

軌跡クラスタリングに基づくすれ違い行動の予測

田中 勇記^{1,a)} 池田 徹志² 浮田 宗伯¹ 篠沢 一彦^{2,3} 近藤 公久² 宮下 敬宏² 萩田 紀博²

概要：ロボットが人間と空間を共有して動作するためには、安全性を考慮した上で社会的に許容される移動をすることが求められる。特に車いすロボットのような利用者が存在する搭乗型ロボットには、これらに加えて移動効率や安心感など利用者の快適性を重視する必要がある。例えばロボットが人間とすれ違う際、一般的な自律移動型ロボットであれば安全性を考慮して大きく回避すれば良いが、搭乗型ロボットでそのような移動をすると移動効率が悪くなるため利用者にとっての快適性が低下してしまう。利用者の快適性を考慮した移動をするためには、周囲の人の動きを正しく認識して将来の移動を予測する必要がある。これまで多くの研究で、歩行者が他人や障害物を避ける際の移動を予測するモデルが提案されてきた。そのほとんどがパラメトリックモデルによってすれ違い方を表現している。だが、車いすロボットが運用される病院内では移動特性の異なる様々な移動手段が存在し、更に同一の移動手段であってもその人や状況に応じて多様なパターンのすれ違い方が観測される。これまでのパラメトリックモデルではすれ違いパターン毎に適切なパラメータを学習する必要があるため、このような複雑な問題を扱うことは難しい。多様なすれ違い方を予測するには、観測されたすれ違い時の軌跡データ群から様々なすれ違いパターンを学習する、事例ベースの予測手法が有効であることが知られている。そこで本研究では観測された軌跡データ群をクラスタリングすることですれ違い方の代表的なパターンを学習する手法を提案する。本稿では、すれ違う際の相対的な位置関係や移動速度といった特徴量ですれ違い方を表現し、対象の移動を予測する。提案手法の有効性を検証するために、車いすロボットと4種類の移動手段を用いた被験者がすれ違う実験を行った。その結果、提案手法で高精度な予測が得られることを確認した。

キーワード：衝突回避、移動予測、移動ロボット、軌跡クラスタリング

1. はじめに

ロボットが人間と空間を共有して動作するためには、安全性を考慮した上で社会的に許容される移動をすることが求められる。特に車いすロボットのような利用者が存在する搭乗型ロボットには、これらに加えて移動効率や安心感など利用者の快適性を重視する必要がある。例えばロボットが人間とすれ違う際、一般的な自律移動型ロボットであれば安全性のみを重視して大きく回避すれば良い。しかし、搭乗型ロボットでそのような移動をすると移動効率が悪くなるため利用者にとっての快適性が低下してしまう。一方、ロボットの移動効率のみを重視して常に最短経路を

進むように移動すると、衝突の危険性が増したり周辺人物の快適性が低下したりするため社会的に許容されない。利用者の快適性を考慮し、且つ社会的に許容される移動を行うためには、安全性を確保した上で両者が互いに避け合うすれ違いが望ましいと考えられる。このような移動を実現するためには、周囲の人の将来の移動を予測する必要がある。周辺人物がロボットを避ける際の移動を予測することで、その予測結果に合わせてロボットを制御して理想的なすれ違いを実現することができる。

これまで多くの研究で、社会的な移動パターンをモデル化する手法が提案されてきた。人は他人との社会的な関係に基づいて快適な距離を保ちながら行動する [1]。複数の人が存在する中でロボットが移動する場合、ロボット自身が社会的に許容される距離を保つことで周囲の人が快適に感じられる [2]。これまでの多くの研究ではパラメトリックモデルによって歩行者の移動を表現している。しかし、車いすロボットが利用される病院などでは様々な移動手段が存在し (図 1)、それぞれ異なる移動特性を持っている。また、同一の移動手段であっても利用する人やその場の状況

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology, Nara 630-0192, Japan

² 国際電気通信基礎技術研究所
ATR Intelligent Robotics and Communication Laboratories, Kyoto 619-0288, Japan

³ NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, Kyoto 619-0237, Japan

a) yuki-tan@is.naist.jp



a) pedestrian b) wheelchair c) walk support d) cart

図1 車いすロボットが運用される病院内で見られる移動手段

に応じて移動の傾向が異なる。例えば、すれ違う相手と接触する直前で回避する場合もあれば、遠く離れた時点から緩やかに避ける場合もある。移動パターンを単純なパラメトリックモデルで表現した手法 [3] では予め学習してあるパラメータに基づいた移動しか表すことができない。多様なすれ違い方を扱う場合、すれ違いパターン毎に適切なパラメータを学習することは困難であり、これまでのパラメトリックモデルではこのような複雑な問題を扱うことは難しい。

多様なすれ違い方を予測するためには、パラメトリックモデルではなく、観測されたすれ違い時の軌跡データ群から様々なすれ違いパターンを学習する、事例ベースの予測手法が有効であると考えられる。そこで提案手法では、実際のすれ違い行動から、行動パターンを抽出し、多様なすれ違い方をモデル化する。そして、新たに観測されたすれ違いと最も類似する行動パターンを推定することで、将来の位置を予測する。すれ違い方の差異を表すために、すれ違う直前の数秒間における移動体間の相対位置と移動速度に着目し、距離関数を定義する。

本稿の構成は以下の通りである。第2章では移動予測モデルに関する関連研究を紹介する。第3章ではすれ違い方を表現する特徴量を定義し、クラスタリングに基づく提案手法について述べる。第4章では提案手法の有用性を検証した実験の枠組みと、実験結果について述べる。第5章、第6章では本研究に関する考察と結論について述べる。

2. 関連研究

これまで多くの研究で、正確に歩行者を追跡するための移動モデルが提案されてきた。歩行者の動きを予測する歩行動作の単純なモデルは、人が一定の速度で動き続けると仮定した等速線形モデルである。このモデルは短期的な移動を予測する際に効果的であり、多くの追跡手法で用いられてきた [5][6]。

観測された歩行者の動作を学習するため、観測領域を分割したグリッド内 [7] での移動の変化 [8] や停止領域の変化 [9] をモデル化できることが知られている。これらの手法では歩行者と他の移動対象との相対関係を含んでいないため、相互にすれ違いを行う場合には適応できない。そのため、歩行者間の相対関係を考慮した予測モデルが注目されてきている [10]。Pellegrini ら [11] は歩行者間の反発力

をエネルギー関数として表現し、これを最小とするすれ違い行動を予測した。Luber ら [12] や Yamaguchi ら [13] は社会的な相互作用を考慮したすれ違い行動のモデルを提案し、追跡精度を向上させた。

しかし、これらの手法のようなパラメトリックモデルを用いて実環境で観測される多様なすれ違いパターンに対応するためには、様々なすれ違いパターンを表現するためのパラメータを無数に用意する必要があり現実的ではない。過去に取得したすれ違いデータを分類して異なるパターンを学習することが、多様なすれ違い方が発生する場合の予測に有効であると考えられる。Luber ら [4] は観測軌跡のクラスタリングにより社会性を考慮した歩行者の移動モデルを提案した。この手法では広場のような環境ですれ違う際の相手との進行方向の角度に基いてクラスタリングを行い、すれ違い方をモデル化している。しかし、進行方向の角度に注目した手法であり、移動速度の変化や相手の進行方向からの回避による多様なすれ違い方を表現するには限界がある。

そこで本稿では、多様なすれ違い方における相対位置や速度の時間変化に注目し、そのパターンをクラスタリングによって抽出し、移動軌跡を予測する手法を提案する。

3. クラスタリングに基づく移動対象のすれ違い予測

3.1 提案手法の概要

図2は図1に示す移動対象が直進する車いすロボットとすれ違う際の移動軌跡を表す。本手法では、このようにすれ違う二つの軌跡のペアをクラスタリング等、解析する。図3は提案手法における処理の流れを示す。オフライン処理では、予め観測した様々な軌跡データを分類し、クラスタとして抽出する。クラスタはそれぞれ異なるすれ違いパターンを表現している。オンライン処理では、これまでに観測されたすれ違い方が最も近いクラスタを選択し、クラスタの代表ベクトルに基づいて将来の位置を予測する。オフライン処理については3.3で、オンライン処理については3.4でそれぞれ詳細を説明する。

3.2 すれ違い行動間の距離関数

予備実験を行ったところ、図2に示すようなすれ違い行動が観測された。すれ違う行動はすれ違う時刻から数秒前までの相対位置と移動速度の時間変化によって様々なパターンに分類できる。そこで本研究ではすれ違い方を表現するための特徴量として、相対位置と移動速度に焦点を当てる。

最も単純な相対位置を表す特徴量には、相対距離や2次元平面上での x, y 軸の値、進行方向の角度差 [4] などが挙げられる。しかし、相対距離では相手の位置の方向やすれ違い時の避けた量を表現することができない。また、平面

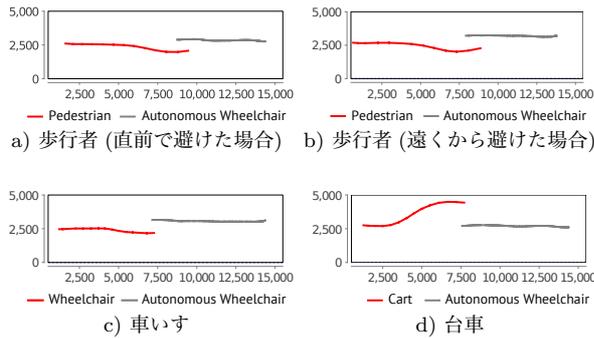


図 2 移動対象 (図 1) が直進する車いすロボットとすれ違う際の移動軌跡。歩行者、車いす、台車のロボットを避ける軌跡はそれぞれ異なる。a,b:歩行者は自由に動き回れるため、様々なすれ違い方が観測される。c:車いすは機敏に動くことが難しいため、避ける量が制限される傾向がある。d:台車は荷物の影響を受けるため、動作が大きくなる傾向が見られる。

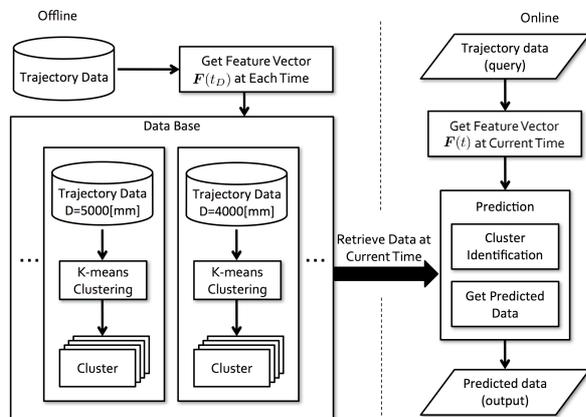


図 3 提案手法の処理の流れ

における各軸の値を特徴量に用いるためには軸の方向を決定する必要があるが、広いスペースで様々な方向を向いてすれ違うような複雑な環境下では軸の方向を固定することができない。進行方向の角度差を用いることでそのような複雑な環境下での相対的な位置関係は表現できるが、廊下のように必ず一定方向を向く環境ではすれ違い方の詳細を表現することができない。限られた学習サンプル数を分類してすれ違いパターンを学習するためには、できるだけ少ない次元数の特徴量を用いて効率的にすれ違い方を表現する必要がある。従って、一つの次元で多くの情報を含む特徴量を使用することが望ましい。

そこで、相対的な位置関係を図 4 の Lateral Distance (以降, LD) として定義する。LD はロボットが現在位置から目標地点を見た時のすれ違い対象との側方距離であり、すれ違う相手がロボットをどれだけ避けた位置にいるのかを表現している。すれ違い対象がロボットの左側にいる場合には正の値を、右側にいる場合には負の値をとると定義する (図 4 では LD は負の値である)。大きく避けるようなすれ違い方を観測した場合には LD の絶対値は大きくなり、

少ししか避けられない場合には LD の絶対値は小さくなる。軸がロボットの位置によって変化するため、様々な方向のすれ違いであっても同様に扱うことができ、LD の符号や値の大きさによって、すれ違い時に避けた量を直接表現することができる。

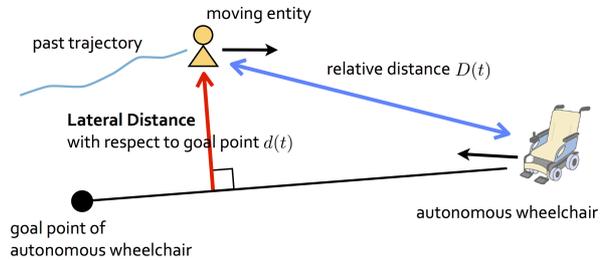


図 4 観測から得られる特徴量。Lateral Distance はロボットがゴール方向を向いたときの側方距離であり、移動対象がロボットを避けた際の避け量と方向を表す。

この LD と対象の移動速度の時系列データを用いることですれ違い方を表現する。ロボットと移動対象がすれ違うとき、時刻 t におけるすれ違い方の特徴ベクトル F を以下のように定義する。

$$F(t) = [d(t), d(t - \Delta t), \dots, d(t - (N - 1)\Delta t), v(t), v(t - \Delta t), \dots, v(t - (N - 1)\Delta t)] \quad (1)$$

ここで $d(t)$ は時刻 t における LD, $v(t)$ は対象の移動速度, Δt はサンプリング周期を表す。特徴ベクトルを計算する際の時間ウィンドウ長を T とすると、時間ウィンドウ内のサンプル数は $N = T/\Delta t$ である。実験では、 $\Delta t = 500[\text{msec}]$, $T = 3[\text{sec}]$ とした。

式 1 に基いて二つのすれ違い方を比較するための距離関数を定義する。時刻 t において、各すれ違いから得られる特徴ベクトルを F_a, F_b (図 5) とすると、重み付きユークリッド距離で以下のように定義する。

$$\text{distance}(F_a, F_b) = \sqrt{\sum_{i=0}^{N-1} (N - i) C_{a,b}(i)} \quad (2)$$

$$C_{a,b}(i) = (d'_a(t - i\Delta t) - d'_b(t - i\Delta t))^2 + (v'_a(t - i\Delta t) - v'_b(t - i\Delta t))^2 \quad (3)$$

$d'_a(t), v'_a(t)$ は F_a の正規化された $d_a(t), v_a(t)$ とする。

3.3 クラスタリング

前節の距離関数 (式 2) に基いてすれ違い方をクラスタリングする。クラスタリングの流れを図 6 に示す。ここでは、図 4 の相対距離 D に対応するクラスタデータベースを構築する。従って、データベースを作成する D を設定し

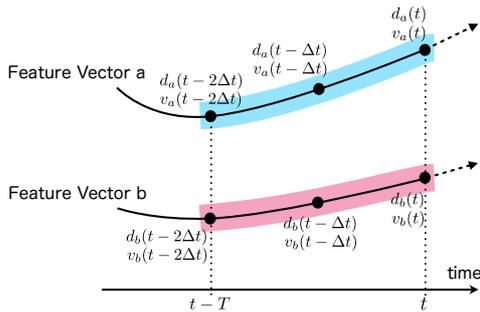


図5 すれ違い行動間の比較. 現在時刻 t から T 秒前までの範囲で特徴量をサンプリングし、ユークリッド距離を用いて距離計算を行う.

ておく必要がある. 実験では $1\sim 7\text{m}$ の 1m 間隔で相対距離 D を設定した.

すれ違いにおける移動対象とロボットとの相対距離が D になった時刻を t とすると, 時刻 $t-T$ から時刻 t のすれ違い軌跡から式 1 の特徴ベクトルを抽出し, D 毎のデータベースに蓄積させる. 各データベースで式 2 に基づいてクラスタリングすることでクラスタデータベースを構築する.

クラスタデータベースに含まれるクラスタはそれぞれ典型的なすれ違いパターンを表す. 例えば, あるクラスタでは双方が近づいたときに大きく避けるすれ違い方を表し, あるクラスタでは小さく避けるすれ違い方を表す.

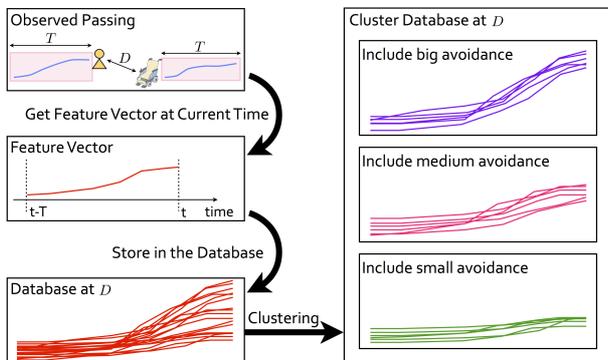


図6 クラスタリングの概要

3.4 予測

前節で構築したクラスタデータベースを用いて予測を行う. 予測処理の流れを図7に示す. 新たに移動対象が観測されたとき, ロボットと移動対象の軌跡から相対距離 \hat{D} を取得する. 次に, $\hat{D} < D$ となる最小の相対距離 D を求め, 相対距離 D に対応するクラスタデータベースを決定する. 現在までのすれ違い軌跡から特徴ベクトル F を抽出し, クラスタデータベースから距離関数 (式 2) に基づいて特徴ベクトル F とクラスタ中心の距離を計算して最も近いクラスタを選択する. 選択したクラスタの中心ベクトルから将来の LD の推移を予測結果として取得する. このとき, 予測

結果を滑らかにするため, 観測データにおける現在の LD と予測結果の現在時刻の LD を重ねあわせる.

例を挙げて予測の流れを説明する. $1\sim 7\text{m}$ の 1m 間隔で相対距離 D を設定してクラスタデータベースを構築したとする. まず, 新たに観測された移動対象とロボットの相対距離 \hat{D} が 7m になった時点で $D = 7\text{m}$ のクラスタデータベースを選択する. 次に観測されたすれ違い軌跡から特徴ベクトル F を抽出する. このとき, 現在時刻 t から $t-T$ までのデータを使用する. そして, 選択したクラスタデータベースに含まれる各クラスタの中心ベクトルと距離を計算し, 最も近いクラスタを選択して予測結果を取得する. その後, 相対距離 $\hat{D} = 6\text{m}$ になった時点で $D = 6\text{m}$ のクラスタデータベースを選択し, 同様の処理を行う.

一般的に, 相対距離 D が小さくなるほど予測が容易になるといえる. そこでこのように, クラスタデータベースに設定された相対距離 D に従って段階的に予測を更新することで, より精度の高い予測結果を得ることができる.

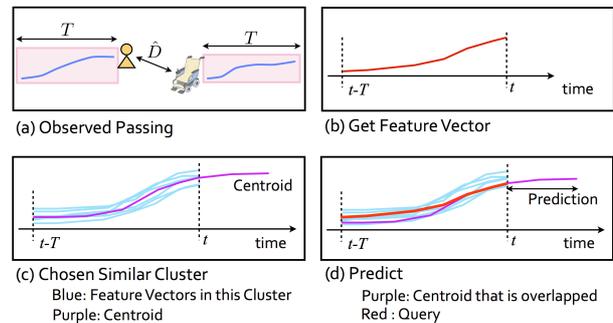


図7 予測処理の概要

4. 実験

4.1 実験設定

提案手法を評価するため被験者と車いすロボットがすれ違い実験を行った. 多様な移動手段が見られる環境として, 病院が挙げられる. 本実験では病院内で頻りに利用される, 歩行者, 車いす, 歩行器, 台車の4種類の移動手段を使用した (図1). 各被験者はこれら4種類の移動手段を利用して, 対向する車いすロボットとすれ違いを行った. 図8は実験環境を, 図9は実験の様子を示している. 条件を統一するため, 車いすロボットは目標地点に向かって直進するように制御した. すれ違いの開始地点及び目標地点を三つの異なる位置で設定し, 軌跡を計測した. 全ての条件下で被験者は図8のA地点からD地点へ移動した (戻る場合にはD地点からA地点). また, 車いすロボットは以下の条件で移動した.

- (a) D地点からA地点 (A地点からD地点)
- (b) E地点からB地点 (B地点からE地点)
- (c) F地点からC地点 (C地点からF地点)

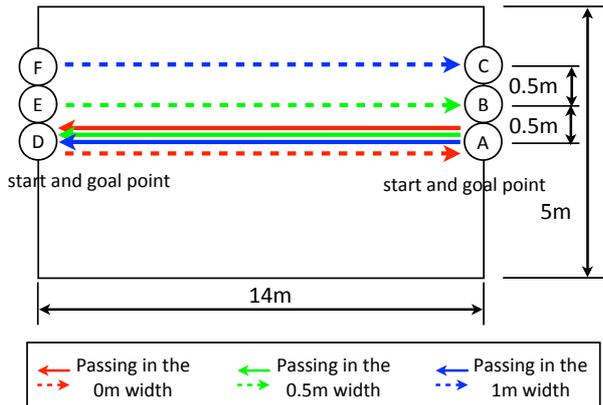


図 8 実験環境



図 9 実験風景

表 1 実験設定

すれ違い時の間隔	0, 500, 1000 mm
移動手段	歩行者, 車いす, 台車, 歩行器
被験者数	30 人
被験者 1 人あたりの試行回数	32 回
全すれ違い試行回数	960 回

(a), (b) の条件で 3 回, (c) の条件で 2 回すれ違いを試行した。1 人の被験者に対して 4 種類の移動手段で各条件のすれ違いを行い, 32 回のすれ違い方を計測した。これを 30 人の被験者で実験を行い, 合計で 960 回のすれ違い方を計測した。表 1 に実験設定をまとめた。

環境中に 8 個のレーザレンジファインダ (LRF) を用いた追跡システムにより, 移動対象の軌跡を計測した。追跡システムには [6] に基づくパーティクルフィルタを用いたアルゴリズムを使用し, 車いすロボットと被験者を追跡した。

4.2 クラスタと予測の構成

図 10 は相対距離 $D = 2000\text{mm}$ のクラスタデータベースに含まれるクラスタの中心ベクトルの LD 成分である。横軸は時刻 t , 縦軸は LD の値 $d(t)$ を表す。このとき, 相対距離 $D = 2000\text{mm}$ になった時刻から 3 秒前までの範囲で特徴ベクトルを抽出してクラスタリングを実行した。車いすロボットから見て移動対象が左側にいる場合には $d(t)$ は正の値を, 右側にいる場合には負の値をとる。クラスタ中心は横軸に対してほぼ線対称であり, クラスタ毎に異なるすれ違い方を表現していることがわかった。

例えば, 図 11 はある二つのクラスタ内の LD を示している。左のクラスタでは両者が接近してから急激に避ける挙動が見られるが, 右のクラスタでは事前に回避行動をとった。

図 12, 図 13 は別な二つのクラスタ内の LD と移動速度を示している。二つのクラスタにおける LD の推移は類似しているが, 速度成分は異なっている。このように, 各クラスタが特徴的なすれ違い方を表現しており, 新たに観測されたすれ違いに近いものを選択することで正確な予測を実現できた。

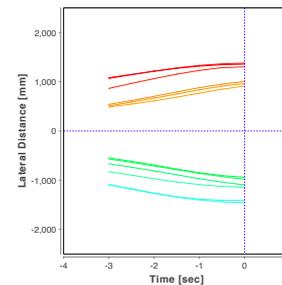


図 10 各クラスタの中心ベクトルの LD. 中心ベクトルの距離に応じて色を設定している。すれ違う際の避けた方向(左右)や, 直前で避けるか遠くの地点から避けているかといった回避行動のタイミング, 避け量の大小などで分かれたクラスタが構築された。

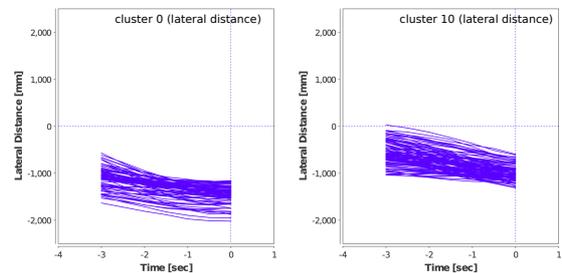


図 11 クラスタ 0,10 に含まれる LD, クラスタ 0 は遠くの地点から大きく避けるすれ違い方で構成された。クラスタ 10 は直前で小さく避けるすれ違い方が集まった。

図 14 (a) は新たに観測されたすれ違い方において, 相対距離 $D = 5000\text{mm}$ になった時点で選択されたクラスタの LD を示す。また, 図 14 (b) は選択したクラスタによる将来の LD の予測 (青点) と将来の真の LD (赤点) を示している。ここから少し時間が経過し, 相対距離 $D = 4000\text{mm}$ の時点で改めて同じ処理を行ってクラスタを選択すると, 図 15 (a) に示すようになった。図 15 (b) では, 時間が経過して新たなクラスタが選択されることで, 時刻 $t = 0$ になる時点での予測結果がより良くなることがわかった。時間経過に応じてクラスタを繰り返し選択することで, すれ違い方の特徴がより鮮明になるため, 最終的により正確な予測結果が得られた。

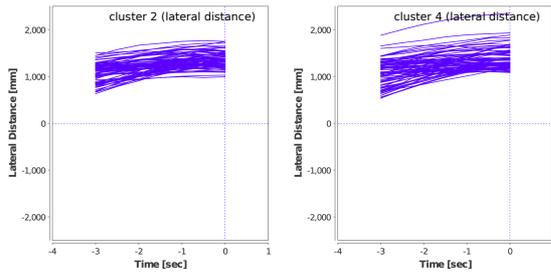


図 12 クラスタ 2,4 に含まれる LD

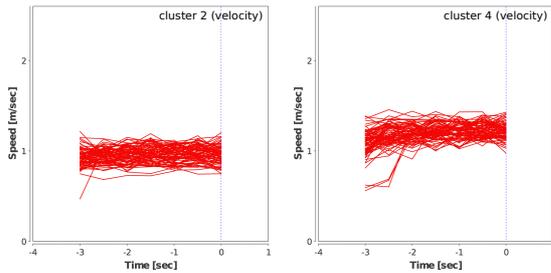
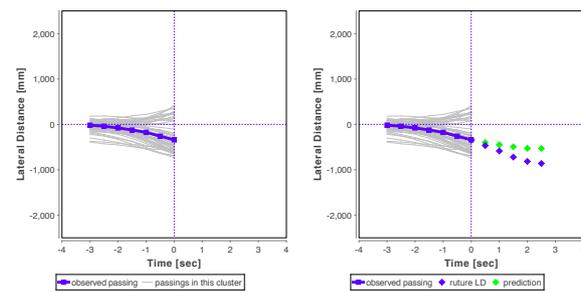


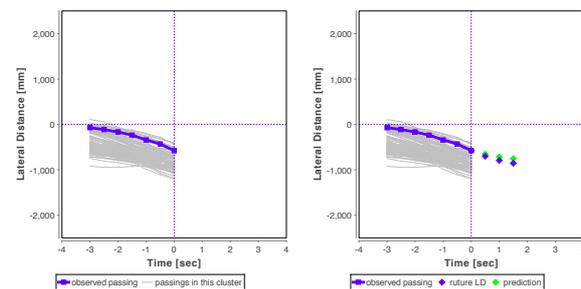
図 13 クラスタ 2,4 に含まれる速度特徴. 図 12 のように同様の LD を持つクラスタであっても, 速度に着目すると異なるすれ違いを表現できることが分かった.



(a) 観測されたすれ違い方と選択したクラスタ

(b) 予測結果

図 14 相対距離 $D=5000$ [mm] における予測結果



(a) 観測されたすれ違い方と選択したクラスタ

(b) 予測結果

図 15 相対距離 $D=4000$ [mm] における予測結果

4.3 予測結果

提案手法による予測結果を評価するため, クラスタリングを行わない単純な最近傍法と比較した. 比較手法では, 新しいすれ違いが観測された場合, データベース内の全て

のすれ違いデータから最近傍を選択し, 予測結果として使用した.

社会的に許容されるナビゲーションを実現するためには, 車いすロボットと移動対象がすれ違う時点での LD を予測することが重要である. 従って, 本稿では車いすロボットと移動対象がすれ違う軌跡データから得られる LD の予測誤差を用いて提案手法を評価する. 図 16 は相対距離 D が 1000mm から 7000mm の 1000mm 間隔で予測を開始したときの平均予測誤差を示している. 相対距離 D が小さくなるにつれて予測が容易になるため, 予測誤差は相対距離に対して単調増加の性質を持つ. 提案手法での平均予測誤差は全ての場合で比較手法よりも小さな値となった. 相対距離が大きい場合には正確な予測が困難であり, どちらの手法でも似た予測結果となった. 相対距離が小さくなるにつれて, 提案手法ではより高精度な予測結果が得られた.

安全かつ社会的に許容されるナビゲーションを実現するためには, 大きな予測誤差を回避することも重要な要件となる. そこで我々は大きな予測誤差が発生する事例について調査した. 図 17, および図 18 は予測誤差が 1000mm 以上, 及び 1500mm 以上となった回数の割合を示している. どちらの場合にも提案手法の結果の値が比較手法よりも小さくなっており, 提案手法の優位性を明確に示している.

5. 議論

5.1 すれ違いパターンと対象の移動手段との関係性

図 19 は各クラスタに含まれる対象の移動手段の分布を示している. クラスタ 1 では車いすが半数以上含まれており, 対称的にクラスタ 5 では歩行者が殆どを占めている. 図 20 はクラスタ 1 とクラスタ 5 に含まれる移動対象の速度成分である. このように, 特定の移動手段がクラスタ内の大部分を占めている場合があり, 一つのクラスタで特定の移動手段のすれ違い方が表現することができる.

一方, このような傾向が見られないクラスタも存在する. これは, 移動手段が異なっても似たすれ違い方をとる場合もあることを意味する. 従って, 提案手法では移動手段の種類によって異なるすれ違い方と, 移動手段に依らない多様なすれ違い方の両方を表現することができる.

また, 予測実験の結果から, すれ違いに対して分類器を使用することで対象の移動手段を推定することが期待できる. しかし, 異なる移動手段の対象が状況に応じて同じようなすれ違いを行う場合があり, 短い軌跡から移動手段の特定を行うことは困難といえる. そこで, 様々な種類のセンサを使用して, 他の分類手法と組み合わせることが対象の移動手段を推定するのに有効であると考えられる.

5.2 他の環境への適応性

提案手法は観測されたすれ違い軌跡に基づいてすれ違い

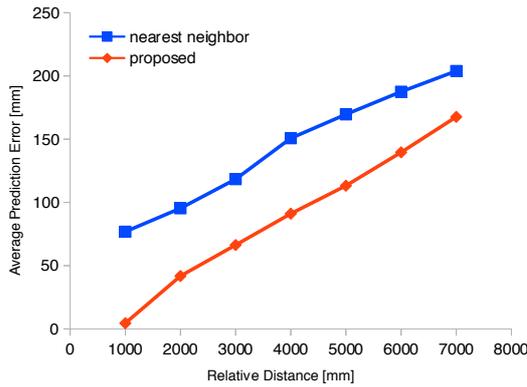


図 16 平均予測誤差. 横軸は予測を行った相対距離 D である. 相手との距離が近くなるほど予測が容易になるため, 予測誤差は小さくなった.

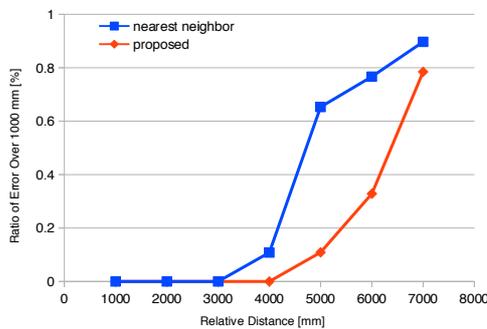


図 17 予測誤差 1000mm 以上となった結果の割合

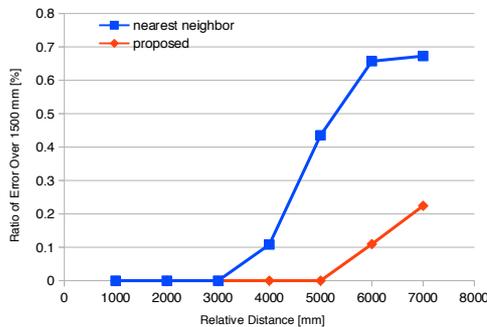


図 18 予測誤差 1500mm 以上となった結果の割合

方を予測する. 我々はシステムの使用環境に多数の移動手段が存在する病院や診療所を想定しているが, 今回行った実験では被験者は実際に病気や怪我をした人ではない. 健康者は病院内の人と比べて機敏に移動する傾向が見られ, 計測した軌跡の変化は実際の場合よりも大きくなると考えられる. すれ違い方の変化が大きい健康者の場合にも良好な結果を得ていることは, 変化が小さくなる病院などにおいても適用可能であると考え.

本稿では 1 対 1 の単純なすれ違いにのみ焦点を当てた. 実際の環境では, 複数の移動対象と同時にすれ違うことが考えられる. しかし, 多くの病院などの廊下は, 複数の移動対象と同時にすれ違える場所は多くないため, 病院内の

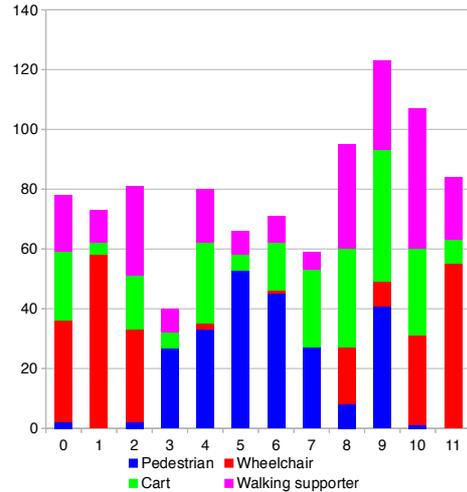
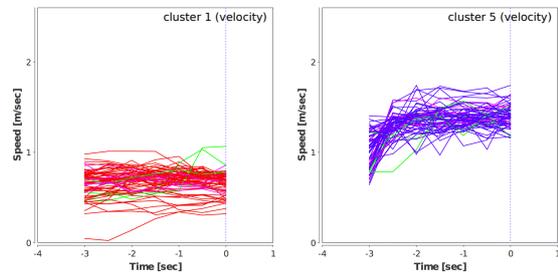


図 19 各クラスに含まれる移動手段の数



(a) cluster 1

(b) cluster 5

図 20 クラスに含まれる移動手段

ここでは速度成分のみを表示している. 色の設定については図 19 に対応している.

多くの場所でのすれ違いに適用できると考える.

また, 廊下の曲がり角や十字路のように移動が複雑になる環境下での適応性も重要な問題となる. このような環境で予測を行うためには, 短期的な目標地点を導入し, 各移動対象との距離を計算してクラスタリングすることで適応できる. 移動対象の経路全体は, 一時的な目標地点の連続としてモデル化できる. 例えば, ランドマークや建築物といった特徴的な存在を一時的な目標地点となりうる [3]. 一般的には, 目標地点は観測軌跡から推定できる [14].

6. まとめ

多くのすれ違いパターンに対応して正確な将来の相対位置を予測するために, 本稿では様々なすれ違いパターンを表すクラスを学習することで予測を行う手法を提案した. 提案手法では, 観測されたすれ違い軌跡から得られる LD と移動速度の時系列データを基にすれ違い方を予測し, 相対距離 $D = 5000\text{mm}$ 時点での予測における予測誤差 113mm で高精度に予測できることを示した. 本手法では観測された軌跡からモデルを構築するため, 新しい環境下で車いすロボットを動作させる場合においても, 容易に予

測用のデータベースを構築することができる。

車いすロボットの運用が想定される病院といった環境に対応するため、病院内で見られる、歩行者、車いす、歩行器、台車の4種類の移動手段を用いて研究室内で実験を行った。平均予測誤差は全ての場合において比較手法よりも小さく、大きい予測誤差の発生率も低かったことから、提案手法の有効性が示された。

今後の課題として、曲がり角や交差点など、より複雑な環境で提案手法が有効であることを確認する必要がある。また、提案手法での予測結果を用いて、すでに開発されている車いすロボット [15] を制御する機能を開発する必要がある。

謝辞 本研究は総務省委託研究「脳の仕組みを活かしたイノベーション創成型研究開発」により実施したものである。

参考文献

- [1] E. T. Hall, *The Hidden Dimension*. Anchor, 1966.
- [2] E. Pacchierotti, H. I. Christensen, and P. Jensfelt, "Evaluation of Passing Distance for Social Robots," in *Proc. of the 15th Int. Symp. on Robot and Human Interactive Communication (RO-MAN)*, 2006, pp. 315–320.
- [3] D. Helbing and P. Molnár, "Social force model for pedestrian dynamics," *Physical Review E*, vol. 51, no. 5, pp. 4282–4286, 1995.
- [4] M. Luber, L. Spinello, J. Silva, and K. O. Arras, "Socially-aware robot navigation: A learning approach," in *Proc. Int. Conf. on Intelligent Robots and Systems (IROS)*, 2012, pp. 902–907.
- [5] H. Zhao and R. Shibasaki, "A novel system for tracking pedestrians using multiple single-row laser range scanners," *IEEE Trans. Syst., Man, Cybern. Part A*, vol. 35, no. 2, pp. 283–291, 2005.
- [6] D. F. Glas, T. Miyashita, H. Ishiguro, and N. Hagita, "Laser-based tracking of human position and orientation using parametric shape modeling," *Advanced Robotics*, vol. 23, no. 4, pp. 405–428, 2009.
- [7] K. Nagel and M. Schreckenberg, "A cellular automaton model for freeway traffic," *J. Phys. I France*, vol. 2, pp. 2221–2229, 1992.
- [8] B. D. Ziebart, N. Ratliff, G. Gallagher, C. Mertz, K. Peterson, J. A. Bagnell, M. Hebert, A. K. Dey, and S. Srinivasa, "Planning-based prediction for pedestrians," in *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, 2009, pp. 3931–3936.
- [9] M. Bennewitz, "Learning Motion Patterns of People for Compliant Robot Motion," *Int. J. Robotics Research*, vol. 24, no. 1, pp. 31–48, 2005.
- [10] P. Scovanner, and M. F. Tappen, "Learning pedestrian dynamics from the real world," in *Proc. Int. Conf. on Computer Vision (ICCV)*, 2009, pp. 381–388.
- [11] S. Pellegrini, A. Ess, K. Schindler, and L. van Gool, "You'll never walk alone: Modeling social behavior for multi-target tracking," in *Proc. Int. Conf. on Computer Vision (ICCV)*, 2009, pp. 261–268.
- [12] M. Luber, J. A. Stork, G. D. Tipaldi, and K. O. Arras, "People tracking with human motion predictions from social forces," in *Proc. Int. Conf. on Robotics and Automation (ICRA)*, 2010, pp. 464–469.
- [13] K. Yamaguchi, A. C. Berg, L. E. Ortiz, and T. L. Berg, "Who are you with and where are you going?" in *Proc. Int. Conf. Computer Vision and Pattern Recognition (CVPR)*, 2011, pp. 1345–1352.
- [14] T. Ikeda, Y. Chigodo, D. Rea, F. Zanlungo, M. Shiomio, and T. Kanda, "Modeling and prediction of pedestrian behavior based on the sub-goal concept," in *Proc. Robotics Science and Systems (RSS)*, 2012.
- [15] L. Morares, N. Kallakuri, K. Shinozawa, T. Miyashita, and N. Hagita, "Human-Comfortable Navigation for an Autonomous Robotic Wheelchair (in press)," in *Proc. Int. Conf. on Intelligent Robots and Systems (IROS)*, 2013.