

複数人物の移動軌跡データからの 環境モデルパラメータの逐次ベイズ推定

田代 祐志¹ 川本 一彦² 岡本 一志³

概要：複数人物移動に現れる誘引や反発などの相互作用を確率的セルオートマトンモデルで表現し、そこに含まれるパラメータを移動軌跡データから推定する手法を提案する。このモデルでは、人物は、空間を格子状に区切った「セル」に配置され、セルに埋め込まれた値に基づき確率的に次の移動場所を決定する。その値は、壁や出入口などの静的環境と動的に変化する人物移動軌跡の両者に依存して決定される。本研究では、静的環境を決めるパラメータとして、目的地からの距離によって誘引の強弱を制御するものと、各人物がどの目的地へ向かっているかを指定するラベルを導入し、それを環境モデルパラメータと呼ぶことにする。これらのパラメータは観測できない隠れ変数であるため、一般状態空間モデルの枠組みで推定問題を定式化し、粒子フィルタを用いて数値的に推定する。実験では、公開されている実際の移動軌跡データに対してパラメータを推定し、推定したパラメータによるシミュレーションがどのくらい実際の移動軌跡に近いかを評価した。

キーワード：確率的セルオートマトンモデル，集団行動解析，粒子フィルタ，逐次ベイズ推定

Sequential Bayesian Estimation of Environmental Model Parameters from Moving People Trajectories

TASHIRO YUJI¹ KAWAMOTO KAZUHIKO² OKAMOTO KAZUSHI³

1. はじめに

ビデオカメラを用いて人物を検出し追跡する技術は、さまざまな応用に展開できるため、コンピュータビジョンの基本的な課題として広く研究されている。この10年で、人検出器 [1], [2] の性能が大幅に向上したこともあり、その成果を利用して、単一人物追跡よりも、より挑戦的な複数人物追跡に対する研究 [3], [4], [5], [6] も進んでいる。さらに、ここ数年では、より複雑なシーンでの高精度な追跡や群集 (crowd) の追跡を実現するために、人と人、あるいは

は人と環境 (障害物や出口など) の間の相互作用を取り入れた運動モデルによって追跡を実現する方法が提案されている [7], [8], [9], [10], [11]。例えば、「人は出口に向かってなるべく最短経路を選択する」、「他者とは一定の距離を保つように進む」、あるいは「歩道の上を歩く」、などの先験的な知識が相互作用として運動モデルの中に組み込まれている。このような運動モデルの研究は、公共空間における避難計画の数値シミュレーションのために、おもに物理学分野で盛んに進められている [12], [13]。代表的なモデルとして、Social Force モデル [14] と確率的セルオートマトンモデル [15] がある。

一般に、このような数値モデルを用いて現実の歩行者の動きを表現するためには、そこに含まれるパラメータを適切なものに設定しなければならない。Mehran ら [8] は、オプティカルフローを用いて Social Force モデルのパラメータ推定する方法を提案した。Ali ら [7] は、高密度の群集の

¹ 千葉大学大学院融合科学研究科情報科学専攻
Chiba University, Graduate School of Advanced Integration
Science, Information Science

² 千葉大学総合メディア基盤センター
Chiba University, Institute of Media and Information Tech-
nology

³ 千葉大学アカデミック・リンク・センター
Chiba University, Academic Link Center

中から、対象人物を追跡するために、オプティカルフローを用いてセルオートマトンモデルのパラメータ推定を行った。Pellegrini ら [9] は、ラベル付けされた歩行軌跡データから、遺伝的アルゴリズムによって、Social Force モデルの最適パラメータを探索する方法を提案した。Luber ら [11] は、Social Force モデルのパラメータを手動設定し、レーザレンジファインダと拡張カルマンフィルタの組み合わせによる複数人物追跡アルゴリズムを提案した。

本研究では、確率的セルオートマトン [15] を用い、歩行者位置が観測されるたびにモデルに含まれるパラメータを逐次的に推定する手法を提案する。Ali ら [7] は、高密度の集団の支配的な1つの動きを抽出することを目的としているが、我々は複数の目的地がある状況下で、複数の支配的な動きを推定することを目的としている。このような静的な環境から決まる支配的な集団の動きを制御するパラメータを環境モデルパラメータと呼ぶことにする。このパラメータは観測することができない隠れ変数であり、観測できる信号は移動軌跡データだけである。さらに、我々のモデルでは、移動軌跡データは、環境モデルパラメータだけに依存して決まるのではなく、人物移動に伴って発生する動的な相互作用—同じ方向に進む他の歩行者の後について行きやすい性質—にも依存して決まる。

本研究ではこの推定問題を一般状態空間モデル [16] の枠組みで定式化する。ここで、複数人物の時間発展は、確率的セルオートマトンモデルによって記述される。このような数値シミュレーションを状態変数の時間発展に導入するアプローチは、データ同化 [17] などと呼ばれる。確率的セルオートマトンによる時間発展は、状態変数に関して線形でなくガウス分布型でもないため、粒子フィルタを用いて逐次ベイズ推定を数値的におこなう。

実験では、公開されている移動軌跡データセット [9] を用いて、推定したパラメータによるシミュレーションがどのくらい実際の移動軌跡に近いかを評価した。さらに、人物間の動的な相互作用の導入の効果を調べるために、どれを導入したときとしないときでも評価した。

論文構成は次のとおりである。2節では、確率的セルオートマトンモデルについて概略を示す。3節では、2節で示したモデルを組み込んだ一般状態空間モデルに対して粒子フィルタによる環境モデルパラメータの推定手法について述べる。4節では、実験結果を示す。

2. 確率的セルオートマトンによる歩行者移動モデル

本研究では、歩行者の移動モデルとして確率的セルオートマトン [15] を導入する。このモデルでは、歩行者は「セル」上を離散的に移動し、現在位置と周辺のセルに埋め込まれた値から決まる確率に従って移動方向を決める。このような値を各セルに埋め込んで構成される空間をフロ

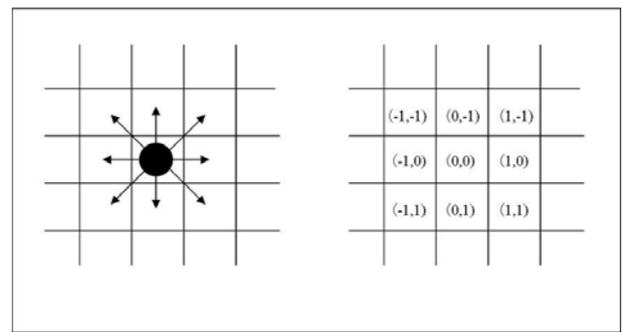


図 1 移動方向

アフィールドと呼ぶ。セル値は、環境（出入口や障害物など）に依存して静的に決まる値と歩行者位置に依存して動的に決まる値の重ね合わせて計算される。前者の成分からなる空間を静的フロアフィールド、後者の空間を動的フロアフィールドと呼ぶ。以下、この移動モデルの概略を説明する。

2.1 推移確率による歩行者の移動

空間には K 人の歩行者が存在しているとする。時刻 t での k 番目の歩行者の位置を $\mathbf{r}_{k,t} \in \mathbb{Z}^2$ とする。ここで \mathbb{Z}^2 は整数の集合である。歩行者は、現在位置を含めた周囲 9 方向のセルのいずれかに移動することを仮定する。すなわち現在位置を中心とする座標系では、移動方向は (i, j) , $i = -1, 0, 1$, $j = -1, 0, 1$ で表すことができる (図 1)。したがって歩行者の移動は次のように表現できる。

$$\mathbf{r}_{k,t} = \mathbf{r}_{k,t-1} + \begin{pmatrix} i \\ j \end{pmatrix} \quad (1)$$

ただし、移動方向 (i, j) は確率的に選ばれる。その確率を $P_{k,(i,j)}$ と表記することにする。この確率の決め方は後述する。

このモデルでは、同じセルには複数の歩行者は存在しないことを仮定する。もし、移動先のセルにすでに歩行者がいればその動きは実行されない。また、 k 番目の歩行者と k' 番目の歩行者の移動先が同じ位置になったときは、相対確率 $P_k, P_{k'}$ によってどちらかの歩行者のみが選ばれ移動する。

$$P_k = \frac{P_{k,(i,j)}}{P_{k,(i,j)} + P_{k',(i',j')}} , P_{k'} = \frac{P_{k',(i',j')}}{P_{k,(i,j)} + P_{k',(i',j')}} \quad (2)$$

選ばれなかった歩行者はそのままの位置に残る。これは 2 以上の歩行者が同じセルを移動先としたときも同様に考える。このような移動を K 人に対して毎ステップ実行することにより、歩行者行動をシミュレートする。

2.2 フロアフィールド

推移確率 $P_{k,(i,j)}$ は、フロアフィールド値を参照することで決まる。フロアフィールド F は、時間的に静的なフロアフィールド SF と動的フロアフィールド DF を重ね合わ

せて構成される．以下、これら2つのフロアフィールドについて説明する．

2.2.1 静的フロアフィールドの構築

歩行者はそれぞれの目的地を持ち、各自の目的地に向かって移動するため、歩行者ごとに静的フロアフィールドを構築することが自然である．しかし、環境を限定すれば、目的地となりうる場所はある程度限定され、複数人が共通した目的地を持つこともありうる．例えば、出口が2つしかない大きな部屋から脱出するような状況を考えれば、部屋内の全ての歩行者の目的地はどちらかの出口となる．本研究では、事前に決めた複数の目的地を設定したうえで、静的フロアフィールド SF を構築する．歩行者数でなく目的地数に応じて静的フロアフィールドを作成するため、大人数でのシミュレーションになっても爆発的に計算量が増えることはない．

本研究では、各セルのフロアフィールドの値は目的地 $d = (d_x, d_y)^\top$ とセルの座標 (x, y) との距離によって決まると仮定する．目的地の静的フロアフィールド値を $SF_{(d_x, d_y)} = 0$ とし、目的地から離れるに従ってフロアフィールド値が大きくなるようなフロアフィールドを導入する．本研究では、目的地を $d = (d_x, d_y)^\top$ とし、座標 (x, y) での静的フロアフィールドの値 $SF_{(x, y)}(a)$ を次のように定義する．

$$SF_{(x, y)}(a) = a \left(\sqrt{(x - d_x)^2 + (y - d_y)^2} \right)^b \quad (3)$$

ここで、 $a = (a, b)^\top$ は、数値が大きいほど歩行者は出口の方向に移動しやすくなり、数値が小さいほどランダムに移動しやすくなることを表現する正の実数パラメータである．このパラメータは、次節で説明する方法によって実際の移動軌跡データから推定される．

目的地は L 個あるとし、それらは整数値ラベル $l = 1, \dots, L$ で区別する． l 番目の目的地位置とそのパラメータを、それぞれ d_l および a_l ($l = 1, \dots, L$) と表記する．本稿では、このパラメータを環境モデルパラメータと呼ぶことにする．

2.2.2 動的フロアフィールドの構築

動的フロアフィールドは、歩行者の持つ「同じ方向に進む他の歩行者の後をついて行きやすい」という性質を表現するフィールドである．したがって、歩行者がセル間を移動し位置 (x, y) に来たならば、その動的フロアフィールド値を実定数 α だけ増加させる．ただし、歩行者は移動せずにその場に留まっているときは増加させない．これは、同じ場所に留まっている歩行者に他の人が引きつけられてしまうことを防ぐためである．

$$DF_{t, (x, y)} = \begin{cases} DF_{t-1, (x, y)} + \alpha & \text{移動したとき} \\ DF_{t-1, (x, y)} & \text{留まっているとき} \end{cases} \quad (4)$$

ただし、増加した値は時間経過と共に半減する．この際、

閾値 ϵ より値が小さければ値を 0 に書き換える．

動的フロアフィールドに関しては歩行者間の相互作用を表現するフィールドであるため、目的地の数によらず、1つのフィールドをすべての歩行者が共有する．

2.3 推移確率の設定

l 番目の目的地とその環境モデルパラメータ a_l が与えられているもとで、位置 (x, y) におけるフロアフィールド値 $F_{t, (x, y)}(a_l)$ を次のように定義する．

$$F_{t, (x, y)}(a_l) = \beta_s SF_{(x, y)}(a_l) + \beta_d DF_{t, (x, y)} \quad (5)$$

ここで、 β_s, β_d はそれぞれ静的フロアフィールドと動的フロアフィールドのバランスを取るための重み係数である．

この $F_{t, (x, y)}(a_l)$ を用いて、推移確率 $P_{k, (i, j)}$ を次のように定義する．

$$P_{k, (i, j)} = N \exp(F_{t, (x+i, y+j)}(a_l)) (1 - n_{(x+i, y+j)}) \quad (6)$$

ここで N は正規化因子で、 $N = 1 / \sum_{i, j} P_{k, (i, j)}$ である． $n_{x, y}$ は歩行者の占有状態を表す 0 か 1 をとりうる変数で、座標 (x, y) のセルに歩行者がすでにいる場合は 1、いなければ 0 とする．

3. 環境モデルパラメータの逐次ベイズ推定

実際の動画から環境モデルパラメータを推定するために、一般状態空間モデル [16] を導入する．ここでは、確率的セルオートマトンモデルをシステムモデルとし、動画像から検出および追跡された人位置を観測値とする．

3.1 一般状態空間モデルと逐次ベイズ推定

一般状態空間モデル表現のために、まず時刻 t におけるシステム全体の状態ベクトル x_t を次のように定義する．

$$x_t = (r_{1,t}^\top, \dots, r_{K,t}^\top, l_{1,t}, \dots, l_{K,t}, a_{1,t}^\top, \dots, a_{L,t}^\top)^\top \quad (7)$$

注意すべき点は、ラベル l_t^k および環境モデルパラメータ $a_{l,t}$ も時間変化する確率変数と見なしていることである．このような表現は、自己組織型一般状態空間モデル [16] と呼ばれる．さらに、状態ベクトルの中に連続値および離散値の両方を含んでいることから、ハイブリッド状態空間モデルとも呼ばれる．

次に、状態ベクトルのシステムモデル $p(x_t | x_{t-1})$ を特定する．ただし、初期分布 $p(x_0)$ は与えられているものとする．システムモデルに基づいて状態 x_{t-1} を状態 x_t へ推移させることは、歩行者情報を 2 節で説明した歩行者行動シミュレーションを 1 ステップ実行することにあたる． a_t の時間推移は、ランダムウォークモデルで記述することにする．

$$a_{l,t} = a_{l,t-1} + v_a, \quad v_a \sim N(0, \sigma_a) \quad (8)$$

$$b_{l,t} = b_{l,t-1} + v_b, \quad v_b \sim N(0, \sigma_b) \quad (9)$$

ラベル $l_{k,t}$ の時間変化は一次のマルコフ連鎖にしたがうと仮定し、推移確率を次のように設定する．

$$\Pr(l_{k,t}|l_{k,t-1}) = \begin{cases} \alpha & l_{k,t} = l_{k,t-1} \\ \frac{1-\alpha}{L-1} & l_{k,t} \neq l_{k,t-1} \end{cases} \quad (10)$$

観測ベクトル \mathbf{y}_t は、時刻 t での k 番目の歩行者位置を $\mathbf{y}_{k,t} \in \mathcal{Z}^2$ とし、 K 人分の観測値をまとめて次のように定義する．

$$\mathbf{y}_t = (\mathbf{y}_{1,t}^\top, \dots, \mathbf{y}_{K,t}^\top)^\top \quad (11)$$

観測モデル $p(\mathbf{y}_t|\mathbf{x}_t)$ を次のように定義する．

$$p(\mathbf{y}_t|\mathbf{x}_t) \propto \exp\left(-\frac{\sum_{k=1}^K \|\mathbf{r}_{k,t} - \mathbf{y}_{k,t}\|^2 / K}{2\sigma^2}\right) \quad (12)$$

上記の一般状態空間モデルのもと、我々が解くべき問題は \mathbf{Y}_t が与えられたもとでの \mathbf{x}_t に関する条件付き確率分布 $p(\mathbf{x}_t|\mathbf{Y}_t)$ を推定することである．ここで、 $\mathbf{Y}_t (= \{\mathbf{y}_1, \dots, \mathbf{y}_t\})$ は \mathbf{y}_t の時刻 1 から t までの系列である．条件付き確率分布 $p(\mathbf{x}_t|\mathbf{Y}_t)$ の逐次ベイズ更新式は以下のように与えられる．

$$p(\mathbf{x}_t|\mathbf{Y}_{t-1}) = \int p(\mathbf{x}_t|\mathbf{x}_{t-1})p(\mathbf{x}_{t-1}|\mathbf{Y}_{t-1})d\mathbf{x}_{t-1} \quad (13)$$

$$p(\mathbf{x}_t|\mathbf{Y}_t) = \frac{p(\mathbf{y}_t|\mathbf{x}_t)p(\mathbf{x}_t|\mathbf{Y}_{t-1})}{p(\mathbf{y}_t|\mathbf{Y}_{t-1})} \quad (14)$$

3.2 粒子フィルタによるモンテカルロ近似

一般に、式 (13)、式 (14) の逐次ベイズ推定式は、線形・ガウス型状態空間モデルなど非常に限られたクラスのモデル以外では、解析的に計算することが困難である．本研究の歩行者行動モデルも式 (1) に見られるように非線形であり、解析的に計算することが困難である．そこで、解析的な逐次ベイズ推定の代わりに、粒子フィルタを導入する．

粒子フィルタの基本的な考え方は、フィルタリング分布 $p(\mathbf{x}_t|\mathbf{Y}_t)$ を解析的に表現する代わりに、この分布からの無作為サンプルとみなせる多数のサンプル $\mathbf{x}_t^{(i)} (i = 1, \dots, N)$ を以下の式で近似表現することである．ただし $w_t^{(i)}$ はサンプル $\mathbf{x}_t^{(i)}$ に対する正規化された重みである．

$$p(\mathbf{x}_t|\mathbf{Y}_t) \approx \sum_{i=1}^N w_t^{(i)} \delta(\mathbf{x}_t - \mathbf{x}_t^{(i)}), \quad \sum_{i=1}^N w_t^{(i)} = 1 \quad (15)$$

これらのサンプルのことを粒子と呼び、シミュレーションにおいては粒子 $\mathbf{x}_t^{(i)}$ が時刻 t での i 番目のシミュレーション試行となる．

式 (7) の状態ベクトルの事後分布 $p(\mathbf{x}_t|\mathbf{Y}_t)$ を求めることができれば、環境モデルパラメータ $\mathbf{a}_{l,t}$ の事後分布 $p(\mathbf{a}_t|\mathbf{Y}_t)$ を以下のように $p(\mathbf{x}_t|\mathbf{Y}_t)$ の周辺化により求めることができる．

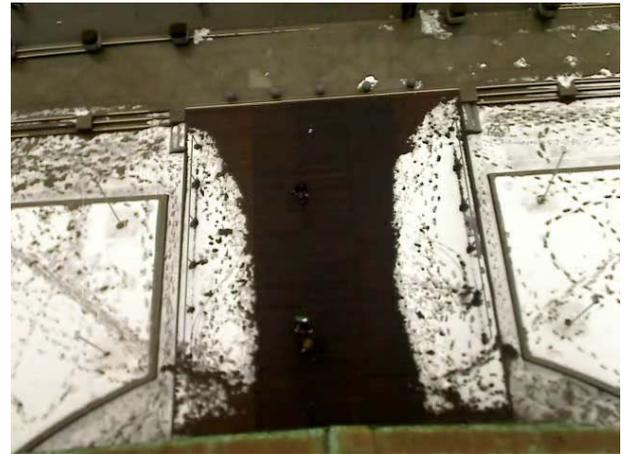


図 2 歩行者データ

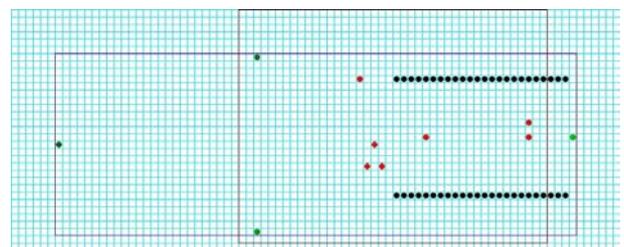


図 3 データのセル上描画

$$p(\mathbf{a}_t|\mathbf{Y}_t) = \int p(\mathbf{x}_t|\mathbf{Y}_t)d\mathbf{x}_t \quad (16)$$

ここで、 $\mathbf{x}_{l,t}$ は、状態ベクトル \mathbf{x}_t から $\mathbf{a}_{l,t}$ を取り除いてできるベクトルとする．ただし、実際には、事後分布 $p(\mathbf{x}_t|\mathbf{Y}_t)$ は粒子フィルタによりモンテカルロ近似によって求めるため、パラメータ \mathbf{a}_t の事後分布 $p(\mathbf{a}_t|\mathbf{Y}_t)$ も近似的に求めることになる．代表値が 1 つ必要なときは、すべての粒子 $\mathbf{a}_{l,t}^{(i)}, i = 1, \dots, N$ の重み付き平均を採用する．

4. 実移動軌跡データによる実験評価

実際の動画像から得られたデータ [9] を用いて実験を行った．この動画は、図 2 のように、建物に出入りする複数歩行者を上から撮影したシーンからなり、画像上での歩行者の移動軌跡の座標系列のデータセットも含まれている．

実験では、この移動軌跡の座標系列を、真上から見下ろすように変換し、さらに、図 3 のように地面を 27×71 のセルに分割したうえで、セルの整数値座標になるように丸めこんだ．データは 8 分 38 秒からなり、歩行者が検出されたフレームから 6 フレームごとに歩行者座標を m 単位で保存したものである．この 6 フレームを 1 ステップとし、我々の単位時間とする．データに保存された歩行者座標は全部で 1448 ステップあるが、歩行者が連続して検出される 1 ステップから 102 ステップまでを実験で用いる．データセットでは、4 つの目的地が存在していることが仮定されている．図 3 の緑セルが目的値を表している．ただし、図 3 は、図 2 を反時計回りにおよそ 90 度回転させて表示

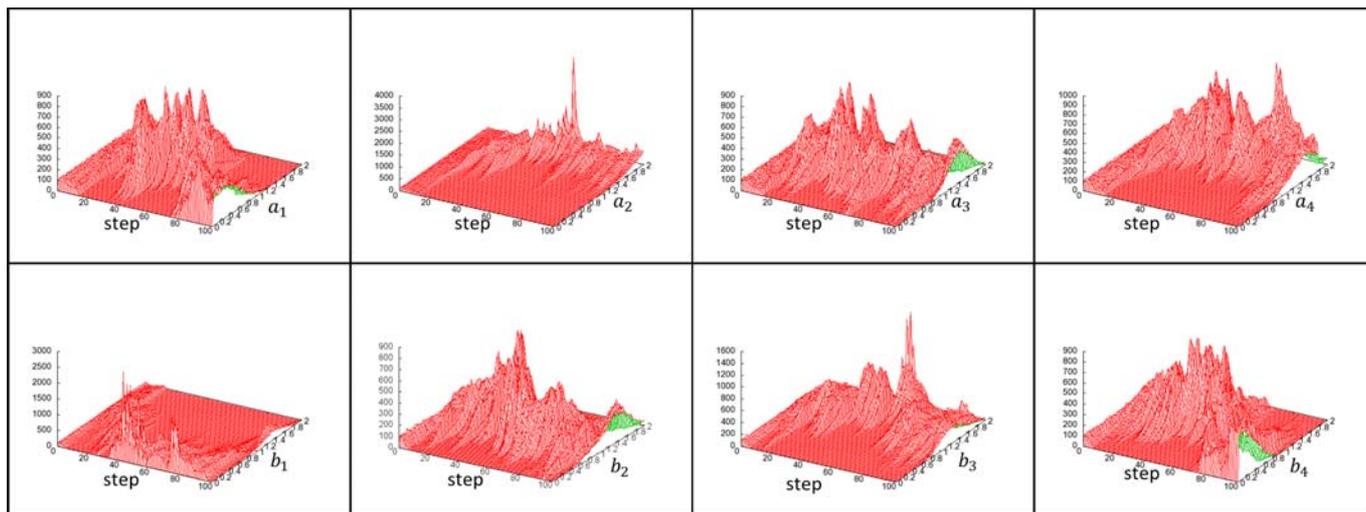


図 4 粒子数を 10000 としてパラメータ $a_{l,t}$ の事後分布．上段が a_l ，下段が b_l ，左から $l = 1, \dots, 4$ の分布を表す．横軸 step (時刻)，縦軸 a_l, b_l はパラメータ，高さはそのステップにパラメータの事後分布 (粒子からつくるヒストグラム) である．

表 1 目的地の座標 (m)

| ラベル | d_x | d_y |
|-----|-------|-------|
| 1 | -20 | 5.85 |
| 2 | -6.59 | 0.06 |
| 3 | -6.55 | 11.8 |
| 4 | 15.1 | 5.56 |

表 2 パラメータ予測値

| ラベル | $a_{l,102}$ | $b_{l,102}$ |
|-----|-------------|-------------|
| 1 | 0.384568 | 1.20762 |
| 2 | 1.71576 | 1.31637 |
| 3 | 1.33549 | 1.28652 |
| 4 | 1.42493 | 0.270905 |

させている．それぞれの目的地の座標を表 1 に示す．

図 4 に，提案手法を用いて推定した 4 つの目的地に対応する環境モデルパラメータ $a_{l,t} = (a_{l,t}, b_{l,t})^T, l = 1, \dots, 4$ の事後分布の時間推移を示す．これらのグラフは，式 (16) に基づいて，各ステップごとに事後分布を求めたものである．実際には，パラメータ空間を適当な幅に区切り，その区間に入る粒子数をカウントし，全体が 1 になるように正規化したうえで，描画したヒストグラムである．この推定には，10000 個の粒子を用いた．パラメータの初期分布 $p(a_{l,0})$ は，適当な値が未知ということを反映して，区間 $[0 : 2]$ の独立な一様分布から発生させた．

$$a_{l,0} \sim U(0, 2) \quad (17)$$

$$b_{l,0} \sim U(0, 2) \quad (18)$$

図 4 の結果を見ると，最初の 20 ステップぐらいまでは，事後分布はほぼ一様分布になっており，適切なパラメータが一意には決定できていない．しかし，時間が経過するごとに，ピークをもつ事後分布になっていく様子が観察できる．これは，パラメータ推定をするためには，十分な移動軌跡データを観測した後でなければできないことを示している．表 2 に最終ステップである 102 ステップ時点での各パラメータの推定値 $a_{l,102}$ を示す．これらのパラメータを用いて，式 (3) にしたがって静的フロアフィールドを描画したものが図 5 である．歩行者はそれぞれの持つ目的地ラベルによって，対応するパラメータ a_l における静的フロ

アフィールドを参照して移動することになる．

次に，推定したパラメータを用いて確率的セル とマトンモデルから生成した移動軌跡が，実際の移動軌跡とどの程度のずれるかを評価するために，次の式を用いて精度を評価した．

$$D_t = \frac{1}{K} \sum_{k=1}^K (x_t^k - y_t^k)^2 \quad (19)$$

なお， x_t^k はシミュレーションにおける各歩行者の座標， y_t^k は実動画における各歩行者の座標である．推定精度は，シミュレーションとデータとの歩行者の距離で求まるため， D_t が小さいほど推定精度が良い．

ここでは，粒子数を 10, 100, 1000, 1000 と変化させながら，式 (19) の D_t を求めた．図 6 に，各粒子数に対する D_t の各ステップでの推移を示す．図 6 のグラフで，例えば 40 ステップあたりで値が急激に増減している区間は新しい歩行者が観測された瞬間や歩行者が画像上から観測されなくなった瞬間である．表 3 に，すべての step で平均を取った D_{mean} を示す．この結果より，粒子数を増やせば増やすほど精度もよくなることがわかる．ただし，モンテカルロ近似による推定のため，粒子数 1000 と 10000 では，粒子数は 10 倍になっているが推定精度はそれに合わせて向上しないこともわかる．

最後に，動的フロアフィールド DF を導入する効果を検証するために，2.2.2 節で説明した動的フロアフィールドを

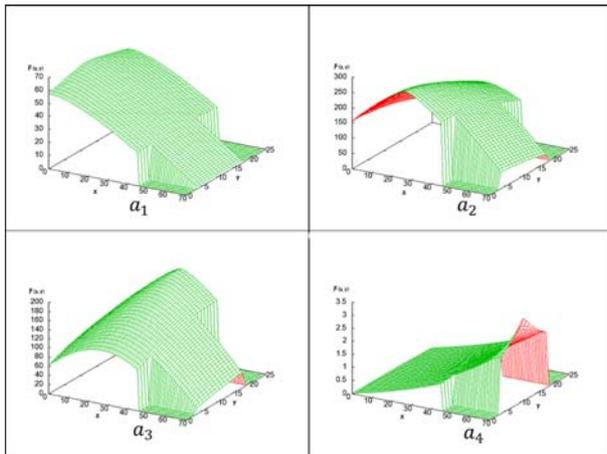


図 5 推定パラメータに対する静的フロアフィールド

表 3 推定精度

| 粒子数 | D_{mean} |
|--------------|------------|
| 10 | 159.992 |
| 100 | 37.2933 |
| 1000 | 17.6192 |
| 10000 | 15.4942 |
| 10000(DF なし) | 52.8294 |

組み込んだモデルとそれを組み込まず静的フロアフィールドだけのモデルを用いて、それぞれの推定精度を比較した。この実験では、粒子数 10000 に設定している。図 7 に、両者の各ステップでの D_t をプロットしたものを示す。この結果より、動的フロアフィールドを導入したほうが、モデルが生成する移動軌跡と実際の軌跡のずれが全体に小さくなっており、推定精度に寄与することがわかる。表 3 に、動的フロアフィールドを導入しないときの D_{mean} も示す。

5. おわりに

本研究では、歩行者の行動を表現する環境モデルにおけるパラメータを実際の動画から推定する手法を提案した。モデルとして確率的セルオートマトンモデルを用い、そこに含まれるパラメータを一般状態空間モデルの枠組みで定式化し、粒子フィルタによってパラメータの推定をした。

実験により、粒子数を増やすことで推定精度が上がることを確認した。さらに、動的フロアフィールドの導入により、推定精度が上がることも確認した。このことから、動的フロアフィールドは歩行者行動を表現するモデルでは精度向上に寄与することが確認できた。

本研究の手法は実験で用いたような目的地がある程度限定され、複数歩行者が同時に観測されるような状況で有効である。逆に、目的地となりうる場所が動的に移動したり、近辺にないような状況では、目的地にラベル付けをすることができず、そのままでは適用できない。さらに、動的フロアフィールドの半減期の設定や、粒子フィルタに含まれるパラメータ（例えば、式(12)の σ ）をどのような値に

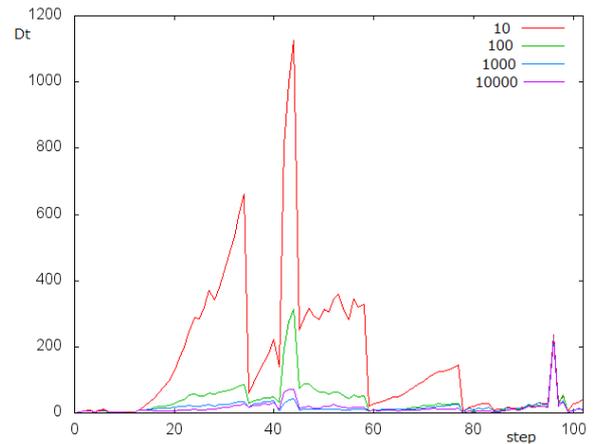


図 6 粒子数を変化させた時の D_t の変化。グラフの 10,100,1000,10000 は粒子数を表す。粒子数が多いほどグラフの起伏が小さく、より良い推定精度であることを表している。

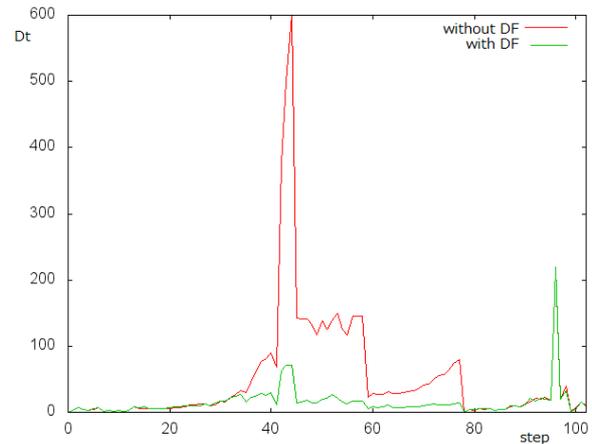


図 7 動的フロアフィールドを導入した場合としない場合を粒子数 10000 での推定精度で比較した。動的フロアフィールドを導入した場合の方が推定精度が良い。

設定するかによっても結果が異なる。本研究では経験的に値を求めたが、これらを適切に設定することも今後の課題である。

参考文献

- [1] N. Dalal and B. Triggs, Histograms of Oriented Gradients for Human Detection, Proc. Conf. Computer Vision and Pattern Recognition, Vol.1, pp. 886–893 (2005).
- [2] P. Viola and M. J. Jones, Robust Real-Time Face Detection, Int. J. Computer Vision, Vol.57, No.2, pp.137–154 (2004).
- [3] K. Okuma, et al., A Boosted Particle Filter: Multi target Detection and Tracking, Proc. ECCV, pp.28–39 (2004).
- [4] B. Leibe, K. Schindler and L. V. Gool, Coupled Detection and Trajectory Estimation for Multi-Object Tracking, Proc. ICCV, pp.1–8 (2007).
- [5] M. Andriluka, S. Roth, and B. Schiele, People-tracking-by-detection and people-detection-by-tracking, Proc. CVPR, pp. 1–8 (2008).
- [6] M. D. Breitenstein, F. Reichlin, B. Leibe, E. Koller-Meier, L. V. Gool, Robust Tracking-by-Detection us-

- ing a Detector Confidence Particle Filter, Proc. ICCV, pp.1515–1522 (2009).
- [7] S. Ali and M. Shah, Floor Fields for Tracking in High Density Crowd Scenes, Proc. ECCV, Vol.2, pp. 1–14 (2008).
- [8] R. Mehran, A. Oyama, and M. Shah, Abnormal Crowd Behavior Detection using Social Force Model, Proc. CVPR, pp.935–942, 2009.
- [9] S. Pellegrini, A. Ess, K. Schindler, L. V. Gool, You'll never walk alone: Modeling social behavior for multi-target tracking, Proc. ICCV, pp.261–268 (2009).
- [10] K. Kawamoto, A Data Assimilation Method for Estimating the Parameters of a Social Force Model for Pedestrian Motion Analysis, Proc. Int. Forum on Multimedia and Image Processing, 2010 .
- [11] M. Luber, J. A. Stork, G. D. Tipaldi, and K. O. Arras, People Tracking with Human Motion Predictions from Social Forces, Proc. Int. Conf. Robotics and Automation, pp.464–469 (2010).
- [12] 柳 大地・西成 活裕, 回り込みと壁・障害物の効果による人の移動流量の変化, 応用力学研究所研究集会報告, No.18ME-S5 (2006).
- [13] A. Schadschneider, W. Klingsch, H. Kluepfel, T. Kretz, C. Rogsch, and, A. Seyfried, Evacuation Dynamics: Empirical Results, Modeling and Applications, Encyclopedia of Complexity and System Science, Springer, pp.3142–3176, 2009.
- [14] Dirk Helbing and Péter Molnár, Social force model for pedestrian dynamics, Physical Review E, Vol.51, No.5, pp.4282–4286 (1995).
- [15] C. Burstedde , K. Klauck , A. Schadschneider, J. Zittartz, Simulation of pedestrian dynamics using a two-dimensional cellular automaton, Physica A: Statistical Mechanics and its Applications, Vol.295, No.3-4, pp.507–525 (2001).
- [16] 北川源四朗, 一般化状態空間モデルと自己組織化の方法, 人工知能学会誌, Vol.16, No.2 pp.300–307 (2001).
- [17] 中村和幸, 上野玄太, 樋口知之, データ同化: その概念と計算アルゴリズム, 統計数理, Vol.53, No.2, pp.211–229 (2005).