネクティッドソリューション部 〒444-8564 愛知県岡崎市岡町原山 6-18

E-mail: [†]{hashimoto-wataru,egi-masashi}@ed.tmu.ac.jp, {araki,ishikawa-hiroshi}@tmu.ac.jp,

^{††}hirota@mis.ous.ac.jp, ^{†††}yukio@planeta.sci.isas.jaxa.jp,

^{††††}{i35669_yamamura,i32661_kuriwaki}@aisin-aw.co.jp,

あらまし 日本では、カーシェアリングサービスの利用が進んでいる。その一方で、カーシェアリングの民間事業者へのヒアリングによって、「自動車のキズ」に関するトラブルが増加していることが分かった。そのため、キズの発生を検知、記録する技術の確立が急務である。従来、機械の異常を振動の波形や周波数特性などから検知をする研究は盛んに行われてきたが、自動車の場合はあらゆる場所で様々な振動が生じるため、新しいアプローチを検討する必要がある。そこで本研究では、機械学習を用いて走行中に発生する振動からキズが発生するような異常振動を自動的に検知する手法を提案する。複数の圧電センサを車内に配置し、取得した振動から特徴量を抽出して教師あり学習を適用することで自動車の異常振動を検知する。

Key words 振動解析, 教師あり学習, 異常検知

1. はじめに

日本では、カーシェアリングのサービス規模が急成長している [1]。図 1 に日本国内でのカーシェアリング車両台数と会員数の推移を示す (注1)。どちらもここ数年で急激増加していることがわかる。カーシェアリング普及の最も大きな要因として挙げられるのが利用者のコスト削減効果である。自動車を所有することに比べて、自動車の購入費用や税金、保険、維持費が必要ない事にメリットがある [2]。これに、昨今の経済不況も相まっ

て利用者増加に繋がっていると考えられる。

今後も成長が見込めるカーシェアリングサービスではあるが、一方で民間事業者にヒアリングを行なったところ、自動車の「キズ」に関する責任の所在が不明確になるトラブルが増えていることが分かった。従来、事業者の人々の目視によって自動車のキズの確認が行われていた。自動車の「凹み」、「擦り傷」、「ガリキズ」などの種類や大きさを、さらには自然発生的であるか人為的なものであるかなどの判断も必要となる。貸出ごとに事業者が自動車を整備するレンタカー事業とは異なり、カーシェアリングでは貸し出しおよび返却の現場を無人化するオペレーションになっている。事業者にとってそのオペレーションの中で、キズの発生やその原因を把握することは自動車を管理する上重要である。

現在、キズの検知を自動化する仕組みとして、自動車の全方位の画像を収集して機械学習などを用いて画像解析を行う仕組みがある [3]。利用前後の画像を機械学習を用いて比較、分析することにより精度の高いキズ検知を行えることが見込めるが、多様化するカーシェアリングなどのサービスでは大きな手間やスペースを取らないことも求められるため、新たなキズの検知の仕組みが必要である。

また、機械の異常を検知するアプローチとして一般的には振動解析が挙げられる [4]。機械にセンサを配置し、取得した振動の波形や周波数特性から異常を検知、その原因を推定する研究は盛んに行われている [5]。これらの研究では、そのほとんどが




図 1 カーシェアリング車両台数と会員数の推移より

(注1) : http://www.ecomo.or.jp/environment/carshare/carshare_graph2018.3.html




図 2 収集した各センサごとの振動波形 (上段) と, PSD (中段), MFCC (下段) の例

異常が発生すると考えられる場所にセンサを配置し, 数パターン程度の異常を検知している. 自動車の場合はあらゆる場所で振動が発生し, 様々な振動要因があると考えられるため, 一般的な機械の異常を検知するための研究を自動車のキズの検知に直接に適用することは困難であると考えられる.

そこで本研究では, 車体に複数の圧電センサを付けて図 2 上段のような振動データを収集し, 機械学習と振動解析を組み合わせることで自動的に振動から異常を検知する実験を行なった. 自動車の異常振動検知を異常であるかそうでないかの二クラス分類問題と捉え, 振動にラベルづけを行い教師あり学習を行うことで自動的に異常振動を分類し, 検知することを目指す. 異常振動とは想定される自動車の使用で発生する振動以外の振動である. また, 振動データから特徴量を生成し学習, 分類を行うことで自動車の異常振動検知に適した手法を検討する.

本論文は, 以下の構成に従う. 2 章では, 本研究に関連する研究について述べる. 3 章では, 提案手法について述べる. 4 章では, 実験結果を示し, 考察を行う. 5 章では, 本論文のまとめと今後の課題について述べる.

2. 関連研究

本章では, これまでの異常振動検知, 及び自動車のキズ検知に関連する研究について述べる.

まず, 異常振動検知を行なっている研究として近藤ら [5] のものが挙げられる. 機械学習を用いた振動解析による状態監視システムを構築し, 鉄道車両における異常振動検知を試みている. 異常が発生すると予測される列車内の各場所に加速度センサを配置し, 長期間振動データを取得する. 取得した振動データをオクターブバンド分析と主成分分析を行い, 正常データとの距離をもとに異常判定を行なっている.

機械学習を用いた振動解析の例として菊池ら [6] のものが挙げられる. 月震を対象とした分類タスクに対して振動から Power Spectral Density (PSD) を計算し, それを用いた機械学習を行う事で, 震源地分類性能の向上を図っている.

次に振動の一つである音を対象とした分類問題に対して機械学習を用いて解決を試みている研究として D-CASE [7] が挙げられる. D-CASE (Detection and Classification of Acoustic Scenes and Events) は, IEEE Signal Processing Society による後援の下, 音環境識別と音響イベント検出を行った競争型ワークショップである. このワークショップで採用されている音環境識別のためのベースラインシステムでは, 音響シーンを分類するために音データを Mel-Frequency Cepstrum Coefficients (MFCC) という特徴量に変換し, 教師あり学習として Gaussian Mixture Model (GMM) を用いて分類を行なっている.

また, 本研究とは異なるアプローチで行なっている自動車の自動検査システムの研究として鈴木ら [3] のものが挙げられる. 自動車の凹みを検知するためにカメラとプロジェクタを用いた位相シフト法による三次元計測器を作成し, 前面部及び後面部の三次元形状を取得する. 凹みが出来る前後の形状を比較することで凹みを検出することを試みている.

本研究では, 機械学習を用いた振動解析に着目して, 前述した鈴木ら [3] とは異なるアプローチで自動車の異常検知を行う.

3. 提案手法

本章では, 本研究で用いた, 特徴量および教師あり学習手法について述べる.

3.1 提案手法の処理の流れ

まず, 提案手法の処理の流れについて述べる. 提案手法の全体的な流れは図 3 のようになっており, 複数チャネルの入力を




図 3 提案手法の流れ




図 4 イベント検出

想定しており、振動データに対してイベント区間の検出を行う事で振動イベントが発生したと考えられる部分のみを入力として扱う。次に後述する方法で生成された高次元特徴量を振動の機械学習においてよく用いられてきた [7] [8] GMM に与えることで、異常振動を識別可能なモデルが作成し、異常振動検知を試みた。

3.2 イベント区間検出手法

本研究ではイベントが発生してる部分を抜き出すことでより性能の高い異常振動検知が行えると推測し、前処理として振動波形からイベント区間を検出することを試みた。手法としては地震のイベント区間検出で知られている STA/LTA (Short Term Average/Long Term Average) を用いた。図 4 上図の赤線と青線がイベント区間であり、図 4 下図の短時間平均、長時間平均の比および閾値で一意に決定される。

地震のイベント区間検出などでは STA/LTA のパラメータを決定する研究などが盛んに行われている [9] が、今回は非常に短い振動かつ多様波形動であったため、一意なパラメータでは網羅的にイベント区間を検出する事が困難であった。そこで本研究では、収集した振動データの中で目視でイベントが発生していると確認されたものに対して一つずつ STA/LTA のパラメータを設定する事でイベント区間の検出を行なった。

3.3 本研究で用いる特徴量生成手法

本研究では、以下の二つの特徴量を入力として用いた。

- PSD

表 1 振動データセット

異常振動のデータセット数	81(27 × 3 チャンネル)
正常な振動のデータセット数	87(29 × 3 チャンネル)
データの長さ	1 ~ 5 s
チャンネル数	3
サンプリング周波数	44.1kHz




図 5 車体センサ配置図

• MFCC

一つ目は周波数解析を参考にして PSD を計算したものを特徴量として使用する。PSD を計算することによって、波形の周波数ごとの強さを計算し、特徴量とすることができる。二つ目は D-CASE を参考にした MFCC [10] である。MFCC は人の聴覚特性を考慮した周波数特性の一表現であり振動波形に対し Fast Fourier Transform (FFT) を行い、結果のパワー成分の対数を取った値を Discrete Cosine Transform (DCT) したものである。

まず、図 2 のようにチャンネルそれぞれに対応する振動データの特徴量を計算する。振動データは時系列データなので、時間的に離れた振動の関係性が識別に関わってくると考えられる。そのため、時間情報を含む PSD 及び MFCC を用いる事で、識別性能の向上が見込めると考えられる。最後に特徴量を 3 チャンネルで連結することで空間情報を持った特徴量とする。

3.4 GMM

本研究では異常振動か正常な振動かを識別するモデルを作成する手法として GMM を用いた。GMM は入力された特徴量のラベルごとにガウス関数の和でモデルを作成する手法である。

4. 実験結果

本章では、それぞれの手法を用いて、異常振動検知を行い、その識別性能を評価する。

4.1 データセット

今回使用するデータセットの要件を表 1 に示す。異常振動を検知するために、図 4 のように車体に 3 つの圧電センサを設置し、振動データを収集した。振動データはサンプリング周波数

表 2 パラメータ設定

次元	PSD 振動の長さにより変化 (× 3) MFCC 60 次元 (× 3)
フレーム長	40ms
フレーム周期	20ms




図 6 実験結果 (PSD)

44.1kHz で自動車の走行中, 徐行中, 停車中にそれぞれ発生する振動を記録した. 異常振動のデータセットは 81 件 (27 セット × 3 チャンネル), 正常な振動のデータセットは 87 件 (29 セット × 3 チャンネル) を使用した. 振動のデータは, 正常な振動では走行中の振動から車止めやハッチを閉めた振動などを幅広く収集した. 異常振動は主に投石や金属の棒で車体を叩いた音などを収集した. それぞれのデータは約 1~5 秒ほどの短い振動である.

4.2 実験条件

表 2 は特徴量の条件を示している. どちらの特徴量でもフレームの分析におけるフレーム長とフレーム周期はそれぞれ 40ms と 20ms である. 今回用いた PSD のサンプリング数を 1,024 点とした. また, MFCC は DCASE 2017 Challenge のベースライン^(注2)で用いられているものを参考に 20 次元 MFCC とその一次差分, 二次差分の計 60 次元をベースとする. 一次差分及び二次差分を用いる事でより詳細な情報を持った特徴量となる. 車体の各場所に付けた 3 チャンネルの PSD 及び MFCC の連結によって特徴量を作成した.

今回は訓練用データセットと評価用データセットをランダムに 7:3 に分けて accuracy を求める事で異常検知の精度を検証する実験を行なった. また, データセットの数も考慮して試行を 5 回行いそれぞれの Accuracy の平均値を結果とした.

4.3 実装

振動解析の実装には, Python のライブラリである librosa [11] を用いた. GMM の実装には, Python のライブラリである scikit-learn [12] を用いた.

4.4 実験結果

実験結果を図 6, 7 に示す. それぞれの特徴量におけるチャンネル結合なしかつイベント検出なし, チャンネル結合ありかつイベント検出なし, チャンネル結合ありかつイベント検出ありの 3 パ




図 7 実験結果 (MFCC)




図 8 投石 (左) とハッチ (右) の特徴量

ターンの実験結果で, 「all」が全体の accuracy, 「out」が異常振動の accuracy, 「safe」が正常な振動の accuracy を表している.

結果を見ると二つの点が精度に影響を与えている事が分かる. 一点目は特徴量の種類である. 結果を見て分かるように PSD では異常振動の識別精度が高くなり, それに比べて正常な振動の識別精度が低くなっている事が分かる. これは機械学習によって作られたモデルが異常振動に偏っていると推測できる. 一方で MFCC では異常振動に偏っているが, 正常な振動の識別精度も PSD に比べて良い実験結果が得られたと言える.

二点目はチャンネル結合の有無である. チャンネルを結合した方が, チャンネルを結合してないよりも精度が高くなった. これは入力として各チャンネルで収集した振動データを別々に用いるよりも結合して用いた方が空間情報などを得られるため識別精度の向上に繋がると考えられる.

一方でイベント区間を検出すると異常振動が発生している部分のみを入力として扱えるため識別精度が向上すると仮説を立てていたが, 結果としてはイベント検出をしない場合に比べて精度が悪くなった. これは振動のイベントが発生した前後の振動が変化しているなど, イベントが発生していない部分も特徴量としては識別に重要な部分であったと推測でき, 今回の振動データはデータの長さがある程度揃えているため, 区間を検出しない方が識別精度が高かったと考えられる.

5. まとめ

本稿では機械学習を用いた自動車の異常振動検知手法を提案した. 様々な振動データを収集して実験を行い, 提案手法の有効性を確認した. 提案手法において特徴量として MFCC, チャンネル結合あり, イベント検出なしで分類を行った場合がもっと高い accuracy となった.

(注2): <https://tut-arg.github.io/DCASE2017-baseline-system/index.html>

今後の課題として、誤分類する確率の高い振動データを可視化して確認した結果、正常な振動の中でイベントが発生し強く揺れを起こすものが多い事がわかった。図8のように特徴量を比較しても、目視では識別が難しい事が分かる。これらの振動を正しく分類する手法を検討する。

6. 謝 辞

本研究は、首都大学東京傾斜的研究(全学分)学長裁量枠戦略的研究プロジェクト戦略的研究支援枠「ソーシャルビッグデータの分析・応用のための学術基盤の研究」及び JSPS 科研費 6K00157, 16K16158 による。

文 献

- [1] 安江勇弥, 金森亮, 山本俊行, 森川高行. カーシェアリング会員特性と利用意向に関する分析. 土木学会論文集 D3 (土木計画学), Vol. 69, No. 5, pp. I-761–I-770, 2013.
- [2] 三井亨保, 外井哲志. わが国におけるカーシェアリング事業の実態. *IATSS Review*, Vol. 32, No. 2, pp. 140–148, 2007.
- [3] 鈴木貴大, 田口亮, 服部公央亮, 保黒政大, 梅崎太造ほか. H-038 三次元形状計測を用いた自動車ボディに対する自動形状検査 (h分野: 画像認識・メディア理解, 一般論文). 情報科学技術フォーラム講演論文集, Vol. 13, No. 3, pp. 151–152, 2014.
- [4] 鈴木英明, 内山宏樹, 湯田晋也. データマイニングによる異常検知技術. オペレーションズ・リサーチ 経営の科学, Vol. 57, No. 9, pp. 506–511, 2012.
- [5] 近藤稔, 高重達朗, 真鍋慎一, 菅野晋. 振動による状態監視手法を用いたディーゼルエンジン異物混入時の異常振動検知. 鉄道総研報告, Vol. 30, No. 4, pp. 47–52, 2016.
- [6] 菊池栄, 山田竜平, 山本幸生, 横山昌平, 石川博. 月震分類に適した機械学習手法の検討. 第8回データ工学と情報マネジメントに関するフォーラム, G4-1, 2016.
- [7] Annamaria Mesaros, Toni Heittola, Aleksandr Diment, Benjamin Elizalde, Ankit Shah, Emmanuel Vincent, Bhiksha Raj, and Tuomas Virtanen. Dcase 2017 challenge setup: Tasks, datasets and baseline system. In *DCASE 2017-Workshop on Detection and Classification of Acoustic Scenes and Events*, 2017.
- [8] 高橋玄, 山田武志, 小野順貴, 牧野昭二. Dnn-gmm と連結特徴量を用いた音響シーン識別の検討. 日本音響学会 2017 年春季研究発表会, 2-P-1, 2017.
- [9] Amadej Trnkoczy. Topic understanding and parameter setting of sta/lta trigger algorithm. *New manual of seismological observatory practice*, Vol. 2, , 1999.
- [10] 平松綾子, 能勢和夫ほか. ニューラルネットによる音源の特性についての検討. 第77回全国大会講演論文集, Vol. 2015, No. 1, pp. 269–270, 2015.
- [11] Brian McFee, Matt McVicar, Stefan Balke, Carl Thomé, Vincent Lostanlen, Colin Raffel, Dana Lee, Oriol Nieto, Eric Battenberg, Dan Ellis, Ryuichi Yamamoto, Josh Moore, WZY, Rachel Bittner, Keunwoo Choi, Pius Friesch, Fabian-Robert Stöter, Matt Vollrath, Siddhartha Kumar, nehz, Simon Waloschek, Seth, Rimvydas Naktinis, Douglas Repetto, Curtis "Fjord" Hawthorne, CJ Carr, João Felipe Santos, JackieWu, Erik, and Adrian Holovaty. librosa/librosa: 0.6.2, August 2018.
- [12] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, Vol. 12, pp. 2825–2830, 2011.