

歩行者クラウドセンシングによる路面状態の推定

藤井 海斗[†] 羽田野真由美^{††} 西田 京介^{††} 戸田 浩之^{††} 澤田 宏^{††}
鹿島 久嗣[†]

[†] 京都大学 〒606-8501 京都府京都市左京区吉田本町 36-1

^{††} 日本電信電話株式会社 NTT サービスエボリューション研究所 〒239-08247 神奈川県横須賀市光の丘 1-1

E-mail: †fujii@ml.ist.i.kyoto-u.ac.jp,

††{hadano.mayumi,nishi.kyosuke,toda.hiroyuki,sawada.hiroshi}@lab.ntt.co.jp, †††kashima@i.kyoto-u.ac.jp

あらまし GPS や加速度等のセンサを持つスマートフォンの普及により、一般のユーザからセンシング結果を収集することで実世界の状況を理解するクラウドセンシングが注目を集めている。本研究では、一步一步に対応する加速度データから、平坦な場所に対応するのか、坂や段差に対応するのかを推定し、GPS など得られる位置情報と組み合わせることで、都市を移動する際に障害となりうる路面情報を収集することを目指す。本稿では初期検討として、約 10 人の屋外における歩行データを集め、行動認識を行う既存研究で提案されている特徴量を利用し、教師あり学習の枠組みを用いて一步単位で行動を推定する実験について報告を行う。その結果、一步単位での推定においても、前後の歩行データを利用することで、精度を向上させられるという知見を得た。

キーワード クラウドセンシング, 加速度データ, 路面情報

1. はじめに

近年、様々なセンサを備えたスマートフォンが普及したことにより、一般のユーザからセンサデータを大規模に収集することが現実的になってきている。このような試みはクラウドセンシングと呼ばれている。これまでも携帯電話の電波状況把握 [6] や環境情報の収集 [4], [9], ホイール付き乗り物を用いた路面状況理解 [5], [8] などの様々な分野でクラウドセンシングを活用した取り組みが行われている。

本研究では、クラウドセンシングを活用したバリアフリーマップ作成について考える。今回対象とするバリアフリーマップとは、都市を移動する際に障害となりうる段差や坂などの路面情報を地図上に表したものである。このようなバリアフリーマップは、自治体などが中心となり作成が進みつつあるが、その作成にあたっては多くの人手がかかることや、街の変化に応じて随時更新が必要であることなど課題も多い。そこで本研究では、クラウドセンシングにより収集したセンサデータを元に路面状況を理解し、GPS 等で得られる位置情報と組み合わせることで、バリアフリーマップの作成コストを低減させることを目標とする。本稿ではこの目標に向け、人が携帯するスマートフォンの加速度データから、人の歩行状況を分析して、平坦な路面なのか、移動する際に障害となり得る路面なのかを識別するタスクに取り組む。

人が携帯するセンサ情報から行動を認識するというタスクは、様々な設定のもとで研究がなされてきた。そのなかでも多くの研究は、あらかじめ決めた一定時間ごとのセグメントにセンサデータを区切り、そのセグメントに対応する行動を判別するタスクに取り組んでいる。

例えば、Kwapisz ら [7] は、時系列加速度データを 10 秒ご

とに区切り、それぞれのセグメントにおいて何が行われていたのか推定するタスクに取り組んだ。推定の対象となる行動は、歩いている、走っている、階段を上っている、階段を下っている、座っている、直立しているという 6 種類であった。Pärkkä ら [10] は同様のタスクに対して 5 秒ごとのセグメントを用いている。Anguita ら [3] の研究では、前後で 50% ずつ重複するように 2.56 秒ごとにセグメント化するという手法がとられている。

しかし、段差の有無のような路面の状況を推定するためには、一步単位で歩行者の行動を認識する必要がある。そのため、このような既存研究と同じ方法をそのまま適用することはできない。そこで、加速度データを一步ごとにセグメント化し、それぞれの一步がどのような路面に対応しているのか識別する問題を考える。

これを実現するためには、二つの課題がある。一つ目は、スマートフォンのセンサから取得した加速度データを、一步ごとにセグメント化するというタスク (課題 1) である。二つ目は、一步単位にセグメント化された短時間のデータから、ユーザの行動を理解し、路面状況を把握するというタスク (課題 2) である (図 1.)。

本稿では、一つ目の課題には立ち入らないものとし、二つ目の課題のみを扱う。ただし、一つ目の課題については、次のような比較的簡易な方法で、ある程度の精度でセグメント化できるという結果が得られている。まず加速度データを 10 秒程度のウィンドウに区切り、そのウィンドウ内で FFT をかけ、ピークの立つ周波数をもとに周期を特定する。そして、それにもとづいてセグメント化するという方法である。

課題 2 の実現のために、本研究では、過去の行動認識の研究と同じく教師あり学習の枠組みを採用した。一步に対応する加

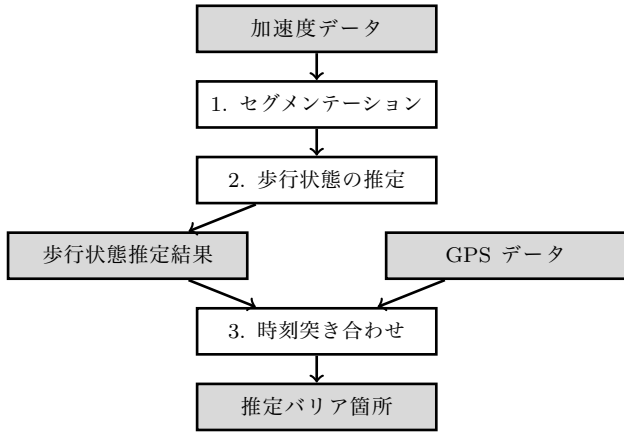


図1 センシングによる路面情報収集プロセス

速度データはある一定期間の波形だが、このままでは学習に向きであるため、ここからその一歩の特徴を表すような特徴量を抽出する必要がある。そこで、行動認識研究で提案されている特徴抽出の手法を、一歩単位のデータに対して適用し、一歩に対応する特徴を得た。また、各ステップの行動は、前後のステップにも影響を及ぼしていると考えられるため、前後のステップに対応するデータも特徴として利用した。

以上の提案内容を検証するため、約10人の被験者から収集した、屋外における歩行データを用いて実験を行った。また、路面状況を推定する課題のみに着目するため、データセットとしてあらかじめ歩行者自身の手によってセグメント化されたデータを用いた。

本論文の貢献は以下のとおりである。

- 行動認識の特徴量を用いた教師あり学習による路面状況推定精度評価
- 複数の特徴量を組み合わせることによる路面状況推定精度向上
- 前後の歩行データを用いることによる路面状況推定精度向上
- スマートフォンの持ち運び方法の違いによる実験結果への影響に対する考察

本稿の構成は以下のとおりである。まず二章で関連研究について述べ、三章で本稿で取り組む問題の設定を明確にする。四章で提案手法について詳述し、五章で提案手法の性能評価のために行った実験の設定と結果の解説にあてる。最後に六章で今後の課題を述べる。

2. 関連研究

2.1 センサデータからの行動認識

加速度データを用いて行動認識するというタスクには、ここ数年で多くの手法が提案されている。そのうち多くは、あらかじめ決めた一定時間ごとに区切った加速度データについて、行動を識別するというタスクを対象としている。

例えば、今回の設定と同じスマートフォンのセンサデータを利用した行動認識の代表的な研究である Kwapisz ら [7] の研究では、スマートフォンから得られた3軸加速度データを10秒

ごとに区切り、それぞれから43次元の特徴量を抽出し、これを使って予測を行っている。Pärkkä ら [10] は、5秒の時間窓を用いてセグメント化し、ユーザごとにパーソナライズされた識別器を作成することで高い予測精度を達成している。Anguita ら [2] の研究では、3軸加速度データから2.56秒ごとに切り出すときに、前後のセグメントが50%ずつ重複するようにとり、それぞれから17次元の特徴量を取り出し、学習を行っている。

Kwapisz らが提案した43次元の特徴量は以下のとおりである(表2)。

各軸の平均 (3次元). x, y, z 軸のそれぞれに関する平均値。これを $\bar{x}, \bar{y}, \bar{z}$ とする。

各軸の標準偏差 (3次元). x, y, z 軸のそれぞれに関する標準偏差。

平均からの差の絶対値の平均 (3次元). x, y, z 軸のそれぞれについて、平均値からの差の絶対値の平均をとったもの。

二乗和の二乗根の平均 (1次元). 各時刻における2-ノルムの平均。

ピーク間の距離 (3次元). x, y, z 軸のそれぞれについて次のように求める。まず、少なくとも3つ以上のピークを見つけるために、最大値よりも少し小さい閾値を定める。その閾値以上の値をとる連続した区間それぞれについて、その最大値をピーク x_{t_1}, \dots, x_{t_K} とする。得られたピークの間隔 $t_k - t_{k-1}$ を求め、その平均をとる。

ヒストグラム (30次元). x, y, z 軸のそれぞれについて、最大値と最小値のあいだを10分割し、各区間に入っているサンプル数を並べたもの。

表1 本稿で用いる記号一覧

N	一歩分のデータにおけるサンプル数
x_t	時刻 t における x 軸方向の加速度
\bar{x}	x 軸方向の加速度の平均
K	ピークの数
t_k	k 番目のピークの時刻
$\text{hist}(X, \text{bins} = b)$	ビン数 b としたときの集合 X のヒストグラム
l	離散フーリエ変換の点数
p_i	正規化されたパワースペクトルの周波数 i における値

表2 3軸加速度データの特徴量 [7]

特徴量	定義
各軸の平均 (3次元)	$\frac{1}{N} \sum_{t=1}^N x_t$
各軸の標準偏差 (3次元)	$\frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})^2$
平均からの差の絶対値の平均 (3次元)	$\frac{1}{N} \sum_{t=1}^N x_t - \bar{x} $
二乗和の二乗根の平均 (1次元)	$\frac{1}{N} \sum_{t=1}^N \sqrt{x_t^2 + y_t^2 + z_t^2}$
ピーク間の距離 (3次元)	$\frac{1}{K-1} \sum_{k=1}^{K-1} (t_{k+1} - t_k)$
ヒストグラム (30次元)	$\text{hist}(\{x_t\}_{t=1}^N, \text{bins} = 10)$

本研究では Kwapisz ら [7] の提案した特徴量を中心に、これ

らの特徴抽出の手法を一步ごとにセグメント化された加速度データに対して用いることにする。

2.2 ホイール付き乗り物を用いた路面状況理解

ホイール付き乗り物にセンサを装着し、そこから得られるデータを用いて、路面情報を収集しようとする試みはいくつか行われてきた。

例えば、Eriksson らの研究 [4] では、タクシーに組み込まれたセンサから得られるデータを利用して、道路のくぼみを検出している。彼らは、加速度データに機械学習の手法を適用することで、道路のくぼみや、その他の深刻な路面の異常を認識することに成功している。

他にも、Mohan ら [8] は、開発途上地域の道路を対象とした手法を開発している。Eriksson らの研究では自動車のダッシュボードに固定されたセンサを用いていたが、より複雑な状況に対応するために、固定されていないスマートフォンのセンサから集めたデータを用いている。彼らは、加速度や GPS データ以外にも音声などのデータを利用し、様々な路面の異常を検出できることを実証した。

本研究では、狭い場所や屋内などの、自動車が入り込めない場所や積極的に通らない場所についても路面情報を収集することを検討しているため、歩行者から集めたセンサデータを利用する。

3. 問題設定

本研究では、一步ごとの加速度データから路面状況を推定する問題に取り組む。具体的な問題設定は次のとおりである。

まず、スマートフォンに内蔵された加速度センサから取得した 3 軸加速度データを、一步ごとにセグメント化したものを入力とする。ただし、スマートフォンがどのような状態にあるかはわからないものとする。例えば、ポケットに入っているか、かばんに入っているかは未知とし、どちらのデータも同じように扱う。

このようなデータを入力として、各ステップがどのような路面状況のもとでなされたのかを予測することを目指す。すなわち、そのステップが平坦な場所を歩いたときのものなのか、段差や坂を歩いたときのものなのかを識別するタスクに取り組む。一步ごとの加速度データそれぞれについて、平坦、段差の上り、段差の下り、坂の上り、坂の下りの 5 つのクラスから一つを出力として返す。

また、一定数の人手でラベル付けされた訓練データを用意する。これを用いて学習を行い、正解ラベルが与えられていないデータについて、路面状況を予測する問題を考える。

4. 提案手法

今回対象とする路面状況は、前述のとおり平坦、段差、坂の 3 種である。我々は、歩行する人がこれらを通る際にそれぞれ異なる動きを行うと考え、行動認識で利用されている加速度データとそれを元にした特徴量を利用することを考える。例えば、平坦な場所を歩くときと段差を上るときでは、歩行者の行動が異なる。そのため、行動認識の手法を利用することで加

速度データから路面状況が推定できるのではないかと考えられる。

提案手法の概略は次のとおりである。まず、それぞれの加速度データから、各ステップに対応する特徴量を抽出する。次に、そうして得られた特徴ベクトルに、教師あり学習の手法を適用する。すなわち、最初に訓練データを用いて学習を行い、識別器を得る。そして、学習済みの識別器を用いてラベルの与えられていないステップのラベルを予測する。以下では、特徴量の抽出手法について詳述する。

4.1 加速度データからの特徴量の抽出

まず、Kwapisz ら [7] の研究で 10 秒ごとの加速度データに対して使われていた特徴量の抽出手法を、一步単位の加速度データに適用し、43 次元の特徴ベクトルを得た (表 2)。しかし、一步単位では、セグメントの幅は Kwapisz らが実験で用いていた 10 秒より短くなってしまいうため、これだけの特徴では差異が明確にならない場合があると考えられる。そこで、以下の 14 次元の歩行検知のための特徴量を追加することで、短いセグメントの中でも行動の特徴を捉えることを狙う。

パワースペクトルのヒストグラム (10 次元). $\{(x_t, y_t, z_t)\}_{t=1}^N$ を離散フーリエ変換したものを $\{X_i\}_{i=1}^l$ とする。ただし、 l は離散フーリエ変換の点数とする。すると、パワースペクトルは $P_i = |X_i|^2$ であり、正規化されたパワースペクトルは $p_i = P_i / \sum_i P_i$ で求められる。 p_i の最大値と最小値のあいだを 10 分割し、各区間に入っているサンプル数を並べたものを特徴として用いる。

周波数成分エントロピー (1 次元). 正規化されたパワースペクトルを p_i とすると、周波数成分エントロピーは $-\sum_i p_i \log p_i$ である。

軸の間の共分散 (3 次元). x 軸と y 軸のあいだの共分散は、 $\frac{1}{N} \sum_t (x_t - \bar{x})(y_t - \bar{y})$ である。同様に、 y 軸と z 軸、 z 軸と x 軸のあいだの共分散も特徴として用いた。

表 3 追加した特徴量

特徴量	定義
パワースペクトルのヒストグラム (10 次元)	$\text{hist}(\{p_i\}_{i=1}^l, \text{bins} = 10)$
周波数成分エントロピー (1 次元)	$\sum_{i=1}^l p_i \log p_i$
軸の間の共分散 (3 次元)	$\frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})(y_t - \bar{y})$

4.2 前後の特徴の利用

次に、上記のような手法で得られた特徴ベクトルに、前後各一步に対応する加速度データから得られた特徴量を追加することを考える。この方法は、以下の二つの理由から効果を発揮すると考えられる。

一つ目の理由は、その場所を歩いたステップのみではなく、前後のステップにも路面状況が影響していると考えられるからである。例えば、段差を歩いた直後のステップは、段差を上った影響が残り、ずっと平坦な場所を歩いているときのステップとは歩き方が異なると考えられる。このように、前後の一步の

特徴量の中にも、その場所の路面状況が現れているため、前後の特徴量の利用によって推定精度が向上すると考えられる。

二つ目の理由は、加速度データの波形が左右どちらの足を踏み出したかによって大きく異なることである。加速度データの x 軸、 y 軸、 z 軸それぞれの値と各時刻における 2-ノルムをプロットして観察したところ、すべての被験者のデータで、右足を踏み出したときと左足を踏み出したときで加速度の波形が大きく異なることが見てとれた (図 2)。これは、例えばスマートフォンをズボンの右ポケットに入れている場合に、右足を踏み出したときの方が左足を踏み出したときよりも加速度が大きく変化するように、スマートフォンの入れ方に起因していると考えられる。この左右の差異に対する最も素朴なアプローチは、右足左足を認識したうえで判別することである。しかし、右足左足の認識は、センサの場所が未知な状況では現実的でない。そこで、別のアプローチとして、前後との関係を見ることで識別精度を向上させられるのではないかと考えた。このような観点からも、この方法は効果的だといえる。




図 2 右足を踏み出したときと左足を踏み出したときの波形の違い (ズボンの右前ポケットにスマートフォンを入れた場合)

5. 実験

5.1 データセット

本研究では、クラウドセンシングによって集めたデータを用いて実験を行う前の段階として、9人の被験者から集めたデータセットで実験を行った。

まず、歩行するルートとして、ともに段差や坂を含む2種類のコースを設定した。そのそれぞれを、スマートフォンを身につけた9人の被験者に歩行してもらい、3軸加速度データを収集した。このとき、スマートフォンを2台用意し、1台をズボンの右前ポケットに、もう1台を手持ちのかばんに入れ、別々にデータを集めた。クラウドセンシングで一般のユーザから集めたデータを想定して、どちらの場合もスマートフォンを特に固定することなく、普段通りの方法でポケットまたはかばんに入れてもらった。

加速度データを集めるためのスマートフォンとは別の端末を

歩行者の手元に用意し、歩行者に歩きながら一歩ごとの間隔を記録してもらった。このセグメントを用いて加速度データを一歩単位に分割した。今回の実験ではこのようにあらかじめ一歩単位にセグメント化されたデータを用い、自動でセグメント化する手法については扱わないものとする。

平坦な場所、上りの段差、下りの段差、上り坂、下り坂の5種類のラベルを、歩行者に同行する人の手によって各セグメントに付与してもらい、これを正解データとした。2種類のコースそれぞれにおいて、ラベルごとのサンプル数の合計は以下の表のようになった。

表 4 ラベルごとのデータ数

	平坦	上り段差	下り段差	上り坂	下り坂
コース 1	6512	520	1079	1232	0
コース 2	4043	898	134	0	1884

スマートフォンは Android4.4 が搭載された Nexus5 を用いた。加速度のサンプリングレートは 200Hz とした。

5.2 実験の設定

ランダムフォレストや AdaBoost など、機械学習ライブラリ scikit-learn [1] に実装されている様々な識別器を試した結果、最もよい結果が得られた RBF カーネルの SVM をすべての実験で識別器として用いた。

特徴ベクトルは次のようにスケールしてから学習した。まず、95 パーセント点の値を 1、5 パーセント点の値を 0 とし、線形のスケールを行った。さらに、1 以上の値すべてを 1 に、0 以下の値すべてを 0 とした。

推定精度の評価には、ユーザごとの交差検定を用いた。データ全体をユーザごとに分割し、それぞれのユーザについて、そのユーザをテストデータ、その他のユーザを訓練データとして実験を行い、その平均を全体の実験結果とした。ユーザごとの分割を用いるのは、実際の応用の場面では未知のユーザの加速度データの予測を行う必要があるからである。

5.3 結果

Kwapisz ら [7] が提案した 43 次元の特徴量を一歩単位の加速度データに用いた場合と、14 次元の特徴を新たに追加した場合それぞれについて、前後の特徴を使わない場合、前の一歩の特徴のみ使う場合、後ろの一歩の特徴のみ使う場合、その両方を使う場合の 4 種類について実験を行った。また、スマートフォンをポケットに入れた場合のデータのみを用いた場合、かばんに入れた場合のデータのみを用いた場合それぞれについて同様の実験を行った。その結果、それぞれの場合の予測精度 (Accuracy) は以下の表のようになった (表 5, 6, 7)。

表 5 データ全体に対する実験結果

	1 歩	2 歩 (+前)	2 歩 (+後)	3 歩
43 次元	0.5828	0.6765	0.6863	0.7178
57 次元	0.6010	0.6989	0.7054	0.7322

14 次元の特徴追加によって、すべての指標において精度向上

表 6 ポケットデータに対する実験結果

	1 歩	2 歩 (+前)	2 歩 (+後)	3 歩
43 次元	0.6021	0.6917	0.7030	0.7324
57 次元	0.6311	0.7226	0.7299	0.7568

表 7 かばんデータに対する実験結果

	1 歩	2 歩 (+前)	2 歩 (+後)	3 歩
43 次元	0.5934	0.6700	0.6788	0.7039
57 次元	0.5985	0.6685	0.6847	0.7119

が見られる。また、前後の特徴を追加することによって、大幅に精度が向上していることがわかる。後ろの一步の特徴を追加したときの方が、前の一步を追加したときよりも精度がよいことから、後ろの一步の方が路面状況の推定に重要であると考えられる。

ポケットデータとかばんデータの結果を比較すると、すべての手法のもとでかばんよりポケットの方が高精度の予測が得られていることがわかる。おそらくポケットの方が被験者の歩き方の影響を直接受けるため、路面状況の推定がより容易なのだと考えられる。

また、データ全体を用いた場合の平坦、段差、坂の各ラベルごとの予測精度の変化は以下の表のようになった (表 8)。ただし、F1 は $2 \cdot \text{precision} \cdot \text{recall} / (\text{precision} + \text{recall})$ で定義される値である。平坦はラベル数が多いため、他のラベルと比較して高い精度で予測できている。一方で、坂は平坦な場所との区別がつきにくいいため、低い予測精度になっている。しかし、すべてのクラスで、提案手法の適用によって予測が大幅に改善されていることがわかる。

表 8 ラベルごとの予測精度

		平坦	上り段差	下り段差	上り坂	下り坂
43 次元 1 歩	Precision	0.7091	0.3258	0.4204	0.2388	0.3119
	Recall	0.7601	0.3124	0.4210	0.1830	0.2549
	F1	0.7337	0.3190	0.4207	0.2072	0.2805
57 次元 1 歩	Precision	0.7207	0.3622	0.4393	0.2673	0.3133
	Recall	0.7837	0.3487	0.4472	0.1818	0.2446
	F1	0.7509	0.3554	0.4432	0.2164	0.2748
43 次元 3 歩	Precision	0.7614	0.5999	0.6598	0.5046	0.5751
	Recall	0.8984	0.4309	0.5996	0.2228	0.4095
	F1	0.8243	0.5015	0.6282	0.3091	0.4784
57 次元 3 歩	Precision	0.7569	0.6773	0.6926	0.5735	0.6282
	Recall	0.9284	0.4292	0.6140	0.1964	0.3879
	F1	0.8339	0.5254	0.6509	0.2926	0.4796

最後に、加速度データと同時に収集した GPS データを使って予測結果を空中写真上に図示したところ、図 3 のようになった。ただし、予測結果には、57 次元の特徴量を 3 歩分利用した場合の結果を用いた。踊り場のように、連続する段差の中に一步分だけ交じっている平坦な場所や、平坦な道の途中にある一步分の段差も、ほとんど正確に検出できていることがわかる。しかし、付近にあるビルなどが原因で、GPS によって得られる座標には測位誤差が含まれてしまっているため、ビルに近い画

像左部分では正しい位置にマッピングできていない。このような GPS 誤差を考慮した手法を開発することは、今後の課題である。

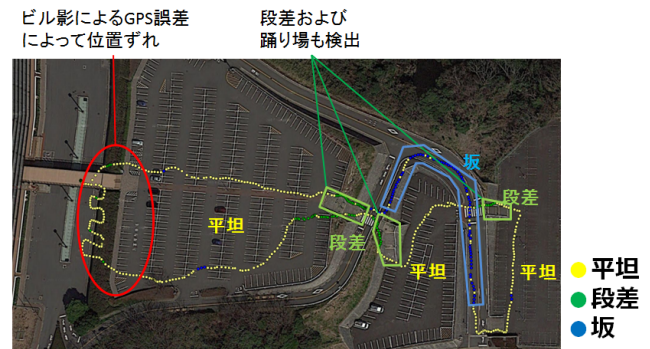


図 3 予測結果の空中写真へのマッピング

(空中写真画像 (c)2016 Google, Digital Earth Technology, DigitalGlobe)

6. おわりに

本稿では、スマートフォンのセンサを用いて集めた加速度データから、教師あり学習の手法を用いて路面情報を収集する問題に取り組んだ。この問題に対して、行動認識に用いられていた特徴量を一步単位の加速度データから抽出し、さらに前後の一步の特徴を利用するという手法を提案した。約 10 人の被験者から収集したデータセットを用いた実験によって、この手法を用いることで推定精度が向上することを確認できた。

しかし、実際にクラウドセンシングのデータに今回の手法を適用して路面状況を集めるためには、いくつかの課題が残されている。

まず、今回の手法によって 70%以上の精度で路面状況を推定できることがわかったが、実社会で利用するためにはまだ不十分である。新たな手法の開発や特徴の追加によって、より高精度で路面状況を予測できなければならない。そのためには、ユーザごとの差異を利用するなど、加速度データの特徴を活用する必要があるが、これについては今後の課題である。

また、得られた路面状況の予測結果を地図上に射影するためには、各ステップと地図上の座標を対応づけなければならない。ほとんどのスマートフォンには GPS センサが内蔵されているため、GPS 情報を取得することは容易だが、実際には図 3 からもわかるように GPS 誤差があるため、正確な座標を対応づけることは困難である。GPS 誤差に対して頑健なマッピング手法を開発することも今後の課題である。例えば、今回の技術を用いて GPS 軌跡中で段差がありそうな箇所を特定し、それと地図上で段差があるとわかっている階段などを対応付けることで、GPS 誤差を修正しつつ、新たなバリアを発見する事なども今後検討すべき課題と考える。

文 献

- [1] scikit-learn: Machine Learning in Python. <http://scikit-learn.org/>
- [2] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, Human activity recognition on smartphones using a

- multiclass hardware-friendly support vector machine, *Ambient assisted living and home care*, Springer Berlin Heidelberg, pp. 216–223, 2012.
- [3] A. Brajdic and R. Harle, Walk detection and step counting on unconstrained smartphones, *Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing*, pp.225-234, 2013.
 - [4] S. B. Eisenman, E. Miluzzo, N. D. Lane, R. A. Peterson, G. Ahn, and A. T. Campbell, BikeNet: A mobile sensing system for cyclist experience mapping, *ACM Transactions on Sensor Networks (TOSN)*, 6(1), 6, 2009.
 - [5] J. Eriksson, L. Girod, B. Hull, R. Newton, S. Madden, and H. Balakrishnan, The pothole patrol: Using a mobile sensor network for road surface monitoring, *Proceedings of the 6th international conference on Mobile systems, applications, and services*, pp.29–39, 2008.
 - [6] W. Guo and S. Wang, Mobile crowd-sensing wireless activity with measured interference power, *Wireless Communications Letters*, IEEE, 2(5), pp.539–542, 2013.
 - [7] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, Activity recognition using cell phone accelerometers, *SIGKDD Explorations Newsletter*, 12(2), pp.74-82, 2010.
 - [8] P. Mohan, V. N. Padmanabhan, and R. Ramjee, Nericell: rich monitoring of road and traffic conditions using mobile smartphones, *Proceedings of the 6th ACM conference on Embedded network sensor systems*, pp.323–336, 2008.
 - [9] M. Mun, S. Reddy, K. Shilton, N. Yau, J. Burke, D. Estrin, M. Hansen, E. Howard, R. West, and P. Boda, PEIR, the personal environmental impact report, as a platform for participatory sensing systems research, *Proceedings of the 7th international conference on Mobile systems, applications, and services*, pp. 55–68, 2009.
 - [10] J. Pärkkä, L. Cluitmans, M. Ermes, Personalization algorithm for real-time activity recognition using PDA, wireless motion bands, and binary decision tree, *IEEE Transactions on Information Technology in Biomedicine*, 14(5), 2010.