

推薦論文

車載マイクロフォンの音響データを用いた水はね検知手法

白戸 拓^{1,a)} 石田 繁巳² 白石 陽²

受付日 2024年5月7日, 採録日 2024年11月1日

概要: 車両が水たまり通過時に発生させる「水はね」により、歩行者の衣服や持ち物が汚損することがある。ドライバーは水はねの回避に責任を負うが、事前に水たまりを把握していないことで水はねが発生させることがある。本研究では、ドライバー間で事前に水はねの発生状況を共有し、回避を促進するシステムの構築を目指す。本稿では、システムの実現に向け、車載マイクロフォンの音響データに教師あり学習を用いて、歩行者に被害をおよぼす水はねを検知する手法を提案する。音響データの使用により、カメラや加速度センサで検知できない状況においても、低コストで水はねを検知できる。筆者らは、音響特徴量として低周波領域を反映する MFCC (Mel-Frequency Cepstral Coefficient) を用い、教師あり学習により車内で収集した音響データを「水はね」・「非水はね」の2クラスに分類した。結果、理想環境および実環境それぞれにおける評価で F 値約 90%前後の高い精度で水はねを検知した。

キーワード: 水はね検知, 音響特徴量, 機械学習, マイクロフォン

Water-splash Detection Method Using Acoustic Data From a Car-mounted Microphone

TAKU SHIROTO^{1,a)} SHIGEMI ISHIDA² YOH SHIRAISHI²

Received: May 7, 2024, Accepted: November 1, 2024

Abstract: Vehicles passing on puddles cause ‘water splashes’, that can damage pedestrians’ clothing and belongings. Although drivers are responsible for avoiding water-splashes, they sometimes mistakenly cause water-splashes due to a lack of awareness. In this study, we aim to construct a system that shares information about water-splashes among drivers so that they could avoid water-splashes. In this paper, we present a method that detects damaging water-splashes for pedestrians with supervised learning using acoustic data recorded with car-mounted microphones. Our method takes advantage of acoustic data to detect water-splashes at low cost in hard situations in which we cannot use cameras or accelerometers. We classified the acoustic data collected inside a vehicle into two classes: ‘splashing’ and ‘not splashing’ using a kind of acoustic feature ‘Mel-Frequency Cepstral Coefficient (MFCC),’ which reflects low-frequency ranges. Finally, we achieved an F measure of approx. 90% in ideal and real environment respectively, confirming the effectiveness.

Keywords: water-splash detection, acoustic features, machine learning, microphones

1. はじめに

車両が水たまりを通過する際に水滴が巻き上げられることによって発生する「水はね」は、歩行者の衣服や持ち物

を汚損させる要因となる。日本の道路交通法第七十一条 [1] においては、歩行者への被害を防ぐために、水はねを発生させないように走行することがドライバーの遵守事項として定められており、違反した場合は反則金が科せられる。日本自動車連盟 (JAF) のサイト [2] でも、轍状の水深 1 cm の水たまりを時速 40 km で通過する際に、側方 2 m の水は

¹ 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, Hakodate, Hokkaido 041-8655, Japan

² 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, Hakodate, Hokkaido 041-8655, Japan

a) g2123030@fun.ac.jp

本論文の内容は 2023 年 7 月のマルチメディア、分散、協調とモバイル (DICOMO2023) シンポジウムで報告され、高度交通システムとスマートコミュニティ研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

ねが発生することが報告されており、水たまり走行時の注意事項が示されている。また、道路上の水たまりは道路舗装とも関係するが、土木研究所の道路舗装に関する調査によると、沿道住民への「不安や危険を感じる事象」というアンケートに対して、半数以上の住民が「水はね」をあげている [3]。このように歩行者への水はね被害は社会的問題として認識されており、学術的にも、水はね被害防止に向けた取り組みとして、車両走行により発生する「水はね」の現象分析に関する研究も行われている [4], [5]。

水はね被害の低減に向けた取り組みとしては、法整備による注意喚起、苦情マップによる注意喚起、道路の修繕など様々な取り組みが考えられる。法整備 [1] による注意喚起については、前述したとおりであるが、ドライバーが十分注意して運転していたとしても、雨天時の視界不良や前方走行車両の存在などにより、水はねを発生させる水たまりの見逃しや発見の遅れが生じ、意図せず水はねを発生させてしまうことがある。加えて現状では、水はね被害が発生しても対象車両が走り去ってしまい、対象車両の特定が難しく、損害賠償やクリーニング代の請求も難しい状況にある。歩行者からの報告に基づく苦情マップによる注意喚起については、SNS などの活用による情報共有は考えられるが、水はねが発生していても、歩行者が存在しない場合は報告がないため情報として不十分である。さらに、専用車両による道路パトロール [6] により損傷箇所の点検・修繕が行われているが、道路の修繕には時間を要するため即時性は高くない。そのため、歩行者へ被害を及ぼしうる「水はね発生箇所」を網羅的かつ効率的に把握し、安全運転のための情報としてドライバーに提供するための枠組みが不可欠である。

そこで本研究では、プローブ情報システムのアプローチをとり、水はね発生箇所の情報を収集し、共有することを想定する。プローブ情報システムは、対象エリア内を走行する多数の車両からセンサ情報と位置情報を収集・処理する情報共有基盤であり、様々な分野で利活用が進んでいる [7]。水はね被害の低減においても、各車両にて水はねを検知し、その発生箇所の情報をドライバー間で共有するアプローチが有効と考える。これにより、網羅的かつ即時性の高い情報共有が可能となるため、ドライバーは、水はねの発生箇所を通過前に確認し、徐行など水はね発生防止に向けた運転行動をとることができる。プローブ情報システム実現のためには、ネットワークを介した情報収集の方法や、収集した情報のドライバーへの共有方法の検討も必要であるが、本稿では、各車両が持つべき必須機能である水はねを検知する方法について議論する。

本研究に関連する研究としては、水はねそのものを検知する研究 [8]、水はね発生の要因となる水たまりを検知する研究 [9], [10], [11], [12], [13], [14], [15]、水たまりが形成されやすい路面異常箇所を検知する研究 [16], [17], [18], [19]

があげられる。水はね検知に関する研究として、道路上に設置された固定カメラによる車両周辺の水はねを検知するものがある [8]。しかし、固定カメラを用いる手法では、検知可能な範囲がカメラの設置箇所周辺に限定されるため、網羅的な情報収集が困難である。その他の関連する研究として、車載カメラを用いて道路上の水たまりを検知する研究も多数存在する [9], [10], [11], [12], [13], [14], [15]。水はねは、道路上に局所的かつ一時的に発生した水たまり上を走行する際にも発生しうるが、車載カメラを用いた手法は、夜間では適用できず、視界不良や前方走行車両により視界が遮られる場合には、水たまりを検知することができないため、ロバスト性が低い。さらに、加速度やレーザー光などの専用センサを用いて、轍やひび割れなどの路面損傷・路面異常を検知する手法 [16], [17], [18], [19] も提案されており、前述の水たまり検知の手法と比較するとロバスト性は高い。路面損傷箇所では、水たまり発生の可能性があるが、損傷箇所の排水性によっては必ずしも水たまりが形成されずとは限らない。

本研究では、ロバスト性が高く、かつ、水はねをより網羅的に収集するアプローチとして、音響センシングに注目し、車両走行時の音響データを収集したうえで、抽出した音響特徴量の変化から、水はねを検知する。これまでに著者らは、音響センシングによる水はね検知方法として、車載マイクروفोनを利用した水はね検知手法の検討を進めている。文献 [20] では、初期的検討として、音響特徴量を用いた水はね検知手法を提案し、限定的な条件ながら、一定の有用性を示した。文献 [21], [22] では、文献 [20] で提案した手法を改良し、数種類の音響特徴量の比較・検討を行い、高精度に水はね検知ができることを示したが、実験結果に関する検討が不十分であった。本稿では、著者らの提案する水はね検知手法の詳細を述べ、評価実験に用いるデータの拡充を行ったうえで、より多角的な観点で提案手法の有用性について議論する。具体的には、有効な機械学習アルゴリズムの比較、有効な音響特徴量の比較、各特徴量で有効な次元数の比較、特徴量削減の効果について議論し、提案手法の有用性を示した。

本稿の構成は以下のとおりである。2 章では水はね検知や音響センシングに関する関連研究について述べる。3 章では、本稿の提案手法について述べる。4 章では、提案手法の理想環境における評価について述べる。5 章では、提案手法の実環境における評価について述べ、最後に、6 章にて結論と今後の課題について述べる。

2. 関連研究

関連研究として、水はねを検知・計測する手法 [8], [23], [24]、画像認識により水たまりを検知する手法 [8], [9], [10], [11], [12], [13], [14], [15]、加速度センサやレーザー光により路面上の異常や轍を検知する手法がある [16], [17], [18], [19]。

また、本研究で要素技術として用いる音響センシングについては、路面の湿潤状況や路面状況を推定する研究がある [25], [26], [27].

2.1 水はねの計測・検知に関する研究

水はね検知に関する研究として、道路に向けた監視カメラ映像に対し、畳み込みエンコーダ・デコーダモデルを用いることで、高速道路における水たまりおよび水はねを検知する手法が報告されている [8]. また、乗用車のタイヤハウス後方に設置したキャパシティブセンサの値によって水はねを計測し、そのデータから路面の湿潤状態を最高 93% の精度で推定する研究が報告されている [23]. さらに、大型車から前後方向に発生する水はねを車輪後方付近に設置されたレーザ光およびカメラを用いて計測したうえで、路面の舗装状態ごとに水はねの大きさの変化を考察する研究が報告されている [24].

Weir ら [28] によると、タイヤから巻き上げられる水滴のうち比較的大きい ‘splash’ に分類される水滴は、車両の進行方向前方に飛散する ‘bow wave’ および車両の横方向に飛散する ‘side wave’ である。車両の進行方向後方に飛散する ‘tread pickup’ は、比較的水滴が小さいとされる。本研究では、歩行者に被害をおよぼす恐れのある横方向に飛散する side wave を検知の対象とする。監視カメラを用いる手法 [8] では、side wave および tread pickup を検知可能である。しかし、監視カメラが設置された地点以外での水はねを検知できないため、網羅性に問題がある。また、レーザ光とカメラを用いる手法や、キャパシティブセンサを用いる手法 [23], [24] については、タイヤから発生する水はねを計測していたため、本研究との関連性はあるものの、研究の目的自体が水はね検知ではない。そのうえ、タイヤの後方に発生する水はね、つまり tread pickup のみを対象として計測していた。本研究では、歩行者の存在する横方向に飛散する水はねである side wave を検知する必要があるため、これらの研究を直接本研究と比較することはできない。

2.2 画像処理を用いた水たまりの検知に関する研究

路面の水たまりを検知する研究として、画像認識による手法 [9], [10], [11], [12], [13], [14], [15] が報告されている。水たまり検知手法の中には、水面が周囲の景色を映し出す性質を用い、画像内における上下の類似度から水たまりを検知する手法 [9], [11], ステレオカメラ画像に映った水たまりの深度を利用した手法 [10], [14], 輝度画像や彩度画像により画像上の水たまり部分を検知する手法 [13] がある。また、一部の手法 [9], [11], [12], [15] では、ニューラルネットワークを用いて画像の水たまり部分を分類している。

しかし、画像処理を用いて水たまりを検知する手法は、水たまりの発生部分を判別するための各種情報が光による

情報に依存するため、光量の十分でない夜間や、カメラレンズに水滴が付着する雨天時には、適切に検知ができない。また、前方に走行車両が存在する状況では、車両によって水たまりがさえぎられ、認識することができない。

2.3 路面異常の分類・計測に関する研究

水はねの原因の 1 つである水たまりは、路面の劣化によって形成される凹凸や轍に発生する場合がある。このような路面の異常を検知する手法 [16], [17], [18], [19], [29] が報告されている。これらの手法の中には、一般人のスマートフォンのカメラ画像から路面上の劣化を検知する手法 [29], 車内や自転車に設置したスマートフォンの加速度センサから取得したデータを用い、教師あり学習やディープラーニングによって路面状況や路面の異常を検知する手法 [16], [18], [19], 路面に照射したレーザ光の反射を CCD イメージセンサで観測することで、路面上の轍の深さを推定する手法 [17] が提案されている。

しかし、水はねの要因となる水たまりは、平坦な路面においても、周囲の排水性の悪さなど、路面状況以外の要因によっても発生する。また、雨の状況によっては、特定の路面異常がある地点でも、排水性が十分であれば水たまりが発生しない場合がある。そのため、路面の劣化からの的確に水はねを事前予測することは困難であると考えられる。さらに、Han らの手法 [17] はレーザ照射器や CCD イメージセンサを搭載した特別な車両が必要である。

2.4 音響センシングに関する研究

音響センシングでは、マイクロフォンから収集した音響データから路面状況を分類する手法が報告されている [25], [26], [27], [30], [31]. これらの手法の中には、車外に設置したマイクロフォンから収集した音響データを用いて路面の状態を推定する手法 [25], [26], [30] や、歩行者のスマートフォンに搭載されたマイクロフォンの音響データから湿潤・乾燥・凍結などの路面状況を推定する手法 [27] が存在する。また、機械学習アルゴリズムとしてニューラルネットワークを用いた路面状況推定手法も提案されている [25], [30], [31].

これらの関連研究 [25], [26], [27], [30], [31] は、水はねを対象とした研究ではない。そのため、高い精度で水はねを検知するには、実際の水はねの音響特徴を効果的に反映する音響特徴量を抽出する必要がある。

3. 提案手法

3.1 提案手法の概要

提案手法の概要を以下に述べる。図 1 に、本研究における水はね検知手法の概要図を示す。提案手法は、水はね検知モデルの学習フェーズと、作成した水はね検知モデルによる水はねの検知フェーズという 2 フェーズから構成さ




図 1 水はね検知手法の概要
Fig. 1 Overview of water-splash detection.

れる。

学習フェーズでは、個々の車両に搭載したマイクロフォンから音響データを収集し、走行映像から、水はね発生・非発生いずれかの正解ラベルを付与した音響特徴量を抽出する。具体的な手順を下記に示す。

- (1) マイクロフォンを搭載した車両を走行させ、音響データと走行映像を収集する。
- (2) 走行映像に対し正解ラベルを付与し、水はね発生区間・非発生区間を決定する。
- (3) 音響データに対してスライディングウィンドウを適用し、正解ラベルを付した状態で、水はねの音響特徴を効果的に反映する音響特徴量を抽出する。
- (4) 抽出した音響特徴量に、前処理として正規化および標準化を行ったうえで水はね検知モデルの学習データとして使用する。

検知フェーズでは、正解ラベルのない新たな音響データから音響特徴量を抽出し、水はね検知モデルに入力することで、水はねの発生・非発生を2クラスに分類する。具体的な手順を下記に示す。

- (5) マイクロフォンを搭載した車両を走行させ、音響データを収集する。
- (6) 音響データに対して、正解ラベルが付されていない状態で、学習フェーズで抽出したものと同種の音響特徴量を抽出する。
- (7) 正解ラベルが付されていない音響特徴量を、学習フェーズで構築した水はね検知モデルに入力し、水はねの有無を2クラスで分類することで、水はねを検知する。

3.2 水はねの定義

本研究では、検知対象とする水はねを、車両の走行位置から1m以上左側方に水滴が飛散する状態として定義する。日本では車両が左側通行のため、歩行者に被害を及ぼしうる水はねは、車両左側で発生する。また、車両は路端



図 2 定義を満たす水はねが発生する様子
Fig. 2 Water-splash satisfying the definition.




図 3 水はね発生前後の音響スペクトログラム
Fig. 3 Acoustic spectrogram including water-splash sound.

から50cm未満の範囲である「路肩」を走行することが認められておらず、車道外側線からの路端までの幅は最小の「狭路肩」で、最小50cmとして設計されている[32]。そのうえ、国土交通省の規定では自動車の車線幅は最小で幅3mとして設計されている[32]。ここで、一般的な乗用車は車幅が2m未満、かつ走行車線の中央付近を通行すると仮定すると、実際の車両の左側タイヤの走行位置は、路肩を含め、歩行者が通行する路端や歩道から約1m程度となる。つまり、車両から最短で1m以上側方に水はねの水滴が飛散した場合、その水滴は歩行者に被害を及ぼしうと考える。図2に、この定義を満たす水はねが発生した際の様子を示す。

図3に、水はね発生時とその前後の音響データから作成したスペクトログラム*1を示す。図3のスペクトログラムは、水はね発生時およびその前後の10秒間を切り取り、フーリエ変換することで導出した。水はねは、図3における5秒から6秒付近にかけて発生している。図3からは、水はね発生時に、その前後とは異なる音響特徴を示すことが確認できる。

3.3 データ分割・音響特徴量抽出

学習フェーズでは、個々の車両から水はね発生区間の音響データを走行映像と併せて収集し、走行映像をもとに水はね発生区間・非発生区間ごとに音響データを分割する。

*1 音響の時間領域および周波数領域ごとの相対的な強さを色で表現した図である。横軸が時間経過、縦軸が周波数、色の強さが音響の強さを示す。




図 4 学習フェーズにおける特徴量抽出の流れ

Fig. 4 Steps of feature extraction in the training phase.




図 5 検知フェーズにおける特徴量抽出の流れ

Fig. 5 Steps of feature extraction in the detection phase.

図 4 に、3.1 節の手順 (3) で示された音響データ分割の流れを示す。具体的なデータ分割処理の手順を以下に示す。

- (1) 3.5 節の方法で出力された正解ラベルの記録された CSV ファイルを、対応する音響データとともに読み込む。
- (2) 水はね非発生時の音響データの一部および水はね発生時を切り出す。
- (3) 切り出した音響データについて、スライディングウィンドウにより音響データを分割し、音響特徴量の抽出を行う。

音響データの分割後、音響データから水はねの検知に必要な音響特徴量を抽出し、水はねの発生をとらえた映像により正解ラベルを付与する。

特徴量抽出のプログラム実行にかかる処理時間短縮のため、水はねが発生していない音響データのうち、特徴量抽出の対象となるデータは、2 分ごとに約 1 秒の範囲を抜き出したものである。

図 5 に、3.1 節の手順 (6) における検知対象の音響特徴量を抽出する流れを示す。検知フェーズの音響データに対しては、正解ラベルを付さずに直接スライディングウィンドウを適用し、学習フェーズで抽出したものと同種の音響特徴量を抽出する。

3.4 音響特徴量

本稿にて使用する音響特徴量を下記に示す。これらの音響特徴量は、図 3 に示すような周波数領域の特徴を機械学習モデルに反映するために抽出する。

(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反映する音響特徴量である。低次の次元ほど低い周波数領域を特徴量に反映し、かつ 1 次元あたりに反映する周波数領域が狭い。MFCC は、音響のスペクトルに対し、メルフィルタバンクを掛け合わせ、離散コサイン変換を行うことで作成する。本稿では、0 kHz からナイキスト周波数である 22.05 kHz までを 128 次元で反映した MFCC の中から、スペクトルの直流成分である 0 次元目を除外し、低周波領域から順に 39 次元をそれぞれ抽出する。特徴量に反映される周波数領域は約 0.03 kHz から約 1.32 kHz の範囲である。本稿では、次元の呪いを回避するため、機械学習モデル構築に使用するデータ件数と次元数とのバランスを考慮し、39 次元で MFCC を抽出する。

(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。LFCC は、音響のスペクトルに対し、各周波数領域の分解能を均一に反映する線形フィルタバンクを掛け合わせ、離散コサイン変換することで作成する。LFCC は、各次元で特徴量化する周波数領域が一定であり、かつ特徴量に反映する周波数領域の半分を隣り合う次元と共有する。本稿では、0 kHz から 22.05 kHz までを 40 次元で反映した LFCC に対し、0 次元目を除外し、1 次元目から 39 次元目までの 39 次元を用いる。39 次元の LFCC は約 0.54 kHz から 22.05 kHz までの範囲を特徴量化し、1 次元あたり約 1.08 kHz の範囲を特徴量に反映する。LFCC についても、MFCC と同様に、39 次元で抽出する。

3.5 正解ラベル付与

図 1 の手順 (2) に示す正解ラベルの付与は、「車外カメラによるラベリング」による付与と「車内カメラによるラベリング」による付与の 2 つの方法で行う。

車外カメラによるラベリングは、車道の左側の路肩上に車両の進行方向に向けてカメラを設置し、3.2 節で定義した車両が 1 m 以上の水はねを発生させるかを判断するラベリング方法である。図 2 に、車道の路肩に設置したカメラからの実際の映像を示す。車外カメラによるラベリング方法では、車両走行位置から約 1 m 左側方にある路端に水はねの水滴が飛散したことを確認したのち、確認した時刻から遡って当該水はねが発生した瞬間から収束するまでの間を「水はね発生区間」としてラベリングする。

車内カメラによるラベリングでは、車内後部座席上方に設置したカメラを用い、図 6 左側に示す車窓から車外の水はねの発生を確認した瞬間から、図 6 の右側に示すように



図 6 水はね発生時/非発生時の車内カメラ画像

Fig. 6 In-car camera images with/without water splashes.




図 7 正面から見た際の後部座席カメラの画角

Fig. 7 Field of view of the camera installed above the backseat (front view).




図 8 車両上方から見た際の後部座席カメラの画角

Fig. 8 Field of view of the camera installed above the backseat (downward view).

水はねの収束を確認するまでを「水はね発生区間」とするラベリング方法である。図 7 および図 8 に、上方および正面から見た際の、カメラから左前方の画角を示す。この位置関係、および水はね発生後の水滴と車両の相対的な速度差から、車両の約 1.8m から約 1.9m 以上側方かつ車両の左前方に飛散する水はねを観測することが可能である。また、側方の飛散距離が 1.8m 未満である水滴のうち、窓枠によって形成される空中の画角範囲に入る水滴も観測可能である。

車外カメラによるラベリング方法は、車両側方に飛散する水はねを直接観測するために行う。このラベリング環境は理想的なものであるが、雨天時の撮影機材の保護、路端へのカメラ設置、および水はね発生位置の事前把握が必要である。一方、車内カメラによるラベリング方法は、水は

ねの発生箇所が事前に予測できない公道における実環境での使用を想定するが、定義した水はねのうち側方の飛距離が 1.8m 未満 1.0m 以上となる水はねの一部がカメラの撮影範囲外に飛散する可能性がある。そのため、車外カメラによるラベリング方法をとった場合を理想環境向き、車内カメラによるラベリング方法をとった場合を実環境向きのラベリング方法とし、双方のラベリング方法による水はね検知モデルを作成・評価する。

3.6 音響特徴量の正規化

先行研究 [21], [22] では、各水はね間における音響振幅値の違いが水はね検知モデルに与える影響を抑えるため、EBU-R128 に準拠したラウドネスの正規化を行った。しかし、EBU-R128 では、正規化後の振幅値の範囲が明確でなかった。そのため本稿では、抽出した後の音響特徴量の値を対象として各サンプルごとに Min-Max Normalization を行い、各サンプルの最小値 0、最大値 1 となるように調整した。

3.7 機械学習アルゴリズム

本稿では、水はね検知モデル構築時の比較対象として、SVM (Support Vector Machine) および Random Forest の 2 種類の機械学習アルゴリズムを用い、それぞれにおける水はね検知精度を比較する。SVM を用いた理由としては、教師あり学習の分野で広く用いられ、学習データ量が少なくとも高い精度での分類が可能であることから採用した。Random Forest を用いた理由としては、変数重要度による再帰的特徴量削減を行うことができ、適切な次元数や特徴量に関する議論を行いやすいことから採用した。後述する評価実験では、39 次元で抽出した各特徴量について、再帰的特徴量削減によって適切な次元数を議論する。

4. 理想環境における評価実験

本章では、提案手法の有効性と基本的な性質を検証するために実施した理想環境での実験結果について述べる。

4.1 実験環境

4.1.1 人工水たまりの設置

本実験は、公立はこだて未来大学敷地内の私道で、ビニールシートおよびゴムマットによる人工的な水たまりを作成し、その上を車両で走行することによって水はねを発生させた。水たまり作成時には、水たまりの深さが約 1cm の条件、および約 2cm の条件という 2 条件を設定した。図 9 に、深さ 1cm で作成した水たまりを示す。図 10 に、深さ 2cm で作成した水たまりを示す。三角形に薄青色を付した領域が、実際に水がたまった領域である。

4.1.2 データ収集環境

表 1 に、データ収集場所、使用した車両、録音デバイス




図 9 深さ 1 cm の人工水たまり
Fig. 9 Artificial puddle with 1 cm deep.



図 10 深さ 2 cm の人工水たまり
Fig. 10 Artificial puddle with 2 cm deep.

表 1 データ収集環境

Table 1 Environments of data collection.

項目	収集環境
使用車両	コンパクトカー (トヨタ・ラクティス, DBA-NCP125)
録音デバイス	ZOOM Q2N-4K
マイクロフォン	AT9944
サンプリングレート	44.1 kHz
ビット長	16 bit




図 11 実験車両の車輪周辺の寸法
Fig. 11 Dimensions around the wheel of the car used in the experiment.

の情報を示す。図 11 に、水はねが発生する車両左前輪周辺の寸法を示す。実験は、公立はこだて未来大学敷地内の私道にて行った。実験実施時の天候は晴天、もしくは曇天であった。梅村らによると、車両が時速 20 km の速度で走行した際、水はねの水滴は 2 m 以上側方に飛散したと報告されている [4]。今回の実験では、3.2 節の定義に従った水はねが発生する場合としない場合のデータ両方を集めるため、実験実施時、車両は水はねが発生すると考えられる時速 20 km よりも低い時速 10 km から、時速 10 km ごとに速度を変化させ、時速 40 km までの間で複数回走行した。収集した音響データには、停車中の音響データを含めた。



図 12 実験で使用したマイクロフォン
Fig. 12 Microphone used in the experiment.



図 13 側方カメラから水はねを観測した様子
Fig. 13 Water-splash captured from a side view camera.

図 12 に、実験車両内に設置したマイクロフォンを示す。使用したマイクロフォンは汎用目的のマイクロフォンであり、3.2 節にて述べた車両左側で発生する水はねを容易に検知可能となるよう、後部座席左側の天井付近からカメラアームを用いて吊るす状態で設置した。音響データのサンプリングレートは 44.1 kHz、ビット長は 16 bit であった。

実験車両は、図 9 および図 10 に示す薄青色の水たまり部分を通りした。本実験では、3.2 節で定義した水はねを検知対象とした。本実験は理想環境で行うため、ラベリング方法は、3.5 節における車外カメラによるラベリング方法をとった。図 2 に、定義に従った水はね発生時の図を示す。

4.1.3 水はねの発生

図 13 に、深さが 2 cm の水たまりを時速 40 km にて走行した際の様子を示す。水はねの水滴は、ビニールシート上で発生した。その水滴は車両側方だけでなく、タイヤの接地面前方向から、車両の進行方向に対して、左前方に水はねの水滴が押し出されていることが確認できる。Weirら [28] の定義に照らした場合、side waveに加え、フロントバンパー前方に bow wave と思われる水滴も確認できる。

表 2 に、今回の実験で発生した側方 1 m 以上の水はねの回数および走行回数を、速度ごと、水たまりの深さごとに示す。水はねは、その多くが時速 20 km 以上の速度域にて発生した。深さが約 1 cm の水たまりからは、40 回の走行中 27 回の水はねが発生した。深さが約 2 cm の水たまりからは、42 回中 34 回の水はねが発生した。なお、時速 20 km 以下の低速域では、1 回の走行で前輪と後輪が通過した際にそれぞれ別々の水はねが発生した事象が 2 回発生した。

表 2 側方飛距離 1 m を超えた水はねの発生回数 (単位: 回)
Table 2 Numbers of water splashes over 1 m to the side.

	時速 10 km	時速 20 km	時速 30 km	時速 40 km	全速度域
深さ約 1 cm	0/10	10/11	7/8	10/11	27/40
深さ約 2 cm	3/11	10/10	11/11	10/10	34/42
合計	3/21	20/21	18/19	20/21	61/82

4.1.4 音響特徴量の抽出

データの収集後は, 3.3 節の方法に基づき音響データを分割し, 分割した各データに対し正解ラベルを付与したのち, スライディングウィンドウを用いて音響特徴量の抽出を行った. ウィンドウサイズは約 0.37 秒に相当する 16,384 サンプル, オーバーラップ 50%とした. 水はね発生時の音響データは, 水はねが持続していると判断される時間 (持続時間) のデータを抽出した. 水はねによって持続時間が異なるため, 各水はねから抽出されるウィンドウ数 (データ数) は異なる. 水はねと判断される持続時間に従って各水はねで異なるウィンドウ数のデータを抽出した. 水はね非発生時の音響データについては, 収集した音響データの開始 2 分後から, 2 分おきにウィンドウ 4 個分 (約 0.93 秒分) のデータを抽出した. このとき, 水はね発生時・非発生時の各時間範囲の末尾において, ウィンドウサイズに収まらない音響データを除外し, 音響特徴量の重複や質の低下を防止するよう試みた.

音響特徴量抽出は, 3.4 節に示す (1) の MFCC については, Python のライブラリである librosa を用いて抽出した. (2) の LFCC については, 音響データをフーリエ変換した後, 独自に作成した線形フィルタバンクを掛け合わせ, 離散コサイン変換を行うことで抽出した.

本稿の手法では, スライディングウィンドウを用いることで 1 回の水はねから複数ウィンドウの音響特徴量を抽出する. 抽出した音響特徴量は, 先行研究 [21], [22] と同じく, 水はねごとにまとめて扱った.

4.1.5 水はね検知モデルモデルの構築

水はね検知モデルの特徴量には, MFCC および LFCC 各 39 次元を抽出した場合を用いた. 機械学習アルゴリズムとしては, SVM を用いた.

水たまり深さ 1 cm の条件では, 水はね・非水はね各 57 件の計 114 件, 水たまり深さ 2 cm の条件では水はね・非水はね各 94 件の計 188 件が抽出された. 水たまり深さ 1 cm の条件において抽出されるデータ数が少ない理由として, 浅く小さい水たまりを形成したことによって約 0.37 秒分のスライディングウィンドウで抽出されるデータ数が少なくなったことがあげられる.

モデル構築前には, 抽出した音響特徴量の各ウィンドウ内で, 3.6 節に基づく正規化を行った. 特徴量の最小値が 0, 最大値が 1 となるように Min-Max Normalization による正規化を行った. その後, 全音響特徴量間の各次元単位

で標準化を行った.

水はね非発生時の音響特徴量は, 実際に抽出した特徴量のうち, 水はね発生時の音響特徴量と同数のデータをランダムに絞り込んで水はね検知モデルの作成に使用した.

機械学習モデルの作成には Python のライブラリである scikit-learn (ver. 1.2.2) を用いた. SVM による水はね検知モデル作成時のコストパラメータは 1.0 とし, 線形カーネルを用いた.

本稿では, 抽出した音響特徴量を水はね単位で 5 分割し, 交差検証を行った. 収集したデータを水はね単位で 5 分割したうえで, そのうちの 1 グループを評価データとして用い, 残り 4 グループと 5 で割り切れずに余った水はねデータを学習データとして用いた. この試行を, 評価データとするグループを変えながら 5 回繰り返し, 平均の F 値を算出した.

4.2 実験結果

抽出した機械学習モデルについて, 水はね回数ごとの 5 分割交差検証により評価した結果を表 3 に示す. 条件 A-1, A-2 が深さ約 1 cm の水たまりを走行したデータを用いた際の精度, 条件 A-3, A-4 が, 深さ約 2 cm の水たまりを走行したデータを用いた際の精度, 条件 A-5, A-6 が, 深さ約 1 cm, 2 cm 両方の水たまり両方を走行したデータを用いた際の精度である.

4.3 考察

4.3.1 水はね検知に対する有用性に関する考察

今回作成した機械学習モデルでは, 両方の水たまり深さにおけるデータを用いた条件 A-5 および条件 A-6 において, F 値約 90%の高い精度を得た. また, 各水たまり深さのデータを用いた条件 A-1 から条件 A-4 においても, 90%前後の高い精度を得た. 特に, 水たまり深さ 1 cm の条件 A-1, A-2 では, F 値 95%近くの非常に高い精度を得た. よって, 本稿の提案手法は, 十分有用な精度で水はねを検知できることが明らかとなった.

4.3.2 水はねの深さごとの検知精度に関する考察

また, 水たまり深さ 1 cm と 2 cm のデータを両方用いた条件 A-5 および条件 A-6 では, ほかの条件 A-1 から条件 A-4 と比較して, 精度が低い傾向にある. この要因としては, 大小異なる水たまりを走行したデータを混合したことにより, 異なる音響特徴が同一の機械学習モデルの構築に

表 3 人工的に発生させた水はねの検知精度

Table 3 F-measures of water-splash detection of artificial water-splashes.

条件	水たまり深さ	特徴量	次元数	データ数	平均 F 値 (SVM)
A-1	約 1 cm	MFCC	39	114 (水はね・非水はね各 57 件)	94.77%
A-2	約 1 cm	LFCC	39	114 件 (水はね・非水はね各 57 件)	95.09%
A-3	約 2 cm	MFCC	39	188 件 (水はね・非水はね各 94 件)	91.65%
A-4	約 2 cm	LFCC	39	188 件 (水はね・非水はね各 94 件)	89.46%
A-5	混合	MFCC	39	302 件 (水はね・非水はね各 151 件)	90.67%
A-6	混合	LFCC	39	302 件 (水はね・非水はね各 151 件)	89.96%

用いられ、学習データの類似性が低くなったことが推測される。また、他の要因としては、水たまり 1 cm の条件のデータに、比較的分類精度の低くデータ数が多い水たまり 2 cm 条件のデータを加えたことで、検知精度が水たまり 2 cm 条件に類似するように影響を受けた可能性も考えられる。

水たまり深さが 1 cm である条件 A-1, A-2 では、F 値約 95%前後の高い精度を得た。このような結果が得られた理由として、時速 10 km の水はね区間データが学習データに含まれていないことが要因として考えられる。一般的に、水はねによる音響の大小は、発生する水はねの大きさによって決まると考える。時速 10 km の水はねの音量は小さく、水はね検知に用いる際には非水はね時の音響との区別が難しくなることが推測される。水たまり深さ 1 cm 条件では、水はねが発生しなかったことにより、そのような区別の難しい学習データがそもそもモデル作成に用いられなかったことで、学習データに占める水はねデータが、比較的区別しやすい時速 20 km 以上のデータによって構成されることで精度が上がったと考えられる。また、他条件とは学習データ数が異なったことも留意すべき点であると考ええる。

5. 実環境における評価実験

本章では、雨天時に公道を走行して収集したデータにより水はね検知モデルを構築し、その精度から歩行者に被害を及ぼす大きな水はねが発生する実環境における本手法の実現可能性を評価する。

5.1 評価方法

データ収集は、普通乗用車を用い函館市内の公道を約 40 km 前後で走行して行った。データ収集時の天候は雨天であった。収集した音響データには、停車中の音響データを含めた。その他のデータ収集環境は、表 1 のとおりとした。使用した車両は、4.1.2 項の環境で用いた車両と同一であるため、水はねの発生する左前輪付近の寸法は、図 11 のとおりであった。収集した数日分の音響データのうち、観測した水はねの回数は合計 226 回であった。

本章の実験においては、3.5 節における車内カメラを用

いたラベリング方法により、音響データに正解ラベルを付与した。図 13 に示すように、水はね発生時にタイヤによって押し出された水滴は側方だけでなく前方にも発生する。これにより、巻き上げられた水滴が、図 7 および図 8 における後部座席上方に設置したカメラの画角内に入り、図 6 に示すように観測される。

5.1.1 音響特徴量の抽出

音響特徴量の抽出方法については、4.1.4 項と同様の方法で抽出した。

5.1.2 水はね検知モデルの構築

5.1.1 項における音響特徴量の抽出後、SVM および Random Forest による水はね検知モデルを構築した。モデル構築前には、4.1.5 項と同様に、音響特徴量の正規化・標準化を行った。水はね非発生時の音響特徴量は、4.1.5 項と同様に、抽出した特徴量のうち、水はね発生時の音響特徴量と同数のデータをランダムに絞り込んで水はね検知モデルの作成に使用した。機械学習モデルの作成には、4.1.5 項と同様に、scikit-learn を用い、SVM による水はね検知モデル作成時のコストパラメータは 1.0 とし、線形カーネルを用いた。そのほかのパラメータはデフォルトのとおりとした。

学習モデルを評価する際には、4.1.5 項と同じく水はね回数ごとの 5 分割交差検証を用いた。観測した 226 回の水はねから 1,074 件の音響特徴量を抽出し、同数の水はね非発生時のデータを分類対象として使用することで、合計のデータ数は 2,148 件となった。1 回の試行で評価データとなる水はねの件数は 45 回であり、残りの 181 回を学習データとして使用した。226 回のうち 5 で割り切れない 1 回の水はねについては、5 回の試行のすべてにおいて学習データとして使用した。

5.2 実験結果

表 4 に、水はね単位の 5 分割交差検証結果を示す。平均 F 値は、5 分割交差検証の各試行で算出された F 値の平均値である。

SVM を使用した場合に精度が高かった条件 R-1 については、約 91.99%の精度で水はねを検出した。また、Random Forest を用いた場合に精度が高かった条件 R-1 について

表 4 機械学習アルゴリズム・特徴量・次元数ごとの水はね検知精度
Table 4 F-measures of water-splash detection for each algorithm, feature, and number of dimensions.

条件	特徴量	次元数	平均 F 値	平均 F 値
			(SVM)	(Random Forest)
R-1	MFCC	39	91.99%	90.32%
R-2	LFCC	39	87.36%	89.23%

は、約 90.32%の精度で水はねを検知した。

5.3 考察

5.3.1 水はね検知精度の有効性に関する考察

表 4 の条件 R-1, R-2 の両方において、F 値約 90%前後の精度で水はねを検知可能であることが示唆された。このことから、提案手法は、水はねの検知に対して十分有用であるといえる。

5.3.2 機械学習アルゴリズムの違いに対する分析

SVM を用いた条件と、Random Forest を用いた条件を比較すると、MFCC を用いた条件 R-1 では、SVM のほうが高い条件を示し、その差は約 1.67%であった。このことから、MFCC を用いる場合においては、Random Forest と SVM の間とは精度差が小さく、水はね検知精度にほぼ変わりがないことが示唆された。

LFCC を用いた場合、Random Forest のほうが高い精度を示し、その差は 1.87%であった。このことから、LFCC を用いる場合には、Random Forest のほうが精度が高く、SVM と比較して有効性が高いことが示唆された。

5.3.3 異なる音響特徴量間の精度変化に対する考察

異なる特徴量を用いた表 4 の条件 R-1 と条件 R-2 を比較すると、SVM を用いた場合、Random Forest を用いた場合の両方において、MFCC のほうが高い精度を示した。このことから、水はねの検知に対しては、MFCC を用いることが水はね検知に対して有効であることが示唆された。

5.4 再帰的特徴量削減による特徴量選択の結果・考察

収集した水はねの音響データに特化した音響特徴量を抽出するため、また、実環境の水はね検知における機械学習モデルの適切な次元数について考察するため、Random Forest を用いた再帰的特徴量削減による特徴量選択を行った。具体的には、39 次元の MFCC および LFCC について、38 次元から 1 次元まで Random Forest による機械学習モデルの作成を繰り返し、変数重要度が低い特徴量を 1 つずつ削減した。

表 5 に、選択した特徴量のうち音響特徴量・機械学習アルゴリズムごとに最も精度が高かった組合せを示す。各条件は、使用した特徴量と、学習アルゴリズムの組合せである。また、図 14 に、特徴量選択の過程において Random Forest によって構築した水はね検知モデルの F 値の変化を

表 5 再帰的特徴量削減による精度の最大値

Table 5 Maximum F-measures obtained through recursive feature elimination.

条件	特徴量	学習アルゴリズム	次元数	平均 F 値
R-3	MFCC	SVM	38	91.99%
R-4	MFCC	Random Forest	25	91.50%
R-5	LFCC	SVM	26	88.14%
R-6	LFCC	Random Forest	27	90.23%




図 14 再帰的特徴量削減による Random Forest の次元数ごとの F 値

Fig. 14 F-measures of random forest for each number of dimensions during recursive feature elimination.




図 15 SVM の特徴量の次元数ごとの F 値

Fig. 15 F-measures of SVM for each number of feature dimensions.

示す。図 15 には、選択した特徴量の各組合せで作成した SVM による水はね検知モデルの F 値の推移を示す。また、図 16 に、条件 R-5 において使用された特徴量の各次元の、Random Forest における変数重要度を示す。図 16 の縦軸は 1 次元目から 39 次元目まで各次元の番号を示しており、次元の番号が小さいほど低周波領域に着目する特徴量である。

Random Forest を用いた場合と SVM を用いた場合の両者において、MFCC の精度が全体的に LFCC を上回っていた。また、Random Forest を用いた場合と SVM を用いた場合ともに、MFCC と LFCC の両方の特徴量が 10 次元前後まではほぼ同一の精度を保っていた。このことから、本稿の提案手法において、10 次元前後まで削減したとして




図 16 LFCC において 26 次元を選出した際の変数重要度

Fig. 16 Feature importance when selecting 26 dimensions in LFCC.

も、提案手法の有効性が保たれることが示唆された。

また、図 16 から、LFCC の変数重要度が高い上位 5 次元が着目する周波数領域は、それぞれ約 1.08 kHz–2.15 kHz (2 次元目)、2.15 kHz–3.23 kHz (4 次元目)、1.61 kHz–2.69 kHz (3 次元目)、3.76 kHz–4.84 kHz (7 次元目)、2.69 kHz–3.76 kHz (5 次元目)、であった。39 次元の MFCC が特徴量化する周波数領域が 0.03 kHz から 1.32 kHz の間であることに鑑みると、MFCC が特徴量化しない LFCC の周波数領域の中でも、低周波領域の重要性が高いことが示唆された。

5.5 考察まとめ

本稿の結果から、本稿で提案する車載マイクロフォンを用いた手法は、SVM を用いた場合と Random Forest を用いた場合、また、MFCC を用いた場合と LFCC を用いた場合のすべてにおいて、90%前後の精度で水はねを検知し、提案手法の有効性を示した。

機械学習アルゴリズムについては、MFCC を用いる場合には SVM と Random Forest の間に大きな精度差はなく、LFCC を用いた場合には Random Forest の精度が高いことが示された。

特徴量の種類について、Random Forest, SVM それぞれを用いた場合の両方において、MFCC の精度が LFCC と比較して高いことを示した。

特徴量の次元数においては、Random Forest, SVM を用いた場合の両者において、10 次元前後まで高い検知精度を維持すること、LFCC においては低周波領域に偏った周波数の次元が重要であることが示された。

実環境における評価時の制約として、3.2 節にて定義した水はねのうち、車窓から車外を見た際の撮影範囲外に飛散する比較的小さい水はねを見逃す可能性があるという点があげられる。この点について、カメラ式サイドミラーなど、車外左側方の水はねを確実に把握可能な車載デバイスの使用を検討する必要がある。しかし、車内カメラから観測可能なほどに大きい水はねは、歩行者に対し特に大きい被害を与える。このような大きい水はねに対して検知精

度を得たことにより、本研究の一定の有効性が示されたいえる。

6. おわりに

本研究の目的は、車両からの水はねによる歩行者への被害を防ぐため、水はねを検知する手法を確立することである。この目的に向け、本研究では車載マイクロフォンの音響データを用いた音響センシングによる手法を提案する。提案手法により、ドライバーはカメラや加速度センサが検知できない場所での水はね検知を、市販のマイクロフォンを用いて低コストに行うことが可能となる。本稿では、先行研究 [20], [21], [22] の知見を活かしつつ、使用する音響データの拡充を行ったうえで、車載マイクロフォンの音響データから抽出した音響特徴量に教師あり学習を適用することで、水はね検知モデルを作成・評価した。結果として、理想環境および実環境における評価実験を通して、SVM 使用時に 90%前後の精度で水はねを検知し、提案手法が集合知の形成を前提として水はね検知に十分有用であることを示した。また、LFCC 使用時は Random Forest が SVM と比較して有効であること、低周波領域が水はねの検知に有効であること、10 次元前後まで特徴量削減をしても、提案手法の有効性が保たれることを示した。

今後の課題として、小さな水はねなど、検知対象の水はねと類似する音響データを区別する手法の確立が必要である。また、水はね発生区間を指定する際の作業を自動化し、属人性の低いデータ分割手法を確立する必要がある。加えて、音響データに対するラベリング方法を改善する必要がある。本稿の提案手法では、車内カメラを用いたラベリングと車外カメラを用いたラベリングを提案したが、車内カメラによるラベリングでは、定義した水はねのうち小さい水はねを正確に把握することができない。車外カメラによるラベリングでは、路端などにカメラを設置するため、データ収集コストが大きい。これに対し、車内カメラによるラベリングの問題点を解決するため、カメラ式サイドミラーのような車外の様子を把握できる車載デバイスの活用などが有効と考えられる。さらに、今回の評価に用いたデータは、同一の車両およびマイクロフォンを用いて収集したデータであったため、車種・天候など様々な環境におけるデータを使用した水はね検知モデルを作成し、さらに多様な環境に最適化するように、水はね検知モデルを改善する必要があると考える。プローブ情報システムの考え方にに基づき、一般の車両からデータを収集するためにも、データの多様化への対応は今後重要となる。複数の車両で水はね検知を行うことが可能なシステムの構築が実現した場合、同じ地点での水はねを複数車両で検知することにより、同一の車両およびマイクロフォンを用いた場合よりも高い精度での水はね検知が可能となることが期待できる。

参考文献

- [1] デジタル庁：道路交通法，入手先 (<https://laws.e-gov.go.jp/law/335AC0000000105#Mp-Ch.4-Se.1-At.71>) (参照 2024-08-15).
- [2] 日本自動車連盟：「水はね」をしないためには、どんなところに気をつけて走行すればいいのですか？，入手先 (<https://jaf.or.jp/common/kuruma-qa/category-drive/subcategory-technique/faq096>) (参照 2022-06-21).
- [3] 土木研究所：道路ユーザーの視点に立った舗装性能評価法に関する研究，土木研究所資料第 4317 号 (2015).
- [4] 梅村 章，大橋栄市，岡崎勝利，平野芳太郎：走行車による水はねの研究，日本機械学会論文集 (C 編)，Vol.56, No.521, pp.53–62 (1990).
- [5] 熊谷 洋，寺口和弘，加来照俊：舗装路面の水はね現象の挙動分析，土木学会北海道支部論文報告集，pp.597–602 (1990).
- [6] 道路 WEB：道路パトロール，入手先 (https://www.douroweb.jp/211road_patrol/road_patrol) (参照 2024-09-09).
- [7] 砂原秀樹，佐藤雅明，植原啓介，青木邦友，村井 純：インターネットを利用した自動車ブローブ情報システムの構築，電子情報通信学会論文誌 B，Vol.J85-B, No.4, pp.431–437 (2002).
- [8] Qiao, J.-J., Wu, X., Jun-Yan He, W.L. and Peng, Q.: SWNet: Deep Learning Based Approach for Splashed Water Detection on Road, *IEEE Trans. Intelligent Transportation Systems*, Vol.23, No.4, pp.3012–3025 (2022).
- [9] 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).
- [10] 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).
- [11] Li, W. and Huan, W.: Water Hazard Detection Using Conditional Generative Adversarial Network With Mixture Reflection Attention Units, *IEEE Access*, Vol.7, pp.167497–167506 (2019).
- [12] Li, J. and Nguyen, C.: Realtime Water-Hazard Detection and Visualisation for Autonomous Navigation and Advanced Driving Assistance, *2019 IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct)*, pp.287–288 (2019).
- [13] Rankin, A. and Matthies, L.: Daytime Water Detection Based on Color Variation, *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.215–221 (2010).
- [14] Rankin, A.L., Matthies, L.H. and Huertas, A.: Day-time Water Detection By Fusing Multiple Cues For Autonomous Off-road Navigation, *Transformational Science and Technology for the Current and Future Force*, pp.177–184 (2006).
- [15] Shi, Y., Feng, X., Li, Y. and Li, H.: Pavement Area Water Detection Algorithm Based on Improved DEEPLABV3+, *2022 3rd International Conference on Control, Robotics and Intelligent System*, pp.93–97 (2022).
- [16] 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).
- [17] Han, J., Cui, L. and Shi, S.: Road Rut Detection System with Embedded Multi-Channel Laser Sensor, *The International Journal of Advanced Manufacturing Technology*, Vol.122, pp.41–50 (2022).
- [18] Tiwari, S., Bhandari, R. and Raman, B.: RoadCare: A Deep-learning Based Approach to Quantifying Road Surface Quality, *Proc. 3rd ACM SIGCAS Conference on Computing and Sustainable Societies*, pp.231–242 (2020).
- [19] Peng, D., Strout, Z., Jiang, S. and Shull, P.: A Road Condition Classifier via Lock Embedded IMU on Dock-Less Shared Bikes, *Proc. International Conference on Industrial Control Network and System Engineering Research*, pp.32–36 (2019).
- [20] 白戸 拓，金澤玲実，石田繁巳，白石 陽：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，情報処理学会研究報告高度交通システムとスマートコミュニティ (ITS)，Vol.2022-ITS-91, No.7, pp.1–5 (2022).
- [21] 白戸 拓，金澤玲実，石田繁巳，白石 陽：音響センシングを用いた車道における水はね検知手法の改善に向けた検討，情報処理学会マルチメディア，分散，協調とモバイルシンポジウム 2023 論文集，Vol.2023, pp.1378–1384 (2023).
- [22] Shiroto, T., Kanazawa, R., Ishida, S. and Shiraishi, Y.: Roadway Water-Splash Detection Method Using Acoustic Sensing, *2023 14th International Conference on Mobile Computing and Ubiquitous Network (ICMU)*, pp.1–4 (2023).
- [23] Döring, J., Beering, A., Scholtyssek, J. and Krieger, K.-L.: Road Surface Wetness Quantification Using a Capacitive Sensor System, *IEEE Access*, Vol.9, pp.145498–145512 (2021).
- [24] Garcia, J.M.S., Garcia, M.R. and Garcia, J.A.R.: Influence of Texture on Drainability, Splash and Spray in Flexible Pavements, *The Baltic Journal of Road and Bridge Engineering*, Vol.16, No.3, pp.1–30 (2021).
- [25] Bahrami, S., Doraisamy, S., Azman, A., Nasharuddin, N.A. and Yue, S.: Acoustic Feature Analysis for Wet and Dry Road Surface Classification Using Two-stream CNN, *CSAI 2020: 2020 4th International Conference on Computer Science and Artificial Intelligence*, pp.194–200 (2021).
- [26] 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, *2016 23rd International Conference on Pattern Recognition*, pp.3458–3463 (2016).
- [27] 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).
- [28] Weir, D.H., Strange, J.F. and Heffley, R.K.: Reduction of Adverse Aerodynamic Effects of Large Trucks, Volume I. Technical Report, Technical Report, United States. Federal Highway Administration (1978).
- [29] Hiroya, M., Yoshihide, S. and Toshikazu, S.: Lightweight Road Manager: Smartphone-Based Automatic Determination of Road Damage Status by Deep Neural Network, *Proc. 5th ACM SIGSPATIAL International Workshop on Mobile Geographic Information Systems*, pp.37–45 (2016).
- [30] Gagliardi, A., Staderini, V. and Saponara, S.: An Embedded System for Acoustic Data Processing and AI-Based Real-Time Classification for Road Surface Analysis, *IEEE Access*, Vol.10, pp.63073–63084 (2022).
- [31] Atibi, M., Atouf, I., Boussaa, M. and Bennis, A.: Com-

parison between the MFCC and DWT Applied to the Roadway Classification, *2016 7th International Conference on Computer Science and Information Technology (CSIT)*, pp.1–6 (2016).

[32] 国土交通省：2 幅員構成，入手先 (<https://www.mlit.go.jp/road/sign/pdf/kouzourei.3-2.pdf>) (参照 2024-09-06).

推薦文

DICOMO2023 の発表論文の中で特に評価が高かったため，本論文は，音響センシングを用いた水はね検知手法を提案している．初期的検討として代表的な音響特徴量により水はねを検知する機械学習モデルを作成し，音響特徴量が有効であると著者らの先行研究において示している一方，音響特徴量の検討が不十分で，収音状況の違いが分類に悪影響を及ぼすという問題が残されていた．著者らは，本論文において，提案手法の改善に向け，音響振幅値の正規化とあわせ，水はねの音響特徴を反映した音響特徴量を作成することで，先行研究で利用した 2 種類の音響特徴量との比較・検討を行い，低周波領域に着目した音響特徴量において，水はね検知精度が高いことを見い出している．本論文は，課題と対処が明確で，論文としての完成度も高いため，本論文をここに推薦する．

(高度交通システムとスマートコミュニティ
研究会主査 徳永 雄一)



白戸 拓 (学生会員)

2023 年公立はこだて未来大学システム情報科学部情報アーキテクチャ学科卒業．現在，同大学大学院システム情報科学研究科システム情報科学専攻博士前期課程在学中．音響センシング，高度道路交通システムに関する研究に

従事．



石田 繁巳 (正会員)

2006 年芝浦工業大学工学部卒業．2008 年東京大学大学院新領域創成科学研究科修士課程修了．2012 年同大学院工学系研究科博士課程修了．博士 (工学)．2008 年 (株) アクティス入社．2013 年米国ミネソタ大学客員

研究員．2013 年九州大学システム情報科学研究所助教．2021 年公立はこだて未来大学准教授．無線通信，センサネットワークに関する研究に従事．2016 年度山下記念研究賞，2023 年 IPSJ/IEEE Computer Society Young Computer Researcher Award．IEEE，ACM，電子情報通信学会各会員．



白石 陽 (正会員)

2002 年慶應義塾大学大学院理工学研究科博士課程単位取得退学．東京大学空間情報科学研究センター研究機関研究員，助手，助教を経て，2009 年より公立はこだて未来大学助教．2016 年より同大学教授．博士 (工学)．セン

サネットワーク，データベース，高度交通システムに関する研究に従事．ACM，電子情報通信学会，地理情報システム学会等各会員．