

歩行者のための積雪マップ実現に向けたスマートフォンを用いた路面積雪量推定

桂田 連¹ 長谷川 達人¹

概要: 本研究ではスマートフォンに搭載されている加速度センサ, ジャイロセンサから観測される値をもとに機械学習によって, ユーザーが歩いている道路の積雪状況を推定する手法を開発し, 評価する. この手法を開発することで, 各歩行者からセンサ値を取得し, 路面の積雪量推定ができる. 推定したデータを蓄積することで, 積雪マップを実現し, 歩きやすい歩行経路の推薦ができる. 提案手法では, 通常の道路, 雪が少し積もった道路, アイスバーンのように踏み固められた道路, 雪がかなり積もった道路の4種類の推定を行った. 被験者8人に対して, それぞれ自己データのみ用いて10-foldCVで検証した結果, 全ての被験者において推定精度約100%を達成した. 一方, 自己データを含めずに学習するLOSO-CVでは最も良い精度を出す手法でも55%となり, 個人差の影響を大きく受けた. この実験を通して, 通常の道路とアイスバーンの道路は加速度センサやジャイロセンサでは識別が難しいことも明らかにした. また, アイスバーンを除く3種類の道路の推定では約70%の精度を実現した.

Estimation of road snow accumulation using smartphone for creating snow cover map for pedestrians

REN KATSURADA¹ TATSUHITO HASEGAWA¹

1. はじめに

本研究では, 歩行者のための積雪マップ実現を目的として, スマートフォンを用いた路面の積雪量推定手法を開発する. スマートフォン所持者の歩行時の位置情報とセンサ情報を計測し, 機械学習を用いて計測したデータから路面の積雪量を推定する. 路面の積雪量を推定し, 参加者らのデータを集約することで, 図1のような各道路の積雪量を可視化した積雪マップを実現する.

冬期に降雪がある地域では, 様々な雪害に見舞われる. 積雪が多い時は歩行することが困難である. さらに, 首相官邸の防災の手引きによると, 被害の一部として, 積雪による歩行者の転倒事故があるとしている. 特に, 車が何度も通り路面上の氷が磨かれた所や, 多くの人によって踏み固められた所は非常に滑りやすくなっており, 転倒の危




図1: 積雪マップの構想

険性が高い. 転倒等の事故を減らすためには, 外出する際に安全で, 歩行しやすい道を把握する必要がある. そこで, 地域の積雪情報を地図アプリケーションなどを用いて知ることができれば, 歩行者は予め危険な道を回避することができ, 事故件数の減少に繋がると考えられる. 地域の安全情報を共有する試みとしては, 雪みち情報ネットふくい [1] や青森みち情報 [2] のように県庁や各自治体が提供しているものがある. これらは, 冬期間に通行止めになる道路の

¹ 福井大学大学院工学研究科情報・メディア工学専攻
Department of Information Science, Graduate School of Engineering, University of Fukui, Fukui City, Fukui 910-8507, Japan

通知や、路面情報などを web サイト上にて提供しているものであるが、その大多数は車道に着目したものであり、歩道などの細かい情報に関しては提供できていない。また、路面情報の提供に関しては設置されたカメラを使うことが一般的であるため、カメラのない場所の情報は提供できない。加えて、情報提供に対して積極的な自治体が各々で行っているため、情報を提供できていない地域が存在するといった現状がある。以上より、歩行者をターゲットとした路面情報を収集し、提供することが必要だと考える。

本研究では、歩道の積雪マップ実現を目的として、スマートフォンに標準搭載されている各種センサを用いて自動的に路面情報を推定する手法を提案する。参加型センシングを利用した場合でも、参加者はセンサを起動後ポケットにスマートフォンを格納し歩行するだけでよいため、手軽に参加できる。特に本稿では、提案手法の実現可能性を確認するために、センサデータから積雪状況の推定精度の評価を目的とした歩行データ収集実験と性能評価実験を行う。

2. 関連研究と本研究の位置づけ

路面状況の推定に関連する研究は、久野らの研究 [3] や山田らの研究 [4] がある。久野らは、道路の様子を映すライブカメラから路面上の光沢度を検出し、様々な撮影環境にも関わらず路面状態（道路の“乾燥”、“湿潤”、“冠水”）を推定する手法を提案した。また、山田らは車載カメラを用いて撮影した映像から“乾燥”、“湿潤”、“シャーベット”、“ザクレ”“圧雪”という 5 種類の路面状態を検出していた。さらに、夜間における路面水分検出手法も提案し、それらの有効性を示していた。道路の路面状態を検出する研究の他に、Hui らの研究 [5] のような、悪環境下でも画像から路面状態を検出する手法を提案するなど、実用性を高めるような発展的な研究も行われている。以上のように車道に着目した研究は進められているが、歩道に着目した研究はあまり進められていない。積雪のある地域では積雪時に車で移動することが一般的ではあるが、運転免許を所持していない若年層や、車を運転できない高齢者や妊婦等による転倒・怪我の危険性を考えると、歩行者に対して安全で歩きやすい道を提示することが望ましい。

本研究では歩道の積雪マップ実現に向けて、歩行者参加型センシングによるデータ収集を想定した積雪量推定手法を開発する。単純に関連研究のような、カメラから積雪量を推定する手法を歩行者に適用する場合、歩行者にカメラを起動しながら歩行してもらうことは、歩きスマホの促進に繋がり危険である。また手間という観点からも、センシングへの参加意欲を低下させることが懸念され、現実的ではない。本研究ではスマートフォンに標準搭載されている加速度センサやジャイロセンサを用いて、道路の積雪情報を自動的に推定する点が特徴である。

スマートフォンを用いた行動認識に関する研究は、An-




図 2: 提案手法の概要

guita ら [6] や Abbate ら [7], Shoaib らの研究 [8] がある。Anguita らはスマートフォンに内蔵されているセンサを用いて、“直立”、“歩行”、“横になる”、“階段を上る”、“階段を下がる”といった行動を認識するシステムを提案している。Abbate らはスマートフォンを用いて高齢者の転倒を検出しており、Shoaib らは様々な識別対象となる行動に対して、ジャイロセンサや磁気センサの有効性を確認していた。また、長谷川ら [9] のスマートフォンの所持位置推定のように、スマートフォンを用いて、より細やかなコンテキストの推定を行っている研究もある。本研究では、より細やかなコンテキスト推定の一環として、歩行動作の中でも“どのような路上を歩行していたのか”を推定する点が挑戦的である。

3. 提案手法

3.1 提案手法概要

図 2 に提案手法の概要を示す。提案手法では、歩行中のユーザが所持しているスマートフォンに搭載されている加速度センサとジャイロセンサから観測される値をもとに機械学習によって路面の積雪量を推定する。加速度センサは 3 軸各方向における加速度を計測する。ジャイロセンサは加速度センサの軸方向において回転する際の角加速度を計測する。行動認識の分野では、重力成分が端末の方向に強く影響を受けてしまうことが懸念されることを理由として、加速度センサは重力成分と加速度成分に分解し、加速度成分を用いている研究があるが、本研究では重力成分も識別に重要であると考え、加速度センサから観測できる生データをそのまま用いた。

3.2 特徴量の抽出

スマートフォンからセンサ値を取得し、各センサ値から一定長の窓に区切って特徴量を抽出する。本稿では応答性を考慮した結果、256 サンプルを 1 フレームとして用いる。これを 30 サンプルずつスライドしてデータセットを生成する。次に、フレーム内のセンサ値から特徴量を抽出する。学習時にはこれに正解ラベルを追加する。

抽出した特徴量を表 1 に示す。加速度センサ、ジャイロセンサを用いた行動認識の分野では、フレーム内の平均値や分散など、様々な特徴量が採用されている。本研究では行動認識の分野で用いられている主な特徴量を抽出した。

表 1: 1 フレームから抽出した特徴量

| 特徴量名称 | 軸 |
|----------------------|-------------|
| 平均値 | x,y,z |
| 絶対値の平均値 | x,y,z |
| 標準偏差 | x,y,z |
| 絶対値の標準偏差 | x,y,z |
| 最小値 | x,y,z |
| 最大値 | x,y,z |
| 二乗平均平方根 | x,y,z |
| 第一四分位数 | x,y,z |
| 中央値 | x,y,z |
| 第三四分位数 | x,y,z |
| 四分位範囲 | x,y,z |
| 軸間の相関係数 | x,y,z |
| 軸間の絶対値の相関係数 | x-y,y-z,z-x |
| 動きの激しさ | x,y,z |
| 周波数パワースペクトルの最大値 | x,y,z |
| 周波数パワースペクトルの最大の周波数 | x,y,z |
| 周波数パワースペクトルの最小値 | x,y,z |
| 周波数パワースペクトルの標準偏差 | x,y,z |
| 周波数パワースペクトルの第一四分位数 | x,y,z |
| 周波数パワースペクトルの中央値 | x,y,z |
| 周波数パワースペクトルの第三四分位数 | x,y,z |
| 周波数パワースペクトルの四分位範囲 | x,y,z |
| 周波数パワースペクトルの軸間の相関係数 | x-y,y-z,z-x |
| 低周波数パワースペクトルの最大値 | x,y,z |
| 低周波数パワースペクトルの最大の周波数 | x,y,z |
| 低周波数パワースペクトルの最小値 | x,y,z |
| 低周波数パワースペクトルの標準偏差 | x,y,z |
| 低周波数パワースペクトルの第一四分位数 | x,y,z |
| 低周波数パワースペクトルの中央値 | x,y,z |
| 低周波数パワースペクトルの第三四分位数 | x,y,z |
| 低周波数パワースペクトルの四分位範囲 | x,y,z |
| 低周波数パワースペクトルの軸間の相関係数 | x-y,y-z,z-x |
| 中周波数パワースペクトルの最大値 | x,y,z |
| 中周波数パワースペクトルの最大の周波数 | x,y,z |
| 中周波数パワースペクトルの最小値 | x,y,z |
| 中周波数パワースペクトルの標準偏差 | x,y,z |
| 中周波数パワースペクトルの第一四分位数 | x,y,z |
| 中周波数パワースペクトルの中央値 | x,y,z |
| 中周波数パワースペクトルの第三四分位数 | x,y,z |
| 中周波数パワースペクトルの四分位範囲 | x,y,z |
| 中周波数パワースペクトルの軸間の相関係数 | x-y,y-z,z-x |
| 高周波数パワースペクトルの最大値 | x,y,z |
| 高周波数パワースペクトルの最大の周波数 | x,y,z |
| 高周波数パワースペクトルの最小値 | x,y,z |
| 高周波数パワースペクトルの標準偏差 | x,y,z |
| 高周波数パワースペクトルの第一四分位数 | x,y,z |
| 高周波数パワースペクトルの中央値 | x,y,z |
| 高周波数パワースペクトルの第三四分位数 | x,y,z |
| 高周波数パワースペクトルの四分位範囲 | x,y,z |
| 高周波数パワースペクトルの軸間の相関係数 | x-y,y-z,z-x |

表 1 中の低周波数・中周波数・高周波数パワースペクトルについては、周波数パワースペクトルの内 0.4~1.6Hz 帯を低周波数パワースペクトル、1.6~3.1Hz 帯を中周波数パワースペクトル、3.1~4.7Hz 帯を高周波数パワースペクトルとし、それぞれから通常の周波数パワースペクトルと同じ特徴量を抽出した。表 1 における絶対値の平均値とは、

表 2: 被験者 8 人の詳細

| ID | 年齢 | 性別 | 利用機種 |
|----|----|----|---------------|
| A | 22 | 男 | iPhone 7 |
| B | 23 | 男 | iPhone 8 Plus |
| C | 22 | 男 | iPhone 7 |
| D | 29 | 男 | ZTE AXON 7 |
| E | 22 | 男 | iPhone 5s |
| F | 23 | 男 | iPhone 7 |
| G | 22 | 男 | iPhone 7 |
| H | 22 | 男 | iPhone 6s |

各フレームの絶対値を抽出したデータセットから平均値を算出している。二乗平均平方根とは、各値の二乗を合計して平方根を算出するものである。また、第一四分位数や中央値、第三四分位数はフレーム内の離散値を昇順に並べ、それぞれ 1/4, 1/2, 3/4 の位置にあたる値である。動きの激しさ (Intensity) [10] は標本サイズを n , x 軸センサ値を $X_i (i: 1, 2, 3, \dots, n)$ とするとき、式 (1) で表され、動きの激しさ (Intensity) を定義している。

$$Intensity = \frac{1}{n-1} \sum_{i=1}^{n-1} |X_i - X_{i+1}| \quad (1)$$

4. 評価実験

4.1 データ収集実験

提案手法の評価を行うためにデータ収集を行った。被験者は表 2 の 8 人である。各自、使用した機種はそれぞれ異なる。被験者は加速度センサ、ジャイロセンサ、磁気センサ、近接センサなどを記録するアプリケーション HASC Tool [11] を起動させた後、以下の 4 種類の道路を歩行する。

- Normal** 雪の積もっていないアスファルトの道
- Middle** 雪が少し積もった道 (積雪 40cm 未満)
- Ice burn** アイスバーンのように踏み固められた道
- Over40** 雪が積もった道路 (積雪 40cm 以上)

図 3(a)-(d) に、それぞれ分類対象となる道路の画像を示す。サンプリング周波数は 100Hz として実験を行う。スマートフォンは右前ズボンポケットに格納し、大学構内やその周辺を歩行する。歩行はそれぞれ 1 分程度行い、その間に U ターンやカーブを含んでいる。また、実験場所が被験者により異なるため、直進のみの場合も存在する。被験者によっては計測していない種類の道路もあるため、各ラベルのデータ数にも若干偏りがある。

実際の計測においては、積雪量ラベルには切り替え区間が存在する。よって、移動した際ラベル切り替わりのタイミングで最大 1 フレーム (256 サンプル=約 2.56 秒) 推定が遅延する可能性がある。フレーム内でも複数状態が混在するものが存在するが、今回の実験ではそのようなサンプルを除外した。



(a) 雪の積もっていないアスファルトの道路



(b) 雪が少し積もった道路



(c) アイスバーンのように踏み固められた道路



(d) 雪が積もった道路 (積雪 40cm 以上)

図 3: 分類対象となる道路

4.2 推定精度評価実験

提案手法の精度評価実験を行った。本研究で利用する機械学習手法は、Random Forest(以下 RF) [12], Support Vector Machine(SVM) [13], Deep Neural Network(DNN) を用い、それぞれの推定精度を比較する。各アルゴリズムにおけるパラメータチューニングは実験を繰り返し探索を行い、精度が最も高いものを採用した。評価手法として、自己データのみで 10-fold Cross Validation (10-fold CV) を行い精度を確かめる。ただし、行動認識の分野においては自己データを含むデータから交差検証を行った場合、精度が上昇することが確認されている [14]。そのため、自己データを除いて学習モデルを形成し、自己データで検証を行う Leave-One-Subject-Out Cross Validation(LOSO-CV) による精度評価も実施する。

5. 実験結果と考察

5.1 各学習アルゴリズムのチューニング

各学習アルゴリズムに対してパラメータのチューニングを行った。結果、RF においては木の数を 150 とし、DNN においては、ノード数 512 の層を 3 層配置し、その出力に対し dropout 率 0.2% で dropout を行った後、softmax 関数を用いて出力を算出する。最適化関数は Adam を使用した。エポック数は 10 とした。尚、チューニングの際、全ての学習データを一通り学習するまでをエポック数 1 として扱っている。SVM のパラメータは RGF カーネル、C=1.0 としたが、SVM に対してのみ特徴選択も事前に行っている。特徴選択アルゴリズムには L1 をベースとしたモデル

表 3: 被験者・学習手法別 4 値分類 10-fold CV 精度評価

| ID | RF | SVM | DNN |
|-------|------|------|-----|
| A | 100% | 100% | 95% |
| B | 100% | 100% | 98% |
| C | 100% | 100% | 85% |
| D | 100% | 100% | 92% |
| E | 100% | 100% | 88% |
| F | 100% | 100% | 97% |
| G | 100% | 100% | 99% |
| H | 100% | 100% | 95% |
| Total | 100% | 100% | 94% |

による特徴選択を用いた。一度全ての特徴量を SVM に入力し、各特徴量の推定係数を算出し降順に並べる。並べた中から中央値以上を学習に用いる特徴として選択した。

5.2 自己データのみを用いた 10-fold CV

自己データ内で学習用とテスト用に分けた 10-fold CV の 4 値分類における実験結果を表 3 に示す。4 値分類の対象は Normal, Middle, Ice burn, Over40 の 4 つのクラスである。Total には全員分の予測と正解を結合した精度評価を示す。表 3 より、RF, SVM では被験者全員のデータで推定精度約 100% を達成することができた。ただし、DNN では 100% には達しなかった。過学習の影響を強く受けたと考えられる。DNN のパラメータをさらにチューニングすることで DNN も 100% に近い推定精度が出ると考えている。実験結果より、自己データを学習に用いることで、路面の積雪量を高精度で推定できる可能性が示唆された。

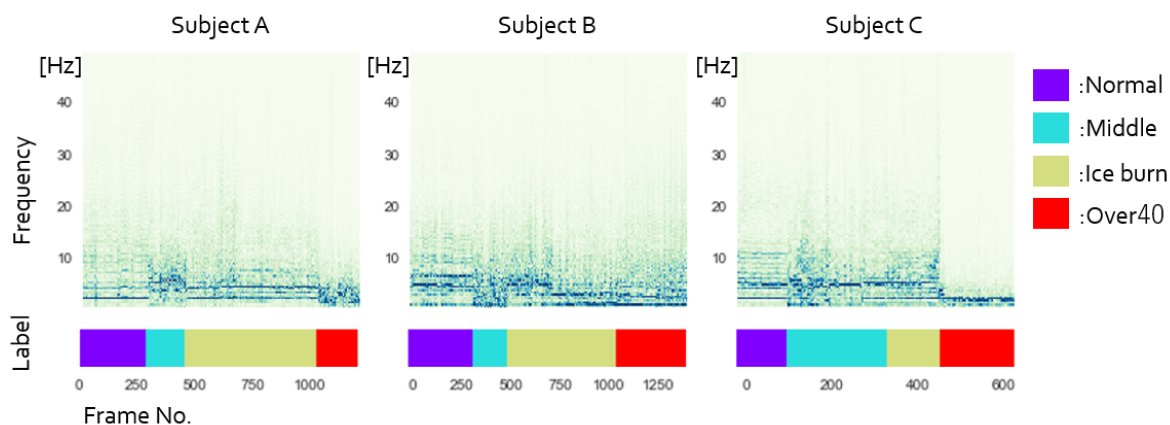


図 4: 被験者 3 名の加速度センサ x 軸 FFT スペクトラム

表 4: 被験者・学習手法別 4 値分類 LOSO-CV 精度評価

| ID | RF | SVM | DNN |
|-------|-----|-----|-----|
| A | 61% | 65% | 64% |
| B | 40% | 40% | 20% |
| C | 30% | 24% | 21% |
| D | 48% | 45% | 37% |
| E | 82% | 77% | 81% |
| F | 65% | 42% | 58% |
| G | 42% | 49% | 32% |
| H | 92% | 61% | 55% |
| Total | 55% | 49% | 42% |

表 5: RF による 4 値分類推定結果の混同行列

| 予測\正解 | Normal | Middle | Ice burn | Over40 | Precision |
|----------|--------|--------|----------|--------|-----------|
| Normal | 199 | 46 | 55 | 216 | 39% |
| Middle | 173 | 333 | 383 | 230 | 30% |
| Ice burn | 827 | 334 | 1774 | 310 | 55% |
| Over40 | 155 | 54 | 79 | 1252 | 81% |
| Recall | 15% | 43% | 77% | 62% | 55% |

5.3 4 値分類 LOSO-CV

LOSO-CV の 4 値分類における実験結果を表 4 に示す。表 4 より、全体としては RF が Total で 55% と最も良い推定精度を達成するという結果が得られた。また、被験者 H に対しては RF を用いると 92% で推定できているが、被験者 D においては RF で推定精度 30% であるなど、同じ学習手法を用いても、被験者によって推定精度が大きく変わるという結果が得られた。

次に、RF による全員の結果を結合した Confusion Matrix を表 5 に示す。表 5 から、Normal, Middle では共に Ice burn と予測した事例が多いという結果が得られた。特に、Normal を Ice burn と間違えるケースが最も多い。実験前には、Ice burn の路上を歩くと滑りやすいことで歩き方に変化が起り、加速度を用いた本手法によって識別できるのではないかと考えていた。しかし、実験結果より Normal と Middle の歩き方と Ice burn での歩き方の差異

が想定以上に少なく、うまく識別できなかったと考えられる。実際に被験者からも「Ice burn は滑る時もあるが基本的には普通の道を歩くと体感的に変わらないと思った」という意見もあった。そこで、加速度センサのウィンドウに対して FFT を施したスペクトラムを確認する。

図 4 に被験者 A, B, C における加速度センサの x 軸のスペクトラムを示す。左の図から被験者 A, 被験者 B, 被験者 C のスペクトラムを示している。各スペクトラムの下部は直上のスペクトルのクラスを示す。例えば、紫色のラベルの上には Normal を歩行した際のスペクトルが示されている。FFT 波形に関して同じ種類の道路でも被験者によってスペクトルが異なることが読み取れる。特に、Over40 の道路を歩行した時のスペクトラムは被験者によって大きく異なった分布であることが確認される。また、被験者 A や C においては、Normal と Ice burn が特に似ているように読み取れる。そのため、Normal を Ice burn と間違えるケースが多いという結果が得られたと考えられる。個人差に関しては、別途個人差を校正する手法を考案して改善を図る必要があると考える。

5.4 3 値分類 LOSO-CV

4 値分類の LOSO-CV について、特に Normal と Middle の推定が Ice burn に偏り精度が下がるという結果を受け、Ice burn のデータを除外し、Normal, Middle, Over40 の 3 値分類を LOSO-CV で交差検証した。被験者・学習手法別 3 値分類推定結果を表 6 に示す。表 6 より、Ice burn を識別対象から外すと、全体的に 4 値分類より高い精度を達成することが確認された。ただし、被験者 H の SVM は精度が著しく精度が低下する結果が得られた。これは、他被験者の中で有用と選択された特徴選択が被験者 H には有用に働いていなかったことが原因として考えられる。最も高い精度を達成した RF の 3 値分類の Confusion Matrix を表 7 に示す。表 7 より、Normal と Middle の識別の誤りがやや多く、また Over40 の中で Middle と誤るケースも多く

表 6: 3 値分類 LOSO-CV 精度評価

| ID | RF | SVM | DNN |
|-------|-----|-----|-----|
| A | 73% | 67% | 67% |
| B | 19% | 50% | 19% |
| C | 65% | 23% | 24% |
| D | 83% | 72% | 70% |
| E | 82% | 83% | 82% |
| F | 66% | 86% | 65% |
| G | 42% | 42% | 43% |
| H | 82% | 8% | 78% |
| Total | 68% | 68% | 51% |

表 7: RF による 3 値分類推定結果の混同行列

| 予測\正解 | Normal | Middle | Over40 | Precision |
|--------|--------|--------|--------|-----------|
| Normal | 737 | 206 | 178 | 66% |
| Middle | 385 | 537 | 534 | 37% |
| Over40 | 234 | 24 | 1296 | 83% |
| Recall | 54% | 70% | 65% | 68% |

みられたものの、4 値分類による実験結果と比較すると、推定精度はおおよそ改善したと考えられる。通常の道、雪のある道、かなり雪のある道の 3 分類においてはある程度の推定精度が実現できており、雪道マップ実現の可能性を確認することができた。ただし、歩きやすい雪道を提示する積雪マップ実現には、Ice burn の道の検出が必要であると考えられる。個人適応技術や Abbate ら [7] のような転倒を検出する手法を応用することで、Ice burn 道路の検出に関しても模索を続けたい。

6. おわりに

本稿では歩行者のための積雪マップ実現を目的として、スマートフォンを用いた路面積雪量推定を開発した。また、その有効性を確認するため推定精度を確認した。自己データのみを用いた 10-fold CV では、RF や SVM において推定精度約 100% を達成することができた。自己データを含めないデータで学習モデルを構築する LOSO-CV で 4 値分類を行うと、自己データのみで学習を行った際よりも推定精度が大きく低下し、最大でも RF で 55% の推定精度となった。結果を Confusion Matrix で確認すると、通常の道路と雪が少し積もった道路を共にアイスバーンの道路と誤るケースが多く確認された。また、加速度センサのスペクトラムを確認したところ、同じ道路でも被験者間でスペクトラムが異なることと、通常の道路がアイスバーンの道路と似ているスペクトルが多いことが明らかになった。アイスバーンの道路を除いた 3 値分類では 4 値分類よりも全体的に精度が向上し、RF, SVM で推定精度が共に最大で 68% を達成した。

積雪マップを実現し安全な道を示すためには、アイスバーンの道路を検出することが必要であると考えている。

そこで、転倒を検出する手法を組み合わせるアイスバーンの道路を検出することを検討したい。加えて、他者のデータを学習に用いる際は、個人差による影響が無視できないと考えられるため、個人差を校正し、推定精度を高める手法も考案していきたい。

参考文献

- [1] 福井県庁. 雪みち情報ネットふくい. <http://info.pref.fukui.jp/hozen/yuki/>. Accessed: 2018-2-15.
- [2] 青森県幹線道路協議会. 青森みち情報. <http://www.koutsu-aomori.com/Road/yukimitimap.html>. Accessed: 2018-4-3.
- [3] 久野徹也, 杉浦博明, 吉田潤一. 車載カメラによる路面状態検出方式の検討. 電子情報通信学会論文誌 D, Vol. 81, No. 10, pp. 2301–2310, 1998.
- [4] 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.
- [5] Hui Kong, Jean-Yves Audibert, and Jean Ponce. General road detection from a single image. *IEEE Transactions on Image Processing*, Vol. 19, No. 8, pp. 2211–2220, 2010.
- [6] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra, and Jorge L Reyes-Ortiz. Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine. In *International workshop on ambient assisted living*, pp. 216–223. Springer, 2012.
- [7] Stefano Abbate, Marco Avvenuti, Francesco Bonatesta, Guglielmo Cola, Paolo Corsini, and Alessio Vecchio. A smartphone-based fall detection system. *Pervasive and Mobile Computing*, Vol. 8, No. 6, pp. 883–899, 2012.
- [8] Muhammad Shoab, Hans Scholten, and Paul JM Havinga. Towards physical activity recognition using smartphone sensors. In *Ubiquitous intelligence and computing, 2013 IEEE 10th international conference on and 10th international conference on autonomic and trusted computing (uic/atc)*, pp. 80–87. IEEE, 2013.
- [9] 長谷川達人, 越野亮. 深層学習を用いた歩行時におけるスマートフォンの所持位置推定. 情報処理学会論文誌, Vol. 57, No. 10, pp. 2186–2196, 2016.
- [10] Norbert Györfi, Ákos Fábrián, and Gergely Hományi. An activity recognition system for mobile phones. *Mobile Networks and Applications*, Vol. 14, No. 1, pp. 82–91, Feb 2009.
- [11] Nobuo Kawaguchi, Nobuhiro Ogawa, Yohei Iwasaki, Katsuhiko Kaji, Tsutomu Terada, Kazuya Murao, Sozo Inoue, Yoshihiro Kawahara, Yasuyuki Sumi, and Nobuhiko Nishio. Hasc challenge: gathering large scale human activity corpus for the real-world activity understandings. In *Proceedings of the 2nd augmented human international conference*, p. 27. ACM, 2011.
- [12] Leo Breiman. Random forests. *Machine learning*, Vol. 45, No. 1, pp. 5–32, 2001.
- [13] Cortes Corinna and Vladimir Vapnik. Support-vector networks. *Machine Learning*, Vol. 20, No. 3, pp. 273–297, 1995.
- [14] Kaori Fujinami and Satoshi Kouchi. Recognizing a mobile phone's storing position as a context of a device and a user. In *International Conference on Mobile and Ubiquitous Systems: Computing, Networking, and Services*, pp. 76–88. Springer, 2012.