

推薦論文

直近移動能力を考慮した車椅子操作推定モデル

宮田 章裕^{1,†1,a)} 伊勢崎 隆司¹ 中野 将尚¹ 石原 達也¹ 有賀 玲子¹ 望月 崇由¹ 渡部 智樹¹
水野 理²

受付日 2015年12月19日, 採録日 2016年7月5日

概要: 車椅子ユーザの移動を妨げる“バリア”に関する情報を収集することが、社会的に求められている。しかし、既存手法では、電柱や道路工事などの路上物バリアを発見することは困難である。我々は、路上物バリアをよける・引き返すといった動作を構成する車椅子操作を推定できれば、操作の推定結果をもとに路上バリアの存在を検出できると考えている。このとき、操作推定は、多くのユーザが持つスマートフォン内蔵の加速度・角速度センサを利用して行えることが望ましい。ところが、車椅子操作時に発生する加速度・角速度は、同じ操作であってもユーザ・操作習熟度・状況によって大きく振舞いが異なり、単一の推定器では精度良く推定できないという問題がある。そこで、我々は、ユーザの直近の移動能力を推定した後に、その移動能力に適した推定器で操作内容を推定するアプローチを提案する。ディープラーニングを用いて提案コンセプトを実装し、ユーザの実走行データに基づいて構築した約 25 万件のデータセットを用いて実施した検証実験では、提案手法が前後進・右左折・停止などの操作を高精度に推定できるだけでなく、段差・傾斜の検出にも有効であり、適合率・再現率はともに 98.9%とベースライン手法を大きく上回った。提案手法は、バリア情報の収集に大きく貢献しうるものと考えられる。

キーワード：バリア，車椅子，センサ，ディープラーニング

A Wheelchair Motion Estimation Model Using the Recent Control Ability

AKIHIRO MIYATA^{1,†1,a)} TAKASHI ISEZAKI¹ MASANAO NAKANO¹ TATSUYA ISHIHARA¹ REIKO ARUGA¹
TAKAYOSHI MOCHIZUKI¹ TOMOKI WATANABE¹ OSAMU MIZUNO²

Received: December 19, 2015, Accepted: July 5, 2016

Abstract: It is socially desired to collect information on “barriers” that prevent free movement of wheelchair users. But, existing techniques have difficulty in detecting barriers on the road such as power poles and roadworks. We consider it is possible to detect barriers on the road by estimating wheelchair motions that constitute actions such as changing the course or turning back due to barriers. Here, it is deemed desirable to estimate wheelchair motions using the accelerometer/gyroscope in the smartphone that most users already have. However, a single estimator fails to estimate wheelchair motions with a high degree of accuracy. Because behaviors of acceleration and angular velocity vary according to the user, ability of controlling the wheelchair and situation even if the motion to be estimated is same. To address this problem, we propose a wheelchair motion estimation method that consists of two steps; in the first step, estimates the user’s ability of controlling the wheelchair, and in the second step, estimates the wheelchair motion using the suitable estimator for the ability. To conduct an evaluation task, we made a prototype system based on Deep Learning, and constructed a dataset of two hundred and fifty thousand motions extracted from actual wheelchair driving data. The result shows that the proposed method can estimate not only motions such as moving forward/backward, turning right/left and stop, but road conditions such as a step and slope, with an accuracy of 98.9 percent that greatly exceeds that of the baseline method. The proposal method is considered to contribute collecting barrier information.

Keywords: barrier, wheelchair, sensor, deep learning

1. はじめに

人の移動能力は年齢, 体力, 病歴などによって多様である。それゆえ, 健常者にとっては問題のない道でも, たとえば車椅子利用者にとっては通行できない道となりうる。この問題は世界共通であり, 歩道の幅・勾配・段差・路面平滑性に問題がある場合や, 通行部が違法駐輪や電柱などで塞がれている場合, 車椅子利用者は移動が困難/不可能になることが国内外で指摘されている [1], [2]。車椅子利用に適した歩道条件を抽出するための検証実験もいくつか行われており [3], これらの検証結果を反映した形で, 2006年の「高齢者, 障害者等の移動等の円滑化に関する法律 (バリアフリー新法)」の制定ともなって, 国土交通省は歩道構造に基準を設けた。基準では, やむをえない場合を除き, 通行幅は 2m 以上, 縦断勾配 5%以下・横断勾配 1%以下, 歩道と車道の接合部の段差は 2cm とされている [4]。しかし, 整備が追いついていない歩道が数多く存在しているのが現状であり, 図 1, 図 2 のように車椅子では通行が困難な場所が市街地に散見される。

このような状況に対応すべく, 一部のサービスでは歩道の段差有無, 坂の傾斜などの情報 (以降, バリア情報) を提供している [5]。しかし, これらのバリア情報は, サービス提供者が現地に赴いて収集していることが多く [6], [7], [8], [9], 情報収集の人的コストが高いため, バリア情報収集におけるエリアの網羅性・更新頻度が低くなりがちである。人的コストを低減させる方法としては, 多くのユーザが道路画像からバリアを発見するクラウドソーシング型の取り組み [10], [11], [12] が考えられるが, この場合は道路画像の撮影角度などの問題でバリア情報の正確性・種類の網羅性が高まりにくい。一方, 車椅子に装着したセンサデータに基づいてバリア情報を収集するアプローチ [16], [17], [18], [19] は, 車椅子利用者が通行するエリアの情報が網羅的に集められるうえ, 人手による作業が発生しないため情報の更新頻度も高いというメリットがある。しかし, 現時点では段差・傾斜しか検出できず, 電柱や道路工事, 放置されている違法駐輪などの路上物に起因するバリア (以降, 路上物バリア) を検出できないため, バリア情報の種類の網羅性は高いとはいえない。

そこで, 我々は, 多くのユーザがすでに持っているスマートフォンに内蔵されている加速度・角速度センサを利用して, 路上物バリアを高精度に検出することを研究課題とし



図 1 違法駐輪がある歩道

Fig. 1 An illegally-parked bike on the sidewalk.



図 2 電柱が通行幅を狭めている歩道

Fig. 2 A power pole that reduces the width of the sidewalk.

て設定する。この課題に対し, 路上物バリアをよける・路上物バリアのために引き返すといった動作を構成する前後進・右左折・停止などの車椅子操作を推定できれば, 操作の推定結果をもとに路上バリアの存在を検出できると考えられる。ただし, 操作時に発生する加速度・角速度は, 同じ操作であってもユーザ・操作習熟度・状況・体調によって大きく振舞いが異なるため, 単一の推定器では高精度に操作を推定することは難しい。この問題を解決するため, 我々は, ユーザの直近の移動能力を推定した後に, その移動能力に適した推定器で操作内容を推定する推定モデルを提案する。

本論文の貢献を下記に示す。

- 車椅子利用者の移動の妨げとなる路上物バリアを検出するための, ユーザの直近移動能力を考慮した高精度な車椅子操作推定モデルを考案したこと。
- 大規模データセットを構築して上記モデルの検証を行い, 操作内容を適合率・再現率 98.9%の高精度で推定できることを実証したこと。

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
NTT Service Evolution Laboratories, NTT Corporation,
Yokosuka, Kanagawa 239-0847, Japan

² 日本電信電話株式会社 NTT 知的財産センタ
NTT Intellectual Property Center, NTT Corporation,
Musashino, Tokyo 180-8585, Japan

^{†1} 現在, 日本大学
Presently with Nihon University

a) miyata.akihiro@nihon-u.ac.jp

本論文の内容は 2015 年 7 月のマルチメディア, 分散, 協調とモバイル (DICOMO2015) シンポジウムにて報告され, グループウェアとネットワークサービス研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

2. バリア情報収集に関する研究事例

2.1 人間が現地で判断するアプローチ

人間が現地で判断するアプローチとして、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 [6], [7], [8], [9]. 文献 [6], [7] 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。文献 [8] 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。文献 [9] 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がい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。

2.2 人間が遠隔地で判断するアプローチ

人間が遠隔地で判断するアプローチとして、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・収集する事例がある [10], [11], [12]. 文献 [10], [11], [12] 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法を提案している。現地に赴かずに写真だけで判断しているが、文献 [10] では情報の正確性は 93% であるとしている。

2.3 センサを利用して自動判断するアプローチ

センサを利用して自動判断するアプローチとして、車椅子に装着したセンサデータに基づいて路面状態を評価する試みが古くから行われている [13], [14], [15]. 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がある [16], [17], [18], [19]. 文献 [16] は SVM を用いて加速度データから段差・傾斜の有無を推定しており、段差であれば適合率 94%, 再現率 52% で検出できる。文献 [17] 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。文献 [18] 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適合率 85% で推定している。文献 [19] 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。

3. 研究課題

3.1 問題の定義

日本のバリアフリー新法 [4] や米国運輸省によるガイドライン [2] では、歩道の幅・勾配・段差・路面平滑性が不適切な場合や、通行部が放置物などで塞がれている場合、車椅子での通行が困難になるとしている。我々が車椅子利用者数名にヒアリングしたところ、同様のコメントが得られた。これらの情報に基づき、本研究では車椅子通行時におけるバリアを下記のように定義する。

路面状態バリア：路面自体の幅・勾配・段差・平滑性などの路面状態に起因するバリア。

路上物バリア：電柱や道路工事、放置されている違法駐輪などの路上物に起因するバリア。

車椅子利用者の移動に役立つバリアフリーマップを作成するためには上記のバリアに関する情報（以降、バリア情報）を収集する必要がある。ここで、2章で紹介した研究事例について、バリア情報の正確性、バリア情報の種類の網羅性、バリア情報を収集するエリアの網羅性、バリア情報の更新頻度の観点で整理する。

まず、2.1 節の人間が現地で判断するアプローチ [6], [8], [9] は、人が現地に赴いて実際に道を移動しながらバリア情報を発見・収集するので、路面状態バリア・路上物バリアともに正確性・種類の網羅性は高いといえる。逆に、人が現地で意図的に発見・収集作業を行わなければならないため人的コストが高く、エリアの網羅性・更新頻度は低くなりがち傾向が見受けられる。たとえば、文献 [6], [7] では行政スタッフが現地でバリア情報を収集していると思われるが、取り組みが始まって数年で収集されたデータは大都市圏の数カ所（1カ所は半径数キロ程度）の比較的大きな通りに関するもののみである。行政主導ではなく、一般市民にバリア情報の発見・収集を促す方法 [8], [9] もあるが、ユーザがスマートフォンや PC などシステムにアクセスしてからバリア情報を投稿する必要があり、仕事や買い物などで市街地を移動している最中、バリアを見つけるたびに投稿する作業を多くのユーザ（特に両手が塞がりやすい車椅子利用者）が行うとは考えにくく、やはりエリアの網羅性・更新頻度は高まりにくいと思われる。たとえば文献 [8] で東京駅に登録されているバリア情報は 2015 年 4 月時点で数件である。

また、2.2 節の人間が遠隔地で判断するアプローチ [10], [11], [12] では、インターネットが利用できる人であれば誰でも自宅などからバリア情報を発見・投稿できるため 2.1 節のアプローチより人的コストが低く、エリアの網羅性が高まりやすい。一方で、ユーザは Google Street View 上の道路画像だけからバリア情報を探するため、撮影角度や写り込んだ自動車などのオクルージョンの影響で、見えにくい/見えないバリアも少なくないと思われる。このため、特に路面状態バリアについては見誤り・見落としが起りやすく、正確性・種類の網羅性は低いと考えられる。さらに、道路画像の更新頻度は数年単位であるエリアが多く、更新頻度は低いといえる。

一方、2.3 節のセンサを利用して自動判断するアプローチ [16], [17], [18] では、段差であれば適合率 94% [16], 傾斜であれば適合率 85% [18] で推定でき、正確性は高いといえる。しかし、文献 [16], [17], [18] が対象としているバリアが路面状態（段差、傾斜など）のみであり、路上物バリア

表 1 バリア情報収集アプローチの比較

Table 1 The comparison of approaches for collecting barrier information.

アプローチ	正確性	種類の網羅性	エリアの網羅性	更新頻度
人間が現地判断	高い	高い	低い	低い
人間が遠隔地判断	低い	低い	高い	低い
センサで自動判断	高い	低い	中程度	高い

アの発見をサポートしていないことから、種類の網羅性は低いといえる。車椅子で走行する必要があるため、エリアの網羅性は高いとはいえないが、逆にいえば、車椅子ユーザが通行するエリアについてはバリア情報が収集できるので、エリアの網羅性は中程度であるといえる。また、車椅子ユーザが各エリアを通行するたびに最新のバリア情報を収集できるので、更新頻度は高いといえる。

このように、既存手法では正確性、種類の網羅性、エリアの網羅性、更新頻度のすべてを中程度から高い範囲で実現することは困難であるという問題がある。これをまとめると、表 1 のようになる。

3.2 研究課題の設定

前節で述べた既存手法のうち、人間が現地で判断するアプローチを改善するためには、スタッフが赴くエリアを拡大したり（エリアの網羅性の向上）、調査の頻度を上げたり（更新頻度の向上）する必要がある。また、人間が遠隔地で判断するアプローチを改善するためには、道路をより多くの角度から高解像度で撮影したり（種類の網羅性の向上）、撮影頻度を上げたり（更新頻度の向上）する必要がある。すなわち、人間が現地/遠隔地で判断するアプローチは、どちらも大きな人的コストをかけなければ解決が難しい問題である。

一方、センサを利用して自動判断するアプローチは、センサを用いて路上物バリア情報を自動収集できれば種類の網羅性を向上させることができ、大きな人的コストをかけずに正確性、種類の網羅性、エリアの網羅性、更新頻度を中程度から高い範囲で実現できる可能性がある。ただし、車椅子ユーザが新たに用意しなくてはならないセンサを用いてしまうと、多くのユーザに利用してもらえず、エリアの網羅性が低減してしまうと思われる。やはり、既存手法 [16], [17], [18], [19] と同様に、多くのユーザがすでに持っているスマートフォンに内蔵されているセンサを用いる必要があると考えられる。

上記の検討に基づき、スマートフォン内蔵センサを用いて路上物バリアを高精度に検出することを研究課題として設定する。

4. 提案方式

我々は、3.2 節で設定した研究課題に対して、スマート




図 3 よける動作
Fig. 3 Avoid an object.

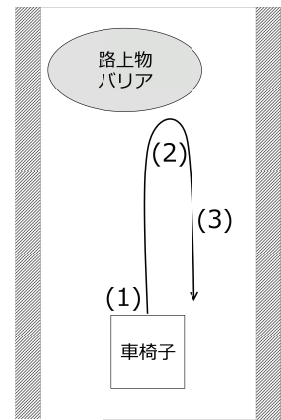


図 4 引き返す動作
Fig. 4 Turn back.




図 5 停止して左折する場合
Fig. 5 Stop, then, turn left.




図 6 停止せず左折する場合
Fig. 6 Turn left without stopping.

フォンに内蔵されている加速度センサ・角速度センサを用いて路上物バリアの存在を検出するアプローチをとる。図 3, 図 4 に典型的な路上物バリアとそれに対する車椅子の動作の例を示す。図 3 は路上の一部が電柱や道路工事などで塞がれているためよけて通る例である。この動作は、細かく見ると (1) 前進, (2) 右折, (3) 左折, (4) 前進の操作から構成されているととらえることができる。また、図 4 は路上に放置自転車が倒れているなどの理由で通行を諦めて引き返す例である。こちらも、細かく見ると (1) 前進, (2) 停止, (3) 後進の操作から構成されているととらえることができる。すなわち、センサデータから前後進・右左折・停止といった車椅子の操作を精度良く推定できれば、これらの操作の組合せである路上物バリアに対処する動作が発生したこと (= 路上物バリアが存在すること) を的確に検出できると思われる。

しかし、このアプローチには 1 つ問題がある。それは、車椅子ユーザの操作習熟度によって、同じ操作でも観測されるセンサデータの振舞いに大きな差があるということである。たとえば、電動車椅子操作の習熟度が異なるユーザが同じ角を左折した場合に観測されたセンサデータを図 5, 図 6 に示す。破線は前後軸の加速度であり、減速すると負の方向に値が変化する。実線は上下軸周りの角速度であり、左折すると負の方向に値が変化する。操作に不慣れな




図 7 学習フロー

Fig. 7 The flow of learning.




図 8 推定フロー

Fig. 8 The flow of estimation.

ユーザはいったん停止してから左折していたため、図 5 のように前後軸の加速度が大きく負の方向に変化した後に、上下軸周りの角速度が負の方向に大きく変化していた。一方、操作に慣れているユーザは角の手前からスムーズに減速して停止することなく左折を行っていたため、図 6 のように前後軸の加速度・上下軸周りの角速度はともに滑らかに負の方向に変化していた。このように、同じ操作であっても観測されるセンサデータの振舞いがユーザによって大きく異なるため、センサデータから操作内容を高精度に推定することが難しい可能性がある。また、1 人のユーザが行う同じ操作であっても、短期的には状況（急いでいる/のんびりしているなど）や体調（元気/疲れているなど）によって、長期的には操作習熟度の変化（不慣れ/慣れてきたなど）によって、観測されるセンサデータの振舞いが異なることが想像される。

そこで我々は、車椅子を操作して移動する能力（以降、移動能力）は操作習熟度や状況、体調などによって変化すると仮説を立て、ユーザの直近の移動能力を推定した後に、その移動能力に適した推定器で操作内容を推定する推定モデルを提案する。直近の移動能力を推定する材料として、車椅子の移動に左右変化が生じている期間のセンサデータを用いる。なぜならば、ただまっすぐ前進するなどの単純な操作より、左右に曲がるなどの操作の方が、移動能力の差が現れやすいと思われるためである。車椅子の移動に左右変化が生じていることは、上下軸周りの角速度（Vertical angular velocity, 以降、VAV）の変化の有無から容易に検出できる。提案方式を具体化すると、下記の学習フロー（図 7）・推定フロー（図 8）のようになる。

学習フロー：

L1) できるだけ多くのユーザから、一定時間（例：1 時間、半日）連続して車椅子を操作した際の加速度・角速度の生

センサデータ群 $D = \{d_{(1)}, d_{(2)}, \dots\}$ を収集する。各生センサデータ $d_{(i)}$ 内部には、どの時間に何の操作（例：前進、左折）をしていたか示すラベルが 1 つ以上付与されているものとする。

L2) 各生センサデータ $d_{(i)} \in D$ 内で移動能力が一定と見なせる連続期間のデータを“シーケンスデータ”と定義し、 $d_{(i)}$ を 1 つ以上のシーケンスデータ群 $\{s_{(i,1)}, s_{(i,2)}, \dots\}$ に分割する。分割方法としては、 $d_{(i)}$ を一定時間（例：10 分）ごとに区切る方法や、特徴的なイベント（例：入店する、雨が降り出す）で区切る方法が考えられる。これをすべての $d_{(i)} \in D$ に対して行い、シーケンスデータ群 $S = \{s_{(1,1)}, s_{(1,2)}, \dots, s_{(2,1)}, s_{(2,2)}, \dots, s_{(i,j)}, \dots\}$ を作成する。

L3) 各シーケンスデータ $s_{(i,j)} \in S$ について、VAV の絶対値が閾値を超えている区間の加速度・角速度センサデータの特徴量（例：振幅特徴量、周波数特徴量）を求め、この特徴量を用いて既存クラスタリング手法でシーケンスデータ群 S を 2 つ以上のグループ群 $G = \{g_{(1)}, g_{(2)}, \dots, g_{(k)}, \dots\}$ にクラスタリングする。

L4) シーケンスデータ $s_{(i,j)} \in g_{(k)}$ の内部で操作内容を示すラベルが付与されている区間の加速度・角速度センサデータを“操作データ”と定義し、各グループ $g_{(k)} \in G$ について、 $g_{(k)}$ に含まれる全シーケンスデータの内部から操作データ群 $A_{(k)} = \{a_{(k,1)}, a_{(k,2)}, \dots\}$ をすべて抽出する。既存機械学習手法を用いて、抽出した $A_{(k)}$ に対して学習を行い、センサデータから操作内容を推定する操作推定器を構築する。このとき、グループごとに操作推定器を構築していることがポイントである。

推定フロー：

E1) あるユーザがある時刻に行った操作を推定対象とするとき、当該時刻のセンサデータを推定対象操作データ $a'_{(x)}$ として取得する。たとえば、一定時間ごとに固定長のセンサデータを取得する方法が想定できる。L1 における $a_{(x)}$ と異なり、 $a'_{(x)}$ には操作を示すラベルは付与されていない。また、当該時刻直近のシーケンスデータ $s_{(x)}$ を取得する。シーケンスデータの定義は L2 と同じであり、当該時刻を含むシーケンスデータ s_{now} を取得してもよいし、 s_{now} のデータ長が規定値に満たない場合は s_{now} の 1 つ前のシーケンスデータ s_{prev} を取得してもよい。

E2) 移動能力グループ推定器は、シーケンスデータ $s_{(x)}$ 内で VAV の絶対値が閾値を超えている区間の加速度・角速度センサデータの特徴量を L3 と同じ方法で求め、この特徴量を用いて $s_{(x)}$ が属する移動能力グループ $g_{(k)}$ を推定する。たとえば、L3 でセントロイド法のクラスタリングを行った場合、 $s_{(x)}$ と $g_{(1)}, g_{(2)}, \dots$ の各セントロイドの特徴量の類似度を算出し、最も類似度が高いセントロイドが属するグループ $g_{(k)}$ に $s_{(x)}$ も属すると推定できる。

E3) E2 で推定した移動能力グループ $g_{(k)}$ に専用の操作推

定器 (L4 で構築) に推定対象操作データ $a_{(x)}$ を入力し、ユーザが行った操作を推定する。

5. 検証実験

5.1 実験の目的・手順

本実験の目的は、4章で提案した推定モデルによる操作推定精度を検証することである。

実験場所は図9のような屋外の私有地である。路面はタイル舗装 (タイルの1辺は15cm) されており、平坦な場所のほかに、傾斜 (斜度約2度) や段差 (高さ約2cm) があり、一般的な公共空間の道路に準ずる環境である。ここに、既存の柵や工事現場用の柵を用いて図10のような実験コースを作成した。コース内の道幅は、文献[4]が推奨する最低限の幅である約2mとした。

被験者には、図10中の矢印のようにコースを往復するよう指示した。図中のアルファベット3文字は、コース中の各場所で実施するよう被験者に指示した車椅子操作であり、表2に一覧した。このようにコースを進むことで、図1・2のような路上物バリアがある場合に行う「直進→停止→左旋回→直進」といった一連の操作 (平地の行き止



図9 実験場所

Fig. 9 The experiment field.

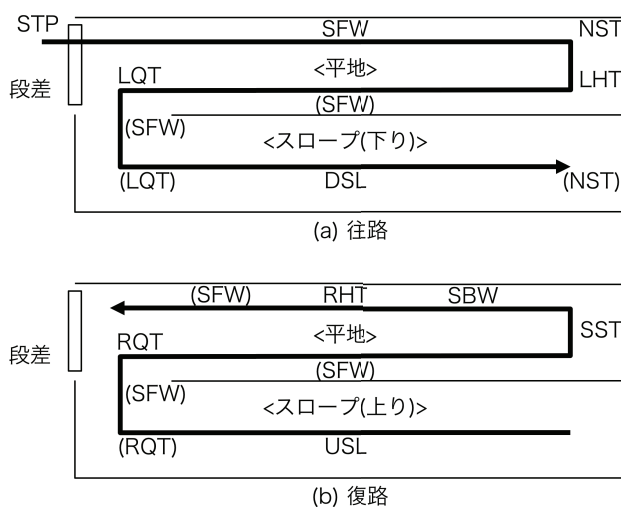


図10 実験コース

Fig. 10 The experiment course.

まり部分) や、図3・4の動作を構成する前後進、右左折などの各操作をすべて実行することになる。また、既存研究[16], [17], [18]が取り組んでいる路面状態バリアも提案手法で検出可能か確認するため、段差、上り坂、下り坂を進む操作もコース内で実施するようにした。なお、いくつかの操作はコース中に複数回発生しているため、図10中の括弧で囲んだ操作は後述の検証には用いていない。

車椅子には、電動車椅子 WHILL [21] を利用した。車椅子の座面後部にはスマートフォン (Sony Xperia A) を装着した。その際、スマートフォン内部の加速度センサ・角速度センサのx軸正の方向が車椅子の前方向、y軸正の方向が車椅子の左方向、z軸正の方向が車椅子の上方向になるようにした。スマートフォンには、加速度・角速度を12.5Hzのサンプリングレートで記録するアプリケーションをインストールした。

被験者は20名 (20~30代、女性4名、男性16名) である。全員、車椅子を操作するのはほぼ初めてであったため、5分ほどのレクチャ・操作練習を行い、意図どおりの走行ができるようにした。加速度・角速度、および、どの時間帯にどの操作をしていたかを記録しながら、各被験者に実験コースを5周してもらった。

5.2 データセット

被験者の実験コース走行により、被験者が各操作を行っている際の操作データの集合 (以降、観測データ集合) を取得した。20被験者が11操作を含むコースを5周したので、観測データ集合のサイズは100周分、1,100件である。このサイズは既存研究[16], [17], [18]と比較して大きいサイズであるが、一般的な機械学習タスクのデータセットとしてはやや小さい。

そこで、データセットのサイズを大きくするため、観測データ集合内の各操作データに対して、データ長の変化、振幅の変化、ノイズ付加を実施して新たな操作データの集合 (以降、拡張データ集合) を構築した。データ長の変化は

表2 操作一覧

Table 2 The list of wheelchair motions.

操作名	内容
前進 (SFW)	車椅子をまっすぐ前に進める操作
後進 (SBW)	車椅子をまっすぐ後に進める操作
左折 (LQT)	90度左に曲がる操作
左旋回 (LHT)	左回りにUターンする操作
右折 (RQT)	90度右に曲がる操作
右旋回 (RHT)	右回りにUターンする操作
停止 (NST)	前進中に車椅子をゆっくり止める操作
急停止 (SST)	前進中に車椅子を急に止める操作
段差 (STP)	段差を乗り越える操作
上り坂 (USL)	上り坂を進む操作
下り坂 (DSL)	下り坂を進む操作

表 3 操作データのフォーマット
Table 3 The format of motion data.

項目	内容
操作ラベル	11 操作ラベルのいずれか 1 つ
ax	加速度 x 軸のセンサデータ
ay	加速度 y 軸のセンサデータ
az	加速度 z 軸のセンサデータ
gx	角速度 x 軸のセンサデータ
gy	角速度 y 軸のセンサデータ
gz	角速度 z 軸のセンサデータ

(ax~gz はそれぞれデータ長 447 の配列)

3 パターン (0.8 倍, 1 倍, 1.2 倍) 行った^{*1}. 全時間帯のセンサ計測値間を線形補間してリサンプリングすることで, データ長を変化させた. 振幅の変化は 3 パターン (0.8 倍, 1 倍, 1.2 倍) 行った^{*1}. 全時間帯のセンサ計測値に変化率を乗じることで, 振幅を変化させた. ノイズ付加は, 一定割合 (5 パターン: 5%, 10%, 20%, 30%, 40%) のセンサ計測値について, 値を一定比率 (5 パターン: 5%, 10%, 20%, 30%, 40%) 増減させる (増えるか減るかはランダムに決定) ことで実現した. なお, データ長変化・振幅変化・ノイズ付加においてセンサ計測値を変化させる際, 変化のパターンの組合せは各加速度軸・角速度軸で共通とした. 上記処理により, 1 件の観測データから $3 \times 3 \times 5 \times 5 = 225$ 件の擬似的な操作データが生成されることになる. 観測データはコース 100 周分, 1,100 件の操作データがあったので, コース 22,500 周分, 247,500 件の擬似操作データからなる拡張データ集合を作成できた.

以降, 観測データ集合と拡張データ集合をマージした 22,600 周分, 248,600 件の操作データからなるデータ集合をデータセットと称する. データセット内の各操作データのフォーマットを表 3 に示す. ax~gz は平均 0, 分散 1 になるよう正規化してあり, データ長はデータセット中最大の操作データにあわせて 447 にそろえた (データ長がこれに満たない場合は後部に 0 をパディングした).

5.3 提案手法の検証手順・実装

検証は 4 章の学習フロー・推定フローに沿って 10 試行実施した. 本実験の固有条件・実装は下記のとおりである. なお, 各フローの詳細は 4 章を参照されたい.

学習フロー:

- L1) 5.2 節のとおりである.
- L2) シーケンスデータの期間は, 実験コースを 1 周走行する期間と同一とした. すなわち, シーケンスデータは 22,600 件 (1 シーケンスあたり 11 件の操作データを含ん

^{*1} 1 倍とは変化を加えないことと同義である. データ長変化, 振幅変化, ノイズ付加の各パターンを網羅的に組み合わせることを考慮し, 便宜上 1 倍の変化という処理を設けた. これにより, たとえば, データ長 1 倍, 振幅 1 倍, ノイズ付加は 5% のセンサ計測値を 5% 増加させるという擬似操作データが生成される.




図 11 構築したニューラルネットワーク
Fig. 11 The neural network for the experiment.

でいる) 得られた. これを, 学習フロー用の 20,000 件と推定フロー用の 2,600 件にランダムに分離した.

L3) VAV の絶対値の閾値は 1.0, 1.5, 2.0^{*2} の 3 種類を用いた. 加速度・角速度の特徴量は, ax~gz の各軸間の相関係数, 各軸の振幅絶対値の合計, 各軸の各周波数帯域 (0~6 Hz, 1 Hz 刻みで 6 区間) の強度を用いた. クラスタリング手法は, 凝集型階層クラスタリングを用い, 移動能力グループ数 (クラスタ数) は 2~6 の各場合を検証対象とした. これにより, 学習フロー用シーケンスデータ 20,000 件を 2~6 個の移動能力グループに分割した.

L4) 各移動能力グループともグループ内からランダム抽出した 15,000 件の操作データを学習に用いた. 機械学習手法は, ディープラーニングの 1 つである Stacked Denoising Autoencoders [20] による 5 層ニューラルネットワークを用いた (図 11). 各層の活性化関数にはシグモイド関数, 出力層には多クラス分類器の 1 つである多次元ロジスティック回帰を用いた. ニューラルネットワークの入力フォーマットは, 表 3 に示す操作データの ax~gz の 6 軸のセンサデータ (各軸 447 サンプル) をそのまま連結した 2,682 次元のデータ列とした^{*3}. このニューラルネットワークを用いて, 移動能力グループごとに操作推定器を構築した.

推定フロー:

- E1) 推定フロー用シーケンスデータ 2,600 件に含まれる操作データ 28,600 件の中からランダムに抽出した 1,000 件を推定対象操作データとした. シーケンスデータ $s(x)$ は推定対象操作データ $a(x)$ が発生した時刻を含むシーケンスデータ s_{now} を用いた.
- E2) VAV の絶対値の閾値, 特徴量は L3 と同じである. $s(x)$

^{*2} データセットは平均 0, 分散 1 となるように正規化されているため, 閾値に単位はない.

^{*3} Stacked Denoising Autoencoders を用いたディープラーニングはほぼ生に近いデータ列を入力しても高精度な推定ができることが画像処理, 自然言語処理の各分野で確認されているため, センサデータから特徴量を抽出して入力に用いることはしなかった.

が属する移動能力グループを決定するやり方は4章記載の方法と同様に、 $s_{(x)}$ と各移動能力グループのセントロイドの特徴量のコサイン類似度を算出し、類似度が最高となったグループに $s_{(x)}$ が所属していると決定した。

E3) E2で決定したグループの操作推定器に推定対象操作データ $a_{(x)}$ をL4と同じフォーマットで入力して操作ラベルを推定した。

5.4 ベースライン手法の検証手順・実装

ベースライン手法としては、既存研究 [16], [17], [18] のように単一の操作推定器を構築する方法を用いた。具体的には、下記の手順を10試行を行った。

学習フロー：

BL1) 5.2節で構築したデータセットからランダムに15,000件の操作データを抽出した。

BL2) 5.3節L4と同じ構成のニューラルネットワークにBL1の操作データを入力して操作推定器を構築した。

推定フロー：

BE1) BL1とは別にデータセットからランダムに抽出した1,000件の操作データをBL2で構築した操作推定器に入力して操作ラベルを推定した。

5.5 結果・考察

提案手法・ベースライン手法で操作ラベル推定を行った結果の適合率を図12、再現率を図13に示す。グラフの数値はすべて10試行の平均値である。提案手法は、VAVの絶対値の閾値 th を1.0, 1.5, 2.0に変化させた場合と、移動能力グループ数 k を2~6に変化させた場合をすべてプロットしている。グラフを見ると、 $th \cdot k$ がどの場合でも提案手法がベースライン手法を適合率・再現率ともに上回っており、 $th=2.0, k=6$ の場合が適合率・再現率ともに98.9%と最高値となることが分かる*4。

全体的に、 th を大きく、すなわち、車椅子がより大きく左右に変化した部分のセンサデータのみを用い、 k を大きく、すなわち、多くの移動能力グループに細かく分割した方が、適合率・再現率とも向上する傾向が見受けられる。この傾向が普遍的なものであるのか、より多様な $th \cdot k$ で検証を行う必要があると考えられる。

次に、提案手法で $th=2.0, k=6$ とした場合について分析を深める。まず、移動能力に基づくグループ分け(学習フローL3)について、各グループ内のデータがどの被験者(被験者U1~20)の何周目(1~5)の操作データであるか(あるいは、どの被験者の何周目の操作データから生成し

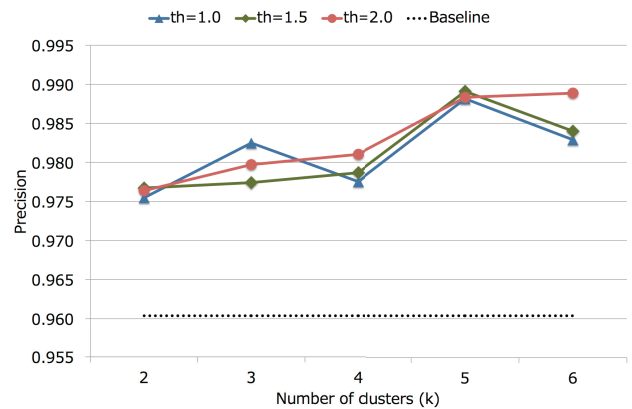


図12 各手法の適合率 (全操作の平均)

Fig. 12 The precisions of each method (the avg. of all motions).




図13 各手法の再現率 (全操作の平均)

Fig. 13 The recalls of each method (the avg. of all motions).

た擬似操作データであるか) 調査した。6つのグループをG1~6としたとき、G1は被験者U1の(擬似)操作データが40%以上を占めていた。U1は電動カートの経験があり、実験者が客観的に見ても電動車椅子をうまく乗りこなしていた被験者である。G2は被験者U2・U3の(擬似)操作データが35%以上を占めていた。U2・U3は乗り物操作が苦手と自己申告しており、直進路を蛇行してしまうなど、かなり車椅子操作に苦労していた被験者である。G3・G4・G5は各被験者の(擬似)操作データがほぼ均等に含まれており、G3は1周目、G4は2周目、G5は5周目のデータが大半を占めていた。実験時の観察においては、各被験者とも、1周目はコース初体験のため操作は不慣れであったが、2周目から5周目にかけてはコース・操作への慣れが発生していた。G6は各被験者の1~5周目の(擬似)操作データがほぼ均等に含まれており、G1~G5にあてはまらないデータによるグループであると思われる。上記のように、特に操作がうまい/へたな被験者のデータが大半を占めるグループ(G1, G2)や、特定の試行(1周目, 2周目, 5周目)のデータが大半を占めるグループ(G3, G4, G5)が形成されていることから、今回の検証実験では、移動能力に基づくグループ分けができていたと考えられる。

*4 提案手法・ベースライン手法とも、推定誤りとなった操作データの操作者が特定被験者に偏ることはなかった。ここから、特定被験者の操作に極端な癖があり、実験結果全体に悪影響を与えるといった事態は発生していないことが確認できた。

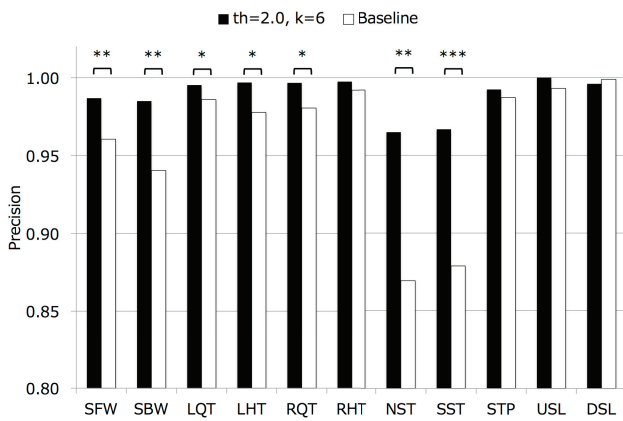


図 14 各手法の適合率 (操作別)

Fig. 14 The precisions of each method (by motion).




図 15 各操作の再現率 (操作別)

Fig. 15 The recalls of each method (by motion).

図 14, 図 15 に示すのは, 提案手法で $th=2.0, k=6$ とした場合とベースライン手法の操作別の適合率と再現率である。5%水準で t 検定を行ったところ, 全操作を平均した適合率・再現率において, 提案手法がベースライン手法を有意に上回っていた。個別の操作については, 適合率で有意に差が認められたのは SFW・SBW・LQT・LHT・RQT・NST・SST, 再現率で有意に差が認められたのは SFW・SBW・LQT・NST・SST・STP であり, これらはすべて提案手法がベースライン手法を上回っていた。路上物バリアをよける動作や, 路上物バリアのため引き返す動作に必要な前後進・右左折・停止・急停止などの操作を検出するうえで, 提案手法が一定の有効性を示せたといえる。さらに, 提案手法はベースラインと同等の高い適合率・再現率で STP・USL・DSL を推定できたことから, 提案手法は路面状態バリアの検出にも十分利用可能であると思われる。

6. おわりに

車椅子ユーザの移動を妨げるバリアの情報を正確・網羅的・高頻度に収集することが困難であるという問題をふまえて, スマートフォン内蔵センサを用いて路上物バリアを高精度に検出することを研究課題として設定した。この課題

に対し, 本研究では, 路上物バリアをよける・路上物バリアのために引き返すといった動作を構成する前後進・右左折・停止などの車椅子操作を推定するアプローチをとった。操作時に発生する加速度・角速度は, 同じ操作であってもユーザ・操作習熟度・状況・体調によって大きく振舞いが異なるため, 我々は, ユーザの直近の移動能力を推定した後に, その移動能力に適した推定器で操作内容を推定する推定モデルを提案した。ユーザの実走行データに基づいて構築した約 25 万件のデータセットを用いて実施した検証実験では, 提案手法が前後進・右左折・停止などの操作を高精度に推定できるだけでなく, 段差・傾斜の検出にも有効であり, 適合率・再現率はともに 98.9%とベースライン手法を大きく上回った。提案手法は, バリア情報の収集に大きく貢献するものと考えられる。

ただし, いくつか課題が残っている。まず, センサデータからノイズを取り除く技術を確立する必要がある。検証実験ではセンサを内蔵したスマートフォンを車椅子に固定したため, 安定的にセンサデータが取得できた。しかし, 実利用シーンではスマートフォンはユーザのポケットや鞆に入っていて固定されていないため, センサデータには多くのノイズが混じる。この問題を解決するためには, 角速度センサでスマートフォンの現在姿勢を常時監視し, 計測するセンサデータに補正をかけるアプローチが考えられる。

提案手法の操作推定の適合率・再現率についてはともに 98.9%となったが, これは擬似操作データからなる拡張データ集合を含む検証用のデータセットにおいて観測された数値であることに注意されたい。今後は大量に車椅子操作データを収集し, 実際の操作データのみからなるデータセットに提案手法を適用した場合の適合率・再現率を測定する必要がある。

シーケンスデータをクラスタリングする際に用いる VAV の閾値 th とグループ数 k については, 今回の 20 被験者による操作データを用いた検証条件では $th=2.0, k=6$ が最適であったが, より多くの車椅子ユーザの操作データを用いた場合には最適値が異なる可能性がある。本技術を実サービスに適用する際には, より大規模なデータセットに基づいて適切な th, k を求める必要があると思われる。

また, 操作の推定結果から, 路上物バリアの存在を高精度に推定する手法を確立する必要がある。たとえば, 路上で停止して引き返す操作が発生すれば, そこには通行を妨げる路上物バリアがある可能性が高いと思われるが, もしかしらユーザが忘れ物に気付いて引き返すだけかもしれない。この問題を解決するためには, 複数のユーザの操作を集計し, 多くのユーザが引き返す場所は路上物バリアが存在する可能性が高いと判断するなどのアプローチが考えられる。

今後は, 上記課題の解決に取り組むとともに, 生体センサなども利用して [22], より多様なバリアの検出にも取り

組む予定である。また、東京駅丸の内エリアなど実ワールドにおける検証 [23] も進めており、車椅子ユーザが安心して移動できる世界の実現に向けて、取り組みをいっそう加速していきたい。

参考文献

- [1] 中川伸一, 栗山 清, 小笠原章, 横山 哲: 「人にやさしい道路」を目指して, 土木計画学論文集, No.12, pp.775-786 (1995).
- [2] U.S. Department of Transportation: Designing Sidewalks and Trails for Access (1999).
- [3] 鍋島益弘, 山田 優: 車いすを利用する高齢者のための歩道構造に関する研究, 土木学会論文集, Vol.2003, No.725, pp.157-169 (2003).
- [4] 国土交通省: 基準移動等円滑化のために必要な道路の構造に関する基準に定める省令 (2006).
- [5] 国土交通省: バリアフリー経路探索, 入手先 (<http://www.hokokukan.jp/routeseach/areaselect.html>) (参照 2015-04-01).
- [6] 国土交通省: 歩行空間ネットワークデータ整備仕様案.
- [7] 国土交通省: 歩行空間ネットワークデータダウンロード, 入手先 (https://www.hokokukan.go.jp/download/download/nwdata_download.html) (参照 2015-04-01).
- [8] Sozialhelden e.V.: Wheelmap, available from (<http://wheelmap.org>) (accessed 2015-04-01).
- [9] 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, *SMC'12* (2012).
- [10] Hara, K., Le, V. and Froehlich, J.: Combining Crowdsourcing and Google Street View to Identify Street-level Accessibility Problems, *CHI'13* (2013).
- [11] 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).
- [12] 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, No.6, pp.1007-1016 (2010).
- [13] 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).
- [14] 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).
- [15] 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).
- [16] 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).
- [17] 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, 電子情報通信学会技術研究報告 (WIT), Vol.114, No.357, pp.63-68 (2014).
- [18] Kuwahara, N., Nishiura, M., Shiomi, Y., Morimoto, K., Iwawaki, Y. and Nishida, N.: A Study on a Ubiquitous System for Collecting Barrier-free Information of Evacuation Centers for Wheelchair Users, *CASEMANS'10* (2010).
- [19] PADM: みんなでつくるバリアフリーマップ, 入手先 (http://enigata.com/data/minna_bmap.pdf) (参照 2015-

04-01).

- [20] Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y. and Manzagol, P.-A.: Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion, *The Journal of Machine Learning Research*, Vol.11, pp.3371-3408 (2010).
- [21] WHILL, available from (<http://whill.us>) (accessed 2015-04-01).
- [22] 伊勢崎隆司, 宮田章裕, 渡部智樹, 田中智博: 車椅子利用者の慣性・生体情報に基づく乗り心地推定, 情報処理学会研究報告 (GN), Vol.95, No.18, pp.1-4 (2015).
- [23] NTT 報道発表: 「ダイバシティ・ナビゲーション」の実現に向けた研究開発を推進, 入手先 (<http://www.ntt.co.jp/news2015/1501/150115a.html>) (参照 2015-04-01).

推薦文


本論文は、車椅子ユーザの移動を妨げる“バリア”に関する情報を収集する手法において、電柱や道路工事、違法駐車などの路上物バリアを発見することが困難であるという課題に対し、路上物バリアをよける・路上物バリアのために引き返すといった動作を構成する車椅子操作を推定し、操作の推定結果をもとに路上バリアの存在を検出する手法に関するものである。著者らは、車椅子操作時に発生する加速度・角速度は、同じ操作であってもユーザ・操作習熟度・状況・体調によって大きく振舞いが異なり、単一の推定器では精度良く推定できないという問題に対し、ユーザの直近の移動能力を推定した後に、その移動能力に適した推定器で操作内容を推定する 2 段階推定モデルを提案している。ディープラーニングを用いて提案コンセプトを実装し、ユーザの実走行データに基づいて構築した約 25 万件のデータセットを用いて実施した検証実験により、提案手法が前後進・右左折・停止などの操作を高精度に推定できるだけでなく、段差・傾斜の検出にも有効であることを実証しており、バリア情報の収集の実現に向けて大きく貢献している点が高く評価できる優れた論文であるため、推薦する。

(グループウェアとネットワークサービス研究会主査
市村 哲)



宮田 章裕 (正会員)

2005 年日本電信電話株式会社入社。2008 年慶應義塾大学大学院博士課程修了。2016 年より日本大学文理学部情報科学科准教授。ヒューマンコンピュータインタラクションの研究に従事。ヒューマンインタフェース学会、日本データベース学会各会員。博士 (工学)。



伊勢崎 隆司

2013年筑波大学大学院システム情報工学研究科修了。同年日本電信電話株式会社入社。現在、NTT サービスエボリューション研究所研究員。知能機能システムの研究に従事。



渡部 智樹

1992年横浜国立大学工学部卒業。同年日本電信電話株式会社入社。主に、家電制御技術、生体状態計測・推定技術の研究開発に従事。現在、NTT サービスエボリューション研究所主任研究員。博士（工学）。




中野 将尚

2014年神戸大学システム情報学研究科修了。同年日本電信電話株式会社入社。現在、NTT サービスエボリューション研究所に所属。ヒューマンコンピュータインタラクションの研究に従事。



水野 理

1994年早稲田大学大学院理工電気工学研究科修了。同年日本電信電話株式会社入社。現在、NTT 知的財産センター。日本音響学会、言語処理学会各会員。



石原 達也

2007年東京大学大学院情報理工学系研究科修了。同年日本電信電話株式会社入社。現在、NTT サービスエボリューション研究所研究主任。ヒューマンコンピュータインタラクションの研究に従事。



有賀 玲子（正会員）

2010年慶應義塾大学大学院理工学研究科修了。同年日本電信電話株式会社入社。現在、NTT サービスエボリューション研究所研究員。ヒューマンインタフェースの研究に従事。



望月 崇由

2001年早稲田大学大学院人間科学研究科修了。同年日本電信電話株式会社入社。2005～2014年NTT レゾナントにて、検索サービスを中心としたポータルサイト向けサービスの開発。現在、NTT サービスエボリューション研究所主任研究員。