

人流における学習型誘導技術のデータ同化

Data Assimilation and Preliminary Security Planning for People Crowd

松林 達史
Tatsushi Matsubayashi

NTT サービスエボリューション研究所
NTT Service Evolution Laboratories
matsubayashi.tatsushi.tb@hco.ntt.co.jp

清武 寛
Hiroshi Kiyotake

(同 上)

幸島 匡宏
Masahiro Kohjima

(同 上)

戸田 浩之
Hiroyuki Toda

(同 上)

田中 悠介
Yusuke Tanaka

(同 上)

六藤 雄一
Yuichi Muto

(同 上)

塩原 寿子
hisako Shiohara

(同 上)

宮本 勝
Masaru Miyamoto

(同 上)

清水 仁
Hitoshi Shimizu

NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

大塚 琢馬
Takuma Ohtsuka

(同 上)

岩田 具治
Tomoharu Iwata

(同 上)

澤田 宏
Hiroshi Sawada

(同 上)

納谷 太
Futoshi Naya

(同 上)

上田 修功
Naonori Ueda

(同 上)

keywords: multi agent simulation, bayesian optimization

Summary

Forming security plans for crowd navigation is essential to ensure safety management at large-scale events. The Multi Agent Simulator (MAS) is widely used for preparing security plans that will guide responses to sudden and unexpected accidents at large events. For forming security plans, it is necessary that we simulate crowd behaviors which reflects the real world situations. However, the crowd behavior situations require the OD information (departure time, place of Origin, and Destination) of each agent. Moreover, from the viewpoint of protection of personal information, it is difficult to observe the whole trajectories of all pedestrians around the event area. Therefore, the OD information should be estimated from the several observed data which is counted the number of passed people at the fixed points.

In this paper, we propose a new method for estimating the OD information which has following two features. Firstly, by using Bayesian optimization (BO) which is widely used to find optimal hyper parameters in the machine learning fields, the OD information are estimated efficiently. Secondly, by dividing the time window and considering the time delay due to observation points that are separated, we propose a more accurate objective function.

We experiment the proposed method to the projection-mapping event (YOYOGI CANDLE 2020), and evaluate the reproduction of the people flow on MAS. We also show an example of the processing for making a guidance plan to reduce crowd congestion by using MAS.

1. はじめに

明石歩道橋の雑踏事故 [明石市 01, 室崎 02] を機に, 大規模なスポーツイベントやライブイベントなどにおいては, 観覧者の入退場時などで混雑や雑踏事故などを未然に防ぎ, 安全に運営を行うための事前の綿密な警備計画の重要性がより高まった. 警備計画では事前に, 転落防止措置, 通路の段差などに対する危険防止措置, 幅員の確保 (緩衝帯の確保), 避難路 (迂回路) の確保, 一方通行または相互通行における中央線設計など, 危険箇所を抽出し予測される人の流量などから対処方法を考え, 未然に事故を防ぐことが重要になっている [兵庫県 02]. 2020 年に東京で開催予定であるオリンピック・パラリンピックでは, 新国立競技場 (オリンピックスタジアム) の建設と関連施設の改修が進み, 周辺複数の駅からの歩行者移動経路を想定して, 安全なアクセス環境の計画立案を進めている. 特にオリンピックスタジアムでは, 建設時においても, 工事車両の動線を考慮した事前計画を綿密に立てて工事の着手に至っている [東京都 1].

警備などにおける事前計画策定において, 広く用いられているのが Multi-Agent Simulation (以下 MAS) である. MAS は, 各エージェントが「いつ, どこから, どこへ向かうか」という情報を元に, 群衆行動をコンピュータ上で模擬するシステムであり, 様々なシチュエーションでの群衆行動の分析を実施することで, 誘導計画や, 歩行者路の道幅確保などの警備計画の策定に役立てられている [犬飼 05, 山下 12, Yamashita 13, Yamashita 14]. 群衆行動の模擬シミュレーションを行う際, 例えば避難行動シミュレーションでは, 対象となる空間において複数カメラから群衆の動線を測定し, 人々の動きを推定する [大西 15, Zhou 15]. しかしながらカメラなどによる計測には限界があり, 対象領域によっては, 例えば花火会場と駅を結ぶ広域な空間においては, 限られた動線を仮定して, 群衆の流れの推定を行う [重中 18, 山下 14a, 山下 14b].

また, 警備計画における群衆行動の想定には, 過去の知見のみならず類似イベントによる調査も重要視されており, 新国立競技場では群衆行動のテストイベントも計画されている [東京都 2]. テストイベントなどによる群衆行動の把握には, 人流の計測が重要である. しかしながら, 人々の軌跡を GPS などで追跡し続けることは困難であり, またプライバシー保護の観点からも画像から人々を追跡し続けることは難しい. そのため, 限られた計測情報から人々の流れを推定する必要がある. この時, 各観測点での単純な人の流量だけではなく, 群衆が「いつ, どこから, どこへ」という, Origin and Destination (OD) の推定が必要になる. この OD を推定してエージェントの目的地を定めることにより, MAS 上において通行止めや幅員減少などの環境を変更した群衆行動のシミュレーションを検証することが可能になる [Castle 11, 川口 15].



図1 学習型誘導技術の全体スキーム. ①: 実世界において限られた観測点から人々の通過人数を定点観測. ②: 機械学習技術により, OD と呼ばれる人の目的地と発生人数を推定. ③: OD の推定からエージェントを発生させマルチエージェントシミュレータへの入力として利用. ④: 混雑解消のための交通改善施策の検討や, 事故を想定した誘導計画準備などを, シミュレーションを用いて What-If 分析を行う. ⑤: 分析結果を翌日以降の警備に反映したり, 分析ノウハウを蓄積してゆく.

警備計画においては, 単純に危険箇所を通行止めにすることや迂回路指示の準備をするだけではなく, 迂回先に人々が殺到しないようにすることや全体の最適化を考慮しながらの事前計画が重要となってくる. そのためにも群衆の OD 推定をより正確に行うことが重要になる.

本研究では, 大規模なイベントなどで, イベント会場と周辺駅などの間を群衆が移動する, 群衆行動のデータ同化技術 (OD 推定) を, 実際に新宿駅新南口周辺で行われたイベントの分析を交えて紹介を行う. また, MAS を用いることにより, 警備計画の What-If 分析例も併せて行う. ここで, 図1に我々の What-If 分析技術のフレームワークである, “学習型誘導技術” [納谷 17] の全体スキームを示す.

2. YOYOGI CANDLE 2020

2.1 イベント概要

本研究では, 新宿駅新南口を中心として開催された, 「YOYOGI CANDLE 2020」のイベントの紹介と, イベントにおいて取得した人の流れのデータを元に議論を進める.

YOYOGI CANDLE 2020 (以降 YOYOGI2020 と略す) は, NTT ドコモ代々木ビルへ向けたプロジェクションマッピングのイベント *1 であり, 新宿駅新南口周辺から観覧可能であることと, アプリによりユーザメッセージを直接投影できる, インタラクティブなイベントである. 2017 年の 10 月 28 日と 11 月 29 日の 2 回実施され, 10 月 28 日は悪天候であったが 11 月 29 日は晴天に恵まれ, 数千人の観覧者が訪れた. その様子の一部を図2に示す.

なお, 本イベントでは多くの観覧者がイーストデッキ上でスマートフォンを用いてプロジェクションマッピングに参加したが, イーストデッキの直下には電車が走って

*1 http://style20.jp/rd/article/article_36/




図2 イベントの様子。上図が新宿駅より、NTTドコモ代々木ビルを望んだ景色。イーストデッキに、人々が集まっている。下図はその現地の様子であり、スマホアプリによりメッセージを映すことが可能になっている。

おり、スマートフォンを落としてしまう危険性から、イーストデッキ上の端は数 m ほど規制していた。

本イベントは 2 回実施されることにより、1 回目の警備計画の課題を 2 回目のイベントに反映することが可能であった。人々の行動ログを取得する実証実験では、イベント主催者を中心に事前告知やプライバシー配慮の調整が必要であり、地元自治体や警察へのイベント計画書の届け出が必要な場合がある。本イベントでは主催者の協力により、計測に関わる事前交渉や現地でのイベント告知などプライバシー配慮を十分に行って進めたため、本研究の検証実験の場の一つとして選択した。

2.2 データ取得方法

本稿では、10 月 28 日のイベントでは、雨天のためにイベント効果測定が困難であることより、11 月 29 日（水曜日）の取得データを用いて議論を行う。また、イベントに向かう人の流れを把握するために、イベント開催前の 11 月 27 日、28 日の二日間にわたり、平日の人の流れを観測。通常時の人の流れも併せて議論を行う。

主な観覧場所は 3 か所あり、観覧場所への流入出を測定するために、13 か所で人の流れを計測した（図 3）。観覧場所は事前にパーティションで区切り、警備員の配置を行い、観覧場所以外では立ち止まらぬように誘導を実施した。観測点は 3 か所の観覧場所に対する動線を中心に、事前調査を行い決定。特に四叉路では動線方向への




図3 人流観測点と推定経路。観覧場所は主に黄色のエリア X, Y, Z の 3 か所。観測地点 A.....M の 13 か所計測を実施。



図4 手動計測方法。計測は有向で行い、基準線に対して右方向と左方向を区別して計測。計測時には関係者用のスタッフジャンパーを着用。

流量が極力正確に把握可能にするため、閉空間を作るように 4 か所の観測を実施。特に、新南口のイーストデッキ（新宿サザンテラスとタイムズスクエアビルを結ぶ人道橋）での観覧者が多くなることを想定し、橋の東西および、滞留人数の測定も併せて実施した。また警備計画の議論の中で、「新宿駅までの安全な誘導」と「ショッピングセンターに向かう一般客への配慮」の 2 点に関しての配慮が焦点となったため、誘導効果などの考察のために観測点 E と M の計測を決めるなど、警備の観点から計測場所の選定を行った。

計測には Android スマートフォンアプリを用いて、各観測点に人員を配置して手動計測を実施。図 4 に示すように、各観測点では基準線に対して右方向と左方向の計測を行った。また、計測時にはスタッフジャンパーを着用し、イベント関係者であることが分かりやすくなるよう配慮を行った。

2.3 集客と人の流れ

本節では特に観覧者が多く、重点的に警備を行っていたイーストデッキの東西の観測点をピックアップし、イーストデッキ上での観覧者と群衆の流れに関して分析を報告する。

図 5 は、観測点 B（西側）および C（東側）における、11 月 27, 28, 29 日の 3 日間の通過人数計測結果を表す。B1 および C1 は『東から西へ向かう通過人数』であり、B2 および C2 は『西から東へ向かう通過人数』を示す。計測は 1 分毎に集計を行い、縦軸は 1 分当たりの通過人数である。計測は 18:00 から 21:30 までの 3 時間半（210 分間）行った。

各観測日 $DD = \{27, 28, 29\}$ の、観測点 i かつ時刻 t の観測データを $\mathbf{Y}^{DD} = y_{i,t}^{DD} \in \mathbb{N}^{I \times T}$ とした時、図 5-(a), (c), (e), (g) はそれぞれの観測点における 1 分毎の集計値であり、 $y_{B1,t}^{DD}, y_{B2,t}^{DD}, y_{C1,t}^{DD}, y_{C2,t}^{DD}$ である。また、図 5-(b), (d), (f), (h) はそれぞれの積算値を表し、例えば図 5-(b) では $\sum_{t'=0}^t y_{B1,t'}^{DD}$ を表している。図 5-(b), (d), (f), (h) の各日の傾きからも、3 日間ともイベントを開催していない時間帯の通過人数に大きな変動はないことが分かり、イベント開催日の 29 日では、イベント前後でそれぞれ流量が増え、観覧場所へ人が一時的に集まり、人が捌けて行っていることが分かる。

イベント開催日にはプロジェクションマッピングを 35 分間にわたり、1 回目投影が 18:25~19:00、2 回目投影が 20:25~21:00 と 2 回の投影を実施した。1 回目投影時には 17:30 から警備開始を行い、付近でチラシ配布も行った。2 回目投影時には 19:30 からチラシ配布を行った。ここで図 5 と図 6 では投影時間帯を薄ピンクで網掛けをした。

図 5 の積算値に対し、図 5-(b) からは通常時と比較して流入量が 1,680 人増えていることが分かり、図 5-(h) からは流入量が 280 人増えていることが分かり、流入量の総計は 1,960 人増えている。また、図 5-(d) からは通常時と比較して流出量が 1,560 人増えていることが分かり、図 5-(f) からは流出量が 480 人増えていることが分かり、流出量の総計は 2,040 人増えている。差分の 80 人は観測誤差として考えられるが、イベントに影響を受けての流入流出量は $2,000 \pm 40$ 人と見積もることができる。しかしながら、この増加した 2,000 人の全てがイベントに影響を受け、観覧をしたとは考えられない。興味をもってイーストデッキを通りながらそのまま通過した人も多い。

そこで次に、通常時の流量（流入 $\bar{y}_{IN}(t)$ および流出 $\bar{y}_{OUT}(t)$ ）を求め、イベント時特有に表れた流入 $In(t)$ と流出 $Out(t)$ を求めた。通常時の流量は 27 日と 28 日の平均とし、式で表すと以下の通りである、

$$\bar{y}_{IN}(t) = \frac{1}{2} \left\{ y_{B1,t}^{27} + y_{C2,t}^{27} + y_{B1,t}^{28} + y_{C2,t}^{28} \right\}, \quad (1)$$

$$\bar{y}_{OUT}(t) = \frac{1}{2} \left\{ y_{B2,t}^{27} + y_{C1,t}^{27} + y_{B2,t}^{28} + y_{C1,t}^{28} \right\}. \quad (2)$$




図 6 紫線と緑線はそれぞれ流入 $In(t)$ と流出 $Out(t)$ を表す。

従って、イベント時特有の流入と流出は、イベント日（29 日）の流量と通常時の流量の差分で、以下の式で表すことができる、

$$In(t) = \sum_{t'=0}^t \left\{ y_{B1,t'}^{29} + y_{C2,t'}^{29} - \bar{y}_{IN}(t') \right\}, \quad (3)$$

$$Out(t) = \sum_{t'=0}^t \left\{ y_{B2,t'}^{29} + y_{C1,t'}^{29} - \bar{y}_{OUT}(t') \right\}. \quad (4)$$

図 6 は流入 $In(t)$ （紫線）と流出 $Out(t)$ （緑線）をグラフとして表した。図 6 より、イベント開始時刻（18:30）前より、通常時より流入が増え始めるが、同時に通常時より流出も増え始める。流入と流出のタイミングには時間差があり、この流入と流出の差分を見ることにより平均滞在時間の見積もりが可能である。例えば、18:15 ほどに流入した人達はおおよそ 20 分ほどの滞在が推定され、18:30 に流入した人達は終了間際（19:00）までの 25 分ほど滞在していることが分かる。終了後に両線がフラットになっているのは、流入も流出も平日と変わらない流量であることを示している。また、第 2 回目のプロジェクションには 20:10 頃より流入が増え始め、増えた人々はそのまま 20 分ほど滞在していることが分かり、20:40 頃からは流入した人もほとんどそのまま流れ、流出していることが分かる。このことより、全体の流入流出に対して、効果的に 20 分ほど観覧した人達は、第 1 回目のプロジェクションマッピングで 800 人、第 2 回目のプロジェクションマッピングで 500 人の、合わせて 1,300 人ほどの群衆が観覧を楽しんだことが分かる。

3. データ同化技術

次に、観測されたデータから人々の流れ（Origin and Destination :OD）を推定する、データ同化技術の紹介を行う。本研究では、ベイズ最適化手法 [Snoek 12] を基にした時間遅れを考慮した推定手法を提案する。

ここでデータ同化対象はイベントが開催された 29 日のみで行い、観測データを $\mathbf{Y}^{29} = \mathbf{Y} = \{y_{it}\} \in \mathbb{N}^{I \times T}$ 、経路ごとの OD を $\mathbf{X} = \{x_{rt}\} \in \mathbb{N}^{R \times T}$ とし、また、観




図5 観測点 B,C における3日間の通過人数計測結果. 図-(a), (c), (e), (g) はそれぞれ1分毎の通過人数を表す. 図-(b), (d), (f), (h) はそれぞれの観測点での通過人数積算値を表す.

測点 $i \in \{1, \dots, I\}$, 時間帯 $t \in \{1, \dots, T\}$, 通行経路 $r \in \{1, \dots, R\}$ とする. 次に, 手法から得られた推定結果を $\hat{Y} = \{\hat{y}_{it}\}$ とし, 基本的には観測と推定の誤差である $L(Y, \hat{Y})$ を極力小さくすることによって, 推定による再現性を高める手法をデータ同化と呼んでいる. 最終的には, MAS への入力パラメータ X を求めるため, 最適な X^* は以下で表される,

$$X^* = \arg \min_X L(Y, \hat{Y}). \quad (5)$$

この時, 推定結果は入力パラメータ X により再現するため, 関数 f により $\hat{Y} = f(X)$ と表現可能である.

3.1 Multi Time Window Bayesian Optimization

本手法は, Multi Time Window Bayesian Optimization (MTW-BO) と呼び, ベイズ最適化を用いて最適な入力パラメータ X を求める手法である.

MAS におけるエージェントは, 歩行モデルに従って動く一方, 実際の人の動きはパーソナルスペースを保つために, お互いの相互作用が発生し不規則な動きを行う. 特に混雑時では, 例えば MAS 上でもエージェント間の相互作用が発生し, エージェントの動きは非線形となるため規則的な推定が困難となる.

一方ベイズ最適化は, $\hat{Y} = f(X)$ としたとき, f の関数形が不明な, いわゆる BlackBox 関数を扱う時に有効な手法である. そこで本研究では, MAS での再現シミュレーションを BlackBox 関数とし, シミュレーション結果を $\hat{Y} = f(X)$ として表すことにより, ベイズ最適化の枠組みを適用して最適な入力パラメータ X を求める.

ベイズ最適化は推定するパラメータ空間に対して $f(X)$ が確率的に連続であることを仮定しており, その確率モデルをガウス過程近似 [Rasmussen 06] を用いて推定する手法である. しかしながら, パラメータ空間に対して BlackBox 関数の結果が不連続であったり, 推定空間が高次元になると解くことが難しくなる [Kandasamy 15, Wang 16] という課題がある. そこで提案手法では, パラメータの探索空間を時間帯 t ごとに行い $X_t (= \{x_r\}_t \in \mathbb{N}^R)$ の推定問題を解く.

ナイーブに解く方法では, 図7のように時間帯ごとに最適化を行い, 時刻 t でのパラメータ X_t の探索に対して





図7 観測の時間遅れ例と, ナイーブな方法と提案手法 (MTW-BO) の概要

の損失関数 $L(\cdot)$ も, 時刻 t での観測値 Y_t とシミュレーションによる再現結果 $\hat{Y}_t = f(X_t)$ との誤差で与えられ, 以下で表される,

$$X_t^* = \arg \min_{X_t} L(Y_t, f(X_t)). \quad (6)$$

しかしながら混雑時や広域での経路を扱う時, エージェントの挙動は単一の時間帯に観測されないケースがある. 図7のように, 10分ごとに時間帯を設定した場合, 10分以上かけて移動した場合にはそれぞれの観測点では異なる時間帯にて観測される. そのため, f をシミュレーション結果による関数とみなすと, $\hat{Y}_t = f(X_t)$ では表すことができない. つまり, 時刻 t で観測された人々 $\hat{Y}_t$ は, 数時刻前 (ここでは ω とする) より観測領域内にい

ることを考慮し,

$$\hat{Y}_t = f(\{X_{t'}\}_{t'=t-\omega}^t) \quad (7)$$

とする必要がある. つまり, MAS 上では時刻 t で観測される人々 $\hat{Y}_t$ は, 時刻 $t-\omega$ から時刻 t までに発生するエージェント $\{X_{t'}\}_{t'=t-\omega}^t$ の影響を考慮する.

一方, 時刻 t に発生するエージェント X_t は, 観測地点においては時刻 $t+\omega$ まで観測され続けることを考慮すると, 最適化させる X_t^* は,

$$X_t^* = \arg \min_{X_t} L(\{Y_{t'}, \hat{Y}_{t'}\}_{t'=t}^{t+\omega}) \quad (8)$$

となる. 式 (7) および式 (8) を合わせて, 下記のように表現することができる,

$$X_t^* = \arg \min_{X_t} \sum_{t'=t}^{t+\omega} L(Y_{t'}, f(X_{t'-\omega}, \dots, X_{t'})) . \quad (9)$$

時間帯 t に対して逐次的に X_t^* を求め, さらに前反復時の最適解を再利用して複数回繰り返すことにより, 精度の高い, つまり再現度の高い推定値 X が得られる.

ここで, 評価値には下記の正規化平均誤差 (Normalized Averaged Error : NAE) を用いた,

$$NAE = \frac{\sum_i^I \sum_t^T |y_{it} - \hat{y}_{it}|}{\sum_i^I \sum_t^T y_{it}} . \quad (10)$$

式 (9) で最小化させる損失関数を $L_\omega(t)$ とすると, 時刻 t から $t+\omega$ における正規化平均誤差とし以下となる,

$$\begin{aligned} L_t^\omega(t) &= \sum_{t'}^{t+\omega} [L(Y_{t'}, f(X_{t'-\omega}, \dots, X_{t'}))] \\ &= \frac{\sum_i^I \sum_{t'=t}^{t+\omega} |y_{it'} - \hat{y}_{it'}|}{\sum_i^I \sum_{t'=t}^{t+\omega} y_{it'}} . \end{aligned} \quad (11)$$

各時間帯における最適化には, まず初期値として M 個のランダムサンプリング $\{X_t^{(m)} | m = 1, \dots, M\}$ を行い, M 個の MAS を走らせ, シミュレーション結果を元にカーネル関数を推定する. ここで本研究ではガウス過程 [Rasmussen 06] を用いて $f(x)$ を推定した. 次に, カーネル関数 $f(X)$ と損失関数 L を元に獲得関数を計算し, 逐次的に次の最良とする初期値 $X_t^{(n)}$ を求める. ここで本研究では, 獲得関数には EI (Expected Improvement) [Bull 11, Mockus 12, Vazquez 10] を用いた.

最適化の処理としては, この式 (9) の最適化を, 逐次的に $t = 0 \sim T$ 行っていく. しかしながら時刻 t の最適化時には, $t+1 \sim t+\omega$ までの値は最適値が得られていないために, 繰り返し反復処理 (Cycle) を行う必要がある. 本実験では 10 回以内で値が収束することがわかり, 一律 $C = 10$ とした. ここでアルゴリズムを, Algorithm 1 に示した. $\text{Sampling}\{X\}$ は X の取りうる空間からのランダムサンプリングを表す.

Algorithm 1 MTW-BO

Input:

$C \in \mathbb{N}^+$: 反復回数;
 $T \in \mathbb{N}^+$: 分析時間幅;
 $M \in \mathbb{N}^+$: 初期ランダムサンプル数;
 $N \in \mathbb{N}^+$: 最適化繰り返し回数;
 $\omega \in \mathbb{N}^+$: 遅延考慮幅;

```

1: Sampling  $\{X_t^* | t = 1, \dots, T\}$ 
2: for  $c = 1$  to  $C$  do
3:   for  $t = 1$  to  $T$  do
4:      $D_t = \emptyset$ 
5:     for  $m = 1$  to  $M$  do
6:       Sampling  $\{X_t^{(m)}\}$ 
7:        $\hat{Y}_{t'}^{(m)} = f(X_{t'-\omega}^{(m)}, \dots, X_t^{(m)}, \dots, X_{t'+\omega}^{(m)})$ 
8:        $D_t = D_t \cup X_t^{(m)}$ 
9:     end for
10:    for  $n = M + 1$  to  $M + N$  do
11:       $X_t^{(n)} = \text{argmax}_{X_t} \alpha(x_t; D_t)$ 
12:      Select  $X_t^{(n)}$  by MTWBO
13:       $\hat{Y}_{t'}^{(n)} = f(X_{t'-\omega}^{(n)}, \dots, X_t^{(n)}, \dots, X_{t'+\omega}^{(n)})$ 
14:       $D_t = D_t \cup X_t^{(n)}$ 
15:    end for
16:     $X_t^* \leftarrow \text{argmin}_{X_t \in D_t} L_\omega(X_t)$ 
17:  end for
18: end for
  
```

3.2 Multi Agent Simulation (MAS)

本研究では, 印南ら [印南 12] の提案したネットワーク歩行型のマルチエージェントモデルをベースに, 独自に開発した MAS を用いた. C 言語にて動作し, 数万人規模のエージェントを, 1sec/1step として 10,000Step を数分程度で動かすことが可能である. 各エージェントは, 印南らと同様に, 一次元の歩行路ネットワーク上を前方の密度を元に歩行速度を与えて動く, ネットワークマルチエージェントシミュレーションを実施, 各エージェントは進行方向に対して混雑度合いを観測することが可能であり, 混雑の度合いにより, 歩行モデルに従い歩行速度を変更する. 速度決定関数も印南らのモデルと同様なものを利用した. 定常時 (密度 $\rho < \rho_c$) には一定の歩行速度 $v = v_{\max}$ [m/sec] で動き, 混雑時では歩行速度は $v = 1.8/\rho - 0.3$ に従い, 異常混雑時 (密度 $\rho > 6$ [人/m²]) では歩行速度が 0 になる. 各エージェントは歩行速度の上限 $v_{\max}$ を, 対数正規分布を用いて $\ln \mathcal{N}(1.2[\text{m/sec}], 0.12)$ で与えた. 混雑の閾値となる ρ_c は各エージェントによって異なり, $\rho_c = 1.8/(v_{\max} + 0.3)$ [人/m²] で与えられ, 混雑してくると ρ_c に反比例して速度が遅くなる. まとめる

と下記のとおりである,

$$v = \begin{cases} v_{\max} & (\rho_c > \rho \geq 0) \\ 1.8/\rho - 0.3 & (6 > \rho \geq \rho_c) \\ 0.0 & (\rho \geq 6). \end{cases} \quad (12)$$

エージェントのアニメーションには OpenGL を用いており、リアルタイムに視点変更が可能な、立体描画を実現している。加えて、道路の通行止めや、一方通行化などの交通状況をインタラクティブに変えることができる。各エージェントは交差点到達時に、混雑状況を加味した重み付き最短経路探索により、常にオンラインで経路を再探索し続けている。そのため、交通状況をリアルタイムに反映してエージェントが目的地に向かうことができる。さらにタッチパネルモニタ対応にすることにより、各歩行路をタッチすることによって { 通常, 片側通行, 逆片側通行, 通行止め } の切り替えが可能であり、例えば警備計画立案事業者による複数人同時で警備計画の検証議論が可能となっている。

道路ネットワークはインクリメント P 社の歩行者ネットワークデータを用いて、三次元のポリゴン画像はゼンリン社の 3D 都市モデルデータ (©2017 ZENRIN CO. LTD) を利用し、ポリゴンテクスチャ画像の半透明化などを行い、人の流れの可視化を可能としている。ここで MAS の動作画面を図 8 に示す。

3.3 精度検証実験

2 章でも述べた通り、観測は 1 分おきに行ったため時間窓の幅を 1 分とする。観測箇所 $I = 26$ 、経路数 $R = 30$ とし、観測時刻は 18:00 ~ 21:20 の 200 分間 ($T = 200$) とする。また、提案手法における時間遅れ項 ω は、各経路の平均通過時間 (図 10 参照) から $\omega = 5$ とした。

本イベントでは、図 3 の通り観覧場所が 3 か所設けられており、人々は観覧エリアで観覧のために滞留することから、同化対象のエリアを 4 分割した (図 9 参照)。これは、滞在時間をハイパーパラメータとして最適化を実施した場合、解に一意性がないことで探索次元が増えてしまうことにより推定が困難であるためである。次にエリアごとにルートを策定し、15 双方向で合計 30 のルートを用意した。最終的に、エリアごとに分断したエージェントを FIFO (First In, First Out) で繋ぎ、観覧時間を逆算して与え、再現シミュレーションを実施した。

また対比手法として、ハイパーパラメータ探索に広く用いられている遺伝的アルゴリズムを利用した (Genetic Algorithm: GA) [Bera 15, Holland 92]。遺伝的アルゴリズムには主に 5 個のパラメータ { 交叉確率, 突然変異確率, 変異割合, 世代数, 個体数 } を持ち、パラメータのグリッドサーチにより、各時間窓 t における最適化に対して、**交叉確率 = 0.95, 突然変異確率 = 0.02, 変異割合 = 0.5, 世代数 = 144, および個体数 = 10** とした。遺伝的アルゴリズムにおいても、3.1 節で示した時間遅れ項を考慮し




図 8 MAS の動作画面。上図は全体俯瞰、下図はイベント終了直後のイーストデッキにズームインした様子。

た目的関数 L (式 (9) 参照) を用いて、ベイズ最適化と同様に $C = 10, \omega = 5$ とした。なお提案手法では、初期のランダムサンプリング ($M = 60$) による MAS の計算は並列処理を行い、MTWBO による最適化探索 ($N = 60$) は逐次処理を実施。一方 GA では、個体数に対しては常に並列処理が可能であり、個体数 (10) の並列処理を行い、世代数 (144) だけ繰り返し最適化探索の処理を実施。全体の CPU 時間は、2CPU の Xeon E5-2670 (2.6GHz/16 コア/32 スレッド) において、提案手法 (MTWBO) は平均 10 時間、GA は平均 60 時間かかった。

精度評価の結果を図 11 に示す。エリアごとによって通過人数が異なるため、棒グラフの線の太さで総通過人数 ($\sum_i^I \sum_t^T y_{it}$) の比を表し、ALL は各棒グラフの面積の和に相当する。GA では全てのエリアで NAE が 0.4 を上回り、全体でも平均 0.504 (最小 0.496, 最大 0.518) の精度であるのに対し、提案手法は全てのエリアで NAE が 0.3 を下回り、全体でも平均 0.136 (最小 0.132, 最大 0.143) と高い精度を示していることがわかる。

観測点が 1 か所であるエリア 2 において、NAE = 0.115 の推定誤差が生じる理由は、時間窓内の時間帯でエージェントのスタート時刻を乱数生成するためである。つまり、1 分の時間窓に対してエリア 2 での推定経路⑦ではエー




図9 分割した四つのエリアと推定経路




図10 各経路ごとの平均所要時間

ジェントが 15 秒ほどで通過するため、人数が少ないエリアでは必ず誤差が 10% ほど発生する。これは時間窓を更に粒度を下げることによって精度を向上させることが可能であるが、探索空間の次元が大きくなり、計算時間が膨大になってしまうことから現実的ではない。一方で、エリア 1 やエリア 3 でも同程度の推定ができていることは、提案手法によるシミュレーション上での経路推定精度は十分高いことを示している。

また我々は、2 万人ほどの大規模音楽イベントでも同様な計測を行い、歩行速度などの詳細分析も実施した [田中 19]。その結果、主催者発表の来場者数と手動計測による誤差は 10% 程度であることを確認した。そのため再現精度 13.6% は十分限界近くの推定精度に到達していることがわかる。加えて我々は、提案手法を利用した精度評価も実施 [Kiyotake 18] し、GA やナイーブ手法による BO ($\omega = 0$) とも比較検証を行った。三つの大きなイベントにおいて、いずれも十数%の誤差に抑えることを達成し、提案手法が頑健かつ高精度であることを示して




図11 提案手法 (MTW-BO) と GA の精度評価結果。

いる。

4. 再現と What-If 分析

YOYOGI CANDLE 2020 は、10 月 28 日と 11 月 29 日の二日にわたり開催を実施した。第 1 章でも述べたが、明石歩道橋の雑踏事故以来、イベント主催者は警備会社と議論を行い、安全にイベントを運営することに注力している。そこで本イベントでも、事前に MAS を用いた模擬シミュレーションにより、警備計画の議論を行ってイベントに挑んだ。

(i) 実際のイベントでの取り組み

イベントの終了後には新宿駅に向かう人が多かった。メインの観覧場所であるイーストデッキから駅に向かう歩行路は主に二つあり、西側のサザンテラスを通り抜ける歩行路と、東側のショッピングセンタの前を通る歩行路である。ショッピングセンタの前は他の歩行通路と比較しても幅員が狭小になっているため、実際の誘導計画としては、イベント終了後にイーストデッキでの観覧者に対し、新宿駅に向かう人にはショッピングセンタ方面ではなく、西側のサザンテラスを経由して帰宅していただくようにアナウンスを実施した。その結果、データ分析からも観覧終了後はサザンテラスから新宿駅新南口方面に向かう人が多いことが分かった (図 12)。

(ii) 警戒すべき想定シナリオ

イーストデッキの警備にはもう一つ重要な点がある。それは、デッキの西側は階段になっており、雑踏事故の危険性を警戒する必要がある。そのため本イベントでは、イーストデッキの観覧エリアには一定数以上の観覧者が入らないように制限を行っていた。

しかしながらイベントの警備計画準備には、人数制限や、危険回避はもとより、有事の際の対処の事前計画を立てておかなければならない。例えば、人数制限をしていたにもかかわらず雑踏事故などの事故が起き、観覧場所の西側階段付近を通行止めにせざるを得なくなったケースを考える (図 13)。

(iii) シミュレーションによる検証と課題抽出

この場合、駅に向かう人たちはショッピングセンタ前のデッキを通ろうとする。また、西側から夕方ショッピングセンタや駅の東口へ向かおうとしていた人々は、駅の南口広場を経由して東側に渡ろうとする。すると、MAS 上でのシミュレーション結果では、ショッピングセンタ前のデッキは狭くなっていることもあり、新宿駅に向かおうとする人々との対向流により混雑することが分かる(図 14)。

(iv) シミュレーションによる誘導作策定

この時に、観覧者を直接駅に向かわせずに、ショッピングセンタから広い国道側に迂回するように誘導することを仮定し、ショッピングセンタ前のデッキを一方通行にする。すると、しばらくして混雑が解消することが観測される(図 15)。

このような What-If 分析は、データ同化により、人々の経路(目的地)推定が実現されていればこそ、様々なシチュエーションを MAS 上での検証が可能となる。

5. ま と め

本研究では、実イベントの観測データを元に、観測された人々の通過人数から、「いつ、どこから、どこへ」人々が流れてゆくのか? という推定問題に対するデータ同化技術の紹介を行った。実イベントからの推定結果を用いて、シミュレーションによるエージェントの流量を $NAE \approx 0.136$ の誤差での再現を可能とした。人々の目的地を把握し、推定することによって、「もしこの道路が封鎖されたら?」という仮定のシミュレーションを実現可能とし、様々なシチュエーションでの What-If 分析が可能となる。

現実的なイベントでは、時間帯(終了間際や定常時)や、属性(居住国や性別)によって人の歩行モデルは異なり、イベントに対する挙動は大きく異なってくる。そのため、スマートフォンアプリなどを用いて属性情報を一部でも取得することができれば、属性情報を用いた半教師あり学習などを用いたデータ同化技術などが可能になると考えられる。本研究では、大域的な最適解導出技術としてベイズ最適化を用いたデータ同化技術を提案したが、将来的には人の属性なども加味し、局所的に起きる非線形現象な挙動にも重点を置いた研究を進めたいと考えている。

安全対策には様々な考察を行う必要があり、事故を想定した誘導策も、道路拡張や、通行止め、迂回路指示など、様々な組み合わせを考えなければならない。我々の学習型誘導技術では、最適化技術を用いた最適誘導探索技術の研究開発も進めている。




図 12 実際のイベントでは観覧者にはサザンテラスを通り駅に向かうように誘導。




図 13 イーストデッキ西側には階段があり、警備上最も警戒していた。そこで、万一の事故で通行止めにするを仮定する。




図 14 シミュレーションによれば、駅に向かう人と東へ渡ろうとする人たちの対向流により混雑発生が起きる。




図 15 一方通行化することによって混雑解消が可能。

謝 辞

NTTドコモの小田哲氏と岡田佳之氏の両氏は YOYOGI CANDLE 2020 のイベント開催を先導され、警備計画議論に加え分析議論にも参画していただき、非常に多くの有益なコメントを頂きました。心より感謝いたします。

◇ 参 考 文 献 ◇

- [明石市 01] 明石市民夏まつり事故調査委員会: “第 32 回明石市民夏まつりにおける花火大会事故調査報告書”, 明石市民夏まつり事故調査報告書 <https://www.city.akashi.lg.jp/ansen/anशन/bosai/kikikanri/jikochosa/> (2002)
- [Bera 15] Bera, A., Kim, S., and Manocha, D.: “Efficient trajectory extraction and parameter learning for data-driven crowd simulation”, In: Proceedings of the 41st Graphics Interface Conference, pp. 65–72. Canadian Information Processing Society (2015)
- [Bull 11] Bull, A.D.: “Convergence rates of efficient global optimization algorithms”, Journal of Machine Learning Research, Vol.12 No. Oct, pp. 2879–2904 (2011)
- [Castle 11] Castle, C., Waterson, N., Pellissier, E., and Le Bail, S.: “A comparison of grid-based and continuous space pedestrian modelling software: Analysis of two uk train stations”, In: Pedestrian and Evacuation Dynamics, pp. 433–446, Springer (2011)
- [Holland 92] Holland, J. H.: “Genetic algorithms”, Scientific American, Vol.267, No.1, pp. 66–73 (1992).
- [印南 12] 印南 潤二, 正垣 隆祥, 笈 文彦, 福井 潔, 山田 武志: “群集シミュレーション手法を活用した大規模ターミナル駅周辺の避難誘導情報の施策検討”, 土木計画学研究・講演集, Vol.45, pp. 1–8 (2012)
- [犬飼 05] 犬飼 洋平, 小国 健二, 堀 宗朗: “計測に基づく避難行動マルチエージェントシミュレータの開発”. 応用力学論文集, Vol. 8, pp. 629–636 (2005)
- [兵庫県 02] 兵庫県警察: “雑踏警備の手引き – 第 4 章 雑踏警備の計画から実施まで –”. <https://www.police.pref.hyogo.lg.jp/zattou/> (2002)
- [Kandasamy 15] Kandasamy, K., Schneider, J., and Póczos, B.: “High dimensional Bayesian optimisation and bandits via additive models”, In: International Conference on Machine Learning, pp. 295–304 (2015)
- [川口 15] 川口 英俊, 野田 五十樹: “人流シミュレーションにおける複数の評価基準を考慮した時間別 od 表の推定”, 人工知能学会第 29 回全国大会論文集, Vol. 29, pp. 1–4 (2015)
- [Kiyotake 18] Kiyotake, H., Kohjima, M., Matsubayashi, T., and Toda, H.: “Multi agent flow estimation based on Bayesian optimization with time delay and low dimensional parameter conversion”, In: International Conference on Principles and Practice of Multi-Agent Systems, pp. 53–69, Springer, Cham (2018)
- [Mockus 12] Mockus, J.: “Bayesian approach to global optimization: theory and applications”, Vol. 37, Springer Science & Business Media (2012)
- [室崎 02] 室崎 益輝: “明石花火大会における群集雪崩”, 予防時報, 日本損害保険協会, Vol. 208, pp. 8–13 (2002)
- [納谷 17] 納谷 太, 宮本 勝, 上田 修功: “時空間多次元集合データ解析技術による集団最適誘導”, 電気通信協会, NTT 技術ジャーナル, Vol. 29, No.7, pp. 24–28 (2017)
- [大西 15] 大西 正輝, 山下 倫央, 星川 哲也, 佐藤 和人: “人の流れの計測とシミュレーションによる避難誘導方法の伝承”, 人工知能学会研究会資料, SIG-KST-026-06 (2015)
- [Rasmussen 06] Rasmussen, C.E., Williams, C.K.: “Gaussian process for machine learning”, MIT Press (2006)
- [重中 18] 重中 秀介, 大西 正輝, 山下 倫央, 野田 五十樹: “データ同化を用いた大規模人流推定手法”, 電子情報通信学会論文誌, Vol.J101-D, No.9, pp. 1286–1294 (2018)
- [Snoek 12] Snoek, J., Larochelle, H., and Adams, R.P.: “Practical Bayesian optimization of machine learning algorithms”, In: Advances in Neural Information Processing Systems, pp. 2951–2959 (2012)
- [田中 19] 田中 悠介, 大井 伸哉, 唐 恒進, 松林 達史, 宮本 勝: “大

規模イベントにおける歩行者モデルの設計と評価”, WSSIT2019 Workshop of Social System and Information Technology (WSSIT19) (2019)

- [東京都 1] 東京都オリンピックパラリンピック準備局: “東京 2020 オリンピック・パラリンピック競技大会フォローアップ計画書 (新国立競技場 (オリンピックスタジアム))”, https://www.2020games.metro.tokyo.jp/followupkeikaku_olympicstadium_all.pdf. (2016)
- [東京都 2] 東京 2020 大会開催基本計画: <https://tokyo2020.org/jp/games/plan/> (2015)
- [Vazquez 10] Vazquez, E., Bect, J.: “Convergence properties of the expected improvement algorithm with fixed mean and covariance functions”, Journal of Statistical Planning and Inference, Vol.140, No.11, pp. 3088–3095 (2010)
- [Wang 16] Wang, Z., Hutter, F., Zoghi, M., Matheson, D., and de Freitas, N.: “Bayesian optimization in a billion dimensions via random embeddings”, Journal of Artificial Intelligence Research, Vol.55, pp. 361–387 (2016)
- [山下 12] 山下 倫央, 副田 俊介, 大西 正輝, 依田 育士, 野田 五十樹: “一次元歩行者モデルを用いた高速避難シミュレータの開発とその応用”, 情報処理学会論文誌, Vol. 53, No. 7, pp. 1732–1744 (2012)
- [Yamashita 13] Yamashita, T., Okada, T., and Noda, I.: “Implementation of simulation environment for exhaustive analysis of huge-scale pedestrian flow”, SICE Journal of Control, Measurement, and System Integration, Vol. 6, No. 2, pp. 137–146 (2013)
- [山下 14a] 山下 倫央, 野田 五十樹: “屋外大規模イベントにおける群集規制モデルの構築”, 人工知能学会第 28 回全国大会論文集, Vol.28 (2014)
- [山下 14b] 山下 倫央, 大西 正輝: “オリンピックにおける人の流れの解析”, オリンピックのための情報処理 特集, 情報処理学会誌, Vol.55, No.11, pp.1189–1195, (2014)
- [Yamashita 14] Yamashita, T., Matsushima, H., and Noda, I.: “Exhaustive analysis with a pedestrian simulation environment for assistant of evacuation planning”, Transportation Research Procedia, Vol.2, pp. 264–272 (2014)
- [Zhou 15] Zhou, B., Tang, X., and Wang, X.: “Learning collective crowd behaviors with dynamic pedestrian-agents”, International Journal of Computer Vision, Vol.111, Issue 1, pp. 50–68 (2015)

[担当委員: 服部 宏充]

2019 年 1 月 7 日 受理

—— 著 者 紹 介 ——

松林 達史



2000 年 京都大学理学部物理学科卒業。2002 年 10 月より 2 年半 理化学研究所非常勤研究員。2005 年 東京工業大学大学院理工学研究科地球惑星科学専攻博士課程修了。同年、日本電信電話株式会社入社。以来、NTT コミュニケーション科学基礎研究所、NTT サービスエボリューション研究所にて、グラフ可視化および機械学習の研究開発に従事。博士 (理学)。情報処理学会会員。

清武 寛



2013 年 九州大学理学部数学科卒業。2015 年 同大学院数理学府数理学専攻修士課程修了。同年、日本電信電話株式会社入社。以来、NTT サービスエボリューション研究所にて、MAS を用いた最適化手法の研究に従事。現在、NTT 国際通信株式会社に所属。



幸島 匡宏

2009 年 東京工業大学工学部情報工学科卒業。2012 年 同大学院総合理工学研究科知能システム科学専攻修士課程修了。2019 年 同大学情報理工学院数理・計算科学系博士課程修了。博士 (理学)。2012 年 日本電信電話株式会社入社。以来 NTT サービスエボリューション研究所にて、機械学習の研究に従事。



戸田 浩之

1997 年 名古屋大学工学部材料プロセス工学科卒業。1999 年 同大学院工学研究科材料プロセス工学専攻博士課程前期課程修了。同年、日本電信電話株式会社入社。2007 年筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻博士後期課程修了。博士 (工学)。情報検索、データマイニングの研究に従事。現在、NTT サービスエボリューション研究所主幹研究員。電子情報通信学会、情報処理学会、日本データベース学会、ACM 各会員。



田中 悠介

2006 年 京都大学工学部電気電子システム科卒業。2008 年 同大学院情報学研究科修士課程修了。同年、西日本電信電話株式会社入社。2015 年より 日本電信電話株式会社に転籍。以来、人流計測・予測技術の研究に従事。2019 年 7 月より 西日本電信電話株式会社に転籍。



六藤 雄一

1998 年 東北大学工学部 電気情報物理工学科卒業。2000 年 同大学院情報科学研究科修士課程修了。同年、日本電信電話株式会社入社。NTT サービスエボリューション研究所にて、人流計測・予測技術の研究開発に従事。現在、エヌ・ティ・ティ・プロードバンドプラットフォーム株式会社。



塩原 寿子

1990 年 大阪大学理学部物理学科卒業。1992 年 同大学院理学研究科博士前期課程修了。同年、日本電信電話株式会社入社。以来、データ可視化やデータマイニングなどの研究開発に従事。現在、NTT アドバンステクノロジー社。情報処理学会 会員。



宮本 勝

1995 年 早稲田大学理工学部経営システム工学科卒業。1997 年 同大学院理工学研究科経営システム工学科修士課程修了。同年、日本電信電話株式会社入社。NTT ヒューマンインタフェース研究所、NTT 研究企画部門、NTT サービスエボリューション研究所にて、ユーザエクスペリエンス、データサイエンスに関する研究開発及びプロデュース活動に従事。電子情報通信学会 会員。



清水 仁(正会員)

2001 年 東京大学工学部化学生命工学科卒業。2004 年 奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。同年、西日本電信電話株式会社入社。2006 年より 3 年間 NTT ネットワークサービスシステム研究所、2014 年より NTT コミュニケーション科学基礎研究所にて、機械学習および人流分析の研究開発に従事。電子情報通信学会 会員。




大塚 琢馬(正会員)

2009 年 京都大学工学部情報学科卒業。2011 年 同大学院情報学研究科知能情報学専攻修士課程修了。2014 年 同専攻博士課程修了。同年、日本電信電話株式会社入社。以来、NTT コミュニケーション科学基礎研究所にて、機械学習等の研究に従事。博士 (情報学)。IEEE 会員。



岩田 具治

2001 年 慶應義塾大学環境情報学部卒業。2003 年 東京大学大学院総合文化研究科修士課程修了。同年、日本電信電話株式会社入社。2008 年 京都大学大学院情報学研究科博士課程修了。博士 (情報学)。2012 年から 2013 年にかけて、ケンブリッジ大学客員研究員。現在、NTT コミュニケーション科学基礎研究所特別研究員。データマイニング、機械学習の研究に従事。2014 年長尾真記念特別賞等受賞。情報処理学会、電子情報通信学会各会員。



澤田 宏

1991 年 京都大学工学部情報工学科卒業。1993 年 同大学院工学研究科情報工学専攻修士課程修了。2001 年博士 (情報学、京都大学)。1993 年 日本電信電話株式会社入社。以来、VLSI 設計技術、計算機アーキテクチャ、信号処理、機械学習の研究に従事。現在、NTT コミュニケーション科学基礎研究所協創情報研究部部長。IEEE Fellow、電子情報通信学会フェロー、日本音響学会会員。



納谷 太

1992 年 慶應義塾大学理工学部電気工学科卒業。1994 年 同大学院理工学研究科計算機科学専攻修士課程修了。同年、日本電信電話株式会社入社。2003 年より 6 年間 ATR メディア情報科学研究所、同知識科学研究所出向。コミュニケーションロボット、パターン認識、センサネットワークによる実世界センシングおよびデータマイニング等の研究に従事。現在、NTT コミュニケーション科学基礎研究所企画担当 主席研究員。博士 (工学)。電子情報通信学会、計測自動制御学会、IEEE 各会員。



上田 修功

1982 年 大阪大学工学部通信工学科卒業。1984 年 同大学院工学研究科通信工学専攻修士課程修了。同年、日本電信電話公社 (現 NTT) 横須賀電気通信研究所入所。以来、コンピュータビジョン、パターン認識、統計的学習、データマイニング等の研究に従事。1993-2004 年米国 Purdue 大学客員研究員。現在、日本電信電話株式会社 NTT コミュニケーション科学基礎研究所 上田特別研究室 (NTT フェロー) 機械学習・データ科学センタ長、科学技術振興機構 (JST) 数理的活用基盤 CREST 研究総括、京都大学大学院情報学研究科 連携教授、神戸大学大学院システム情報学研究科情報科学専攻 知能統合講座 客員教授、理化学研究所 革新知能統合研究センター 副センター長。電子情報通信学会 (フェロー)、情報処理学会、IEEE 各会員。