

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

宮田 章裕^{1,a)} 荒木 伊織¹ 王 統順¹ 鈴木 天詩¹

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には問題がある。例えば、加速度センサを搭載した車椅子を用いてバリア検出する手法があるが、これは車椅子が通過したエリアのバリアしか検出できない。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、健常者歩行時のセンサデータから障害者に対するバリアの存在を推定するアプローチをとる。本稿では、このアプローチに適した機械学習方式の比較・検討を行い、実際の歩行データを用いた精度検証実験の結果を報告する。

A Study on Machine Learning Methods for Barrier Detection using Sensor Data of an Unimpaired Walker

AKIHIRO MIYATA^{1,a)} IORI ARAKI¹ TONGSHUN WANG¹ TENSHI SUZUKI¹

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・通路は障害者にとって移動しやすいものではない。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、障害者の移動計画を助けるだけでなく、道路・施設管理者への改善を促せるという観点からも、有益である。

この問題意識は多くの研究者に共通するところであり、屋内外のバリア情報を収集する試みは多数行われている。しかし、現時点では、広域のバリア情報を高精度に収集する方式は確立されていない。例えば、車椅子に装着したセンサデータを分析することで、路上のバリアを検出しようとする事例がある。このアプローチは一定精度でバリア情報を収集できるが、車椅子が移動した範囲の情報しか収集

できないという制約がある。車椅子利用者の数は健常者と比べると少ないため、広域におけるバリア情報の収集が困難である。

一方、健常者の歩行時に発生するセンサデータを分析してバリア情報を収集しようとする試みもある。このアプローチであれば、広域のバリア情報を収集できる可能性がある。しかし、従来研究は、坂道や階段といった、健常者でも歩行パターンが大きく変わるバリアの推定にとどまっておらず、石畳（図1）、1段の段差（図2）、押し引きする開き戸といった、健常者の移動はほとんど妨げないが障害者の移動は妨げる対象の存在も推定できるのかどうかは、明らかではない。

そこで、我々は、健常者歩行時のセンサデータから障害者に対するバリアの存在を推定するアプローチの基礎検討 [1] を開始しており、従来研究が明らかにできていない多様なバリア（石畳、1段の段差など）の存在を推定できるかどうか、検証を進めている。本稿では、バリア検出に適用可能な機械学習手法を実験・考察により比較し、最適な手法の選定を目指す。

本稿の貢献は次のとおりである。

¹ 日本大学 文理学部
College of Humanities and Sciences, Nihon University
^{a)} miyata.akihiro@nihon-u.ac.jp

- 従来研究より細かい粒度で多様なバリアを推定対象として定義し、実際に歩行した際の加速度センサデータからバリア推定を行う実験を実施した点。
- バリア検出において、人手で設計した特徴量を機械学習する方式と、2種類の Deep Learning で自動設計した特徴量を機械学習する方式の精度比較を実施した点。

2. バリア情報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、人間が遠隔地から判断するもの(2.1.2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、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。[2]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。[3]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。[4]も同様の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。[5]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[6]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 [7][8][9] 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。

[10]は、専用モジュールを搭載した自動車に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。[11]らも同様の取り組みをしているが、車内のスマートフォンをデータ計測に用いている点が異なる。

一方、[12][13][14]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。[15]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。[16]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。[17]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。[18]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すとしている。[19]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挑戦している。[20]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、車道が近くで緊張するなどの心理的なバリアの検出を試みている。

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。[21]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。[22]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、[23]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。[24]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。[25]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



図 1 石畳



図 2 段差



図 3 急斜面

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．

3. 研究課題

3.1 問題の定義

屋内外のバリア情報を収集する試みは多数行われているが，[19]に整理されているように，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．そこで，本研究では，2.2節のセンサデータから自動判断するアプローチに関して検討を進める．

2.2.1節の研究事例は，車椅子利用者の移動時に発生するセンサデータを分析するアプローチであるが，車椅子利用者の数は健常者と比べると少ないため，広域におけるバリア情報の収集が困難である．

一方，2.2.2節の研究事例は，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である．健常者の人数は相対的に多いため，より広域のバリア情報を収集できる．しかし，我々が調査したかぎりでは，石畳，緩い坂，1段の段差，押し引きする開き戸といった，健常者の移動はほとんど妨げないが障害者の移動は妨げる対象の存在も推定できるのかどうかは，明らかではない．

以上より，バリア情報の収集における問題は次のように整理できる．

- 人の判断が介在するアプローチでは，広域のバリア情報を収集することは困難である．
- 車椅子移動時のセンサデータを分析するアプローチでは，広域のバリア情報を収集することは困難である．
- 健常者移動時のセンサデータを分析するアプローチは広域のバリア情報を収集できるが，障害者に対するバリアを検出できていない可能性がある．

3.2 研究課題の設定

3.1節で定義した問題をふまえ，本研究では，バリアを

“円滑な移動を妨げるもの”と定義した上で，健常者歩行時のセンサデータから障害者に対するバリアの存在・種類を推定する技術の確立を研究課題に設定する．

4. 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，図2のような1段の段差がある．このような段差を超える際，健常者の歩行の様子はほとんど変化しないようにも思われる．このため，果たしてセンサデータから1段の段差が推定できるかどうか，検証する価値はあると言える．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す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．あるいは，人混みもバリアになりうる．車椅子や松葉杖で移動する際は，ある程度のスペースが必要になるし，多くの人が周囲で不規則に動く状況にスムーズに対応することは難しい．

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くない．しかし，引き開ける／押し開けるタイプの開き戸は，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
- 人混み
- 開き戸

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。

5. 機械学習方式の検討

本研究では、歩行時に生じる加速度センサデータを機械学習することで、バリアの種類を推定することとする。以降、加速度センサデータを機械学習するための方式について、各観点から検討する。

5.1 教師ラベルの有無

機械学習には、大きく分けて、データに教師ラベルを必要としない教師なし学習と、教師ラベルを必要とする教師あり学習がある。

教師なし学習には、学習データに教師ラベルを付与する必要がないため、学習データの作成・収集が低コストであるという長所がある。教師なし学習の代表例としては、k-means 法などのクラスタリングが挙げられる。加速度センサデータにクラスタリングを適用すると、センサデータをバリアごとにグルーピングできると思われる。しかし、各データが何を表しているかを学習していないため、各グループがどのバリアに対応するか判断できない。このため、本研究の研究課題を達成するためには、教師なし学習だけでは不十分であると言える。

一方、SVM に代表される教師あり学習であれば、センサデータがどのバリアに対応するか一定の精度で推定できる。ただし、高精度な推定を行うためには教師ラベル付きデータが多く必要であり、それらを作成・収集するには大きなコストがかかるという問題がある。画像分類タスクのように、コミュニティが整備する教師ラベル付きデータセットを利用できるケースもあるが、本研究課題の達成に必要な歩行時の加速度センサデータにおいては、大規模な教師ラベル付きデータセットは著者らが調査するがぎり、存在していない。

この問題を解決する一手法として、教師ラベルなしデータ・教師ラベル付きデータの混在データから学習を行う半教師あり学習があり [26]、本研究のタスクにおいても適用できる可能性はある。この半教師あり学習とは仕組みは異なるが、多数の教師ラベルなしデータと少数の教師ラベル付きデータから高精度な推定を行うアプローチとして、Autoencoder [27] と教師あり学習器の組み合わせが考えられる。具体的には、Autoencoder を教師ラベルなしデータに適用して符号化器を獲得し、教師ラベル付きデータにこの符号化器を適用して次元削減したものを教師あり学習器の特徴量として利用する方法である。

上記の検討から、本研究では、教師ラベルなしデータ・教師ラベル付きデータの混在データから学習を行うアプローチをとることとする。

5.2 特徴量の設計

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を機械学習するアプローチが考えられる。

一方で、Deep Learning (深層学習、特徴表現学習) を用いて自動的に設計した特徴量を用いる機械学習方式もある。近年、この方式の性能が、人手で設計した特徴量を用いる機械学習の性能を凌駕する事例が、画像認識、音声認識、自然言語処理などの各分野で数多く報告されている。

上記の検討から、本研究では、人手で設計する特徴量を用いる機械学習に加え、Deep Learning で自動設計した特徴量を用いる機械学習についても実装・検証を行うこととする。以降、人手による特徴量設計の詳細を 5.2.1 節、Deep Learning による特徴量設計の詳細を 5.2.2 節にて述べる。

5.2.1 人手による特徴量設計

人手で設計した特徴量を機械学習する研究事例 [21][22][23][24][25] では、3 軸加速度センサで計測した加速度値の平均値・標準偏差や、軸間の相関係数などが特徴量として用いられている。また、時系列データである加速度値をフーリエ変換し、各周波数帯域の強度などの周波数特徴量を利用している事例もある。

本研究では、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。

5.2.2 Deep Learning による特徴量設計

Deep Learning とは、多層構造のニューラルネットワークを用いた機械学習のことであり、目的に応じて様々なネットワーク形態が存在する。本研究では、Deep Learning の一種であり、汎用的な特徴量抽出に利用可能な Denoising Autoencoder (以降、DAE) [28] を用いることとする。

図 4 は、DAE の最も単純なネットワーク形態である。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, L_2 の 2 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り、詳細は6章で述べる。

L_1 : x, y, z 軸の加速度センサデータを1次元に結合したものを入力する層である。

L_2 : L_1 に DAE を適用して次元削減した層であり、この過程で L_1 を次元削減するためのエンコーダ E を得る。

Fine-tuning 実施時には、上記で獲得した E を用いて加速度センサ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。

一方、図5は入力層が3要素に分離したネットワーク形態である。これは、加速度センサデータが x, y, z の直交する3次元データであることに着目し、マルチモーダルな Deep Learning のネットワークを構築している [29] などの研究事例を参考にして設計したものであり、 L_1 から L_4 の4層からなる。図中の各層に記載した次元数の詳細は6章で述べる。

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1次元に結合した層である。

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。




図4 単純な DAE

6. 検証実験

6.1 実験目的

本実験の目的は、5章で述べた各方式がどの程度の精度でバリアの存在を推定できるのか測定し、適切な推定方式を選択する判断材料を得ることである。




図5 入力層が3要素に分離した DAE

具体的には、3つの方式を比較する。1つ目は、5.2.1節の人手で設計した特徴量 (Hand-crafted Features) を用いる機械学習方式であり、これを HCF 方式とする。2つ目、3つ目は、5.2.2節の図4、図5のネットワークで自動設計した特徴量を用いる機械学習方式であり、それぞれ DAE1方式、DAE2方式とする。

6.2 データセット

4章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6cm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16cmの屋内の段差である。USR / DSR は高さ約16cmの段が20段程度続く屋内の階段である。PLD / PSD は手で引き開け・押し開けす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に示す山頂の公園に続く勾配約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させてスマートフォンサイズの専用デバイスを製作した。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。今回は基礎検討であることから、独立変数を減らすために、計測実施者は1人(男性、30代)とした。ズボンは計測時によって異なるが、サイズ・ポケット位置は概ね同じであった。靴は全計測を通じて同一のスニーカーを履いた。

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20サン

表 1 推定対象

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

ブル, 計 260 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. 教師なしデータは, 都内への通勤, 駅・商業施設・公園の散策などの日常生活における歩行を計測し, 計 55000 サンプルを収集した. これは, 我々が以前行なった実験 [1] のものよりも 20000 サンプルほど多いデータセットとなる.

6.3 実験手順

6.3.1 HCF 方式

教師ありサンプル 260 件のそれぞれについて 5.2.1 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 160 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 100 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.

6.3.2 DAE1・DAE2 方式

Pre-training では, 教師なしサンプルを training 用 50000 件と validation 用 5000 件に無作為に分割し, DAE による Deep Learning を行ってエンコーダを獲得する. このとき, DAE1 方式は図 4 のネットワークを用いてエンコーダ E を獲得する. 入力層 L_1 の次元数は 180 (20Hz, 3 秒分, 3 軸分) であり, L_2 の次元数は 130 である. DAE のパラメータはノイズ率 25%, ミニバッチサイズ 20, エポック数 100 である. DAE2 方式は図 5 のネットワークを用いてエンコーダ $E_{1,x}, E_{1,y}, E_{1,z}, E_2$ を獲得する. 入力層 L_1 の各要素の次元数は 60 (20Hz, 3 秒分) であり, L_2 の各要素は 50 である. L_3 は L_2 の各要素を 1 次元に結合するので 150 次元であり, L_4 は 130 次元である. $L_1 - L_2$ 間, $L_3 - L_4$ 間とも, DAE のパラメータはノイズ率 25%, ミニバッチサイズ 20, エポック数 100 である.

Fine-tuning は, 利用する特徴量以外は HCF 方式と同条

件にする. すなわち, 教師ありサンプル 260 件のそれぞれについて DAE1 方式はエンコーダ E , DAE2 方式はエンコーダ $E_{1,x}, E_{1,y}, E_{1,z}, E_2$ を用いて 130 次元に次元削減し, これを各サンプルの特徴量とする. 次に, 教師ありサンプルから学習用サンプル 160 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 100 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.

6.4 実験結果

各方式の推定精度 (100 試行の平均 F 値) を図 6 に示す. HCF 方式, DAE1 方式, DAE2 方式の間で t 検定を行ったところ, HCF 方式と DAE2 方式間, DAE1 方式と DAE2 方式間にそれぞれ 0.1% 水準で有意差がみとめられた. HCF 方式と DAE1 方式間には有意差がみとめられなかった.

次に, HCF 方式と DAE2 方式の対象ごとの推定精度 (100 試行の平均 F 値) を図 7 に示す. 対象ごとに見ると, HCF 方式の方が高精度の項目がいくつかあることが分かる. 各対象について, 方式間で t 検定を行うと, CRD と ULS を除く各対象において, 5% 水準で有意差がみとめられた.




図 6 各方式の推定精度 (F 値, N=100)




図 7 HCF・DAE2 方式の対象ごとの推定精度 (F 値, N=100)

6.5 考察

6.1 節で述べたように、今後研究を進める上で、どの推定方式を選択すればよいかという観点で考察を行う。

図 6 に示すように、全体的な推定精度では、HCF 方式と DAE1 方式に有意な差はみとめられなかった。これは、図 4 のように x, y, z 軸を区別せずに 1 次元に結合して入力する DAE で設計した特徴量は、人手で設計した特徴量と同程度にしか加速度データの特徴を表現できていないことを示唆している。一方で、DAE2 方式は、HCF 方式・DAE1 方式よりも 0.1 %水準で有意に高い推定精度を示した。これは、図 5 のように x, y, z 軸を区別して別々に入力する DAE で設計した特徴量は、人手で設計した特徴量よりも加速度データの特徴をよりの確に表現できていることを示唆している。

ただし、DAE2 方式が HCF 方式より全面的に優れているわけではない。具体的には、STN (石畳)、USR (階段(上り))、DLS (緩い坂(上り・下り))、UHS・DHS (急な坂(上り・下り))において、HCF 方式の方が 5 %水準で有意に高精度となっている。多くの推定対象で差の程度は大きくないが、UHS、DHS においては、それぞれ 1.20 倍、1.15 倍、HCF 方式が DAE2 方式よりも高精度である。この結果を導いた原因として、2 つの可能性が考えられる。1 つ目は、HCF 方式が用いる TD・FD 特徴量がこれらの対象を推定するのに効果的であるということである。2 つ目は、DAE 方式で用いた教師なしサンプルに、これらの対象を通過しているものが少量しか含まれていないため、うまく Pre-training できなかつたということである。計測実施者の日常生活の歩行時に教師なしサンプルを計測したが、実施者の生活圏には急坂がほとんど存在していなかった。これらの対象を通過時のサンプルを十分に含むデータセットを用いれば、DAE 方式の推定精度が向上する可能性は否定できない。今後さらにデータを集めて検証を行い、どちらか一方を用いる、あるいは、対象によって精度が高い推定方式を使い分けるなど、幅広い視野で検討を進める必要がある。

次に、推定に要するデータセットサイズについて考える。今回の実験では教師あり学習に用いたサンプル数は各方式とも 160 件である。教師あり学習に用いるサンプル数を 10 倍程度に増やせば、経験的には推定精度はあと数パーセントは向上すると思われる。教師ありサンプルを 2000 件程度集めることは、人的作業としては非現実的ではない。これに加え、DAE 方式は教師なし学習に用いるサンプルが必要である。今回の実験条件においては、55000 件(約 46 時間分の歩行に相当)のサンプルを収集した。一見、これだけのデータを収集する労力は膨大に感じられるかもしれないが、計測ソフトウェアをスマートフォンアプリケーションとして実装すれば、常時携行することが多いスマートフォンを計測装置として利用できるため、この程度のサ

ンプル数は収集可能であると思われる。

以上より、今回の検証実験からは次の結論が導かれる。

- バリア種類によって、HCF 方式と DAE2 方式の優劣は一定ではないため、さらに多くのサンプルを収集し、比較検証を続行する必要がある。
- 各バリアの存在を網羅的に高精度に推定するためには、HCF 方式と DAE2 方式をハイブリッドに用いるアプローチも考えられる。
- DAE2 方式は学習に数万件のサンプルを必要とするが、スマートフォンを利用するなどの工夫を行えば、収集は現実的である。

7. おわりに

本研究は、広域のバリア情報を高精度に収集するために、健常者歩行時のセンサデータから障害者に対するバリアの存在を推定する技術の確立を目指しており、現在は基礎検討の段階にある。本稿では、従来研究より細かい粒度で多様なバリアを推定対象として定義し、加速度データからバリアを推定するための機械学習手法を体系的に整理して検討した。その中から、人手で設計した特徴量を機械学習する方式(HCF 方式)と、Deep Learning で自動設計した特徴量を機械学習する方式(DAE1・DAE2 方式)については、検証実験を行なって推定精度を比較した。その結果、全体的には DAE2 方式が高精度(81.4%)で推定できるが、バリア種類によっては HCF 方式の方が高精度になることも分かった。

今後行うべきことは主に 2 つある。1 つ目は、より多くの実験データを収集して検証を重ね、HCF 方式と DAE 方式のどちらを用いるか、あるいは両方を併用するか見極め、さらなる精度向上を目指してアルゴリズム改良を行うことである。2 つ目は、フィールド調査や障害者へのヒアリングを行い、我々が推定しようとしているバリアが妥当であるか、あるいは他に推定すべきバリアは無いか、明らかにすることである。

参考文献

- [1] 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), Vol.2017-HCI-171, No.8, pp.1-8 (2017).
- [2] 国土交通省: 歩行空間ネットワークデータ整備仕様案(2010).
- [3] Sozialhelden e.V.: Wheelmap. <http://wheelmap.org> (last visited Dec. 1, 2016).
- [4] Miura, T., Yabu, K., Ikematsu, S., Kano, A., Ueda, M., Suzuki, J., Sakajiri, M. and Ifukube, T.: 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).
- [5] 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).

- [6] 山本千尋, 船越要, 小西宏志, 落合慶広, 川野辺彰久: パ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).
- [7] 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).
- [8] 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).
- [9] 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).
- [10] 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).
- [11] Mohan, P., Padmanabhan, V. N. and Ramjee, R.: Nerice: Rich Monitoring of Road and Traffic Conditions using Mobile Smartphones, Proc. SenSys'08, pp.323–336 (2008).
- [12] 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).
- [13] 石田真二, 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, No.2, pp.295–305 (2006).
- [14] 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).
- [15] 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).
- [16] 隅田康明, 松永勝也, 合志和晃, 志堂寺和則: 車いす使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, WIT2014-64, pp.63–68 (2014).
- [17] Kuwahara, N., Nishiura, M., Shiomi, Y., Morimoto, K., Iwakaki, Y. and Nishida, N.: A Study on a Ubiquitous System for Collecting Barrier-free Information of Evacuation Centers for Wheelchair Users, Proc. CASE-MANS'10, pp.36–39 (2010).
- [18] PADM: みんなでつくるパリアフリーマップ, <http://enigata.com/data/minna.bmap.pdf> (last visited Dec. 1, 2016).
- [19] 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).
- [20] Isezaki, T., Nijima, A., Miyata, A., Watanabe, T. and Mizuno, O.: Wheelchair Users' Psychological Barrier Estimation Based on Inertial and Vital Data, Proc. HCI'16, pp.403–413 (2016).
- [21] 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).
- [22] 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).
- [23] Brajdic, A. and Harle, R.: Walk Detection and Step Counting on Unconstrained Smartphones, Proc. UbiComp'13, pp.225–234 (2013).
- [24] 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, DICO'14, pp.258–265 (2014).
- [25] 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).
- [26] Chapelle, O., Schölkopf, B. and Zien, A.: Semi-supervised Learning, MIT Press (2006).
- [27] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, Science, Vol.313, Issue 5786, pp.504–507 (2006).
- [28] 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).
- [29] Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., and Ng, A. Y.: Multimodal Deep Learning, Proc. ICML'11, pp.689–696 (2011).