

# 時空間確率モデルに基づく移動ロボット制御のための 障害物位置推定・予測手法

大下 裕一<sup>†</sup> 安田 真也<sup>‡</sup> 熊谷 太一<sup>‡</sup> 吉田 裕志<sup>‡</sup> 金友 大<sup>‡</sup> 村田 正幸<sup>†</sup>

<sup>†</sup> 大阪大学 大学院情報科学研究科 〒565-0871 大阪府吹田市山田丘 1-5

<sup>‡</sup> NEC システムプラットフォーム研究所 〒211-8666 神奈川県川崎市中原区下沼部 1753

E-mail: <sup>†</sup> {y-ohsita, murata}@ist.osaka-u.ac.jp,

<sup>‡</sup> {shinya-yasuda@, t\_kumagai@, yoshida@, d-kanetomo@}nec.com

**あらまし** 移動ロボットは障害物との衝突を避けながら、要求されたタスクを行うような制御をする必要がある。しかしながら、移動ロボットの作業領域内には、他のロボットや人といった移動する障害物も存在する。そのような障害物との衝突をさけつつ、効率的な制御を行うためには、各時刻の障害物の位置を予測することが重要である。

ただし、将来の障害物の位置は、正確に予測できるとは限らない。そのため、我々は、将来の障害物の位置を、確率として把握し、それにより、障害物が存在する時空間上の領域を避けるような移動ロボットの制御を実現することを目指している。本稿では、時空間上の各点の障害物の有無の関係を、条件付確率場としてモデル化を行い、逐次、新たに領域内をセンシングして得られた情報をもとに、モデルの更新を行うことにより、時空間上の各領域の障害物が存在する確率を予測する手法について提案する。そして、シミュレーション評価により提案手法の有効性を確認する。

**キーワード** クラウド, ロボット, 制御

## Estimation and prediction of obstacles based-on spatio-temporal random fields for control of moving robots

Yuichi OHSITA<sup>†</sup> Shinya YASUDA<sup>‡</sup> Taichi KUMAGAI<sup>‡</sup> Hiroshi YOSHIDA<sup>‡</sup>  
Dai KANETOMO<sup>‡</sup> and Masayuki MURATA<sup>†</sup>

<sup>†</sup> Graduate School of Information Science and Technology, Osaka University

1-5 Yamadaoka, Suita, Osaka, 565-0871 Japan

<sup>‡</sup> System Platform Research Laboratories, NEC Corporation

1753 Shimonumabe, Nakahara, Kawasaki, Kanagawa, 211-8666 Japan

E-mail: <sup>†</sup> {y-ohsita, murata}@ist.osaka-u.ac.jp,

<sup>‡</sup> {shinya-yasuda@, t\_kumagai@, yoshida@, d-kanetomo@}nec.com

**Abstract** The mobile robot needs to be controlled to perform the required task without collisions with obstacles. However, there are moving obstacles such as other robots and people in the work area of the mobile robot. To avoid control the robot efficiently without collisions with such obstacles and, it is important to predict the position of the obstacles at each time.

However, it is not always possible to accurately predict the position of obstacles. Therefore, we are developing a method to control the mobile robots based on the predicted probability of the existence of obstacles. In this paper, we propose a method to predict the probabilities of the existence of obstacles in each time. In this method, we model the relationship between the presence or absence of obstacles at each area in each time by using a conditional random field. Then we update the model based on the information obtained at each time slot. In this paper, we evaluate the proposed method by simulation.

**Keywords** Cloud, Robot, Control

### 1. はじめに

我々は、環境センサを用いて、ロボットの無線ネットワーク経由での遠隔制御について研究してきた[1,2]。ネットワーク経由でロボットを制御するには、ロボ

ットが動作する際に当該ロボットの周囲における障害物の有無を把握し、当該障害物を回避するような行動をとることが必要となる。ただし、この障害物は、常に当該地点に存在するとは限らず、人や他のロボット

等の移動体であることも考えられる。そのため、各時刻によって変わる各地点における障害物の有無を把握することがロボットの制御において必要となる。障害物の有無の把握のためには、ロボットが動作する範囲をカメラ等の環境センサで観測することに加え、ロボットに取り付けた LiDAR 等のセンサからの情報を用いることが有用である。しかしながら、(1)カメラ、LiDAR 等のいずれのセンサにおいても、死角が生じてしまい、障害物の有無が把握できない地点ができてしまう、(2)必要なのは、センシングされた時点の障害物の情報ではなく、ロボットが動作する際の障害物の情報であり、センサ情報をネットワーク経由でコントローラに集約し、制御方法を計算、ネットワーク経由で制御を行うことを考えると、センサ情報が得られた時点よりも将来の情報が必要となるという問題点がある。この問題を解決するために、本研究では、制御対象エリアの各時刻、各地点における障害物の有無を確率としてとらえる。そして、観測された情報をもとに、センサの死角にあたり、観測されなかった地点の障害物の有無や、センサの観測結果が得られた地点から将来の地点における各地点の障害物の有無を確率として推定する。この確率の推定を行う際には、空間的に隣接する位置における観測結果が有用となると考えられる。例えば、観測エリアを障害物の有無を判別する各地点に分割する際に、障害物のサイズよりも小さなサイズに分割した場合を考えると、周囲の観測結果のいずれも障害物がないと観測された地点においては、障害物が存在する確率は低いと推定することができる。同様に、時間的に前後において観測された障害物の有無の情報を用いることが有用である。これは、移動する障害物においても、前の時刻で障害物が観測された地点から、当該障害物の移動方向に一定の距離以内の地点であれば、障害物がある確率が高いものの、一定以上離れた箇所においては、障害物が存在する確率が低いととらえることができるためである。すなわち、死角や将来の状況の推定のためには、一定時間内に観測された障害物の有無の情報を束ねることにより、障害物の有無が観測されなかった地点における障害物の有無を補完するということができると考えられる。本研究では、このような一定時間内の情報を統合して処理をする手法として、条件付確率場を用いることを検討する。

## 2. 条件付確率場

本研究では、時空間にわたる実世界の確率的表現として、条件付確率場を用いる。条件付確率場[4]は、マルコフ確率場[3]の一種である。そこで、本節では、マルコフ確率場について説明したのちに、条件付確率場の

説明をする。

マルコフ確率場は、確率変数に対応する頂点と、関係性のあるノード間に辺を定義することにより構築された無向グラフィカルモデルである。マルコフ確率場で構築されたグラフを、クリークと呼ばれる完全グラフに分解できる。この各クリークに属するノードは、互いに直接関係する確率変数に対応する。マルコフ確率場では、この各クリーク  $c$  に対して、関数  $f_c(x_c)$  を定義する。これにより、同時確率分布  $p(x)$  は、以下のようにならわすことができる。

$$p(x) = \frac{1}{Z} \exp(-E(x))$$

$$E(x) = \sum_{c \in C} f_c(x_c)$$

ただし  $C$  は、マルコフ確率場に含まれるクリークの集合であり、 $Z$  は正則化項である。

マルコフ確率場では、同時確率分布を最大化する  $x$  の推定は、 $E(x)$  を最小化するような  $x$  を求めることにより達成できる。条件付き確率場は、観測可能な変数  $D$  が得られた際の潜在変数  $X$  の条件付確率分布  $p(X|D)$  をマルコフ確率場で表現したものである。条件付確率場では、以下のように、各クリークに対する関数  $f_c(x_c; D)$  を定めることにより、 $p(X|D)$  を表すことができる。

$$p(X|D) = \frac{1}{Z(D)} \exp(-E(X; D))$$

$$E(X; D) = \sum_{c \in C} f_c(x_c; D)$$

ただし、 $Z(D)$  は正則化項である。

条件付確率場において、マルコフ確率場としてモデル化されているのは、潜在変数の関係性のみであり、観測可能な変数間の関係性は、モデルに含んでいない。そのため、観測可能な変数間の相関関係に影響を受けることなく、潜在変数の推定が可能となる。

条件付確率場において、確率変数  $x_i \in X$  の周辺確率

$$P(x_i|D) = \sum_{x \setminus x_i} P(x|D)$$

を把握することにより、確率変数  $x_i$  が対応する状態について把握することが可能である。条件付確率場では、このような周辺分布の推定は、Loopy BP (Loopy Belief Propagation Algorithm: 確率伝搬法) と呼ばれるアルゴリズムを用いることにより、可能である。

## 3. 時空間確率モデルにもとづく障害物位置推定・予測手法

### 3.1. 時空間確率モデル

本研究で対象とする障害物の有無の推定は、特定の時間帯、特定の場所についての障害物の状況について、観測された情報から推定を行う。すなわち、対象とす




図 1 時空間確率モデルの概要

る時間、空間の範囲を、一定のタイムスロット、一定のエリアで分割し、分割された各エリアの障害物の状況について推定を行う。時空間上のエリア間には、相関関係がある。例えば、各エリアにおける障害物の有無とその種類を判定するような場面を考えると、複数の空間エリアにまたがるような大きさの障害物も考えられるなど、空間的に隣接するエリアは、類似した状況である可能性が高いと考えられる。また、時間方向についても同様であり、時空間上のあるエリアにおいて障害物が存在した場合は、次の時間帯においても、当該エリアと同一箇所か隣接エリアにおいては、当該障害物が存在する可能性は高い。

本研究では、このような時空間上の各エリア間の相関関係も含めて、確率的に表現をするモデルとして、条件付確率場を用いる。図 1 に、時空間にわたる確率変数の条件付確率場での表現を示す。

本表現では、時空間上の各点に対応する確率変数を導入し、当該確率変数に対応する頂点を配置している。また、空間方向には、各頂点について、同一時刻の隣接するエリアに対応するノードとの間に辺を足す。さらに時間方向には、各頂点について、隣接する時間帯の同一エリアや当該障害物が移動する可能性のあるエリアに対応する頂点との間に辺を足す。本モデルにおいては、観測  $D$  が得られた際の変数  $O$  の確率分布  $P(O|D)$  は、以下のように定義する。

$$p(O|D) = \frac{1}{Z(D)} \exp(E(O; D))$$

$$E(O; D) = \sum_{(t,x,y) \in N} f_{x,y}(o_{t,x,y}; d_{t,x,y}) + \sum_{((t_1,x_1,y_1),(t_2,x_2,y_2)) \in E} f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$$

ただし、 $N$  は頂点の集合、 $f_{x,y}(o_{t,x,y}; d_{t,x,y})$  は観測値  $d_{t,x,y}$  によって定義された確率変数  $o_{t,x,y}$  の関数、 $E$  は辺の集合、 $f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$  は確率変数  $o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}$  の関数であり、辺の両端  $(t_1, x_1, y_1), (t_2, x_2, y_2)$  のエリアに対応する観測値  $d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2}$  に応じて定義されるものである。

この時空間上の各エリア間の関係を表した条件付確率場を用いることにより、時空間上の任意の点について、周辺確率分布  $p(O|D)$  を Loopy BP を用いた近似計算に

より求めることができる。本研究では、 $O$  として、障害物の有無だけでなく、障害物が存在する際には、その障害物の移動に関する属性をラベルとして定め、各地点におけるラベルの確率を推定することにより、障害物の移動パターンを推定し、将来の予測に用いる。

### 3.2. 時空間確率モデルに基づく障害物推定

条件付確率場を用いた状況判定に必要な手順は以下のとおりである。

観測： 必要なセンシング情報を収集する

モデル構築： センシング情報をもとに条件付確率場の各頂点、各辺に  $f_{x,y}(o_{t,x,y}; d_{t,x,y})$ 、 $f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$  の関数をあてはめることにより、モデルを構築する

推定： Loopy BP アルゴリズムにより、推定が必要な時空間上の各エリアの状態について、周辺確率を求める。

### 3.3. 時空間確率モデルの学習

本研究では、事前に観測されたデータに基づいて、障害物にラベルの付与、 $f_{x,y}(o_{t,x,y}; d_{t,x,y})$ 、 $f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$  を付与したラベルをもとに学習する。

障害物に対するラベルの付与は、観測されたデータをもとに、障害物の軌跡が類似する障害物をグループとしてまとめ、各グループに対して、ラベルを設定する。その後、 $f_{x,y}(o_{t,x,y}; d_{t,x,y})$ 、 $f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$  を設定する。障害物の移動の傾向は、障害物の種類以外にも場所に依存する。そのため、本研究では、これらの関数を場所に合わせて設計する。

$f_{x,y}(o_{t,x,y}; d_{t,x,y})$  は

$$f_{x,y}(o; d) = \frac{\text{Number}[D_{t,x,y} = d, O_{t,x,y} = o]}{\text{Number}[D_{t,x,y} = d]}$$

ただし、 $D_{t,x,y}$  は学習データ中の時刻  $t$ 、座標  $x, y$  の観測値、 $O_{t,x,y}$  は時刻  $t$ 、座標  $x, y$  のラベルであり、 $\text{Number}[ ]$  は、 $[ ]$  内の条件を満たす学習データの要素数を示す。また、観測値が得られない場合においては、以下のよう定める。

$f_{x,y}(o; \text{None})$

$$= \begin{cases} \alpha & o = \text{障害物無し} \\ (1 - \alpha) \frac{\text{Number}[O_{t,x,y} = o]}{\text{Number}[D_{t,x,y}]} & \text{それ以外} \end{cases}$$

$f_{(x_1,y_1),(t_2,x_2,y_2)}(o_{t_1,x_1,y_1} o_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$  も同様に、

$$f_{(x_1,y_1),(t_2,x_2,y_2)}(o_1 o_2; d_1, d_2) = \frac{[D_{t_1,x_1,y_1} = d_1, D_{t_2,x_2,y_2} = d_2, O_{t_1,x_1,y_1} = o_1, O_{t_2,x_2,y_2} = o_2]}{[D_{t_1,x_1,y_1} = d_1, D_{t_2,x_2,y_2} = d_2]}$$

と定める。また、観測値が得られない場合については、

$$f_{(x1,y1),(t2,x2,y2)}(o1,o2; \text{None}, \text{None}) = \begin{cases} \beta & o1, o2 \text{ ともに障害物無し} \\ \gamma & o2 \text{ のみ障害物無し} \\ (1-\beta-\gamma) \frac{[D_{t1,x1,y1} = d_1, D_{t1+t2,x2,y2} = d_2]}{[D_{t1,x1,y1}, D_{t1+t2,x2,y2}]} & \text{それ以外} \end{cases}$$

と定める。上記のように学習することにより、観測データに基づいた各ラベルの確率、また、領域間の関係を定めることができる。

### 3.4. モデル構築・推定の高速化

時空間確率モデルに基づいた障害物位置の推定・予測手法において、細粒度で分割した広範囲の領域について、モデル構築・推定を行うと、推定を行う領域が膨大となるため、多大な計算時間を要する。一方で、ロボットの制御に用いるためには、状況変化に追従可能な速度で、モデル構築・推定を繰り返すことが求められる。そのため、本研究では、これらの時間を削減するための方針を以下のように定める。

#### 3.4.1. モデル構築・推定対象の限定化

推定対象の領域において、移動障害物が存在する領域は、障害物が存在しない領域よりも狭いと考えられる。また、各障害物は、前の時刻に存在したエリアから障害物の移動可能な速度を超えて、著しく離れたエリアに移動することはない。そのため、モデル構築・推定対象のエリアを、障害物が存在する領域に絞ることにより、計算量を削減することができる。また、モデルに含まれるリンクについても、過去の学習結果において、当該エリア間の関係性を表すデータが存在しない領域については、構築する必要はないため、学習データから2エリア間の関係が定義できる領域に絞ることにより、モデルのサイズを削減可能である。さらに、モデルの更新の際に、観測結果が得られていない領域（死角等や将来の領域）の推定結果が観測された領域の推定結果に影響を与えることは防ぐことにより、推定結果の収束の高速化と精度の向上の両立を図る。

#### 3.4.2. モデルの逐次更新

時空間確率モデルを用いた障害物位置の推定・予測は、新たな観測データが得られる度に、最新の予測結果を得るために、繰り返し行われる。その際、過去の一定タイムスロットから将来までの各時刻の状態を含む時空間確率モデルが構築される。ある時刻の推定・予測に用いられる時空間確率モデルと、前の時刻に用いた時空間確率モデルでは、共通するノード・リンクが多い。そのため、各時刻では、前の時刻の時空間確率モデルをもとに、必要な更新を行うのみとすることにより、各時刻のモデル構築にかかる時間を短縮できる。具体的には、新たな時刻の観測結果が得られる度以下の手順により、時空間確率モデルを更新する。

1. 不要なノードの削除：過去 $N$ タイムスロット以前の現在行う推定に不要な過去のノードや、

新たな観測結果によって、障害物がないことが判明し、障害物の有無や障害物の属性の推定を行う必要がなくなった領域に対応するノードを時空間確率モデルから除去する。

2. ノード・リンクの追加：新たに障害物が観測された時空間上のエリアを起点に、予測を行う対象となる将来 $H$ タイムスロット先までに障害物が移動しうるエリアに対応するノード、リンクを追加する。
3. ノード・リンクの状態の更新：新たな観測結果が得られたノードとリンクに対応する  $f_{x,y}(o_{t,x,y}; d_{t,x,y})$ 、 $f_{(x1,y1),(t2,x2,y2)}(o_{t1,x1,y1}, o_{t1+t2,x2,y2}; d_{t1,x1,y1}, d_{t1+t2,x2,y2})$  を観測結果に合わせて更新する。
4. 確率伝播法による推論処理：更新されたモデルを用いて、各地点の障害物の有無・ラベルを推定・予測する

## 4. 動作確認

本研究では、シミュレーション環境において、移動する障害物を生成、生成した障害物の位置の予測を行い、その計算時間、精度について確認する。なお、本評価においては、時空間確率モデル上の推論は、Direct Graphical Models C++ Library [5] を用いて行った。

### 4.1. 動作確認環境

#### 4.1.1. 障害物の動作

本研究では、図2に示すような $50 \times 50$ エリアの領域内で、幅10の経路が交差している交差点において、大きさ $5 \times 5$ の障害物を生成した。障害物は、上下左右のいずれかから、領域に侵入し、毎タイムスロット1の速度で移動する。交差点に進入するとランダムに移動する向きを変更し、直進をするものとした。

#### 4.1.2. 観測情報の定義

本評価では、各時刻において、各エリアにおける障害物の有無が観測情報として得られるものとした。ただし、障害物の有無の情報のみでは、障害物の移動軌跡を把握するために十分な情報が得られない。そのため、本評価では、各地点における観測情報として、観測情報をもとに、以下のような情報が得られるものとした。

$$o_{t,x,y} = [o^{EXIST}_{t,x,y}, o^{MOVE}_{t,x,y}, o^{LOCATION}_{t,x,y}]$$

ここで、 $o^{EXIST}_{t,x,y}$ は障害物の有無を表すフラグであり、障害物があれば1、なければ0であり、 $o^{MOVE}_{t,x,y}$ は移動方向を表すフラグであり、上下左右、斜めを合わせて8方向に対応する8bitで構成し、1時刻前の該当する方向の1つ前の時刻に障害物があれば、該当ビットを立てる。 $o^{LOCATION}_{t,x,y}$ についても、上下左右、斜めを合わせて8方向に対応する8bitで構成し、当該領域の該当する向きに障害物がなければ1、あれば0を立て




図 2 評価に用いた領域

る。これにより、各エリアについて、障害物の有無のみならず、障害物内の位置（端なのか等）、前の時刻の障害物の位置との関係を含めた情報を与えることができる。

#### 4.1.3. 学習

本評価では、障害物の移動に対するラベルは、移動方向に対して与えるものとした。すなわち、交差点において、障害物が移動の向きを変えた際には、当該障害物に対して与えられるラベルも変化するものとした。学習はランダムに生成した障害物の軌跡 10 回分を学習した上で、学習結果に含まれるパターンと同じパターンで移動する障害物を生成し、その予測結果を調べた。


#### 4.2. 予測結果例

図 3 に予測結果の例を示す。図 3(a)は交差点付近での障害物の位置の予測結果、図 3(b)は直線経路上での障害物の予測結果を示す。いずれも、過去 10 タイムスロットの観測結果を用いて、4 ステップ後の障害物の有無の予測結果であり、障害物が存在する確率が高くなるほど濃い緑であらわす。また、実際の障害物の位置を赤の四角で示している。

図 3 に示されるように、直線移動をする際には、正確に障害物の位置を予測することができ、複数方向への移動が考えられる交差点においては、障害物の移動が考えられる複数方向とも障害物が存在する確率が高くなっている。また、いずれの場合も、時空間確率モデルを用いることにより、将来の障害物が存在するエリアをとらえることができ、リスクを考慮したロボットの制御に活用できる。

#### 4.3. 逐次モデル更新の効果

本研究では、前の時刻のモデルを逐次更新することによる各時刻でのモデル構築にかかる時間を削減しつつ、推定精度を維持する。本節では、その逐次モデル更新の効果について確認する。本評価では、各時刻で、過去 2、5、10 タイムスロット分の観測結果を含む時空間確率モデルを構築し、4 タイムスロット先までの将来



(a) 交差点付近 (b) 直線通路上


図 3 障害物位置予測結果例

の状況を予測する。

まず、逐次モデル更新の場合と、毎回新規に必要なモデルを構築した場合について、予測精度を比較する。本比較では、障害物の存在する確率に対する閾値を 0 から 1 まで 0.01 刻みで変化させ、閾値を超えると障害物が存在するという予測であるとして、障害物があると予測されたにもかかわらず、障害物が存在しなかった領域の割合（False Positive Rate ; FPR）、障害物が存在する領域のうち、障害物が存在すると正しく予測できた割合（True Positive Rate ; TPR）の関係を示した。

図 4 に、逐次モデル更新と毎回新規モデル構築を行った際の 4 タイムスロット先の FPR、TPR の関係を示す。図 4 より、時空間確率モデル構築に含まれるタイムスロット数が短い場合は、特に逐次モデル更新では、予測精度が大きく低下することが分かる。本研究で構築する時空間確率モデルでは、各領域で観測された情報のみではなく、各領域について連続した時間における障害物の移動方向にあるノード間に対して定義された  $f(x_1, y_1, t_1, x_2, y_2) (o_{t_1, x_1, y_1}, o_{t_1+t_2, x_2, y_2}; d_{t_1, x_1, y_1}, d_{t_1+t_2, x_2, y_2})$  を用いて、障害物に対するラベルの推定精度を向上している。時空間確率モデル構築に含まれるタイムスロット数が短いと、このような推定精度の向上に用いることができる情報が少ない。また、逐次推定を行う際には、前の時刻の推定結果を含んだモデルに対して、新たな観測情報に関連するノードの更新を行っている。その場合、過去の情報が足りず、誤ったラベルの推定を行った場合に、その影響が将来にわたり残ってしまうという問題が生じる。しかしながら、推定に用いる過去情報数を十分に確保することにより、このような問題を解消することができる。図 4 より、十分なタイムスロット数の情報を含むことにより、逐次更新の場合も毎回新規にモデル構築した場合と同程度の推定精度を達成可能であることが分かる。

また、図 5 に、逐次更新の場合、毎回新規モデル構築の場合の予測一回あたりにかかる計算時間を比較する。本比較では、Direct Graph Models C++ Library を用いて実装し、Intel(R) Xeon(R) CPU E7-8867 を搭載したコン



(a) 逐次更新 (b) 毎回新規モデル構築  
 図 4 予測精度(4 タイムスロット先)




図 5 推定・予測 1 回あたりの計算時間

コンピュータ上で動作させた。図 5 より、毎回新規モデル構築の場合は、参照する過去のタイムスロット数が大きくなれば、計算時間も長くなっているのに対して、逐次更新の場合は計算時間を抑えたまま、過去の参照タイムスロット数を増やすことが可能である。以上より、時空間確率モデルを用いた障害物の推定においては、十分な過去のタイムスロット数を含むモデルを構築した上で、逐次モデルを更新する方式が有用であると考えられる。

## 5. 大規模環境への適用に向けて

前節での動作確認は、小規模な領域で、領域内に一つの障害物のみがある環境について評価をしている。しかしながら、実際のロボットが動作する環境を想定すると、より大きな領域内で複数の人などの移動する障害物が存在する。本手法は、そのような場合であっても、方式としては対応できるものの、各時刻で更新が必要な領域数、推定を行う時空間確率モデルの大きさともに大きくなり、計算時間が大きな問題となる。一方で、ロボットを制御する際に障害物の有無の推定・予測が必要となる領域は、当該ロボットが移動する周囲の情報のみである。そのため、推定・予測が必要な領域に絞ることにより、ロボット制御に必要な領域を短時間で予測することが可能となる。ただし、将来の障害物の有無を予測する際には、予測対象とした領域外からの障害物の流入も考えられるため、より広範囲の障害物予測結果も踏まえることが必要となる。

そこで、この問題に対しては、より大規模な範囲について状況把握・予測をする高性能なコンピュータ（クラウド等を利用）と実際に必要なロボットの制御を行うエッジの連携により実現することが考えられる。この連携においては、クラウド側では制御領域全体の情報を収集し、時空間確率モデルを更新、推定を行う。一方で、エッジ側では、推定が必要な領域とその周辺領域において、クラウド側での時空間確率モデルと予測結果を取得、自身が新たに取得した制御領域の観測結果を加えてモデルを更新しながら必要な領域の障害物の予測を行う。これにより、高頻度で必要な領域の予測を行いつつ、範囲外の領域から流入する障害物についても考慮をすることができる。このようなエッジ・クラウドの連携については、今後、実装・評価を進める予定である。

## 6. まとめと今後の課題

本稿では、時空間上の各点の障害物の有無の関係を、条件付確率場としてモデル化を行い、逐次、新たに領域内をセンシングして得られた情報をもとに、モデルの更新を行うことにより、時空間上の各領域の障害物が存在する確率を予測する手法について提案し、シミュレーション評価により提案手法の有効性を確認した。ただし、本稿のシミュレーションでは、単純な移動をする障害物のみを用いており、人などのより複雑な移動をする障害物についての評価は今後の課題である。また、本稿では、より大規模な環境への対応として、エッジ・クラウドの連携制御についても議論したが、エッジ・クラウド連携制御の評価も今後の課題である。

## 謝辞

本研究の一部は、NICT 委託研究によるものである。

## 文 献

- [1] 安田真也, 大下裕一, 熊谷太一, 吉田裕志, 里田浩三, 村田正幸, "環境センサーを用いたロボットの無線遠隔制御の実機実験," 電子情報通信学会技術研究報告(IN2018-15), pp. 15-20, Aug. 2018.
- [2] 吉田裕志, 安田真也, 熊谷太一, 大下裕一, 里田浩三, 村田正幸, "通信ネットワークを介した遠隔制御手法と複数ロボットによる協調搬送への応用," 電子情報通信学会技術研究報告(IN2018-55), pp. 19-24, Nov. 2018.
- [3] W. Chaohui, K. Nikos, and P. Nikos, "Markov random field modeling, inference & learning in computer vision & image understanding: A survey," Computer Vision and Image Understanding, vol. 117, pp. 1610-1627, July 2013.
- [4] Y. Bengong and F. Zhaodi, "A comprehensive review of conditional random fields: variants, hybrids and applications," Artificial Intelligence Review, vol. 53, pp. 4289- 4333, Aug. 2020.
- [5] S. Kosov, "Direct graphical models C++ library," 2013.