

クラウドソースによるモバイルセンシングを用いた路面状況推定

朴 斌^{1,a)} 相原 健郎^{1,2,b)}

受付日 2017年12月22日, 採録日 2018年7月10日

概要: 路面状況の判別は、交通安全や運転の快適性を確保するために不可欠な技術である。本論文では、クラウドソースによるモバイルセンシングを用いた新たな路面状況推定手法を提案する。提案手法は、参加型センシングの観点から、一般の自動車利用者のスマートフォンをセンサとして、走行時に収集されたモーションセンサのみのデータを用いて路面状態（凍結、シャーベット、舗装路など）と路面形状（バンプ、穴、平坦など）の両方の推定を可能にする。提案手法では、2つのモジュール：1) 車両走行モードクラスタリング（VTMC：Vehicle Travel Mode Clustering）モジュールと、2) 路面状況分類（RSCC：Road Surface Condition Classification）モジュールを用いて路面の推定を行う。VTMCモジュールは、K-meansアルゴリズムを用いて各運転ごとの車両走行モードのクラスタリングすることで、ユーザ間の個人差を考慮する必要がなく、複数のユーザから収集したデータを統合した路面状況の推定を可能にする。一方RSCCモジュールは生成された各クラスに振られ、Random Forest 分類器を用いて各クラス内で路面状態の推定を行う。本論文では提案手法を実際のフィールドにおいて収集した走行データに適用し、その有用性についての検証を行った。その結果、提案手法による路面状況推定の平均正解率は90%を超える。

キーワード: 路面状況推定, モバイルセンシング, クラウドソーシング

Detecting the Road Surface Condition by Using Mobile Crowdsensing with Drive Recorder

BIN PIAO^{1,a)} KENRO AIHARA^{1,2,b)}

Received: December 22, 2017, Accepted: July 10, 2018

Abstract: Road surface conditions affect transport safety and driving comfort, particularly in snowy areas. This paper proposes a new method for detecting road surface conditions based on crowdsourced mobile sensing technology. The method can efficiently detect road surface conditions using motion sensors embedded in smartphones mounted on vehicles. Detecting road conditions using such sensors, which are usually loosely placed in the vehicle, nonetheless poses a challenge. Our approach comprises two modules: a VTMC (Vehicle Travel Mode Clustering) module and RSCC (Road Surface Condition Classification) module. The VTMC module uses a K-means algorithm to distribute the vehicle travel mode into a proper cluster. This module enable to estimate road surface conditions by integrating data collected from multiple users without having to consider individual differences among users. The RSCC module uses the random forest classifier, which is assigned to each group of vehicle travel mode, to classify the road surface conditions. We defined new road surface conditions as the estimation target, considering both the substance that covers the road surface and the shape of the road surface itself. The results show that our approach can detect road surface conditions with accuracy as high as 90%.

Keywords: road condition detection, mobile sensing, crowdsourcing

¹ 国立情報学研究所
National Institute of Informatics, Chiyoda, Tokyo 101-8430, Japan

² 総合研究大学院大学
SOKENDAI (The Graduate University for Advanced Studies), Hayama, Kanagawa 240-0193, Japan

1. はじめに

路面状況は交通安全や運転の快適性に重大な影響を与え

^{a)} pakuhin@gmail.com

^{b)} kenro.aihara@nii.ac.jp




図 1 異なる路面状態における交通事故の発生率 [23]

Fig. 1 Traffic accident rates for different road surface conditions [23].

る社会的問題として注目されてきた。特に降雪地域では、路面の悪化は、冬型事故（積雪、凍結、吹雪などの冬期現象が事故発生の直接または間接の要因になった事故）を起こす主な原因の1つとして知られている。国総研の研究資料 [23] によると、冬型事故の約9割はスリップによるものであり、各路面状態における発生率は、図 1 に示すように、凍結路面が最も多く、全体の5割を占めている。冬期の路面は、降積雪、気温、日の当たり具合、交通量などの様々な要素の影響を受け、時間帯や場所によってその路面状態（RST：Road Surface Type）や路面形状（RSS：Road Surface Shape）には大きな差が生じる場合がある。

冬期の安全で円滑な交通を確保するためには、危険な路面状態を素早く検出する必要がある。しかし、現状は除雪員のパトロールなど人手による状況確認によっている [25]。一方、路面の推定に関する研究は多く行われているものの、高価な専用センサの導入を必要とするものが多く、広範囲・高頻度のモニタリングを行うにはコストが高い。

近年、クラウドソーシングの一種としてユーザ参加型センシング [2] という、多様なセンサが組み込まれたモバイルデバイスを持ち歩く歩行者や自動車をセンサと見なし、広範囲にわたる情報を低コストで収集できる技術が注目され、多くの研究がなされてきた [6], [14]。さらに、それらモバイルデバイスの1つであるスマートフォンが広く普及しコモディティ化したことによって、その潜在的な参加可能者の数も増え、都市規模のセンシングも可能となりつつある。これらの特徴から、参加型センシングによる路面モニタリングはコストが低く、実現性が高いと考えられ、その実用化が期待されている。

本論文では、参加型センシングの観点から、一般の自動車利用者のスマートフォンをセンサとして、走行時の位置、加速度などのログデータを収集し、それを用いて路面状態と路面形状の両方を含む路面状況の推定を行う新たな手法を提案する。提案手法は、2つのモジュール：1) 車両走行モードクラスタリング（VTMC：Vehicle Travel Mode

Clustreing）モジュールと、2) 路面状況分類（RSCC：Road Surface Condition Classification）モジュールを用いて路面の推定を行う。VTMC モジュールでは、車種、スマートフォンの設置位置、乗員数など不確定要素の相違によって生じる異なる震動パターンを車両走行モードと見なし、K-means アルゴリズムを用いてそれらのクラスタリングを行う。一方 RSCC モジュールは、生成された各クラスに振られ、各クラス内で路面状況の推定を行う。これにより、車種、スマートフォンの設置位置、乗員数など不確定要素による影響を減少させ、より高精度の路面状況推定を可能とする。

本研究における参加型センシングの方法論は、我々の先行研究 [1] で提案されている。この方法論に基づいて本研究では、*Drive around-the-corner*. (Drive ATC.) というスマートフォンアプリケーションを開発・公開した。このアプリは映像とともに走行時の各種センサのログデータを運転記録としてクラウド上のサーバ側に転送し、保存することができる。利用者は保存容量などを気にする必要はなく、運転中に記録した映像や自分の走行記録などを後でクラウド上で確認することができる。さらに、推定結果を Drive ATC. や専用の Web ページでリアルタイムに公開することによって、最新の路面状況を共有できる環境を提供する、これにより利用者の参加を促し、サービスの高度化を実現する好循環を生み出すことを目指す。

本論文の構成は以下のとおりである。2章では本論文で提案する路面状況推定手法と関連研究の比較を行う。3章では開発した Drive ATC. の概要を説明する。4章では推定対象となる路面状況の定義について説明する。5章では提案手法の概要を説明する。6章では実験とその結果について詳述する。最後に、結論を7章で述べる。

2. 関連研究と課題

本章では、路面状況の推定に関する既存研究を、それらの利用するセンサ機器によって、カメラを用いた画像処理による路面状態推定と、加速度センサを用いた路面形状推定の2種類に分けて説明するとともに、推定できる路面の種類、推定精度、ロバスト性、機器導入および実施のコストの4つの観点から、本研究との比較を行う。

2.1 路面状態の推定：カメラ画像の処理に基づく手法

カメラを用いた既存の路面状態推定システムは、主に冬期の雪道を対象とし、凍結、積雪、乾燥などの RST の推定を目的としている。路面状態推定に使うカメラは大きく分けて、道路側に設置された固定カメラと車載カメラの2種類がある。

2.1.1 固定カメラ

現在、道路管理者の情報収集や共有化、および利用者への情報提供のために、数多くの道路監視用カメラ（CCTV）

表 1 従来手法のまとめ
Table 1 Summary of related works.

		推定対象		推定精度	ロバスト性	導入および実装コスト
		路面状態 (RST)	路面形状 (RSS)			
加速度	文献 [5]	×	✓	高	高	高
	文献 [3], [15], [22]	×	✓	高	高	低
車載カメラ	文献 [10], [13], [16], [18]	✓	×	低	低	低
	文献 [26]	✓	×	高	中	高
固定カメラ	文献 [9]	✓	×	高	中	高

が全国範囲で設置されるようになった。したがって、これらを用いた事故や災害、路面凍結などの危険事象の検知に関する研究が多く行われている。Jonsson らは、このような道路側に固定されているカメラを用いて凍結、乾燥、濡れ、圧雪などの路面状態を推定する手法を提案した [9]。その推定精度は平均 90%以上を示しており、天気情報を併用した場合には、平均 95%を超えている。固定カメラは光源を確保しやすく、常時のモニタリングが可能である。しかし、モニタリング対象が設置した場所に限定され、都市全域を網羅するモニタリングを行うためには、膨大なコストがかかる。

2.1.2 車載カメラ

ドライブレコーダやスマートフォンなどの低コストの車載カメラを使って路面状態を推定するシステムを提案されている [10], [13], [16], [18]。Omer ら [16] や Kawai ら [10] の提案システムは、高い推定精度で乾燥路面、濡れた路面、積雪路面の 3 つの路面状態の推定を可能にしている。しかしながら、最も危険とされている凍結路面の推定ができないという制約がある。Linton らは、スマートフォン内蔵のカメラを用いた路面状態推定手法を提案し、高い推定精度を持つ固定カメラを用いた路面状態推定手法と比較しながら、その実用性を証明した [13]。しかし、比較対象となる路面状態に凍結路面は含まれていない。これに対し Qian らは、凍結路面の推定を対象としている [18]。ここでは、推定精度は約 62%にとどまっております、精度の向上が求められる。山田らは、2 枚の偏光フィルムを取り付けた特殊な車載カメラを使った路面状態を推定するシステムを提案した [26]。推定精度は高いが、機器導入のコストが相対的に高く、対象地域全域にわたっての走査には課題がある。

上記の関連研究とは異なるアプローチの提案として、花塚らによる、タイヤの振動波形を用いた路面状態推定手法がある [24]。推定精度は高いが、振動波形を計測できる専用のタイヤが必要となり、機器導入のコストが非常に高い。そのため、この手法には実用上の課題が少なくないと判断し、本論文では比較対象から除外する。

2.2 路面形状の推定：加速度センサを用いた手法

加速度センサを用いた既存の路面形状推定システムは、主

に雪のない舗装路を対象として、その平坦性や、くぼみなどの異常、すなわち RSS の推定を目的としている。舗装路の平坦性の評価には、国際ラフネス指数 (IRI: International Roughness Index) [19] が世界共通指標として広く使われている。正確な IRI を算出するためには専用のロードプロファイラが必要となるので、多くの研究は車載の加速度計を用いて近似の IRI を推定することに注目している。Fujino らは、IRI と車載加速度センサの垂直方向の二乗平均平方根 (RMS: Root Mean Square) は強い相関性を持つことを示し、その相関性に基づいて一般車両を用いた IRI の近似計算を可能にした [5]。この手法では、車種ごとに手で相関係数を測定する必要があることから、一般車両を用いるうえでの課題となる。また Yagi らは、車の減衰比と共振周波数を自動的に推定し、それらを用いて IRI を算出するスプリングダンパーモデルを提案している [22]。Nomura らは、独自のラフネス指標を用いて路面形状を 3 つのグループに分類し、同じ道路セグメントの異なる時期の路面形状の変化を検知する手法を提案している [15]。

2.3 問題点

関連研究の概要を表 1 示す。表 1 に示すように、上述した関連研究では、RSS と RST の両方を推定できるものは存在しない。また、カメラによる路面状態推定は、本質的に光学的条件に精度などが依存するため、悪天候や夜中などの条件下ではそれらの環境の影響を受けることから、加速度計を用いた路面推定と比較するとロバスト性の観点で制約が大きい。さらに、凍結路面が薄い雪に覆われている場合、カメラの画像からは雪としか認識できない恐れがあり、それらの危険な凍結状態の検出に課題があると考えられる。そこで、本研究では、RSS と RST の両方を推定の対象とし、加速度などのモーションセンサのみを用いて路面状態を推定する手法を提案する。

3. クラウドソーシングサービスによるセンシング

筆者らは、クラウドソーシングにより路面状況を反映したデータを広く収集するための機構として、ドライブレコーダアプリケーションサービス Drive ATC. を開発し、




図 2 スマートフォンの車載例

Fig. 2 Examples of smartphones mounted in the vehicle.

表 2 Drive ATC. での収集データの種類
Table 2 Drive ATC. collected data types.

種別	属性
位置	緯度, 経度, 高度, 精度 (垂直, 水平)
方位	真北に対する方位角, 精度
移動	速度, 移動方向
加速度	x, y, z
回転速度	x, y, z

2016年2月から一般公開している。このサービスは、専用のiOSアプリケーション*1を用いて利用者は利用することができる。図2に示すように、利用者は自分のスマートフォンをダッシュボードなどに設置し、必要に応じて電源ケーブルを接続して、Drive ATC. アプリケーションを起動させておくだけで、運転中の行動ログや映像が自動的に記録され、サーバ側にアップロードされる。また、他の利用者によって収集や投稿されたイベントなどの情報を地図上で確認することができる。

ドライブレコーディング機能が無償で利用できるということ、運転記録がクラウド上に自動で保存され、後で自由に見返すことができること、道路状況の情報をリアルタイムに得られること、などの特徴によって、利用者のサービスへの参加の動機付けが高まることが期待される。

3.1 ドライブレコーディング機能

本機能は、スマートフォンが取得する位置情報 (GPS, Wi-Fi, 基地局による測位) と加速度および回転 (ジャイロ) のセンサ情報、走行中のカメラ映像を記録するものである。収集されたセンサデータの詳細を表2に示す。ここでは、2種類のカメラ映像が記録される。1つは、後でスムーズな映像として利用者自身が見直すことができる高品質なもので、スマートフォン内に保存される。一般的なドライブレコーダが記録するものに相当する。ここでは、解像度 1,280 × 720, フレームレート 30 fps としている。もう1つは、クラウドに5分おきに無線通信回線を通じて送信されるもので、走行状況に応じてフレームレートを動的に変更し、ファイルサイズを圧縮した間欠映像である。ここでは、路面状況や交通状況が悪い場所の方がより他者に

*1 <https://itunes.apple.com/app/drive-around-the-corner./id1053216595>



(a) メイン画面 (Main Screen)



(b) イベント投稿画面 (Posting Events)

図 3 Drive around-the-corner. アプリケーションの画面例
Fig. 3 Snapshots of the Drive around-the-corner. application.

にとって重要であろうという仮定を置き、低速や渋滞などの走行状態のフレームレートを相対的に高くし、逆に高速でスムーズな走行ができているときはフレームレートを下げるといったルールに基づき調整が行われている。

3.2 イベント投稿と表示

イベントの投稿は、車両が静止しているときにユーザが道路上のイベントを他人に報告できる機能である。画面右上にあるフットプリントマーカをタップすると、図3(b)のようにイベント選択画面が表示される。このアプリケーションでは、3つのカテゴリ：渋滞、路面状況、交通障害、計8つのイベント候補を提供している。選択されたイベントは、時刻と位置情報とともにサーバに送信される。

投稿されたイベント情報は、利用者のマップ上に表示される (図3(a))。たとえば、図3(a)中央に位置する黄色のアイコンは、他のサービス利用者によって投稿された道路工事イベントを示している。

4. 路面状況定義

本章では、推定対象となる路面状況の定義を行う。本論文では、路面状況を路面状態 (RST) と路面形状 (RSS) の組合せとして定義する。ここで、RST は山田らの手法 [26] を参考に、提案された舗装路、シャーベット、圧雪、凍結の4つの路面状態を推定の対象とする。表3に各路面状態の定義を示す。一方RSSについては、Yagiら [22] や Nomuraら [15] の従来の研究では、高サンプリングレート (100 Hz 以上) を採用した加速度センサを用いて、定量化による路面形状の定義を行っている。本研究では、センサデータの通信量とスマートフォンの計測および処理の負荷の抑制のために、加速度やジャイロの収集に 30 Hz のサンプリング・レートを採用した。従来の路面形状の推定手法



図 4 検知対象となる路面状況の例

Fig. 4 Some examples of the defined road surface conditions.

表 3 路面状態定義

Table 3 Road surface type definitions.

路面状態	定義
舗装路	アスファルトやコンクリートによって舗装されており、雪、氷、などのかぶり物がない状態
シャーベット	路面が水と雪氷の混合物に覆われている状態
圧雪	路面が乾燥した雪に覆われている状態
凍結	路面が凍結した雪や氷に覆われている状態

表 4 路面形状定義

Table 4 Road surface shape definitions.

路面形状	定義
平坦	突起や穴のない状態
バンブ	周囲の路面に比べ突起している状態 (例：減速バンブ、凍結による水玉のような突起など)
くぼみ	路面上に大きな穴がある状態 (例：舗装路の陥没による穴、路面上の積雪または氷が局部的に溶けることによって生成する穴など)
バンブ&くぼみ	バンブとくぼみが混在している状態

に比べ低いサンプリング・レートであるが、本研究では、路面形状の詳細かつ正確な推定を目的とはしておらず、運転の快適さに影響を及ぼすと考えられる平坦、バンブ、くぼみ、バンブ&くぼみの4つの路面形状を推定の対象とする。表 4 に各路面形状の定義を示す。図 4 に路面状況の例を示す。図 4(a), 図 4(b), 図 4(c) はすべて凍結の路面を表しているが、その形状は異なっている。1 章で述べたように、凍結路面は最も危険とされているが、これらの路面状況は気温が低い夜中に発生する可能性が高く、カメラ映像の解析に基づく冬期路面状況推定の従来手法では、有効性に課題がある。図 4(d) は、くぼみのあるシャーベット路面を表している。このような路面は気温の高い昼間に発生することが多く、不規則にあるくぼみを徐行もしくは回避しながら通行する必要があるため、速度、挙動ともに、

スムーズな走行が困難となる。図 4(e) は平坦な圧雪路面を表している。このような路面は冬用タイヤ装着車であれば比較的問題なく通行できるが、それでもスリップする可能性は一般の舗装路に比べ高い。

5. データセット

本研究では、開発したドライブレコーダアプリケーションサービス Drive ATC. の一般市民への告知効果を高めるため、札幌市を実験フィールドとして告知の範囲を絞った。札幌市の年間積雪量は 6m に迫り、人口 100 万人以上の世界中の都市の中で最も多く、除排雪の年間予算は 180 億円

に達する [20]. Drive ATC. で収集された実際の札幌市における走行データの量は、2017 年 3 月末時点で約 200 万点以上の位置情報、5,000 万以上の加速度データに達している。これらはすべて一般市民の日常生活の中で収集した走行データである。

路面状況推定の正解データのために、収集された実際のデータから、対象期間を雪の影響を大きく受ける冬期(1月~3月)に限定し、雪道での走行回数が多い5人の一般ユーザの40の独立した走行軌跡(トラジェクトリ)のべ333kmに対し、映像から路面状況を目視で確認し定義したRSTとRSSのラベルを付けた。正解データの信頼性を考慮し、雪道での運転経験がある3人がそれぞれ作成したデータを用いて、投票によって同一路面のRSTとRSSの両方に対し、ともに2つ以上の同じラベルが付けられた場合のみを最終的な正解データと決めた。作成した正解データの各速度域での分布を図5に示す。正解データには定義したすべての路面状況を含んでおらず、各路面状況の数も不均等である。特に、走行速度におけるRSSの分布は図6に示すように、高速になるほど、平坦な路面の割合は高くなり、50km/hを超えた場合、99%以上が平坦であることが分かる。これは、一般市民の日常生活の中で収集した走

行データを用いたのが大きな要因の1つと考えられる。通常の市街地などでの走行では、高速で走行可能な路面は平坦であると考えられるが、それを示しているともいえる。利用者および蓄積されるデータの総量が増えることによって、収集される路面状況の網羅性も高くなると考えられるが、日常生活の中での走行データのみ利用した場合、均等な学習データの収集および作成は課題があるといえる。

6. 提案手法

提案手法は、2つのモジュール：1) 車両走行モードクラスタリング (VTMC: Vehicle Travel Mode Clustering) モジュールと、2) 路面状況分類 (RSCC: Road Surface Condition Classification) モジュールを用いて路面状況の推定を行う。VTMCモジュールでは、車種、スマートフォンの設置位置、乗員数など不確定要素の相違によって、走行中に生じる異なる垂直方向と車軸方向の震動パターンを車両走行モードと見なし、K-means アルゴリズムを用いてそれらのクラスタリングを行う。RSCCモジュールは生成された各クラスに振られ、各クラス内で路面状態の推定を行う。

6.1 VTMC モジュール

車両走行モードは、車種、スマートフォンの設置位置やマウント方法、乗員数などによって影響を受けるため、同一ユーザであっても、各運転ごとに変動する可能性がある。したがって、ユーザごとに車両走行モードを定めるのは困難である。一方、一回の走行に関しては、車種、スマートフォンの設置状態、乗員や荷物などの搭載状況などの要素が変動する可能性は低くなると考えられる。そのため、車両走行モードは各運転ごとに特定することが適切だと考えられる。

センサデータから各走行ごとの車両走行モードを抽出するには、路面と運転操作による影響を除去する必要がある。路面からの影響は、同じ路面状況を走行する際のセンサデータを用いることによって埋め合わせをすることができる。本研究では、各走行から震動が少ない平坦な路面を走行する際のセンサデータを用いる。

一方、ドライバによる運転操作は、主に加速、減速、左折、右折などあり、これらは車両の進行方向と車軸方向の加速度に影響を及ぼす。Heらの報告[8]によれば、人間の行動は主に低周波領域で行われていることが多いとされる。したがって、高周波領域のみに着目することで運転操作による影響を除去することが可能だと考えられる。

これらを考慮して、VTMCモジュールでは、各トラジェクトリから図6に示すように平坦な路面の割合が高い50km/hを超える速度域での1分間の走行データを用いて、トラジェクトリごとの車両走行モードの特徴量を算出する。具体的には、1分間の走行データに対し、2秒の時間窓を1秒間隔でスライドしながら、各時間窓内で、垂直方向加速度のRMSと車軸方向加速度の高周波数帯部分の

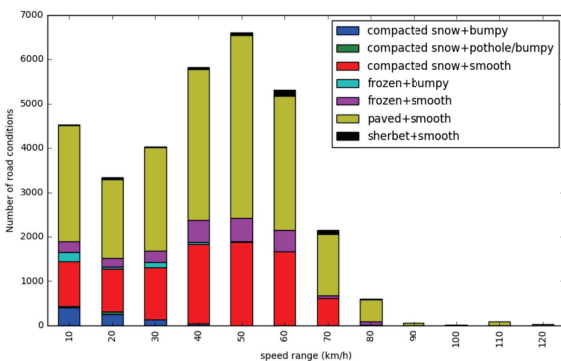


図5 各速度域における路面状況ごとのデータ数

Fig. 5 Numbers of each road condition in different speed ranges.




図6 走行速度と平坦路面の割合

Fig. 6 The rate of flat road surface in different domains of speed.

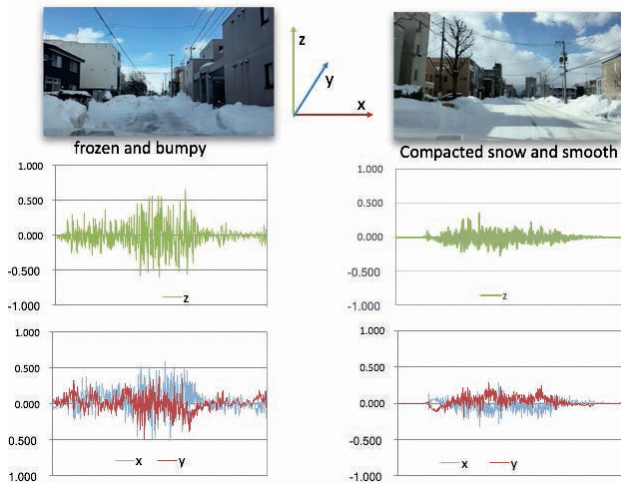


図 7 路面状況と加速度の例

Fig. 7 Examples of road condition and corresponding accelerations.

エネルギーを算出する。エネルギーは、フーリエ変換の直流部分を除いたフーリエ係数の和である。算出した垂直方向加速度の RMS と車軸方向加速度の高周波数帯部分のエネルギーの回帰回線を求め、その回帰係数、切片、決定係数を、車両走行モードの特徴量とする。

車両走行モードのクラスタリングには K-means アルゴリズム [4] を用いる。K-means を用いた教師なしのクラスタリングにおいて、適切なクラスタ数 k を選択するのは一般に容易ではなく、 k を推定するための多く研究がなされてきた [17]。しかし、同じデータセットであっても、何を特徴量として持ち、何を得ようとするかによってその見方は異なり、最終的には利用者による決定が必要となる。本研究では、路面推定の精度に重点を置きながらクラスタ内の平均誤差の和を評価の指標とするエルボ法を用いて k の推定を行う。

6.2 RSCC モジュール

図 7 に、異なる 2 つの路面（左：凍結 + バンプ、右：圧雪 + 平坦）を走行する際に収集された生の加速度データの例を示す。この例では、それぞれ直進しているにもかかわらず、左側のバンプがある凍結路面における鉛直 (z) と車軸 (x) の両方向の加速度の変化は、右側の平坦な圧雪路面より大きいことが分かる。これは、バンプ路面による鉛直方向の震動の増加とともに、凍結によって横方向にスリップ現象が起こっており、それが車軸方向の加速度として現れていると考えられる。このように、走行中の加速度データは RST と RSS の両方の影響を受ける可能性が高く、特徴量の選択次第で、加速度だけでも RST と RSS の両方の推定が実現可能であると考えている。

6.2.1 特徴量抽出

3 軸加速度センサを用いた行動分析は、人間活動認識分野で多く利用されている [7], [11], [21]。これらの研究では、日常の活動を有効に認識するための特徴量を数多く提案し

表 5 路面状況推定における特徴量の初期集合

Table 5 Initial set of features for estimating the road surface condition.

種別	特徴量
平均	$mean_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$
標準偏差	$std_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$
相関	$correlation_t (t \in \{x_a - y_a, y_a - z_a, z_a - x_a, x_g - y_g, y_g - z_g, z_g - x_g\})$
エネルギー	$energy_{t_i} (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\}, i \in [0, 4])$
エントロピー	$entropy_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$
最大	$max_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$
最小	$min_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$
平均速度	$mstp_t (t \in \{x_a, y_a, z_a, x_g, y_g, z_g\})$

てきた。本研究では、人間活動認識でのモデルを参考に、これらで提案された特徴量を用いて路面状況の推定を行う。提案手法では、2 秒の時間窓を 1 秒間隔でスライドしながら、加速度およびジャイロの各軸の信号から特徴量を算出する。特徴量の詳細を表 5 に示す。ここで、 x_a, y_a, z_a はそれぞれ加速度の 3 軸を表し、 x_g, y_g, z_g はそれぞれジャイロの 3 軸を表す。算出した特徴量の次元は 63 である。

路面状況による車の震動には、大きなバンプやくぼみを超える際の比較的フワフワとした震動から、連続した凹凸によるガタガタする震動まで、様々な周波数帯の震動が混在している。本研究では、周波数ドメインの特徴であるエネルギーに対し、加速度およびジャイロ各軸の信号を 5 つの周波数域に分け、各周波数域でのエネルギー特徴量をそれぞれ算出する。

6.2.2 分類

本研究では、ランダムフォレスト (Random Forest Classification, RFC) を用いて路面状況の推定を行う。RFC は複数の決定木を用いたアンサンブル学習法として、パターン認識や機械学習の分野で広く使われてきた [12]。RFC は高次元と不均衡な問題の分類に優れている。

図 6 で示すように、速度が 50 km/h を超えた速度域での RSS は平坦が多く、実質 RST のみの分類になる。本研究では、50 km/h を境に速度域を 2 つに分け、路面状況の推定を各速度域でそれぞれ行う。

7. 実験および考察

本研究では、車両走行モードのクラスタリングを行う VTMC モジュールにおいて、正解データとしてのトラジェクトリ数が少ないため、毎回 40 個の独立したトラジェクトリから 1 個のトラジェクトリデータをテストデータとし、残り 39 個のデータを学習データとして計 40 回実験を繰り返す。

7.1 車両走行モードのクラスタ数および路面推定精度の評価

図 8 に、2 から 14 までの各 k の平均クラスタ内平方和

表 6 低速度域における路面状況推定結果 (<= 50 km/h)

Table 6 Result of estimating the road surface condition in the low speed domain (<= 50 km/h).

路面状況	精度						支持数
	k = 5	k = 6	k = 7	k = 8	k = 9	k = 10	
舗装路-平坦	97.02%	97.06%	98.14%	98.30%	98.33%	98.19%	11,961
圧雪-バンプ	46.57%	46.78%	50.31%	49.69%	50.31%	52.39%	481
凍結-バンプ	42.45%	53.30%	55.66%	57.08%	62.26%	65.57%	212
圧雪-バンプ&くぼみ	69.35%	72.58%	80.65%	77.42%	82.26%	80.65%	62
圧雪-平坦	92.86%	93.59%	92.11%	93.55%	93.70%	93.84%	6,128
シャーベット-平坦	48.86%	46.59%	55.11%	54.55%	51.70%	52.84%	176
凍結-平坦	83.43%	82.90%	79.39%	83.64%	83.03%	83.18%	1,485

表 7 高速度域における路面状況推定結果 (> 50 km/h)

Table 7 The result of estimating road surface condition in high speed domain (> 50 km/h).

路面状況	精度						支持数
	k = 5	k = 6	k = 7	k = 8	k = 9	k = 10	
シャーベット-平坦	84.36%	80.66%	83.95%	82.30%	80.66%	80.25%	243
圧雪-平坦	95.54%	95.64%	95.64%	96.30%	96.20%	96.20%	1,972
舗装路-平坦	98.40%	98.43%	98.40%	98.75%	98.96%	99.01%	4,281
凍結-平坦	75.31%	73.54%	77.95%	79.54%	76.72%	77.78%	567




図 8 K-means クラスタリングにおけるエルボ曲線
Fig. 8 Elbow for K-means clustering.

を示す。この結果からは、明確な“エルボポイント”は見取れないが、5から10までの区間がエルボポイントに近い可能性が高く、また、この区間の各kにおける路面状況の推定精度も考慮して、適切なkを選択することとした。

本研究では、各路面状況の各クラスにおける平均正解率を用いて路面状況の推定精度を評価する。路面状況sの各クラスにおける平均正解率 $Accuracy^s$ を以下のように定義する。

$$Accuracy^s = \frac{\sum_i^k N_{correct}^{i,s}}{\sum_i^k N_{groundtruth}^{i,s}} \times 100 \quad (1)$$

ここで、 $N_{correct}^{i,s}$ はクラスiの中で正しく推定された路面状態sの数を表し、 $N_{groundtruth}^{i,s}$ は、クラスiに割り振られた路面状況sの数を表す。

表6と表7に異なる速度域における各kの路面状況の推定結果を示す。最も高い推定精度を与えるkは路面状況ごとに異なっており、最適なkを決めるのは困難である。本研究は、実社会での重要性などに鑑みて、各路面の危険度から検知すべき路面状態の優先順位を決めて、それに基づいて最適なkの選択を行うこととする。1章で述べたように、最も危険な路面は交通事故の発生率が一番高い凍結路面である。したがって、このような路面を効率的に検出することは、社会への貢献に寄与できると考えられる。

表6と表7に示すように、k=8のとき、両速度域ともに凍結-平坦路面の推定精度が一番高い。一方、低速度域において、凍結-バンプ路面はk=10のとき推定精度が一番高い。凍結-バンプ路面も最も危険な路面の1つであるが、収集したデータ数から、凍結-平坦路面の発生率が凍結-バンプ路面より高いことが推測することができ、本研究では、kを8とした。

7.2 考察

凍結路面状況の推定結果は、k=8のとき、高速域で79.54%、低速度域で83.64%に達している。この精度は、一般の車載カメラを用いたQianらの路面推定システム[18]などと比較して約20%高い。また、各速度域の平均正解率はいずれも90%を超えている。

低速度域において、目視でも比較的確認しやすい“圧雪-バンプ&くぼみバンプ”という路面状況は大きな危険性

はないものの、運転に熟していない利用者においては、大きな不安要素となる可能性がある。実験の結果、“圧雪-バンブ&くぼみバンブ”の推定精度は77.42%に達している。一方、バンブを含む路面状況の推定精度は、50%から60%間にとどまっている。これは今回用意されたデータセットにおいて、これらのクラスのデータが十分には含まれておらず、また、正解データ作成時における主観判断の影響も相対的に大きくなると考えられるため、学習データの収集および作成の課題があるといえる。

本研究では、提案手法の有効性の評価に、提案手法と路面状況推定モジュールのみを用いた場合との推定精度の比較を用いた。その結果を図9(a)と図9(b)に示す。提案手法の各路面状況の推定精度は両速度域ともに路面状況推定モジュールのみを用いた場合より高い。特に、提案手法における凍結-平坦な路面の推定精度は、低速域で約40%、高速域で約24%高くなっているのが分かる。したがって、複

数のユーザのデータを用いて路面を推定するためにVTMCモジュールは必要であると考えられる。

VTMCモジュールは、降積雪地域の路面状況検出に着目し、 k の値を決めている。実験フィールドである札幌市の冬期(1月から3月)の気温は、最高気温約 10°C から最低気温約 -15°C の間で変動しており*2、年間約6mの降雪量をあわせて考えると、降雪地域の中でも路面状態の多様性が高いと考えられる。さらに、特徴量として利用者の車種や個人の運転特徴を考慮していないため、降積雪地域であれば特定の地域に限定されず、汎用性があるといえる。正解データの作成に用いた利用者の数は少ないものの、学習データを増やすことによって他の地域への適用も期待できる。しかし、降雪のない地域の路面状況を推定する場合は、着目点が異なり k 値の再選定が必要となる。

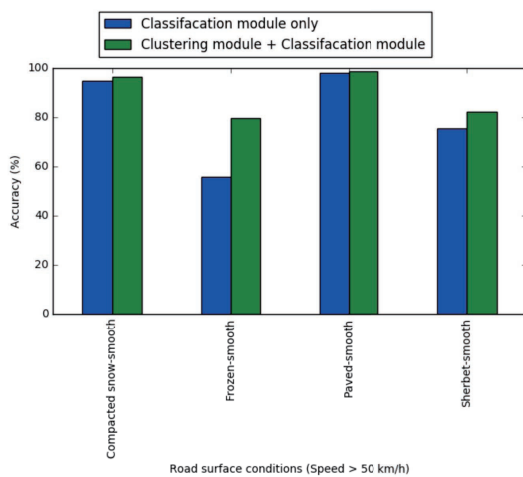
8. おわりに

本論文では、クラウドソースによるモバイルセンシングを用いた新たな路面状況推定手法を提案した。提案手法は、モーションセンサのみを用いて路面状態(RST)と路面形状(RSS)の両方の推定を可能にした。提案手法では、各運転ごとの車両走行モードに着目し、それに基づいて各運転をクラスタリングすることで、ユーザ間の個人差を考慮する必要なく、複数のユーザから収集したデータを統合した路面状況の推定を可能にした。

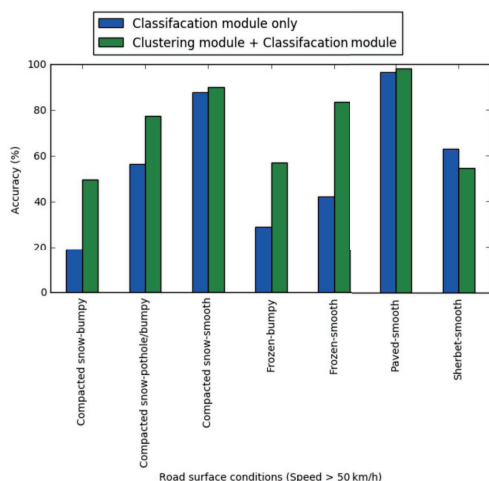
謝辞 本研究は、国立研究開発法人情報通信研究機構(NICT)の委託研究「ソーシャル・ビッグデータ利活用・基盤技術の研究開発」(課題A ソーシャル・ビッグデータ利活用アプリケーションの研究開発-モバイルセンシングを活用したスマートシティアプリケーションの研究開発)の支援を受けている。ここに謝意を表す。

参考文献

- [1] Aihara, K., Bin, P., Imura, H., Takasu, A. and Tanaka, Y.: On Feasibility of Crowdsourced Mobile Sensing for Smarter City Life, *International Conference on Distributed, Ambient, and Pervasive Interactions*, pp.395–404, Springer (2016).
- [2] Burke, J.A., Estrin, D., Hansen, M., Parker, A., Ramanathan, N., Reddy, S. and Srivastava, M.B.: Participatory sensing (2006).
- [3] Chen, K., Lu, M., Tan, G. and Wu, J.: CRSM: Crowdsourcing based road surface monitoring, *2013 IEEE 10th International Conference on High Performance Computing and Communications & 2013 IEEE International Conference on Embedded and Ubiquitous Computing (HPCC-EUC)*, pp.2151–2158, IEEE (2013).
- [4] Duda, R.O. and Hart, P.E.: *Pattern Recognition and Scene Analysis*, Wiley, part 1 edition (1973).
- [5] Fujino, Y., Kitagawa, K., Furukawa, T. and Ishii, H.: *Development of Vehicle Intelligent Monitoring System (VIMS)*, Vol.5765, pp.148–157 (online), DOI: 10.1117/12.601727, SPIE, part 1 edition (2005).
- [6] Ganti, R.K., Ye, F. and Lei, H.: Mobile crowdsensing:



(a) Speed > 50 km/h



(b) Speed <= 50 km/h

図9 路面状況ごとの精度比較

Fig. 9 Comparing our method with a method that only uses the classification module.

*2 <https://weather.time-j.net/Stations/Jp/Sapporo/2>

- Current state and future challenges, *IEEE Communications Magazine*, Vol.49, No.11 (2011).
- [7] Gupta, P. and Dallas, T.: Feature selection and activity recognition system using a single triaxial accelerometer, *IEEE Trans. Biomedical Engineering*, Vol.61, No.6, pp.1780–1786 (2014).
- [8] He, Z. and Jin, L.: Activity recognition from acceleration data based on discrete cosine transform and SVM, *The 2009 IEEE International Conference on Systems, Man, and Cybernetics*, pp.5041–5044 (2009) (online), available from (<http://ieeexplore.ieee.org/xpl/downloadCitations>).
- [9] Jonsson, P.: Classification of road conditions: From camera images and weather data, *2011 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications (CIMSAS)*, pp.1–6, IEEE (2011).
- [10] Kawai, S., Takeuchi, K., Shibata, K. and Horita, Y.: A method to distinguish road surface conditions for car-mounted camera images at night-time, *2012 12th International Conference on ITS Telecommunications (ITST)*, pp.668–672, IEEE (2012).
- [11] Korpela, J., Maekawa, T., Eberle, J., Chakraborty, D. and Aberer, K.: Tree-structured classifier for acceleration-based activity and gesture recognition on smartwatches, *2016 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, pp.1–4, IEEE (2016).
- [12] Liaw, A., Wiener, M., et al.: Classification and regression by randomForest, *R News*, Vol.2, No.3, pp.18–22 (2002).
- [13] Linton, M.A. and Fu, L.: Winter road surface condition monitoring: Field evaluation of a smartphone-based system, *Transportation Research Record: Journal of the Transportation Research Board*, No.2482, pp.46–56 (2015).
- [14] Ma, H., Zhao, D. and Yuan, P.: Opportunities in mobile crowd sensing, *IEEE Communications Magazine*, Vol.52, No.8, pp.29–35 (2014).
- [15] Nomura, T. and Shiraishi, Y.: A method for estimating road surface conditions with a smartphone, *International Journal of Informatics Society*, Vol.7, No.1, pp.29–36 (2015).
- [16] Omer, R. and Fu, L.: An automatic image recognition system for winter road surface condition classification, *2010 13th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp.1375–1379, IEEE (2010).
- [17] Pelleg, D., Moore, A.W., et al.: X-means: Extending K-means with Efficient Estimation of the Number of Clusters, *ICML*, Vol.1, pp.727–734 (2000).
- [18] Qian, Y., Almazan, E.J. and Elder, J.H.: Evaluating features and classifiers for road weather condition analysis, *2016 IEEE International Conference on Image Processing (ICIP)*, pp.4403–4407, IEEE (2016).
- [19] Sayers, M.: On the Calculation of International Roughness Index from Longitudinal Road Profile, *Transp. Res. Rec.*, No.1501, pp.1–12 (1995).
- [20] Tanaka, Y., Sjöbergh, J. and Takahashi, K.: A Need for Exploratory Visual Analytics in Big Data Research and for Open Science, *20th International Conference Information Visualisation*, pp.261–270 (2016).
- [21] Wu, J., Pan, G., Zhang, D., Qi, G. and Li, S.: Gesture recognition with a 3-D accelerometer, *International Conference on Ubiquitous Intelligence and Computing*, pp.25–38, Springer (2009).
- [22] Yagi, K.: A Measuring Method of Road Surface Longitudinal Profile from Sprung Acceleration, and Verification with Road Profiler, *Journal of Japan Society of Civil Engineers, Ser. E1 (Pavement Engineering)*, Vol.69, No.3 (2013).
- [23] Yamada, H., Kawasaki, S., Kiyasu, K., Fukuda, Y., Makino, H., Toba, T., Ouchi, H., Mizuguchi, S., Yoasa, M., Kazuya, Y., Matsuzawa, M. and Suzuki, T.: The technical note of joint research about advanced cruise-assist technology in a winter road, Technical Report (2004).
- [24] 花塚泰史, 樋口知之, 松井知子: HMMに基づくタイヤ振動波形解析による路面状態判別, *電子情報通信学会論文誌 D*, Vol.95, No.3, pp.570–577 (2012).
- [25] 札幌市建設局雪対策室計画課: 札幌市建設局雪対策室計画課, (オンライン), 入手先 (<http://www.city.sapporo.jp/kensetsu/yuki/jigyou/jyosetsu6.html>) (参照 2018-05-02).
- [26] 山田宗男, 上田浩次, 堀場勇夫, 津川定之, 山本 新: 画像処理による車載型路面状態検出センサの開発, *電気学会論文誌 C (電子・情報・システム部門誌)*, Vol.124, No.3, pp.753–760 (2004).



朴 斌

2015年北海道大学大学院情報科学研究科博士課程修了。博士(情報科学)。2015年～現在, 国立情報学研究所コンテンツ科学研究系特任助教。インタラクティブな情報可視化, クラウドソースによるモバイルセンシングに関する

研究等に従事。



相原 健郎 (正会員)

1997年東京大学大学院工学系研究科博士課程修了。博士(工学)。1997年文部省学術情報センターシステム研究系助手。2000年国立情報学研究所ソフトウェア研究系助手。2004年国立情報学研究所ソフトウェア研究系助教。2006年国立情報学研究所コンテンツ科学研究系助教。2007年～現在, 国立情報学研究所コンテンツ科学研究系准教授。サイバーフィジカルシステム, コンテキストウェア, 行動分析・行動変容に関する研究等に従事。人工知能学会, 日本認知科学会, ACM各会員。