

ロボットナビゲーション用シミュレータのための 環境に適した群衆モデルの評価

田中 碧^{1,a)} 加藤 由花¹

概要: 人・ロボット共存環境で動作する自律移動ロボットの研究開発には、一般にロボット用シミュレータが利用される。ここでは、移動する歩行者を動的障害物としてシミュレータ内に設定する必要があるため、そのために群衆シミュレーション分野で開発された様々な群衆モデルを用いることが多い。しかし、既存の群衆モデルには、全エージェントが同一モデルに従う、環境側の情報を全て観測可能である等の前提条件が存在し、ロボット用シミュレータで利用する場合の妥当性は必ずしも明らかになっていない。本稿では、ロボットナビゲーション用シミュレータでの利用を前提に、既存の群衆モデルの分析を行う。さらに簡易な移動モデルを用いたシミュレーション実験を行い、環境の違いが群衆モデルの性能に与える影響について評価する。

1. はじめに

近年、サービスロボットなど、人・ロボット共存環境で動作する自律移動ロボットへの関心が高まっている。これらのロボットでは、オープンスペースでの安全かつ効率的な経路計画が重要な研究課題になっており、古くから、群衆内でのロボットサービスについて多くの実証実験が行われてきた [1], [2]。しかし、現在に至っても実証実験の域を抜けることは難しく、実社会でのサービス提供は、一部の限定された環境内での限定された機能にとどまっている。人の行動は構造化されておらず、明示的なルールにも従わないため、自律移動ロボットには、不確実な動的環境への対応が求められるためである。人の密度が高くなると、移動できるスペースを見つけれずロボットが停止してしまう Freezing Robot Problem (FRP) [3] に陥ってしまう。

これらの問題を解決するために、近年では特に、強化学習等、機械学習に基づく経路計画手法が多く提案されている。我々もこれまで、歩行者が存在する動的環境を対象に、強化学習を用いた自律移動ロボットナビゲーション手法の研究開発を進めてきた。具体的には、ロボットに搭載された LiDAR によるセンシング結果のみを利用し、観測した周囲の混雑状況により行動ルールを切り替えることで、局所的動作計画を行う手法を提案している [4]。ここで、ロボットを対象とした強化学習モデルの訓練は、主に学習時

間の制約から、実ロボットを用いた実世界での学習が困難である場合が多く、シミュレータを用いるのが一般的である。Sim-to-Real と呼ばれる一連の研究が存在し、一例として自動運転のための強化学習用シミュレータに関する研究 [5] などがある。ここでは、動的障害物として、移動する歩行者をシミュレータ内に設定する必要があるが、どのような歩行者移動モデルを用いるのが良いかは明らかになっていない。本稿では、文献 [4] で提案するナビゲーション手法を対象に、適切な歩行者移動モデルについて考察する。

我々はこれまでも、歩行者移動モデルに関する一連の研究を行ってきた。文献 [6] では、ロボットの存在を前提とした環境における歩行者の移動モデルを提案した。これは、人と人、人と障害物間に斥力を仮定し、粒子の運動として人の移動をモデル化する Social Force Model (SFM) [7] を拡張した手法である。しかし、この手法には、シミュレーション用のモデルではない、環境ごとに事前にベクトル場の設計が必要であるという課題がある。文献 [8] では、歩行者の未来の移動経路を、観測された過去の移動経路から系列データとして予測する手法を提案した。これは、データセットを用いて事前に学習した予測器を用いる機械学習 (LSTM) ベースの手法である。データを先読みすることにより、行動制御に利用することが可能であるが、ロボットと人との相互作用が発生するシミュレーションで利用することはできない。ロボットの動作により歩行者の経路はリアルタイムに変わるため、環境に適した移動モデルが必要になるためである。

本稿では、環境に適した歩行者移動モデル (以降、既存

¹ 東京女子大学 大学院理学研究科
Suginami, Tokyo 167-8585, Japan
^{a)} d21m205@cis.twcu.ac.jp

研究で用いられる用語に合わせて群衆モデルと記す)の構築を目指して、まず既存モデルの分析を行う。次に、簡易なシミュレーション実験により、環境の違いが群衆モデルに与える影響を調べる。本稿の貢献は以下の2点である。

- 既存の群衆モデルを分析し、ロボットシミュレータで使われることが多い Optimal Reciprocal Collision Avoidance (ORCA) [9] の課題を示す。
- 簡易実験により、環境の違いが人の移動傾向に与える影響を示す。

2. 関連研究

2.1 ロボットシミュレーション用群衆モデルに関する研究

群衆モデルは様々なアプリケーションで利用されており、活発に研究が進められている分野である。都市計画や避難行動のシミュレーションの他、CG、アニメーション、ビデオゲームなどでも利用されている。マクロシミュレーション(群衆を流れとして扱う)とミクロシミュレーション(仮想エージェントの集まりとして群衆を表現する)の2種類に分類されるが、ロボットシミュレーションでは主にミクロシミュレーションが対象になる。

ミクロシミュレーションはさらに、以下の3つに分類されることが多い。Force モデルに基づく手法、Velocity Object (VO) に基づく手法、視覚情報に基づく手法である。Force モデルに基づく手法の代表は、前述した SFM [7], [10] である。環境や周囲のエージェントから仮想的な斥力を受けると仮定し、各エージェントの時刻ごとの振る舞いを決定するもので、SFM を拡張した多くの手法が提案されている。VO に基づく手法では、複数の独立したエージェントが相互にコミュニケーションすることなしに、互いに衝突を回避するスムーズな経路が生成される。ここでは、エージェントの速度を利用し、他のエージェントの未来の動きを短い時間間隔で逐次予測しながら自身の行動を決定する。代表的な手法に ORCA [9] がある。視覚情報に基づく手法は、オプティカルフロー、視差、物体の大きさの変化など、視覚的な手がかりから各エージェントが振る舞いを生成するものである。例えば [11] などがある。

いずれの手法も様々なロボットシミュレータで利用されており、特に ORCA ベースの手法がよく用いられる。ただし、その妥当性は明らかになっていない。

2.2 群衆モデルの評価に関する研究

複数の群衆モデルを比較し、その妥当性を検証する研究も行われている。文献 [12] では、群衆モデルをロボットの行動生成に利用することを目的に、各群衆モデルを分析し、問題点を明らかにしている。群衆内での実ロボットナビゲーションは未だ多くの課題を抱える一方、群衆シミュレーションの分野では高密度な仮想エージェントのスムーズな移動が実現している。この要因を分析することがこ

での目的である。論文内では、ロボティクスの観点から、既存の群衆モデルの問題点を以下の3点にまとめている。

- Homogeneity: 群衆を構成する仮想エージェントが全て同じ振る舞いをする(つまり、同じアルゴリズムで制御される)ことを前提としている。これは現実世界ではありえない。
- Omniscience: 仮想エージェントは、環境側の情報(対象環境に存在する全てのオブジェクトの形・位置・速度などの完全な情報)を保持していることを前提としている。実ロボットは、一部の情報のみ観測可能である場合がほとんどである。
- Safety: 仮想エージェント同士の軽微な接触はある程度許容されるが、実ロボットでは許容されない。

これらのうち、最初の2つの前提条件を外してシミュレーション実験を行ったところ、特に VO に基づく手法では性能(この場合は衝突率)が著しく劣化し、移動軌跡も不自然な形状になることが示されている。

本稿では、シミュレータ上のロボットと仮想エージェントは異なるアルゴリズムで動作することになり、既存群衆モデルにおける Homogeneity の前提は問題になる。また、環境の観測はロボットに搭載されるセンサーで行うため、Omniscience の前提も満たすことができない。

3. 対象とするナビゲーション手法

本稿の考察対象は、文献 [4] で提案するナビゲーション手法である。本章では、その概要を説明する。本手法は、人と空間を共有する自律移動ロボットが、人と障害物が混在する環境下において安全かつ効率的に目的地まで移動することを目的に、深層強化学習(Deep Reinforcement Learning: DRL)手法を含む複数の行動決定ポリシー(サブポリシーと呼ぶ)を状況に応じて切り替えながらナビゲーションを実現するものである。手法の概要を図 1 に示す。サブポリシーとしては、以下の4種類を定義している。

- DRL ポリシー: 安全性と効率性の双方を考慮した行動を生成する。シミュレータ上で学習した DRL モデルを利用する。
- 効率ポリシー: 効率性を重視し、高い速度を維持してゴールに向かう。代表的なフィードバック制御手法である PID 制御を用いる。
- 安全ポリシー: 安全性を重視し、DRL モデルの入出力に制限をかけることでロボットの速度を制限する。
- リセットポリシー: 停止、振動状態から脱する行動を生成する。

サブポリシーの切替には、ロボット周辺の障害物までの最小距離(l_{min})およびロボット周辺の非専有領域の面積(s)を用いる。後者は、ロボットのスキャン範囲内で、障害物が存在しない領域の面積である。 l_{min} が安全しきい値以上であれば効率ポリシー、リスクしきい値以下であれば

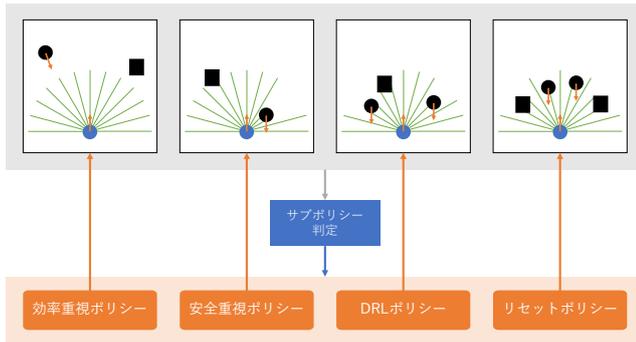


図 1 ナビゲーション手法の概要 [4]. ロボット周辺の状況を観測した結果に基づき、適切なサブポリシーが選択される。青丸がロボット、黒丸が歩行者、黒四角が障害物を表す。緑線は LiDAR によるスキャン範囲をイメージしており、例えばロボット周辺の歩行者密度が高い場合にはリセットポリシーが選択される。

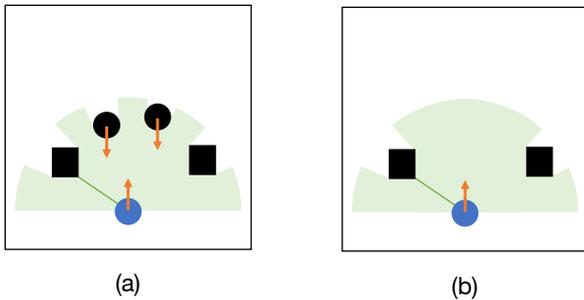


図 2 サブポリシーの切替に利用する l_{min} と s のイメージ [4]. 緑線が l_{min} , 薄緑の領域が s を表す。

安全ポリシー, s がリスクしきい値以下であればリセットポリシーを選択し、いずれでもない場合に DRL ポリシーが選ばれる。図 2 に l_{min} と s のイメージを示す。緑線が l_{min} , 薄緑の領域が s である。LiDAR の観測は離散化されたデータとして取得されるので、面積 s はこれらの観測値の和として算出することができる。

文献 [4] では、移動障害物として、ロボットと歩行者を区別せずに、マルチロボット環境としてモデル化が行われている。また、ロボットの持つ移動ポリシーは、自ロボットを含め全て同じであることを仮定している。本稿で考察対象とする群衆モデルは、このうち、自ロボット以外の他のロボットの移動モデルを置き換えるものになる。

4. 群衆モデルの分析

群衆モデルとしては、文献 [12] で取り上げられている 3 種類のモデルのうち、視覚情報に基づく手法を除いた 2 種類を取り上げる。本稿では観測に LiDAR を使うことを前提としているためである。以下、それぞれのモデルの概要を説明する。

4.1 各モデルの概要

Force モデルに基づく手法として Universal Power Law (UPL) [13], VO に基づく手法として Optimal Reciprocal Collision Avoidance (ORCA) [9] を取り上げる。

4.1.1 UPL

UPL は SFM ベースの群衆モデルである。SFM では、各エージェントは粒子としてモデル化され、エージェントとエージェント、エージェントと壁 (障害物) の間に物理的斥力と心理的斥力が働くことと仮定し、目的地からの引力との合力により、エージェントの進行方向を決定する [10]。数理モデルとしては、時刻 t における速度の変化量を、以下の運動方程式

$$m_i \frac{dv_i(t)}{dt} = m_i \frac{v_i^0(t) - v_i(t)}{\tau_i} + \sum_{j(\neq i)} f_{ij} + \sum_w f_{iw} \quad (1)$$

により計算する。ここで、 m_i はエージェント i の質量、 $v_i^0(t)$ は目標速度、 $v_i(t)$ は実際速度、 τ_i はある時間間隔である。各エージェントは、他のエージェント j と壁 w から、速度とは独立のある距離を保とうとする。これを以下の相互作用力 f_{ij} (エージェント間に働く力) と f_{iw} (エージェントと壁の間に働く力) でモデル化する。

$$f_{ij} = \left\{ A_i \exp\left(\frac{r_{ij} - d_{ij}}{B_i}\right) + kg(r_{ij} - d_{ij}) \right\} \mathbf{n}_{ij} + \kappa g(r_{ij} - d_{ij}) \Delta v_{ji}^t \mathbf{t}_{ij} \quad (2)$$

$$f_{iw} = \left\{ A_i \exp\left(\frac{r_{iw} - d_{iw}}{B_i}\right) + kg(r_{iw} - d_{iw}) \right\} \mathbf{n}_{iw} - \kappa g(r_{iw} - d_{iw}) (\mathbf{v}_i \cdot \mathbf{t}_{iw}) \mathbf{t}_{iw}. \quad (3)$$

式 (2) における $A_i \exp((r_{ij} - d_{ij})/B_i) \mathbf{n}_{ij}$ はエージェント間に働く心理的斥力である。ここで、 A_i と B_i は定数、 r_{ij} はエージェント i と j の身体の半径の和、 d_{ij} はエージェントの重心間の距離、 \mathbf{n}_{ij} は j から i 方向に向かう単位ベクトルである。心理的斥力は i と j が近づくほど大きくなる。 $kg(r_{ij} - d_{ij}) \mathbf{n}_{ij}$ は物理的斥力であり、 k は定数である。 $g(x)$ は、エージェント同士がお互いに接触していない場合 ($d_{ij} > r_{ij}$) に 0 を返し、それ以外に x を返す関数である。物理的斥力も i と j が近づくほど大きくなる。 $\kappa g(r_{ij} - d_{ij}) \Delta v_{ji}^t \mathbf{t}_{ij}$ は摩擦を表し、 κ は定数、 Δv_{ji}^t は接線方向の速度差、 \mathbf{t}_{ij} は \mathbf{n}_{ij} に直行する単位ベクトルである。式 (3) も同様に考えられる。

このように、SFM には多くのパラメータが存在し、環境に適したモデルの設計は困難である。パラメータ値はアドホックに定められる場合が多いが、UPL では大規模データセットの分析結果に基づき値を決定している。

4.1.2 ORCA

ORCA は群衆シミュレーション等において、歩行者の動きを生成するために用いられることが多い移動モデルである。元々はマルチロボットの衝突回避問題のために開発されたアルゴリズムであり、数百台以上のロボットが衝突す

ることなくゴールまで移動する様子等が公開されている*1。ただし、次節で述べるように、環境側に監視用のセンサーが設置されている等、対象となる環境中の全ての障害物を観察できることが前提となっている。ベースとなるのは、動的な障害物に対して、その速度を考慮することで衝突回避を実現する Velocity Obstacles (VO) [14] と呼ばれる考え方である。VO は、二次元平面上を移動する円形のロボットと障害物を対象にしており、各々に対して、collision cone と velocity obstacle と呼ばれる 2 種類のコーン型の領域（衝突領域）を定義する点がポイントである。以下、概要を説明する。

ロボットを R 、障害物を A とし、 R の位置と速度を $\mathbf{x}_R, \mathbf{v}_R$ 、 A の位置と速度を $\mathbf{x}_A, \mathbf{v}_A$ とする。 R と A が衝突する危険性のある相対速度 $\mathbf{v}_R - \mathbf{v}_A$ の集合を領域 CC_A^R (collision cone) と定義すると、両者の相対速度ベクトルがこの領域内にあり続けた場合にロボットは障害物と衝突する。ここで CC を求めるために、 A の視点に基づき、自らの専有範囲と R の専有範囲の空間和を考える。これは、 A の専有範囲および R の専有範囲をそれぞれ A と R のベクトル空間とすると、これらの直和空間 $A \oplus -R = \{\mathbf{a} + (-\mathbf{r}) | \mathbf{a} \in A, \mathbf{r} \in R\}$ で表すことができる。すると、 $\lambda(\mathbf{x}, \mathbf{v}) = \{\mathbf{x} + t\mathbf{v} | t \geq 0\}$ (\mathbf{x} を通り \mathbf{v} 方向に伸びる直線) と書くことにすると、

$$CC_A^R = \{\mathbf{v}_R - \mathbf{v}_A | \lambda(\mathbf{x}_R, \mathbf{v}_R - \mathbf{v}_A) \cap A \oplus -R \neq \emptyset\} \quad (4)$$

となる。次に、 A と衝突する可能性のある R の速度 \mathbf{v}_R の集合を領域 VO_A^R (velocity obstacle) と定義すると、これは CC_A^R を用いて

$$VO_A^R = CC_A^R \oplus \mathbf{v}_A \quad (5)$$

と求められる。 \mathbf{v}_R が VO の領域内にあり続けた場合、ロボットは障害物と衝突してしまうため、各動作ステップにおいて、ゴール方向に最も近く、かつ VO の外側になるよう \mathbf{v}_R を決定する。 \mathbf{v}_R^g をゴール方向に対する最大速度ベクトルとすると、

$$\mathbf{v}_R = \arg \min_{\mathbf{v} \notin VO} \|\mathbf{v}_R^g - \mathbf{v}\| \quad (6)$$

として \mathbf{v}_R を決定できる。

障害物がロボットの周囲に複数存在する場合はそれぞれに対して VO を生成するが、そうすると VO の外側に速度ベクトルを決定できないことがある。このような場合に、ペナルティ値を導入して動作計画を行う手法として、ORCA が提案された。

4.2 各モデルの特徴

UPL, ORCA とともに、群衆シミュレーションとして優れた手法であるが、いずれもいくつかの前提条件があり、

*1 <https://gamma.cs.unc.edu/ORCA/>

それらはロボット用シミュレータにとって必ずしも望ましい条件ではない。以下、前提条件を外した実験結果（文献 [12] における結果）の概要を述べる。

まず、実験は、群衆モデル研究におけるベンチマークシナリオとして、以下の 5 つの環境で実施された。移動速度は、人の平均的な歩行速度にガウスノイズを加えて与えている。

- Circle: 円形に配置された 8 エージェントが対向のゴールに向かって移動する。
- Crossing: 16 エージェントの 2 グループが 90 度の角度ですれ違いながら対向のゴールに向かって移動する。
- Opposite 1: 16 エージェントの 2 グループが直線方向にすれ違いながら対向のゴールに向かって移動する。静止障害物なし。
- Opposite 2: 16 エージェントの 2 グループが直線方向にすれ違いながら対向のゴールに向かって移動する。静止障害物あり。
- Random: 22 エージェントが、ランダムに設定されたスタート地点からゴールに向かって移動する。

評価は、安全性、効率性、経路形状の自然さの 3 つの観点で行われている。安全性については、エージェント間およびエージェントと静止障害物間で衝突が発生した回数をカウントし、後者に重みをつけて衝突率を算出している。効率性については、始点と終点間のユークリッド距離を移動時間で割った値を用いている（始点・終点間を直線移動したと仮定したときの平均速度）。経路形状の自然さについては、速度分布の形状から主観的な評価が行われている。

得られた実験結果の概要を以下にまとめる。なお、実験内容・結果の詳細については文献 [12] を参照のこと。

- Homogeneity と安全性: 前提条件を外さない場合、ORCA の衝突率は全てのシナリオにおいて UPL よりも顕著に低い。一方、条件を外した場合には、ORCA の衝突率は全シナリオの平均で 400% 以上増加する。特に、Crossing シナリオでの劣化度合いが大きい。UPL にはそのような傾向は見られない。
- Omniscience と安全性: 前提条件を外さない場合、ORCA の衝突率は全てのシナリオにおいて UPL よりも顕著に低い。条件を外しても、ORCA の衝突率に増加は見られない。UPL の衝突率はやや増加する。
- Homogeneity と効率性: 前提条件を外さない場合、全シナリオの平均としては ORCA, UPL とともに速度に違いは見られない。条件を外しても、効率性への影響はほぼ見られない。
- Omniscience と効率性: Homogeneity と同様、ほぼ影響は見られない。

経路形状については、Homogeneity の前提条件を外すと、UPL では速度分布の形状に大きな変化は見られないが、ORCA では、2 つのピークがある幅の広いゆるやかな分布

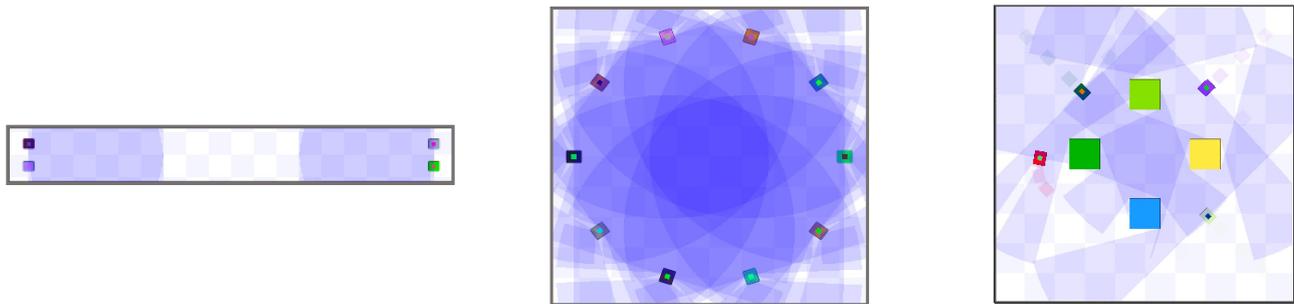


図3 実験に利用した3種類のシナリオ。左: Opposite, 中: Circle 1, 右: Circle 2。中心に点(センサー)のある四角がエージェント, それ以外の四角は静止障害物を表す。また, 青色で各エージェントのセンシング範囲を示した。

に変化することが示されている。また, Omniscience の前提条件を外すと, 平均速度への影響は少ないように見えるが, ORCA では, 衝突を回避するためにエージェントがその場で振動する動きが見られることが報告されている。UPL は若干の軌道のぶれはあるものの, ORCA のような大きな逸脱は見られない。

以上の結果は, ORCA が短時間で他のエージェントの動きを予測しながら自身の動作を決めるため, 予測と異なる動きをするエージェントに対応できないことを示唆している。本稿の想定では, ロボットの移動モデルは ORCA と異なると考えられ, 群衆モデルとして ORCA を利用することは望ましくない。また, Omniscience の前提条件を外すと, 見えないエージェントが視界に入ったときに適切な動作を生成できない状況が発生し, 極端に低速になったり, 迂回したりするエージェントが存在してしまう。ロボットシミュレータで用いる群衆モデルとして, これは適切ではない。UPL にはこれらの問題は生じていないが, 前述したとおり, 環境ごとに適切なパラメータの設定が必要である。文献 [12] の実験では, シナリオが限定されているため, この影響が十分に評価されていないと考えられる。

4.3 考察

本稿で対象とするナビゲーション手法では, ロボットは群衆とは異なる移動モデルを持っており, 群衆はロボットの動作に影響を受けて移動することになる。そのため, Homogeneity に対してロバストである Force モデルに基づく手法を利用するのが望ましい。ただし, 環境ごとにパラメータの調整が必要であるため, その影響度合い, パラメータの調整法等を今後検討していく必要がある。

5. 実験

群衆モデルの設計は今後の課題であるが, 本稿では, シミュレーション環境(シナリオ)の差が群衆の移動傾向に与える影響について, 簡易実験により検証を行う。シナリオが変われば群衆の移動傾向が変わるのは当然のことだが, 環境が変わることで不自然な軌跡が生成されるモデル

は適切なモデルとは言えない。ここでは, 同一モデルを複数シナリオに適用することで, その影響度合いを調べる。シミュレーション環境は, 文献 [4] と同一のものを用いる。

5.1 実験の方法

5.1.1 群衆モデル

群衆モデルとしては, タイムステップごとに LiDAR により周囲の状況をセンシングし, 障害物を検知した場合に迂回行動を生成するという単純なモデルを用いる。具体的な手順は以下のとおりである。

- (1) 各エージェントは, タイムステップごとに, エージェントに設定されたローカル座標から見たゴール位置と, センサーによるスキャンデータを取得する。センシングの範囲は 180° , 6.0 m とする。
- (2) スキャンデータの最小値がしきい値以下であった場合, 障害物を検知したと判断し, 迂回するために既定値分左回転する。
- (3) それ以外の場合, 進行方向がゴール方向から既定値分以上ずれていれば, 旋回してゴール方向を向く。ずれが既定値内であれば直進する。

5.1.2 シミュレータの設定

実験には, ロボット用ソフトウェアプラットフォームである ROS^{*2}, ROS 上で動くロボットシミュレータ Stage^{*3}を用いる。Stage では, 各ロボット(ここでは群衆に相当する各エージェント)にセンサーが搭載されており, 一人称視点でのセンシングを伴うエージェントの制御が可能である。シミュレータ上に複数のエージェント, および静止障害物を配置することで実験環境を構築し, 群衆シミュレーションを実施する。本実験では, 実験環境内の全てのエージェントは 2D LiDAR を搭載し, 同一のナビゲーション手法によりそれぞれのスタート地点からゴール地点まで移動するものとする。また, エージェントが他のエージェントや障害物と衝突した場合, エージェントはその場で停止し, 障害物として残るのものとする。

*2 <https://wiki.ros.org/>

*3 <https://wiki.ros.org/stage>

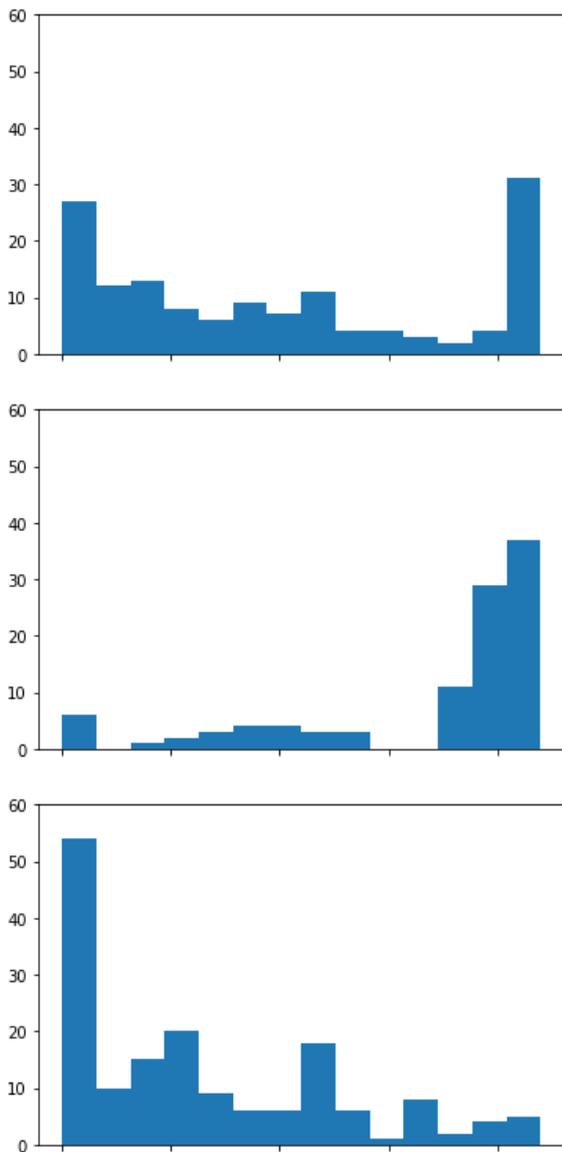


図 4 シナリオごとの移動速度の分布. 上: Opposite, 中: Circle 1, 下: Circle 2. 横軸は速度, 縦軸は頻度を表す.

5.1.3 実験シナリオ

実験は文献 [12] を参考に, 図 3 に示す 3 種類のシナリオを用いて行った. 以下にそれぞれの概要を記す.

- Opposite: 2 エージェントの 2 グループが直線方向にすれ違いながら対向のゴールに向かって移動する.
- Circle 1: 円形に配置された 10 エージェントが対向のゴールに向かって移動する.
- Circle 2: 円形に配置された 4 エージェントが対向のゴールに向かって移動する. 静止障害物あり.

表 1 シナリオごとの移動速度の平均値と分散.

シナリオ	移動速度の平均値	分散
Opposite	0.48	0.19
Circle1	0.83	0.12
Circle2	0.35	0.14

5.1.4 評価尺度

文献 [12] では, 移動モデルをロボットに搭載することを目的に, 安全性, 効率性の指標を評価尺度として用いている. 一方, 本稿では移動傾向の妥当性を評価することを目的とするため, ここでは, 単位時間あたりの移動速度の分布の形状, およびその統計値として移動速度の平均値および分散を評価尺度として用いる.

5.2 実験の結果

シナリオごとの移動速度分布を 図 4 に, 移動速度の平均値と分散を表 1 に示す. 図 4 の横軸は速度, 縦軸は頻度であり, 単位は全てメートルである.

これらの結果から, 同一モデルを異なるシナリオに適用したところ, 移動傾向には顕著な差が出るのがわかった. 前述したとおり, これは当然の結果ではあるが, 特に Opposite の移動傾向は幅のあるゆるやかな分布に加えて 2 つのピークが存在しているものであり, 不自然な動きが発生している可能性が読み取れる. 障害物がなく, すれ違いが発生する頻度も低い Circle 1 は, 各エージェントがスムーズに移動していると推察され, 障害物が存在する Circle 2 は, 全体的に移動速度が低下していると思われる.

以上まとめると, 今回使用した移動モデルは非常に単純なものであるが, Circle 1 や Circle 2 のような単純なシナリオであれば妥当な結果が得られる. 一方, すれ違いが多く発生する狭い廊下などには適さないだろうことがわかった.

6. おわりに

本稿では, ロボットナビゲーション用シミュレータで利用するための群衆モデルの構築を目指して, 既存の群衆モデルの分析を行った. さらに, 簡易な移動モデルを用いたシミュレーション実験を行い, 環境の違いが群衆モデルの性能に与える影響を調べた. 本稿の結論は以下の 2 点である.

- ロボットが群衆とは異なる移動モデルを持つナビゲーション手法では, VO に基づく手法ではなく, Force モデルに基づく群衆モデルを利用する必要がある.
- 群衆モデルの性能はシナリオに大きく依存し, ごく単純な移動モデルでもシナリオによっては高い性能が得られてしまう. 利用環境に応じた適切なモデルの選択が重要である.

今後, 環境に適した群衆モデルの設計を行うとともに, 個々のエージェントの軌跡を分析する等, より詳細な評価実験を行っていく予定である.

謝辞 本研究の一部は, JSPS 科研費 20K11776, 20K12011 の助成を受けたものである.

参考文献

- [1] Burgard, W. et al.: The Museum Tour-Guide Robot RHINO, *Autonome Mobile Systeme 1998*, Springer, pp. 245–254 (1998).
- [2] Thrun, S. et al.: Probabilistic Algorithms and the Interactive Museum Tour-Guide Robot Minerva, *The International Journal of Robotics Research*, Vol. 19, No. 11, pp. 972–999 (2000).
- [3] Trautman, P. and Krause, A.: Unfreezing the Robot: Navigation in Dense, Increasing Crowds, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2010)*, pp. 18–22 (2010).
- [4] 天野加奈子, 加藤由花: 複数ポリシー切替による複雑な環境に適用可能な自律移動ロボットナビゲーション手法, 情報処理学会研究報告 DPS190, pp. 1–7 (2022).
- [5] Osinski, B., Jakubowski, A., Ziecina, P., Piotr, M., Galias, C., Homoceanu, S. and Michalewski, H.: Simulation-Based Reinforcement Learning for Real-World Autonomous Driving, *IEEE International Conference on Robotics and Automation (ICRA 2020)*, pp. 6411–6418 (2020).
- [6] Kato, Y., Nagano, Y. and Yokoyama, H.: A Pedestrian Model in Human-Robot Coexisting Environment for Mobile Robot Navigation, *IEEE/SICE International Symposium on System Integration (SII 2017)*, pp. 992–997 (2017).
- [7] Helbing, D. and Molnar, P.: Social Force Model for Pedestrian Dynamics, *Physical Review E*, Vol. 51, No. 5, pp. 4282–4286 (1995).
- [8] Akabane, R. and Kato, Y.: Pedestrian Trajectory Prediction Based on Transfer Learning for Human-Following Mobile Robots, *IEEE ACCESS*, Vol. 9, pp. 126172–126185 (2021).
- [9] Van Den Berg, J., Guy, S. J., Lin, M. and Manocha, D.: Reciprocal n-body Collision Avoidance, *Robotics Research*, Springer, pp. 3–19 (2011).
- [10] Helbing, D., Farkas, I. and Vicsek, T.: Simulation Dynamics Features of Escape Panic, *Nature*, Vol. 407, No. 6803, pp. 487–490 (2000).
- [11] Ondrej, J., Pettre, J., Olivier, A. and Donikian, S.: A Synthetic-Vision Based Steering Approach for Crowd Simulation, *ACM Trans. on Graphics*, Vol. 29, No. 4, pp. 123:1–123:9 (2010).
- [12] Fraichard, T. and Levesy, V.: From Crowd Simulation to Robot Navigation in Crowds, *IEEE Robotics and Automation Letters*, Vol. 5, No. 2, pp. 729–735 (2020).
- [13] Karamouzas, L., Skinner, B. et al.: Universal Power Law Governing Pedestrian Interactions, *Physical Review Letters*, Vol. 113, No. 23, p. 238701 (2014).
- [14] Fiorini, P. and Shiller, Z.: Motion Planning in Dynamic Environments using Velocity Obstacles, *The International Journal of Robotics Research*, Vol. 17, No. 7, pp. 760–772 (1998).