

## 局所領域の情報からの予測にもとづく歩行者モデル

郷古 学  
東北学院大学工学部

大塚 一路  
東京大学

(受理 2013 年 11 月 1 日; 再受理 2014 年 12 月 30 日)

**和文概要** 人間は、常に変化する動的な環境に対して、その変化を予測することで適応的な行動生成を行っている。本論文では、行動生成における予測の影響に着目し、予測情報にもとづいて意思決定を行う歩行者モデルを構築し、その妥当性を検証する。提案モデルにおいて、各エージェントは周囲の歩行者の情報にもとづいて、混雑状況を予測し、自らの進行方向の決定に利用する。実際の歩行者の認知的な負荷を考慮し、エージェントが予測を行う際には、自身の前方の局所領域のみを観測するとした。また、観測する情報も他のエージェントの有無という比較的単純な情報に限定した。本稿では、モデルの構築とともに、対向流シミュレーションにより、提案モデルがレーン現象を再現できることを確認した。また、実際の対向流において報告されている、予測の影響と歩行者の挙動との関係が再現できることを確認した。

**キーワード:** シミュレーション, 歩行者モデル, レーン現象, 予測

### 1. はじめに

多くの人々が行き交う様子は、駅や商業施設などで日常的に目にすることができる。このような群衆の流れをシミュレーションにより再現することは、非常口の設置場所や効率的な広告の配置の決定など、様々な応用が期待できる。

シミュレーションにおいて、歩行者をどのように表現するかは重要な課題であり、これまでに多くの歩行者モデルが提案されてきた [2, 8, 11]。歩行者の存在する環境 (空間) を複数のセルと呼ばれるマス目に分割し、そのセル内を歩行者に見立てたエージェントが移動する離散モデル [4, 6, 9, 13] や、空間を連続のまま扱う連続モデル [1, 7, 10] などが提案されている。

実際の歩行者が行っている意思決定と類似した行動生成機構を持つ歩行者モデルを実現できれば、個々の歩行者の内部状態が群衆全体の挙動へと及ぼす影響の構成論的な理解が期待できる。そのため、モデルの構築においては、対象とする挙動の再現性はもちろんのこと、実際の歩行者の意思決定メカニズムを反映することが重要である。

一般に、生物は外界 (環境) の情報を観測し、それらをリアルタイムで処理することで、時々刻々と変化する環境に対して適応的な行動を生成している。しかし、生体の情報処理速度には限界がある。そのため、逐次的に観測される情報だけではなく、過去の経験にもとづいた環境の予測が、適応行動の生成に重要な役割を果たすと考えられている [5]。

そこで本研究では、実際の人間の意思決定において重要な役割を果たす予測に着目し、予測にもとづいて意思決定を行う歩行者モデルの構築を目指す。

これまでに、本研究と同様に、周囲の状況の予測を意思決定に反映させる歩行者モデルが提案されている [12]。このモデルでは、各エージェントが自身の移動に際し、他のエージェントとの衝突が起こるかどうかを予測し、それを移動方向の決定に利用している。エージェントは自身の移動方向に存在する他のエージェントだけではなく、これからその方向へ移動

する可能性のある、他のエージェントの情報も予測することが可能であると想定している。また、自身の直前に他のエージェントが存在しても、その先のセルが観測可能であるなど、混雑による遮蔽の影響について考慮していない。

混雑した状況下では、歩行者は他の歩行者の存在により、遠くまで見通すことが困難である。また、常に広範囲を見通して、得られる情報を処理し続けることは、認知的負荷が大きいため、人間は状況に応じて、自身の前方の観測領域を変化させていると考えられる。

さらに、歩行者は周囲の観測と同時に、同行者との会話や携帯デバイスの操作など、複数のタスクを同時に行っている場合が多い。そのため、認知的負荷という観点から考えると、歩行者の観測する情報は比較的単純な情報であることが予想される。

以上の考察のもと、本研究では、エージェントの前方の「局所領域」からのみ得られる情報を意思決定に用いるとし、さらに取得する情報も、「他のエージェントの有無」という、比較的単純な情報のみを用いてモデルの構築を行う。

提案モデルでは、局所領域内の他のエージェントの平均的な存在確率をもとに、エントロピー(2次関数)を計算し、予測に用いることで、「歩行者の存在確率が高い状況」と「存在確率が低い状況」という2つの異なる状況を一つのパラメータでシームレスに表現可能である。その結果、提案モデルでは、前方の同方向歩行者への追従と対向歩行者の回避という、一見相反する2つの挙動を、同一メカニズムで実現することが期待できる。

従来研究[3]では、ある領域に存在する、同方向歩行者(エージェント)の情報にもとづいて、エージェントの移動確率を決定するモデルを提案し、追従行動を実現している。これに対し、本研究では、局所領域内のエージェントの有無の進行方向に関する情報は用いておらず、より単純な情報のみを用いたモデルの実現を目指している。

本稿では、提案モデルの妥当性を検証するために、進行方向が逆のエージェントによる、対向流シミュレーションを行う。実際の対向流では、前方にいる進行方向が同じ歩行者を追従することで、列(レーン)が形成されることが知られている。レーンの形成は、歩行者の密度が比較的高い場合に観測され、レーン形成により、対向者に対する回避行動が減少し、スムーズな流れが生まれる。本稿では、提案モデルがこの様なレーンの形成が可能であることを確認する。さらに、従来研究で報告されている、実際の歩行者の挙動と予測の影響の関係について、提案モデルが同様の傾向を再現できることを示す。

本論文の構成は以下の通りである。次章では、提案するモデルの詳細について述べる。第3章では、提案モデルを用いたシミュレーション結果と考察について述べる。最後に、第4章において、まとめと今後の課題について述べる。

## 2. 提案モデル

本章では、提案モデルにおけるエージェントの動作について説明する。提案するモデルは連続モデルであり、各エージェントは直径1の円形で表現する。また、エージェントごとに進行方向が設定されているとする。エージェントの動作ルールを図1(左)に示す。各エージェントは、このルールに基づき単位時間(タイムステップ)ごとに移動を行う。エージェントの基本的な移動方針は、自身の前方(3方向)のうち、スペースが空いている方向へと移動するというものである。以下でルールの詳細について説明する。

### 2.1. エージェントの移動

提案モデルでは、エージェントが次ステップに移動可能な方向は、進行方向と同方向、および進行方向に対し左右に角度 $\pm\theta$ だけ異なる計3方向とした(図1右)。以下、各方向を正面、

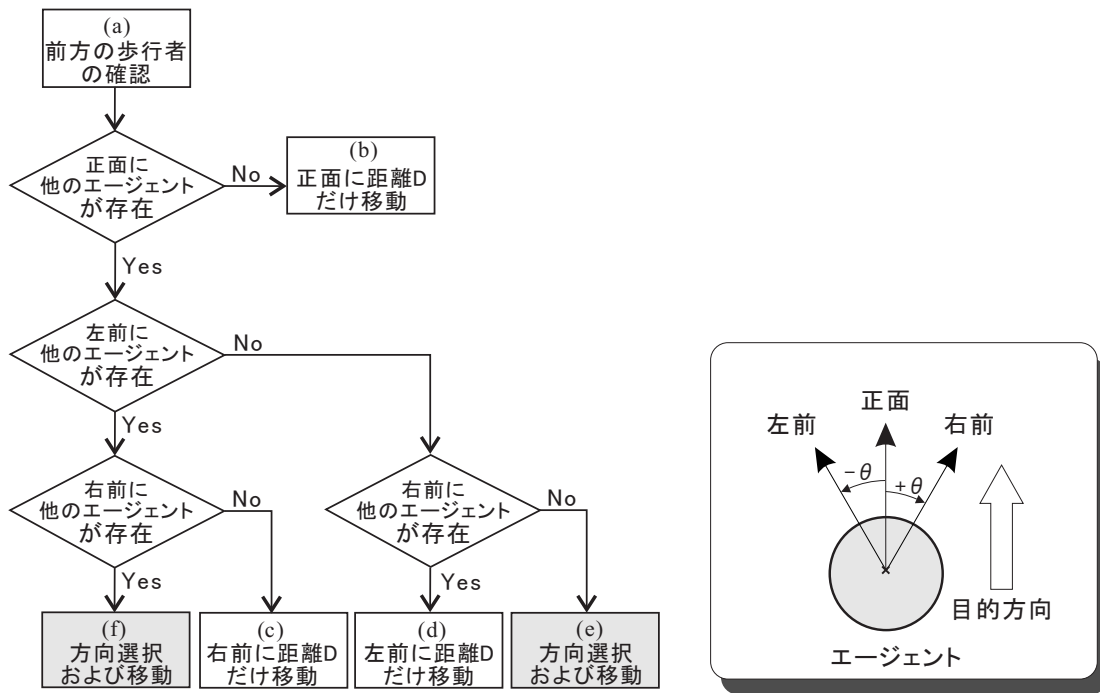


図 1: エージェントの基本ルール (左) とエージェントの進行方向 (右).




図 2: 移動領域 (左前).

左前, 右前と記す). エージェントは各タイムステップにおいて, これらの方向のいずれかを選択し, その方向に最大で距離  $D$  移動する.

エージェントは, 移動方向の選択にあたり, 各移動方向における他のエージェントの有無を確認する (図1左 (a)). エージェント自身の位置から, 距離  $D$  の位置を中心に, 半径  $r$  の領域を移動領域と呼ぶ (図2). 移動領域は正面, 左前, 右前の各方向に存在するとし, エージェントは次ステップの移動方向を決定するにあたり, それぞれの移動領域に存在する他のエージェント有無を確認する. 移動領域はエージェントの移動先のスペースを意味しており, 点ではなく半径  $r$  の領域としているのは, エージェントの視域的な要素を考慮するためである. 移動領域に対する確認結果に応じたエージェントの行動を, 以下にまとめる.

- 1) 正面の移動領域に他のエージェントが存在しない場合, エージェントは距離  $D$  だけ, 正面に移動する (図1左 (b)).
- 2) 正面と左前の移動領域に他のエージェントが存在するが, 右前の移動領域には存在し

- ない場合、エージェントは距離  $D$  だけ、右前に移動する (図1左 (c)).
- 3) 正面と右前の移動領域に他のエージェントが存在するが、左前の移動領域には存在しない場合、エージェントは距離  $D$  だけ、左前に移動する (図1左 (d)).
  - 4) 正面の移動領域には他のエージェントが存在するが、右前と左前の移動領域には存在しない場合、エージェントは、右前か左前のいずれかの方向選択を行った後、距離  $D$  だけ移動する (図1左 (e)).
  - 5) 3方向全ての移動領域に他のエージェントがいる場合には、3方向のいずれかの方向選択を行った後、距離  $\alpha D$ , ( $0 < \alpha < 1$ ) だけ移動する (図1左 (f)).

1)~3) のように、進むべき方向が一意に決定する場合は、エージェントはそれぞれの移動領域の方向に距離  $D$  だけ移動する。4) と 5) の場合は、複数の移動方向の候補が存在する。このとき、エージェントは次節で説明する予測にもとづいて、候補のうち、いずれかの方向を選択して移動を行う。4) の場合は、移動先となる左右どちらの移動領域にも他のエージェントが存在しないため、エージェントの移動距離は  $D$  とする。5) の場合は、いずれの移動先にも他のエージェントが存在しており、混雑している状況に相当することから、減速係数  $\alpha$  ( $0 < \alpha < 1$ ) を用いることで、移動距離を小さく設定する。 $\alpha D$  でのエージェントの移動を後述のシミュレーションでは回避行動と呼ぶ。

## 2.2. 予測にもとづく移動方向の選択

提案モデルにおいて、移動方向の候補が複数存在する場合、エージェントは、予測にもとづいて移動方向を選択する。本研究では、歩行者は認知的負荷の軽減のために、状況が予測しやすい方向へと移動すると考えた。そこで、提案モデルでは、複数の移動方向の候補が存在する場合には、それぞれの方向において、他のエージェントの有無が予測しやすい方へと行動選択を行うものとした。具体的な予測による移動方向の決定について以下に述べる。

エージェントは予測に用いる情報として、自身から一定距離  $D_p$  離れた半径  $r_p$  の領域内の他のエージェントの有無を毎ステップ確認する。この領域を前述の移動領域と区別するため、予測領域と呼ぶ。予測領域は、移動領域同様、正面、左前、右前の各方向に存在する。移動領域から得られる情報は、次のステップにおける移動先のスペースを確認するためのものであり、予測領域の情報は、予測情報の取得のための領域である。

あるタイムステップ  $t$  において、 $n$  ( $n = 1, 2, \dots, N$ ) 番目のエージェントが各方向の予測領域を確認した結果、他のエージェントが存在する場合は、 $\chi_{t,i}^n = 1$ 、存在しない場合は  $\chi_{t,i}^n = 0$  とする。ここで、 $i = 1, 2, 3$  は、それぞれ正面、左前、右前に対応する。各エージェントは、過去  $L_m$  ステップにわたり、 $\chi_{t,i}^n$  の情報を保持するものとする。 $L_m$  を記憶長と呼ぶ。

エージェントは、複数の移動方向の候補のうち、できるだけ状況 (他のエージェントの存在) が予測しやすい方向に移動する。提案モデルでは、予測の容易さを表現するために、統計学において、ある事象の起こりやすさ (起こりにくさ) の尺度として用いられる、エントロピを導入する。次式により、各方向に対応するエントロピを計算する。

$$P_i^n(L_m) = \frac{1}{L_m} \sum_{l=t-L_m}^t \chi_{l,i}^n \quad n = 1, 2, \dots, N \quad (2.1)$$

$$e_i^n = -P_i^n(L_m) \log P_i^n(L_m) - \left(1 - P_i^n(L_m)\right) \log \left(1 - P_i^n(L_m)\right) \\ i = 1, 2, 3, \quad n = 1, 2, \dots, N \quad (2.2)$$




図 3: エントロピ  $e_i^n$  とエージェントの存在確率  $P_i^n(L_m)$  との関係.

式 (2.1) で  $P_i^n(L_m)$  は,  $n$  番目のエージェントの持つ過去  $L_m$  ステップ間の情報から求めた, 方向  $i$  の予測領域における, 他のエージェントの平均的な存在確率に相当する.

確率  $P_i^n(L_m)$  をもとに, 式 (2.2) によりエントロピ  $e_i^n$  を計算する.  $e_i^n$  はその定義より, 確率  $P_i^n(L_m)$  が 0.5 で最大値となり,  $P_i^n(L_m)$  が 0 もしくは 1 で最小値 0 をとる (図 3). これは, 予測領域内に他のエージェントが常に存在する場合 ( $\chi_{t,i}^n$  が常に 1), および, 常に存在しない場合 ( $\chi_{t,i}^n$  が常に 0) に  $e_i^n$  が最小になることを意味している. エージェントは  $k = \operatorname{argmin}_i e_i^n$  となる方向  $k$  を次ステップの移動方向とする. なお,  $k$  が複数存在する場合には, その中からランダムに方向を選択する.

提案モデルでは, フィールド全体に存在するエージェントの数が比較的少ない (密度が低い) 場合には, 確率  $P_i^n(L_m)$  が 0 に近い値になるため,  $e_i^n$  が小さくなる. このときに, エージェントは他のエージェントが存在しない方向へと移動方向を選択する傾向が強くなる.

また, フィールド全体に存在するエージェントの数が比較的多い (密度が高い) 場合には, 確率  $P_i^n(L_m)$  が 1 に近い値になるため, この場合も  $e_i^n$  が小さくなる. この場合, 各エージェントは, 移動方向選択において, 他のエージェントが存在する方向へと移動する傾向が強くなる. つまり提案モデルでは, エントロピの極大値は, エージェントの密度が高い場合の追従行動と低い場合の回避行動の切り替えポイントに対応している.

エージェントにとって, 前方に存在する他のエージェントのうち, 進行方向が同一のエージェントと, 進行方向が異なるエージェントでは, 前者に対する相対速度の方が小さくなる. これは, 予測領域内に他のエージェントが存在する場合, 進行方向が同一のエージェントの方が, 進行方向が異なるエージェントに比べて, 安定してその存在を観測し続けることができることを意味する. つまり, 予測領域における進行方向が同一のエージェントが存在する確率  $P_i^n(L_m)$  が, 進行方向を異にするエージェントに比べて大きくなる. これにより, エージェントは自身と同じ進行方向のエージェントが存在する方向へと移動する傾向が高くなり, 密度が高い場合にはレーンの形成が期待できる. このように, 提案モデルは周囲のエージェントの密度に応じて, 場合分けをすることなく, 異なる行動生成が可能となる.

### 3. 実験結果及び考察

提案モデルの妥当性を検証するため, 互いに反対側を目指す歩行者による対向流のシミュレーションを行った. 図 4 にシミュレーションの様子を示す. 同図中の丸印はエージェントを意味し, 色の違いは進行方向の違いを意味する.




図 4: シミュレーション環境 (エージェントの直径は 1 とし, 周期境界条件を適用).

表 1: シミュレーションに用いたパラメータ

パラメータ	
最大移動距離 $D$	1
移動領域半径 $r$	0.7
移動方向 $\theta$ [deg]	30
減速係数 $\alpha$	0.1
予測領域距離 $D_p$	2
予測領域半径 $r_p$	0.7

フィールドの大きさは長さ:20, 幅:10 とし, シミュレーションでは左右それぞれ異なる方向を進行方向とする 2 種類のエージェントが存在するとした. エージェントの数は各方向で  $N$  で共通とした (全体で  $2N$  のエージェントがフィールド上に存在する). フィールド端での処理は周期境界条件を用いた. シミュレーション環境は, マルチエージェント・シミュレータ artisoc(構造計画研究所社製) により構築した. シミュレーションに用いた各パラメータを表 1 に示す. なお, 本シミュレーションでは  $\alpha \neq 0$  のため, エージェントが完全に停止することはない. これは実世界において, 歩行者同士速度を落としてすれ違う場合を想定している.

### 3.1. エージェントの密度と平均速度の関係

フィールド上のエージェント数を変化させて, エージェントの移動速度への影響を確認した. 実験では, エージェント数とエージェントの平均速度の関係を求めるとともに, レーンの形成について確認した.

各エージェントの速度は, タイムステップあたりに各エージェントが進行方向へと移動した距離に対応しており, 最大で  $D$ [distance/step] であり, 最小で  $\alpha D \cos \theta$ [distance/step] である. 全てのエージェントの速度の合計を全エージェント数で除したものを平均速度とする.

シミュレーションは, フィールド上に各進行方向に進むエージェントをランダムに配置して開始した. 開始後, 300 ステップまで時間発展させ, 300 ステップ時の平均速度を求めた. 記憶長  $L_m$  は 7 で一定とした. また, 予測による移動方向選択の効果を確認するため, 移動方向選択時(図 1 左 (d) および (e) の場合)に, 選択可能な方向からランダムに移動方向を選択するモデル (以下, ランダム選択モデルと呼ぶ) との比較を行った.

図 5 に, フィールド上のエージェント数と平均速度の関係を示す. 横軸は, 進行方向が同




図 5: エージェント数と平均速度

一なエージェントの数  $N$  を示しており、実際にはこの 2 倍のエージェントがフィールド上に存在する。このグラフは、各エージェント数において、初期配置をランダムに変化させて 10 回ずつシミュレーションを行い、得られたデータの平均速度と 95% 信頼区間を示している。また、実際の平均値とその標準偏差を表 2 に示す。

エージェントの数が 30 以下の場合では、いずれのモデルにおいても、平均速度は 1 に近い値になっている。これは、フィールド上で移動を行う上で、十分なスペースが存在することから、全てのエージェントが最大移動距離で移動を行っていることを意味する。

エージェントの数が 35~45 までの場合、提案モデルとランダム選択モデルとでは、統計検定を行った結果、平均速度に有意差が認められた。エージェントの挙動を確認したところ、ランダム選択モデルでは、多くの場合、レーンが形成されず、密度が高くなるに従い、進行方向が異なるエージェント同士の回避行動が増加した。一方で、提案モデルでは時間発展に伴ってレーンが形成され、これにより回避行動が減少し、ランダム選択モデルに比べて高い平均速度となったと考えられる。

図 6 は、同シミュレーションにおいて、全エージェント数に対する、直進 (正面方向への移動) を選択したエージェントの割合を示したものである。この図から、提案モデルの方がランダム選択モデルに比べて、直進を選択するエージェントが多いことが確認できる。

図 7 に、 $N = 35$  における各モデルのエージェントの挙動の一例を示す。図は各モデルにおける、0, 150, 300step でのエージェントの様子を表している。0step におけるエージェントの配置は、いずれのモデルも同じとした。提案モデルでは、時間発展に伴い、同方向に移動するエージェント同士がレーンを形成する様子を確認できる (図 7 上)。一方で、ランダム選択モデルの場合は、進行方向を異にするエージェント同士が混ざり合い、提案モデルのような、レーンの形成が確認できなかった (図 7 下)。

エージェント数が 50 以上の場合は場合、いずれのモデルにおいてもレーンの形成が確認されず、エージェント同士の回避行動により、速度の低下が起きた。提案モデルでは、エージェントの数が多くなると、予測領域内に、進行方向の違いによらず他のエージェントが存在する頻度が上昇する。これにより、方向選択をランダムに行う場合へ近づく。このことから、提案モデルとランダム選択モデルの平均速度が近くなると考えられる。

表 2: エージェント数と平均速度および標準偏差

片側の エージェントの数	提案モデル	ランダム選択モデル
10	1 (0)	1 (0)
15	1 (0)	1 (0)
20	1 (0)	1 (0)
25	1 (0)	1 (0)
30	1 (0.001)	0.987 (0.018)
35	0.981 (0.031)	0.877 (0.072)
40	0.867 (0.060)	0.762 (0.079)
45	0.701 (0.051)	0.637 (0.049)
50	0.552 (0.048)	0.536 (0.071)

※ ( ) 内は標準偏差




図 6: 直進エージェントの割合

### 3.2. 移動領域と最大移動距離の影響

提案モデルでは、移動領域  $r$  および最大移動距離  $D$  がシミュレーション結果に大きな影響を与える。そこで、それらのパラメータを変化させて同様のシミュレーションを行い、各パラメータの設定指針について考察する。図 8 はモデルの移動領域半径  $r$  を変化させた場合の平均速度と、エージェントの密集度合いを示したものである。密集度合いは、あるエージェントを中心として半径 1 以内に存在する他のエージェント数の平均である。  $L = 30$  とし、  $r$  以外のパラメータは前述の値を用いている。

図 8 を見ると、移動領域が小さい方が平均速度が高いことが分かる。提案モデルでは、エージェントは移動領域内の他のエージェントの有無により最大移動距離で移動するか否かを決定するため、  $r$  が小さい方が、領域内にエージェントが存在する頻度が低く、その結果、速度が最大速度に近づく。なお、実環境下においては  $r$  が小さくなるに従い、後述する密集度合いの上昇により、速度が低下することが予想される。  $r = 1.2$  の場合の平均速度の低下は、移動領域が広がることで、領域内に他のエージェントが存在する頻度が高くなるためである。

次に、密集度合いを見ると、  $r = 0.7$  に比べて  $r = 0.2$  および  $1.2$  の方が高くなっている。



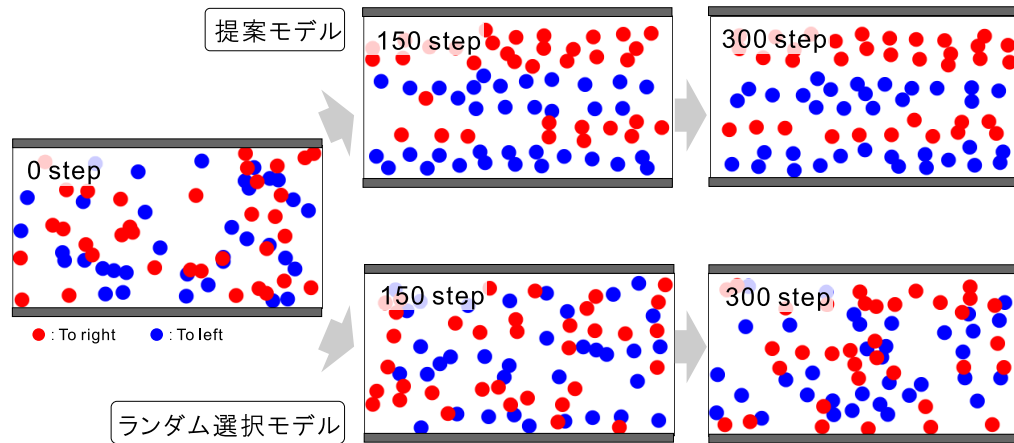


図 7: 提案モデル(上)とランダム選択モデル(下)のエージェントの挙動 ( $N=35$ )




図 8: 移動領域半径  $r$  の影響

$r = 0.2$  の場合に密集度合いが高くなっているのは、 $r$  が小さいために、エージェント同士が互いに接近する状況が発生しているためである。提案モデルでは、移動領域が小さい場合は前述の理由から、エージェントの移動速度は最大速度に近づく。しかし実環境では、歩行者が他の歩行者に接近した場合、速度の低下が生じることが予想される。また、 $r = 1.2$  の場合は、最大速度で移動可能なエージェントの数が低下し、エージェント同士が互いに距離を保つことができずに、密集度合いが高くなる。

つまり提案モデルでは、移動領域  $r$  を小さく、もしくは大きくしすぎると、実際の歩行者の挙動をうまく表現できない。なお本シミュレーション条件では、 $r$  が 0.5 から 0.7 の範囲においては、エージェントの平均速度が 1 で、密集度合いが 0.5 以下となることを確認している。

続いて、最大移動距離  $D$  を変化させたときのエージェントの平均速度を求めた (図 9)。最大速度は  $D$  に依存して変化するため、図中の平均速度は最大で 1 となるように正規化している。なお、予測領域距離  $D_p$  は  $D$  と等しくなるように設定した。また、減衰係数  $\alpha$  を 0.1,




図 9: 最大移動距離  $D$  と減衰係数  $\alpha$  の影響

0.25, 0.5,  $N = 30$  とし, それ以外のパラメータは前述の値を用いている.

この図を見ると,  $D$  が大きくなるにつれて,  $\alpha$  によらず平均速度が低下する傾向が確認された. これは  $D$  が大きくなるにつれて, エージェントが最大移動距離で進むために必要な前方のスペースの増大が求められるためである. エージェントの観測領域は, 進行方向に対してエージェントから  $D$  のところに存在するため,  $D$  が小さい場合は, 三方向の観測領域がオーバーラップする部分が多く観測領域全体は比較的小さくなるが,  $D$  が大きくなると, 三方向の観測領域がオーバーラップする領域が減少し, 観測領域全体が大きくなることから, 最大移動距離での移動が困難となり, 速度が低下すると考えられる. なお本シミュレーション条件では,  $D$  が 1.2 までの範囲においては, エージェントの平均速度の低下は見られなかった.



### 3.3. 予測がモデルの挙動に与える影響

提案モデルでは, エージェントは予測領域内における他のエージェントの有無に関する, 過去数ステップに渡る情報にもとづいて予測を行う. 本実験では, エージェントが予測を行う上で重要な役割を果たす, 予測領域半径  $r_p$  と記憶長  $L_m$  を変化させた場合の平均速度を調べ, 各パラメータがモデルの挙動に与える影響を明らかにする.

従来研究 [12] では, 予測の影響と対向流の挙動の関係について, 実際の被験者を用いた実験が行われている. 実験では, 被験者に携帯デバイスの操作や姿勢の制限などを指示し, 他の歩行者と挙動に関する予測の影響を人工的に変化させて, 各歩行者の移動に要する時間を計測した. その結果, 移動に要する時間が減少する予測の強さが存在することを明らかにした. この結果は, 平均速度を最大化する最適な予測の影響度合いが存在することを意味している.

従来研究の知見を踏まえて, 本実験では, 提案モデルにおいて予測の影響力に対応する予測領域半径  $r_p$  と記憶長  $L_m$  の大きさを変化させてシミュレーションを行い, 従来研究が示唆した, 予測と挙動との関係が再現できるかを確認する.

図 10 に,  $r_p$  を変化させた場合の平均速度の関係を示した. 図は,  $N = 40$ ,  $L_m = 7$  とし, 初期配置をランダムに変化させて 10 回ずつシミュレーションを行って得られたデータの平

図 10: 予測領域半径  $r_p$  と平均速度の関係図 11: 記憶長  $L_m$  と平均速度の関係

均と標準偏差である。実験の結果、 $r_p = 0.7$ の場合に、平均速度が有意に高い ( $p < 0.05$ ) ことを確認した。予測領域が小さい ( $r_p = 0.1$ ) 場合は、各予測領域内に他のエージェントが存在する頻度が低くなるため、予測による移動方向の選択がランダムに近づき、平均速度が低下する。また、予測領域が大きい場合は ( $r_p = 1.3, 1.9$ )、各予測領域内に他のエージェントが存在する頻度が高くなるため、この場合も、予測による方向選択がランダムに近づくことで、平均速度が低下する。

続いて図11に、 $L_m$ を変化させた場合の平均速度の関係を示した。図は、 $N = 40$ 、 $r_p = 0.7$ とし、初期配置をランダムに変化させて10回ずつシミュレーションを行って得られたデータの平均と標準偏差である。記憶長  $L_m = 10$ の場合に、平均速度が有意に高い ( $p < 0.05$ ) ことを確認した。記憶長  $L_m$ が小さい場合は、エントロピーの変化が早く、ランダム選択モデルに近い挙動を示す。一方で、記憶長  $L_m$ が大きい場合は、予測に比較的長い時間の情報を用いるため、エントロピーの変化が遅く、その結果、レーンの形成がなされずに、平均速度が低下が生じる。

以上の結果から、提案モデルでは予測に影響を及ぼす予測領域半径  $r_p$  と記憶長  $L_m$  の大きさにより、従来研究と同様の傾向を示すことを確認できた。

#### 4. まとめ

本論文では、人間の行動生成における予測の役割に着目し、局所領域の情報を用いて状況の予測を行い、それにもとづいて移動方向を決定する歩行者モデルを提案した。提案モデルを用いて対向流シミュレーションを行った結果、レーンが形成されることを確認した。また、予測に用いる情報の時間的な長さを変化させることで、実際の歩行時に見られる予測と挙動の関係と同様の結果を得ることができた。

今後の課題として、経路を複雑にした場合の確認を行う予定である。また、被験者実験を実施して、実際の歩行時の記憶量と  $L_m$  との対応について明らかにするとともに、得られた知見をモデルに反映していく予定である。

本モデルはエージェントの速度が0となることはないため、エージェント同士の衝突が発生する。今後は「その場にとどまる」というルールを追加するなどして、衝突が発生しないようにモデルを改良することが必要である。さらに、モデルでは  $L_m$  の間に得られた情報の予測への影響力が全て同じであるため、新しい情報は古い情報よりも影響力を持つように重み付けをするなどの改良も、今後の課題とする。

#### 参考文献

- [1] 浅野美帆, 桑原雅夫: 先読み行動を考慮した歩行者交通流シミュレーション. 生産研究, **59-3** (2007), 184–187.
- [2] D. Helbing: Traffic and related self-driven many-particle systems. *Reviews of modern physics*, **73**, 4 (2001), 1067–1141.
- [3] M. Isobe, T. Adachi, T. Nagatani: Experiment and simulation of pedestrian counter flow. *Physica A*, **336** (2004), 638–650.
- [4] 石橋竹志, 鈴木章彦, 渋谷秀雄: マルチエージェントシミュレーションを用いた歩行者流の解析. 日本機械学会論文集 C編 **74-744** (2008), 1985–1992.
- [5] 伊藤宏司: 身体知システム論 (共立出版, 2005)
- [6] 鎌田智之, 糸魚川栄一: マルチエージェントモデルによる介護保険施設における火災時の避難誘導に関する研究. 地域安全学会論文集, **10**, (2008), 183–193.
- [7] 木村謙, 佐野友紀, 林田和人, 竹市尚広, 峯岸良和, 吉田克之, 渡辺仁史: マルチエージェントモデルによる群集歩行性状の表現: 歩行者シミュレーションシステム SimTread の構築. 日本建築学会計画系論文集, **74-636** (2009), 371–377
- [8] T. Nagatani: The physics of traffic jams. *Reports on progress in physics*, **65** (2002), 1331–1386.
- [9] 大鋳史男, 小野木基裕: セルオートマトン法による避難流動のシミュレーション. 日本オペレーションズ・リサーチ学会和文論文誌, **51**, (2008), 94–111
- [10] 劉建宏, 大枝良直, 角知憲: パーソナルスペースを用いた障害物を回避する歩行者の群衆流動. 土木学会論文集 D, **64-4** (2008), 513–524.
- [11] A. Schadschneider, D. Chowdhury, and K. Nishinari: *Stochastic Transport in Complex Systems* (Elsevier, 2010)
- [12] Y. Suma, D. Yanagisawa and K. Nishinari: Anticipation effect in pedestrian dynamics: Modeling and experiments. *Physica A*, **391** (2012), 248–263.
- [13] 柳沢大地, 西成活裕: 渋滞学のセルオートマトンモデル. 応用数理, **22-1** (2012), 2–14.

郷古 学  
東北学院大学  
工学部機械知能工学科  
〒 985-8537  
宮城県多賀城市中央 1-13-1  
E-mail: gouko@mail.tohoku-gakuin.ac.jp

## ABSTRACT

PEDESTRIAN MODEL BASED ON PREDICTION OF INFORMATION IN  
A LIMITED AREA

Manabu Gouko                      Kazumichi Ohtsuka  
Tohoku Gakuin University    The University of Tokyo

Humans are capable of adapting their behavior according to changes in their environment. This ability of adaptation is supported by prediction of environmental dynamics. In this paper, we focused on the effectiveness of prediction to generate actions, and then developed a pedestrian model in which agents decide their own behavior based on prediction of their surroundings. We propose the pedestrian model that decides an agent's direction of movement based on prediction of information from the perceived local area. In the proposed model, we considered the limited cognitive load of real human beings; thus, the agents observe only a limited area in front of them, and they only observe whether other agents exist in the limited domain. We carried out simulations using our model to confirm its effectiveness. The results show that the model is able to reproduce lane formation, one of the fundamental characteristics of real world pedestrian dynamics.