

# 複数移動手段を用いたセンシングによる詳細なバリア推定

蔵内 雄貴<sup>†</sup> 阿部 直人<sup>†</sup> 小西 宏志<sup>†</sup> 瀬下 仁志<sup>†</sup>

<sup>†</sup> NTT サービスエボリューション研究所 〒239-0847 神奈川県横須賀市光の丘 1-1

E-mail: <sup>†</sup> {yuuki.kurauchi.mv, naoto.abe.dy, hiroshi.konishi.te, hitoshi.seshimo.kh}@hco.ntt.co.jp

**あらまし** 車椅子やベビーカーなどに対して通行可能な経路を自動的に提示するには、バリアの位置や種別の詳細な情報が必要となる。従来は車椅子や健常者におけるセンサデータを用いたバリア推定がなされていたが、それぞれユーザ数や取得可能なバリアの種類に課題がある。そこで本研究では、様々な移動手段におけるセンサデータを用いて詳細なバリアを検出することを目的とする。この実現のため、移動手段とバリアを2段階で推定するモデルを提案する。実験では6クラスの移動手段推定においてF値0.92を達成し、8クラスのバリア推定においてはベビーカーを用いた場合にF値0.62を達成、移動手段別に推定を行うことで、単一モデルで推定する場合と比べて+0.09ポイント改善。提案法の効果を示し、複数移動手段を用いた詳細なバリア推定を実現した。

**キーワード** センシング, 移動手段推定, バリア推定, CNN, データオーギュメンテーション

## 1. はじめに

車椅子やベビーカーなどを利用される方は、小さな段差などのバリアによって通行が困難となるため、馴染みのない場所などにおいて、回り道を余儀なくされることがある。そこで、車椅子やベビーカーなど様々な属性に対し、属性に応じた通行可能な経路を自動的に提示することで、初めての場所でも安心して移動できる。このためには、バリアの位置や種別の情報が事前に必要となる。特にバリアの種別については、車椅子は2cmの段差は通行できないが、ベビーカーは通行できるなど、属性によって通行可能なバリアは異なるため、段差の大きさや坂の度合などを含む詳細なバリアの情報が必要となる。バリア推定の従来研究として、車椅子や健常者のセンサデータおよびGPSを用いてバリアの位置や種別を推定する研究[3][7][14][15][21]がある。しかし、車椅子ではユーザ数や移動範囲が限られているため、広い範囲で常に最新のバリア情報を更新することは難しい。一方で健常者はユーザ数が多いものの、歩行時に衝撃を吸収するため、小さな段差などの詳細なバリアは検出できないと想定される。そこで本研究では、ユーザ数と検出可能なバリア種別、すなわち質と量を担保するため、徒歩や車椅子に加えベビーカーなどの様々な移動手段におけるセンサデータを用いて詳細なバリアを検出することを目指す。

しかし、複数の移動手段を用いて推定する場合、下記2つの課題が存在する。

課題1: 移動手段ごとのバリア推定モデルの選択方法

課題2: 移動手段ごとのモデルチューニングが煩雑

以下で、課題の詳細と本研究でとる解決手法を述べる。

課題1は、移動手段ごとにバリア推定モデルを作成した方が高精度となることが想定されるが、その場合、推定時にどの移動手段のバリア推定モデルを使うかを選択する必要がある問題である。ユーザに現在の移動

手段を設定いただく方法も考えられるが、手間であるほか、設定忘れ等も考えられる。そこで本研究では、まずセンサデータから移動手段の推定を行い、次に推定した移動手段におけるバリア推定モデルを用いる、2段階の推定モデルを提案する。課題2は、移動手段によって用いるモデルやパラメータを変えたほうが高精度となることが想定されるが、移動手段ごとに最適なモデルを検討することは現実的でない問題、すなわち、用いる移動手段が6つだとすれば、6つのモデルを別々にチューニングしなければならない問題である。本研究では、同一のモデルに対して各移動手段のデータで学習し、移動手段およびバリアの推定を行う。

実験では6クラスの移動手段推定においてF値0.92を達成し、8クラスのバリア推定においてはベビーカーを用いた場合にF値0.62を達成、移動手段別に推定を行うことで、単一モデルで推定する場合と比べて+0.09ポイント改善。提案法の効果を示し、複数移動手段を用いた詳細なバリア推定を実現した。

**本研究の貢献:** 以下の通り。

- センサデータをもとに移動手段を推定し、推定した移動手段におけるバリア推定モデルで推定を行う2段階のモデルを提案
- 6クラス(徒歩, 車椅子, ベビーカー, 台車, キャリーケース, 自転車)の移動手段を推定する精度を評価
- 各移動手段のデータで学習した同一のモデルによるバリア推定精度を評価
- 8クラスの詳細なバリア(平坦, 2cm, 8cm, 16cmの段差, 5%, 10%の坂, 階段, 点字ブロック)の推定精度評価を行い、実用的な高い精度を示した
- バリア推定モデルの選択およびモデルチューニングの問題を解決し、複数移動手段を用いたセンシングが現実的に可能であることを示した

**本稿の構成:** 2章では関連研究, 3章では提案法, 4

章では実験，5章では結果と考察，6章では結論と今後の展望について述べる。

## 2. 関連研究

センシングは，ユーザ行動の推定[8][22]など，様々な推定を行うために用いられている[1]。車載センサによる車道の路面状況センシングもあるが[23]，我々の目的は歩道のセンシングである。特に，多くのユーザの情報をを用いて対象を推定する手法はクラウドセンシングと呼ばれ，駅の混雑度合の推定[2]や詳細な地図の作成[12]などに広く使われており，本手法もクラウドセンシングを用いたバリア収集と言える。

バリア収集の研究では，人手による調査を簡易化する研究があり，ボランティア向け[13]と地域住民向け[24]のものがある。調査項目にはトイレの障がい者対応有無や道幅など，センシングによる収集が難しい項目もある。そのため，詳細な項目が収集可能だがコストの大きい調査による方法と，簡略な項目のみ収集可能だがコストの小さいセンシングによる方法を併用する必要があると考える。Google Street Viewを用いたバリア収集法[25]もあるが，本研究の対象である小さなバリアは解像度やオクルージョンの問題で収集が難しいと考えられる。

クラウドセンシングによるバリア収集では，車椅子によるバリア推定[14]のほか，車椅子のセンサを用いて操作内容を推定するため，ユーザの移動能力を推定し，操作内容を推定する2段階のモデルが提案されている[15]。また，車椅子はユーザ数が少なく，移動範囲が限られていることから，健常者のセンサを用いたバリア推定[3][21]もあり，屋内外を区別した学習データを用いて精度向上することが報告されている[7]。これらは，本研究のうち一部の移動手段に特化して推定精度を向上する研究であり，提案法と併用が可能である。また，いずれも坂や段差の推定であり，坂や段差の度合まで推定する本研究とはバリアの粒度が異なる。

その他のバリア収集手段として，専用のセンサを靴に付与する手法[5][26]や車椅子の車輪に付与する手法[27]もあるが，我々はユーザ自身のスマートフォンを用いる，低コストで実現可能な方法を選択した。また，映像による路面状況推定[16]もあるが，車道を通行する車両では，歩道との距離があるほか，ガードレール等で歩道が隠れる場所も多く，歩道への適用は難しいと考えられる。

移動手段推定については，GPSを用いた推定[17]やセンサを用いた推定[18]があるが，手段は歩行，走行，車，バス，電車，バイク，自転車といった移動手段を推定するもので，ベビーカー，車椅子，台車，キャリーケースなどの推定はなされていなかった。

表 1 属性別，通行可能バリアの定義

	車椅子		ベビーカー	杖	健常者
	介助なし	介助あり			
坂	○	○	○	○	○
~5%	×	○	○	○	○
~10%	×	×	×	○	○
10%~	×	×	×	○	○
段差	○	○	○	○	○
~2cm	×	○	○	○	○
~8cm	×	×	×	○	○
~16cm	×	×	×	×	○
16cm~	×	×	×	×	○
階段	×	×	×	×	○

センシングを省電力，省通信，低遅延にする研究もあり，推論に必要なサンプルに絞って観測するCompressed Learning[6]のほか，センサ上でDNNモデルの前半を計算し，ノード数を絞った中間層の計算結果をサーバへと送信，サーバ上でモデルの後半を計算する研究[9][10]がある。特にユーザ自身のスマートフォンを用いるクラウドセンシングの場合，電力消費や通信量の問題が大きいいため，この手法の適用によりユーザの負担が減り，より協力いただきやすくなると考えられる。

## 3. 提案法

本研究の目的は，属性に応じた通行可能な経路を自動的に提示するために，前もってバリアの種別の情報を収集することである。属性とは，介助なし車椅子，介助あり車椅子，ベビーカー，杖，視覚障がいの5つを意味し，それぞれの属性が通行できるバリアを国土交通省による歩行空間ネットワークデータ等整備仕様案[11]を拡張し表1のように定義した。視覚障がいの方については，健常者と同じく通行できないバリアはないものの，ご案内する上で，点字ブロック（視覚障害者誘導用ブロック）の情報が必要となる。そのため，我々が収集すべきバリアは，段差は2cm, 8cm, 16cm, 坂は5%, 10%, これに階段，点字ブロックを加えた7種類となる。正確には点字ブロックはバリアではないが，本稿では簡単のためバリアと呼ぶ。

本研究では，スマートフォンに搭載されたセンサのデータを用いてバリアを推定する方法を用い，ユーザ数と検出可能なバリア種別，すなわち質と量を担保するため，様々な移動手段におけるセンサデータを用いて詳細なバリアを検出することを目指す。用いる移動手段は，徒歩，車椅子，ベビーカー，台車，キャリーケース，自転車の6種類とした。以降の図表などではキャリーケースはキャリーと表記する。用いるセンサは，3軸加速度，3軸ジャイロ，3軸重力，3軸地磁気，気圧の5種類13次元とした。

しかし，複数の移動手段を用いて推定する場合，下記2つの課題が存在する。

課題1：移動手段ごとのバリア推定モデルの選択方法

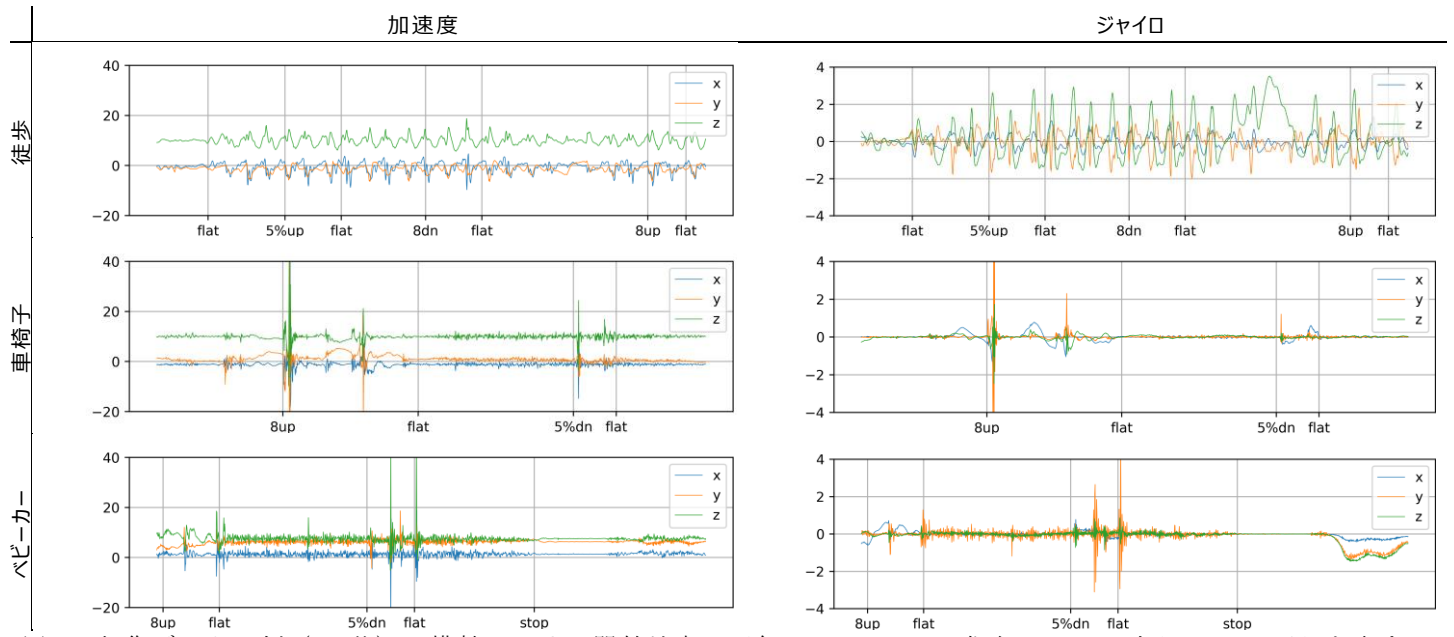


図 1 収集データの例 (15 秒) 横軸はバリア開始地点の正解ラベル. cm は省略し, up は上り, dn は下りを表す.

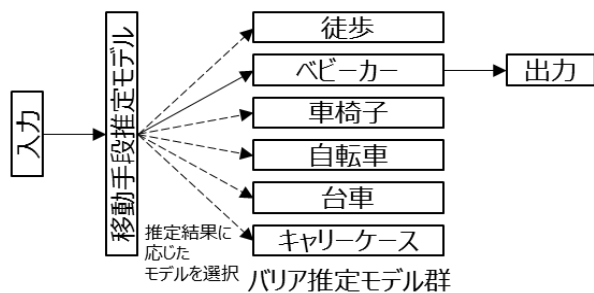


図 2 移動手段とバリアの 2 段階推定モデル(移動手段推定モデルの出力がベビーカーの場合)

課題 2: 移動手段ごとのモデルチューニングが煩雑以下で, 課題の詳細と本稿でとる解決手法を述べる.

課題 1 は, 移動手段ごとにセンサデータの性質が異なるため (図 1), 移動手段ごとにバリア推定モデルを作成した方が高精度となることが想定されるが, その場合, 推定時にどの移動手段のバリア推定モデルを使うかを選択する必要がある問題である. ユーザに現在の移動手段を設定いただく方法も考えられるが, 手間であるほか, 設定忘れ等も考えられる. そこで本研究では, まずセンサデータから移動手段の推定を行い, 次に推定した移動手段におけるバリア推定モデルを用いる, 2 段階の推定モデルを提案する (図 2).

課題 2 は, 移動手段によって用いるモデルやパラメータを変えたほうが高精度となることが想定されるが, 移動手段ごとに最適なモデルを検討することは現実的でない問題, すなわち, 用いる移動手段が 6 つのとき, 6 つのモデルを別々にチューニングするのは現実的で無い問題である. 本研究では, 同一のモデルに対して各移動手段のデータで学習し, 移動手段およびバリアの推定を行うことで, チューニングにかかる時間を削

表 2 追加して用いた特徴と次元数

特徴	次元数
各軸の平均	13
各軸の標準偏差	13
二乗和の二乗根の平均	5
ピーク間の距離	13
ヒストグラム	130
パワースペクトル	1300
パワースペクトルのヒストグラム	130
周波数成分エントロピー	5
軸の間の共分散	13
自己相関係数	130

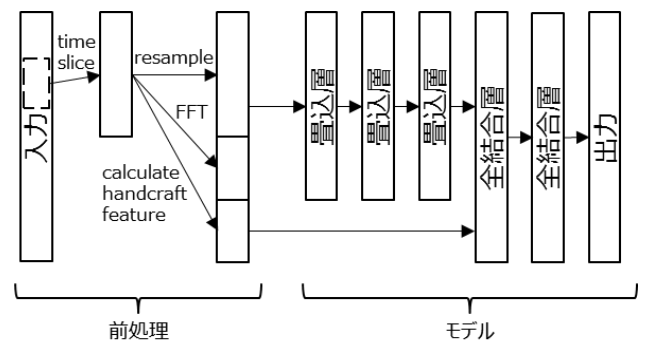


図 3 入力データに対する前処理とモデル概要

減する. 推定の際には[3]で用いられた特徴に加えてパワースペクトル自体と自己相関係数を用いた(表 2). 推定モデルには 3 層の畳込層と 2 層の全結合層からなる CNN(convolutional neural network)を用い, センサデータとパワースペクトルは畳込層に, 特徴は全結合層に入力した (図 3). パラメータは[22]と同等とした.

学習データについては, 移動手段ごとにバリアを推定する場合, 移動手段ごとに様々なバリアを通行したセンサデータが必要となる. また, データを収集する



図 4 データを収集した木製コース

際、街中で自由に歩行したデータに対して正解ラベルを付与しようとする時、歩行場所の測量などによる正解ラベル作成が必要となるほか、出現頻度の低いバリア種別のデータを集めるために大量のデータが必要となるため、コストが大きく現実的で無い。そこで本研究では、収集用コースを用意して学習データを収集した。これにより、ラベル付けが容易となり、街中では出現頻度の低いバリアも容易に收拾が可能となる。これは音声系の研究分野で言えば、一般的なコーパスではなく、少量で全ての音素を含むように設計された音素バランスコーパス[4]に該当すると言える。

## 4. 実験

提案法の効果を確認するため、2つの実験を行った。実験の際のコースおよび収集の条件、データの調整について述べた後、2つの実験の概要について述べる。

### 4.1. 収集用コース条件

収集用のコースについては、推定対象のバリアを備えた木製のコースを屋内に用意した(図 4)。コース内に複数のバリアがある場合には、バリアとバリアの間に 2m 以上の十分な間を設けた。点字ブロックは、線状の誘導ブロックを通行方向と垂直向きに設置した。

### 4.2. 収集条件

上記コースを 3 往復いただいたセンサデータに対し、同時に撮影した映像データをもとに人手で正解ラベルを付与した。被験者は 10~70 代の男女 2 名ずつ、計 28 名とした。スマートフォンの位置は、徒歩の場合はズボンや上着のポケットもしくは鞆の中など普段からスマートフォンを持ち歩く場所、自転車の場合はサドル下部、それ以外の移動手段では持ち手の周辺に固定した。推定の際、徒歩におけるスマートフォンの位置は未知であるとした。階段は徒歩およびキャリーケースのみ取得し、通行不可なデータ(車椅子における 16cm 段差、自転車における 8cm 以上の段差)は取得

表 3 センサごとのサンプリング周波数

センサ種別	周波数
加速度	400Hz
ジャイロ	400Hz
重力	200Hz
地磁気	100Hz
気圧	32Hz




図 5 徒歩の加速度(図 1 左上)に回転処理した場合この例では x 軸:前後方向, y 軸:上下方向, z 軸:左右方向である。

しなかった。ベビーカーおよびキャリーケースには 4kg の重り、車椅子には 50kg の重りを設置した。収集には Android8.0 を搭載した Xperia XZ を用いた。用いるセンサのサンプリング周波数は収集可能な最大の値として表 3 の通りとし、400Hz にリサンプリングして FFT をかけた後、20Hz にリサンプリングして利用した(図 3)。結果、のべ 11.6 時間のデータとなった。

### 4.3. データ調整

標準化について、各センサにおいて行った。すなわち、3 軸あるセンサにおいては、3 軸全ての値を用いて平均と分散を算出し、標準化を行った。

端末の方向を統一するため、重力センサを用いて下式(1)を満たす回転角度  $\theta$  および  $\phi$ , すなわち重力方向に対する回転角度を算出し、各センサについて回転処理を行った。

$$\begin{aligned}
 rR_z(\theta)R_y(\phi)\begin{pmatrix} x \\ y \\ z \end{pmatrix} &= r \begin{pmatrix} \cos \theta & -\sin \theta & 0 \\ \sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \cos \phi & 0 & \sin \phi \\ 0 & 1 & 0 \\ -\sin \phi & 0 & \cos \phi \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} \\
 &= r \begin{pmatrix} \cos \theta \cos \phi & -\sin \theta & \cos \theta \sin \phi \\ \sin \theta \cos \phi & \cos \theta & \sin \theta \sin \phi \\ -\sin \phi & 0 & \cos \phi \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} \\
 &= r \begin{pmatrix} x \cos \theta \cos \phi - y \sin \theta + z \cos \theta \sin \phi \\ x \sin \theta \cos \phi + y \cos \theta + z \sin \theta \sin \phi \\ -z \sin \phi + z \cos \phi \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} \quad (1)
 \end{aligned}$$

ここで、 $r$  は係数であり、静止時には重力加速度の逆数とほぼ一致する。 $R_z$  は z 軸方向、 $R_y$  は y 軸方向の回転を表し、 $\theta$  は z 軸方向、 $\phi$  は y 軸方向の回転角度、 $(xyz)^T$  はセンサの x, y, z 軸の値である。結果、垂直方向と進行方向の成分が中心となり、左右方向の成分はほぼ 0 となった(図 5)。

ラベルについては、人手でつけたラベルには誤差があると考えられるため、隣り合ったラベル区間にお

るデータの性質が異なることを利用して自動で修正を行った。具体的には、各ラベルが付与されている区間のセンサデータの平均と標準偏差を算出し、隣接した区間の平均と標準偏差の差の絶対値が最大化されるようにラベルを移動した (式(2))。

$$t_{n_{new}} = t_n + \underset{-s \leq \Delta t \leq s}{\operatorname{argmax}} \left( f(a_{t_{n-1}:t_n+\Delta t}, a_{t_n+\Delta t:t_{n+1}}) + w g(a_{t_{n-1}:t_n+\Delta t}, a_{t_n+\Delta t:t_{n+1}}) \right)$$

$$f(a_1, a_2) = |\operatorname{avg}(a_1) - \operatorname{avg}(a_2)|$$

$$g(a_1, a_2) = |\operatorname{std}(a_1) - \operatorname{std}(a_2)| \quad (2)$$

ここで、 $t_n$  は  $n$  番目のラベルの時刻、 $a_{t_{n-1}:t_n+\Delta t}$  は  $n-1$  番目のラベルの時刻から  $n$  番目のラベルの時刻を  $\Delta t$  ずらした区間のセンサデータを表す。  $s$  はラベルをずらす範囲であり、ここでは 100 ミリ秒とした。  $w$  は重みであり、ここでは 1 とした。  $\operatorname{avg}$  は平均、  $\operatorname{std}$  は標準偏差を表す。

#### 4.4. 実験条件

推定に使う窓幅は 1500 ミリ秒とし、窓は 100 ミリ秒ごとにずらして推定した。エポック数は 20、loss 関数におけるクラスごとの重みは学習データ中の出現頻度の逆数とした。過学習対策のため、L2 正則化を行い、ドロップアウトを全結合層にのみ半数に対して行った。バッチサイズは 512、活性化関数は ReLU とした。Optimizer には Adam を使い、パラメータは hyperopt[20] を用いて最適化した。実装には chainer を用いた。

評価はクロスバリデーションによって行ったが、ランダムに分割するのではなく、1 人のユーザをテストデータ、残りのユーザを学習データとして 28 分割して用いた。評価指標には accuracy, precision, recall, F 値 ( $F_1$ ) を使い、accuracy 以外については、マルチクラスの場合はクラスごとの指標を平均し、指標名に macro という接頭辞をつけて用いる。

#### 4.5. 実験 1: 移動手段推定

実験 1 の目的は、提案法を用いて移動手段の推定が可能かを確かめることである。このために、移動手段のクラスごとに推定精度を求めた。

#### 4.6. 実験 2: バリア推定

実験 2 の目的は、移動手段ごとのモデルとして学習した効果を確認することと、詳細なバリアを推定する上で複数の移動手段を用いた効果を確認することである。このために、移動手段ごとのデータで学習したモデルと、全ての移動手段のデータを一度に学習した単一モデルの精度を比較し、また、移動手段のモデルご

表 4 実験 1(移動手段推定)の結果

太字は移動手段クラスのうち最大値。

クラス	accuracy	precision	recall	$F_1$
徒歩	-	0.935	0.806	0.866
車椅子	-	0.932	0.900	0.915
ベビーカー	-	0.924	<b>0.981</b>	0.952
台車	-	0.896	0.951	0.923
キャリー	-	0.868	0.945	0.905
自転車	-	<b>0.949</b>	0.975	<b>0.962</b>
全体	91.5%	0.917	0.927	0.920

表 5 実験 1(移動手段推定)の混同行列

正解ラベル	予測ラベル						合計
	徒歩	車椅子	ベビーカー	台車	キャリー	自転車	
徒歩	79,948	2,329	4,382	1,295	9,885	1,339	99,178
車椅子	485	61,195	422	5,559	182	177	68,020
ベビーカー	741	95	66,060	25	148	237	67,306
台車	518	1,895	261	59,619	239	130	62,662
キャリー	3,235	134	219	52	70,861	459	74,960
自転車	570	27	121	23	368	43,507	44,616
合計	85,497	65,675	71,465	66,573	81,683	45,849	416,742

とにバリアのクラスごとの推定精度を求め比較した。

### 5. 結果と考察

前章で述べた実験の結果および考察を述べる。

#### 5.1. 実験 1: 移動手段推定

移動手段のクラスごとの精度は表 4 の通りである。移動手段推定の accuracy は 91.5%、 $F_1$  は全体で 0.920 と高い精度で推定できていることがわかる。移動手段のクラス別に  $F_1$  を見ると、特に自転車のクラスにおいて 0.962 と最も高かった。これは、ジャイロに緩やかな波が見られるなど (図 6 上部)、特徴が多くあったために推定精度が高かったと考えられる。

他のクラスでも  $F_1$  は概ね 0.9 を超えているが、徒歩のクラスで 0.866 と最も低いほか、キャリーケースのクラスで 0.905 と次に低かった。それぞれ precision が 0.868, recall が 0.806 と低かったことが影響している。そこで混同行列(表 5)を見ると、徒歩をキャリーケースとする誤りが最も多かったためであることがわかる。これは、徒歩とキャリーケースがともに 1 歩ごとに加速減速を繰り返すため (図 6 中部) に誤りが多かったと考えられる。混同行列において次に多い誤りは、車椅子を台車とする誤りで、これはともに 4 輪でサイズも似ているため (図 6 下部) に誤ったと考えられる。

#### 5.2. 実験 2: バリア推定

単一モデルとの比較と、提案法における移動手段のモデルごとの比較について順に述べる。

##### 5.2.1. 単一モデルとの比較

移動手段ごとのモデルにおけるバリア推定精度は表 6 の通りである。全ての移動手段のデータを一度に学習した単一モデル (以降、単一と記載) では accuracy




図 6 収集データの例(15秒)

上から自転車のジャイロ、キャリーケースの加速度、台車の加速度である。キャリーケースの x 軸に徒歩と似た 1 歩ごとの傾向が見てとれる。

表 6 実験 2(バリア推定)の結果

太字は移動手段別モデルのうち最大値。

モデル	accuracy	macro precision	macro recall	macro $F_1$
単一	79.7%	0.666	0.328	0.381
合計	81.0%	0.619	0.426	0.472
徒歩	60.2%	0.192	0.176	0.171
車椅子	84.2%	0.593	0.353	0.392
ベビーカー	87.7%	0.663	<b>0.606</b>	<b>0.618</b>
台車	80.7%	0.574	0.428	0.461
キャリー	84.6%	0.466	0.287	0.289
自転車	<b>87.8%</b>	<b>0.785</b>	0.406	0.429

は 79.7%,  $F_1$  は 0.381 であったが、移動手段ごとのデータで学習したモデルの結果を合計（以降、合計と記載）すると accuracy は 81.0%,  $F_1$  は 0.472 となっており、移動手段ごとに学習することで、accuracy で +1.3 ポイント、 $F_1$  で +0.09 の改善となった。平坦のクラスの比率が多いために accuracy では大きな向上はないが、 $F_1$  が大きく向上しており、平坦以外のクラスにおいて精度が向上したと考えられる。

これを確認するため、移動手段ごとのモデルにおけるバリアのクラスごとの推定精度（表 7~表 9）を見ると、移動手段ごとに学習することで、階段を除く全てのバリアのクラスで  $F_1$  が向上していることがわかる。precision は微減もしくは同等である一方、recall が向上しており、バリアの出力が増え、バリアの検出力が向上していると考えられる。また、 $F_1$  をバリアのクラスごとにみると、最も向上したのは 8cm の段差で 0.333 から 0.525 と +0.192 向上、次に向上したのは 5% の坂で 0.132 から 0.277 と +0.145 向上した。

表 7 実験 2 バリア別推定精度(指標: precision)

太字は各バリアのクラスにおける最大値。  
ハイフンは通行不可能なバリアを表す。

クラス	単一		合計					
	徒歩	車椅子	ベビーカー	台車	キャリー	自転車		
平坦	0.809	0.848	0.669	0.868	<b>0.929</b>	0.840	0.862	0.906
2cm	0.590	0.429	0.000	0.308	0.346	0.494	0.200	<b>0.879</b>
8cm	0.675	0.678	0.013	<b>0.790</b>	0.653	0.576	0.345	-
16cm	0.730	0.693	0.116	-	<b>0.807</b>	0.683	0.529	-
5%	0.559	0.505	0.174	0.477	0.537	0.423	0.556	<b>0.573</b>
10%	0.548	0.504	0.154	0.512	0.630	0.410	0.000	<b>0.817</b>
階段	0.730	0.637	0.406	-	-	-	<b>0.783</b>	-
点字	0.686	0.655	0.000	0.603	0.737	0.592	0.456	<b>0.750</b>
全体	0.666	0.619	0.192	0.593	0.663	0.574	0.466	0.785

表 8 実験 2 バリア別推定精度(指標: recall)

クラス	単一		合計					
	徒歩	車椅子	ベビーカー	台車	キャリー	自転車		
平坦	0.985	0.962	0.871	<b>0.984</b>	0.978	0.974	0.968	0.979
2cm	0.013	0.051	0.000	0.021	0.086	<b>0.140</b>	0.003	0.039
8cm	0.221	0.429	0.001	0.535	<b>0.654</b>	0.457	0.017	-
16cm	0.408	0.580	0.040	-	<b>0.822</b>	0.669	0.260	-
5%	0.075	0.191	0.023	0.121	0.289	0.119	0.002	<b>0.620</b>
10%	0.140	0.268	0.088	0.393	<b>0.637</b>	0.110	0.000	0.391
階段	0.627	0.704	0.387	-	-	-	<b>0.963</b>	-
点字	0.154	0.219	0.000	0.063	<b>0.777</b>	0.529	0.088	0.003
全体	0.328	0.426	0.176	0.353	0.606	0.428	0.287	0.406

表 9 実験 2 バリア別推定精度(指標:  $F_1$ )

クラス	単一		合計					
	徒歩	車椅子	ベビーカー	台車	キャリー	自転車		
平坦	0.888	0.901	0.757	0.922	<b>0.953</b>	0.902	0.912	0.941
2cm	0.025	0.091	0.000	0.039	0.137	<b>0.219</b>	0.007	0.074
8cm	0.333	0.525	0.002	0.638	<b>0.653</b>	0.510	0.032	-
16cm	0.523	0.632	0.060	-	<b>0.814</b>	0.676	0.348	-
5%	0.132	0.277	0.041	0.193	0.376	0.186	0.003	<b>0.595</b>
10%	0.223	0.350	0.112	0.445	<b>0.634</b>	0.173	0.000	0.529
階段	0.675	0.669	0.397	-	-	-	<b>0.864</b>	-
点字	0.252	0.328	0.000	0.115	<b>0.756</b>	0.559	0.147	0.006
全体	0.381	0.472	0.171	0.392	0.618	0.461	0.289	0.429

ここで、単一における混同行列は表 10 上から 1 つ目、合計における混同行列は表 10 上から 2 つ目である。まず予測ラベルの出力数を比較すると、確かに全てのバリアで出力が増えており、特に段差や坂において 2 倍程度に出力が増えている。次に誤りの傾向を見ると、ともに多くの誤推定がバリアを平坦と誤っているが、これは後述する徒歩の推定における誤りによるものである。その他には、平坦を坂とする誤りや、坂の間での誤りがともに多いことがわかる。しかし、例えば 5% の坂を 10% の坂と誤る間違いは、単一では 5,704 件中 1,351 件で 23.7%, 合計では 12,773 件中 2,210 件で 17.3% となっているなど、段差間や坂間における誤りの比率が減っていることがわかる。これにより、8cm の段差や 5% の段差において精度の向上が大きかったと想定できる。なお、2cm の推定精度が低くなっているが、実用上は 4.4 章にて述べた loss 関数におけるクラスごとの重みを 2cm について手動で大きくする

表 10 実験 2(バリア推定)の混同行列 ハイフンは通行不可能なバリアを表す。

	予測ラベル										合計
	平坦	2cm	8cm	16cm	5%	10%	点字	階段	合計		
一冊	平坦	246,428	9	179	446	257	687	57	2,212	250,275	100,000
	2cm	4,049	62	141	30	142	183	188	58	4,853	10,000
	8cm	4,908	13	1,657	472	69	264	18	94	7,495	1,000
	16cm	3,154	0	333	2,801	1	60	1	522	6,872	100
	5%	18,839	8	55	41	1,672	1,351	40	359	22,365	100
	10%	18,036	1	81	34	838	3,125	11	219	22,345	10
	点字	3,658	12	8	0	14	9	688	66	4,455	0
	階段	5,653	0	0	14	0	25	0	9,567	15,259	0
	合計	304,725	105	2,454	3,838	2,993	5,704	1,003	13,097	333,919	
	合計										
合計	平坦	251,795	91	570	841	1,526	2,679	197	3,930	261,629	100,000
	2cm	3,392	265	300	47	472	382	235	97	5,190	10,000
	8cm	2,840	94	3,209	696	73	415	23	133	7,483	1,000
	16cm	1,772	6	403	3,991	59	91	7	547	6,876	100
	5%	15,248	58	65	59	4,313	2,210	75	596	22,624	100
	10%	14,728	26	164	12	1,934	6,434	30	695	24,023	10
	点字	3,274	77	22	16	146	172	1,075	123	4,905	0
	階段	4,013	0	0	93	19	390	0	10,740	15,255	0
	合計	297,062	617	4,733	5,755	8,542	12,773	1,642	16,861	347,985	
	合計										
徒歩	平坦	30,304	0	59	141	357	1,383	0	2,535	34,779	10,000
	2cm	803	0	4	9	7	68	0	81	972	1,000
	8cm	845	0	1	24	22	93	0	78	1,063	100
	16cm	646	0	14	38	1	36	0	206	941	100
	5%	3,789	0	1	16	109	370	0	429	4,714	10
	10%	4,092	0	0	10	92	448	0	437	5,079	0
	点字	1,098	0	1	13	18	115	0	114	1,359	0
	階段	3,720	0	0	77	19	389	0	2,657	6,862	0
	合計	45,297	0	80	328	625	2,902	0	6,537	55,769	
	合計										
ベビーカー	平坦	45,214	38	123	129	270	379	96	-	46,249	10,000
	2cm	335	80	74	27	195	156	66	-	933	1,000
	8cm	129	31	1,053	345	6	46	0	-	1,610	100
	16cm	179	3	218	2,097	4	47	4	-	2,552	100
	5%	1,829	46	40	1	1,160	913	19	-	4,008	10
	10%	855	23	101	1	498	2,626	16	-	4,120	0
	点字	118	10	4	0	28	2	563	-	725	0
	階段	-	-	-	-	-	-	-	-	0	0
	合計	48,659	231	1,613	2,600	2,161	4,169	764	0	60,197	
	合計										

ことで、2cmの推定精度を高くできる。

### 5.2.2. 移動手段のモデルごとの比較

提案法について移動手段ごとのモデル別に見ていくと、自転車のモデルにおいて macro precision が 0.785 と最も高かったが、macro recall が 0.406 と合計よりも低かったため、macro F1 も 0.429 と合計よりも低い結果となった。ベビーカーのモデルにおいては macro precision が 0.663 と 2 番目に高く、macro recall は 0.606 と最も高かったため、F<sub>1</sub> は 0.618 と最も高かった。これは、ベビーカーが 4 輪であるために坂の角度をそのまま反映し、他の車輪と比べてクッション性が少なく、振動をそのまま伝える性質があったために精度が高かったと想定される。徒歩のモデルにおいては全ての指標において最も低かったが、後述する通り、一部のバリアの推定には有用と考えられる。

バリアのクラス別に F<sub>1</sub> を見ると、それぞれのモデルに得意なバリアや不得意なバリアがあり、複数の移動手段を用いることで詳細なバリアを推定することが可能となっていると言える。例えば、点字ブロックの推定精度が高いのはベビーカーのモデルで 0.756、台車のモデルで 0.559 であり、同じく車輪を持つ移動手段でも車椅子のモデルでは 0.115、自転車のモデルでは

0.006 と精度が低い。これは、クッション性のある車輪を持つ移動手段において精度が低く、クッション性のないもので精度が高いのではないかと想定される。その他、徒歩では小さい段差などは吸収しながら歩くので 2cm や点字では 0.000 と推定は難しい。また、キャリアケースは腕が坂の角度を吸収してしまうため、坂の度合の推定は難しいほか、段差においても、8cm と 16cm とともにキャリアケースを持ち上げる方が多く、段差の大きさの推定は難しい。一方で、階段は徒歩またはキャリアケースのみで通行するため、これらの移動手段によって推定が可能となり、ユーザ数が多いが精度の低い徒歩と、ユーザ数が少ないが精度の高いキャリアケースの組合せによる推定が可能となる。

混同行列について、最も精度の低かった徒歩および最も精度の高かったベビーカーについて考察する。徒歩における混同行列(表 10 上から 3 つ目)を見ると、そもそも坂と階段以外のバリアをほぼ出力できておらず、多くを平坦として出力していることがわかる。ここから、本手法においては徒歩では詳細なバリアを推定することが難しいことが確かめられた。定性的には、坂については加速するように下りる場合に正しく推定できる傾向があった。ベビーカーにおける混同行列(表

10 上から 4 つ目)を見ると, 坂を平坦とする誤りのほか, 坂の間および 8cm 以上の段差の間での誤りが多いことがわかる. 8cm の段差でも大きい動きで乗り越えた場合などに 16cm の段差と誤る傾向があったが, これは, 多くの方のデータが集まることで正しく推定ができると考えられる.

以上のように, 移動手段ごとに通行可能なバリアが異なるほか, 得意なバリアが異なるため, 詳細なバリアを収集する上では, 単独の移動手段よりも, 複数の移動手段を用いて収集する効果が大きかった.

## 6. 結論と今後の展望

本研究では, 様々な移動手段におけるセンサデータを用いて詳細なバリアを検出するため, 移動手段とバリアを 2 段階で推定するモデルを提案した. 実験では 6 クラスの移動手段推定において F 値 0.92 を達成し, 8 クラスのバリア推定においてはベビーカーを用いた場合に F 値 0.62 を達成, 移動手段別に推定を行うことで, 単一モデルで推定する場合と比べて +0.09 ポイント改善. 提案法の効果を示し, 複数移動手段を用いた詳細なバリア推定を実現した.

今後は, バリアフリーマップ生成の効率化に向けた検討のため, バリア推定結果と位置情報に基づき歩道にマッチング[19]した結果と組み合わせる手法や複数人や複数手段の統合方法について検証を行う.

## 参考文献

- [1] Raffaele Gravina, et al.: "Multi-sensor fusion in body sensor networks: State-of-the-art and research challenges". *Information Fusion* 35, pp.68-80, 2017.
- [2] Moustafa Elhamshary, et al.: "CrowdMeter: Congestion Level Estimation in Railway Stations Using Smartphones". *IEEE PerCom*, pp.1-12, 2018.
- [3] 藤井海斗, 澤田宏ほか: "歩行者クラウドセンシングによる路面状態の推定". *DEIM* 2016.
- [4] Vincent Aubanel, Martin Cooke, et al.: "The Sharvard Corpus: A phonemically-balanced Spanish sentence resource for audiology". *International Journal of Audiology*, 53(9), pp.1-6, 2014.
- [5] 佐藤匠, 東野輝夫ほか: "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*, pp.258-265, 2014.
- [6] Amir Adler, Michael Zibulevsky, et al.: "Compressed Learning: A Deep Neural Network Approach". *arXiv preprint arXiv:1610.09615*, 2016.
- [7] 宮田章裕, 篠崎涼太ほか: "健常歩行者センサデータからのバリア検出のための屋内外別機械学習方式". *情報処理学会論文誌* 59(9), pp.1774-1782, 2018.
- [8] Francisco Javier Ordonez, et al.: "Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition". *Sensors* 16(1) 115, 2016.
- [9] Yiping Kang, et al.: "Neurosurgeon: Collaborative intelligence between the cloud and mobile edge." *ACM SIGPLAN Notices* 52.4, pp.615-629, 2017.
- [10] 蔵内雄貴, 瀬下仁志ほか: "ニューラル特徴抽出による省通信センサフュージョン". *DICOMO*, pp.1500-1506, 2018.
- [11] 国土交通省: "歩行空間ネットワークデータ整備仕様案 (2018 年 3 月版)". [http://www.mlit.go.jp/sogoseisaku/soukou/seisakutokatsu\\_soukou\\_tk\\_000026.html](http://www.mlit.go.jp/sogoseisaku/soukou/seisakutokatsu_soukou_tk_000026.html), (accessed 2019-1-10).
- [12] Qiarnu Wang, et al.: "CrowdNavi: Last-mile Outdoor Navigation for Pedestrians Using Mobile Crowdsensing". *ACM HCI*, Vol. 2, pp. 1-23, 2018.
- [13] 山本千尋, 川野辺彰久ほか: "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*, pp.21-24, 2016.
- [14] Kenichi Arai, Noboru Sonohara.: "On-demand barrier-free street view system using sensor information from general-purpose wheelchair users". *IEEE COMPSAC*, Vol. 2, pp. 348-353, 2017.
- [15] 宮田章裕, 水野理ほか: "直近移動能力を考慮した車椅子操作推定モデル". *情報処理学会論文誌*, Vol. 57, No. 10, pp.2316-2326, 2016.
- [16] Young Jin Cha, Oral Buyukozturk, et al.: "Deep learning-based crack damage detection using convolutional neural networks". *Computer-Aided Civil and Infrastructure Engineering*, 32(5), pp.361-378, 2017.
- [17] Yuki Endo, Akihisa Kawanobe, et al.: "Deep Feature Extraction from Trajectories for Transportation Mode Estimation". *PAKDD*, Vol. 9652, pp.54-66, 2016.
- [18] Oana Lorintiu, Andrea Vassilev.: "Transportation mode recognition based on smartphone embedded sensors for carbon footprint estimation". *IEEE ITSC*, 2016.
- [19] 阿部裕文, 瀬下仁志ほか: "アーバンキャニオン下における歩行者の歩行通路判定法". *映像情報メディア学会 冬季大会*, 2018.
- [20] GitHub. <https://github.com/hyperopt/hyperopt>, (accessed 2019-1-10)
- [21] Akihiro Miyata, Tongshun Wang, et al.: "Barrier Detection using Sensor Data from Unimpaired Pedestrians". *HCI*, Vol.10908, pp.308-319, 2018.
- [22] Jian Bo Yang, Shonali Krishnaswamy, et al.: "Deep Convolutional Neural Networks On Multichannel Time Series For Human Activity Recognition". *IJICAI*, pp. 3995-4001, 2015.
- [23] Jakob Eriksson, Hari Balakrishnan, et al.: "The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring". *MobiSys*, pp. 29-39, 2008.
- [24] Takahiro Miura, Asuka Kano, et al.: "Barrier-free walk: a social sharing platform of barrier-free information for sensory/physically-impaired and aged people," *IEEE SMC*, pp. 2927-2932, 2012.
- [25] Kotaro Hara, Vicki Le, and Jon Froehlich.: "Combining crowdsourcing and google street view to identify street-level accessibility problems," *ACM CHI*, pp. 631-640, 2013.
- [26] Shubham Jain, Carla-Fabiana Chiasserini, et al.: "Lookup: enabling pedestrian safety services via shoe sensing," *ACM Mobisys*, pp. 257-271, 2015.
- [27] Hiroki Taniue, Swagat Kumar, et al.: "Development of automatic barrier detection system for wheelchair," *IEEE GCCE*, pp. 374-376, 2015.