

屋内外を区別した機械学習による  
健常歩行者センサデータからの  
バリア検出方式

平成29年度 卒業論文

日本大学 文理学部 情報科学科 宮田研究室

王 統順

# 概要

屋内外には段差・階段などのバリアが多数存在し、障害者や高齢者の外出を不安にさせることを加え、彼ら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、彼らの移動計画が立てやすくなり、外出しやすいと考えられる。この問題に鑑みて、バリアを通過する人の挙動を分析してバリア検出を行おうとする研究が盛んに行われている。しかし、屋内と屋外ではバリアの形状・素材や通過する人の挙動が異なるにも関わらず、これを従来研究は考慮しておらず、このことがバリア推定精度に悪影響を与えている可能性がある。そこで、本研究では、屋内外を区別してバリア検出を行う方式を提案する。この方式では、教師なし学習部分と教師あり学習部分のそれぞれにおいて屋内外データを区別して機械学習を行う。機械学習において、人手で設計した特徴量と Deep Learning で設計した特徴量を両方利用した。検証実験により、人手で設計した特徴量を用いた場合、屋内外を区別することでバリア検出精度が有意に向上することが明らかになった。

# 目次

<b>第1章</b>	<b>序論</b>	<b>1</b>
1.1	研究の背景	2
1.2	研究の目的	2
1.3	本論文の構成	2
<b>第2章</b>	<b>関連研究</b>	<b>4</b>
2.1	人間が判断を行うアプローチ	5
2.1.1	人間が現地に赴き判断するアプローチ	5
2.1.2	人間が遠隔地から判断するアプローチ	6
2.2	センサデータから判断するアプローチ	6
2.2.1	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	6
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	6
2.3	屋内外位置情報推定	7
2.4	屋内外路面素材	8
<b>第3章</b>	<b>研究課題</b>	<b>9</b>
3.1	問題の定義	10
3.2	研究課題の設定	13
<b>第4章</b>	<b>提案方式</b>	<b>14</b>
4.1	推定対象のバリア	15
4.2	特徴量を抽出する方式	15
4.2.1	人手で設計した特徴量を機械学習する方式	16
4.2.2	Deep Learning で設計した特徴量を機械学習する方式	16
4.3	屋内外を区別したバリア推定方式の提案	17
4.3.1	ベースとなる従来方式	17
4.3.2	提案方式	18
<b>第5章</b>	<b>歩行データの計測装置の実装</b>	<b>21</b>
5.1	教師ありデータ計測デバイスの実装	22
5.2	教師なしデータ計測アプリケーションの実装	22

---

<b>第 6 章 検証実験</b>	<b>24</b>
6.1 検証実験 1 . . . . .	25
6.1.1 実験の目的 . . . . .	25
6.1.2 データセット . . . . .	25
6.1.3 実験の手順 . . . . .	26
6.1.4 ベースライン方式 . . . . .	26
6.1.5 提案方式 . . . . .	27
6.1.6 実験結果・考察 . . . . .	27
6.2 検証実験 2 . . . . .	29
6.2.1 実験の目的 . . . . .	29
6.2.2 データセット . . . . .	30
6.2.3 実験の手順 . . . . .	31
6.2.4 ベースライン方式 . . . . .	31
6.2.5 提案方式 . . . . .	32
6.2.6 実験結果・考察 . . . . .	32
<b>第 7 章 結論</b>	<b>38</b>
参考文献	40
研究業績	44

# 目 次

3.1	典型的な階段 (左:屋内, 右:屋外) . . . . .	10
3.2	男性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り) . . . . .	11
3.3	男性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り) . . . . .	11
3.4	男性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り) . . . . .	12
3.5	女性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り) . . . . .	12
4.1	入力層が 3 要素に分離した DAE . . . . .	17
4.2	従来方式の学習フェーズ . . . . .	18
4.3	従来方式の推定フェーズ . . . . .	18
4.4	提案方式の学習フェーズ . . . . .	19
4.5	提案方式の推定フェーズ . . . . .	20
5.1	加速度計測デバイス . . . . .	22
5.2	iOS 加速度計測アプリケーション . . . . .	23
5.3	Android 加速度計測アプリケーション . . . . .	23
6.1	計測デバイスを制御するアプリケーション . . . . .	26
6.2	HCF_IN/HCF_MIX 方式の推定精度 (F 値, N = 100) . . . . .	28
6.3	HCF_OUT/HCF_MIX 方式の推定精度 (F 値, N = 100) . . . . .	28
6.4	HCF_IN の混同行列 . . . . .	29
6.5	HCF_OUT の混同行列 . . . . .	30
6.6	HCF_MIX の混同行列 . . . . .	31
6.7	DAF_IN/DAF_MIX 方式の推定精度 (F 値, N = 100) . . . . .	33
6.8	DAF_OUT/DAF_MIX 方式の推定精度 (F 値, N = 100) . . . . .	33
6.9	DAF_IN の混同行列 . . . . .	34
6.10	DAF_MIX (屋内教師ありデータ) の混同行列 . . . . .	35
6.11	DAF_OUT の混同行列 . . . . .	36
6.12	DAF_MIX (屋外教師ありデータ) の混同行列 . . . . .	37

# 表 目 次

3.1 主な床面・路面素材 . . . . .	11
6.1 計測対象 . . . . .	25

# 第1章 序論

## 1.1 研究の背景

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。

## 1.2 研究の目的

従来研究では健常者の歩行時に発生するセンサデータを分析するアプローチを用い、より広域のバリア情報を収集できる。このアプローチは健常者の移動はほとんど妨げないが、障害者の移動を妨げる一段の段差、階段も推定できる。しかし、屋内と屋外ではバリアの形状・素材や通過する人の挙動が異なるにも関わらず、これを従来研究は考慮しておらず、このことがバリア推定精度に悪影響を与えている可能性がある。例えば、屋外路面舗装は、アスファルト系の表層を持つ舗装(アスファルト舗装)とコンクリート版を表層に持つ舗装(コンクリート舗装)と分けられる。屋内路面舗装は、ビニル床シート、ビニル床タイル、ゴム床タイル張り、カーペット床、合成樹脂塗床、フローリング張りなど多く使われている。したがって、本研究では、屋内外を区別してバリア検出を行う方式を提案し、バリア検出精度に与える影響を明らかにすることを目的とする。

## 1.3 本論文の構成

本論文の構成は次のとおりである。

2章では、人間が判断を行うアプローチの研究事例、センサデータから自動判断を行うアプローチの研究事例、屋内外位置情報推定の研究事例、屋内外路面素材について紹介します。

3章では、2章で述べた研究事例の問題点を述べ、屋内外でバリアを通過する加速度データが異なることを明らかにし、そこから、本研究の研究課題を設定する。

4章では、本研究の推定対象バリアを述べ、特徴量を抽出する方式を紹介し、従来のバリア方式と本研究の提案方式を述べる。

5章では、教師ありデータを計測するデバイスと教師なしデータを計測するデバイスを述べる。

6章では、実験の目的、データセット、実験の手順、ベースライン方式、提案方式を述べ、得られた実験結果から考察を述べる。

最後に7章にて，本論文の結論を述べる．

## 第2章 関連研究

本章では、バリアフリーに関する研究事例について述べる。現在世界でバリアフリーに向けた取り組みは数多く行われている。

聴覚障害者を助けるための研究として [1][2] がある。[3] は音を使ってバリアフリーを目指しており、音によってバリアフリーを目指すものを音バリアフリーという。音バリアフリーの研究で [4] は音声によって、体の不自由な機能の補償をしようとしている。次に視覚障害者や弱視者を助けるための研究として [5][6] がある。視覚障害者向けの研究で [7] は視覚障害者でもパソコンを使えるように、音だけで操作できる研究をしている。日常生活で、視覚障害者を助けるものとして触覚的に気が付けるものがある。足の触覚で視覚障害者を助ける点字ブロックや、指の触覚で視覚障害者を助ける [8] の牛乳パックの切吹きなどがある。また、聴覚障害者と視覚障害者を助けるための研究の [9] は、バリアフリー放送サービスのための感覚効果メタデータのオーサリング、伝送、及び表現方法を提案している。

上述のバリアフリーの実現も重要であるが、我々は移動におけるバリアフリーを重視している。これは、高齢者や車椅子の人などの移動弱者を助けるに加え、健常者でも移動することが難しい路面や通路を減らすために研究が行われている。日常生活で、路面や通路のバリアフリー化されているものは、段差の解消や手すりの設置などがある。路面や通路のバリアフリーを目指す研究は、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。2.1 節では、人間が判断を行うアプローチについて紹介する。2.2 節では、センサデータから自動判断するアプローチについて紹介する。2.3 節では、近年スマートフォンの普及とともに発展している、屋内外位置推定技術に関する研究事例について紹介する。2.4 節では、日本の屋内外での床の材質の違いを、国交省の公共建築工事標準仕様書をもとに紹介する。

## 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、行政スタッフや車椅子利用者、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。[10] は、国交省主導で行われているバリア情報収集の取り組みである。[11] は、車椅子利用者向けのバリア情報をユーザがインターネット上に投稿できるサービスである。[12] は、[11] と同様な仕組みを提案しているが、対象を車椅子利用者だけでなく視聴覚障害者にも広げている点、投稿されたバリア情報を他のユーザが評価できる点が異なる。[13] 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、これを利用した路面バリアのクラウドセンシングシステム MaPiece[14] 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 [15][16][17] 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自動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。[18] 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。一方、[19][20][21][22][23] は、車椅子に装着したセンサデータに基づいて主に歩道の路面状態を評価する試みである。この手法を応用し、加速度・角速度センサを装着した車椅子で市街地を移動することで、バリアがある場所を発見しようとする試みも盛んである。[24] は、加速度データを SVM で分析することで段差・傾斜の有無を推定している。[25] は、加速度変化から車椅子の角度を計算し、これに基づいて段差・傾斜の有無と大きさを推定している。[26] は、加速度データを k 近傍法で分析して平坦・傾斜などの路面状態を推定している。[27] は、アルゴリズムの詳細を明らかにしていないが、加速度変化から路面の凹凸を検出するアプリケーションの開発を目指している。[28] は、車椅子の移動の様子がユーザごとに異なることに着目し、ユーザごとに適切なモデルを選択した上で加速度データを Deep Learning で分析することで、段差・傾斜に加え、引き返しが生じる場所などの検出にも試みている。[29] は、加速度データに加え、心拍データも分析対象とすることで、車道が近くて緊張するなどの心理的なバリアの検出を試みている。[30] 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。[31] 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。[32] 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。[33]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、[34]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、鞆に入れた状態、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。[35]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、路面が平坦か凸凹かを推定している。[36]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, 鞆)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。我々もこれまでに、健常者の歩行時の加速度データを計測し、その加速度データで機械学習を行い、バリア検出[37][38][39][40][41]を行なっている。[40]は、複数人の健常者の歩行時加速度データを計測し、そのデータで機械学習を行い、1人と複数人の場合のバリア検出精度の差を調べている。[41]は、健常者の歩行時加速度データを計測する場所を屋内外で分け、そのデータでそれぞれ機械学習を行い、バリア検出精度を調べている。

## 2.3 屋内外位置情報推定

スマートフォンに搭載されているセンサを用いて、ユーザの現在位置が屋内であるか屋外であるか判定する技術、あるいは、屋内外を通じて位置推定をする技術が数多く行われている。

IODetector[42]は、スマートフォンで計測する照度、通信基地局からの電波強度、地磁気を複合的に分析し、ユーザの現在位置が屋内であるか、屋外であるかを高精度に判定している。彼らは、HMM (Hidden Markov Model) を用いて屋外・半屋外・屋内の状態遷移を考慮することで、屋内外判定の精度を向上させる工夫も行っている。[43][44]は、スマートフォン上のGPSセンサの受信状況を分析し、屋内と屋外では受信状況が変化することを利用して、ユーザ位置の屋内外を判定している。TLIFES[45]は、スマートフォンのセンサ類(加速度センサ, GPSなど)を利用して常にTLIFES利用者の位置や行動を把握する。彼らはTLIFESにおいて位置測位を省エネルギーで行うための屋内外判定手法を検討した。また、Dead Reckoningを用いてTLIFES利用者の歩行した軌跡を推定することにより、屋内から屋外に移動したことの判定も検討した。[46]は、GPSとBluetoothを用い、同一アプリケーションで操作なしに屋内外の位置をシームレスに検出することが可能である。[47]は、モバイル端末が搭載するGPSと各種センサ情報を利用し、端末が屋内・屋外のどちらに存在するかを判定する。[48]は、3次元距離センサを用いて3次元

距離データを計測し、レーザ信号の受光強度が測定できるセンサを用い、輝度情報付き多次元正規分布の集合を作成する。作成した輝度情報付き多次元正規分布の集合と3次元距離計測データと組み合わせて屋内外の位置推定を行う。

## 2.4 屋内外路面素材

屋内外路面を設計する際、屋外と屋内路面で果たす機能が異なる。

屋外路面舗装 [49] の果たす機能としては、以下のことが挙げられる。

- 路面に緻密な層を設けることにより、雨天時の路面の泥濘化や乾燥時の砂塵を防止し、快適性を保持すること。
- 路面の平坦性を良好にするとともに適度の滑り抵抗性を持たせることにより、車両通行時や歩行時の快適性や安全性を向上させること。
- 周辺の環境に適合した舗装材料を使用することにより、良好な路面景観や沿道環境を創出すること。

この機能を実験するため、屋外路面舗装は、アスファルト系の表層を持つ舗装（アスファルト舗装）とコンクリート版を表層に持つ舗装（コンクリート舗装）と分けられる。日本においては昭和30年代以降自動車の増大、石油産業の進展に伴って舗装のうち、アスファルト系の舗装の路面舗装に占める割合は、90%を超える比率となっている。

一方、屋内路面舗装 [50] の果たす機能としては、以下のことが挙げられる。

- 床の平坦性を良好にするとともに粗面または滑りにくい材料にすることにより、高齢者、障害者などが移動する時、転倒を防止すること。
- 衝撃の少ない材料で仕上げることにより、高齢者、障害者などが転倒しても、負傷程度を最小限に抑えること。

この機能を実現するため、屋内路面舗装は、ビニル床シート、ビニル床タイル、ゴム床タイル張り、カーペット床、合成樹脂塗床、フローリング張りなど多く使われている。

## 第3章 研究課題

### 3.1 問題の定義

2.1.1 項の人間が現地に赴き判断するアプローチは、直接現地を見て判断することができるのでバリア情報の正確性は高いと考えられるが、現地に赴かなければいけないため人的コストが高い。日々新しい場所や道路ができる現在の日本では、新しくなるたびにその場所を訪れなければいけないため、広域のバリア情報を集めるには不向きである。

2.1.2 項の人間が遠隔地から判断するアプローチは、直接現地に行かなくてもいいので、2.1.1 項の人間が現地に赴き判断するアプローチより広域のバリア情報を集めることができるが、画像の解像度・オクルージョンの問題から、小さな段差や目には見えないバリアなどがあるため、実際に現地に赴き判断することに比べるとバリア情報の正確性は低いと考えられる。

2.2.1 項の車両移動時のセンサデータから判断するアプローチは、車椅子を用いた研究が多い。車椅子では地面の状態の影響を受けやすいので正確なバリア情報を得ることができると考えられるが、狭い場所のバリア情報を集めることができず、階段や少し大きな段差や急坂といったバリア情報を集めるのには不向きである。また、車椅子利用者の数は健常者と比べると少ないので多くのデータを集めることは難しい。以上のことから車両移動時のセンサデータから判断するアプローチは広域におけるバリア情報の収集が困難である。

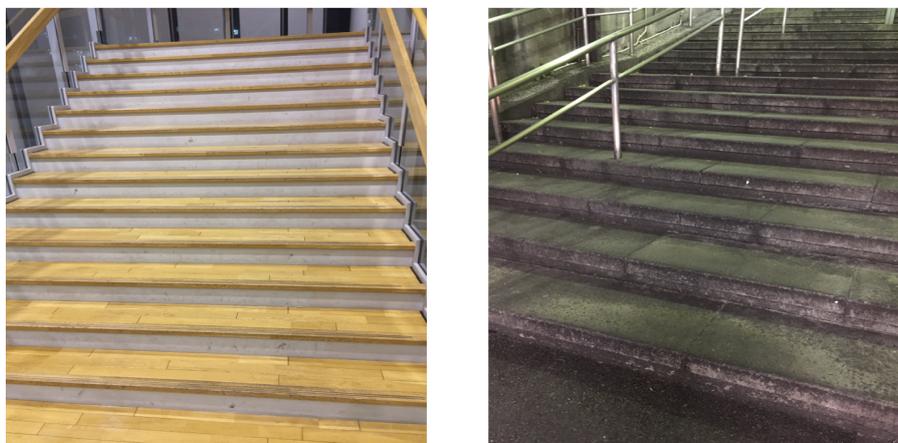


図 3.1: 典型的な階段 (左:屋内, 右:屋外)

2.2.2 項の歩行時のセンサデータから自動判断するアプローチは、健常者の数は車椅子利用者と比べると多いことに加え、車椅子が入ることのできない狭い道などのバリア情報も集めることができる。また、車椅子では判断することが難しい階段や少し大きな段差や急坂といったバリア情報も健常者であれば集めることができる。よって、本研究では、健常者歩行時に生じるセンサデータからバリアの存在・種別を推定する方法を利用する。

2.4 節の屋内外路面素材は、屋外と屋内路面で果たす機能が異なるため、同じ種別のバリアであっても、屋内外で形状・素材に違いがあることに気付く。例えば、図 3.1 に示す

のは、屋内と屋外の典型的な階段である。屋内の階段は建築基準法などにより寸法の範囲が規定され、1段の高さは18cm前後、1段の奥行きは26cm前後であることが多い。一方、建築物とは独立した屋外の階段については、管轄者・地区により基準に幅があるが、1段の高さ・奥行きともに屋内のものより大きい傾向にある。また、表3.1のとおり屋内と屋外では床面・路面（階段を含む）の素材は異なる[49][50]。

表 3.1: 主な床面・路面素材

屋内床面	屋外路面
ビニル, ゴム, 合成樹脂, 木材, 絨毯	アスファルト コンクリート, 石材

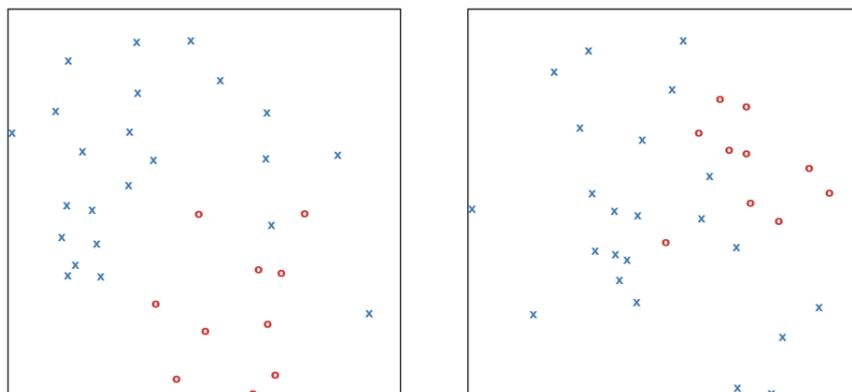


図 3.2: 男性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り)

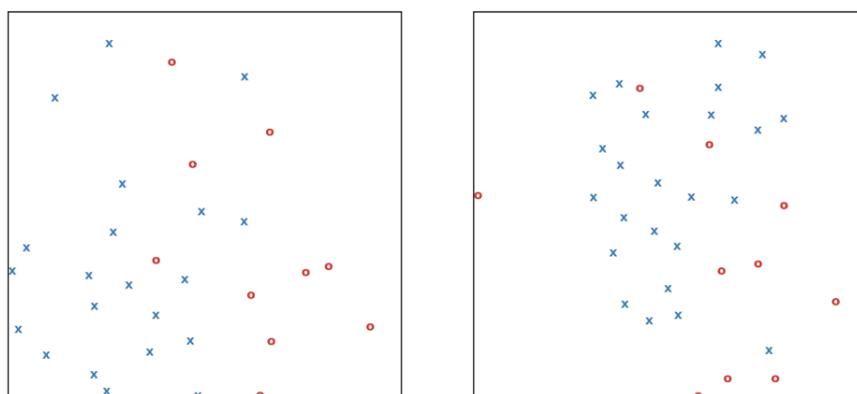


図 3.3: 男性の階段歩行時の加速度の特徴 (左:階段上り, 右:階段下り)

屋内外でバリアの形状・素材に差があることは、バリア通過時の歩行者の挙動に少なからず影響を与えらると思われる。図3.2～3.5に示すのは健常歩行者が階段を通行した際に生じた加速度の特徴を2次元空間で表現したものである。図3.2～3.4は男性、図3.5は女性の健常歩行者によるものである。各プロットは、屋内外それぞれ数種類ずつの階段を3秒間通行した際に生じた加速度データ(計測方法は5.1節参照)から抽出した33次元の特徴量(5.2節参照)をMulti Dimensional Scalingにより2次元に削減したものであり、似たものは近く、異なったものは遠くに配置される。○印のプロットが屋内階段、×印のプロットが屋外階段のものである。

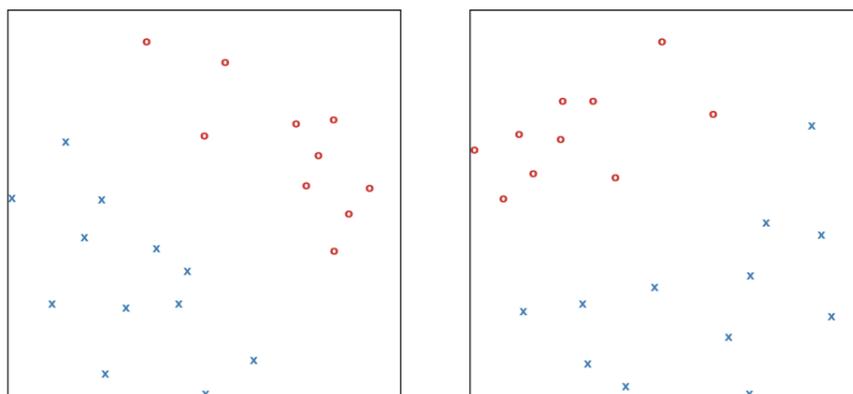


図 3.4: 男性の階段歩行時の加速度の特徴(左:階段上り, 右:階段下り)

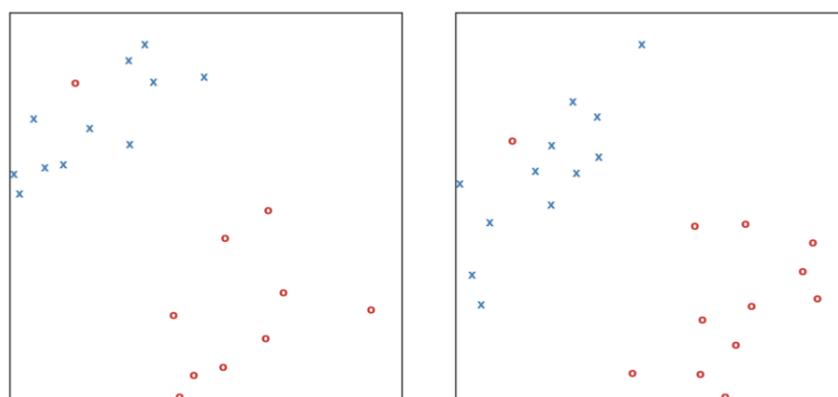


図 3.5: 女性の階段歩行時の加速度の特徴(左:階段上り, 右:階段下り)

図3.2と図3.3を見ると、2次元空間中の境界線は多少曖昧ではあるが、屋内データ同士はより近く、屋外データ同士はより近く配置されていることがわかる。また、図3.4と図3.5では屋内データと屋外データの境界は明確である。これは、屋内外の差が、歩行者の挙動に影響を与えたことを示唆している。

しかし、屋内外ではバリア形状・素材や歩行者挙動に差があるにも関わらず、これを従来方式は考慮していない。[37][38][39][40]は、健常者の歩行時加速度データからバリアの存在・種別を推定する方式を提案していたが、屋内外を区別しないアルゴリズムとなっている。

このように、屋内外の差を区別しないことは、これらの方式の推定精度に悪影響を与えている可能性がある。[41]は、複数人健常歩行者の歩行時の加速度データから、人手で設計した特徴量（平均値・標準偏差・相関係数・スペクトル強度）を機械学習する方式を用いた。屋内歩行時加速度データのみから学習を行った推定器を屋内専用推定器、屋外歩行時加速度データのみから学習を行った推定器を屋外専用推定器、屋内外歩行時加速度データから学習を行った推定器を屋内外推定器と称した。屋内外を区別した歩行データから構築した屋内専用の推定器・屋外専用の推定器を用いると、屋内外を区別せずに歩行データから構築した屋内外推定器より高精度にバリア推定を行えることを明らかにしたが、同じバリアであっても屋内外の歩行時加速度が異なるか、検証が行われていない。また、屋内外を区別することがバリア検出精度に与える影響を明らかにしていなかった。[37][38][39]で高精度だった特徴量抽出の設計方法を使用していないので、特徴量抽出の設計方法を変更した場合バリア検出精度を向上させることができると考えられる。

## 3.2 研究課題の設定

屋内外でバリアの形状・素材に差があることは、バリア通過時の歩行者の挙動に少なからず影響を与えられると思われる。そこで、本研究では、健常者の歩行時加速度データからバリアの存在・種別を推定するタスクにおいて、下記を研究課題として設定する。

課題1：屋内外を区別することがバリア検出精度に与える影響を明らかにする

課題2：高精度・実用的に屋内外のバリアの存在・種別を推定する方式を提言する

なお、2.3節に示したように、現在位置の屋内外を判定する技術は国内外で数多くの研究事例があり、実用的な市中製品も登場しつつある。このため、加速度計測位置の屋内外判定は既存技術の利用を想定するものとし、本研究の対象範囲外とする。

## 第4章 提案方式

## 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、屋内と屋外どちらにも存在する階段と坂があり、これらは屋内外による傾きや地面の素材などの特徴が異なるかどうか、検討する価値があるため、推定対象とする。階段に類するものとして、1段の段差がある。このような段差を超える際、健常者は、段差があることに気がついていれば、あまり気にせず乗り越えることができるが、障害者や高齢者は段差1つでも大きなバリアであると考えられる。上りの段差であれば、障害者や高齢者は足が上りきらずに段差に足を引っ掛けてしまい転倒してしまうことがある。下りの段差であれば、段差があることに気がつかずに転倒してしまうことがある。健常者であっても、段差を見落とし転倒してしまうことがある。健常者であれば受け身をとることで大きな怪我を回避することができるが、障害者や高齢者だと、受け身をとることができずに大きな怪我に繋がり、最悪死に至ることもあるため推定すべきだと考えられる。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）が屋内外にある。一方、健常者でも自転車でするのは難しいような急坂（勾配10度程度）は屋外に存在する（屋内にはほとんど無い）。

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、屋外に多く存在する石畳は、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。

屋内に多く存在す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、うまく開閉できる障害者は少なくない。車椅子や松葉杖を繰り返しながら開けることは容易ではない。

しかし、屋内外のバリアごとを比較する際、屋内外のバリアの種類を統一する必要があるため、屋内または屋外のどちらか一方にはほとんど存在しない急坂・石畳・ドアを推定対象外とする。

以上をまとめると、本稿で推定対象とする屋内外共通のバリアは次のとおりである。

屋内外に共通するバリア

- 階段
- 1段の段差
- 緩い坂（勾配3度程度）

## 4.2 特徴量を抽出する方式

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全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。以降、加速度センサデータを機械学習するための方式を2つ示す。

### 4.2.1 人手で設計した特徴量を機械学習する方式

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 [32][33][34][35][36]. 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.

### 4.2.2 Deep Learning で設計した特徴量を機械学習する方式

2010 年前後から, 画像処理, 自然言語処理などの各技術分野において, Deep Learning (深層学習, 特徴表現学習) による機械学習の性能が, HCF 方式のそれを凌駕する事例が数多く報告されてきた. また, [37][38][39] の研究により, 加速度データを用いたバリア推定においても Deep Learning が有効であることがわかっている. そこで, 本研究では, Deep Learning の利用を検討する. 具体的には, 汎用的な特徴量抽出に利用可能な Denoising Autoencoder (以降 DAE) を用いた機械学習を行うこととし, 以降これを DAF 方式と称する. 加速度センサデータは x, y, z の直交する 3 次元データであるため, マルチモーダルな Deep Learning のネットワークを構築しているなどの研究事例を参考にして, 図 4.1 のような入力層が 3 要素に分離したネットワークを構築する. これは教師あり学習 (Fine-tuning) を行う際に用いる特徴量を自動抽出するために教師なし学習 (Pre-training) を行うネットワークであり,  $L_1$  から  $L_4$  までの 4 層からなる. なお, 図中の各層に記載した数字は検証実験実施時の次元数である.

$L_1$  : x, y, z 軸の加速度センサデータを入力する, 3 要素に独立した層である.

$L_2$  :  $L_1$  に DAE を適用してそれぞれ次元削減した層であり, この過程で  $L_1$  の各要素を次元削減するためのエンコーダ  $E_{1,x}$ ,  $E_{1,y}$ ,  $E_{1,z}$  を得る.

$L_3$  :  $L_2$  の各要素を連結した層である.

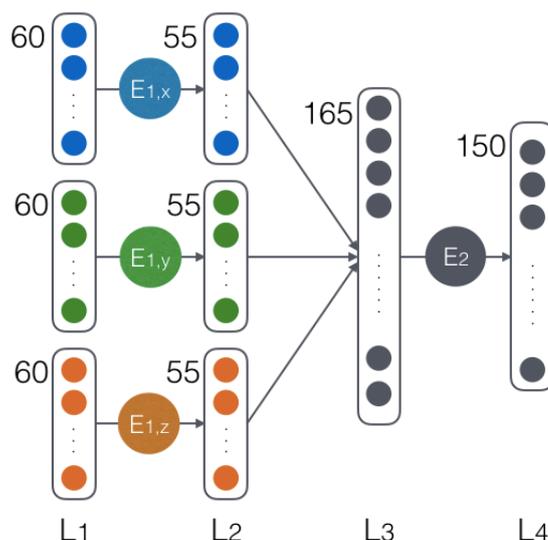


図 4.1: 入力層が 3 要素に分離した DAE

$L_4 : L_3$  に DAE を適用して次元削減した層であり、この過程で  $L_3$  を次元削減するためのエンコーダ  $E_2$  を得る。

Fine-tuning 実施時には、上記で獲得した  $E_{1,x}$ ,  $E_{1,y}$ ,  $E_{1,z}$ ,  $E_2$  を用いて加速度センサーデータを次元圧縮し、それらを特徴量として機械学習する。

### 4.3 屋内外を区別したバリア推定方式の提案

#### 4.3.1 ベースとなる従来方式

屋内外を区別してバリアの存在・種別を推定する方式を提案するにあたり、まずベースとなる従来方式について説明する。以降登場する教師なしデータとは、教師ラベルが付与されていない固定長の歩行時加速度データである。教師ありデータとは、教師ラベル(例: 段差上り, 階段下り)が付与された固定長の歩行時加速度データである。

図 4.2 に示すのは、屋内外を区別しない機械学習によりバリア推定を行う従来方式 [37][38][39][40][41] の学習フェーズである。

学習フェーズは教師なし学習 (図 3 上半分) と教師あり学習 (図 3 下半分) からなる。教師なし学習では、教師なしデータ (Unlabeled Data) を Deep Learning の一種である Denoising Autoencoder (DAE) [51] で分析することで、高次元の生データを低次元に圧縮するためのエンコーダ (Encoder) を獲得する。教師あり学習では、教師ありデータ (Labeled Data) をエンコーダで次元削減したもの (Labeled Feature) を元データの特徴量とみなし、Support Vector Machines (SVM) を用いて教師ラベルとデータ特徴量の関係を表現するモデル (Model) を構築する。

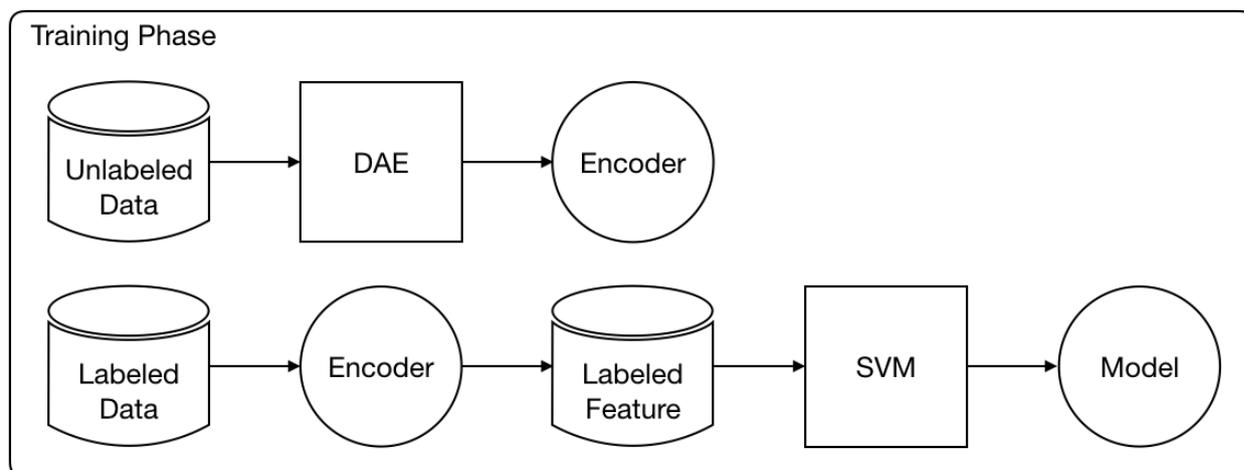


図 4.2: 従来方式の学習フェーズ

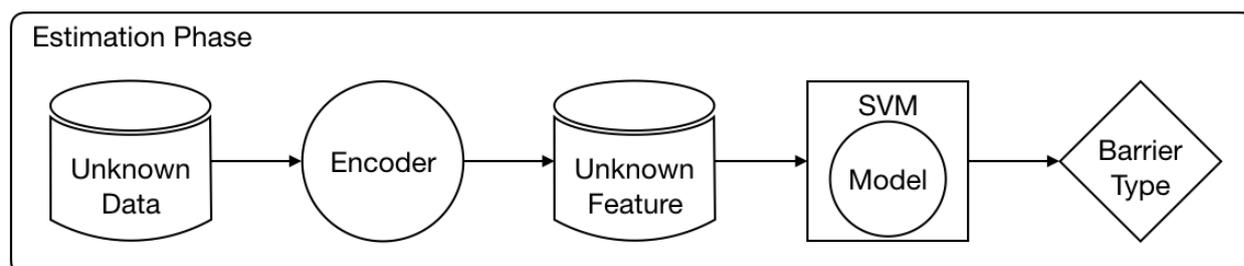


図 4.3: 従来方式の推定フェーズ

図 4.3 に示すのは、従来方式の推定フェーズである。推定フェーズでは、ラベルが未知のデータ (Unknown Data) をエンコーダで次元削減したもの (Unknown Feature) を、学習フェーズで構築したモデルに基づいて SVM で分析することで、未知のデータのラベル (Barrier Type) を推定する。

なお、ここでは従来方式について説明したが、2.2.2 項の既存技術も、特徴量抽出手法や教師あり学習が異なるだけで、屋内外を区別していないという点では同じである。

### 4.3.2 提案方式

3.1 節により、屋内外でバリアの形状・素材に差があることが分かった。したがって、バリア通過時の歩行者の挙動に少なからず影響を与えられられるため、同じ種類のバリア (階段・段差など) を通過したとしても、屋内と屋外で計測した加速度データに差が出ると考えられる。このため、モデルを構築する際、屋内と屋外を混在した加速度データを

使ってしまうと、正しいモデルが構築できず、推定精度に影響を与える可能性がある。

そこで、4.3.1 項の従来方式を改良し、バリア推定位置の屋内外に応じてモデルを使い分ける方式を提案する。以降、屋内 / 屋外で計測したデータという表現を用いるが、3.2 節で述べたとおり、歩行時加速度データの計測位置の屋内外は既存技術で判定するものとし、屋内外の別は加速度データにメタデータとして付与されているものとする。

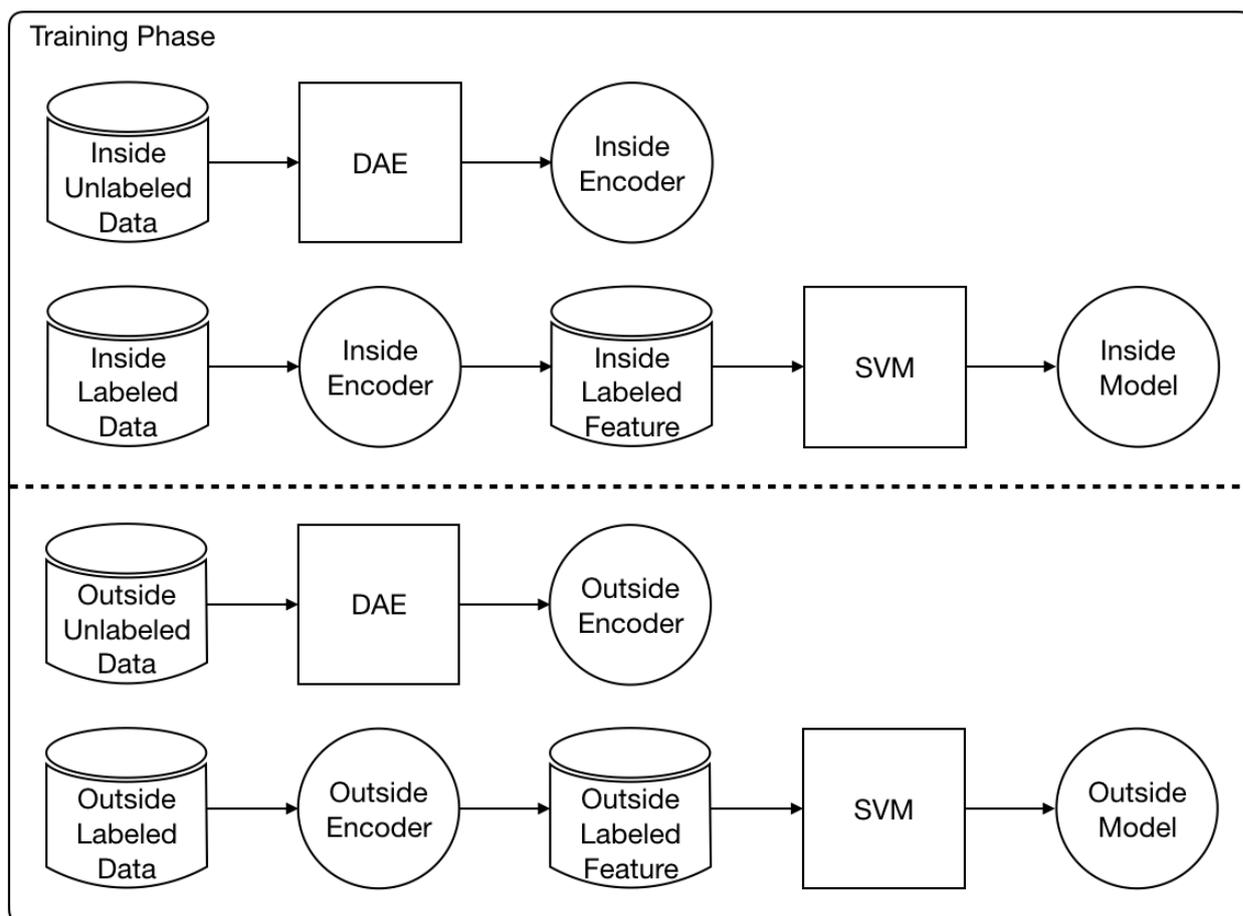


図 4.4: 提案方式の学習フェーズ

図 4.4 は提案方式の学習フェーズである。点線の上側は、屋内のバリア推定を行うモデル (以降、屋内モデル) を構築する処理である。教師なし学習では、屋内で計測した教師なしデータ (Inside Unlabeled Data) を DAE で分析し、屋内エンコーダ (Inside Encoder) を獲得する。教師あり学習では、屋内で計測した教師ありデータ (Inside Labeled Data) を屋内エンコーダで次元削減したもの (Inside Labeled Feature) を SVM で分析して、屋内における教師ラベルとデータ特徴量の関係を表現する屋内モデル (Inside Model) を構築する。点線の下側は、屋外のバリア推定を行うモデル (以降、屋外モデル) を構築する処理であり、データの計測位置が屋外である以外は、屋内モデルの構築と同じである。

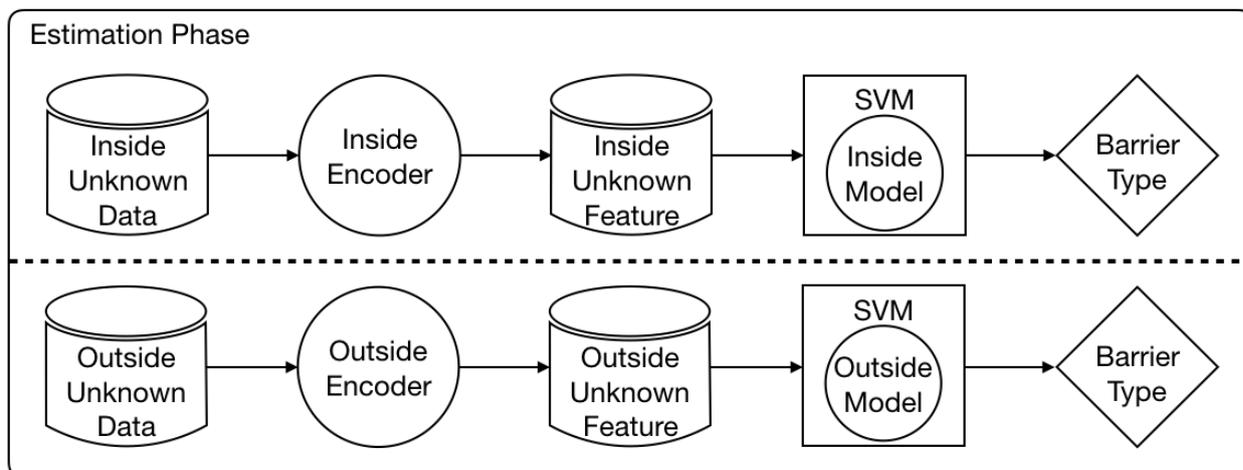


図 4.5: 提案方式の推定フェーズ

図 4.5 は提案方式の推定フェーズである。点線の上側は、屋内のバリア推定を行う処理である。屋内で計測したラベルが未知のデータ (Inside Unknown Data) を屋内エンコーダで次元削減したもの (Inside Unknown Feature) を、学習フェーズで構築した屋内モデルに基づいて SVM で分析することで、未知のデータのラベルを推定する。点線の下側は、屋外のバリア推定を行う処理であり、データの計測位置が屋外である以外は、屋内のバリア推定と同じである。

## 第5章 歩行データの計測装置の実装

## 5.1 教師ありデータ計測デバイスの実装

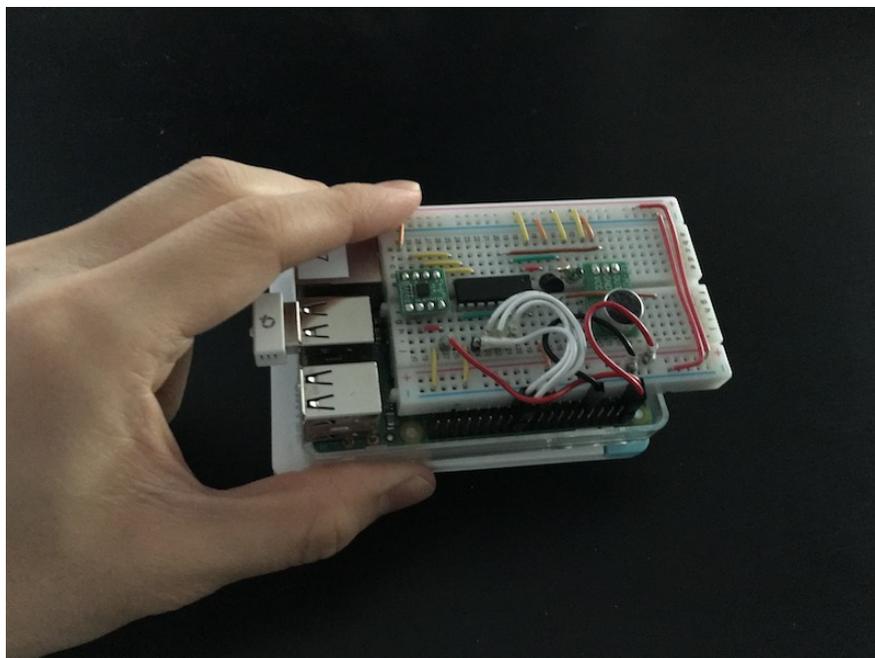


図 5.1: 加速度計測デバイス

本研究では、各バリアを HCF 方式・DAF 方式で推定するために教師ありデータが必要である。教師ありデータについては 6 章で詳しく説明する。教師ありデータを計測するために、市販の加速度センサなどの部品を組み合わせ、スマートフォンサイズの専用デバイス図 5.1 を製作した。この専用デバイスと計測者のスマートフォンの間で通信することにより、計測者がリアルタイムでより正確な教師ありデータを計測できる。専用のソフトウェアも作成し、 $\pm 2g$  の範囲の  $x$ ,  $y$ ,  $z$  軸の加速度をサンプリングレート 20Hz で記録できるように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、各対象を通過することによって教師ありデータを計測できる。

## 5.2 教師なしデータ計測アプリケーションの実装

本研究では、各バリアを DAF 方式で推定するために教師なしデータが必要である。教師なしデータについては 6 章で詳しく説明する。5.1 節のデバイスと同じ仕様で加速度データを計測する iOS・Android アプリケーション図 5.2・図 5.3 を開発した。今回この iOS・Android アプリケーションを開発した理由は、スマートフォンならば多くの人が持っているため、加速度データを多く計測できると考えたからである。以下にアプリケーションの使用手順を示す。このアプリケーションの Name に計測者名を入力して Location を ON にするかを決める (Location を ON にすると位置情報を記録し、OFF にすると位

置情報を記録せずに計測する)。Inside と Outside をタップすることにより屋内と屋外ラベルを切り替えることができるので歩行する場所に合わせて屋内と屋外ラベルを決める。この操作を行った後に Start ボタンをタップし，スマートフォンをズボンの左前ポケットに入れた状態で，通勤/通学，商業施設・公園の散策などの日常生活における歩行を行うことで，教師なしデータを計測できる。

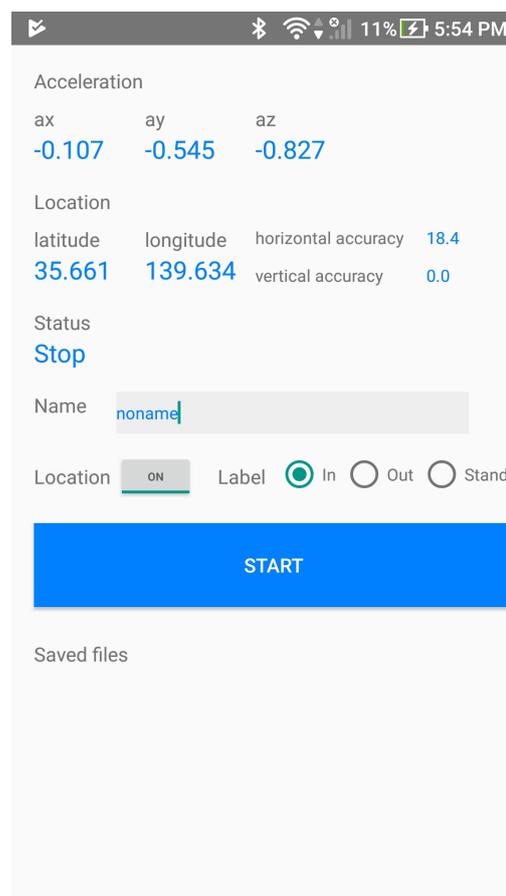
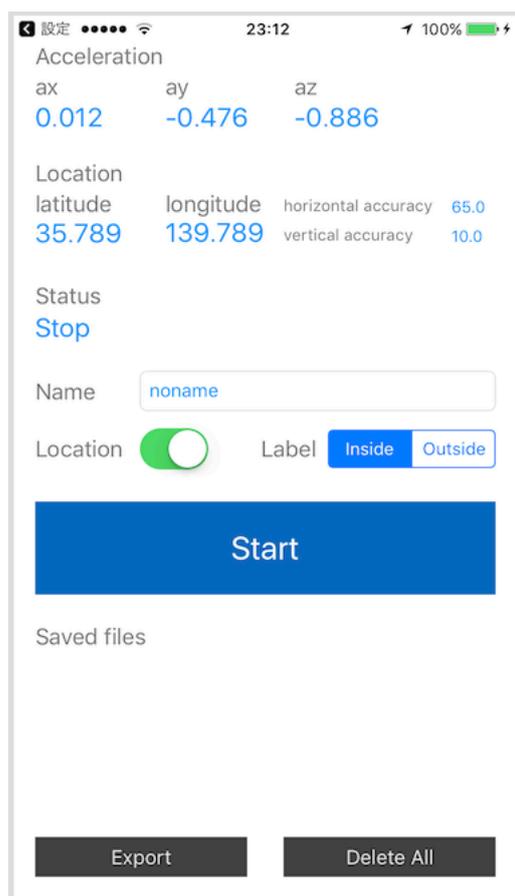


図 5.2: iOS 加速度計測アプリケーション 図 5.3: Android 加速度計測アプリケーション

## 第6章 検証実験

表 6.1: 計測対象

略称	内容
FLT (FLaT)	平地
USP (Up SteP)	上り段差
DSP (Down SteP)	下り段差
USR (Up StaiRs)	上り階段
DSR (Down StaiRs)	下り階段
ULS (Up Low Slope)	上り緩い坂
DLS (Down Low Slope)	下り緩い坂

## 6.1 検証実験 1

### 6.1.1 実験の目的

提案方式の機械学習は、エンコーダを獲得するための教師なし学習と、モデルを構築するための教師あり学習に分かれている。このとき、エンコーダを用いて加速度データから抽出した特徴量を教師あり学習で利用するため、教師なし学習の結果は教師あり学習の性能に影響を与える。

そこで、厳密な検証を行うため、検証実験 1 では、提案方式の教師あり学習についてのみ検証を行う。すなわち、検証実験 1 では、加速度データからバリア推定を行うタスクにおいて、屋内外を区別しない教師あり学習と、屋内外を区別する教師あり学習の推定精度に差があるか検証することを実験の目的とする。

### 6.1.2 データセット

以降、加速度データを計測した健常歩行者を計測者と称する。計測者に合図を出す人を実験者と称する。本実験では、屋内外に共通して存在する表 6.1 に示す対象を計測者が歩行したときの加速度を計測した。

FLT は平地である。USP / DSP は高さ約 15cm の段差である。USR / DSR は 1 段の高さが約 15cm の階段である。ULS / DLS は車椅子用の勾配約 3 度の緩い坂である。

加速度データの計測には、5.1 節で述べた専用デバイス (図 5.1) を用いた。計測者は、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。各サンプルにはラベルとして表 6.1 の略称を付与する。

計測は 20 代の健常歩行者 19 名 (男性 18 名, 女性 1 名) が行った。計測者 1 人あたり、表 6.1 の各対象について屋内・屋外それぞれ 10~20 サンプル程度計測した。計測の際、より正確なデータを計測するために、実験者のスマートフォンで計測デバイスを制御

した(図6.1)。実験者は各対象のラベルをプルダウンメニューで選択し、合図を出して計



図 6.1: 計測デバイスを制御するアプリケーション

測者には各対象をいつも通り歩いてもらう。その合図と同時に実験者がスマートフォンで Start のボタンをタップし、加速度データを記録し始める。今回の計測対象の USP / DSP はより正確な加速度データを計測するために、段差を乗り越えるときは計測者全員に左足から乗り越えるように練習してもらった。このとき、計測対象が特定の位置のバリアに偏らないよう、同一バリア種別であっても複数箇所の異なる場所で測定を行った。この結果、屋内・屋外それぞれにおいて 1800 件ずつの教師ありデータを計測した。以降、屋内で計測した教師ありデータを屋内教師ありデータ、屋外で計測した教師ありデータを屋外教師ありデータとする。

### 6.1.3 実験の手順

本実験においては、4.2.1 項で説明した人手で設計した特徴量（平均値・標準偏差・相関係数・スペクトル強度）を利用し、学習フェーズと推定フェーズを行う。

### 6.1.4 ベースライン方式

屋内外を区別しない教師あり学習を行う方式であり、以降、HCF\_MIX 方式とする。具体的には、6.1.2 項の屋内教師ありデータと屋外教師ありデータを合わせた 3600 件から無

作為に抽出した 1620 件を学習データとし、同じく無作為に抽出した 180 件をテストデータとする。学習フェーズにおいては、学習データから上述の HCF を抽出して SVM に入力してモデルを構築する。推定フェーズにおいては、テストデータから HCF を抽出して、学習フェーズで構築したモデルを用いた SVM でラベル (バリア種別) の推定を行う。この試行を、無作為に抽出する学習データ・テストデータを毎回変えながら 100 回繰り返す。

### 6.1.5 提案方式

屋内外を区別して教師あり学習を行う方式であり、以降、屋内/屋外に関する学習・推定を行うものをそれぞれ、HCF\_IN 方式 / HCF\_OUT 方式とする。具体的には、HCF\_IN 方式は、6.1.2 項の屋内教師ありデータ 1800 件から無作為に抽出した 1620 件を学習データとし、同じく無作為に抽出した 180 件をテストデータとする。学習フェーズにおいては、学習データから HCF を抽出して SVM に入力してモデルを構築する。推定フェーズにおいては、テストデータから HCF を抽出して、学習フェーズで構築したモデルを用いた SVM でラベルの推定を行う。この試行を、無作為に抽出する学習データ・テストデータを毎回変えながら 100 回繰り返す。HCF\_OUT 方式は、屋外教師ありデータを利用する以外は、HCF\_IN 方式と同様である。

### 6.1.6 実験結果・考察

HCF\_IN 方式と HCF\_MIX 方式の F 値を比較したものを図 6.2, HCF\_OUT 方式と HCF\_MIX 方式の F 値を比較したものを図 6.3 に示す。それぞれ、100 回の試行の結果を箱ひげ図で可視化したものである。横軸はバリア種別を表しており、縦軸は推定精度 (F 値) を表しており、左端の Mean は全バリアの平均値である。Mean の中央値は HCF\_IN 方式で 0.640, HCF\_OUT 方式で 0.700, HCF\_MIX 方式で 0.580 である。Mean の平均値は HCF\_IN 方式で 0.642, HCF\_OUT 方式で 0.702, HCF\_MIX 方式で 0.585 である。HCF\_IN 方式, HCF\_MIX 方式, HCF\_OUT 方式の間で t 検定を行うと、HCF\_IN 方式と HCF\_MIX 方式間, HCF\_OUT 方式と HCF\_MIX 方式間にそれぞれ 0.1 %水準で有意差が認められ、各バリア種別においても、0.1 %水準で有意差が認められた。以上の結果より、HCF\_IN 方式 / HCF\_OUT 方式が HCF\_MIX 方式を有意に上回る結果となっている。

HCF\_IN 方式, HCF\_OUT 方式, HCF\_MIX 方式の推定結果をそれぞれ混同行列にしたものを図 6.4, 図 6.5, 図 6.6 に示す。横軸は予測の推定結果を表しており、縦軸は実際の推定結果である。HCF\_IN 方式の混同行列 (図 6.4) を着目すると、USP(上り段差) は推定精度 0.55 だったが、推定精度 0.19 で DSP(下り段差) に誤って推定された。DSP(下り段差) は推定精度 0.47 だったが、推定精度 0.20 で USP(上り段差) に誤って推定された。USP(上り段差)・DSP(下り段差) の推定精度はあまり高くないが、上り・下りのことを考慮せず、段差があることを求めれば、USP(上り段差) の推定精度は 0.74 であり、DSP(下り段差) の推定精度は 0.67 である。ULS(上り緩い坂)・DLS(下り緩い坂) の推定精度が低い原因は、坂道の教師なしデータが少ないためだと考えられる。

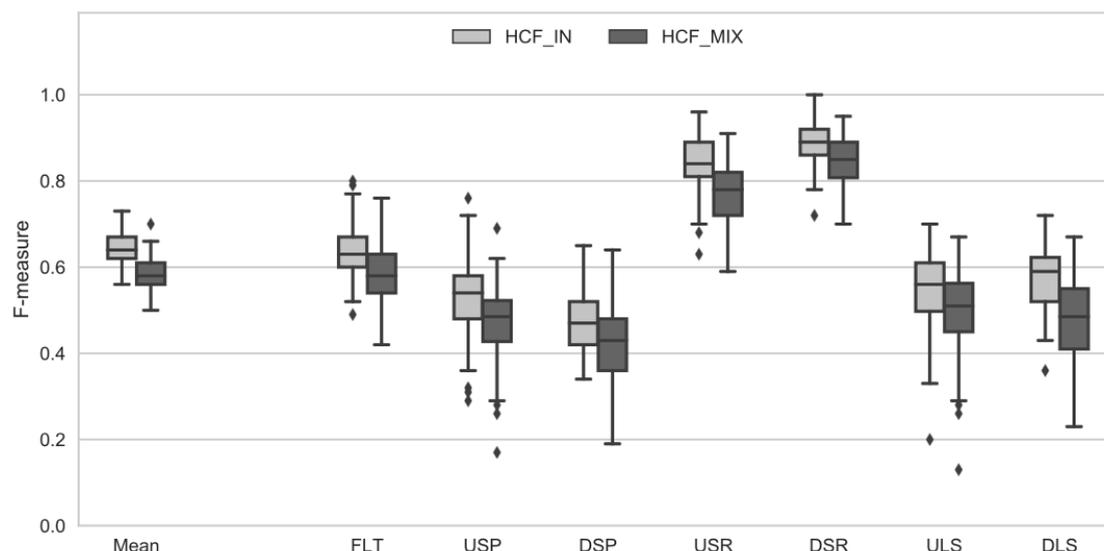


図 6.2: HCF\_IN/HCF\_MIX 方式の推定精度 (F 値, N = 100)

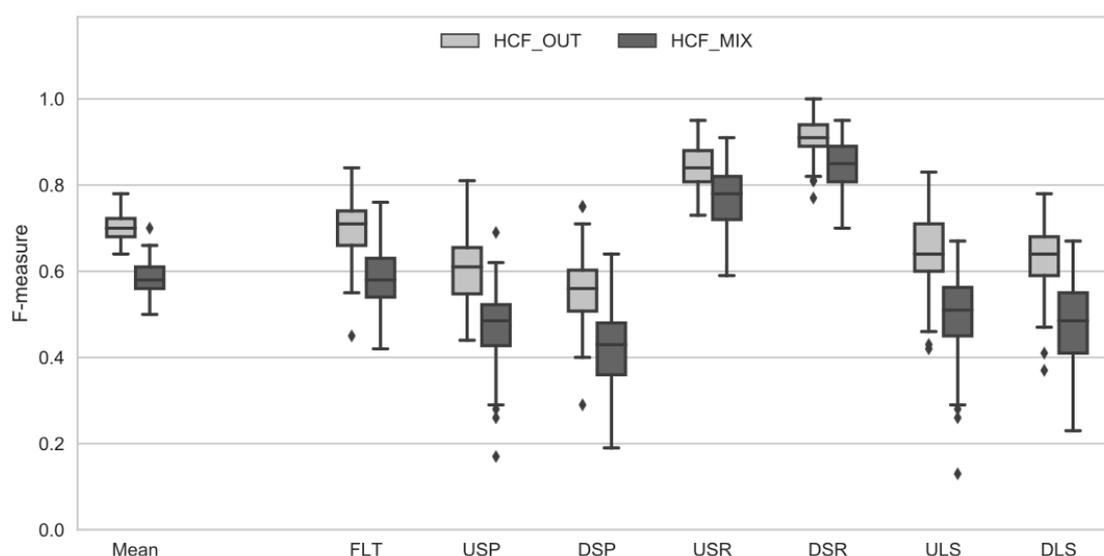


図 6.3: HCF\_OUT/HCF\_MIX 方式の推定精度 (F 値, N = 100)

HCF\_OUT方式・HCF\_MIX方式に関する USP(上り段差)・DSP(下り段差)・ULS(上り緩い坂)・DLS(下り緩い坂)の推定精度が高くない原因は、HCF\_IN方式と同様であることが考えられる。

HCF\_IN方式 / HCF\_OUT方式と HCF\_MIX方式の差は、学習・推定対象の加速度データ計測位置が屋内外混在しているか否かである。6.1.2項で述べたとおり、同一バリア種別であっても複数箇所で加速度データを計測しているため、屋内(または屋外)で計測したデータセットだけを用いたことで特定位置のバリアを過学習して精度が向上したとは考

えにくい。以上より、加速度データからバリア推定を行うタスクにおいて、屋内外を区別する教師あり学習の方が推定精度が向上すると判断できる。

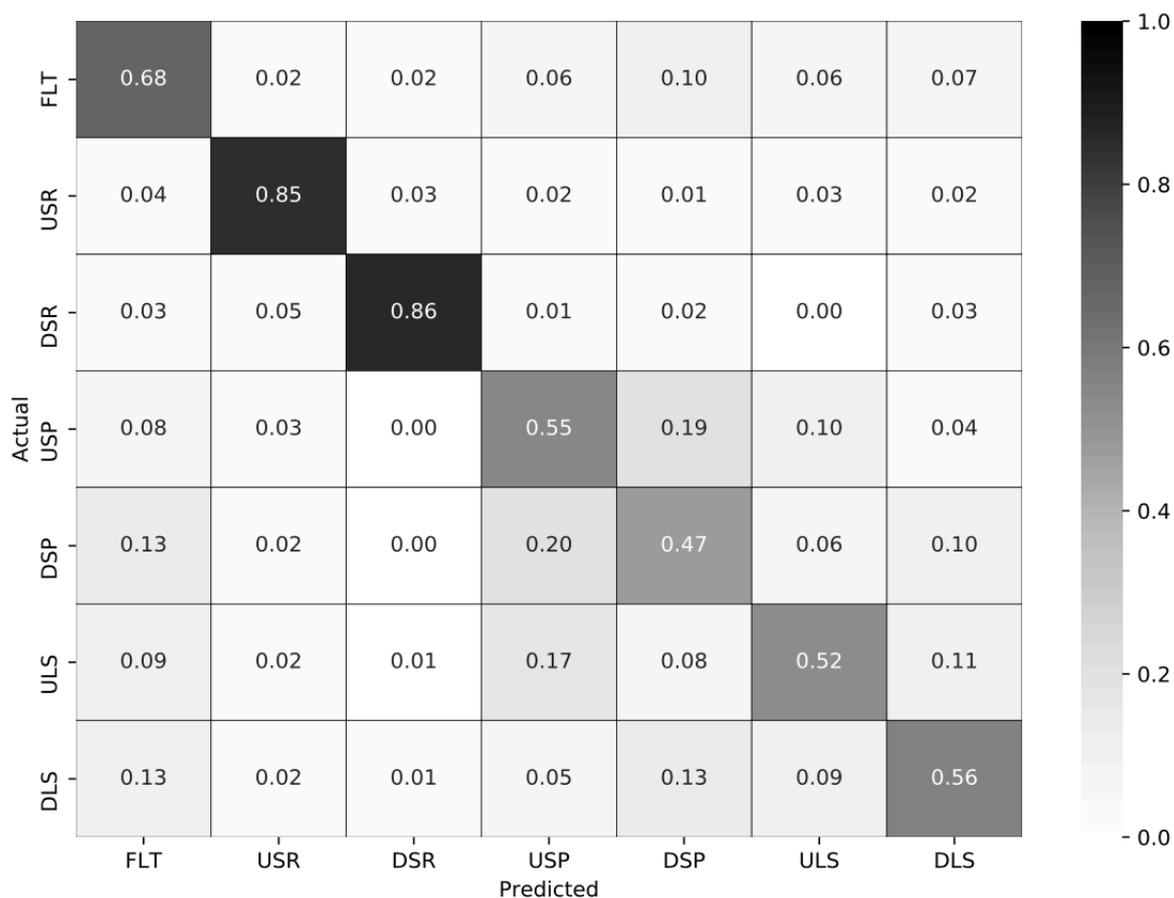


図 6.4: HCF\_IN の混同行列

## 6.2 検証実験 2

### 6.2.1 実験の目的

検証実験 1 より、教師あり学習においては、屋内外を区別した方が有意に推定精度が高いことが確認できた。そこで、検証実験 2 では、屋内外を区別しない教師なし学習と、屋内外を区別する教師なし学習の推定精度に差があるか検証することを実験の目的とする。

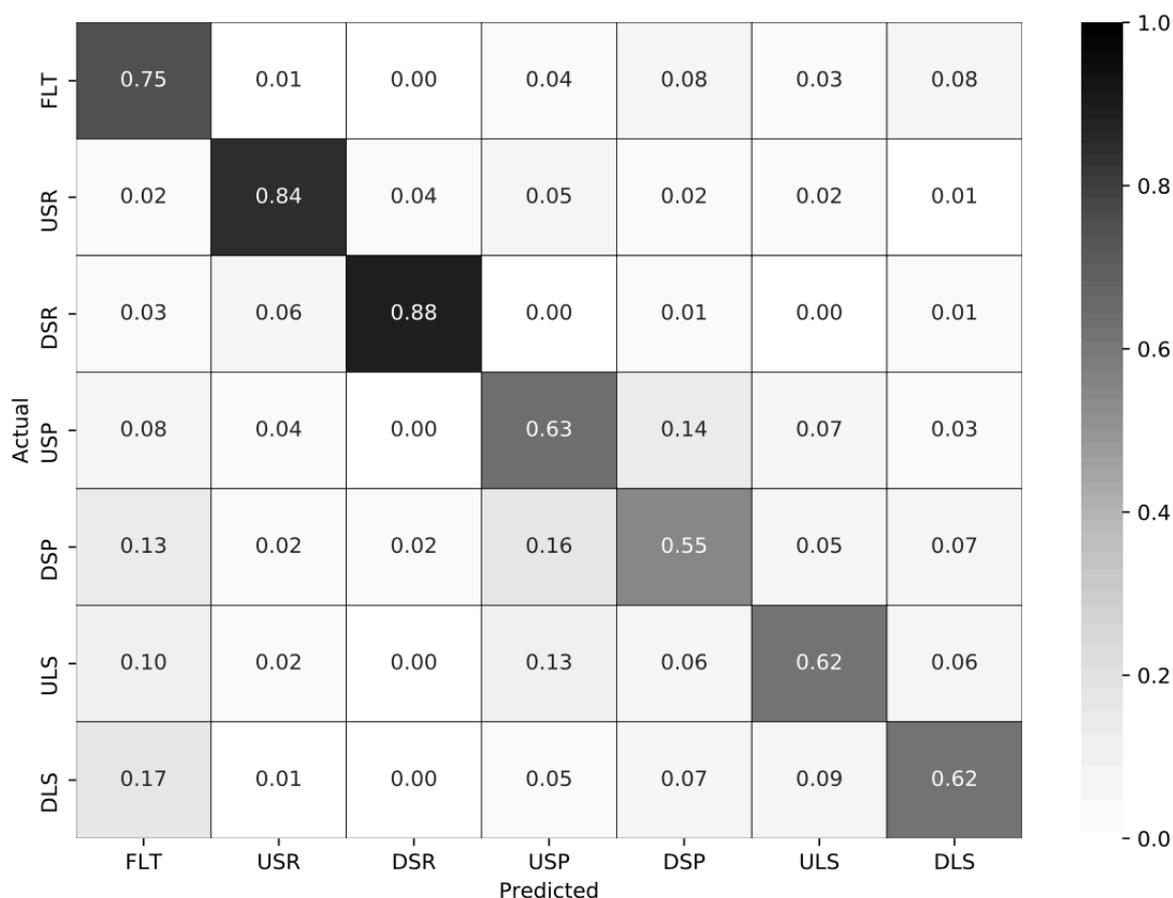


図 6.5: HCF\_OUT の混同行列

## 6.2.2 データセット

6.1.2 項のデバイスと同じ仕様で加速度データを記録する iOS・Android アプリケーションを開発した。これを動作させたスマートフォンをズボンの左前ポケットに入れた状態で、計測者が通勤/通学、商業施設・公園の散策などの日常生活における歩行を行うことで、教師なしデータを計測した。計測位置の屋内外の別は、計測者が手動で記録した。計測は 20~30 代の男性健常歩行者 12 名が行った。屋内・屋外ともに、計測者 1 人あたり数千~数万サンプルの計測を行った、この結果、屋内・屋外のそれぞれにおいて 120000 件ずつの教師なしデータを計測した。以降、屋内で計測した教師なしデータを屋内教師なしデータ、屋外で計測した教師なしデータを屋外教師なしデータとする。教師あり学習に用いるデータセットは、6.1.2 項で構築したものと同一である。

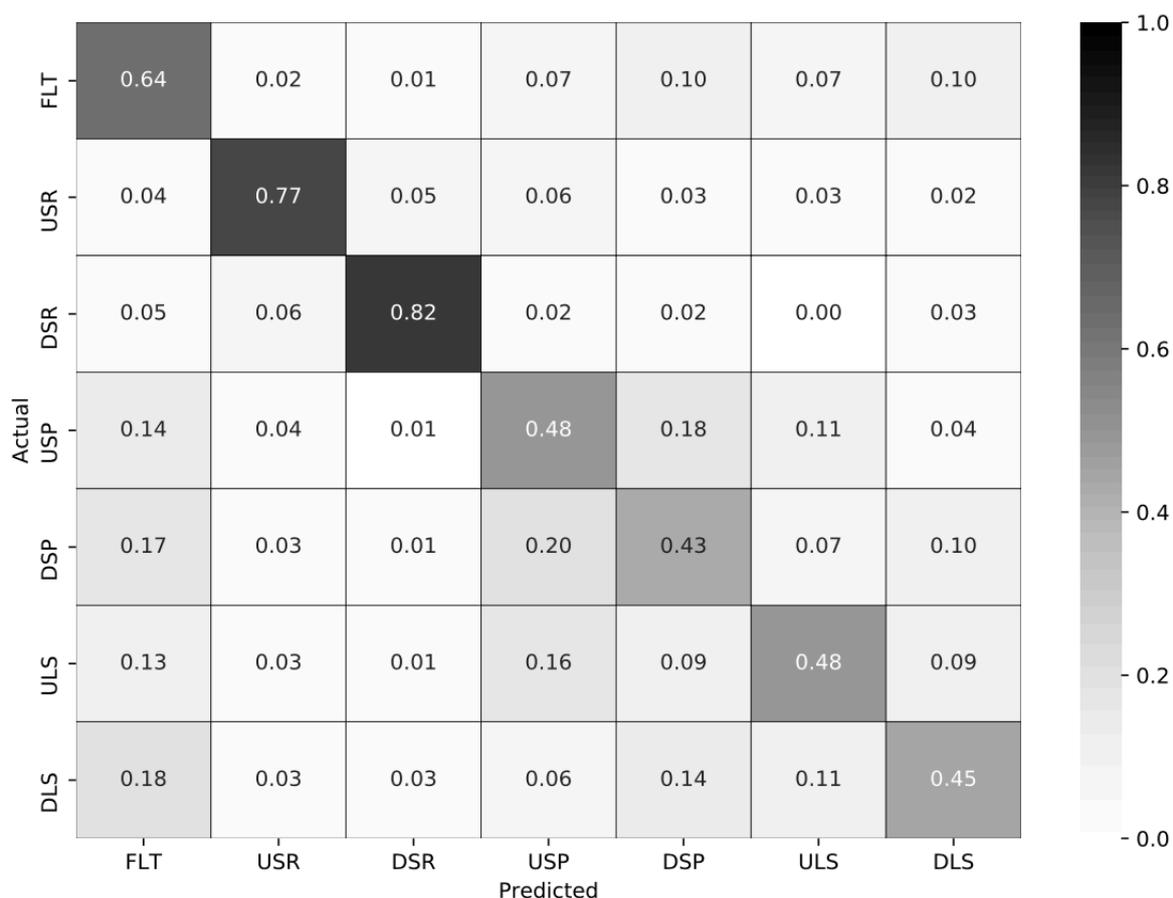


図 6.6: HCF\_MIX の混同行列

### 6.2.3 実験の手順

4.2.2 項で述べたとおり，DAE のネットワーク（図 4.1）を構築して，教師なし学習用のエンコーダを獲得する．本研究では，獲得したエンコーダを用いて加速度データを次元削減したものを元データの特徴量（Denoising Autoencoder Features，以降 DAF）とみなし，以降の教師あり学習で利用する．

なお，教師あり学習は，屋内外を区別する方が推定精度が高いことが 6.1.6 項で確認できたため，下記ベースライン方式，提案方式ともに屋内外を区別することとする．

### 6.2.4 ベースライン方式

屋内外を区別しない教師なし学習と，屋内外を区別した教師あり学習を行う方式であり，以降，DAF\_MIX 方式とする．教師なし学習では，6.2.2 項の屋内教師なしデータと屋外教師なしデータを合わせた 240000 件から無作為に抽出した 120000 件を用いて DAE

を行い、エンコーダを獲得する。教師あり学習については、利用する特徴量が HCF ではなく、エンコーダを用いて抽出する DAF であること以外は、6.1.4 項と同様である。

### 6.2.5 提案方式

教師なし学習、教師あり学習ともに、屋内外を区別した学習を行う方式であり、以降、屋内/屋外データで教師なし学習を行うものをそれぞれ、DAF\_IN 方式/ DAF\_OUT 方式とする。DAF\_IN 方式の教師なし学習では、6.2.2 項の屋内教師なしデータ 120000 件を用いて DAE を行い、エンコーダを獲得する。同様に、DAF\_OUT 方式の教師なし学習では、屋外教師なしデータ 120000 件を用いて DAE を行い、エンコーダを獲得する。DAF\_IN 方式、DAF\_OUT 方式ともに、教師あり学習については、HCF ではなく DAF を特徴量として利用する以外は、6.1.5 項と同様である。

### 6.2.6 実験結果・考察

DAF\_IN 方式と DAF\_MIX 方式の比較を図 6.7、DAF\_OUT 方式と DAF\_MIX 方式の比較を図 6.8 に示す。それぞれ、100 回の試行の結果を 6.1.6 項と同様に可視化したものである。なお、図 6.7 の DAF\_MIX 方式は屋内データを用いて教師あり学習・推定を行ったもの、図 6.8 の DAF\_MIX 方式は屋外データを用いて教師あり学習・推定を行ったものであり、両者は異なるものである。図 6.7 について、Mean の中央値は DAF\_MIX 方式で 0.710、DAF\_IN 方式で 0.700 である。Mean の平均値は DAF\_MIX 方式で 0.704、DAF\_IN 方式で 0.694 である。DAF\_IN 方式と DAF\_MIX 方式の間に有意差が認められなかった。バリア種別ごとに見ると、USR(上り階段)・DLS(下り緩い坂)は 1% 水準の有意差があり、ULS(上り緩い坂)は 5% 水準の有意差があるが、それ以外のバリアは有意差がなかった。

図 6.8 について、Mean の中央値は DAF\_MIX 方式で 0.750、DAF\_OUT 方式で 0.760 である。Mean の平均値は DAF\_MIX 方式で 0.751、DAF\_OUT 方式で 0.752 である。DAF\_OUT 方式と DAF\_MIX 方式の間に有意差が認められなかった。バリア種別ごとを見ると、DSR(下り階段)だけ 0.1% 水準の有意差があるが、それ以外のバリアは有意差がなかった。

DAF\_IN 方式、DAF\_MIX 方式（屋内教師ありデータ）の推定結果をそれぞれ混同行列にしたものを図 6.9、図 6.10 に示し、DAF\_OUT 方式、DAF\_MIX 方式（屋外教師ありデータ）の推定結果をそれぞれ混同行列にしたものを図 6.11、図 6.12 に示す。横軸は予測の推定結果を表しており、縦軸は実際の推定結果である。

DAF\_MIX 方式と DAF\_IN 方式 / DAF\_OUT 方式の差は、教師なし学習に用いる加速度データ計測位置が屋内外混在しているか否かである。上記の結果より、屋内外を区別する DAF\_IN 方式・DAF\_OUT 方式の推定精度は DAF\_MIX 方式の推定精度とあまり差がなかった。この理由として、次の 3 つの仮説が立てられる。1 つ目は、実験に用いたデータ量が不足しているという仮説である。今回教師なし学習に用いたデータは 120000 件 (約

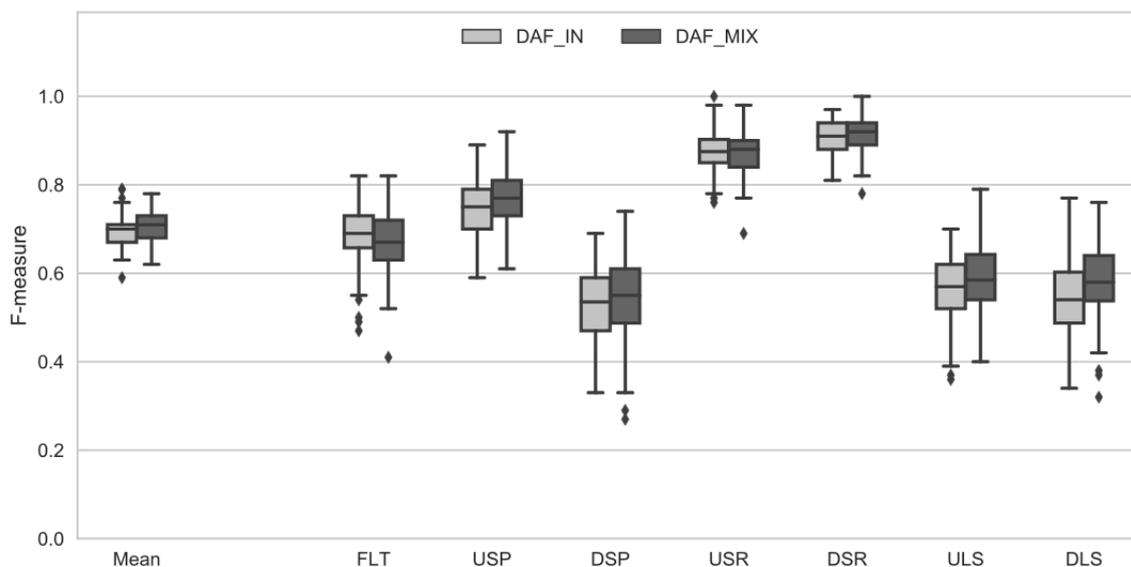


図 6.7: DAF\_IN/DAF\_MIX 方式の推定精度 (F 値, N = 100)

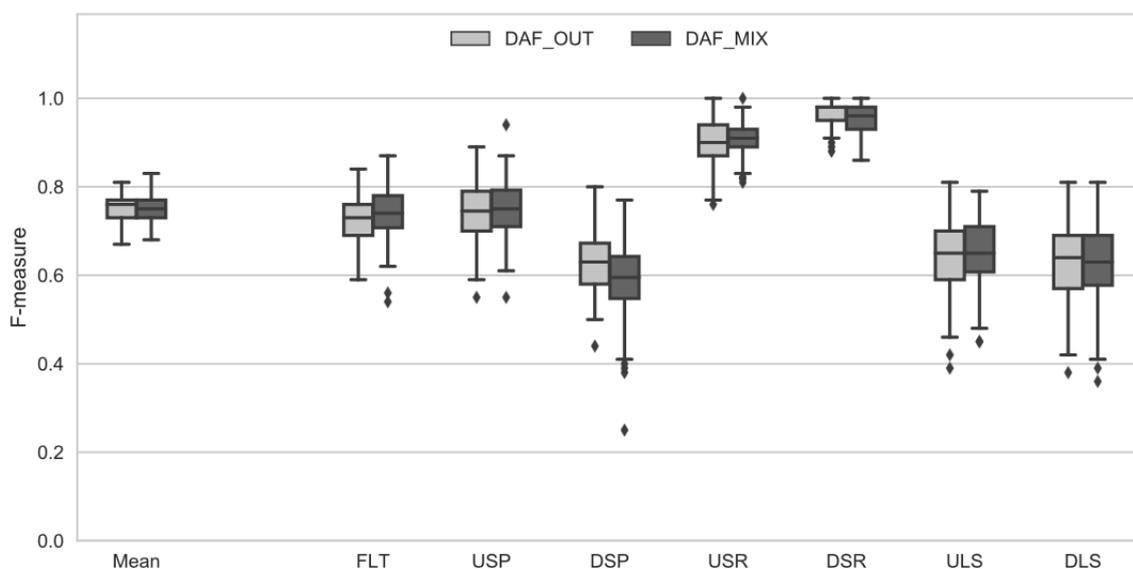


図 6.8: DAF\_OUT/DAF\_MIX 方式の推定精度 (F 値, N = 100)

100 時間分の歩行に相当) である。これは、人の行動によって生じる加速度データを機械学習する研究事例の中では多い部類に属すると思われるが、一般的な Deep Learning タスクとしては不十分なデータサイズである。データサイズを大きくすることで、DAF\_IN 方式・DAF\_OUT 方式の精度はさらに向上する可能性がある。2つ目は、加速度データ計測場所の屋内外を区別してもしなくても、獲得できるエンコーダには大差が無いという仮説である。この仮説が正しい場合、より多くの教師なしデータを利用するためにあえて

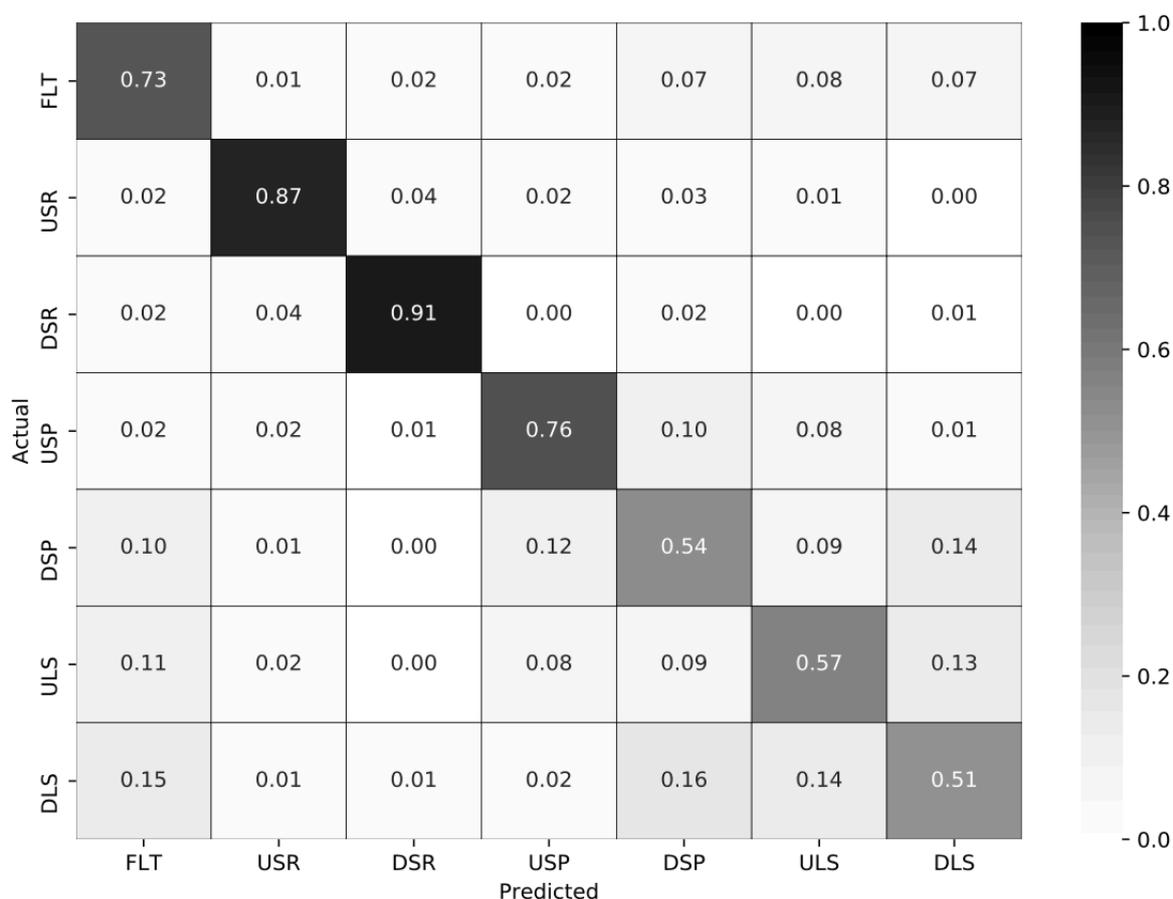


図 6.9: DAF\_IN の混同行列

DAF\_MIX 方式を用いる判断が可能になる。3つ目は、教師ありデータを計測した健常者が教師なしデータを計測していない、もしくは、少量の教師なしデータしか計測していない場合、推定精度に影響を与えるという仮説である。今回の実験では、教師ありデータを計測する健常者は19名であり、教師なしデータを計測する健常者は12名であり、教師あり/なしデータの計測者の人数条件を統一していなかった。世の中に多くの健常者を特定の場所で教師ありデータを計測するのは難しいが、この仮説が正しくない場合、教師ありデータを計測せずに、教師なしデータを計測するだけでも、推定精度に影響を与えないため、今後、より多く教師なしデータを集めるコストが低くなる可能性がある。すなわち、上述のとおり Deep Learning には大量の教師なしデータが必要であるが、DAF\_IN 方式 / DAF\_OUT 方式では教師なしデータセットのうち、それぞれ屋内/屋外で計測された部分しか利用できない。一方、DAF\_MIX 方式では屋内外を問わず計測済みのすべての加速度データを利用でき、より高精度な推定に寄与するエンコーダを獲得できる可能性がある。いずれにせよ、より多くの教師なしデータを集め、仮説1・2・3のどちらが正しいか見極める必要がある。

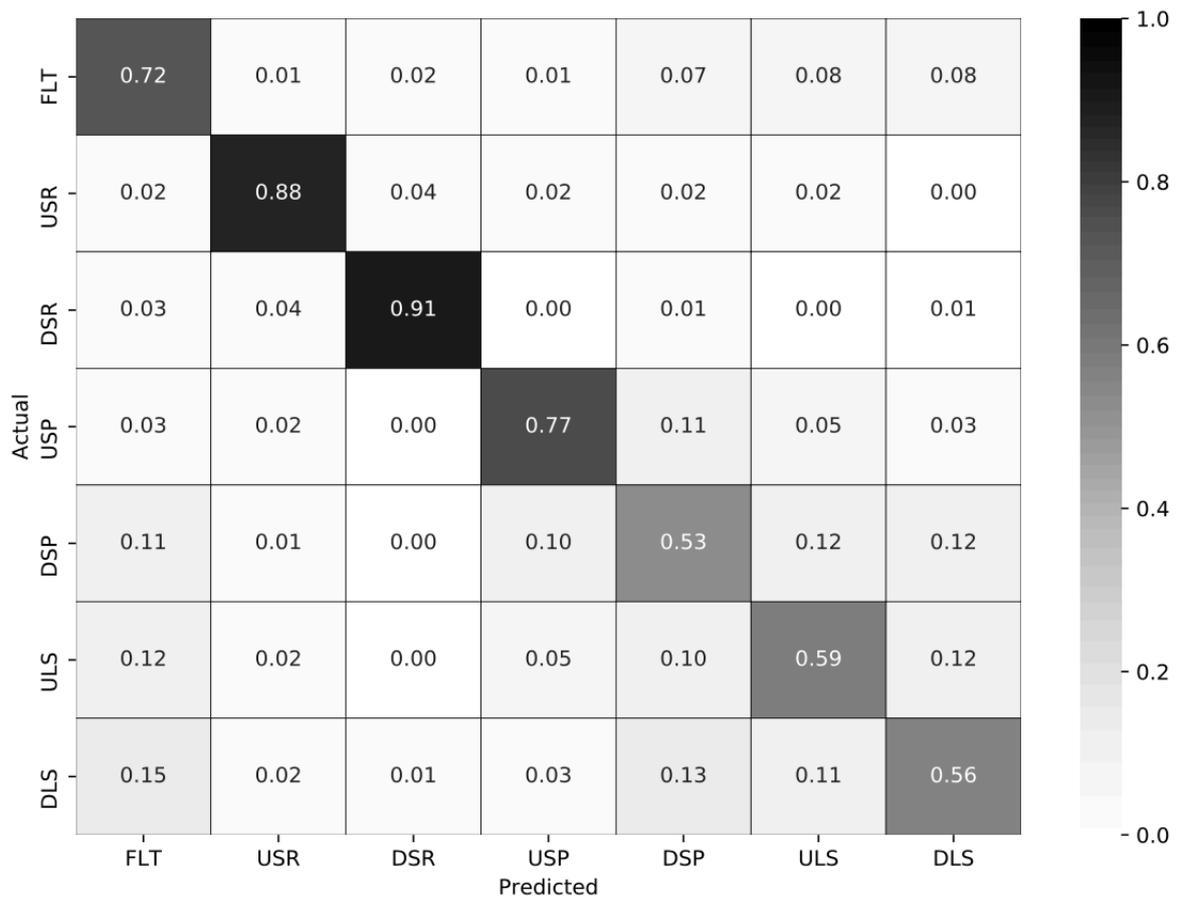


図 6.10: DAF\_MIX (屋内教師ありデータ) の混同行列

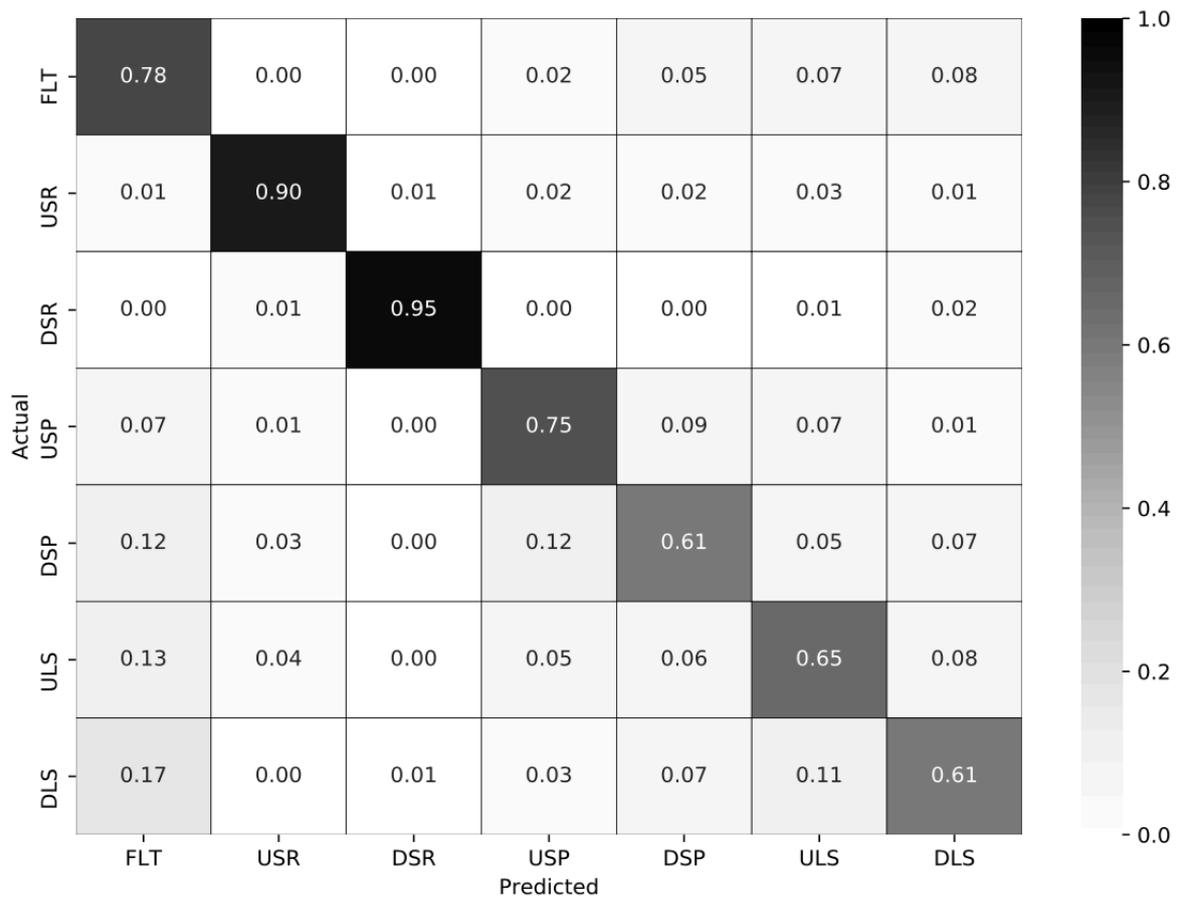


図 6.11: DAF\_OUT の混同行列

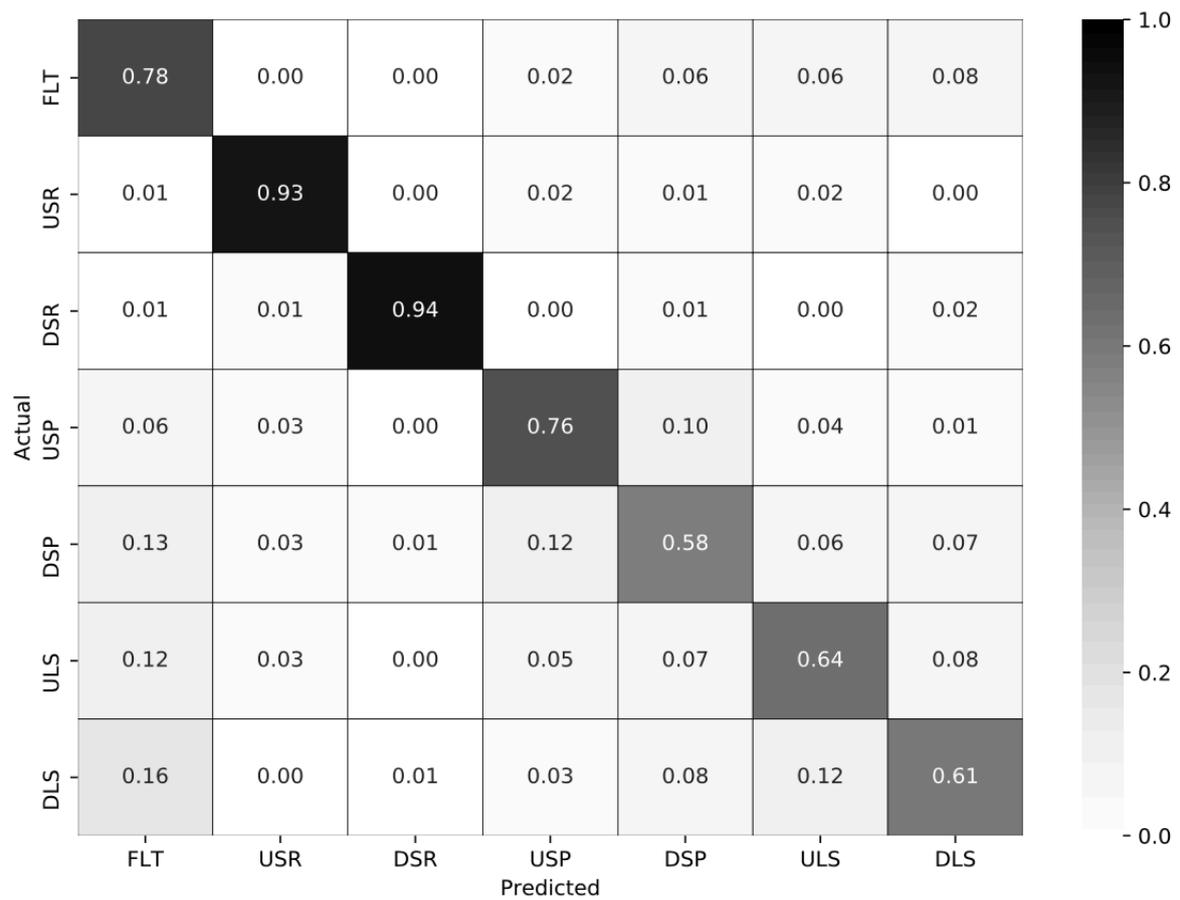


図 6.12: DAF\_MIX (屋外教師ありデータ) の混同行列

## 第7章 結論

本研究では、健常歩行者の加速度データを機械学習してバリア検出するタスクにおいて、推定対象の屋内外を区別する方式を提案した。屋内外を区別したバリア検出方式を提案した。この方式では、屋内外を区別した教師なし学習により、屋内エンコーダと屋外エンコーダを獲得する。同じく、屋内外を区別した教師あり学習により、屋内モデルと屋外モデルを構築する。屋内バリア検出時は屋内エンコーダ・屋内モデルを、屋外バリア検出時は屋外エンコーダ・屋外モデルを用いる。検証実験の結果、この提案方式は屋内外を考慮しない従来方式より有意に高精度なバリア推定を行えることが判明した。この結果より、3.2節で設定した屋内外を区別することがバリア検出精度に与える影響を明らかにするという課題1を達成できたと考えられる。このとき、教師あり学習においては屋内外を区別することで大きな精度向上が認められたが、教師なし学習においては精度向上があまり認められなかった。屋内外それぞれについて膨大な教師なし加速度データを収集すれば、DAF\_IN / DAF\_OUT方式にも高精度なバリア推定が行えると考えられる。しかし、膨大な屋内外それぞれの教師なし加速度データを収集するコスト・大変さを考慮すれば、DAF\_MIX方式を選択することが考えられる。以上の結果より、3.2節で設定した高精度・実用的に屋内外のバリアの存在・種別を推定する方式を提言するという課題2を概ねに達成できたと考えられる。

今後は、より多くのデータを収集し、6.2.6項で生じた1つ目と2つ目の仮説の検証を行う必要がある。教師ありデータ・教師なしデータを計測する健常者の人数を統一して実験を行い、6.2.6項で生じた3つ目の仮説の検証を行う必要もある。また、実際に移動に困難を感じている人へのヒアリングも行うことで、推定すべきバリアに過不足が無いのか、多様な視点から精査する必要もある。少しでも早く本研究の成果を実用化し、移動に困難を抱える人の一助となることを目指したい。

## 参考文献

- [1] 紺家裕子, 椎尾一郎. バリアフリー演劇における聴覚障害者向け字幕表示方法の提案 (観客反応の提示). 情報処理学会研究報告 (EC), エンタテインメントコンピューティング, Vol. 2012-EC-23, No. 19, pp. 1–6, 2012.
- [2] 江草遼平, 川口漱也, 酒井嗣之介, 楠房子, 生田目美紀, 溝口博, 稲垣成哲. ユニバーサル人形劇システムにおける吹き出し型字幕の検討. 情報処理学会研究報告 (GN), グループウェアとネットワークサービス, Vol. 2017-GN-100, No. 41, pp. 1–6, 2012.
- [3] 上羽貞行, 荒井隆行, 栗栖清浩, 倉片憲治, 坂本真一, 船場ひさお, 佐藤洋. 音バリアフリーの現状と課題. 日本音響学会誌, Vol. 63, pp. 723–730, 2007.
- [4] 荒井隆行. 音声に関わるバリアフリー. 日本音響学会聴覚研究会資料, pp. 377–382, 2007.
- [5] 浅川恵美子, 高木啓伸, 井野秀一, 伊福部達. 視覚障害者への音声提示における最適・最高速度. ヒューマンインタフェース学会論文集, Vol. 7, pp. 105–111, 2005.
- [6] 窪田諭, 関博之, 狩野徹, 阿部昭博. 歩行空間におけるカラーユニバーサルデザイン支援システムの開発と適用. 情報処理学会論文誌, Vol. 52, No. 1, pp. 140–152, 2011.
- [7] 在塚俊之, 畑岡信夫. 視覚障害者の GUI アクセスを助ける音響技術. 日本音響学会誌, Vol. 54, pp. 393–398, 1998.
- [8] <http://www.j-milk.jp/anzen/shoku/8d863s000007z1wa.html> (last visited: 2017/12/07).
- [9] Ji Hoon Choi, Chung Hyun AHN, Jeongil Seo, and Ohseok Kwon. Sensory effect representation for barrier-free broadcasting service, Proc. ICACT '17, pp. 664–667, 2017.
- [10] 国土交通省: 歩行空間ネットワークデータ整備仕様案 (2010).
- [11] <http://wheelmap.org> (last visited: 2017/12/07).
- [12] Miura, T., Yabu, K., Ikematsu, S., Kano, A., Ueda, M., Suzuki, J., Sakajiri M., and Ifukube. Barrier-free walk: A social sharing platform of barrier-free information for sensory/physically-impaired and aged people, Proc. SMC'12, pp. 2927–2932, 2012.

- [13] 山本千尋, 船越用, 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. 情報処理学会研究報告 (GN), グループウェアとネットワークサービス, Vol. 2016-GN-99, pp. 1–6, 2016.
- [14] 山本千尋, 船越用, 小長井俊介, 小西宏志, 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, pp. 21–24, 2016.
- [15] Hara, K., Le, V., Froehlich, and J. E. Combining crowdsourcing and google street view to identify streetlevel accessibility problems, Proc. *CHI'13*, pp. 631–640, 2013.
- [16] Rundle, A., Bader, M. Richards, C., Neckerman, K., Teitler, and J. Using google street view to audit neighborhood environments. *American Journal of Preventive Medicine*, Vol. 140, No. 1, pp. 94–100, 2011.
- [17] Badland, H., Opit, S., Witten, K., Kearns, R., Mavoa, and S. Can virtual streetscape audits reliably replace physical streetscape audits? *Journal of Urban Health*, Vol. 87, pp. 1007–1016, 2010.
- [18] Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., Balakrishnan, and H. The pothole patrol: Using a mobile sensor network for road surface monitoring, Proc. *MobiSys '08*, pp. 29–39, 2008.
- [19] 牧恒雄, 竹内康, 松田誠. 歩道の凹凸評価方法に関する研究. 第1回舗装工学講演会論文集, pp. 151–158, 1996.
- [20] 石田眞二, 亀山修一, 岳本秀人, 姫野賢治, 鹿島茂. 車椅子の走行負荷に基づいた歩道の路面凹凸評価方法. 土木学会論文集 E, Vol. 62, pp. 295–305, 2006.
- [21] 岡村美好. 車いすの乗り心地に着目した歩行者系舗装の性能指標に関する一考察. 土木学会舗装工学論文集, Vol. 14, pp. 189–194, 2009.
- [22] Kenichi ARAI, Takuya TATEISHI, Toru LOBAYASHI, and Noboru SONEHARA. On-demand barrier-free street view system using sensor information from general-purpose wheelchair users, Proc. *COMPSAC '17*, Vol. 2, pp. 348–353, 2017.
- [23] 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, No. 2015, 2015.
- [24] 岩澤有祐, 矢入郁子. 多次元時系列データ解析によるアクセシビリティ可視化システムの開発. *JSAI'14*, 2014.
- [25] 隅田康明, 松永勝也, 合志和晃, 志堂寺和則. 車いす利用者向け経路探索のための路面の傾斜及び段差測定システムの開発. 信学技報, Vol. 114, No. 357, pp. 63–68, 2014.

- [26] Kuwahara, N., Nishiura, M., Shiomi, Y., Morimoto, K., Iwawaki, Y., Nishida, and N. A study on a ubiquitous system for collecting barrier-free information of evacuation centers for wheelchair users, Proc. CASEMANS ' 10, pp. 36–39, 2010.
- [27] <http://npopadm.com> (last visited: 2017/12/07).
- [28] 宮田章裕, 伊勢崎隆司, 中野将尚, 石原達也, 有賀玲子, 望月崇由, 渡部智樹, 水野理. 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.
- [29] Isezaki, T., Nijjima, A., Miyata, A., Watanabe, T., Mizuno, and O. Wheelchair users' psychological barrier estimation based on inertial and vital data, Proc. *HCI'16*, pp. 403–413, 2016.
- [30] 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, 2016.
- [31] Taniue, H., Kojima, K., Kanedo, and J. Development of automatic barrier detection system for wheelchair, Proc. GCCE ' 15, 2015.
- [32] 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.
- [33] Kwapisz, J. R., Weiss, G. M., Moore, and S. A. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*, Vol. 12, pp. 74–82, 2010.
- [34] Brajdic, A., Harle, and R. Walk detection and step counting on unconstrained smartphones, Proc. UBiComp ' 13, pp. 225–234, 2016.
- [35] 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. マルチメディア、分散、協調とモバイルシンポジウム 2014 論文集, pp. 258–265, 2014.
- [36] 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.
- [37] 宮田章裕, 荒木伊織, 王統順, 鈴木天詩. 健常者をセンサ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 (HCI), ヒューマンコンピュータインタラクション, Vol. 2017-HCI-171, pp. 1–8, 2017.
- [38] 宮田章裕, 荒木伊織, 王統順, 鈴木天詩. 健常者をセンサノードとして用いたバリア検出手法に向けて. 第 79 回全国大会講演論文集, 2017.

- [39] 宮田章裕, 荒木伊織, 王統順, 鈴木天詩. 健常者をセンサ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), グループウェアとネットワークサービス, Vol. 2017-GN-101, pp. 1–8, 2017.
- [40] 荒木伊織, 王統順, 鈴木天詩, 宮田章裕. 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. 情報処理学会研究報告 (GN), グループウェアとネットワークサービス, Vol. 2017-GN-102, pp. 1–5, 2017.
- [41] 王統順, 荒木伊織, 鈴木天詩, 宮田章裕. 屋内外を区別した機械学習によるバリア検出方式. マルチメディア, 分散、協調とモバイルシンポジウム 2017 論文集, pp. 1500–1506, 2017.
- [42] Li, M., Zhou, P., Zheng, Y., Li, Z., Shen, and G. Iodetector: A generic service for indoor/outdoor detection. *ACM Trans. Sensor Networks*, Vol. 11, No. 2, pp. 18:1–28:29, 2014.
- [43] Ravindranath, L., Newport, C., Balakrishnan, H., Madden, and S. Improving wireless network performance using sensor hints. *Proc. NSDI'11*, pp. 281–294, 2011.
- [44] 勝田悦子, 内山彰, 山口弘純, 東野輝夫. Gps 受信状態を用いた屋内外判定法. 情報処理学会研究報告 (ITS), 高度交通システム, Vol. 2011-ITS-47, pp. 1–8, 2011.
- [45] 伴拓実, 鈴木秀和, 旭健作, 渡邊晃. Tlifes における省エネ位置測位のための屋内外判定手法の検討. 第 76 回全国大会講演論文集, Vol. 2014, pp. 205–206, 2014.
- [46] 今野貴洋, 渡部修平, 森脇康介, 森嶋健平. 屋内及び屋外のシームレスな位置検出に関する検討. 第 68 回全国大会講演論文集, Vol. 2006, pp. 311–312, 2006.
- [47] 尾崎勝義, 田中幹衡, 吉田慶介, 松野省吾, 大山実. モバイル端末を用いた屋内外判定法の検討. 情報科学技術フォーラム講演論文集, Vol. 14, pp. 549–550, 2015.
- [48] 伊藤誠悟, 鋤柄和俊, 小山渚, 大桑政幸. 輝度付き多次元正規分布地図を用いた屋内外位置推定手法. 情報処理学会論文誌, Vol. 57, No. 1, pp. 3–11, 2017.
- [49] 国土交通省: 建設技術移転指針策定調査 (2004).
- [50] 国土交通省: 公共建築工事標準仕様書 (2016).
- [51] 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.

# 研究業績

## 査読付き論文誌

- (1) Akihiro Miyata, Iori Araki and Tongshun Wang: Barrier Detection using Sensor Data from Unimpaired Pedestrians, to be appeared in Proceedings of the 20th International Conference on Human-Computer Interaction (HCI'18) (2018).
- (2) 宮田章裕, 荒木伊織, 王統順, 鈴木天誌: 健常歩行者センサデータを用いたバリア検出の基礎検討, 情報処理学会論文誌 (2018年1月掲載予定).

## 研究会・シンポジウム

- (1) 王統順, 荒木伊織, 鈴木天詩, 宮田章裕: 屋内外を区別した機械学習によるバリア検出方式, マルチメディア、分散、協調とモバイル (DICOMO2017) シンポジウム, pp.1500–1506 (2017年6月).
- (2) 荒木伊織, 王統順, 鈴木天詩, 宮田章裕: 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, 情報処理学会研究報告 (GN), グループウェアとネットワークサービス, Vol.2017-GN-102, No.10, pp.1–5 (2017年5月).
- (3) 宮田章裕, 荒木伊織, 王統順, 鈴木天詩: 健常者をセンサノードとして用いたバリア検出手法に向けて, 情報処理学会第79回全国大会公演論文集, Vol.2017, No.1, pp.7–8 (2017年3月).
- (4) 宮田章裕, 荒木伊織, 王統順, 鈴木天詩: 健常歩行者センサデータを用いたバリア検出に向けた機械学習手法の検討, 情報処理学会研究報告 (GN), グループウェアとネットワークサービス, Vol.2017-GN-101, No.11, pp.1–8 (2017年3月).
- (5) 宮田章裕, 荒木伊織, 王統順, 鈴木天詩: 健常歩行者センサデータを用いたバリア検出の基礎検討, 情報処理学会研究報告 (HCI), ヒューマンコンピュータインタラクション, Vol.2017-HCI-171, No.8, pp.1–8 (2017年1月).

## 受賞

- (1) 情報処理学会論文誌ジャーナ/JIP 特選論文, 健常歩行者センサデータを用いたバリア検出の基礎検討, 受賞者: 宮田章裕, 荒木伊織, 王統順, 鈴木天誌 (2018年1月).