株式会社構造計画研究所御中

マサチューセッツ工科大学
丸山　隼
斎藤　武
浅田　春比古

「日常的な駅構内旅客流動分析手法の確立に向けた研究」における artisoc 使用に伴う研究報告書

1.　初めに

1.1.　本報告書について

本報告書は、マサチューセッツ工科大学と東日本旅客鉄道株式会社（以下 JR 東日本）による共同研究におけるマルチエージェントシミュレータ「artisoc」を使用した研究の報告書である。本研究は駅に配置されるセンサ類から駅を利用する旅客の流動を再現する旅客流動分析手法の確立を目的とするものであり、artisoc を使用したシミュレーションデータと分析手法によって行った実験の結果と考察について報告する。

1.2.　研究目的と背景

ICT によるお客さまサービスの品質向上を目的に、マサチューセッツ工科大学と JR 東日本は駅を中心とした情報サービスに関する共同研究を行っている。その中でも特に、駅の中で最も動的かつ推定する手法が現在確立されていない情報である旅客流動の分析に着目し、駅の中に配置されるセンサを用いることでセンサ情報から流動を再現することを一つのテーマとして研究を進めている。

しかし、全ての流動をシステム的に把握することは現状の駅設備環境では非常に困難であり、駅内のカメラや改札機の実データに直接推定手法を当てはめたとしても、真の値が未知であることからその推定値の妥当性を評価することは難しい。そこで、実データによる手法の確立や評価の前段階として、シミュレーションによる旅客流動データと、それを元にセンサから得られることが想定されるセンサデータを生成し、センサデータから正解である旅客流動データの推定とその結果の評価を行う。この実験を行うにあたり、artisoc を使用し、旅客流動のシミュレーションデータの生成を行った。

2.　旅客流動推定手法

2.1.　限定的な観測データに基づく旅客流動推定手法

人の位置情報及び混雑情報の取得において最も確実な方法は、旅客が到達する可能性がある区画全てをカメラなどのセンサにより網羅し、その情報を統合することである。だが、この方法は駅構内が広大であるほど膨大なセンサの数の設置を必要とし、コストの面で困難が想定される。

そこで本研究では、部分的に設置されたセンサから旅客の通過情報を取得し、その情報から未観測の区画を含めた最も確からしい旅客の位置を推定する手法の検討を行う。推定手法の基本理論としては、ベイズ統計理論に基づいた確率的推定手法を採用することとする。

ベイズ統計理論を用いる理由としては

- 推定対象に対して観測情報が少ない状況においても推定の枠組みを構築可能であること
- 旅客のような行動が決定論的ではなくランダム性が高い対象を確率的に表現できること
- 事前に把握している情報を「事前確率」として自然に組み込むことが可能であり、ビッグデータ分析等の結果を推定に組み込むことが容易であること

があげられ、本件の旅客流動推定の枠組みに適していると考えられるからである。

2.2.　観測データ

本研究では観測データとして、センサによる旅客の通過人数をカメラもしくは人数をカウント可能なセンサを用いて取得して使用することを想定し、通過人数をインプットとする。その理由は以下の通りである。

- 駅構内では既に監視カメラが運用されており、既存設備の併用による低コスト化が期待できること
- 画像処理技術による個別人認識はまだ研究途上だが、通過する人数の認識は一定の精度が期待できること
- 通過人数を入力とすることでカメラに限らず、人物通過を検出可能なセンサであれば追加できること
- 人数データは個別の人の動きを取得したものではなく、匿名性が高いこと

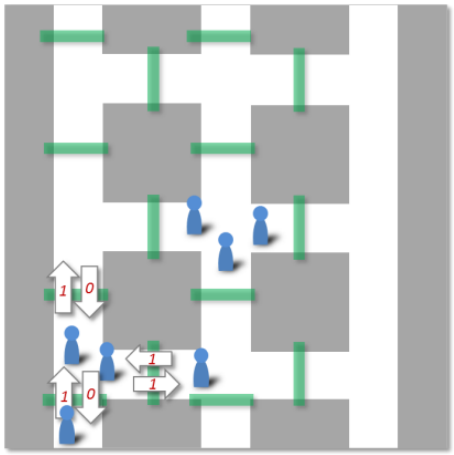

図 1 通過人数観測イメージ

なお、入力データについては通過人数データ以外にも有効なものが考えられ、例としては顔画像認識を用いた旅客の ID 化がある。先行研究にて顔画像認識による旅客追跡を行う手法も行われており、顔認識精度によっては個別の旅客を認識できることから正確な経路推定ができる可能性はある。しかし、顔画像はプライバシーに関わるデータであり、不特定多数の旅客が利用する駅では、使用許可取得を前提とした場合にリアルタイムな画像の活用は困難である。

そのため、本研究では顔画像認識による旅客追跡は行わないことを前提とした上で、旅客流動推定が可能かという視点で検討を行った。

3.　旅客流動モデル

3.1.　エージェントベースドモデル

本研究ではミクロな旅客ごとの動きを表現可能なモデルとして、エージェントベースドモデルによるモデル設計を検討する。エージェントベースドモデルは個別の旅客をエージェントとして一定のルールに基づき行動をシミュレートし、個々のエージェントの動きを統合した結果を全体のアウトプットとするモデルである。さらに、実際の旅客の動きは同じ状況であっても目的地の違いや個人差により異なる行動を取ることから、確率的な行動を取るモデルとして定義し、確率的エージェントベースドモデルを用いることとする。

3.2.　ブロック遷移モデル

エージェントベースドモデルにおけるエージェントの行動とフィールドのモデル定義を行う。各旅客をエージェントに見立て、観測データである旅客通過人数データに適合するように設計したモデルとして、エージェントが各ブロックを確率的に遷移するモデルを用いる。

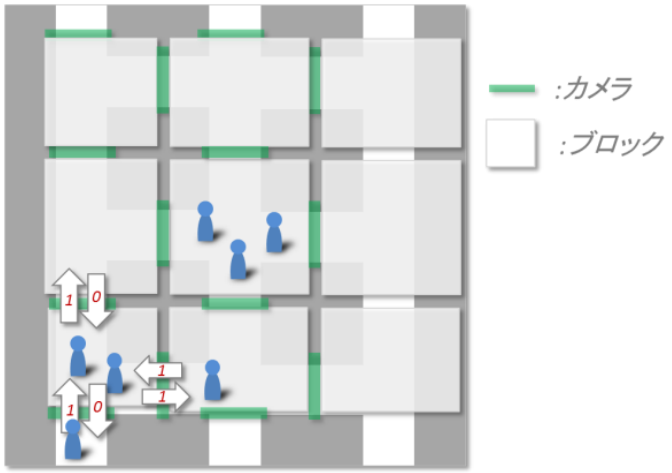

図 2 ブロック遷移のイメージ

このモデルでは、図 2 のようにエージェントが移動する空間をセンサによって分割された空間を一つのブロックとして見立て、エージェントがブロック間を遷移した結果が通過人数としてのみ観測されるモデルである。緑の線がカメラによる通過人数の線、白い四角がブロックのイメージを表す。

エージェントは各ステップにおけるブロックに滞在する確率と、他のブロックに遷移するかの確率を保持しており、各ステップにおける滞在と遷移の選択は確率的に行われる。各エージェントは移動に必要な時間を考慮し速度の平均と分散パラメータを持ち、エージェントの移動速度は正規分布に従うと定義する。これにより、次のブロックに移動≒到達する確率を計算することが可能であり、各エージェントのブロック遷移・滞在を確率的に扱うことが可能となる。

移動可能なブロックが複数ある（三叉路や十字路）場合は、上記移動速度に加えて次のブロックを選択する確率をパラメータとして定義する。もしブロックを選択する確率の事前情報がない場合は一様な確率分布として定義することになるが、もし自然な経路選択情報や正解データによる選択確率が得られている場合はこのパラメータに組み込むことが可能である。

また、エージェントの発生及び消滅は、フィールド外から内、フィールド内から外へのセンサ通過人数の観測データによって観測することができる。

3.3. ブロック遷移モデルにおける事後確率計算

次に 3.2 で定義したモデルにおける具体的な事後確率の計算について述べる。

ステップ t において、h 番目のエージェントが通過したセンサを $B_t^{(h)}$、全てエージェントの通過センサの値の集合を $B_t = \{B_t^{(1)},...,B_t^{(h)},...\}$ とする。また、s 番目のセンサによる通過人数の観測を $Y_t^{(s)}$、それらの全てのセンサの観測値の集合を $Y_t = \{Y_t^{(1)},...,Y_t^{(s)},...\}$ と定義する。

まず、初期ステップ t=0 のセンサ観測 Y_0 が得られた時の各エージェントの位置を B_0 の事後確率 $P(B_0 \mid Y_0)$ を求める。初期状態のフィールドは無人と設定し、フィールド外からのエージェントの遷移によって決定されることとする。フィールド外からの通過人数はセンサにより観測されているため、Y_0 で得られたセンサの人数だけエージェントを該当ブロックに発生させることで一意に B_0 の値を求めることができる。

次に t>0 の場合のステップ t 時点の事後確率 $P(B_{0:t}^{(h)} \mid Y_{0:t})$ は以下のように表すことができる。

$$
\begin{aligned}
&P(B_{0:t} \mid Y_{0:t}) \\
&\propto P(Y_t \mid B_{0:t}, Y_{0:t-1}) P(B_{0:t} \mid Y_{0:t-1}) \\
&= P(Y_t \mid B_{0:t}, Y_{0:t-1}) P(B_t \mid B_{0:t-1}, Y_{0:t-1}) P(B_{0:t-1} \mid Y_{0:t-1}) \\
&= P(Y_t \mid B_{0:t}, Y_{0:t-1}) \cdot \sum_{D_t} P(B_t \mid D_t, B_{0:t-1}, Y_{0:t-1}) P(D_t \mid B_{0:t-1}, Y_{0:t-1}) P(B_{0:t-1} \mid Y_{0:t-1})
\end{aligned}
$$

ここで、D_t はエージェントがステップ t 時点での次に通過する予定のセンサ番号の集合とする。

$P(B_{0:t-1} \mid Y_{0:t-1})$は事後確率 $P(B_{0:t} \mid Y_{0:t})$の 1 ステップ前の事後確率である。$P(B_0 \mid Y_0)$は既に定義しているため、$P(B_{0:1} \mid Y_{0:1})$を求める際は $P(B_0 \mid Y_0)$の値を代入すればよい。あとは各ステップの $P(B_{0:t} \mid Y_{0:t})$が求まるごとに、その値を次のステップの $P(B_{0:t-1} \mid Y_{0:t-1})$として代入すれば再帰的に値を求めることが可能である。

$P(D_{0:t} \mid B_{0:t-1}, Y_{0:t-1})$はステップ t における次の通過センサ（方向）の選択確率である。3.2 で述べたように、方向選択の事前情報を持っている場合、それに沿って方向の確率を定義して計算する。事前情報がない場合は一様な確率として設定する。

$P(B_t \mid D_t, B_{0:t-1}, Y_{0:t-1})$は次の通過センサが決定している時に、そのセンサに到達するかどうかを表す確率である。この確率はエージェントの移動速度に依存し、エージェントの移動速度が正規分布に従うと仮定して、センサ間の距離からセンサを通過するには必要な速度を求めて、その速度以上の確率を計算する。

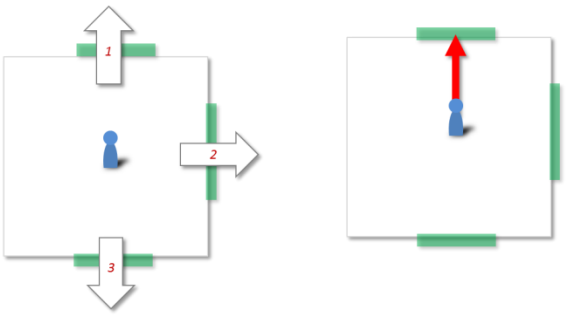

図 3 方向選択確率 $P(D_t^{(h')} \mid B_{0:t-1}^{(h')}, Y_{0:t-1})$と到達確率 $P(B_t^{(h')} \mid D_t^{(h')}, B_{0:t-1}^{(h')}, Y_{0:t-1})$

$P(Y_t \mid B_{0:t}, Y_{0:t-1})$はエージェントの遷移とセンサによる通過人数観測が一致するかどうか評価する確率である。通過人数はエージェントの遷移から一意に求めることができ、この確率は観測通過人数と一致する遷移であれば 1、一致しないのであれば 0 とする。これにより、実際の計算では不一致する遷移は常に 0 となるため、通過人数が一致する場合の遷移確率計算のみ行えば事後確率を求めることができる。

なお、0 と 1 以外の確率値を設定することで、実際の通過人数とセンサの通過人数の観測誤差をモデル化することも可能である。例えば、実際には通過人数が 2 人場合でも、2 人と観測される確率は 1 ではなく 0.8 で、カメラの誤検出で 3 人となることや逆に検出漏れで 1 人となる確率を 0.1 とすることで観測誤差を表現できる。

ただし、その場合誤差が発生する確率の設定と、観測値以外の場合の確率計算も必要となり計算量が増加する点が課題となる。特に計算量については 4.1 で述べるが、全てのパターンを考慮すると計算量が膨大となり、アルゴリズム自体も複雑となる。そこで、本実験では初期評価として誤差の考慮は行わない場合での計算を考える。

4. パラメータ推定

4.1. パラメータの推定における計算問題

3.のモデル定義により各エージェントの行動確率を定義し、各ステップにおける事後確率分布の計算が可能となる。この各エージェントの移動確率とカメラの移動人数の観測データを元に事後確率を各ステップで逐次的に計算し、各ステップにおける最も事後確率が高い結果を推定結果とする。

しかし、本モデルの事後確率を解析的に計算するには計算量の問題がある。1 つのブロックに X 人のエージェントが滞在する時に Y 人のエージェントが次のブロックに移動したとすると、センサデータに適合する組み合わせで X 人から Y 人を選ぶ確率を計算する必要があるが、その計算が必要な組み合わせな数は ${}_X C_Y$ となる。

例としてそれぞれ 5~50 人から 2~20 人が遷移した場合、表 1 の選択可能な組み合わせの数の確率を全て計算する必要がある。表から、人数が増加すると指数関数的に計算量が増加することが分かる。

一つのブロックに存在しうる最大人数は駅の利用者の数やブロックの範囲の設定にも依るが、30 人以上が一つのブロックに滞在することは東京駅等のような大規模駅では十分に起こりえる状況であり、その場合計算量は表の通り膨大なものとなる。

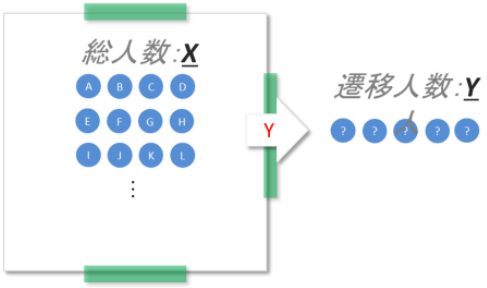

図 4 総人数と遷移人数

総人数 X	遷移人数 Y	組み合わせ数 ${}_X C_Y$
5	2	10
10	4	210
20	8	125970
30	10	30045015
50	10	10272278170

表 1　総人数と遷移人数に対する可能な組み合わせ数

一つ当たりのブロックに位置しているエージェントの数を減らす対策としては、ブロックをより小さく分割する方法等が考えられる。しかし、ブロックの分割は通過人数を取得するセンサの数と位置に依存することから、全てブロックを細かく分割するには多数のセンサ設置が必要となり、コストの面で実現できない場合がある。また、どの程度分割すれば最適な人数分布となるかは状況に応じて変化することから、推定が困難である。

以上より、事後確率の解析的な計算を常に一定の時間内に収めることは困難であることがわかる。そのため、次節にてパラメータの推定のための事後確率計算の計算量を一定の範囲で収めることができるような近似的計算手法の適用について説明する。

4.2.　パーティクルフィルタ

計算の近似手法には複数の手法が存在するが、ここではパーティクルフィルタと呼ばれる確率的近似手法を選定した。選定理由としては

- ステップごとの状態を逐次的に推定するオンライン推定が可能であること
- パーティクルの数の設定に応じて計算量を有限時間内に設定できること
- 本モデルのような滞在ブロックやカメラの人数等の離散値を含むモデルに適用可能であること
- パーティクルの数を極限的に無限とすることで対象の確立分布と一致することがわかっている

等の特徴があげられ、適用可能範囲が広く、本研究の目的とモデルに適合しているためである。

パーティクルフィルタは、確率的手法により近似を行うモンテカルロ法の一種であり、逐次モンテカルロ法とも呼ばれる。モンテカルロ法は対象の確率式に沿うようなサンプルを確率的に生成する手法を適用し、その生成されたサンプル群からパラメータの値や確率分布の特徴の推定を行う。パーティクルフィルタは別名の通りモンテカルロ法の中でも逐次的な確率分布のオンライン推定に適用可能であることが特徴である。新たな観測が得られる度に変化する事後確率分布を表すパーティクル（粒子）と呼ばれるサンプル群がパラメータを変化させ、再サンプリングを行うことで逐次的に変化する事後確率分布を近似する。

5.　実験

5.1.　実験条件

3.と 4.にて設計したアルゴリズムを評価するため、実装プログラムによる数値実験を実施した。

実験条件として図 5 のような簡略的な駅をイメージした仮想駅を設定し、この中で旅客を模したエージェントをシミュレーション上で動かして旅客の各時刻の位置データと観測データを生成した。そして観測データに推定アルゴリズムを適用し、正解である位置データと比較することで推定したエージェントの経路が正しく推定できたかどうか確認した。

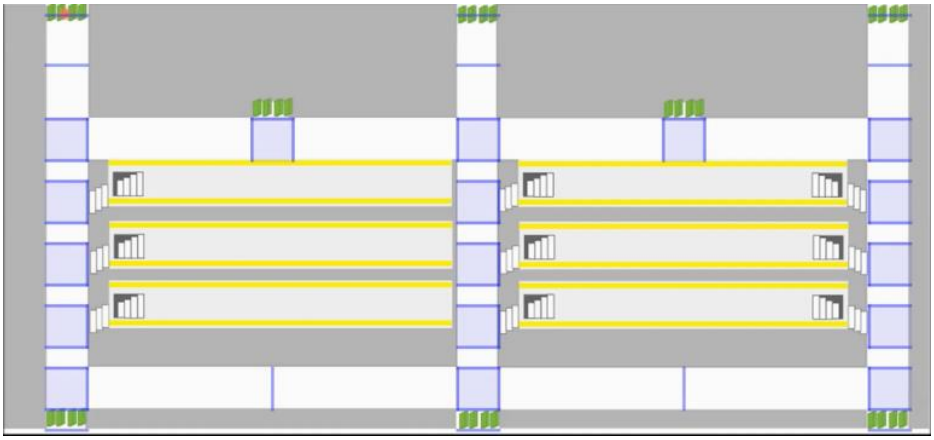

図 5 数値実験用仮想駅

緑の箇所は改札口を表しており、改札と階段から旅客は発生し、目的の改札と階段に到達すると消滅する。青い線は通過人数をカウントするラインを表しており、さらに青い四角はカメラの範囲を表していて、この中を通っている旅客は方向を追跡し、入った方向と出た方向を観測として与える。観測が得られる間隔は 1 ステップ 1 秒と設定し、1000 ステップ=1000 秒を 1 実験としてシミュレーションデータを生成した。また旅客の動きは本来の駅の場合は立ち止まりや逆方向への転換が考えられるが、ここでは目的地に直進する動きとした。

また、本アルゴリズムは人数情報だけを観測とし、個別の旅客を区別できるような情報、例えば顔認識による ID 等は与えていない。このことから、人数が多くなるごとに個々の区別が困難となることが予想される。そのため、どれくらいの頻度で各ステップに各改札、階段から新たな旅客が入場するかを定義する確率「入場率」のパラメータを設定し、毎秒 1, 3, 5, 10, 20, 50%それぞれの場合で実験を行い、推定精度の比較を行った。

5.2.　実験結果

実験結果を表 1 に示す。正答数は経路を正しく推定できた旅客の人数、総数は推定対象の旅客の人数を表す。正答率は[正答数]/[総数]で計算している。

入場率	正答数	総数	正答率
1%	152	160	95.0%
3%	392	474	82.7%
5%	656	768	85.4%
10%	1056	1653	63.9%
20%	1396	3159	44.2%
50%	1883	8030	23.4%

表 2　旅客経路推定結果

結果を見ると分かる通り、人数が少ない入場率 1%では正答率 95.0%と非常に高い確率で経路を推定できている。しかし、入場率が高い実験になるにつれて正答率が下がってきており、入場率 50%では正答率 23.4%になってしま

うという結果となった。

また、推定した結果を動画として出力し、映像で確認したところ、推定結果と真の旅客の位置関係や分布はおおよそ正しい位置を推定しており、混雑している場所や空いている場所はほぼ一致していた。しかし、追い越しや合流で位置が重なりあった時などは個別の旅客同士が入れ替わって推定されることがあり、経路の追跡についてはうまく推定できない場合があることがわかった。

5.3. 考察

入場率の上昇に伴い正答率が低下する理由には、前述の通り人数情報のみの推定における情報量の不足が考えられる。入場率が低く、人数が少ないうちは旅客同士が近くを歩く確率は低く、取り違いが起きる可能性は低い。しかし、人数が増加するごとに付近に存在する旅客は増加し、取り違いが発生する可能性も増加する。

取り違いが起きる理由については、個別の旅客を区別する情報が通過人数には含まれていないことが挙げられる。現状の枠組みでは個人を区別する情報は通過タイミングであり、逆に言えば不自然ではないタイミングの通過であれば入れ替わりを許容してしまう。これを回避するためには画像等の個人を区別しうる情報を追加情報として与える方策が考えられるが、そういった情報が利用可能であるかは個人情報取り扱いの法令に依存し、本研究の前提に反する。

その一方で旅客の全体的な混雑状況などは、入れ違いが発生してもその後の位置追跡は可能であるため、個別に旅客を区別せずに旅客の分布状況を推定するのであれば比較的有効に機能すると言える。

5.4. まとめと今後の展開

今回のシミュレーションによる実験により、通過人数を観測するセンサデータへ確率的エージェントベースドモデルに基づく推定手法の評価を行った。その結果、対象のフィールドが比較的混雑していない環境では旅客の個別の軌跡を推定可能であることがわかった。その一方で、混雑している環境下ではセンサデータに個別旅客を区別できるような情報が含まれていないため、周囲の旅客と混同する場合があり、正確な経路推定が困難であるという結果となった。また、個別の旅客の区別を除いた位置関係の推定には混雑下においても一定の精度が得られることがわかった。この結果から、今後は以下の 2 つの方向性の検討を行う予定である。

- 個別の歩行経路は推定せず、混雑の推定や近未来予測を行う
- 駅内のセンサ範囲拡大の低コスト手法を検討し、未知エリアを狭めることで精度を高める

特に今後は後者を主体に検討を進めると同時に、実サービスへのアプリケーション開発を前提とした取得情報の活用の方向性を模索する。