

インタフェースロボット応答制御のための 歩行者分岐方向の予測

加藤 由花^{1,a)} 池田 貴政^{2,†1} 岡野 憲² 松日楽 信人³

受付日 2018年5月4日, 採録日 2018年11月7日

概要: 本稿では, 公共施設などの受付に設置されたインタフェースロボットの応答制御を目的に, ロボットに向かってくる人が, ロボットの前を通過する時点でどの方向に分岐していくかを事前に予測する手法を提案する. ここでは, ロボットに取り付けられた測域センサにより人の移動軌跡を計測し, 機械学習アルゴリズムによりあらかじめ構築しておいた予測器を用いて, 分岐方向を予測する. 学習に用いる特徴量としては, 歩行者動線を速度ベクトルの集合ととらえ, 速さと方向を組にした系列データを用いる. 公開されている, ショッピングモールにおける歩行者移動軌跡のデータセットを用いた実験により, 提案手法により, 80%程度の精度で分岐先を予測できることを確認した.

キーワード: サービスロボット, 歩行者モデル, 学習済予測器, データセット, 機械学習

A Method Predicting the Destination of a Pedestrian for Voice Guidance of Communication Robots

YUKA KATO^{1,a)} TAKAMASA IKEDA^{2,†1} SATOSHI OKANO² NOBUTO MATSUHIRA³

Received: May 4, 2018, Accepted: November 7, 2018

Abstract: In this paper, we propose a method to predict the destination of a pedestrian heading toward a robot in order to provide suitable voice guidance to him/her by communication robots installed at the reception desks of public facilities. For this purpose, we measure a pedestrian trajectory with a laser range scanner attached to the robot, and predict the branch destination by using a predictor model pretrained by a machine learning algorithm. In feature selection, we assume the pedestrian trajectory as a set of velocity vectors, and use series data combining velocity and direction values as the features for the predictor model. In order to verify the effectiveness of the proposed method, we conduct experiments using a dataset of tracking pedestrians at a shopping mall, and observe data in the real environment. The result shows that our method can predict branch destinations with an accuracy of over 80%.

Keywords: service robot, pedestrian model, pre-trained predictor, dataset, machine learning

1. はじめに

近年, 人々に対してコミュニケーションや情報提供を行い, サポートするインタフェースロボットが急速に普及してきている. これらのロボットには, 案内, 受付, 見守り, アミューズメントなど, 多岐にわたるサービスが期待されているが, より適切なコミュニケーションを実現するためには, サービス対象となる人の状況推定が必須である.

このような背景から, 我々はこれまで, ロボットに取り

¹ 東京女子大学現代教養学部
School of Arts and Sciences, Tokyo Woman's Christian University, Suginami, Tokyo 167-8585, Japan

² 芝浦工業大学大学院理工学研究科
Graduate School of Engineering and Science, Shibaura Institute of Technology, Koto, Tokyo 135-8548, Japan

³ 芝浦工業大学工学部
Engineering Science and Mechanics, Shibaura Institute of Technology, Koto, Tokyo 135-8548, Japan

^{†1} 現在, 富士電機株式会社
Presently with Fuji Electric Co., Ltd.

^{a)} yuka@lab.twcu.ac.jp

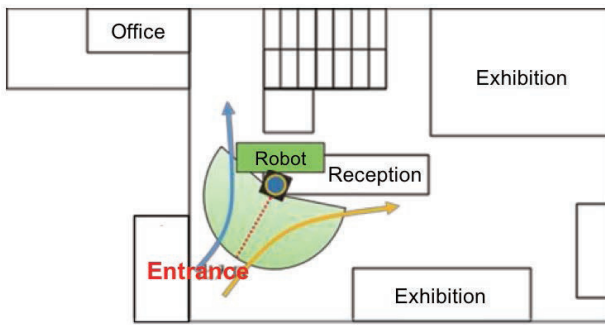


図 1 考察対象となる受付のレイアウト. 中央の黒い四角の位置に LRF を配置し, そのセンシング結果を用いて, 出入口から入ってくる人の分岐方向を予測する

Fig. 1 Layout of target reception desk. LRF is placed at black square position in middle of figure.

付けられた測域センサ (Laser Range Finder: LRF) のセンシング結果から人の状況を推定し, インタフェースロボットの応答制御を行う研究を進めてきた. 特に, 公共施設などの受付に設置される案内ロボットを対象に, 単一のセンサで案内対象の人の状況を推定する手法を提案している. たとえば, 人の接近を検知し応答制御を行う手法 [1] や, 人の足首の移動軌跡から高齢者と若年者を弁別する手法 [2], [3] などである. ここで, ロボットが受付で案内を行う場合, 人の移動経路は様々であり, 目的によって移動先は異なる. そのため, 応答の仕方でも人々の移動先 (目的) によって異なるべきだが, 既存手法では現在の状況を推定するのみで, 人々の目的に適った案内が難しいという問題があった.

本稿ではこの問題を解決するために, 人の移動軌跡から目的地を予測し, その結果を応答制御に利用することを考える. 事前検討として, これまで, 図 1 に示すような受付を対象に, LRF のセンシング範囲内に人が入ったとき, 人の追尾を行いながら, 受付に対する人の身体の向きを取得し, 分岐前に歩行者が「事務所側」と「受付側」のどちらの方向に進むかを予測する手法を提案してきた [4]. この手法には, ロボットに取り付けられた単一のセンサを用いて, 限られた測定範囲のデータから, 制限時間内に, 簡易に分岐方向が予測できるというメリットがある. 一方, 身体の向きという単一データによる予測であるため, 精度が不十分であるという問題が残った. 本稿では, この手法を拡張し, 瞬間的な身体の向きだけでなく, 数秒前からの人の移動軌跡を用いることで, 予測の精度向上を目指す. 具体的には, 大量の移動軌跡データを用いて, 機械学習手法により予測器を構築しておき, LRF によるセンシング結果をこの予測器の入力とすることで, 分岐方向を予測する. 提案手法における予測のイメージを図 2 に示す.

ここで, 予測器の構築には大量の移動軌跡データが必要であるが, 一般の公共空間では, サービス提供前に十分な数のデータを収集しておくことは難しく, 予測器の構築が

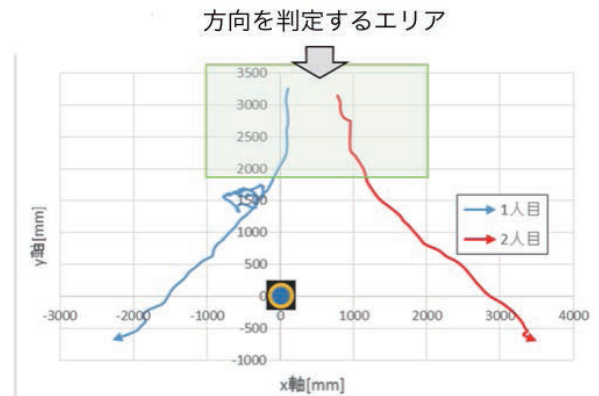


図 2 提案手法における予測のイメージ. 「方向を判定するエリア」内でのセンシング結果を利用し, その後の分岐方向を予測する
Fig. 2 Image of prediction. Using sensing data in “area for judging direction,” the branch direction is predicted.

困難であるという問題がある. 本稿では, 考察対象と類似した条件 (今回の場合, 公共空間での通常歩行) では, 人の移動傾向にある程度の一般性があり, 環境に依存しない予測器の構築が可能であるという仮説を立てた. この仮説の下, 大量の人移動軌跡データとして公開されているデータセットを用いて予測器を構築し, この予測器を用いて, 対象環境において人の分岐方向を予測する. 提案手法の概要を図 3 に示す.

ここで, 予測に用いる特徴量には様々な表現方法が考えられる. 時間ステップごとの座標を直接入力する方法や, その one-hot 表現 (やそれを圧縮したもの), 速度や加速度, その統計量を用いる方法などである. 本稿では, 分岐方向を予測するためには, 速度ベクトル (大きさと向きを持つ 2 次元データ) の利用が有効であると考え, これを特徴量として用いる. また, 速度ベクトルの時間順序にも意味があると考えられるため, 判定エリア内で観測された速度ベクトルの統計量 (平均値や分散など) ではなく, 時間ステップごとの系列データとして特徴量を構成することにした. 本稿ではこれらの手法に対し, データセットを用いた評価実験と, 対象環境において測定されたデータを用いた評価実験を行い, 手法の有効性を検証する.

本稿の貢献は以下の 3 点である.

- データセットにより事前に構築しておいた学習済予測器を利用して, 予測が可能であることを明らかにする.
- 特徴量として, 速度ベクトルの系列データを用いる手法の有効性を示す.
- 評価実験により, 100 人程度の人移動データがあれば実用的な精度で予測が可能であることを示す.

以下, 2 章で関連研究について述べた後, 3 章で本稿において考察対象とするロボットシステムについて説明する. その後, 4 章で提案する予測手法の内容を説明し, 5 章で評価実験の結果を述べる. 最後に, 6 章で本稿をまとめる.

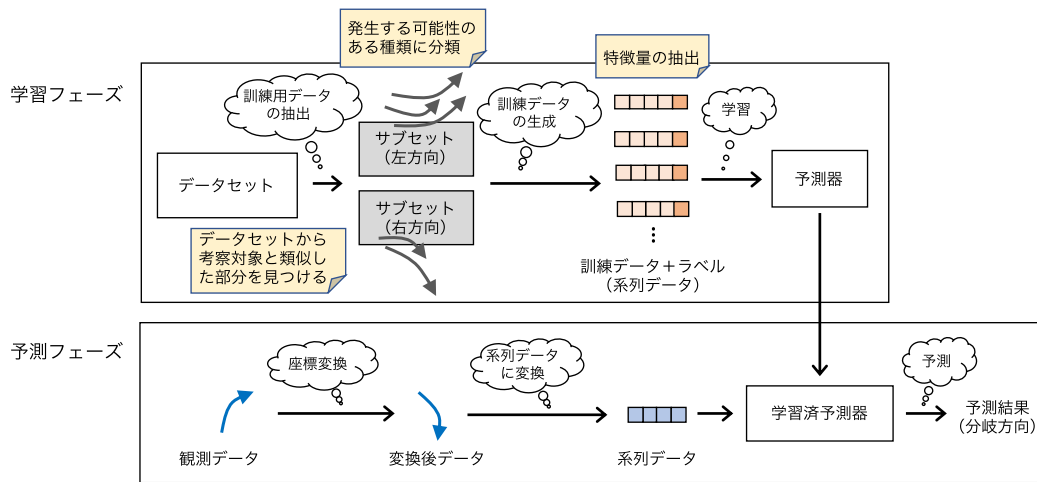


図 3 提案手法の概要. 公開されているデータセットを用いてあらかじめ構築しておいた予測器を用いて, 人の分岐方向を予測する

Fig. 3 Procedure of method. Branch direction is predicted using pre-trained predictor.

2. 関連研究

本稿の目的は, 限られた領域での人移動のセンシング結果から, その目的地(進行方向)をリアルタイムに予測することである. これを実現するためには, 大きく分けて2つの方法が考えられる. 1つは, 歩行者の移動傾向を数値モデルとして定式化し, このモデルに従い人の移動傾向を推定するものである. もう1つは, 大量の観測データを利用し, 対象環境における人の移動傾向を推定するものである.

2.1 人移動モデルを用いる方法

人移動モデルを用いる手法として最もよく知られているのは, Helbing の Social Force Model (SFM) [5], [6] である. これは, 人と人, 人と壁の間に, 粒子間力のような心理的斥力と物理的斥力を定義し, 歩行者の進行方向を決定するモデルである. その他, 避難シミュレーションのためにセル・オートマトンモデルを用いて人の移動傾向を予測する手法 [7] の提案や, ロボットと共存する環境での人移動モデルの定式化 [8] なども行われている.

これらの手法は, 適切なモデルを定義することができれば, 事前に大量のデータ取得を行う必要がなく, 適用が容易であるという大きな利点がある. 一方, モデル化において考慮する必要があるパラメータ数が多く, 精度の高いモデル構築が難しい. また, 適切なモデル構築が行われた場合でもモデル自体が複雑になり, その結果予測が困難になるという課題を抱えている. たとえば, 斥力の定式化には人属性(身長, 性別, 年齢など)の考慮が必要であり, また地理的形状以外の環境要素(ドアからの出入りなど)をモデルに取り込むことも考える必要がある.

さらに, 人移動モデルを用いて分岐予測を行うためには, 移動モデルに従ったシミュレーションを行う必要があり, 予測精度やリアルタイム性の問題からも, 本稿における考

察対象への適用は難しい.

2.2 観測データを用いる方法

観測データを用いる方法は, 環境ごとに大量の移動軌跡データを収集し, その結果から人の移動傾向を推定する方法である. 人移動計測データから移動モデルを生成し, ロボットの経路計画に利用する手法 [9] や, 環境の幾何的形状をモデルに取り込む手法 [10] など, これまでも様々な研究が行われてきた. 近年では, 機械学習手法も多く用いられており, 特に, 自然言語処理技術の進展により, 移動データを系列データとして学習させる研究がさかんに行われている [11]. RNN (Recurrent Neural Network) を用いて移動軌跡の系列から目的地を推定する手法 [12] や, 系列データ間の相互作用を Social LSTM (Long short-term memory) としてモデル化する手法 [13] などが提案されている.

これらの手法は, 適切な予測器を構築することができれば, 短時間で精度の良い予測が可能であり, 予測精度やリアルタイム性の問題を解決できる. また, 環境に適したモデルの構築が可能であり, 建物の幾何形状や環境要素もモデルに取り込むことができる. 一方, 学習のために, 大量の観測データを, 環境ごとに, 事前に収集する必要があり, 予測器構築に手間がかかるという問題がある. また, 環境に応じて適切な特徴量を選択する必要があり, これがうまくいかない場合には十分な精度が期待できない可能性もある. さらに, 予測器構築のためには, 収集した生データの加工, データの統合などが必要であり, この手間も無視できないほど煩雑である.

本稿では, 分岐予測のために, 観測データを用いて予測器を構築する手法を採用するが, サービス提供前に十分な数のデータを収集しておくことが困難であるという問題に対応するために, 他の環境で構築しておいた学習済予測器を利用することを考える. 近年, 一般に公開された様々な

種類のデータセットの利用が可能であるため、これらを利用して事前に予測器を構築しておく。

3. 対象となるロボットシステムの構成

3.1 システムの概要

まず、本稿で考察対象とするロボットシステムについて説明する。インタフェースロボットを含むシステムの全体構成を図4に示す。システムは、インタフェースロボット(据え置き型の小型ロボット)、ロボットに取り付けられたLRF(スキャン範囲270°、最大検出距離10,000mm)、LRFに接続されたノートPCからなる。ここでは、人がLRFの計測範囲内(今回は4,000mmとした)に入ると、LRFが人までの距離と角度を計測する。このデータをノートPC上で処理し、処理結果に従いロボットの応答制御指令を生成する。制御指令はソケット通信でインタフェースロボットに送られ、指令を受け取ったロボットは、指令に応じてモータドライバ、スピーカに動作指令を行うことで様々な応答を実現する。

このロボットシステムは、深川江戸資料館^{*1}の受付に設置され、受付用ロボットとして、お客様に資料館やイベントの案内を行ってきた。これまでは、受付側に行く人とそれ以外の人など、目的の異なる人々に対して同様の応答を行ってきたが、前述したとおり、本稿では、図1に示すように、「事務所側」と「受付側」に行く人に対して異なる応答を行えるよう、分岐対応を可能にすることを目指す。ここでは、人々の進行方向を基準に、受付側を「右方向分岐」、事務所側を「左方向分岐」と設定する。

LRFは、出入り口(Entrance)方向に中心軸を向けるため、図1に示すように斜め45°の向きに設置する。ここで、ロボットは受付(Reception)と同じ向きに正面を向いて設置されている。そのため、何らかの情報提供を受けるためにロボットに近づく利用者は受付側に分岐することになり、ロボットから情報提供を受ける意図のない利用者は事務所(Office)側に分岐することになる。このように、分




図4 本稿で考察対象とするロボットシステムの全体構成。ロボットにはLRFが取り付けられているが、LRFでのセンシング結果は、LRFに接続されたノートPC上で処理される。その処理結果に従いインタフェースロボットが動作する

Fig. 4 Overall configuration of target robot system. LRF is attached to robot, but sensing data is processed on laptop PC. Robot runs according to processing results.

^{*1} 深川江戸資料館: <https://www.kcf.or.jp/fukagawa/>

岐方向を予測することにより、案内が必要な人とそれ以外の人を弁別することができるようになる。この結果を用いて、たとえば、受付側に向かう人に対して「ようこそ、〇〇へ。本日のイベントについて案内しています」などの語りかけを行い、事務所側に向かう人に対しては「ありがとうございました」などの語りかけを行うことなどが想定される。

3.2 移動軌跡の傾向を調べるための予備実験

考察対象における移動軌跡の傾向を把握するために、LRFにより人移動軌跡を計測する予備実験を行った。結果を図5に示す。ここでは、13人分の移動軌跡を計測した。7人目のみ事務所側から出入り口に向かう軌跡になっているが、それ以外は、出入り口から受付側、または事務所側に向かう軌跡である。座標軸は、LRFの設置場所を原点とし、LRFの中心軸方向をy軸、水平方向をx軸としている。単位はmmである。

図5からは、歩行者が受付側と事務所側に分岐して進んでいることが分かる。1人目、2人目、11人目は、出入り口から受付まで直線的に向かっていることから、元々受付に行く目的を持っていたと推察される。3人目、4人目、6人目、8人目、9人目、10人目、13人目も同様に、移動軌跡から、元々事務所側に行く目的を持っていたと考えられる。5人目は、y=2,000付近までロボットに向かって直進した後、受付側に分岐している。12人目は、y=500付近まで直進した後、事務所側に分岐している。これは、ロボットに興味を持ち、近寄った後に目的地に向かっていったためと考えられる。

これらの結果から、各軌跡の幾何的形狀、つまり速度ベクトルの系列データから、受付側、事務所側への分岐傾向が推定できることが分かった。一方、5人目、12人目のように、いったんロボットに近づきながら事務所側に分岐す

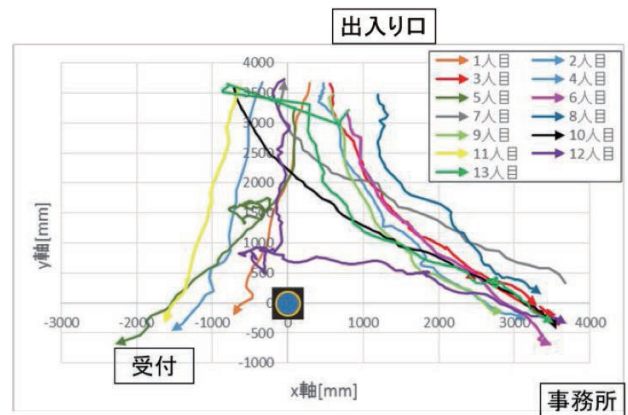


図5 移動軌跡の傾向を調べるための予備実験の結果。13人分の軌跡を色別の矢印で表示した

Fig. 5 Result of preliminary experiment to investigate trajectory trend. 13 trajectories are illustrated by arrows.

る利用者や、途中で向きを変えたり、蛇行したりする利用者が存在することも分かった。提案手法ではこれらを検知することはできないため、現実に予測が困難な軌跡の発生確率に基づき、予測精度の目標値を想定することとする。予備実験からは、逆走している7人目を除き、12人中2人(5人目と12人目、全体の約20%)の予測は困難であると考えられることから、本稿での目標精度を80%とする。なお、ロボットは人の近接を検知して応答を行うので、逆走する軌跡は除外して考えることができる。

ちなみに、予測を誤った場合には、案内が不要な利用者に語りかけるなど、ロボットの応答内容が不適切なものになるが、それでもすべて同一の応答をする場合、まったくランダムに回答する場合より大幅な正解率の向上が見込めるため、20%程度の予測誤りは許容範囲と考えられる。

3.3 ロボットの応答タイミング

分岐の判断は、歩行者が受付に到達した時点で、ロボットの応答が可能であるタイミングで行われる必要がある。先行研究[1]によると、PCからロボットに命令を送信する通信時間は40ms、ロボットの動作時間(首の回転などのジェスチャ)は985msである。ロボットは動作後に発話する。また、文献[14]によると、一般男性の通常状態での歩行速度の平均は1,400mm/sである。このことから、ロボットは判定エリアから $(40 + 985) \times 1,400 / 1,000 = 1,435$ mm以上離れている必要がある。

本稿では、LRFの計測範囲を4,000mmとしているため、これと上記の条件を勘案し、 $2,000 \leq y \leq 3,500$ の範囲で歩行者の分岐方向の判定を行い、 $0 \leq y < 2,000$ の範囲でロボットが応答するという設定にすることにした。これにより、ロボットは歩行者の通過前に応答することが可能になる。

4. 提案手法

4.1 手法の概要

前章で示したロボットシステムを対象に、歩行者の分岐方向を予測する手法を提案する。1章で述べたように、ここでは、公開されているデータセットを用いて、あらかじめ予測器を構築しておき、それを実環境での予測に利用する。提案手法は、データセットを用いて予測器を構築する学習フェーズと、予測器を用いて予測を行う予測フェーズに分かれる。それぞれ以下の手順で予測器の構築と分岐方向の予測を行う。

- 学習フェーズ
 - (1) データセットから訓練データを生成する。
 - (2) 訓練データを用いて予測器を構築する。
- 予測フェーズ
 - (1) 移動軌跡データを計測する。
 - (2) 計測データから予測器への入力データを生成する。

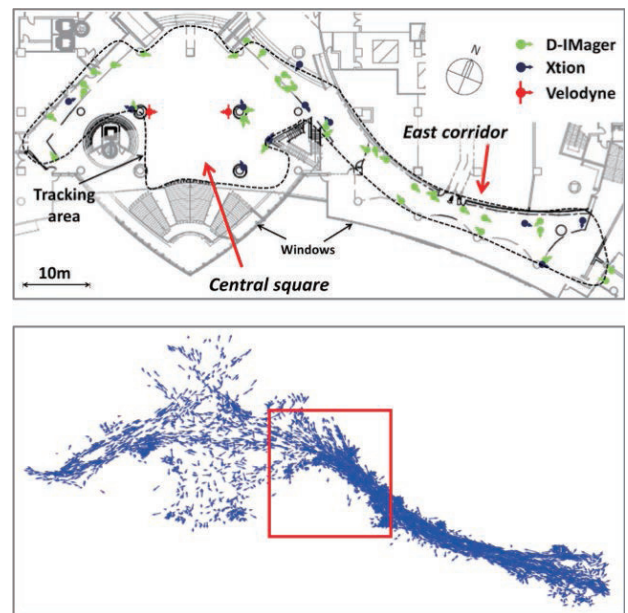


図6 (上図) 利用するデータセットの計測対象となるショッピングモールの形状 (Reprinted with permission from Ref. [15]. ©2018 IEEE). 人が滞留する広場と人が移動する通路を組み合わせた形をしている。(下図) 人移動軌跡データの一部を可視化した結果。提案手法では、赤枠で囲った範囲のデータから対象となる人数分のデータを抽出し、予測器の構築に利用する

Fig. 6 (Upper figure) Shape of shopping mall where data were measured (Reprinted with permission from Ref. [15] ©2018 IEEE.) (Lower figure) Result of visualization of part of trajectory data.

- (3) 分岐方向を予測する。

4.2 学習フェーズ

4.2.1 利用するデータセット

本稿では、商業施設内を一般の歩行者が徒歩で移動するデータとして、ATC pedestrian tracking dataset [15]を予測器の構築に利用することにした。これは、大阪の商業施設ATCショッピングモールにおけるのべ3,758,348人(1日平均40,851人)の人移動軌跡(トラッキングデータ)と、ユーザIDなどのメタデータを含んだ、約1年間(2012/10~2013/11までの毎週水曜・日曜, 9:40~20:20)、通算92日分のデータである。複数の3次元距離画像センサにより、人の位置が、10~40Hz間隔(周期は人の密集度により異なる)で継続的に計測されている。計測対象となるショッピングモールの形状を図6の上図に示す。これは、人が滞留する広場と人が移動する通路を組み合わせた形状をしており、場所により様々な傾向を持つ移動軌跡が抽出可能であることが分かる。

データはCSV形式で蓄積されており、以下の情報を1レコードとして、観測周期ごとに観測されたユーザID分のデータが格納されている。

- 測定時刻 [ms] (UNIX 時刻 + ミリ秒/1,000)

- ユーザ ID (1 トラッキングごとに割り当てられる ID)
- 測定時刻における x, y, z 座標 [mm]
- 移動速度 [mm/s]
- 移動方向 [rad]
- 人の顔が向いている方向 [rad]

ここでは、ある時刻 t における x, y, z 座標を x_t, y_t, z_t 、移動速度を v_t 、移動方向を θ_t と表すことにする (すべてスカラー値)。データセットにおける座標軸については後述する。

人移動軌跡データのイメージを把握するために、一部のユーザ ID に対応する一連のトラッキングデータを取り出し、可視化した結果を図 6 の下図に示す。本稿では、このうちで分岐が観測される部分を対象に、ある人の移動軌跡を対象となる人数分 (N 人分) 取り出して、予測器の構築に利用する。

4.2.2 訓練データの生成

訓練データは、データセットから、考察対象と類似した部分を取り出すことで生成する。具体的には、図 6 の下図において赤枠で囲んだ部分を分岐点と見なすことにした。データセットからどの部分を取り出して訓練データを生成するかは、予測したい対象に応じて決定する必要がある。これは、必ずしも地理的形状の似ている部分である必要はなく、予測したい対象と人の移動傾向が類似しており、予測対象の環境で発生する可能性のあるデータの種類が網羅的に含まれているエリアであれば選択可能である。このような前提の下、本稿では、通路から広場に向けて左右に分岐が発生しており、左右それぞれのデータを偏りなく取得できる部分として、対象エリアを選定した。このデータセットからは、他にも、広場からの様々な方向への分岐を予測するためのエリアなどが選択できると考えられる。

今、このエリアを通過するすべての人移動軌跡の集合を T とし、分岐点から右方向に分岐する軌跡の集合を $T^r \subset T$ 、左方向に分岐する軌跡の集合を $T^l \subset T$ とする。左右に分岐は、このエリア内で各軌跡が到達した地点の座標を基に決定する。ここではまず、 T^r と T^l の要素から、対象軌跡をランダムに $N/2$ 個ずつ選ぶ。選択した軌跡データを可視化した例 ($N = 60$ の場合) を図 7 に示す。滞留している軌跡など、いくつかの例外は見られるが、分岐点の手前で、右方向と左方向に分岐しているデータの抽出に成功していることが分かる。なお、図 7 にはデータセットにおける座標軸を示した。

次に、それぞれの軌跡に対し、学習に利用する特徴量を系列データとして構成することを考える。前章での予備実験、および図 7 から、各軌跡データを速度ベクトル $\mathbf{a}_t = (v_t, \theta_t)$ の集合として構成することで、分岐方向を表現可能であると考えられる。このとき、 x_t, y_t, z_t 座標、および時刻 t 自体には意味はないが、その系列 (たとえば、角度の変化率の推移など) は分岐方向決定に意味を持つと




図 7 分岐点付近で、右方向に分岐する軌跡 30 本と左方向に分岐する軌跡 30 本を抽出した例。対象エリアは、図 6 の下図における赤枠内に相当する

Fig. 7 Example of extracting 30 trajectories branching to right and 30 ones branching to left around branch point.

考えられる。そこで、提案手法では、各軌跡を速度ベクトルの集合と見なし、この系列データを訓練データとすることにした。ここでは、時刻 t を時間間隔を考慮せず、その並び順のみを考慮して離散化する。つまり、 \mathbf{a}_t の並び順に意味を持たせるために、新たに順序を表すためのパラメータ i を導入する。ここで、 i を付与するデータが観測される時刻 t を $t(i)$ とすると、つねに $t(i) < t(i+1)$ が成り立つ。これにより、ある移動軌跡 $T \in T$ は

$$T := \mathbf{a}_0, \dots, \mathbf{a}_i, \mathbf{a}_{i+1}, \dots \quad (1)$$

と \mathbf{a}_i の順序対集合として定義される。

ここで、考察対象での方向判定エリアは、分岐点の手前 2,000 mm から 3,500 mm の部分のデータなので、 T の中から、このエリアに相当する \mathbf{a}_i を順序関係を保持したまま取り出すことで、訓練データが構成できる。つまり、 $2,000 \leq x_k \leq 3,500$ を満たす k に対応する \mathbf{a}_k からなる集合 $D \subset T$ を生成し、 $T \in T^r$ の部分集合である D からなる集合 D^r 、および $T \in T^l$ の部分集合である D からなる集合 D^l を訓練データとする。ただし、 D は予測器構築用に v_i と θ_i を時系列順に並べて構成し、軌跡間のデータ数を合わせるために、 x_k が小さい方から順に n 個の速度ベクトルを抽出することにした。つまり、

$$D := v_0, \theta_0, \dots, v_{n-1}, \theta_{n-1} \quad (2)$$

となる。この D が、 D^r, D^l どちらの集合に属しているかにより、正解データ (D^r に属していれば右、 D^l に属していれば左) を付与する。

4.2.3 予測器の構築

前項で生成した訓練データを入力として、予測器の学習を行う。予測モデルとしては、サポートベクターマシンを利用することにした。

*2 厳密には座標軸の傾きを考慮する必要があるが、後ほど系列長の調整を行うため、傾きの影響は打ち消される。

4.3 予測フェーズ

4.3.1 データの計測

予測フェーズでは、LRF の計測範囲内 ($y \leq 4,000$) に入った人の位置追跡を行い、10 Hz 周期で LRF から人までの距離と角度を計測する。人位置追跡には、文献 [3] に記載されたものと同様の方法を用いる (ただし、文献 [3] では人の足首を追跡対象としているが、本稿では胴体を追跡対象とする)。ここでは、追跡対象の位置を確率分布として扱い、追跡対象に応じた遷移モデル (人の移動) と、センサデータに基づく観測モデル (LRF により測定される距離) から、再帰的に追跡対象の状態量に関する確率密度関数を推定する。人位置 (追跡器の位置) の確率分布には、パーティクルフィルタを用いる。パーティクルフィルタでは、確率分布は標本 (パーティクル) の集合として定義され、パーティクルを重みに従ってリサンプリングすることで、事後確率 (同じくパーティクルの集合として定義される) が生成される。

歩行者の位置は、LRF により計測される距離と角度を、極座標形式から直行座標形式に変換することで求める。この結果から、単位時間ごとの人位置データ (\hat{x}_t, \hat{y}_t) が算出される。なお、ここでの座標系は図 5 に示したものであり、通常、観測エリア内において 1~2 秒程度の歩行軌跡が測定される。

4.3.2 入力データの生成

前項で示した計測結果から、予測器への入力データを生成する。予測器には、速度と角度の系列データを入力するが、ここでは、学習時に用いたものと同じ形式のデータを用意する必要がある。具体的には、図 5 に示した対象システムの座標系を、図 7 に示したデータセットの座標系に変換した上で、データの系列長を $2n$ 個に合わせる。なお、座標変換に関しては、絶対的な x 座標、 y 座標の値には意味がないので、回転移動のみを行うこととする。系列長を合わせるためには、系列長が $2n$ より大きい場合には $2n$ で打ち切り、少ない場合には最後尾のデータを複製することで足りないデータを補う。

ここではまず、計測結果から得られた (\hat{x}_t, \hat{y}_t) を φ だけ回転移動することにより、データセットの座標軸に対応した (x_t, y_t) を

$$\begin{pmatrix} x_t \\ y_t \end{pmatrix} = \begin{pmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{pmatrix} \begin{pmatrix} \hat{x}_t \\ \hat{y}_t \end{pmatrix} \quad (3)$$

として求める。つまり、 φ は、データセットにおける分岐前の歩行者の進行方向と y 軸とのなす角度により決定する。ちなみに本稿では $\varphi = -3\pi/4$ とした。これにより、訓練データと同一の座標系での、単位時間ごとの位置データが取得できる。すると、単位時間を Δt とすると、

$$v_t = \frac{\sqrt{(x_{t+1} - x_t)^2 + (y_{t+1} - y_t)^2}}{\Delta t} \quad (4)$$

$$\theta_t = \begin{cases} \arctan \left(\frac{y_{t+1} - y_t}{x_{t+1} - x_t} \right) & (x_{t+1} > x_t) \\ \arctan \left(\frac{y_{t+1} - y_t}{x_{t+1} - x_t} \right) + \pi & (x_{t+1} < x_t, y_{t+1} \geq y_t) \\ \arctan \left(\frac{y_{t+1} - y_t}{x_{t+1} - x_t} \right) - \pi & (x_{t+1} < x_t, y_{t+1} < y_t) \end{cases} \quad (5)$$

により v_t および θ_t が算出できる。これらから、 $2n$ 個の系列データ D^* を以下のように生成する。

$$D^* := v_0, \theta_0, \dots, v_t, \theta_t, \dots, v_{n-1}, \theta_{n-1} \quad (6)$$

4.3.3 分岐方向の予測

前項で構築した予測器に D^* を入力することで、分岐方向を予測する。

5. 実験

本稿ではまず、構築した予測器自体の性能を、学習に用いた訓練データの数を換え、データセットに含まれるデータを用いて検証した (実験 1)。次に、この予測器で、実環境での観測データを用いた予測が可能なることを検証した (実験 2)。以下、それぞれの結果について述べる。

5.1 実験 1: データセットを用いた評価

5.1.1 実験の方法

前章で示した ATC データセットを用いて、構築した予測器の評価実験を行った。ここでは、訓練データの数 N を 40, 100, 200, 400 と換え、右方向に分岐したデータに対する、適合率 (Precision)、再現率 (Recall)、F 値を比較した。たとえば、 $N = 100$ の場合、右方向に進んだデータ 50 個、左方向に進んだデータ 50 個で訓練データを構成している。データ系列長は $n = 23$ を用いた。データの検証には、データを 5 グループに分割し ($N = 40$ の場合は 8 個 \times 5 グループ、 $N = 200$ の場合は 40 個 \times 5 グループなど)、4 グループのデータを用いて予測器を構築し、残りの 1 グループのデータでテストを行う作業を 5 回繰り返す交差検証を行った。

なお、予測器の構築には、Python の機械学習ライブラリ scikit-learn の svm.SVC 関数を利用し、RBF カーネル (ガウシアンカーネル) の SVM により予測モデルを構築した。

5.1.2 実験の結果

実験の結果を表 1 に示す。考察対象では、蛇行などにより方向の検出が困難である軌跡を左方向 (誤り) と認識する傾向があると適合率が高くなり、右方向と認識する傾向があると再現率が高くなる。そのため、目標精度は F 値 (適合率と再現率の調和平均) に相当すると考える。そうすると、 N の値が増えるにつれて性能は上がっていくが、

表 1 訓練データの数による予測性能の比較

Table 1 Comparison result of prediction performance.

| 訓練データ数 | 40 | 100 | 200 | 400 |
|--------|------|------|------|------|
| 適合率 | 0.75 | 0.81 | 0.86 | 0.82 |
| 再現率 | 0.63 | 0.78 | 0.80 | 0.82 |
| F 値 | 0.69 | 0.79 | 0.83 | 0.82 |

表 2 観測データを用いて分岐方向を予測した結果

Table 2 Prediction result of branch direction.

| 用いた予測器 | 40 | 100 | 200 | 400 |
|----------|----|-----|-----|-----|
| 1 人目の結果 | 0 | 0 | 0 | 0 |
| 2 人目の結果 | 0 | 0 | 0 | 0 |
| 8 人目の結果 | 1 | 1 | 1 | 1 |
| 10 人目の結果 | 1 | 1 | 1 | 1 |

$N = 200$ で頭打ちになり、 $N = 100$ 以上であれば、ほぼ目標値である 80% の精度で分岐方向の予測が可能であること ($N = 100$ は予測のための十分な訓練データ数であること) が分かる。

なお、図 7 に示すように、ここでの訓練データは、始点と終点のみを指定して軌跡を抽出しているため、蛇行や不規則な動きをしている軌跡が含まれる。このデータを用いた予測精度と、予備実験の結果がほぼ同一の値になっていることから、公共空間での通常歩行において、予測可能な軌跡の割合として 80% という値を設定することは妥当であると判断できる。

5.2 実験 2：観測データを用いた評価

5.2.1 実験の内容

考察対象で観測されたデータを用いて、予測結果の評価を行った。観測データとしては、図 5 の中の 4 人分のデータを選択した。ここでは、ロボットに興味を持って近づいてきた軌跡や、大きく蛇行した軌跡は対象外とし、典型的な軌跡として、1 人目 (右に分岐)、2 人目 (右に分岐)、8 人目 (左に分岐)、10 人目 (左に分岐) を選んだ。その後、 $2,000 \leq y \leq 3,500$ を満たす軌跡から 24 個分の座標を抽出し (その結果、23 個の v_t と θ_t が算出される)、前章で示した変換を施すことで D^* を生成した。これを予測器に入力し、分岐方向を出力した。

5.2.2 実験の結果

実験の結果を表 2 に示す。ここでは、右方向への分岐を 0、左方向への分岐を 1 としている。 N を 40、100、200、400 と変えて予測器を構築し、それぞれについて実験を行ったが、いずれの場合も正しく弁別できていることが分かる。今回は、用いたデータも限定的なものであるが、学習済予測器を使った予測の可能性を検証できたと考えられる。

なお、本実験結果は、実環境データを用いた精度の評価結果を示したものではなく、学習済予測器を用いて分岐経路をうまく識別できることを検証したものにすぎない。実

環境での評価を行った場合には、予備実験や実験 1 とほぼ同程度の、80% 程度の予測精度になると考えられる。

以上、実験 1 の結果と合わせて考えると、のべ人数で合計 100 程度のデータがあれば、考察対象についての予測器を構築できると考えられる。

6. おわりに

本稿では、インタフェースロボットの応答制御を目的に、データセットを用いてあらかじめ構築しておいた学習済予測器を用いて、歩行者の分岐方向を予測する手法を提案した。また、データセットを用いた実験、実環境での観測データを用いた実験により、手法の有効性を検証した。本稿の結論は以下の 3 点である。

- 考察対象と類似した環境では、データセットを用いて構築した予測器の利用が可能であることが分かった。ただし、適切なデータ変換が必要である。
- データセットを用いて構築した予測器により、80% 程度の精度で歩行者の分岐方向を予測可能であることが分かった。
- 今回の環境では、のべ 100 人程度の訓練データがあれば、十分な精度で予測が可能であることが分かった。

本稿における考察対象は、インタフェースロボットの導入形態として妥当であると考えられるが、実際のロボットの配置や受付の形状、歩行者の属性などは環境により様々である。このような、環境に依存した状況の影響については、今後より詳細な検討が必要であると考えられる。予測分岐数についても、2 つ以上の複数パターンを分類することで、より詳細な制御が実現する可能性がある。今後、データセットからのデータ取得方法、データ取得部分の適切さに対する結果のロバスト性などを検証していく必要がある。これらの検証により、提案手法をより一般の環境に適用していくことが可能になると考えられる。また、学習済予測器を用いる他、実環境において人工的に訓練データを生成する、またはデータを取得しながらオンラインで予測器を構築するなどの方法も考えられるため、今後は、それらの手法と提案手法の比較なども行っていきたいと考えている。

謝辞 本研究の一部は、JSPS 科研費 15K00137、17K00366 の助成を受けたものである。

参考文献

- [1] 野見山大基, 折笠登志彦, 松日楽信人, 山本大介, 佐野雅仁: 人の移動に伴うインタフェースロボットの対面応答制御法の開発, ロボティクス・メカトロニクス講演会, 2A1-M05 (2014).
- [2] Sakai, S., Kimura, S., Nomiya, D., Ikeda, T., Matsuhira, N. and Kato, Y.: Classification of Age Groups using Walking Data Obtained from a Laser Range Scanner, *Proc. 42nd Annual Conference of the IEEE Industrial Electronics Society (IECON 2016)*, pp.5862–5867 (2016).

- [3] 坂井 栞, 木村純麗, 池田貴政, 野見山大基, 松日楽信人, 加藤由花: 測域センサにより取得される歩行パターンを利用した高齢者/若年者弁別手法, 情報処理学会論文誌, Vol.58, No.2, pp.375-383 (2017).
- [4] 池田貴政, 岡野 憲, 松日楽信人, 加藤由花: 歩行者の分岐におけるインタフェースロボットの応答制御の検討, 計測自動制御学会システムインテグレーション部門講演会, 3C1-03 (2017).
- [5] Helbing, D. and Molnar, P.: Social force model for pedestrian dynamics, *Physical Review E*, Vol.51, No.5, p.4282 (1995).
- [6] Helbing, D., Farkas, I. and Vicsek, T.: Simulating Dynamical Features of Escape Panic, *Nature*, Vol.407, pp.487-490 (2000).
- [7] Boukas, E., Kostavelis, I., Gasteratos, A. and Sirakoulis, G.: Robot Guided Crowd Evacuation, *IEEE Trans. Automation Science and Engineering*, Vol.12, No.2, pp.739-751 (2015).
- [8] Kato, Y., Nagano, Y. and Yokoyama, H.: A Pedestrian Model in Human-Robot Coexisting Environment for Mobile Robot Navigation, *Proc. 2017 IEEE/SICE International Symposium on System Integration (SII 2017)* (2017).
- [9] Noguchi, H., Yamada, T., Mori, T. and Sato, T.: Mobile Robot Path Planning Using Human Prediction Model Based on Massive Trajectory, *Proc. IEEE International Conference on Networked Sensing Systems (INSS 2012)*, pp.1-7 (2012).
- [10] Hamasaki, S., Tamura, Y., Yamashita, A. and Asama, H.: Prediction of Human's Movement for Collision Avoidance of Mobile Robot, *Proc. IEEE International Conference on Robotics and Biomimetics (ROBIO 2011)*, pp.1633-1638 (2011).
- [11] Mavrogiannis, C.I., Blukis, V. and Knepper, R.A.: Socially Competent Navigation Planning by Deep Learning of Multi-Agent Path Topologies, *Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2017)*, pp.6817-6824 (2017).
- [12] 遠藤結城, 西田京介, 戸田浩之, 澤田 宏: 長期的な状態依存性を考慮した移動軌跡からの目的地予測, 情報処理学会マルチメディア・分散協調とモバイルシンポジウム 2016 論文集, pp.1524-1536 (2016).
- [13] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L. and Savarese, S.: Social LSTM: Human Trajectory Prediction in Crowded Spaces, *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, pp.961-971 (2016).
- [14] 関屋 昇, 長崎 浩, 伊東 元, 古名丈人: 正常歩行における歩行速度, 歩行率, 歩幅の相互関係, 理学療法学, p.416 (1994).
- [15] Brscic, D., Kanda, T., Ikeda, T. and Miyashita, T.: Person position and body direction tracking in large public spaces using 3D range sensors, *IEEE Trans. Human-Machine Systems*, Vol.43, No.6, pp.522-534 (2013).



加藤 由花 (正会員)

1989年東京大学理学部卒業。同年日本電信電話(株)入社。2002年電気通信大学大学院情報システム学研究科博士後期課程修了。博士(工学)。同年電気通信大学助手, 2006年産業技術大学院大学准教授, 2009年同教授。

2014年より東京女子大学教授。情報ネットワーク, ネットワークを利用したロボットサービスに関する研究に従事。電子情報通信学会, 日本ロボット学会, 人工知能学会, ACM, IEEE 各会員。本会シニア会員。



池田 貴政

2018年芝浦工業大学大学院理工学研究科機械工学専攻博士前期課程修了。同年, 富士電機(株)入社。在学中, インタフェースロボットに関する研究に従事。



岡野 憲

2018年芝浦工業大学工学部機械機能工学科卒業。現在, 同大学院理工学研究科機械工学専攻博士前期課程在学中。インタフェースロボットに関する研究に従事。



松日楽 信人

1982年東京工業大学大学院理工学研究科機械物理工学専攻修了。同年(株)東芝入社。企業では各種ロボットシステムの研究開発を実施, 最近は共存型ロボットの研究に従事。現在, 芝浦工業大学教授。博士(工学)。日本機械学会, 計測自動制御学会, 日本ロボット学会, IEEE 各会員。著書『わかりやすいロボットシステム入門』等。