Vol.2011-CVIM-177 No.6
2011/5/19

複数人物追跡のためのセルオートマトン型歩行者行動モデルのパラメータ推定に関する基礎検討

田 代 祐 志[†1]　川 本 一 彦[†2]

動画像中の複数人物を追跡するために，出口や障害物などの環境が歩行者に与える作用を組み込んだセルオートマトンモデルに基づく歩行モデルを導入し，そのパラメータを動画像から推定するための統計的推定法を提案する．そのために，離散的なモデルであるセルオートマトンモデルをシステムモデルとして組み込んだ一般状態空間モデルを導入し，粒子フィルタによる逐次モンテカルロ近似によってパラメータを推定する．推定法では，オフライン型の最尤推定法とオンライン型の逐次ベイズ推定法の 2 つを用いている．実験では，基本的な性能を評価するために，歩行者位置は検出できているものとして，人工的に作成した数値データを用いて，2 つの推定法を比較検証している．

Estimating parameters of a cellular automaton model for people tracking

Yuji Tashiro[†1] and Kazuhiko Kawamoto[†2]

For people tracking in image sequences, we introduce a cellular automaton model which describes the effect of obstacles and exits in space on the movement of people, and proposes a statistical method for estimating parameters of the model from image sequences. To this end, we formulate the cellular automaton model as a general state space model and estimates the parameters using a particle filter in the framework of maximum likelihood and sequential Bayesian estimation. In experiments, we compare the two estimates with numerical data to evaluate the basic performance of the proposed methods.

†1 千葉大学大学院融合科学研究科
Graduate School of Advanced Integration Science, Chiba University
†2 千葉大学総合メディア基盤センター
Institute of Media and Information Technology, Chiba University

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．代表的な方法としては，色ヒストグラム[1] などの画像特徴量を用いて，平均値シフト[2] や粒子フィルタ[3] よって局所的探索をしながら人物の追跡を実現する方法が挙げられる．最近では，複数人物追跡のために，HOG（Histogram of Oriented Gradients）[4] や Haar-like 特徴量[5] を用いて人物画像を事前学習しておき，人検出器と追跡アルゴリズムを組み合わせた「Tracking-by-Detection」[6)–9)] という枠組みも提案され，その有効性が示されてきている．

一方，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[10)–14)]．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[15),16)]．代表的なモデルとして，Social Force モデル[17] とセルオートマトンモデル[18] がある．

一般に，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[11] 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[10] は，同様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[12] 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[14] は，Social Force モデルのパラメータを手動設定し，レーザー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，セルオートマトンモデルに基づく歩行行動モデルに含まれるパラメータをビデオ映像から推定するための統計的推定法を提案する．上述した先行研究では，モデルパラメータをオプティカルフローの平均化など比較的単純な方法で推定している．そこでは，パラメータの確率分布を陽に扱っているわけではないため，推定値の統計的な意味が必ずしも明確ではなく，ばらつきや信頼性が評価できるとは限らない．また，セルオートマトンは離散的なモデルであるから，カルマンフィルタやその拡張版を直接には適用できない．そこ

© 2011 Information Processing Society of Japan

で，本研究では，一般化状態空間モデル[19] の枠組みに基づいて，セルオートマトンモデルをシステムモデルとして組み込んだ状態空間モデルを定義し，粒子フィルタによる逐次モンテカルロ近似によってパラメータを推定する．この考え方は，地球物理学などで利用されているデータ同化[20] と呼ばれるものと同じである．推定アルゴリズムとして，最尤推定法と逐次ベイズ推定法の 2 つを採用した．前者は，観測値がすべて与えられたもとで推定値を求めるオフライン型の手法であり，後者は，推定すべきパラメータを状態ベクトルの中に組み込んだ自己組織型の状態空間モデル[19] で，オンラインでパラメータを推定する．これら 2 つの推定法は，想定するシーンや応用分野によって使い分けることができる．本研究では，提案手法の基礎検討として，歩行者間の相互作用は扱わず，位置が未知の出口が歩行者に与える相互作用を対象にする．実験では，基本的な性能を評価するために，歩行者位置は検出できているものとして，人工的に作成した数値データを用いて検証している．

論文構成は次のとおりである．2 節では，歩行者行動モデルとして用いるフロアフィールドを用いたセルオートマトンモデルについて述べる．ここでは，フロアフィールドとセルオートマトンモデルとの関連性を説明し，フロアフィールドを決定するパラメータを仮定する．3 節では，最尤推定法と逐次ベイズ推定に基づく 2 つのパラメータ推定の手法について説明し，それぞれのアルゴリズムを示す．4 節では，提案手法を用いて実際に行った実験について述べ結果を示す．

2. セルオートマトン型歩行者行動モデル

Social Force モデルでは，相互作用を反発や誘引を表す「社会的な」力として表現し，それらの項を含む微分方程式として歩行経路を記述する．そのような項は，人と人あるいは人と環境の関係を直接的に結び付けて表現するため，例えば，歩行者 i は歩行者 j から，どの程度の誘引力を受けているか，ということを陽に表すことができる．そのため，画像上で個々の歩行者が区別できる程度の大きさで撮影されたシーンを前提に，歩行者間の相互作用を陽に扱いたい応用では Social Force モデルが利用される[11)–14)]．

セルオートマトンモデルでは，2 つの対象間の相互作用を直接的には記述しない．その代わりに，床や地面を格子状に区切った「セル」に，歩行者が通過した回数を記録したり，障害物の周辺に歩行者が近寄りにくい値を設定したりするなどして，相互作用を間接的に表現する．すなわち，歩行者は，他者を直接見ているわけではなく，自身の周辺のセルに書きこまれた値を読み取りながら，次にどのセルに移動するかを決定する．このような値をもったセルからなる平面は，フロアーフィールドなどと呼ばれる．Social Force モデルでは，対象間の相互作用を陽に扱える利点があるが，歩行者や障害物の増加に伴い，組み合わせ爆発の問題が発生する．セルオートマトンモデルでは，フロアーフィールドを介して相互作用を伝達するため，この組み合わせ問題は発生しない．したがって，歩行者数が非常に多いシーンでは，セルオートマトンモデルが適している[10)]．

本研究では歩行者行動をフロアフィールドを用いたセルオートマトンでモデル化する．以下,「歩行者行動モデル」は「フロアフィールドを用いたセルオートマトンモデル」を意味する．

2.1 推移確率による歩行者の移動

2 次元セルオートマトンモデルでは，歩行者は有限個のセルに区切られた空間上を確率的に移動する．

K 人の歩行者の行動を考える．時刻 t での k 番目の歩行者の位置を $\boldsymbol{x}_t^k = (r_{x,t}^k, r_{y,t}^k)^\top \in \boldsymbol{R}^2$ とする．時刻 t での K 人の歩行者の位置 $\boldsymbol{x}_t$ は以下のように表現する．

$$\boldsymbol{x}_t = (\boldsymbol{x}_t^{1\top}, \boldsymbol{x}_t^{2\top}, \ldots, \boldsymbol{x}_t^{K\top})^\top \tag{1}$$

この時，$(r_{x,t}^k, r_{y,t}^k)$ は S 内の各セルの x 座標，y 座標である．時刻 $t-1$ での k 番目の歩行者の位置 $\boldsymbol{x}_{t-1}^k$ は，その位置を含めた周囲 9 方向のセルのいずれかに移動する．$\boldsymbol{x}_{t-1}^k$ の座標を中心に考えた場合，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 参照)．各方向 (i,j) への推移確率を $P_{i,j}^k$ として，時刻 t での歩行者の位置 $\boldsymbol{x}_t^k$ を以下のように表現する．

$$\boldsymbol{x}_t^k = \boldsymbol{x}_{t-1}^k + \begin{pmatrix} i \\ j \end{pmatrix} \tag{2}$$

同じセルには複数の歩行者は存在しないことを仮定し，推移確率によって選ばれた $\boldsymbol{x}_t^k$ のセルにすでに歩行者がいた場合，その動きは実行されない．また，k 番目の歩行者と k' 番目の歩行者の位置 $\boldsymbol{x}_t^k$ と $\boldsymbol{x}_t^{k'}$ が同じ座標の場合，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．選ばれなかった歩行者は時刻 $t-1$ の位置に残る．これは 2 以上の歩行者が同じセルをターゲットとした場合も同様に考える．

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 フロアフィールドによる推移確率の変更

歩行者行動モデルでは，推移確率 $P_{i,j}^k$ をフロアフィールドの値によって変更することで

© 2011 Information Processing Society of Japan

Vol.2011-CVIM-177 No.6
2011/5/19

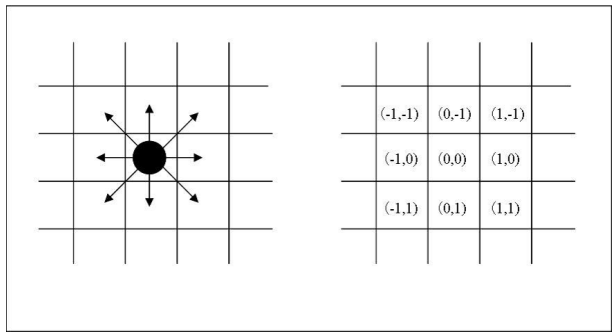


図 1 移動方向

歩行者を動かす．フロアフィールドは各セルに埋め込まれた値であり，推移確率 $P^k_{i,j}$ は方向 (i,j) のセルのフロアフィールドの値を参照することで求めることができる．

座標 (x,y) を基準にした (i,j) 方向のセルの座標は $(x+i,y+j)$ で書くことができる．座標 (x,y) のフロアフィールド値を $F_{x,y}(\boldsymbol{a})$ とし，推移確率 $P^k_{i,j}$ を以下の式 (3) で定義する．

$$P^k_{i,j} = CM_{i,j}\exp(-F_{x+i,y+j}(\boldsymbol{a}))(1-n_{x+i,y+j}),\quad C=\frac{1}{\sum_{i,j}P^k_{i,j}} \tag{3}$$

$M_{i,j}$ は歩行者ごとに与えられる 9 つの値で，この値で歩行者の個性を表現する．しかし本研究では歩行者の個性は考えないので，$M_{i,j}$ は一様に 1 とする．C は正規化因子である．$n_{x+i,y+j}$ 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 $(x+i,y+j)$ 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．

2.3 フロアフィールドを決定するパラメータ

フロアフィールド F は静的フロアフィールド S-F と動的フロアフィールド D-F に分けて考えられる．静的フロアフィールド S-F は壁や障害物などの，場所の特性を表現する時間変化のないフィールドである．動的フロアフィールド D-F は歩行者間の相互作用を表現する時間的に変化するフィールドである．本研究では場所の特性を考える為，静的フロアフィールドのみを考える．以下，フロアフィールド F は静的フロアフィールド S-F を意味する．

歩行者はそれぞれが目的地を持って行動すると考えられる．そのため，歩行者ごとに目的地に応じたフロアフィールドが作成され，そのフロアフィールド値に基づいた行動をするが，状況を限定して考えれば，目的地となりうる場所はある程度限定される．例えば，出口が 1 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出口に一致し，1 つのフロアフィールドで全ての歩行者の行動を表現できる．本研究ではこの状況を考え，フロアフィールドを決定するパラメータの推定法を提案する．

出口が 1 つの大きな部屋からの脱出を考えた場合，各セルのフロアフィールドの値は目的地 $\boldsymbol{d}=(d_x,d_y)^{\mathsf{T}}$ とセルの座標 (x,y) との距離によって決定すると考えられる．従って，目的地のフロアフィールド値 $F_{d_x,d_y}=0$ として，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考える．

しかし実際に各セルにどのような値を設定すれば歩行者行動を表現できるかはわからない．そこで，座標 (x,y) でのフロアフィールドの値 $F_{x,y}(\boldsymbol{a})$ を以下の式で定義する．

$$F_{x,y}(\boldsymbol{a}) = a\left\|\begin{pmatrix}x\\y\end{pmatrix}-\begin{pmatrix}d_x\\d_y\end{pmatrix}\right\|^b \tag{4}$$

式 (4) より，フロアフィールド値 $F_{x,y}(\boldsymbol{a})$ は目的地 $\boldsymbol{d}$ を含むパラメータ $\boldsymbol{a}=(a,b,d_x,d_y)^{\mathsf{T}}$ によって決定される．ここで a,b 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することを表現するパラメータである．パラメータ $\boldsymbol{a}$ を「フロアフィールドパラメータ」と定義し，フロアフィールドパラメータを与えることでフロアフィールドは決定する．従って，正しいパラメータを推定することができれば観測対象の歩行者の行動を表現できると考えられる．観測対象を表現するフロアフィールドパラメータ $\boldsymbol{a}$ を推定することが本研究の目的である．

3. フロアフィールドパラメータの推定

3.1 一般状態空間モデルと逐次ベイズ推定

フロアフィールドパラメータ $\boldsymbol{a}$ を推定するために，モデルの一般状態空間モデルを考える．時刻 t におけるシステム全体の状態 $\boldsymbol{x}_t$ は確率的に移動する歩行者の位置によって構成される．従って，$\boldsymbol{x}_t$ は $\boldsymbol{x}_{t-1}$ からの確率的な時間発展としてまとめて $p(\boldsymbol{x}_t|\boldsymbol{x}_{t-1})$ と書くことができる．これをシステムモデルと呼ぶ．ただし，初期分布 $p(\boldsymbol{x}_0)$ 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 $\boldsymbol{x}_{t-1}$ を状態 $\boldsymbol{x}_t$ へ推移させることは，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．

次に，時刻 t での k 番目の歩行者の観測値を $\boldsymbol{y}^k_t\in\boldsymbol{R}^2$ とし，K 人分の観測値をまとめたものを $\boldsymbol{y}_t$，時刻 1 から t までの観測値の系列を $\boldsymbol{Y}_t$ で記述する．

© 2011 Information Processing Society of Japan

$$\boldsymbol{y}_t = (\boldsymbol{y}_t^{1\mathsf{T}}, \ldots, \boldsymbol{y}_t^{K\mathsf{T}})^{\mathsf{T}} \tag{5}$$
$$\boldsymbol{Y}_t = \{\boldsymbol{y}_1, \ldots, \boldsymbol{y}_t\} \tag{6}$$

ある状態 $\boldsymbol{x}_t$ が与えられたもとでの観測値 $\boldsymbol{y}_t$ の分布を $p(\boldsymbol{y}_t|\boldsymbol{x}_t)$ とする．これを観測モデルと呼ぶ．これらをまとめると，一般状態空間モデルはシステムモデル $p(\boldsymbol{x}_t|\boldsymbol{x}_{t-1})$ と，観測モデル $p(\boldsymbol{y}_t|\boldsymbol{x}_t)$ で記述できる．

$$\begin{cases} \boldsymbol{x}_t = p(\boldsymbol{x}_t|\boldsymbol{x}_{t-1}) \\ \boldsymbol{y}_t = p(\boldsymbol{y}_t|\boldsymbol{x}_t) \end{cases} \tag{7}$$

上記の表現を用いれば，問題は $\boldsymbol{Y}_t$ が与えられたもとでの $\boldsymbol{x}_t$ に関する条件付き確率分布 $p(\boldsymbol{x}_t|\boldsymbol{Y}_t)$ を推定する問題として定式化できる．条件付き確率分布はろ波分布と呼ばれ，ろ波分布の逐次ベイズ推定は以下の式の繰り返し計算に帰着できる．

$$p(\boldsymbol{x}_t|\boldsymbol{Y}_{t-1}) = \int p(\boldsymbol{x}_t|\boldsymbol{x}_{t-1}) p(\boldsymbol{x}_{t-1}|\boldsymbol{Y}_{t-1}) d\boldsymbol{x}_{t-1} \tag{8}$$
$$p(\boldsymbol{x}_t|\boldsymbol{Y}_t) = \frac{p(\boldsymbol{y}_t|\boldsymbol{x}_t) p(\boldsymbol{x}_t|\boldsymbol{Y}_{t-1})}{p(\boldsymbol{y}_t|\boldsymbol{Y}_{t-1})} \tag{9}$$

一般に，式 (8)，式 (9) 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 (2) 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．

3.2 粒子フィルタによるモンテカルロ近似

粒子フィルタの基本的な考え方は，フィルタリング分布 $p(\boldsymbol{x}_t|\boldsymbol{Y}_t)$ 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 $\boldsymbol{x}_t^{(i)} (i = 1, \ldots, N)$ 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 $\boldsymbol{x}_t^{(i)}$ に対する正規化された重みである．

$$p(\boldsymbol{x}_t|\boldsymbol{Y}_t) \approx \sum_{i=1}^{N} w_t^{(i)} \delta(\boldsymbol{x}_t - \boldsymbol{x}_t^{(i)}), \quad \sum_{i=1}^{N} w_t^{(i)} = 1 \tag{10}$$

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 $\boldsymbol{x}_t^{(i)}$ が時刻 t での i 番目のシミュレーション試行となる．

3.3 パラメータ推定の手法

フロアフィールドパラメータを推定するために，2 つの手法を提案する．

1 つ目の手法では，フロアフィールドパラメータを最尤推定法を用いて求める．この手法は，観測値がすべて与えられたもとで推定値を求めるオフライン型の手法である．ただし，フロアーフィールドを用いた歩行者行動モデルは，非線形な状態空間モデルであり，そのパラメータの最尤推定量は閉形式の解としては導けない．そこで，粗密探索に基づいた繰り返しアルゴリズムで数値的にパラメータを探索する．

もう 1 つ手法では，フロアフィールドパラメータを時間変化する確率変数 $\boldsymbol{a}_t$ とみなし，状態空間モデルの状態ベクトル $\boldsymbol{x}_t$ の中に含めて推定する．このようなモデルは，自己組織化型状態空間モデルと呼ばれる．この手法は，最尤推定法と異なり，観測値が得られるたびにパラメータを推定するオンライン型の手法である．数値探索を必要としないため，最尤推定法よりも計算量は少なくすみ，従って，高速に推定することができる．

3.3.1 最尤推定法

観測値の系列 $\boldsymbol{y}_1, \ldots, \boldsymbol{y}_T$ が与えられたもとでの，パラメータ $\boldsymbol{a}$ の尤度 $l(\boldsymbol{a}) = p(\boldsymbol{y}_1, \ldots, \boldsymbol{y}_T|\boldsymbol{a})$ は，以下の式で与えられる．

$$l(\boldsymbol{a}) = p(\boldsymbol{y}_1, \ldots, \boldsymbol{y}_T|\boldsymbol{a}) = \prod_{t=1}^{T} p(\boldsymbol{y}_t|\boldsymbol{Y}_{t-1}) = \prod_{t=1}^{T} \int p(\boldsymbol{y}_t|\boldsymbol{x}_t) p(\boldsymbol{x}_t|\boldsymbol{Y}_{t-1}) d\boldsymbol{x}_t \tag{11}$$

ただし，T は観測値の系列の長さとする．観測値が与えられたもとでの状態 $\boldsymbol{x}_t$ の事後分布 $p(\boldsymbol{x}_t|\boldsymbol{Y}_t)$ が，粒子フィルタによってモンテカルロ近似されているとすると，式（11）の尤度の近似値は次のように求めることができる．

$$l(\boldsymbol{a}) \approx \prod_{t=1}^{T} \left(\frac{1}{N} \sum_{i=1}^{N} p(\boldsymbol{y}_t|\boldsymbol{x}_t^{(i)}) \right) \tag{12}$$

ただし，$\boldsymbol{x}_t^{(i)}$, $i = 1, \ldots, N$ は，事後分布 $p(\boldsymbol{x}_t|\boldsymbol{Y}_t)$ を近似する i 番目の粒子とする．実装では，式（12）の尤度では，小さな数の乗算を繰り返すことになりアンダーフローが発生しやすいため，その対数尤度を用いることにする．

$$L(\boldsymbol{a}) = \log l(\boldsymbol{a}) \approx \sum_{t=1}^{T} \log \left(\sum_{i=1}^{N} p(\boldsymbol{y}_t|\boldsymbol{x}_t^{(i)}) \right) - T \log N \tag{13}$$

この対数尤度 $L(\boldsymbol{a})$ を最大とするパラメータ $\boldsymbol{a}_{ML}$ を推定値として求める．すなわち，$\boldsymbol{a}_{ML}$

© 2011 Information Processing Society of Japan

は次で与えられる．

$$\boldsymbol{a}_{ML} = \arg \max_{\boldsymbol{a}} L(\boldsymbol{a}) \tag{14}$$

式（14）の最尤推定値は，閉形式の解として導くことができないため，次のように数値探索を用いて推定する．まず，M 個のパラメータ $\{\boldsymbol{a}^{(j)}\}_{j=1}^{M}$ を適当な範囲の一様分布から生成し，各パラメータ $\boldsymbol{a}^{(j)},\ j = 1, \ldots, M$ に対して，式（13）の対数尤度 $L(\boldsymbol{a}^{(j)})$ を求める．次に，各パラメータ $\boldsymbol{a}^{(j)},\ j = 1, \ldots, M$ の中から，最大対数尤度を持つパラメータを選ぶ．次に，そのパラメータ周辺で探索するために，そのパラメータを中心とするガウス分布から，改めて M 個のパラメータ $\{\boldsymbol{a}^{(j)}\}_{j=1}^{M}$ を生成し，それらの中から最大対数尤度となるパラメータを求める．以上の処理を繰り返すことにより，最大対数尤度推定値 $\boldsymbol{a}_{ML}$ を数値的に探索し求める．

3.3.2 逐次ベイズ推定法

逐次ベイズ推定法では，パラメータ $\boldsymbol{a}$ を時間変化する確率変数として状態ベクトル $\boldsymbol{x}_t$ の中に含める．すなわち，状態ベクトル $\boldsymbol{x}_t$ を次のように拡張する．

$$\tilde{\boldsymbol{x}}_t = (\boldsymbol{x}_t^{1\mathsf{T}}, \ldots, \boldsymbol{x}_t^{K\mathsf{T}}, \boldsymbol{a}_t^{\mathsf{T}}) \tag{15}$$

ただし，$\boldsymbol{x}_t^k, k = 1, \ldots, K$ は，k 番目の歩行者の状態ベクトルを表わす．パラメータ $\boldsymbol{a}_t$ 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．

$$\boldsymbol{a}_t = \boldsymbol{a}_{t-1} + \boldsymbol{v}_2, \quad \boldsymbol{v}_2 \sim N(\boldsymbol{0}, \Sigma_{\boldsymbol{v}_2}) \tag{16}$$

式（15）の拡張状態ベクトルの事後分布 $p(\tilde{\boldsymbol{x}}_t|\boldsymbol{Y}_t)$ を求めることができれば，パラメータ $\boldsymbol{a}_t$ の事後分布 $p(\boldsymbol{a}_t|\boldsymbol{Y}_t)$ も以下のように $p(\tilde{\boldsymbol{x}}_t|\boldsymbol{Y}_t)$ の周辺化により求めることができる．

$$p(\boldsymbol{a}_t|\boldsymbol{Y}_t) = \int \ldots \int p(\tilde{\boldsymbol{x}}_t|\boldsymbol{Y}_t) d\boldsymbol{x}_t^1 \ldots d\boldsymbol{x}_t^K \tag{17}$$

ただし，実際には，事後分布 $p(\tilde{\boldsymbol{x}}_t|\boldsymbol{Y}_t)$ 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 $\boldsymbol{a}_t$ の事後分布 $p(\boldsymbol{a}_t|\boldsymbol{Y}_t)$ も近似的に求めることになる．

この逐次ベイズ推定法では，最尤推定法とは異なり，数値探索の繰返しを必要としないため，より高速にパラメータ $\boldsymbol{a}_t$ を推定することができる．しかし，初期分布 $p(\boldsymbol{a}_0)$ や式 (16) のランダムウォークモデルの分散値の設定により，その精度は決まるため，それらをどのように設定するかの問題は残る．このアルゴリズムを $t = 1, \ldots, T$ に対して行うことで，$\boldsymbol{a}_t^{(i)}$ は観測値を表現するパラメータを近似することができる．

3.4 位置精度による再現性の評価

提案手法を評価するために，推定したフロアーフィールドパラメータと真値との比較だけでなく，推定値と真値によって生成した 2 つの歩行軌跡が互いにどの程度似通っているかも比較する．この評価基準は，例えば，ある推定値と真値の差が 0.1 で，別の推定値では 0.01 であった場合に，前者は後者のものよりも，どの程度予測性能を向上させるかを評価することが難しいために導入する．すなわち，推定値から生成した歩行軌跡の再現性という観点から，推定値を評価する．

そこで，推定したフロアフィールドパラメータの再現性を評価するために，位置精度 D_p を以下の式で定義する．

$$D_p = \frac{1}{TKI} \sum_{t=1}^{T} \sum_{k=1}^{K} \sum_{i=1}^{I} \|\boldsymbol{y}_t^k - \boldsymbol{x}_t^{k,(i)}\| \tag{18}$$

この式では，同じパラメータ下で何度かシミュレーションを行い，観測値系列 $\boldsymbol{Y}_t,\ t = 1, \ldots, T$ に対しての歩行軌跡のずれの平均値を求めている．ここで，I は推定パラメータ下で走らせたシミュレーションの数，$\boldsymbol{r}_t^{k,(i)}, k = 1, \ldots, K$ はステップごとの K 人の歩行者の位置を表す．

真値に対しても位置精度を求め，推定値の位置精度と比較し，推定値の再現性を評価する．推定値の位置精度と真値の位置精度との差が小さいほど，推定値によるシミュレーションは再現性が高いものとする．

4. 実験・考察

4.1 実 験 準 備

2 節で仮定したフロアフィールドパラメータは，出口が 1 つしかない大きな部屋からの脱出を想定したものだった．実験もこの場合を想定して行う．

実験では，$16.4 \times 16.4 m^2$ の部屋を $40 \times 40 cm^2$ のセルで 41×41 に区切り，40 人の歩行者をセル上にランダムに配置する．配置した歩行者が 1 つの出口から脱出する様子をシミュレーションする．

歩行者は 1 ステップごとに 1 セル動くものとする．1 セルの大きさは $40 \times 40 cm^2$ でとし，歩行者の速度は経験的に約 $1.3 m/s$ である．このため，1 ステップ $=0.3 s$ である．

観測値として用いるデータには，事前に真値としてあるパラメータを与えてシミュレーションを行い，$t = 1, \ldots, T$ での観測値 $\boldsymbol{y}_1, \ldots \boldsymbol{y}_T$ を得る．真値としてのパラメータとして表 1

© 2011 Information Processing Society of Japan

の $\boldsymbol{a}^{R_1} \sim \boldsymbol{a}^{R_9}$ を用いた．この表における位置精度は，真値が推定された時に式 (18) によって得られる位置精度である．つまり，推定したパラメータの位置精度が真値と同程度の位置精度ならば，真値と同程度の再現性があるといえる．なお，今回は (d_x, d_y) は固定値として $(20.0, 0.0)$ を用いた．また，真値が $\boldsymbol{a} = (1.0, 1.5, 20.0, 0.0)$ の時と $\boldsymbol{a} = (1.0, 1.5, 20.0, 0.0)$ の時の観測値の推移を図示すると図 2 となる．

ここで得た観測値を用いて，3 節で提案したアルゴリズム 1,2 を用いて数値シミュレーションを行い，フロアフィールドパラメータ $\boldsymbol{a}$ を推定し，各アルゴリズムで推定したパラメータがどの程度観測値を再現するのかを調べる．評価は位置精度を用いて行う．

表 1 真値と位置精度

	$\boldsymbol{a}^{R_1}$	$\boldsymbol{a}^{R_2}$	$\boldsymbol{a}^{R_3}$	$\boldsymbol{a}^{R_4}$	$\boldsymbol{a}^{R_5}$	$\boldsymbol{a}^{R_6}$	$\boldsymbol{a}^{R_7}$	$\boldsymbol{a}^{R_8}$	$\boldsymbol{a}^{R_9}$
a	0.5	0.5	0.5	1.0	1.0	1.0	2.0	2.0	2.0
b	0.5	1.0	1.5	0.5	1.0	1.5	0.5	1.0	1.5
d_x	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0
d_y	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
位置精度	15.8	11.49	8.7	13.4	9.0	6.0	10.2	7.4	5.4

4.2 実験 1 [最尤推定法]

4.2.1 実 験 内 容

パラメータの数 M を $M = 100$，粒子の数 N を $N = 1000$ とした．σ は $\sigma = 10$ とした．繰り返し数値探索の際に用いる分散値は $\Sigma_{\boldsymbol{v}_1} = 1.0$ とした．パラメータ $\{\boldsymbol{a}^{(j)}\}_{j=1}^{M}$ は以下の一様分布で生成する．ただし，$\boldsymbol{a}^{(j)} = (a^{(j)}, b^{(j)}, d_x^{(j)}, d_y^{(j)})$ のうち，$a^{(j)}, b^{(j)}$ は実数値の一様分布とし，$\boldsymbol{d}^{(j)} = (d_x^{(j)}, d_y^{(j)})$ は壁に相当する部分のセル L 内での一様分布とする．

$$a^{(j)} = U(0,3) \quad , \ j = 1, \ldots, M \tag{19}$$
$$b^{(j)} = U(0,3) \quad , \ j = 1, \ldots, M \tag{20}$$
$$\boldsymbol{d}^{(j)} = U(L) \quad , \ j = 1, \ldots, M \tag{21}$$

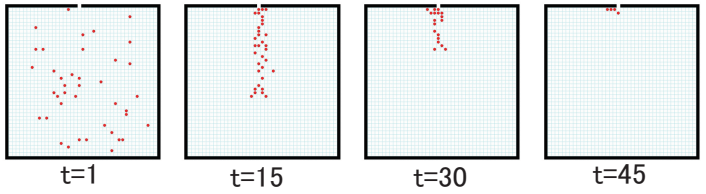
4.2.2 実 験 結 果

真値 $\boldsymbol{a}^{R_1} \sim \boldsymbol{a}^{R_9}$ に対しての推定値 $\boldsymbol{a}^{E1_1} \sim \boldsymbol{a}^{E1_9}$ を表 2 に示す．

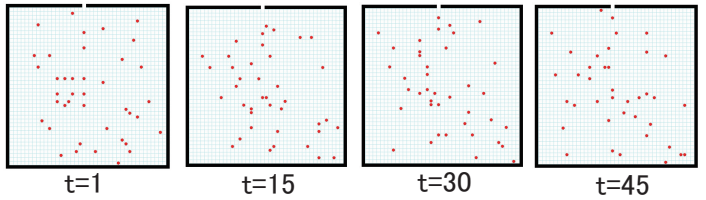
4.3 実験 2 [逐次ベイズ推定法]

4.3.1 実 験 内 容

粒子の数 N を $N = 1000$ とした．パラメータ $\{\boldsymbol{a}_0^{(i)}\}_{i=1}^{N}$ の初期分布は実験 1 と同じ一様分布を用いた．σ は $\sigma = 1$ とした．パラメータの共分散行列は以下のようにした．



(a) $(a, b, d_x, d_y) = (1.0, 1.5, 20.0, 0.0)$ の時の観測値の推移



(b) $(a, b, d_x, d_y) = (0.5, 0.5, 20.0, 0.0)$ の時の観測値の推移

図 2 観測値の推移

表 2 最尤推定法による推定値と位置精度

	$\boldsymbol{a}^{E1_1}$	$\boldsymbol{a}^{E1_2}$	$\boldsymbol{a}^{E1_3}$	$\boldsymbol{a}^{E1_4}$	$\boldsymbol{a}^{E1_5}$	$\boldsymbol{a}^{E1_6}$	$\boldsymbol{a}^{E1_7}$	$\boldsymbol{a}^{E1_8}$	$\boldsymbol{a}^{E1_9}$
a	0.33	0.24	0.99	1.02	0.72	1.30	1.29	1.21	2.41
b	0.90	1.19	1.28	0.48	1.06	1.52	0.64	1.10	2.03
d_x	19.3	19.0	20.0	13.9	18.8	18.7	24.9	17.5	20.0
d_y	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
位置精度	15.47	12.16	7.73	12.83	9.65	7.46	14.94	8.18	5.93

© 2011 Information Processing Society of Japan

Vol.2011-CVIM-177 No.6
2011/5/19

$$\Sigma \boldsymbol{v}_2 = \begin{pmatrix} 0.1 & 0 & 0 & 0 \\ 0 & 0.1 & 0 & 0 \\ 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 0.5 \end{pmatrix} \tag{22}$$

4.3.2 実験結果

真値 $\boldsymbol{a}_1^R \sim \boldsymbol{a}_9^R$ に対しての推定値 $\boldsymbol{a}^{E2_1} \sim \boldsymbol{a}^{E2_9}$ を表 3 に示す.

表 3 逐次ベイズ推定法による推定値と位置精度

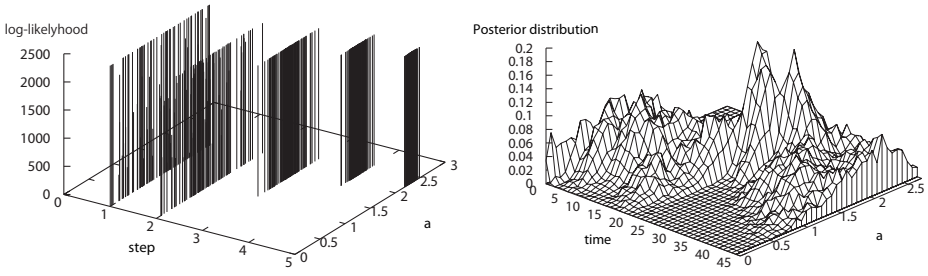
	$\boldsymbol{a}^{E2_1}$	$\boldsymbol{a}^{E2_2}$	$\boldsymbol{a}^{E2_3}$	$\boldsymbol{a}^{E2_4}$	$\boldsymbol{a}^{E2_5}$	$\boldsymbol{a}^{E2_6}$	$\boldsymbol{a}^{E2_7}$	$\boldsymbol{a}^{E2_8}$	$\boldsymbol{a}^{E2_9}$
a	0.53	0.19	2.07	1.65	2.94	1.09	1.48	1.38	1.97
b	0.71	0.49	0.67	0.11	0.75	1.68	0.58	1.68	1.72
d_x	21.1	0.0	19.3	0.0	20.8	20.0	19.46	20.5	20.5
d_y	0.0	3.82	0.0	27.9	0.0	0.0	0.0	0.0	0.0
位置精度	15.6	13.4	10.5	14.4	10.1	6.24	13.2	7.11	5.99

4.4 考　　察

まず，各手法の推定方法の違いについてであるが，最尤推定法では図 3(a) のようにパラメータの要素がある値へ収束する様子が見て取れる．逐次ベイズ推定法では図 3(b) のように，各時刻における要素の事後分布を推定している．

次に，再現性の点から最尤推定法・逐次ベイズ推定法のパラメータ推定の精度を考察する．真値の位置精度と推定値の位置精度とを比較すると表 4 のようになった．3 節で述べたように，真値との位置精度の差が小さいほど推定値の再現性は高いといえる．最尤推定法と逐次ベイズ推定法での推定値の位置精度の差を見てみると，$\boldsymbol{a}^{R_7}$ 以外の推定値では ±1 程度の差で収まっている．このことから，提案手法による推定は再現性の高いパラメータを推定することができたと言える．また，最尤推定法と逐次ベイズ推定法を比べてみると，全体的に最尤推定法での推定値の方が真値の位置精度との差が少なく，より再現性の高いパラメータを推定したことがわかる．

続いて，実際の真値との差を比較してみた．表 5 に各手法による推定値の要素ごとの真値との推定誤差を示す．なお，推定誤差は真値との各要素の差の絶対値をとったものである．各手法での推定誤差を見てみると，最尤推定法の方が推定誤差が少ないことがわかる．また，逐次ベイズ推定法での d_x，d_y の推定誤差が大きいが，a, b の値が小さく，これは出口



(a) 最尤推定法での要素 a の推定　　(b) 逐次ベイズ推定法での要素 a の事後分布推定

図 3 各手法での推定

表 4 真値と推定値の位置精度との差

	$\boldsymbol{a}^{R_1}$	$\boldsymbol{a}^{R_2}$	$\boldsymbol{a}^{R_3}$	$\boldsymbol{a}^{R_4}$	$\boldsymbol{a}^{R_5}$	$\boldsymbol{a}^{R_6}$	$\boldsymbol{a}^{R_7}$	$\boldsymbol{a}^{R_8}$	$\boldsymbol{a}^{R_9}$
最尤推定法	-0.33	+0.67	-0.97	-0.57	+0.65	+1.46	+4.75	+0.78	+0.53
逐次ベイズ推定法	-0.20	+1.91	+1.80	+1.00	+1.10	+0.24	+3.00	-0.29	+0.59

の場所による影響がほとんど無視されるような状況であると考えられる．

表 5 真値と推定値の位置精度との差

	$\boldsymbol{a}^{R_1}$	$\boldsymbol{a}^{R_2}$	$\boldsymbol{a}^{R_3}$	$\boldsymbol{a}^{R_4}$	$\boldsymbol{a}^{R_5}$	$\boldsymbol{a}^{R_6}$	$\boldsymbol{a}^{R_7}$	$\boldsymbol{a}^{R_8}$	$\boldsymbol{a}^{R_9}$
a [最尤推定法]	0.17	0.26	0.49	0.02	0.28	0.3	0.71	0.79	0.41
b [最尤推定法]	0.69	0.19	0.22	0.02	0.06	0.02	0.14	0.1	0.53
d_x [最尤推定法]	0.7	1	0	6.1	1.2	1.3	4.9	2.5	0
d_y [最尤推定法]	0	0	0	0	0	0	0	0	0
a [逐次ベイズ推定法]	0.03	0.31	1.57	0.65	1.94	0.09	0.52	0.62	0.03
b [逐次ベイズ推定法]	0.21	0.51	0.83	0.39	0.25	0.18	0.08	0.68	0.22
d_x [逐次ベイズ推定法]	1.1	20	0.7	20	0.8	0	0.54	0.5	0.5
d_y [逐次ベイズ推定法]	0	3.82	0	27.9	0	0	0	0	0

最後に計算時間であるが，最尤推定法ではこの条件下で 1 つのパラメータを推定するのに約 1 時間ほどかかるのに対し，逐次ベイズ推定法では約 1 分で推定することができる．

© 2011 Information Processing Society of Japan

以上の点から，最尤推定法では時間がかかるが推定精度が高く，逐次ベイズ推定法では時間はかからないが，最尤推定法ほどの推定精度はないということがわかる．また，最尤推定法では 1 つのパラメータを推定するのに対し，逐次ベイズ推定法ではパラメータの事後分布を推定している．このことから，最尤推定法は本研究で取り扱ったような時間変化のない静的フロアフィールドのパラメータ推定に有効であると考えられ，逐次ベイズ推定法は本研究で取り扱っていない動的フロアフィールドのパラメータ推定に有効であると考えられる．

5. おわりに

本研究では，歩行者行動モデルとしてフロアフィールドを用いたセルオートマトンモデルを考え，フロアフィールドパラメータの推定方法を提案した．

フロアフィールドは本来，時間的な変化のない静的フロアフィールドと時間変化のある動的フロアフィールドによって構成されている．しかし本研究では，パラメータ推定の手法を構築することが目的であったため，動的なフィールドを排除して考えた．その為，表現された歩行者の動きが人間らしくないものとなってしまっているという問題点がある．動的フィールドを取り入れたフロアフィールドを考えることで，より現実を表現するシミュレーションを行うことが可能になると考えられる．最尤推定法では本研究で用いた静的フロアフィールドのパラメータ推定を，逐次ベイズ推定法では本研究で用いていない動的フロアフィールドのパラメータ推定を行うのに適していることが考察された．従って，2 つの提案手法を用いることでフロアフィールドを決定し，歩行者行動モデルを構築することが可能になる．

またこの研究の発展として，本研究では 1 人の歩行者が 1 セルのみを占有する場合を考えているが，セルの大きさを小さくし，1 人の歩行者が複数のセルを占有する場合を考がえることでより複雑な行動を表現することが可能になると考えられる．

参 考 文 献

1) K. Nummiaro, E. Koller-Meier, and L. V. Gool, An adaptive color-based particle filter, Image and Vision Computing, Vol.21, pp. 99–110 (2003).
2) D. Comaniciu, V. Ramesh, and P. Meer, Kernel-Based Object Tracking, IEEE Trans.Pattern Analysis and Machine Intelligence, Vol.25, No.5 (2003).
3) M. Isard and A. Blake, Condensation – Conditional density propagation for visual tracking, Int. J. Computer Vision, Vol.29(1), pp.5–28 (1998).
4) 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).
5) P.Viola and M.J.Jones, Robust Real-Time Face Detection, Int.J.Computer Vision, Vol.57, No.2, pp.137–154 (2004).
6) K.Okuma, et al., A Boosted Particle Filter: Multi target Detection and Tracking, Proc.ECCV, pp.28–39 (2004).
7) B.Leibe, K.Schindler and L. V. Gool, Coupled Detection and Trajectory Estimation for Multi-Object Tracking, Proc.ICCV, pp.1–8 (2007).
8) M. Andriluka, S. Roth, and B. Schiele, People-tracking-by-detection and people-detection-by-tracking, Proc.CVPR, pp.1–8 (2008).
9) M. D. Breitenstein, F. Reichlin, B. Leibe, E. Koller-Meier, L. V. Gool, Robust Tracking-by-Detection using a Detector Confidence Particle Filter, Proc. ICCV, pp.1515–1522 (2009).
10) S. Ali and M. Shah, Floor Fields for Tracking in High Density Crowd Scenes, Proc.ECCV, Vol.2, pp.1–14 (2008).
11) R. Mehran, A. Oyama, and M. Shah, Abnormal Crowd Behavior Detection using Social Force Model, Proc.CVPR, pp.935–942, 2009.
12) 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).
13) 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.
14) 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).
15) 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).
16) 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.
17) Dirk Helbing and Péter Molnár, Social force model for pedestrian dynamics, Physical Review E, Vol.51, No.5, pp.4282–4286 (1995).
18) 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).
19) 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).
20) 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).

© 2011 Information Processing Society of Japan