

# 複数人健常者の歩行時加速度データを用いた バリア検出精度の検証

荒木 伊織<sup>1</sup> 王 統順<sup>1</sup> 鈴木 天詩<sup>1</sup> 宮田 章裕<sup>1,a)</sup>

## 概要：

現在、屋内外には段差などのバリアが多数存在し、障害者の円滑な移動を妨げている。バリア位置を事前に把握できれば、彼らは移動計画が立てやすくなるが、既存のバリア検出手法では、網羅性・精度がトレードオフの関係にある。そこで、我々は、広域のバリア情報を高精度に収集するために、健常者の歩行時加速度データを用いてバリア検出を行う取り組みを進めている。本稿では、複数人のセンサデータを用いた場合のバリア検出精度について報告する。

## An Investigation of a Barrier Detection Method using Sensor Data of Unimpaired Walkers

IORI ARAKI<sup>1</sup> TONGSHUN WANG<sup>1</sup> TENSHI SUZUKI<sup>1</sup> AKIHIRO MIYATA<sup>1,a)</sup>

### 1. はじめに

屋内外を観察すれば容易に気付くことであるが、現在の日本の道路・通路は障害者や高齢者にとって移動しやすいものではない。狭い国土であるため道幅が狭いのは仕方がないかもしれないが、車椅子利用者が自力では出入りできないような開き戸しかないオフィスや、段差を越えないと入店できない飲食店が街中に溢れている現状においては、障害者や高齢者に配慮した街づくりがされているとはとても言いにくい。これらの円滑な移動を妨げるもの（以降、バリア）の存在を把握することは、障害者や高齢者の移動計画を助けることができ、障害者や高齢者が外出しやすくなる。

従来研究では、車椅子にセンサを取り付けてバリア検出をするものもあるが、本研究では、健常者にセンサを取り付けることにより、車椅子が通ることのできない狭い道など広範囲のバリアを検出することができる。健常者にセンサをつけてバリア検出することにより、通行人の邪魔をせずに多くのバリア情報を収集することができる。

本研究では、健常者1人の歩行時の加速度データを用いた場合と、健常者複数人の歩行時の加速度データを用いた場合の検出精度差を調査する。

### 2. バリア収集に関する研究事例

屋内外のバリア情報収集に関する研究事例は数多い。それらは、人間が判断を行うアプローチと、システムがセンサデータに基づいて自動判断するアプローチに大別できる。さらに前者は人間が現地に赴いて判断するもの（2.1.1節）と、歩行時のセンサデータに基づくもの（2.2.2節）に細分化でき、後者は車両移動時のセンサデータに基づくもの（2.2.1節）と、歩行時のセンサデータに基づくもの（2.2.2節）に細分化できる。

#### 2.1 人間が判断を行うアプローチ

##### 2.1.1 人間が現地に赴き判断するアプローチ

人間が現地に赴き判断するアプローチとしては、一般ユーザが現地に赴いてバリア情報を発見・収集する事例がある。[1]は、調査すべき項目を明示した専用入力フォームを用いることで、専門知識を持たない調査員でもバリアフリーに関する情報を収集できるツールであり、これを利用

<sup>1</sup> 日本大学 文理学部  
College of Humanities and Sciences, Nihon University  
<sup>a)</sup> miyata.akihiro@nihon-u.ac.jp



図 1 石畳



図 2 段差



図 3 急斜面

した路面バリアのクラウドセンシングシステム MaPiece[2]が提案されている。

### 2.1.2 人間が遠隔地から判断するアプローチ

人間が遠隔地から判断するアプローチとしては、一般ユーザがインターネットを通じて遠隔地からバリア情報を発見・収集する事例 [3][4][5] がある。これらは、Google Street View 上で市街地の写真を作業者が閲覧し、バリアを発見した箇所にマーキングする方式をとっている。

## 2.2 センサデータから自動判断するアプローチ

### 2.2.1 車両移動時のセンサデータから判断するアプローチ

車両移動時のセンサデータから自動判断するアプローチとしては、自動車移動時のセンサデータから車道上のバリア情報を発見する事例や、車椅子移動時のセンサデータから歩道上のバリア情報を発見する事例がある。[6] は、専用モジュールを搭載した自動車で計測した加速度データから抽出した特徴量を、ルールベースで分析して車道上の窪みなどを検出している。[7] は、電動車椅子の移動における走行負荷を移動難度に変換して移動難度によって手動車椅子の移動における仕事量推定が可能かどうかの実験をして、移動難度における路面評価によってバリア検出をしている。[8] は、スマートフォンの各種センサを使い車椅子での移動時に路面情報を収集し、バリア検出をしている。エリア情報判定機能により、バリア検出されたバリア情報を地図上に投影して場所を推定している。[9] は、車椅子用に左右のホイールトルクを測定できる装置を実装して、そこから水平の違いや斜面などの車椅子利用者の障害になるものを検出しマップに記録するシステムを作っている。

### 2.2.2 歩行時のセンサデータから自動判断するアプローチ

センサデータを用いて人間の歩行の様子を推定しようとする試みは数多い。[10] は、健常者の歩行時の加速度データを計測し、そのデータで機械学習を行いバリア検出をしている。[11] は、足首に取り付けた装置で計測した加速度データから抽出した Time Domain (TD), Frequency Domain (FD) の特徴量を分析する決定木を作成し、ユーザが歩いているか、走っているかなどの状態を推定している。決定木に用いられるパラメータは固定的ではなく、各

ユーザの直前のデータに基づいてオンラインで更新されるため、パーソナライズされた推定結果が得られるとしている。[12] は、スポンの前ポケットに入れたスマートフォンで計測した加速度データから抽出した平均値、標準偏差、ピーク間距離などの TD 特徴量を、ロジスティック回帰などの機械学習手法で分析して、歩く、走る、階段を上る、階段を下りる、座る、直立するという 6 つの行動の識別を行なっている。一方、[13] は、スマートフォンをスポンのポケットに入れた状態に加え、靴に入れた状態、手に持った状態で計測した加速度データから、ユーザが歩いているか否かを判定している。判定には HMM などの機械学習手法を用いており、利用する特徴量は TD・FD のものである。上記の行動推定技術の発展として、歩行時のセンサデータから路面状態を推定してバリア情報を発見する試みが現れ始めている。[14] は、靴に固定した加速度センサで計測したデータから抽出した特徴量を、ルールベースで分析することで、路面が平坦か凹凸かを推定している。[15] は、TD,FD の特徴量を分析する SVM の識別器を作成し、ユーザが歩いている路面が平坦か、階段か、坂か判定する試みを行なっている。この研究ではスマートフォンの位置(例:ポケット、靴)が未知であるとし、推定対象の時間帯の前後時間帯も分析することで推定精度を向上させている。

## 3. 研究課題

### 3.1 問題定義

2.1.1 節の人間が現地に赴き判断するアプローチは人的コストが高く、広域のバリア情報を集めるのには不向きであるし、2.1.2 節の人間が遠隔地から判断するアプローチは画像の解像度・オクルージョンの問題から、バリア情報の正確性が高まりにくい。

2.2.1 節の車両移動時のセンサデータから判断するアプローチだと車両が行ける場所でしか判断できず広域のバリア情報を集めるのには不向きである。そこで本研究は 2.2.2 節の歩行時のセンサデータから自動判断するアプローチを用いることにする。2.2.2 節の [10] では、広域のバリア検出ができるが、1 人分のデータでしか実験をしておらず、検証が十分でないと考えられる。

### 3.2 研究課題の設定

本研究では、健常者の歩行時の加速度データを機械学習で分析してバリア検出するタスクにおいて1人のデータを用いた場合と、複数人のデータを用いた場合の検出精度の差を調査する。

## 4. 研究方針

### 4.1 推定対象のバリア

障害者に対するバリアとして自明なものに、階段と坂があり、当然これらは推定対象とする。階段に類するものとして、[10]の実験より図2のような1段の段差もセンサデータから、推定できることがわかったので推定対象とする。坂についても、車椅子利用者でも通行可能な緩い坂(勾配3度程度)と、健常者でも自転車で上るのは難しいような急坂(勾配10度程度)に詳細化して検証する。また、市街地を観察すると、平地であっても、障害者にとってのバリアが存在することに気付く。たとえば図1のような石畳は、車椅子で通行すると路面の凹凸による振動が大きく不快であるし、松葉杖の接地が不安定になることもある。ドアも開き方によってはバリアになりうる。自動ドアや横方向に開く引き戸であれば、上手く開閉できる障害者は少ない。しかし、引き開ける／押し開けるタイプの引き戸は、車椅子や松葉杖を操りながら開けることは容易ではない。

以上をまとめると、本稿で推定対象とするバリアは次のとおりである。

- 階段
- 1段の段差
- 緩い坂(勾配3度程度)
- 急な坂(勾配10度程度)
- 石畳
- 引き戸

他にも推定すべきバリアは存在すると思われるが、さらなる実地調査や、障害者へのヒアリングなどによって明らかにしていきたい。

### 4.2 推定方式

推定には加速度センサデータを用いることにする。歩行という動きを分析する上で加速度に注目することは妥当と思われるし、加速度センサはほぼすべてのスマートフォンに内蔵されており、広く世の中に普及しているためである。

歩行時に生じる加速度センサデータからバリア情報を検出する方法として、人手で設計した特徴量(Hand-crafted Features, 以降 HCF)を機械学習するアプローチが数多く提案されてきた[11][12][13][14][15]。本研究もこの方式(以降 HCF 方式)を利用する。具体的には、上記の研究事例の多くで利用している下記特徴量を機械学習する。特徴量の先頭の記号は、TD / FD 種別と次元数を示しており、合計 33 次元の特徴量となる。

[TD, 3] 平均値 :

推定対象期間における各軸(x, y, z)の加速度値の平均値。

[TD, 3] 標準偏差 :

推定対象期間における各軸(x, y, z)の加速度値の標準偏差。

[TD, 3] 相関係数 :

推定対象期間における各軸間(x-y, y-z, z-x)の加速度値の相関係数。

[FD, 24] スペクトル強度 :

推定対象期間における各軸(x, y, z)の加速度値をフーリエ変換して得られる各周波数帯(0~10Hzを1.25Hzずつ等分した8周波数帯)の平均スペクトル強度。

## 5. 検証実験

### 5.1 実験の目的

健常者の1人の加速度データを用いてバリアごとに精度を分析する方式(以降、1人方式)と複数人の加速度データを用いてバリアごとに精度を分析する方式(以降、複数人方式)に区別してバリア検出精度の差を測定する。

### 5.2 データセット

4.1節の検討に基づく推定対象の一覧を表1に示す。FLTはアスファルト舗装された平坦な屋外の歩道である。STNは図1に示す1辺が約8cmの正方形の敷石で舗装された屋外の歩道である。USP/DSPは図2に示す高さ約15cmの屋内の段差である。USR/DSRは高さ約15cmの段が13段程度続く屋内の階段である。PLD/PSDは手動で引き開け・押し開ける屋内のドアである。ULS/DLSは車椅子用に設置された勾配約3度の屋内のスロープである。UHS/DHSは図3に示す大学内にある勾配約10度のアスファルト舗装された屋外の坂である。

表1の対象を通過している際の加速度センサデータを収集するにあたり、市販の加速度センサなどの部品を組み合わせスマートフォンの専用デバイス(図6)を製作した。専用のソフトウェアも作成し、±2gの範囲のx, y, z軸の加速度をサンプリングレート20Hzで記録できるようデバイスを制御した。このデバイスをズボンの左前ポケットに入れた状態で歩行し、各対象を通過する際に生じる加速度センサデータを計測した。計測実施者は10人(男性, 20代)とした。ズボンは計測者によって異なるが、サイズ・ポケット位置は概ね同じであった。靴は日頃履き慣れているものを履いてもらった。

計測した加速度センサデータはすべて3秒分の固定長になるようにした。以降、この3秒分のデータをサンプルと称する。教師ありデータは、表1の各対象につき10サンプルから20サンプル計測した。結果として、全対象で合

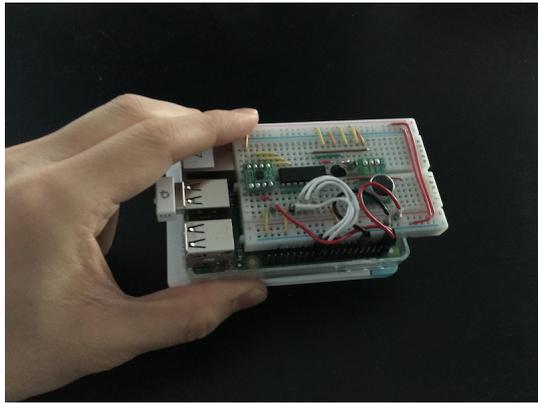


図 4 加速度計測デバイス

表 1 推定対象

略称	内容
FLT (FLaT)	平地
STN (SToNe)	石畳
USR (Up StaiRs)	階段 (上り)
DSR (Down StaiRs)	階段 (下り)
USP (Up SteP)	段差 (上り)
DSP (Down SteP)	段差 (下り)
ULS (Up Low Slope)	緩い坂 (上り)
DLS (Down Low Slope)	緩い坂 (下り)
PSD (PuSh Door)	ドア (押し開け)
PLD (PuLl Door)	ドア (引き開け)
UHS (Up High Slope)	急な坂 (上り)
DHS (Down High Slope)	急な坂 (下り)

計 1700 サンプル計測した。各サンプルには教師ラベルとして表 1 の略称が付与してある。

### 5.3 実験手順

1 人方式の場合、教師ありサンプル 190 件のそれぞれについて 4.2.1 節の TD・FD 特徴量 (33 次元) を算出する。次に、教師ありサンプルから学習用サンプル 152 件を無作為に抽出し、それらを SVM (RBF カーネル) で学習して推定器を作成する。この推定器を用い、教師ありサンプルの残りの 38 件の教師ラベルを推定し、推定精度 (F 値) を測定する。上記試行を、無作為に抽出する学習用サンプルを毎回変えながら、100 回繰り返す。

複数人方式の場合、教師ありサンプル 1700 件のそれぞれについて 4.2.1 節の TD・FD 特徴量 (33 次元) を算出する。次に、教師ありサンプルから学習用サンプル 1360 件を無作為に抽出し、それらを SVM (RBF カーネル) で学習して推定器を作成する。この推定器を用い、教師ありサンプルの残りの 340 件の教師ラベルを推定し、推定精度 (F 値) を測定する。上記試行を、無作為に抽出する学習用サンプルを毎回変えながら、100 回繰り返す。

### 5.4 実験結果

HCF 方式の推定精度 (100 試行の平均 F 値) を図 5 に示す。1 人方式と複数人方式で比べた結果 ULS (緩い坂 (上り)), PSD・PLD (ドア (押し開け・引き開け)) は複数人方式の場合の精度の方が良くなることがわかった。今回検証した ULS (緩い坂 (上り)), PSD・PLD (ドア (押し開け・引き開け)) 以外のバリエーションでは 1 人方式の方が精度が良くなることがわかった。1 人方式と、複数人方式の間で t 検定を行なった結果、全バリエーションの平均精度について 1 人と複数人で比べたところ 0.1 % 水準で有意差がみとめられた。

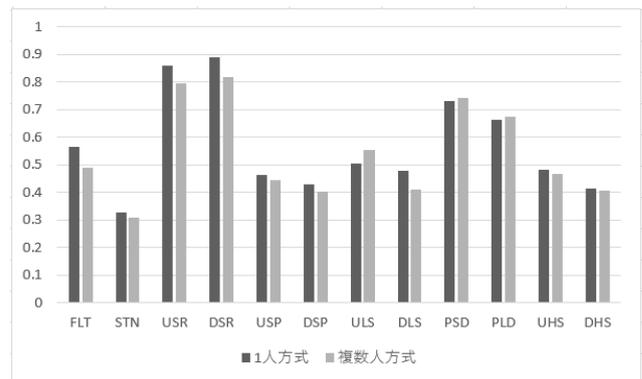


図 5 各方式の推定精度 (F 値)

### 5.5 考察

1 人方式と複数人方式を比べた場合、歩き方に個人差があるため複数人方式では 1 人方式に比べて精度が低いものがあると考えられる。1 人方式と複数人方式を比べた場合、複数人方式の場合の精度が高い ULS (緩い坂 (上り)), PSD・PLD (ドア (押し開け・引き開け)) は個人差の影響が少ないバリエーションで、1 人方式と比べた場合、教師ありサンプルの数も多いので検出精度が上がっていると考えられる。STN (石畳) は、1 人方式と複数人方式共に今回計測した他のバリエーションと比べた場合、精度があまり良く無い、この理由は他のバリエーションと比べ、STN (石畳) は、平面で歩行時の加速度があまり変化しないので FLT (平地) に類似しているからだと考えられる。USR・DSR (階段 (上り・下り)) は、連続して大きな加速度の変化があるため高い精度が出やすいと考えられる。HCF 方式では、教師ありサンプルをもっと増やせば精度は全体的に数パーセント向上すると考えられる。

## 6. おわりに

本研究では、健常者の歩行時の加速度データから、人手で設計した特徴量を機械学習する方式 (HCF 方式) を用いて 1 人方式の場合と複数人方式の場合のバリエーション検出精度の検証を行った。1 人方式の場合の方が精度の高いものが多

いが、個人差の影響が少ないバリアの場合複数人方式の方が精度が高くなることが分かった。本稿では、HCF方式で推定したが、今後、Deep Learnig（深層学習）を用いて推定した場合との比較をすることにより、さらに検出精度が上がるバリアがあると考えられるので、複数人の場合ではどのバリアではHCFとDeep Learnigどちらが優れているかをしっかりと検証していきたい。検証を進めていく中で、点字ブロックは車椅子の人からするとバリアになる可能性があると考えられたので、今後ヒアリングを行い明らかにして、HCF方式またはDeep Learnig方式での推定精度を検証していきたい。今回検証したバリアの他に検証すべきバリアは無いかを障害者にヒアリングして、明らかにしていくことも今後の課題として取り組んでいきたい。今後の研究では人混みの精度の検証をしてより多くのバリアを検出し、精度を検証していきたい。

### 参考文献

- [1] 山本千尋, 船越要, 小長井俊介, 小西宏志, 川野辺彰久: 歩行者移動支援のためのバリアフリー関連情報収集手法の提案, 信学技報, Vol.116, No.23, LOIS2016-8, pp.39-44 (2016).
- [2] 山本千尋, 船越要, 小西宏志, 落合慶広, 川野辺彰久: バリアフリーマップをソーシャルにつくる技術の開発, NTT技術ジャーナル 2016年5月号, pp.21-24 (2016).
- [3] Hara, K., Le, V. and Froehlich, J. E.: Combining Crowdsourcing and Google Street View to Identify Street-level Accessibility Problems, Proc. CHI'13, pp.631-640 (2013).
- [4] Rundle, A., Bader, M., Richards, C., Neckerman, K. and Teitler, J.: Using Google Street View to Audit Neighborhood Environments, American Journal of Preventive Medicine, Vol.40, No.1, pp.94-100 (2011).
- [5] Badland, H., Opit, S., Witten, K., Kearns, R. and Mavoa, S.: Can Virtual Streetscape Audits Reliably Replace Physical Streetscape Audits?, Journal of Urban Health, Vol.87, Issue 6, pp.1007-1016 (2010).
- [6] Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S. and Balakrishnan, H.: The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring, Proc. MobiSys'08, pp.29-39 (2008).
- [7] 隅田康明, 松永勝也, 合志和晃, 志堂寺和則: 車輪付き手動移動体の走行負荷に基づく歩道の評価方法, 情報処理学会論文誌, Vol.57, No5, pp1652-1662 (2016).
- [8] 鈴木貴大, 谷川佳延, 吉田博哉: スマートフォンを用いた車いす利用者のための路面情報収集システムの開発, 2015年度情報処理学会関西支部 支部大会 講演論文集 (2015).
- [9] Taniue, H., Kojima, K., Kanedo, J.: Development of automatic barrier detection System for Wheelchair, Proc. GCCE' 15 (2015).
- [10] 宮田章裕, 荒木伊織, 王統順, 鈴木天詩: 健常者をセンサーノードとして用いたバリア検出の基礎検討, 情報処理学会研究報告 (GN), Vol.2017-GN-101, No.11, pp.1-8 (2017).
- [11] Pärkkä, J., Cluitmans, L. and Ermes, M.: Personalization Algorithm for Real-Time Activity Recognition Using PDA, Wireless Motion Bands, and Binary Decision Tree, IEEE Transactions on Information Technology in Biomedicine, Vol.14, No.5, pp.1211-1215 (2010).
- [12] Kwapisz, J. R., Weiss, G. M. and Moore, S. A.: Activity Recognition Using Cell Phone Accelerometers, ACM SIGKDD Explorations Newsletter, Vol.12, Issue 2, pp.74-82 (2010).
- [13] Brajdic, A. and Harle, R.: Walk Detection and Step Counting on Unconstrained Smartphones, Proc. UBiComp'13, pp.225-234 (2013).
- [14] 佐藤匠, 廣森聡仁, 山口弘純, 東野輝夫: スマートフォンと靴センサを活用した災害時通行路の状況推定, DICOMO'14, pp.258-265 (2014).
- [15] 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: 歩行者クラウドセンシングによる路面状態の推定, DEIM'16 (2016).
- [16] Vincent, P., Larochelle, H., Bengio, Y. and Manzagol, P. A.: Extracting and Composing Robust Features with Denoising Autoencoders, Proc. ICML'08, pp.1096-1103 (2008).
- [17] Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., and Ng, A. Y.: Multimodal Deep Learning, Proc. ICML'11, pp.689-696 (2011).