

特別研究報告

題目

クラウド - エッジ間連携による条件付き確率場を用いた
実世界のリアルタイム推定手法

指導教員

村田 正幸 教授

報告者

木村 一貴

2021年2月9日

大阪大学 基礎工学部 情報科学科

内容梗概

近年、クラウドやエッジなどのサイバー空間でセンサーなどから収集した情報の分析を行い、その結果を実世界へフィードバックすることで社会システムの効率化を目指すサイバーフィジカルシステムが注目を浴びており、自動運転やロボットの制御などへの応用が期待されている。このような高度な制御を実現するにあたり重要な技術の一つが、デジタルツインと呼ばれる技術であるデジタルツインでは、センシングした情報をもとに現実世界を仮想的に複製することにより、現在の状況の把握から将来の予測を行う技術であり、この分析結果をもとに、車両やロボット等の制御を行うことができる。

実世界の状況の把握・推定については、その精度のみならず、リアルタイム性も重要となる。特に、車両やロボットの制御への応用においては、制御を行うタイミングにおいて、その時点の状況を把握することにより的確な制御が可能となる。多量のセンシングデータの分析は、豊富な資源が必要となるため、クラウド側で行われることが想定される。しかし、クラウド側で行ったとしても、多量のセンシングデータの処理には時間がかかる。また、ネットワーク遅延も存在し、さらに、ネットワーク帯域も限られているために、多量のセンシングデータを頻繁にクラウド側に転送することは困難であり、クラウド側でリアルタイムな実世界状況の把握は困難である。一方で、エッジ側は、クラウドのような豊富な計算機資源は持たないため、多量のセンシングデータの分析を行うことはできないが、制御対象に近いため、少ないネットワーク遅延で、かつ、ネットワークの帯域を浪費することなく、センシング情報をリアルタイムに収集することが可能である。

そこで、本報告では、リアルタイムな実世界の状況の推定をクラウド-エッジの連携により行う手法について議論する。本手法では、時空間にわたる実世界の状況を、条件付き確率場として表現し、確率場の更新や、確率場を用いた実世界の推定を行う。自動運転やロボットの制御等の応用を考えると、実世界のリアルタイムな推定は制御に必要な限られた範囲にできればよい。そのため、本報告では、リアルタイムな推定が必要となる範囲を限定することにより豊富な計算機資源をもたないエッジ側でもリアルタイムな推定を実現する。ただし、推定が必要となる範囲を限定した場合でも、当該範囲の状況の正確な推定には時空間上のよ

り広い範囲の情報を利用することが必要となる。そこで、クラウド側においては、自身が持つより広範囲の情報を持ち、時空間上の各範囲の状況を推定し、その推定結果をエッジ側に送ることにより、エッジ側においてもより広い範囲の情報を用いた推定結果を反映した推定を行うことが可能となる。

本方式は、エッジ側で処理を行う必要のある範囲を抑えることにより、リアルタイムな推定を実現するものである。そこで、条件付確率場で表現をする範囲の大きさと推定にかかる時間の関係をカメラからの物体認識を例とした実験により明らかにした。その結果、 25×25 の範囲の処理であれば2秒間隔で、 50×50 の範囲の処理であれば5秒間隔で行うことが可能であることが分かった。

主な用語

デジタルツイン

クラウド - エッジ

マルコフ確率場 (MRF: Markov Random Field)

条件付き確率場 (CRF: Conditional Random Field)

Loopy BP (Loopy Belief Propagation Algorithm: 確率伝播法)

目次

1	はじめに	6
2	条件付確率場	8
3	クラウド - エッジ間連携による条件付き確率場を用いた実世界のリアルタイム推定 手法	11
3.1	時空間確率モデル	11
3.2	クラウド - エッジ間連携による時空間確率モデルの構築・推定	13
4	実験	16
4.1	実験環境	16
4.2	結果	17
5	おわりに	20
	謝辞	21
	参考文献	22

目 次

1	条件付き確率場	9
2	時空間情報の分割	12
3	時刻 t , 座標 (x, y) でのノードおよびリンクの例	13
4	時空間確率モデルの構築・推定のためのクラウド - エッジ間連携の概要	14
5	Loopy BP アルゴリズムの繰り返し回数と次回の周辺確率推定値との差分の 関係	17
6	処理時間	19

表 目 次

1	実行環境	16
2	処理時間	18

1 はじめに

近年、IoT (Internet of Things) の普及によってサーバ上でのデータの収集や分析が容易になり、様々な分野で活用されている。特に、クラウドやエッジなどのサイバー空間でセンサーなどから収集した情報の分析を行い、その結果を実世界へフィードバックすることで社会システムの効率化を目指すサイバーフィジカルシステムが注目を浴びている [1, 2]。例えば、自動運転では自動車に搭載されたカメラやセンサーから周辺の車両や歩行者などの情報を収集し、サイバー空間で分析したうえで自動車の制御を行う [3]。AGV (Automatic Guided Vehicle: 無人搬送車) などのロボットの制御においても、同様に、自身や周囲に配置されたセンサー情報をもとにしたサイバー空間での分析により、ロボットが動作する状況を把握し、制御を行う [4]。

このような高度な制御を実現するにあたり重要な技術の一つが、デジタルツインと呼ばれる技術である [5, 6]。デジタルツインでは、センシングした情報をもとに現実世界を仮想的に複製することにより、現在の状況の把握から将来の予測を行う技術であり、この分析結果をもとに、車両やロボット等の制御を行うことができる。

実世界の状況の把握・推定については、その精度のみならず、リアルタイム性も重要となる。特に、車両やロボットの制御への応用においては、制御を行うタイミングにおいて、その時点の状況を把握することにより的確な制御が可能となる。一方で、多量のセンシングデータの分析は、豊富な資源が必要となるため、クラウド側で行われることが想定される。しかし、クラウド側で行ったとしても、多量のセンシングデータの処理には時間がかかる。また、ネットワーク遅延も存在し、さらに、ネットワーク帯域も限られているために、多量のセンシングデータを頻繁にクラウド側に転送することは困難であり、クラウド側でリアルタイムな実世界状況の把握は困難である。一方で、エッジ側は、クラウドのような豊富な計算機資源は持たないため、多量のセンシングデータの分析を行うことはできないが、制御対象に近いこと、少ないネットワーク遅延で、かつ、ネットワークの帯域を浪費することなく、センシング情報をリアルタイムに収集することが可能である。そこで、本報告では、リアルタイムな実世界の状況の推定をクラウド - エッジの連携により行う手法について議論する。

本報告では時空間にわたる実世界の状況を条件付確率場 [7] として表現する。条件付確率場は、確率変数に対応する頂点と、依存関係のある頂点間に足された辺により構築される確率的なグラフィカル表現の一つであり、観測値を条件として、確率変数の状態の推定に用いられる。本報告では、時空間上の各点に対して頂点を割り当て、時空間上の相関関係のある頂点間に辺を追加することにより、条件付確率場を用いて実世界の時空間モデルを構築する。このように時空間モデルを構築することにより、時空間にわたり観測された情報を統合した高精度な推定が可能となる。

条件付確率場を用いた時空間モデルでは、十分な大きさの時空間上の範囲を観測し、モデルに反映、モデルを用いた推論処理を行うことにより、観測された情報と合致するように実世界の状態を精度よく推定が可能である。しかしながら、推定に用いる時空間モデルが大きくなるほど、必要となる計算資源も大きくなり、また、計算にかかる時間も大きくなる。一方で、時空間上の局所的な範囲のみを用いて、条件付確率場を構築し、推論をすると、少ない計算資源、短い計算時間で計算が可能であるが、大域的な情報を用いることができず、正確な状態推定を行うことができなくなる。

一方で、自動運転やロボットの制御等の応用を考えると、実世界のリアルタイムな推定が必要な時空間上の範囲は、制御に必要な限られた範囲である。そのため、本報告では、リアルタイムな推定が必要となる範囲を限定することにより豊富な計算機資源をもたないエッジ側でもリアルタイムな推定を実現することを考える。ただし、推定が必要となる範囲を限定した場合でも、当該範囲の状況の正確な推定には時空間上のより広い範囲の情報を用いることが必要となる。そこで、クラウド側においては、自身が持つより広範囲の情報を持ち、時空間上の各範囲の状況を推定し、その推定結果をエッジ側に送ることにより、エッジ側においてもより広い範囲の情報を用いた推定結果を反映した推定を行うことが可能となると考えられる。

本方式は、エッジ側で処理を行う必要のある範囲を抑えることにより、リアルタイムな推定を実現するものである。そこで、条件付確率場で表現をする範囲の大きさと推定にかかる時間の関係をカメラからの物体認識を例とした実験により明らかにする。そして、その結果を踏まえ、エッジ側でのリアルタイムな状態推定を行う際に、エッジ側での処理を行うことができる範囲の大きさについて議論する。

本報告の構成は以下のとおりである。まず、2章で、本報告での時空間確率モデルとして用いる条件付確率場について説明を行う。3章で、条件付確率場を用いた時空間確率表現と、条件付確率場にもとづく実世界の状況のリアルタイム推定のためのクラウド - エッジの連携について述べる。4章で、カメラからの物体認識を例として、エッジ側での実世界推定にかかる計算時間についての実験を行う。最後に5章でまとめと今後の課題を述べる。

2 条件付確率場

本報告では、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。条件付確率場は、マルコフ確率場の一種である。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、それらを用いた従来研究について説明する。

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。[8] 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、以下のようにあらわすことができる。

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

$$E(x) = \sum_{c \in C} f_c(x_c). \quad (2)$$

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 \mathbf{D} が得られた際の潜在変数 \mathbf{X} の条件付確率分布 $p(\mathbf{X}|\mathbf{D})$ をマルコフ確率場で表現したものである。[9] 図 1 に例を示す。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。

$$p(X|D) = \frac{1}{Z(D)} \exp(-E(X; D)) \quad (3)$$

$$E(X; D) = \sum_{c \in C} f_c(x_c; D). \quad (4)$$

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。

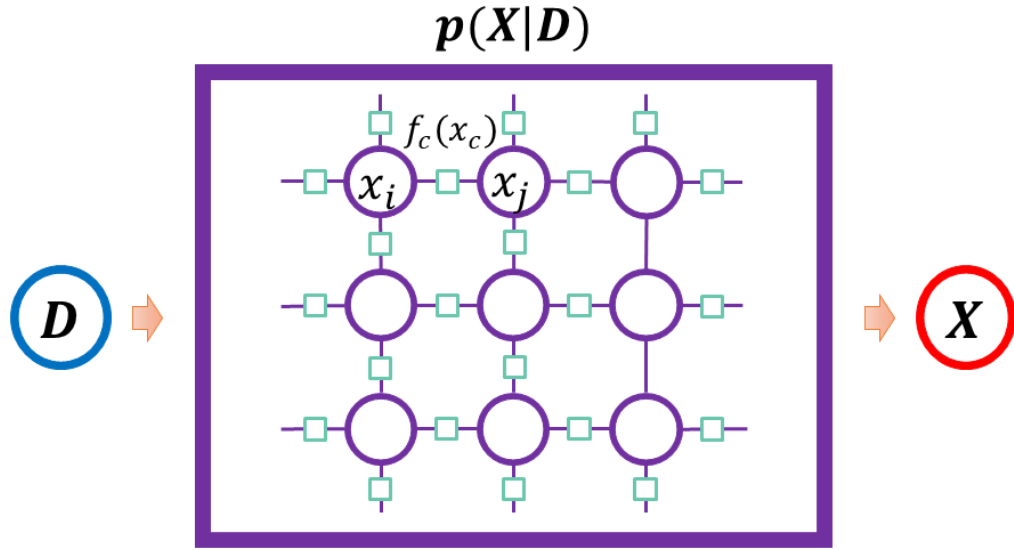


図 1: 条件付き確率場

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: 確率伝播法) 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。確率伝播法では、ノード i からノード j へのメッセージ $m_{i \rightarrow j}$ というものを定義し、メッセージ $m_{i \rightarrow j}$ を確率変数間で交換することにより、周辺確率分布を近似的に計算する。メッセージ $m_{i \rightarrow j}$ とは、周辺分布を計算するために必要な情報の内、隣接するノードより離れたノードに関連するものを集積し、伝達するものである。サイクルのあるグラフ上での確率伝播法は以下のようなになる。

1. 初期化: すべての有向辺 $\alpha \rightarrow j$ に対して、

$$m_{\alpha \rightarrow j}^0(x_j) = 1 \quad (5)$$

と定める。

2. 更新: $t = 0, 1, \dots$ ですべてのメッセージを以下の式で更新し、収束するまで続ける。

$$m_{\alpha \rightarrow i}^{t+1}(x_i) \propto \sum_{x_{\alpha \setminus i}} \Psi_{\alpha}(x_{\alpha}) \prod_{j \in \alpha, j \neq i} \prod_{\beta \ni j, \beta \neq \alpha} m_{\beta \rightarrow j}^t(x_j) \quad (6)$$

3. 近似周辺確率の計算: 収束したメッセージを $m_{\alpha \rightarrow i}^*$ とし、

$$b_i^*(x_i) \propto \prod_{\alpha \ni i} m_{\alpha \rightarrow i}^*(x_i) \quad (7)$$

$$b_\alpha^*(x_\alpha) \propto \Psi_\alpha(x_\alpha) \prod_{j \in \alpha} \prod_{\beta \ni j, \beta \neq \alpha} m_{\beta \rightarrow j}^*(x_j). \quad (8)$$

によって周辺確率分布の近似値 b_i^*, b_α^* を定める。

サイクルのあるグラフ上での確率伝播法では収束が保証されておらず、すべての $\alpha \rightarrow i$ で、 $m_{\alpha \rightarrow i}^t(x_i)$ と $m_{\alpha \rightarrow i}^{t+1}(x_i)$ がほぼ等しくなるまで、式 (6) による更新を続ける。

3 クラウド - エッジ間連携による条件付き確率場を用いた実世界のリアルタイム推定手法

3.1 時空間確率モデル

本報告で対象とする実世界の状況の判断では、特定の時間帯、特定の場所についての状況について、観測された情報から推定を行う。すなわち、対象とする時間、空間の範囲を図2に示すように、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状況について推定を行う。

図2に示される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。

本報告では、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、条件付き確率場を用いる。図3に、時空間にわたる確率変数の条件付き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 が得られた際の状態 S の確率分布 $P(S|D)$ は、以下のよう

$$p(S|D) = \frac{1}{Z(D)} \exp(-E(S; D)) \quad (9)$$

$$E(S; D) = \sum_{(t,x,y) \in N} f(s_{t,x,y}; d_{t,x,y}) + \sum_{((t_1,x_1,y_1),(t_2,x_2,y_2)) \in E} f_{p((t_1,x_1,y_1),(t_2,x_2,y_2))}(s_{t_1,x_1,y_1}, s_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2}). \quad (10)$$

ただし、 t は時間上の時刻、 x, y は空間上の座標、 $s_{t,x,y}$ は時刻 t 、座標 (x, y) に対応するエリアの状態、 $d_{t,x,y}$ は時刻 t 、座標 (x, y) において観測された値、 N は頂点の集合、 $f(s_{t,x,y}; d_{t,x,y})$ は観測値 $d_{t,x,y}$ によって定義された確率変数 $s_{t,x,y}$ の関数、 E は辺の集合、 $p_{((t_1,x_1,y_1),(t_2,x_2,y_2))}$ は (t_1, x_1, y_1) 、 (t_2, x_2, y_2) 間の辺が空間方向の辺か時間方向の辺かの種類、 $f_{p_{((t_1,x_1,y_1),(t_2,x_2,y_2))}}$ は種類 $p_{((t_1,x_1,y_1),(t_2,x_2,y_2))}$ に対して定義される、確率変数 s_{t_1,x_1,y_1} 、 s_{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。本モデル化においては、 $f(s_{t,x,y}; d_{t,x,y})$ 、

$f_{p((t_1,x_1,y_1),(t_2,x_2,y_2))}(s_{t_1,x_1,y_1}, s_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$ は教師データを用いた学習により得る。

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 $P(s_{t,x,y}|D)$ を Loopy BP を用いた近似計算により求めることができる。すなわち、時空間上の任意のエリアの状況を確率分布として得ることが可能となる。

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。

学習： 教師データをもとに $f(s_{t,x,y}; d_{t,x,y})$ 、

$f_{p((t_1,x_1,y_1),(t_2,x_2,y_2))}(s_{t_1,x_1,y_1}, s_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$ を学習する

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 $f(s_{t,x,y}; d_{t,x,y})$ 、

$f_{p((t_1,x_1,y_1),(t_2,x_2,y_2))}(s_{t_1,x_1,y_1}, s_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$ 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

このうち、学習は、モデルを動作させる前にオフラインで行うことができる処理であり、モデル構築、推定については、新たなセンシング情報を取得し反映が必要となったタイミングで毎回行う必要がある処理である。以降、本節では、モデル構築、推定について、クラウド、エッジの連携について議論をする。




図 2: 時空間情報の分割




図 3: 時刻 t , 座標 (x, y) でのノードおよびリンクの例

3.2 クラウド - エッジ間連携による時空間確率モデルの構築・推定

広範囲のセンサーデータを統合することにより、広範囲の時空間確率モデルを構築することが可能となる。このような多量のセンシングデータの分析は、豊富な資源が必要となるため、クラウド側で行われることが想定される。しかし、クラウド側で行ったとしても、多量のセンシングデータの処理には時間がかかる。また、ネットワーク遅延も存在し、さらに、ネットワーク帯域も限られているために、多量のセンシングデータを頻繁にクラウド側に転送することは困難であり、クラウド側でリアルタイムな実世界状況の把握は困難である。一方で、エッジ側は、クラウドのような豊富な計算機資源は持たないため、多量のセンシングデータの分析を行うことはできないが、制御対象に近いので、少ないネットワーク遅延で、かつ、ネットワークの帯域を浪費することなく、センシング情報をリアルタイムに収集することが可能である。

また、自動運転やロボットの制御等の応用を考えると、実世界のリアルタイムな推定が必要な時空間上の範囲は、制御に必要な限られた範囲である。例えば移動ロボット制御の場合であれば、当該ロボットの現在位置の周辺の限られた範囲の状態が推定できればよい。そこで、本報告では、広範囲にわたる推定ではなく、必要となる限られた範囲について、実世界のリアルタイム推定を行うことを議論する。

リアルタイムな推定を精度よく行うためには、最新のセンシング情報の反映が有効である。そのため、リアルタイムな推定は、エッジ側で行うことが妥当であると考えられる。エッジ

側では、短い周期で近隣のセンサーデータを収集し、そのセンサーデータを反映した、局所的な範囲について時空間確率モデルを構築し、推定を行う。

ただし、局所的な範囲の時空間確率モデルでは、十分な精度で、現在の状況を推定することができない可能性がある。例えば、時空間上のあるエリアに他の車両が存在するかという情報を判別・予測するためには、当該エリアに向かう車両が過去に存在したかという情報があれば、当該エリアの現在の状況の推定精度の向上が期待できる。このような広範囲の状態推定は、計算資源が豊富で、多くの情報を収集しているクラウド側において可能である。そして、クラウド側で推定された状態情報をエッジ側に伝え、エッジ側では、その推定結果を反映した時空間確率モデルを構築することにより、広範囲の情報を生かした推定結果を踏まえつつ、推定の処理が必要な範囲を局所的な範囲に抑えることで、リアルタイムな推定が可能となる。

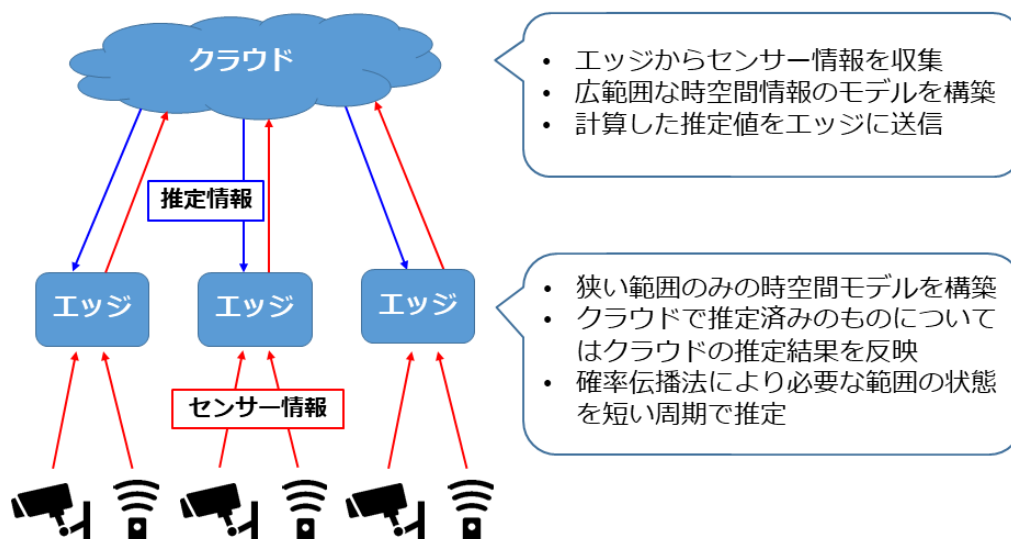


図 4: 時空間確率モデルの構築・推定のためのクラウド - エッジ間連携の概要

図 4 に時空間確率モデルの構築・推定のためのクラウド - エッジ間連携の概要を示す。この連携では、クラウド、エッジの双方において、あらかじめ、 $f(s_{t,x,y}; d_{t,x,y})$ 、 $f_{P((t_1,x_1,y_1),(t_2,x_2,y_2))}(s_{t_1,x_1,y_1}, s_{t_2,x_2,y_2}; d_{t_1,x_1,y_1}, d_{t_2,x_2,y_2})$ については学習を済ませておき、新たにセンシング情報が観測された際に、そのセンシング情報を含む時空間確率モデルを構築し、推定の処理を行う。クラウド側では、広い範囲のセンシング情報を収集し、収集した情報をもとに、広い時空間の範囲に対する時空間確率モデルを構築、構築したモデルを用いて、広い時空間上の範囲における状況の推定を行う。このような広い範囲の情報を生かして、多くのセンシング情報を統合した状況推定を行うことにより、各センシング情報に含まれるノイズや欠損を補った高精度な推定を行うことが期待できる。クラウド側では、このように計

算した時空間上の各エリアの推定値 $P(s_{t,x,y}|D)$ をエッジ側に送信する。

エッジ側においては、クラウド側より短い周期で、近隣のセンサーから情報を収集する。そして、エッジ側では、現在において、当該エッジが推定する必要のある時空間上の範囲に対応する、局所的な時空間確率モデルを構築する。この際、局所的な時空間確率モデルのうち、クラウド側において、すでに状態の推定が完了しているエリアが存在する場合は、当該エリアに該当する確率変数の分布をクラウド側が通知された分布 $P(s_{t,x,y}|D)$ と設定する。その後、エッジ側において、Loopy BP 法により、時空間確率モデルの各隔離変数の周辺分布を計算するが、その際、クラウド側から通知された分布については固定したまま、計算を行う。これにより、クラウド側で、広範囲の情報を用いて推定した情報を反映しつつ、エッジ側で新たに得られた観測値をもとに、必要な範囲の状況を短時間で計算ができると期待できる。

4 実験

前節で述べた、クラウド-エッジ間連携による実世界の推定においては、頻繁にセンシング情報を受信することが可能なエッジ側で、推定が必要となる範囲に限った推定を行うことにより、リアルタイム性を確保している。そこで、本節では、エッジ側で行う局所的な時空間確率モデルを用いた状態推定にかかる時間について計測し、リアルタイム性を維持した推定が可能となる時空間確率モデルの大きさについて議論する。さらに、エッジ側で行う処理のうち、時間がかかる処理を特定することにより、より大規模な時空間確率モデルの処理をエッジ側で可能とするために改善が必要な点についても明らかにする。

4.1 実験環境

本実験では、カメラ映像からロボット等が作業をする範囲の周辺エリアにおける人や障害物を認識するというアプリケーションを想定した実験を行う。本実験では、VIRAT video dataset [10] を用いた。このデータセットは、監視カメラで撮影された駐車場や道のデータセットであり、MPEG4 形式で提供されている。本実験では、このデータセットについて、1 フレームを1つのタイムスロット、1ピクセルを各タイムスロット内の各点に相当するとして、時空間確率モデルの構築、推定の実験を行った。

条件付確率場を用いた時空間確率モデルでは、確率モデル上の各点に対するラベルを設定した教師データが必要となる。そこで、本報告では、教師データとして、最初の2フレーム分の各ピクセルに対して、木、建造物、自動車やバイクなどの車両、通行人、街灯や信号機などのポール、車道や歩道などの地面、ロードコーンやバリケードなどの障害物というラベルを与えて教師データを作成した。

そして、局所的な範囲にしばった上で、条件付確率場による時空間確率モデルの構築、推定の処理を行った時間を測定した。本処理を行ったコンピュータの構成は表1に示すとおりである。

表 1: 実行環境

CPU	Intel Core i7-8550U 1.80GHz
OS	Windows 10 Pro Version 1909
RAM	16.0 GB

4.2 結果

本報告では、条件付確率場における周辺分布の計算は、Loopy BP アルゴリズムにより行う。Loopy BP アルゴリズムでは、その収束にかかる繰り返し回数は問題に依存し、問題やグラフの構造によっては収束しないこともある。そこで、まず、本実験では、時空間確率モデルに含める範囲の大きさを変化させて、それぞれの大きさの確率モデルにおいて、各変数の周辺確率を計算する際に、Loopy BP アルゴリズムで必要となる繰り返し回数について求める。

図5に、Loopy BP アルゴリズムの繰り返し回数と次回の周辺確率推定値との差分の関係を示す。図では、横軸は、メッセージ交換を時空間確率モデルに含まれる全頂点間で行うまでの処理を1回と数えた際の、繰り返し回数を示す。また、縦軸は、当該回のメッセージ交換、周辺確率の推定値の更新をする前と後での、全確率変数の周辺確率の差の平均を示す。図より、繰り返し回数が進むにつれ、周辺確率の差が小さくなり、いずれも収束していることが分かる。また、図より、時空間確率モデルに含まれるエリアが狭いほど、収束が早いことが分かる。そのため、Loopy BP アルゴリズムにおける繰り返し回数の面でみても、エッジにおいて時空間確率モデルに含める必要があるエリアを限定することは有効であると言える。




図5: Loopy BP アルゴリズムの繰り返し回数と次回の周辺確率推定値との差分の関係

次に、時空間確率モデルの構築、Loopy BP の繰り返し 1 回あたりの計算時間を表 2 に示す。表より、グラフの構築時間、Loopy BP の繰り返し 1 回にかかる時間ともに、時空間確率モデルに含まれる範囲が大きくなればなるほど、長くなることが分かる。これは、時空間確率モデルを構築する際に、観測値に合わせて、各リンクに対応する関数

$f_{p((t_1, x_1, y_1), (t_2, x_2, y_2))}(s_{t_1, x_1, y_1}, s_{t_2, x_2, y_2}; d_{t_1, x_1, y_1}, d_{t_2, x_2, y_2})$ を設定する必要があり、また、Loopy BP のメッセージ交換においても、隣接する頂点間でメッセージ交換の処理を行うことが必要となり、いずれもモデルに含まれる辺の数と同じだけの処理が必要であるためである。また、Loopy BP の処理と比べ、グラフ構築にかかる処理の方が時間がかかることが分かる。これは、学習結果をもとに $f_{p((t_1, x_1, y_1), (t_2, x_2, y_2))}(s_{t_1, x_1, y_1}, s_{t_2, x_2, y_2}; d_{t_1, x_1, y_1}, d_{t_2, x_2, y_2})$ を計算が、Loopy BP におけるメッセージの計算よりも時間がかかるためである。

表 2: 処理時間

	時空間確率モデルの構築 [s]	Loopy BP の繰り返し 1 回分 [s]
25×25	0.93	0.027
50×50	3.801	0.11
100×100	15.507	0.43
200×200	62.522	1.76

最後に、実際の処理にかかる時間を図 6 に示す。図では、25×25、50×50、100×100 の範囲において、エッジにおいて毎回必要となる処理として、時空間確率モデル構築にかかる時間と周辺確率の推定値の次の繰り返し時との差がなくなり、Loopy BP による処理が収束するまでの時間について、積み上げ棒グラフで示している。図より、10 タイムスロットにおいて 25×25 以下の範囲に限定することにより 2 秒以内で、50×50 以下の範囲に限定することにより 5 秒以内で推定ができ、リアルタイムに実世界の状況を推定することができる。また、図より、計算時間のうち、モデル構築にかかる時間が支配的であることが分かる。このため、より大きな範囲での推定に対しても、リアルタイムな推定を行うためには、モデル構築にかかる時間を削減することが必要であるといえる。グラフ構築にかかる時間を削減する方法として、前の時刻に構築したグラフを部分的にアップデートすることを繰り返すことにより、毎回計算が必要となる箇所を削減するという方法や、観測情報に依存しないモデルを構築するといった方法が考えられる。グラフ構築にかかる時間の削減方法は今後の課題である。

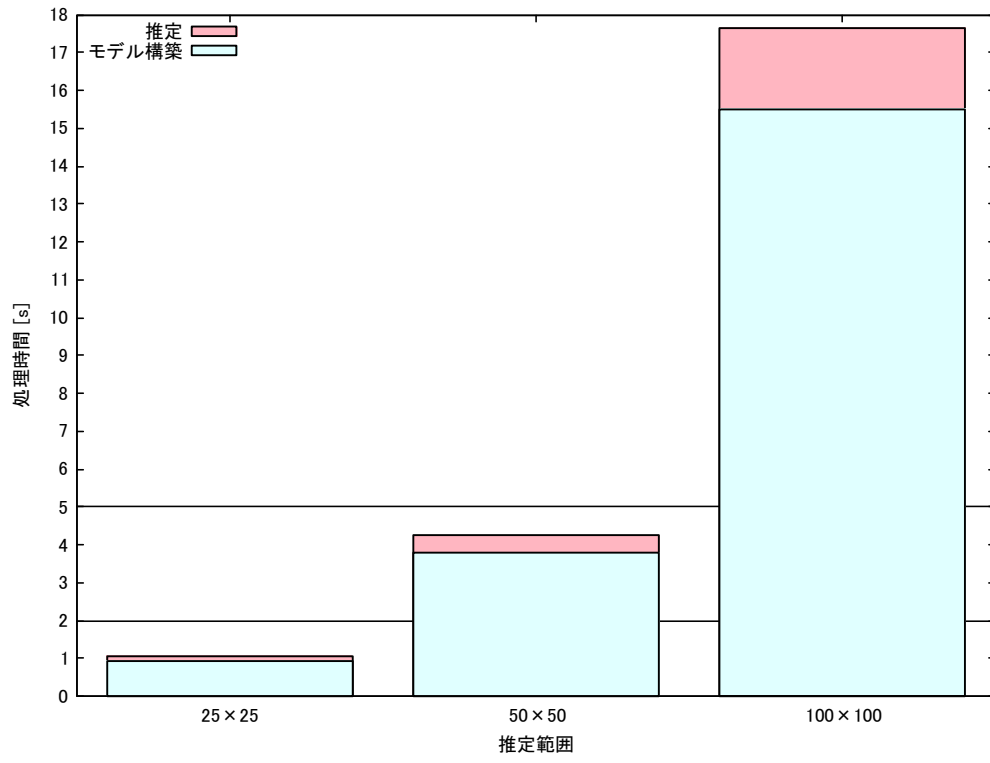


図 6: 処理時間

5 おわりに

本報告では、リアルタイムな実世界の状況の推定をクラウド-エッジの連携により行う手法について議論した。本手法では、時空間にわたる実世界の状況を、条件付確率場として表現し、確率場の更新や、確率場を用いた実世界の推定を行う。自動運転やロボットの制御等の応用を考えると、実世界のリアルタイムな推定は制御に必要な限られた範囲にできればよい。そのため、本報告では、リアルタイムな推定が必要となる範囲を限定することにより豊富な計算機資源をもたないエッジ側でもリアルタイムな推定を実現する。ただし、推定が必要となる範囲を限定した場合でも、当該範囲の状況の正確な推定には時空間上のより広い範囲の情報を用いることが必要となる。そこで、クラウド側においては、自身が持つより広範囲の情報を持ち、時空間上の各範囲の状況を推定し、その推定結果をエッジ側に送ることにより、エッジ側においてもより広い範囲の情報を用いた推定結果を反映した推定を行うことが可能となる。

本方式は、エッジ側で処理を行う必要のある範囲を抑えることにより、リアルタイムな推定を実現するものである。そこで、条件付確率場で表現をする範囲の大きさと推定にかかる時間の関係をカメラからの物体認識を例とした実験により明らかにした。その結果、 25×25 の範囲の処理であれば2秒間隔、 50×50 の範囲の処理であれば5秒間隔で行うことが可能であることが分かった。また、実験の結果より、エッジ側での処理の大部分は、条件付確率場による時空間確率モデルの構築にかかる時間であることが分かった。そのため、より大きな範囲に対してリアルタイムな推定を実現するためには、時空間確率モデルの構築にかかる処理を減らすことが必要である。時空間確率モデルの構築にかかる時間の削減方法は今後の課題である。

また、提案するクラウド-エッジの連携では、単にエッジ側で局所的な範囲での時空間確率モデルを用いた推定を行う場合と比べ、より広範囲な情報を用いたクラウド側での推定結果を踏まえた推定を行うことによる実世界の推定精度の向上も期待できる。このような推定精度の向上に関する評価も今後の課題である。

謝辞

本報告を執筆するにあたり、丁寧かつ熱心にご指導、ご教授くださいました大阪大学大学院情報科学研究科の村田正幸教授に深く感謝いたします。大阪大学先導的学際研究機構の山下裕一准教授には多大なるご助言を賜り、終始懇切なご指導を頂きました。心より感謝申し上げます。また、日頃からご指導、ご教示くださいました大阪大学大学院情報科学研究科の荒川伸一准教授、小南大智助教、大阪大学大学院経済学研究科の大歳達也助教に感謝いたします。そして、様々な面でお世話になりました家族、友人、研究室の皆様に感謝の意を表して謝辞といたします。

参考文献

- [1] H. Chen, “Applications of cyber-physical system: A literature review,” *Journal of Industrial Integration and Management*, vol. 02, no. 03, p. 1750012, 2017.
- [2] J. Sztipanovits, X. Koutsoukos, G. Karsai, N. Kottenstette, P. Antsaklis, V. Gupta, B. Goodwine, J. Baras, and S. Wang, “Toward a science of cyber-physical system integration,” *Proceedings of the IEEE*, vol. 100, no. 1, pp. 29–44, 2012.
- [3] J. K. Naufal, J. B. Camargo, L. F. Vismari, J. R. de Almeida, C. Molina, R. I. R. Gonzalez, R. Inam, and E. Fersman, “A2cps: A vehicle-centric safety conceptual framework for autonomous transport systems,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 6, pp. 1925–1939, 2018.
- [4] Y. Zhang, Z. Zhu, and J. Lv, “Cps-based smart control model for shopfloor material handling,” *IEEE Transactions on Industrial Informatics*, vol. 14, no. 4, pp. 1764–1775, 2018.
- [5] A. Rasheed, O. San, and T. Kvamsdal, “Digital twin: Values, challenges and enablers from a modeling perspective,” *IEEE Access*, vol. 8, pp. 21980–22012, 2020.
- [6] F. Tao, H. Zhang, A. Liu, and A. Y. C. Nee, “Digital twin in industry: State-of-the-art,” *IEEE Transactions on Industrial Informatics*, vol. 15, no. 4, pp. 2405–2415, 2019.
- [7] A. Zhang and P. Tang, “High resolution image classification based on spatio-temporal context model of crf,” in *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, pp. 6979–6982, 2018.
- [8] 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.
- [9] 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.

- [10] S. Oh, A. Hoogs, A. Perera, N. Cuntoor, C.-C. Chen, J. T. Lee, S. Mukherjee, J. K. Aggarwal, H. Lee, L. Davis, E. Swears, X. Wang, Q. Ji, K. Reddy, M. Shah, C. Vondrick, H. Pirsivash, D. Ramanan, J. Yuen, A. Torralba, B. Song, A. Fong, A. Roy-Chowdhury, and M. Desai, “A large-scale benchmark dataset for event recognition in surveillance video,” in *CVPR 2011*, pp. 3153–3160, June 2011.