

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

白戸 拓¹ 金澤 玲実¹ 石田 繁巳² 白石 陽²

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、事前知識の不足や周辺環境の変化により、水はねを発生させる路面状況の見落としや、発見の遅れなどが発生する。そのため、個々の車両が水はねの発生を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の構築が望まれる。このシステムを実現するため、本研究では音響センシングを用いた水はね検知手法を提案する。先行研究では、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ことを示した。しかし、音響特徴量の検討が不十分であり、收音状況の違いが分類に悪影響を及ぼしていた可能性が考えられた。本稿では、提案手法の改善に向けて、音響振幅値の正規化と併せ、水はねの音響特徴を反映した音響特徴量を作成し、先行研究で利用した2種類の音響特徴量との比較・検討を行った。結果として、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確認した。

1. はじめに

車両が水たまりを通過する際に発生する「水はね」は、歩行者の衣服や持ち物を汚損させる要因となる。ドライバーは、水はねの発生を回避する義務を負うが、走行路面における事前知識の不足や周辺環境の変化など様々な要因により、水たまりの見逃しや発見の遅れが発生する。

ドライバーに対し水はねの回避や安全な経路選択を促すには、水はねの発生情報を事前にドライバーに共有することが必要である。日本ではカーナビゲーションシステムの普及に伴い、個々の車両が持つセンサの情報と位置情報を収集・処理する「プローブ情報システム」[1]の利活用が進んでいる。プローブ情報の一種として水はねに関するデータを収集・蓄積することで、走行経路上の水はねの発生状況をマップやカーナビゲーションシステムを通じてドライバーに共有することができると考えられる。

個々の車両で水はねに関するデータを検知するにあたっては、画像認識により水たまりを検知する手法 [2,3] や路面状況の異常を検知する手法 [4,5] が提案されている。

しかし、これらの手法では悪天候や夜間におけるロバスト性に関する問題や、路面状況に異常がない地点の水はねを検知できない問題、一般的な車両には搭載していない特別なセンサが必要となる問題が存在する。水はねの検知に

あたっては、一般的な車両から収集可能なデータを用いて、様々な環境下での検知が可能であることが必要である。

本研究では、カーナビゲーションシステムなどに搭載されたマイクロフォンを利用した車載マイクロフォンを用いた音響センシングにより水はねを検知する。音響データを用いることにより、悪天候や昼夜などの視覚情報によらないセンシングが可能になる。また、路面状況に異常がない地点に発生する水はねを検知することが可能になる。さらに、一般的な車両のカーナビゲーションシステムに搭載されたマイクロフォンを使用することで、特別なセンサを必要とせずに実装が可能となる。そのため、様々な状況下での水はねを検知可能となり、先述したプローブ情報としての活用が期待できる。

水はねの発生区間には、飛散した水滴が路面や車体に打ち付けられる際に特徴的な音響が発生する。この音響データを車内で観測したうえで音響特徴を抽出し、水はねの発生・非発生を2クラスに分類する教師あり学習モデルを用いることで水はねを検知する。

筆者らは、先行研究 [6] にて雨天時にマイクロフォンを搭載した車両を走行させることで音響データを収集し、抽出した複数の音響特徴量から Support Vector Machine (SVM) を用いて水はね検知モデルを作成した。結果として、F 値 98.1%の精度で水はねを検知した。しかし、先行研究 [6] の手法では、関連研究 [7-9] や音声認識分野で用いられた音響特徴量のみを用いており、実際の水はねに基づいた音響

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

² 公立はこだて未来大学システム情報科学部

特徴量の検討が不足していた。また、収集した音響データに対し振幅値の正規化を行っておらず、収音状況の違いによる振幅値の変化がデータの分類に悪影響を及ぼしていた可能性が考えられた。水はね発生区間の音響データの振幅は、周囲の天候、交通状況、自車両の車速など様々な要因で変化するため、提案手法を実用的なものにするためには、様々な環境から収集した音響データにおいて効果的に水はねを検知する機械学習モデルを作成する必要がある。

本稿では、提案手法により様々な環境で効果的に水はねを検知するための改善として、複数の水はねから収集した音響データの分析に基づいた音響特徴量の提案および音響特徴量の正規化という改善を行った結果を報告する。提案手法の評価時には、機械学習モデルの構築に用いるデータを拡充することで、精度値の信頼性を向上することを目指す。

本稿の構成は以下の通りである。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章では予備実験の結果を述べ、4章では提案手法の改善について述べる。5章にて改善手法の評価について述べ、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

水はね検知に関連した研究として、画像認識により水たまりを検知する手法 [2,3]、加速度センサやレーザ光により路面上の異常や轍を検知する手法がある [4,5]。音響センシングでは、路面の湿潤状況や路面状況を推定する研究がある [7-9]。

2.1 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 [2,3] が報告されている。X. Han らは、画像上の水たまりの水面が周囲の景色を映し出す性質を用いた深層学習により、F 値 76.9% の精度で水たまりを検知している [2]。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よりも深度が深いことを利用し、水たまりを検知している [3]。

しかし、車両に搭載したカメラを用いて前方の水たまりを検知する場合、フロントガラスに水滴が付着する雨天時や水たまりの視認性が悪くなる夜間には精度が低下する可能性がある。また、これらの手法における実験環境は水面が穏やかな天候を前提としているため、水たまりの水面が乱れる雨天時には、水たまりに映る景色や水たまりから観測される深度が適切なものにならない可能性がある。

2.2 路面異常検知に関する研究

Basavaraju らは、車内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に SVM を用いることで、90.2% の精度で路面のひび割れや穴を検知している [4]。

また、水たまりは路面上に形成される轍によっても発生する可能性がある。J. Han らは、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している [5]。

しかし、水はねの要因となる水たまりは、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。路面の異常を検知する手法では、路面の異常がない地点に発生する水たまりを予測できない。また、J. Han らの手法はレーザ照射器や CCD イメージセンサを搭載した特別な車両が必要である。

2.3 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の乾燥・湿潤状態を分類する研究や、舗装路面や草地などの路面状況を分類する研究が報告されている [7-9]。Bahrami らは、車両のタイヤ付近に設置したマイクロフォンから収集した音響データに対し、周波数領域・時間領域それぞれに関する 2 系統の Convolutional Neural Network (CNN) を用いて、約 92.3% の精度で路面の乾燥・湿潤状態を分類している [7]。Abdić らは、同じく車両のタイヤ付近で収集した音響データから、人間の聴覚の特徴であるメル尺度に基づいたものを含めた特徴量を抽出し、Bi-directional Long Short-Term Memory (BLSTM) を用いて 93.2% の精度で路面の乾燥・湿潤状態を分類している [8]。金澤らは、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に対し、SVM を用いて湿潤・乾燥・凍結などの路面状況を 69.7% の精度で推定している [9]。

これらの先行研究 [7-9] 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に基づいた適切な音響特徴量を抽出する必要がある。また、Bahrami らおよび Abdić らの研究 [7,8] のように車外にマイクロフォンを設置する手法は、一般的な車両に適用可能ではないうえに、車外では水はね以外にも自他車両の走行音や雨音など様々な要因による音響が発生するため、それらの雑音の混入により機械学習モデルの精度に悪影響を及ぼすことが考えられる。

3. 予備実験

先行研究 [6] では、実際の車両から収集した水はね発生区間の音響データと、水はね発生区間から時系列的に近い水はね非発生区間の音響データをそれぞれ 1 件ずつフーリエ変換し、周波数ごとの音響の強さを比較した。その結果、水はね発生区間は 5kHz から 11kHz の比較的低周波の領域で振幅が大きくなることが明らかになった。しかし、先行研究では 1 回の水はねから分割した音響データのみを用いていたため、様々な状況に共通した音響特徴を把握するうえで適切ではなかった。そこで本稿では、観測した複数の

表 1: データ収集環境

項目	収集環境
天候	雨天
路面状況	湿潤
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	16bit

水はねについて、水はね非発生区間との音響特徴の違いを分析した。

3.1 データ収集環境

表 1 に、音響データの収集環境を示す。データ収集は、後部座席上部にマイクロフォンを設置した車両で雨天時の公道を走行して行った。録音時のサンプリングレートは 44.1kHz、ビット長は 16bit であった。観測した 48 回の水はねをそれぞれにおいて、水はねを確認した区間とその周辺の音響データを 10 秒間切り出した後、水はね発生区間・非発生区間の音響データ各 1 件を 16,384 サンプルずつ選定し、フーリエ変換によりそれぞれのスペクトル包絡を作成した。そして、作成した水はね発生区間・非発生区間のスペクトル包絡に対し各周波数成分ごとに差分をとった。音響データ 1 件分は約 0.37 秒間に相当する範囲である。最後に、取得した水はね 48 回分のスペクトル包絡差分データを平均化した。

3.2 分析結果

図 1 に、作成したスペクトル包絡差分平均を示す。横軸が周波数 (kHz) を、縦軸が音響の強さの 2 乗に対数を取った値を示す。作成したスペクトル包絡差分平均から、12.5kHz 以下の周波数領域において水はね発生区間・非発生区間の差が大きく表れている。特に、その差は 2.5kHz 以下の周波数領域において大きく表れている。この分析結果から、先行研究 [6] の分析結果よりも低い周波数領域に水はねの音響特徴が現れていることが確認できる。

4. 音響センシングを用いた水はね検知手法の改善

4.1 提案手法の概要

提案手法の概要を以下に述べる。提案手法は、機械学習モデルの学習フェーズと、作成した機械学習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れる。図 2 に、本研究における水はね検知手法の概要図を示す。

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。

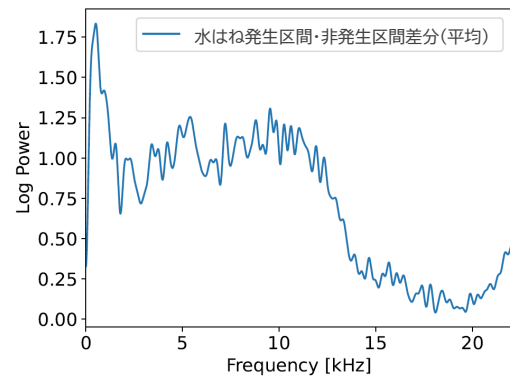


図 1: スペクトル包絡差分平均

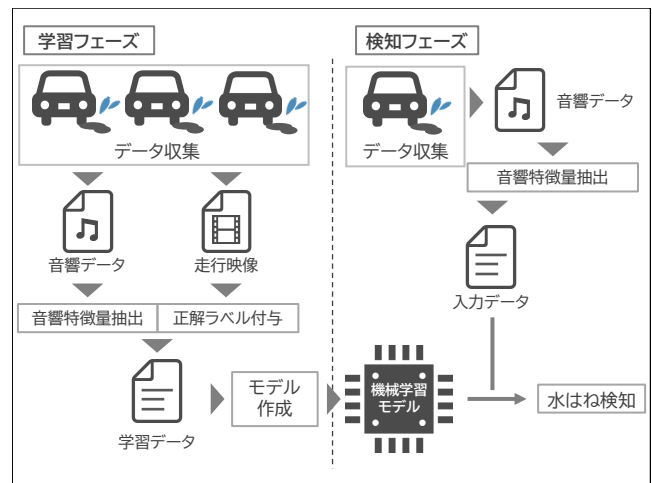


図 2: 水はね検知手法の概要

具体的なデータ分割処理の手順を以下に示す。

- (1) 車両走行時の音響データを走行映像とともに記録した後、走行映像から水はねの発生を判定する
- (2) 水はね発生部分を含む 10 秒間の音響データを、収集した音響データから切り出す
- (3) 切り出した 10 秒間の音響データについて、スペクトログラム*1および走行映像から水はねの発生区間・非発生区間を決定する
- (4) スライディングウィンドウにより音響データの分割・音響特徴量の抽出を行い、水はねの発生区間・非発生区間それぞれの正解ラベルを付与する

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、正解ラベルを付与する。最後に、それらを学習データとして入力し、水はねの有無を 2 クラスに分類する機械学習モデルを構築する。検知フェーズでは、構築した機械学習モデルに対し、新たに走行中に取得した音響データから抽出した音響特徴量を入力することで水はねの有無を検知する。

本研究では、車内からの走行映像において車窓に水はね

*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。

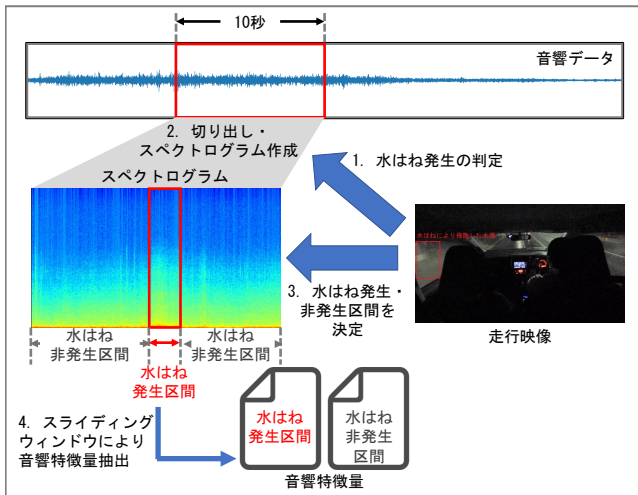



図 3: 音響データ分割の流れ



(a) 水はね発生区間の車内および車外



(b) 水はね非発生区間の車内および車外

図 4: 車内および車外の映像

の水滴を確認した際の音響を水はね発生区間、それ以外の音響を水はね非発生区間として定義する。図 4(a) に、水はね発生区間の車内および車外の様子を示す。図 4(b) に、水はね非発生区間の車内および車外の様子を示す。

4.2 先行研究の課題に対する改善点

先行研究 [6] では、水はね発生区間の音響データから音響特徴量を抽出し、SVM により水はねを検知する機械学習モデルを作成・評価した。結果として F 値 98.1% の精度で水はねを検知したが、先行研究の手法には以下のような課題がある。

課題 1 水はねの検知に用いる適切な音響特徴量に関する検討が不足している

課題 2 水はねの音響の振幅における違いが水はね検知精度に悪影響を及ぼしている可能性がある

これらの課題に対して、本稿では以下に示す改善を行う。

改善策 1 水はねの音響特徴を適切に反映するため、複数の水はねに対するデータ分析の結果を反映した音響特徴量を用いる

改善策 2 音響振幅値による影響を除去するため、音響振幅値を正規化する

以降で、各改善策を実施した内容について述べる。

4.3 音響特徴量

先行研究 [6] では、初期的検討として関連研究 [7-9] および音声認識分野で広く使用されている既存の音響特徴量を用いた。本稿では、水はねの音響特徴をより適切に反映する音響特徴量について検討し、以下に示す 3 種類の音響特徴量を用いる。各音響特徴量の詳細について後述する。

(1) Mel-Frequency Cepstral Coefficient (MFCC)

(2) Linear-Frequency Cepstral Coefficient (LFCC)

(3) Splash-Frequency Cepstral Coefficient (SFCC)


(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。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。図 5(a) に、作成したフィルタバンクを示す。MFCC は低周波領域ほど分解能が高いため、同じく低周波数領域に特徴が表れる水はねの検知に有効であると考え用いる。

(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図 5(b) に示す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 は全周波数領域において分解能が一定であるため、周波数領域ごとに分解能を変化させた MFCC、および後述する SFCC の比較対象として用いる。

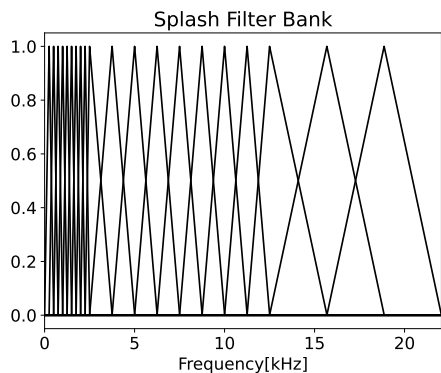
(3) の SFCC は、3 章の分析に基づき、周波数ごとの分解能を変化させた音響特徴量である。SFCC は、音響のスペクトルに対し、独自に作成した水はね特化フィルタバンクを掛け合わせ、離散コサイン変換を行うことで作成する。図 5(c) に、作成した水はね特化フィルタバンクを示す。水はね特化フィルタバンクでは、2.5kHz 以下の領域における分解能を高く、2.5kHz 以上 12.5kHz 以下の分解能を中程度とし、12.5kHz 以上の分解能を低く設定した。水はね発生区間における音響特徴を正確に反映することを目的として用いる。

4.4 音響振幅値の正規化

先行研究 [6] では、使用する音響振幅値を正規化せずに音響特徴量を抽出していた。しかし、音響の振幅が特徴量に反映されることにより、周囲の雑音や水はねの振幅の大



(a) メルフィルタバンク (b) 線形フィルタバンク



(c) 水はね特化フィルタバンク

図 5: 音響特徴量

きさが異なる音響データの分類に悪影響を及ぼしていた可能性が考えられる。そこで、本稿では使用する音響振幅値を正規化したうえで音響特徴量を抽出することで、音響の振幅による影響を取り払い、機械学習モデルの精度向上を図る。

5. 評価実験および考察

本章では、4章にて述べた各改善点を反映した機械学習モデルの作成・評価を行った結果について報告する。

5.1 実験条件

評価実験は、函館市内の公道を2回に分けて走行することで行った。詳細なデータ収集環境は表1の通りとした。収集した音響データは4.1節の方法に基づき分割し、水はね発生区間・非水はね発生区間に対応する正解ラベルを付与した。その後、ウィンドウサイズ16,384サンプル、オーバーラップ50%として、ウィンドウごとに19次元の音響特徴量を、MFCC、LFCC、SFCCそれぞれについて抽出した。

本稿では、4.3節に示す3種類の各音響特徴量について、音響振幅値の正規化を実施した条件と実施しない条件の2条件で検証した。表2に、本稿における実験条件を示す。条件2の音響データに対しては、4.4節に基づきEBU-R128に準拠した音響振幅値の正規化を行った。

5.2 評価方法

本章では、提案手法の評価に関する詳細を述べる。本稿では、4章にて述べた改善策のほか、先行研究[6]の評価方

表 2: 実験条件

条件	データ件数	音響振幅値の正規化
条件1	596件	なし
条件2	596件	あり

法に対するいくつかの改善を行った。

5.2.1 音響データの拡充と絞り込み

先行研究[6]では、観測した18回の水はねの音響データから4.1節の方法に基づき、水はね・非水はね各128件のデータから音響特徴量を抽出した。

しかし、先行研究の問題点として、学習に用いたデータの件数が少なく、多様な環境における提案手法の精度を評価するうえで不十分であった。そのため、本稿では水はね70回分の音響データを用い、機械学習モデルを作成・評価した。また、4.1節のデータ分割方法では、水はね発生区間の音響特徴量は水はね発生区間よりも多数抽出される傾向にある。機械学習モデルにおける水はね・非水はねの偏りを防ぐため、水はね発生区間の音響特徴量から水はね発生区間の音響特徴量と同数のデータをランダムに絞り込んだ。このとき、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が低下することを防止するよう試みた。

5.2.2 学習データと検証データの分割

先行研究[6]では、水はね1回あたりからスライディングウィンドウにより多数の音響特徴量を抽出し、音響特徴量単位で5分割交差検証を行うことで、機械学習モデルの精度を評価した。しかし、音響特徴量単位で5分割したことにより、類似した音響特徴量が学習データと検証データの両方に含まれていた可能性がある。この場合、機械学習モデルの精度が実際よりも高くなってしまいう可能性がある。そのため本稿では、全70回の水はねを14回ずつ5グループに分割し、1グループを検証データ、残り4グループを学習データとする5分割交差検証を行った。

5.3 実験結果・分析

本節では、提案手法を5.1節にて述べた2条件で評価した結果について、音響特徴量および音響振幅値の正規化の観点から分析した結果を述べる。表3に、各条件、各音響特徴量ごとに作成した機械学習モデルに対し5分割交差検証でF値の平均値を求めた結果を示す。条件1,2の両方において、先行研究[6]からの低下がみられるが、依然として、90%前後の高い精度を保っていることが確認できた。

5.3.1 音響特徴量に関する分析

条件1,2の両方において、MFCC、SFCC、LFCCの順で高い精度を示した。MFCCやSFCCのような低周波領域に着目した音響特徴量がLFCCよりも高い精度を示すことは、3章における水はね発生区間・非発生区間の差が低

表 3: 機械学習モデルの 5 分割交差検証結果

	条件 1	条件 2
MFCC	91.85%	90.90%
LFCC	87.79%	88.16%
SFCC	89.10%	89.61%

周波領域に表れやすいという特徴に一致する。そのため、水はねの検知においては MFCC や SFCC のように低周波領域に着目した音響特徴量が有効である可能性が示唆された。

しかし、水はねの音響特徴を分解能に反映した SFCC の精度が MFCC より低かったことから、適切な指標により効果的に水はねを検知する音響特徴量を抽出する必要性が示唆された。本研究では、SFCC の分解能を決定する指標が定性的であった。この課題に対して、定量的指標を用いて水はね発生区間・非発生区間における各音響スペクトルの差分を周波数ごとの分解能に反映することが必要である。また、文献 [7,9] では、音響データの時間領域に着目した特徴量を用いることで分類精度を向上しているため、本研究でも水はねの時系列性を特徴量に反映することの有効性を検証する必要がある。

5.3.2 音響振幅値の正規化に関する分析

条件 1, 2 を比較すると、LFCC, SFCC においては正規化によりそれぞれ 0.37% および 0.51% の精度向上がみられた。しかし、MFCC については 0.95% の精度低下がみられた。

音響振幅値の正規化による機械学習モデルへの影響を詳細に分析するため、条件 1, 2 における各音響特徴量について混同行列を作成・比較した。図 6 に、条件 1, 2 における MFCC, LFCC および SFCC 各混同行列を示す。図 6(a) および図 6(b) に MFCC の混同行列、図 6(c) および図 6(d) に LFCC の混同行列、図 6(e) および図 6(f) に SFCC の混同行列を示す。

MFCC については、水はねを非水はねと誤分類する事象が 1 件、非水はねを水はねと誤分類する事象が 3 件増加した。True Positive (TP) と True Negative (TN) の合計値が 4 件減少しており、若干の精度低下が確認できた。LFCC については、水はねを非水はねと誤分類する事象が 6 件減少し、対照的に非水はねを水はねと誤分類する事象が 6 件増加した。TP と TN の合計値は条件 1, 2 で同じであり、明確な精度向上は確認できなかった。SFCC については、水はねを非水はねと誤分類する事象が 2 件、非水はねを水はねと誤分類する事象が 3 件減少した、TP と TN の合計値が 5 件増加しており、若干の精度向上が確認できた。

表 3 の結果と図 6 の各混同行列の結果から、音響振幅値を正規化した機械学習モデルの精度に対する影響は ± 1% 未満であり、各混同行列においても分類に影響を受ける

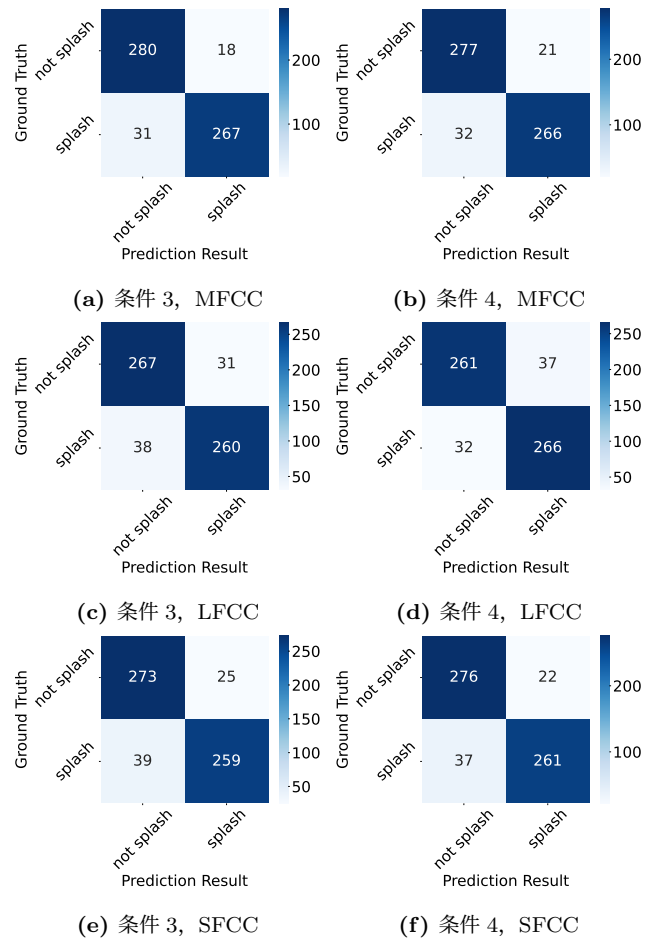


図 6: 条件、音響特徴量ごとの混同行列

データは 20 件未満であった。このことから、音響データの正規化は機械学習モデルの精度に大きく影響しないことが示唆された。この要因として、収集した水はね発生区間の音響データ同士が類似していた可能性が考えられる。本稿では、同一の実験条件で水はねを観測した。また、観測対象の水はねについては車内から確認できる程度に大きいもののみとした。そのため、音響振幅値の正規化による効果を検証するには、車両、天候、路面状況、交通量、車内での会話の有無、オーディオ機器使用の有無といった各条件や、観測される水はねの大きさを変化させた音響データを収集し、再度機械学習モデルを構築する必要がある。

5.3.3 考察まとめ

先行研究 [6] では、LFCC の精度が MFCC を上回っていたが、5.3.1 項の結果により、MFCC などの低周波に着目した音響特徴量の有効性が示された。また、5.3.2 項では、音響振幅値の正規化による明確な精度への影響は示されず、音響データの多様性を確保する必要性が示された。

さらに、提案手法における精度は先行研究 [6] を下回ったものの、依然として 90% 前後の高い精度を示したことから、提案手法の音響センシングによる水はね検知の有効性が確認された。

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、本研究では音響センシングを用いた手法を提案する。先行研究 [6] では、周波数領域ごとの分解能が異なる 2 種類の音響特徴量を用いて、水はねの有無を 2 クラスに分類する機械学習モデルを作成した。本稿では、先行研究における音響特徴量の検討や音響振幅値の正規化に関する課題を改善した水はね検知手法を提案した。結果として、改善後の提案手法による音響センシングは水はね検知に有効であること、MFCC や SFCC といった低周波領域に着目した音響特徴量が有効であること、音響振幅値の正規化は水はねの検知精度に大きく影響しないことを確認した。

今後の課題として、周波数領域ごとの水はねの特徴を定量的に反映する音響特徴量および水はねの時系列性を反映する音響特徴量を抽出する必要性があげられる。また、正規化の有効性を検証するために使用する音響データを多様化する必要性があげられる。今後はこれらの課題に取り組むとともに、一般車両に普及した機器を用いた音響データの収集や、車内雑音の多い環境下での水はね検知に関する検討を行う。

謝辞 本稿で示した研究の一部は、JSPS 科研費 JP20K11793 の助成を受けたものである。

参考文献

- [1] 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プ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).
- [2] 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).
- [3] 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).
- [4] 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).
- [5] 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).
- [6] 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).
- [7] 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).
- [8] 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).
- [9] 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).