

車道における水はね検知に向けた 音響センシングの初期的検討

白戸 拓^{1,a)} 金澤 玲実² 石田 繁巳¹ 白石 陽¹

概要: ドライバーは道路交通法に基づき、雨天時には車両から周囲に水滴を飛散させる「水はね」の回避に努める必要がある。しかし、雨天時には水はねを発生させる路面状況を見落とししたり、発見が遅れて突発的な回避を強いられたりする場合がある。そこで本研究では、個々の車両が水はねの発生を自動で検知したうえで集合知を形成し、他のドライバーに水はねの発生状況を共有するシステムを提案する。本稿ではその一環として、音響センシングを用いた水はね検知手法を示す。本手法では、水はね発生時の音響データから複数の音響特徴量を抽出し、教師あり学習を用いて水はねを検知する。函館市内の公道を走行して収集した音響データを用いて評価した結果、F 値 90%以上という精度で水はねを検知できることを確認した。

キーワード: 音響センシング, 水はね, マイクロフォン

1. はじめに

自動車が水たまりを走行した際に発生する「水はね」は、歩行者の衣服や持ち物を汚損させる原因となる。ドライバーは水はねを回避する義務があるが、視界不良下では水はねの原因である水たまりに気づかないことがあり、完全に回避することは難しい。

ドライバーが水はねを回避するためには、経路上での水はねの危険性を事前に把握する必要がある。そのためには、水はねの危険性をドライバーに共有するシステムの実現が望まれる。本研究は、水はねの発生状況から集合知を形成し、ナビゲーションシステム上で共有する「水はね情報共有システム」の構築を目指す。

「水はね情報共有システム」を実現するためには、水はねの発生を検知する仕組みが必要である。しかし、水はねそのものを検知する手法は、筆者らが調査した範囲では存在しない。水はねの原因となる水たまり、および路面の異常を検知する手法は複数提案されているが[1]~[4]、視界不良下や路面状況の変化に対するロバスト性、もしくは経済的コストに問題がある。また、浅い水たまりや車道外の水たまりなど、水はねの原因とならない水たまりを過剰に検

知する可能性がある。

本研究では、これらの問題点に対する解決策として、音響センシングによる水はね検知手法を示す。本手法では、車内に設置したマイクロフォンで収集した音響データから水はねの発生を示す音響特徴量を抽出し、教師あり学習により水はねを検知する。音響センシングを用いることで、雨天時・夜間などの視界不良下や、路面状況の異常がない地点における水はねの検知が可能となることが期待できる。また、本研究では一般的なマイクロフォンを用いるため、低コストに実現可能となることが期待できる。

本稿では、初期的検討として、収集した音響データから2種類の音響特徴量を抽出し、それぞれを用いて水はねの有無を分類する機械学習モデルを作成・評価する。本稿の構成は以下のとおりである。2. では水はねの検知に関する関連研究について述べ、3. では水はね発生時の音響データを分析する予備実験について示し、4. では提案する水はね検知手法について説明する。5. では、水はね検知を行う機械学習モデルを作成・評価する。最後に6. でまとめとする。

2. 関連研究

2.1 水たまりの検知に関する研究

筆者らが調査した範囲では、水はねを検知する手法は提案されていない。類似の研究として、画像処理により水たまりを検知する手法が提案されている[1],[2]。

Hanらは、画像上の水たまりの水面が周囲の景色を反射によって映し出す性質を用いて、水たまりを検知した[1]。

¹ 公立はこだて未来大学システム情報科学部
School of Systems Information Science, Future University
Hakodate

² 公立はこだて未来大学大学院システム情報科学研究科
Graduate School of Systems Information Science, Future
University Hakodate

a) b1019116@fun.ac.jp

Kim らは、ステレオカメラ画像から作成した深度マップ上において、水たまり箇所は、その周辺と比較して外れ値的に深度が深いことを利用し、水たまりを検知した [2].

水はねの多くは水たまりが原因で発生するため、水たまりの検知は、水はねの検知に応用できる可能性がある。しかし、これらの手法は、水たまりの水面が乱れる雨天時、および光量が不足する夜間などの視界不良下では適用できない。また、水たまりを検知する手法は、浅い水たまりや、車両が通過しない地点の水たまりなど、水はねを発生させない水たまりを過剰に検知する可能性がある。

2.2 路面の異常検知に関する研究

路面に形成される轍やひび割れ、穴などの異常を検知する手法が提案されている [3], [4].

Basavaraju らは、自動車に取り付けたスマートフォンに搭載された加速度・角速度センサから取得したデータに機械学習を用いることで道路上を横断するひび割れ、および穴を検知した [3]. Han らは、路面に向かって横一列に照射したレーザ光の反射を CCD センサで観測し、反射光の形から路面上の轍の深さを推定する手法を提案した [4].

水はねの原因である水たまりは、このような路面の異常が生じた部分に水が滞留して発生することがある。そのため、路面の異常から水たまりの発生を予測することで、水はねの検知に応用できる可能性がある。しかし、Han らの手法 [4] は、CCD センサを搭載した専用の車両が必要となるため、経済的コストが高い。また、水たまりは、道路周辺の排水性の良し悪しなど路面の異常に影響されない環境でも発生しうる。これらの手法では、そのような地点における水たまりの発生を予測できないため、路面状況の変化におけるロバスト性が低いといえる。

2.3 音響センシングに関する研究

路面の状態を音響センシングにより識別する研究が行われている [5]~[7].

Abdić らは、車両の後輪付近に設置したマイクロフォンから車両走行時の音響データを収集し、路面の乾燥・湿潤状態を分類する機械学習モデルを作成した [5]. この研究では、車外にマイクロフォンを設置しているため、周囲の車両や施設からの環境音が観測対象となる音響データに干渉している可能性がある。本研究では、比較的環境音の少ない車内にマイクロフォンを設置することにより、環境音の影響を抑制する。

金澤らは、歩行者が所持するスマートフォンを用いて収集した歩行音の音響データから、湿潤・乾燥・凍結などの路面状況を推定した [6], [7]. 文献 [7] では、先行研究 [6] の調査に基づき、歩行音の特徴が表れる低周波領域に着目した音響特徴量を抽出した。本研究においても収集した音響データに対して周波数ごとの特徴を分析し、適切な音響

特徴量を検討する。

3. 予備実験

本章では、水はね発生時における音響の特徴を明らかにすることを目的とした予備実験について述べる。

3.1 音響データの収集

データ収集は函館市内の公道で行った。1人のデータ収集者が雨天時の深夜に実験車両で走行し、音響データを録音した。実験車両はトヨタ・ラクティスである。データ収集時には実験車両周辺にほぼ走行車両は存在しなかった。図 1 に示すように、車両の後部座席部分に左右 2 台のマイクロフォンを設置し、録音機器 (ZOOM Q2N-4K) を用いて車内からの走行映像とともに音響データを収集した。録音時のサンプリング周波数は 44.1kHz、ビット長は 16bit である。走行映像を参照しながら収集した音響データから水はね発生時を基点としてその前後 5 秒間の音響データを切り取った。録音はステレオで行ったが、音響データの分析では車両左側に設置したマイクロフォンの音響データのみをモノラル音源として抽出して用いた。

3.2 音響データの分析

3.2.1 水はねの判定基準

本稿において検知の対象となる水はねは、「自動車のタイヤによって路面上の水が巻き上げられ、窓ガラス越しに車内からその水滴が確認できる状態」とする。水はね非発生時の車内および車外を撮影した画像を図 2 に示す。また、水はね発生時の車内および車外を撮影した画像を図 3 に示す。

3.2.2 スペクトログラム分析

分析では、水はね発生前後 10 秒間のデータに対し、Python プログラムを用いて、横軸を経過時間、縦軸を周波数、色の变化を相対的な音響の強さとして表現したスペクトログラムを作成した。作成したスペクトログラムを図 4 に示す。その後、作成したスペクトログラムおよび走行映像を照らし合わせ、スペクトログラム上にて水はね発生箇所・非発生箇所を特定した。結果として、走行映像と照合した際に、映像の 5.0 秒時点から 6.0 秒時点において、水はねの発生が車内から確認できた。

その時点のスペクトログラムを確認すると、比較的低周波となる 0.1kHz 付近から 12.5kHz 付近の領域において、その前後の時点よりも音響が強くなっていることが確認できた。

3.2.3 スペクトル包絡分析

図 4 内において、水はね発生時である 5.0 秒時点から 6.0 秒時点の音響、および水はね非発生時である 4.0 秒時点の音響のそれぞれ 1 箇所について、16,384 サンプル (約 0.37 秒) を抽出し、対数パワースペクトルを作成した。さらに、

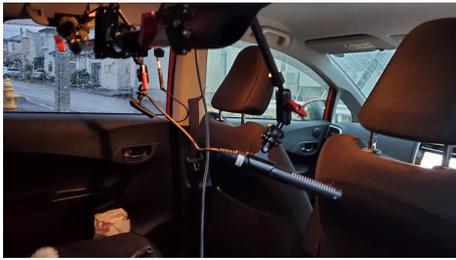


図 1 実験車両内に設置されたマイクロフォン



図 2 水はね非発生時の車内および車外



図 3 水はね発生時の車内および車外

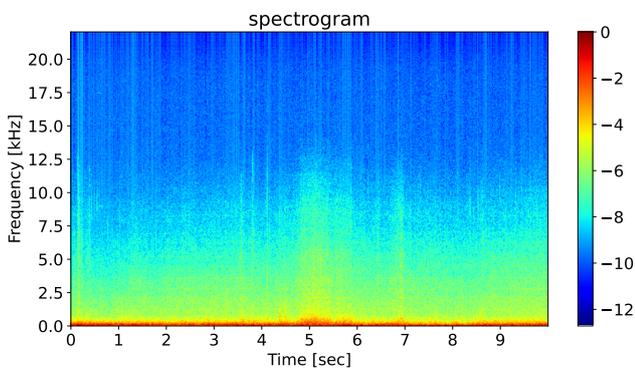


図 4 水はね発生前後 10 秒間の音響のスペクトログラム

作成した対数パワースペクトルに対し逆フーリエ変換を行い、求めたケプストラムに対して低ケフレンシ領域を切り取ることで、スペクトル包絡図(横軸: 周波数, 縦軸: 振幅の絶対値を 2 乗して自然対数を取った値)を作成した。作成したスペクトル包絡図を図 5 に示す。水はね発生時・非発生時それぞれのスペクトル包絡を比較することで、水はね発生時の音響に関する周波数ごとの特徴を分析した。

水はね発生時・非発生時のスペクトル包絡を比較すると、水はね発生時のスペクトル包絡は、水はね非発生時のスペクトル包絡よりも、0.1kHz 付近から 12.5kHz 付近にかけて縦軸方向の値が大きくなっていることが確認できた。こ

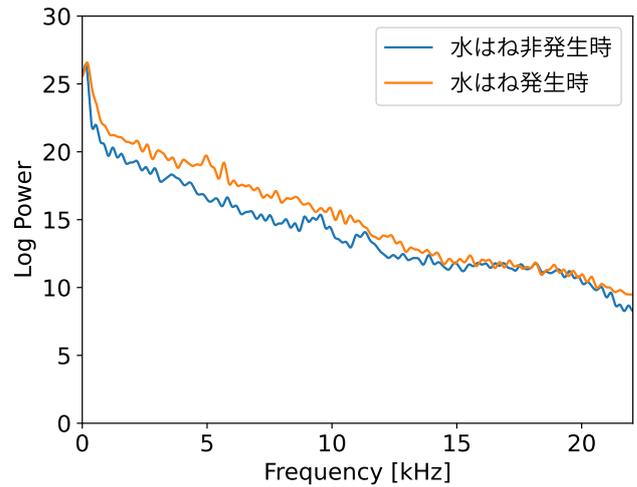


図 5 水はね発生時・水はね非発生時の音響のスペクトル包絡

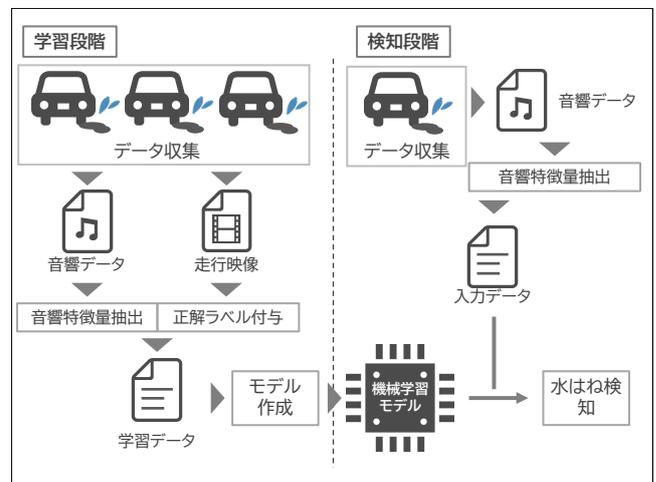


図 6 水はね検知の流れ

れは、前項にて行ったスペクトログラムに対する分析と同様の結果となった。また、5kHz 付近から 11kHz 付近においては、特に水はね発生時・非発生時間の差異が大ききことが確認できた。

4. 車載マイクロフォンを用いた水はね検知手法

4.1 水はね検知の流れ

図 6 に示すように、水はね検知手法は 2 段階で構成される。学習段階では、車両で収集した音響データから正解ラベル付きの音響特徴量を抽出し、それらを学習データとして機械学習モデルを作成する。検知段階では、収集した音響データから音響特徴量を抽出し、学習段階で作成した機械学習モデルに入力することで、水はねを検知する。

段階内における各処理について以下に詳述する。学習段階のデータ収集時には、音響データとともに走行映像を収集する。音響特徴量の抽出処理では、収集した音響データを数十ミリ秒から数百ミリ秒の短時間ごとにフーリエ変換し、適切なフィルタを用いて音響特徴量を抽出する。学習

データの作成時には、走行映像と照らし合わせることで、同時に正解ラベルを付ける。機械学習モデル作成処理では、学習データに対し、教師あり学習を用いてモデルを作成する。水はね検知処理では、ラベルの付いていない音響特徴量を、学習段階で作成した機械学習モデルに入力する。出力結果として、水はね発生の有無を分類した結果を取得することで、水はねを検知する。

4.2 音響特徴量

水はねの検知においては、以下に示す2種類の音響特徴量を用いる。

- (1) MFCC (Mel-Frequency Cepstral Coefficient)
- (2) LFCC (Linear-Frequency Cepstral Coefficient)

(1) の MFCC は、人間の聴覚特性であるメル尺度を模して低周波領域の分解能を高く、高周波領域の分解能を低く表現する音響特徴量である。音響データのスペクトルに対し、図7に示すメルフィルタバンクを掛け合わせて畳み込み、離散コサイン変換を行うことで抽出する。本研究では、20次元のMFCCを抽出した後、水はね検知に影響しない最低次元を取り除いた19次元を用いる。文献[6],[7]では、音響データの特徴が低周波領域に表れることに着目し、MFCCを抽出した。本稿の予備実験の結果からも、水はね発生時は比較的低周波領域の音響が強くなることが認められた。したがって、低周波領域の解像度が高いMFCCを用いることで、水はねの音響特徴を適切に抽出可能であると考える。

(2) の LFCC は、全周波数領域の分解能を均一とした音響特徴量である。スペクトルを畳み込む際にメルフィルタバンクを用いるMFCCに対し、LFCCでは図8に示す線形フィルタバンクを用いる。本研究では、MFCCと同じく20次元のLFCCから最低次元を除いた19次元を用いる。LFCCは、MFCCと比較して周波数領域ごとの分解能を変化させない場合における水はね検知の精度について調査するために採用した。

4.3 機械学習アルゴリズム

本研究では、水はねを検知するための機械学習アルゴリズムとしてSVM (Support Vector Machine) を用いる。水はねの発生は車両走行時の降雨量に左右されるため、機械学習モデル作成の時点で多くのデータ数が集まらない可能性がある。そこで、比較的少数のデータから高精度なモデルを作成可能なSVMを採用する。

5. 機械学習モデルの作成・評価

本章では、水はね検知における音響センシングの有効性、およびMFCC・LFCCの各音響特徴量による水はね検知の精度を評価することを目的とし、音響特徴量抽出、および機械学習モデルの精度分析を行った実験について述べる。

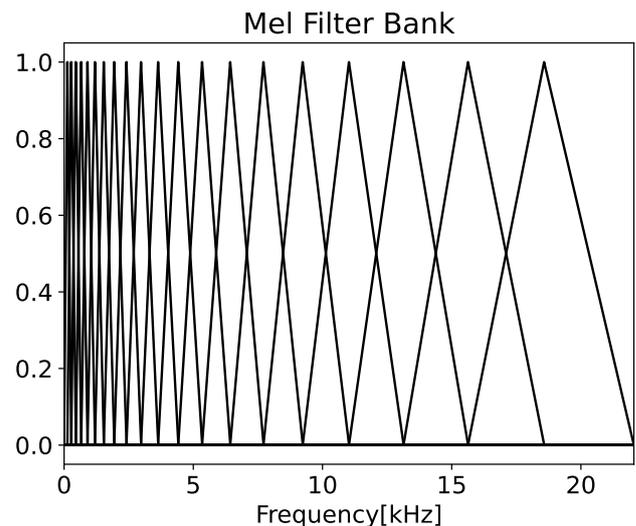


図7 メルフィルタバンクのイメージ

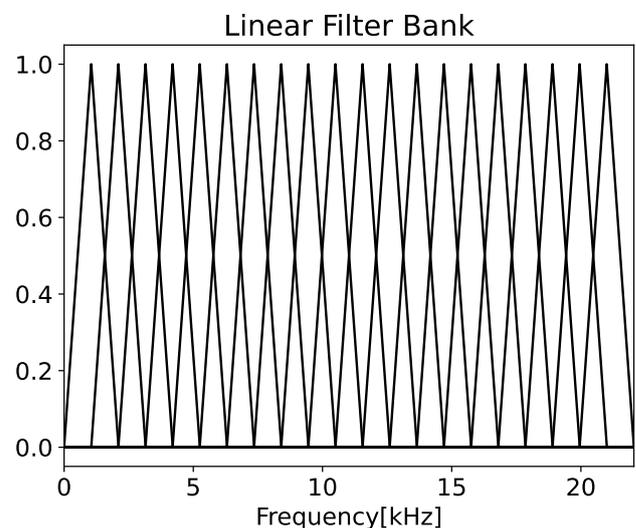


図8 線形フィルタバンクのイメージ

5.1 実験環境

5.1.1 音響データ

本実験の機械学習モデルで使用する学習データは、2022年9月19日、20日の夜間に函館市内の公道を実験車両で走行することで収集した。音響データの収集に用いた機材は、予備実験で用いたものと同一であった。

データの収集後、走行時の映像、およびスペクトログラムと照合しながら、収集した音響データの水はね発生前後10秒間を切り出した。切り出した音響データに対し、Pythonを用い、データ1件あたりをフレームサイズ16,384サンプル(約0.37秒)、フレームシフト50%として音響特徴量を抽出した。特徴量抽出と同時に、当該の音響データから作成したスペクトログラム、および走行映像との照合を行うことで、水はね発生時・非発生時のいずれかに正解ラベルを付けた。最終的に取得したデータのうち、水はね発生時の音響データ100件、水はね非発生時の音響データ100

表 1 機械学習モデルの 5 分割交差検証結果

音響特徴量	正解率	適合率	再現率	F 値
MFCC	94.5%	93.2%	96.0%	94.6%
LFCC	98.0%	96.3%	100.0%	98.1%

件の計 200 件を機械学習モデルの学習データとして使用した。

5.1.2 評価指標

作成した機械学習モデルに対し、5 分割交差検証により評価を行った。5 分割交差検証においては、使用する 200 件のデータを 5 分割し、4 グループを学習データ、1 グループをテストデータとした。学習データとテストデータの組み合わせを変えて検証を 5 回繰り返した平均値を評価の対象とした。今回の評価では、正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、および F 値を評価した。

5.2 実験結果

作成した機械学習モデルの検証により得られた結果を表 1 に示す。MFCC、および LFCC のいずれの場合においても、90%以上の F 値が得られた。また、LFCC は、正解率、適合率、再現率、F 値のいずれにおいても 95%以上の高い精度が得られた。LFCC は、MFCC と比較して正解率、適合率、再現率、F 値の各値においてそれぞれ 3.5%、3.1%、4.0%、3.5%上回った。

5.3 考察

MFCC、および LFCC のいずれの音響特徴量においても、作成した機械学習モデルが高精度を示したことから、本研究で示した音響センシング手法は、水はねの検知に対し有効であることが示唆された。このような結果が得られた要因として、MFCC、および LFCC の両方が、スペクトル包絡から求められる音響特徴量であるため、水はね発生時の音響が示す 0.1kHz 付近から 12.5kHz 付近の特徴を捉えていたことが考えられる。

しかしながら、本実験の結果では、MFCC、および LFCC における精度に差が生じたことから、周波数ごとの分解能に関する違いが、水はねを検知する機械学習モデルの精度に影響することが示唆された。特に、MFCC の精度に関する各値が LFCC を下回っていた点においては、MFCC の分解能が高い 5kHz 以下の領域と、水はね発生時の特徴が著しい 5kHz 付近から 11kHz 付近の領域が重なっていないことが原因と考えられる。これに対しては、水はねの特徴が表れる領域の分解能を高めたフィルタバンクを作成し、特徴量抽出を行うことが有効であると考えられる。

また、今回の実験では、深夜において、他車両が少ない理想環境下でデータ収集を行った。今後は、周囲環境の変化に対応した汎用的なモデルの作成を目指す必要があると考える。

6. まとめ

本稿では、車載マイクロフォンを用いた水はね検知手法の提案を目的とした初期的検討を行った。具体的には、車両に搭載したマイクロフォンの音響データから音響特徴量 MFCC、および LFCC を抽出し、SVM による機械学習モデルを作成・評価した。評価の結果、いずれの音響特徴量を用いた場合においても、高い精度で水はねを検知することができた。しかしながら、実験結果から、水はねの音響が示す特徴を効果的に反映させるフィルタバンクの作成、および周囲環境の変化に対応した汎用的な機械学習モデルを作成する必要性が示唆された。今後は、これらの実験パラメータを考慮したうえで、音響特徴量抽出手法、および機械学習モデルの改善を行う。

謝辞 本稿で示した研究の一部は、JSPS 科研費 (JP20K11793) の助成で行われた。

参考文献

- [1] Han, X., Nguyen, C., You, S. and Lu, J.: Single Image Water Hazard Detection using FCN with Reflection Attention Units, *European Conference on Computer Vision (ECCV) 2018*, pp. 105–121 (2018).
- [2] Kim, J., Baek, J., Choi, H. and Kim, E.: Wet Area and Puddle Detection for Advanced Driver Assistance Systems (ADAS) Using a Stereo Camera, *International Journal of Control, Automation and Systems*, Vol. 14, No. 1, pp. 263–271 (2016).
- [3] Basavaraju, A., Du, J., Zhou, F. and Ji, J.: A Machine Learning Approach to Road Surface Anomaly Assessment Using Smartphone Sensors, *IEEE Sensors Journal*, Vol. 20, No. 5, pp. 2635–2647 (2020).
- [4] Han, J., Cui, L. and Shi, S.: Road Rut Detection System with Embedded Multi-Channel Laser Sensor, *The International Journal of Advanced Manufacturing Technology*, pp. 1–10 (2021).
- [5] Abdić, I., Fridman, L., Brown, D. E., Angell, W., Reimer, B., Marchi, E. and Schuller, B.: Detecting Road Surface Wetness from Audio: A Deep Learning Approach, *International Conference on Pattern Recognition*, pp. 3458–3463 (2016).
- [6] 金澤玲実, 石田繁巳, 白石陽: スマートフォンを用いた音響センシングによる歩道路面状況推定に向けた特徴量の検討, 情報処理学会研究報告, Vol. 2021-ITS-87, No. 23, pp. 1–6 (2021).
- [7] 金澤玲実, 石田繁巳, 白石陽: スマートフォン内蔵マイクを用いた歩道路面状況推定における汎用性の向上に向けた改善, 第 30 回マルチメディア通信と分散処理ワークショップ論文集, pp. 105–111 (2022).