

# モビリティ遠隔運転の緊急回避を実現する動的リスクポテンシャルマップの提案

武安政明<sup>1</sup> 山内尚久<sup>1</sup> 徳永雄一<sup>2</sup>

**概要:** 遠隔運転操作による現場無人化を実現するには、End-to-end の情報伝送遅延の問題を解決する必要がある。伝送遅延で遠隔オペレータが対処できない状況変化に対し、現場のみでこれを回避するための情報として、動的リスクポテンシャルマップを提案する。周辺空間のリスクを時系列に示したマップ情報をサーバからデバイスに提供することで、時間とともに変化する安全箇所を常にデバイス側が把握でき、突然の障害物出現による回避行動を瞬時に行うことができる。本論文では、ベイズ推定を適用した動的リスクポテンシャルマップ生成手法を説明し、シミュレーションにて特性を評価した結果を示す。

## Dynamic Risk Potential Map to Realize Emergency Avoidance of Remote Operated Mobility

MASAAKI TAKEYASU<sup>1</sup> TAKAHISA YAMAUCHI<sup>1</sup>  
YUICHI TOKUNAGA<sup>2</sup>

### 1. はじめに

自動運転技術に象徴されるように、情報通信技術の発展により、産業全体として省人化、無人化が急速に進みつつある。このイノベーションにより、新たなビジネス機会が創出されると同時に、人による労働機会が失われつつある。我々は、人手か機械かの両極端ではなく、人の労働の機会を残しつつ、労働環境としての無駄を排除することで人の価値を最大化する方策を検討しており、その手段としてのモビリティ遠隔運転技術に注目している。日本の通勤による損失は1日あたり約1,500億円という試算が報告されており[1]、特定場所で働かねばならないという場所制約は、人に肉体的・精神的な負担を与え、生産性を低下させる原因となっている[2]。我々は、移動手段を備えたモビリティデバイスを現場の手足とし、これをオペレータが遠隔操作することで、リモートワークをオフィスワークに限らず、製造、物流、建築、農林水産業へと拡大し、人の労働における価値向上を狙う。

モビリティデバイスを用いたリモートワークとしては、建機分野で進んでいる[3][4]が、一般化には至っていない。その課題の1つが、End-to-end の情報伝達遅延である。5Gの登場で、遠方に対する通信時間の低減が期待されるが、現場から離れたオペレータが状況認識するためのセンシングと情報収集加工と可視化、および何らかの判断を伝えるUIと現場で制御へと変換するまでの遅延までを含めると、現場で判断する応答性に対し大きな遅延が生じる。とくに

現場で想定外の危険要因が発生し、瞬間的な判断に迫られる場合に、End-to-end の遅延は安全面で大きな課題となる。

この問題を解くため、通常の運転を遠隔オペレータが担当し、乗員や搭載物への気配りをもった運転でサービスビリティ向上を目指しながら、瞬間的な危険はデバイスで検知し、機械判断で回避する遠隔運転システムを検討している。従来の遠隔運転においてもフェールセーフ機能として現場での緊急停止を備えているものが多く存在するが、現場の完全無人化を目指す場合、緊急停止だけでなく、操舵も使った空間的な回避行動を瞬間的かつ安全に実現することが必要となる。

そこで本稿では、モビリティデバイスの遠隔運転による現場無人化の実現に向け、瞬間的な緊急回避を実現するためのモビリティデバイスに向けた情報支援策を提案する。情報支援策として、制御コマンドレベルの情報をモビリティデバイスへ配信する方法などが検討されている。しかしながら、従来研究の多くは、通常運転での適用を基本に検討されており、想定外の危険要因が発生した場合の対処が難しい。本稿では、情報支援策として、走行範囲の空間における短期未来のリスクポテンシャルマップ情報をモビリティデバイスに提供する方法を提案する。リスク情報の生成にはベイズ推定を用い、統計情報と直近の交通情報をデータとして、走行範囲の空間に存在するモビリティデバイスの移動を予測することで求める。本手法を、道路交通を例に、交通シミュレーション上に実装し、他のモビリティ

1 三菱電機(株) 情報技術総合研究所

2 金沢工業大学 経営情報学科

デバイスとの衝突リスクが低く緊急回避に利用できる安全空間と、衝突リスクが高く緊急回避での利用を避けるべき空間の境界条件を設定して、そのときの移動予測の正解率と、安全空間の割合を評価した。その結果、正解率は99.9%に対し、デバイス密度が低い場合において70%程度が安全空間と判定され、有効性を示すことができた。

本稿は以下のように構成する。第2章では本研究の位置づけを、第3章で関連する従来研究を述べ、第4章で従来の課題を解決するため動的リスクポテンシャルマップを提案する。第5章でシミュレーション環境と評価結果を示す。最後に、第6章で本原稿をまとめる。

## 2. 本研究の位置づけ

我々の目指す遠隔運転の位置づけを示す。table.1は、自動運転のレベル[5]を参考に、遠隔運転レベルを定義したものである。自動運転レベルと区分するため、遠隔運転レベルをR-Level、自動運転レベルをA-Levelと称す。R-Level=0は、人が搭乗しての運転あるいは自律自動運転である。R-Level=1は、例えば盗難車両を遠隔停止させるサービスに代表されるテレマティクスサービスにあたる。R-Level=2は、リモコン操作による自動駐車に代表され、操舵と加減速を扱う。R-Level3以上はすべての運転操作を遠隔にて実施し、4以上で現場での運転完全無人化、5で場所限定解除となる。本研究の目指す遠隔運転は、R-Level4以上である。

また、本表に、自動運転のA-Levelを記している。これは、対応するR-Levelを実現するために、モビリティデバイスが備えねばならない機能レベルを示す。例えばR-Level=2を実現する場合、遠隔指示を評価・受け入れるためにモビリティデバイス内に周辺認知・判断・制御を統括するADAS-ECU相当の機能が必要となる。R-LevelとA-Levelは2までは共通であるが、R-Level=3以上においてA-Levelは2でとどまっている。これを説明するために、table2に自動運転レベルとそれを実現するアーキテクチャの関係を示す。A-Level2まではCANで接続されたECUの分散処理アーキテクチャであったが、A-Level3以上で認知判断機能の高度化要求から、情報収集・処理を高速化するために、Domain Control Unit (DCU)やVehicle Computer (VC)に情報集約する統合アーキテクチャへ刷新する必要がある。そこで我々は、アーキテクチャ刷新要因となる高度な情報処理をサーバ/エッジサイドへと移行し、さらに人と計算機が協働で認知判断を処理することで、モビリティデバイスのアーキテクチャをA-Level2までの組込み型アーキテクチャのまま、A-Level4,5相当のドライバーレス運転を狙う。自動車に限らず、あらゆるモビリティデバイスがA-Level4以上を実現する上で、大きなアーキテクチャ刷新が不要となることは、普及に向けて大きなメリットになると考える。

table.1 遠隔運転レベルの定義

R-Level	遠隔操作	現場	A-Level
0	現場単独で操作	有人	>0
1	部分的な単一遠隔操作		>1
2	部分的な複合遠隔操作		>2
3	場所限定の総合遠隔操作	無人	
4	場所限定の総合遠隔操作		
5	場所限定なく総合遠隔操作		

table.2 自動運転レベルとアーキテクチャ

A-Level	自動運転	E/E-Arch	
0	システム操作なし	None/ECU	分散*1
1	操舵・加減速のいずれか	+CAN	
2	操舵と加減速	+ADAS-ECU	統合
3	場所限定、人への移譲有	→DCU	
4	場所限定	→VC	
5	場所限定なし	+Global NW	分散*2
		*1)車内レベルの分散	
		*2)交通レベルの分散	

## 3. 関連研究

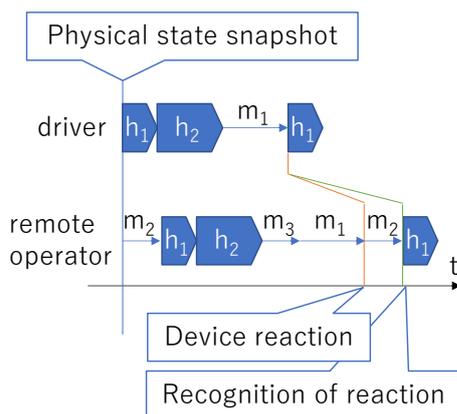
本研究の課題は、遠隔運転で対処できない瞬間的な危険回避を、モビリティデバイスの情報処理リソースに頼らずに実現することにある。本章では、遠隔運転における緊急回避のための情報支援技術に関わる既存研究について概説し、本研究との差異を示す。

危険回避に限らずモビリティデバイスの経路判断を支援する情報であるダイナミックマップ[6]は、地図上に各種障害物の属性とその位置を紐づけた情報を提供し、モビリティデバイスの周辺認識を支援する技術である。更新周期をレイヤ化することで、突然の障害物の出現に対しても動的情報としてリアルタイムに提供される。状況認識についてのモビリティデバイスの演算負担は軽減されるが、得られた空間情報をもとに走行経路を作成する上で、各物体のモデル移動予測、最適経路計画等の演算処理が求められる。

さらにモビリティデバイスの負荷を軽減させるために、経路生成までをモビリティデバイス外で実施し、制御コマンドレベルの情報をモビリティデバイスへ配信することが考えられる。本技術は、製造機器やロボット遠隔制御の分野で議論されている。Guptaらは産業機器のネットワーク制御(NCSs)の課題全体像をまとめ、その中でPLC制御における伝送遅延の問題を指摘している。以後、モデル予測制御が伝送遅延時の有効な補償技術として研究が進められている。Kumagaiらは、通信遅延を予測し、先回りの予測制御を行うことで、予測精度の向上を図り[8][9]、建機の遠隔制御に適用されている[10]。しかし、モデル予測制御は、通常運転での適用を基本に検討されており、想定外の危険要

因が発生した場合の対処については、対応が難しい。この点を図を用いて説明する。

fig1 は、現場の状態を認識し、対応する操作が制御に反映されるまでの流れを、ドライバーによる運転と遠隔運転で比較したものである。ドライバーの場合、危険状況は自身の視覚より認知し( $h_1$ )し、回避判断を行い、行動を操作に反映させる( $h_2$ )。この人による反応時間  $h_1+h_2$  は一般に 150~300 ミリ秒と言われる。機械的な遅延  $m_1$  はステアリングやブレーキ操作による反応で約 100 ミリ秒なので、ドライバーが運転するモビリティデバイスの応答時間は 500 ミリ秒以下となる。一方、遠隔運転の場合も、オペレータの反応時間  $h_1+h_2$  および機械的な遅延  $m_1$  は同等と考えられ、遠隔運転するモビリティデバイスの応答時間は、これにセンサ情報の収集、伝達、可視化時間  $m_2$  およびオペレータ操作のコマンド変換、伝達時間  $m_3$  が加わる。さらにオペレータがモビリティデバイスの反応を認識するには再び  $m_2$  の時間を要する。初動の遅れとしては、往復路の End-to-end 時間  $m_2+m_3$  増分で、インターネット経由の伝送を考慮すると 100~500 ミリ秒であり、ドライバーや遠隔オペレータの反応のゆらぎを考えると許容できる時間ともいえる。しかし、その後の一連の運転操作における反応に対しても  $m_2+m_3$  の遅れが発生し、遠隔オペレータがその反応を認識するにはさらに  $m_2$  の遅れが加わることで、細かな制御を阻害し、遠隔運転における緊急回避行動を難しくしている。先に述べた予測制御においても、突然近くに障害物が出現した場合には、予測計算をやり直す必要があり、その間回避行動は遅れることになる。以上の課題から、これまでは緊急時処置としてはモビリティデバイス側での異常検知による緊急



$h_1$  : recognition time  
 $h_2$  : operation response time  
 $m_1$  : machine response time  
 $m_2$  : data transmission time  
 $m_3$  : command transmission time

fig.1 状況に対する反応時間

停止にとどまり、周辺の安全状況を把握した上で、操舵も含めた高度な回避行動を行うは至っていない。

以上から、検出から回避判断、行動までを 1 秒以内に開始する必要がある瞬間的な危険回避を、遠隔からの情報支援によってモビリティデバイスの情報処理リソースに頼らず実現する方法を提案する。

## 4. 動的リスクポテンシャルマップの提案

### 4.1 提案概要

前記課題により、R-Level=4 以上の遠隔運転を行うためには、瞬間的な危険回避を実現する必要がある。これを高度な演算処理をモビリティデバイスに備えずに行うには、例えば常に回避経路をモビリティデバイスに提供し続けるといったような新たな情報支援を提案する必要がある。しかし経路生成には多くの演算リソースを要するので、例えば各モビリティデバイスに数秒間の回避経路を、予想される状況に応じて複数用意し、それを周期的に繰り返すとするとサーバであっても過負荷となる。

そこで我々は、「線」としての回避経路ではなく、「時空間」としての回避経路を提供することを提案する。これを動的リスクポテンシャルマップ(Dynamic Risk Potential Map : DRPM)と命名する。

リスクポテンシャルマップは、自動運転の経路作成アルゴリズムに利用される情報の 1 つである[11][12]。障害物との衝突リスクを等高線に見立て、リスクの谷間を結ぶことで安全経路を求める。ただし、リスクポテンシャルマップは、現在のリスクを示すもので、時間とともに移動する物体のリスクについては、移動可能範囲までを高リスクとして示すことになる。そのため、走行隊列の車両と車両の間のような空間は、実際には空いていたとしても高いリスクとして示されたままとなる。工藤らは道路を細分化し、各領域における自車を含めた車両の時間に対する出現確率を求め、自車の出現確率と他の車両の出現確率が高い領域を高リスクとしたマップを生成している[13]。これにより、時間移動とともに移動するリスクを考慮し、走行可能範囲を広げている。

DRPM は、工藤らの考え方に近いが、自車の移動経路に依存しないマップである点が相違点となる。すなわち、個々の車両と自車の間のリスクポテンシャルマップを生成するのではなく、各空間に対する短期未来のリスク情報を示すリスクポテンシャルマップを生成する。よって、自車が突然の障害物に対して回避行動を行う際に、ある時間帯にどの空間が安全かを、自車のこれまでの経路とは非依存に判別することができる。

### 4.2 システム構成

fig.2 に動的ポテンシャルマップを用いた遠隔運転システムの構成図を示す。遠隔運転については、クラウドサーバがインターネット上の遠隔オペレータとモビリティデバイ

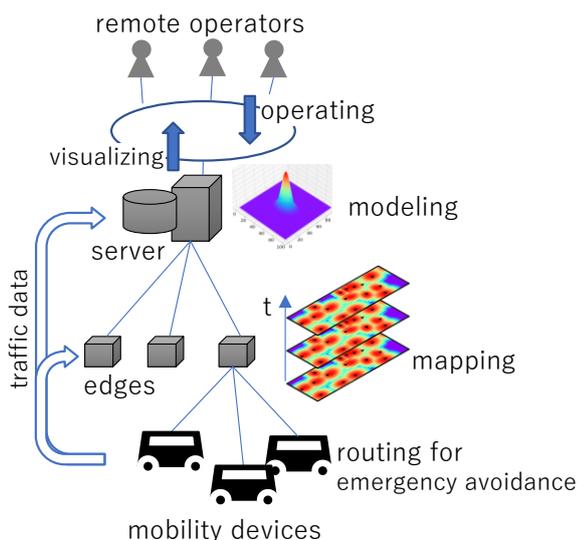


fig.2 システム構成

スをつなぎ、モビリティデバイスとオペレータの割り当て、センサ情報収集、オペレータへの可視化、運転指示の伝送等を行うことで実現する。DRPMは、モビリティデバイスが走行するフィールドを数 km 毎に分割し、領域ごとに割り当てたエッジとサーバの連携で生成・管理する。サーバは、各モビリティデバイスの位置情報を収集し、フィールドをメッシュ分割したセルを単位として、あるセルにいたモビリティデバイスが単位時間（数 100 ミリ〜秒の単位）毎にどのセルに移動したかを追跡する。このモビリティデバイスのセルからセルへの移動先分布をもとに、セル毎の移動推定モデルを作成し、エッジへ分配する。ここで、セル毎の移動推定モデルとは、あるセルを対象に、本セルに存在したモビリティデバイスの単位時間後の移動先セルの分布を示すモデルとなる。モビリティデバイスは、車線に従い走行し、駐車車両等があれば手前で車線変更しこれを避けて走行することから、その移動傾向は、場所に依存すると考えられる。そこで、移動推定モデルを起点となるセル毎に作成する。なお、本提案では、セルに存在するモビリティデバイスは一台と仮定している。

エッジは、管轄する領域のモビリティデバイスの位置を周期的に取得し、モビリティデバイスが存在するセルの時間毎の、セル毎の移動推定モデルを地図上に割り付ける。また、地形、建造物などの静的障害物情報も、衝突リスクとして地図上に割り付ける。これを DRPM として、モビリティデバイスへ伝達する。

モビリティデバイスは、遠隔オペレータの運転指示に従い走行しながら、自身のセンサにより周辺障害物を監視し、DRPM と照合する。モビリティデバイスは、移動経路上に障害物を検知した場合、検知した障害物の位置が低リスクを示していたならば、遠隔運転システムが認知していない障害物の出現とみなし、回避行動を開始する。DRPM の進

行方向を参照し、低リスク空間を繋げての回避経路を探索し、実行する。

### 4.3 DRPM の生成

以下に、提案する DRPM の生成方法について説明する。説明を簡略化するために、リスクとなる障害物をモビリティデバイスに限定しているが、実際には歩行者、自転車などの他の移動体や静止障害物についても同様に確率分布を求めて生成する。

#### (1) 移動推定モデルの作成

まず、サーバにおいて各セルに対する移動推定モデルを作成する。モビリティデバイスの軌跡の学習となるが、交通量の少ない場所では学習データの蓄積量が少ないことが懸念されるため、ベイズ推定を適用する。ベイズ推定は、推定したい特定の変数が、ある分布に従って確率的に発生するとし、複数のデータが観測されたときの変数の分布を求める手法である[14]。推定の目的は、あるセルにいるモビリティデバイスに着目し、単位時間後にどのセルに移動する可能性があるかを求めることにある。すなわち、ベイズ推定で、あるセルに存在するモビリティデバイスの単位時間後の移動先セルの確率分布を求める。

ベイズ推定では、以下の式が成り立つ：

$$f(\theta|x) = \frac{f(x|\theta)f(\theta)}{f(x)} \quad (1)$$

ここで、 $\theta$ は確立分布の母数であり、あるセルにいたモビリティデバイスが単位時間後に移動したセル座標位置  $(C_1, C_2)$ を示すベクトル変数である。 $x$ は観測データであり、実際の観測で得た単位時間後の移動先のセル座標位置の集合である。 $f(\theta|x)$ はベイズ推定による事後分布であり、観測データに基づく座標位置 $\theta$ にモビリティデバイスが移動する確率を示し、 $f(\theta)$ は事前分布として、一般論から導かれる移動確率を示す。 $f(x|\theta)$ は尤度を示す。 $f(x)$ は正規化定数であり $\theta$ に依存しない定数である。すなわち、(1)式により、事前に統計データ等を求めた事前確率を、観測データ $x$ によってセル毎の実状に合わせた確率分布へと更新する。

(1)式によってセル毎に求めた事後分布 $f(\theta|x)$ を、各セルの移動先分布とし、これをサーバにて求める。具体的には、サーバは対象のフィールドの交通状況を収集し、モビリティデバイスの移動軌跡を得る。これを元に、各セル座標に対し、単位時間後の移動先セル座標の集合を集計し、観測データ $x$ を求める。走行中のモビリティデバイスは、現在の進行方向と速度を中心に加減速による前後変動と操舵による左右変動で拡散する分布とみなせるので、その確率分布は二次元正規分布で近似できる。これより、モビリティデバイスの単位時間後の移動先のセルの確率分布についても同様に二次元正規分布で近似できる。すなわち、求めるパラメータは、二次元正規分布の平均値と分散共分散行列である。

以降で、(1)式の各式の求め方を示す。事前分布 $f(\theta)$ は、例えば道路交通センサス[15]のような統計情報から得られる区間の速度推移から分布を求める。式(1)に示す二次元正規分布を用いる。

$$f(\theta) = \frac{1}{2\pi} \frac{1}{\sqrt{|\Sigma|}} e^{-\frac{1}{2}(\theta-\mu)'\Sigma^{-1}(\theta-\mu)} \quad (2)$$

ここで $\mu$ はモビリティデバイスの移動先のセル座標位置の平均値なので統計情報によるモビリティデバイスの平均速度を時間で積分し、現在位置に加算して求める。 $\Sigma$ は分散共分散行列であり、速度の偏差、道路幅、座標平面に対する道路の角度より求め、事前分布を確定する。

尤度も二次元正規分布に従うとし、二次元正規分布の密度関数として、尤度関数 $f(x|\theta)$ は以下の式で示される：

$$f(x|\theta) = \prod_{i=1}^n f(x_i; \hat{\mu}, \hat{\Sigma}) \quad (3)$$

ここで、 $x_i$ は観測された移動先のセル位置群であり、観測時からの経過時間毎のモビリティデバイスが観測されたセル位置である。モビリティデバイスの移動先のセル座標の平均値、ならびに分散共分散の推定値 $\hat{\mu}, \hat{\Sigma}$ は、最尤法により求める。

以上で(1)式右辺分子のパラメータが特定できるが、分母の正規化定数 $f(x)$ を求めるにはデータが少ないので、モンテカルロ法を適用する。モンテカルロ法では、(1)式右辺分子の確率分布に従う十分に大きなサンプルデータを生成し、その分布のパラメータを求めることで、事後分布を求めることができる。これを各セルの単位時間  $x \times N$  毎に実施し、移動推定モデルとしてエッジに提供する。

## (2) DRPM の作成

エッジでは、サーバから得られた各セルの移動推定モデル、すなわち二次元正規分布の平均値と分散共分散行列情報を用いて、現在の交通状況を起点とした単位時間  $x \times N$  までの DRPM を以下の方法で生成する：

- ① 時刻 $t_0$ のモビリティデバイスの位置情報を収集し、セル座標位置に変換する
- ② DRPM をセル座標位置 $\theta$ の関数 $r(\theta)$ とし、初期値 0 を与える
- ③ セル座標位置に対応する移動推定モデル $f(\theta|x)$ を $r(\theta)$ に加算する
- ④ モビリティデバイスの数だけ②③を繰り返す

なお、本論文では、リスクの重み付けを行っていない。すべての障害物に対して衝突すべきでないと考え、移動確率分布の和でリスクを表している。今後、衝突した場合の被害の大きさを考慮したさらに高度な回避判断を行う際には、対象物の属性や位置関係に応じたリスクの重み付けが必要になると予想されるため、今後の課題とする。

## 5. 実装評価

### 5.1 評価概要

オープンソース交通シミュレータ SUMO[16]を用いて交通環境を構築し、その上で DRPM を生成し、信頼性を確認するための移動予測の正解率と、緊急回避としての活用性を確認するための安全空間の出現割合を評価する。

### 5.2 評価環境

基本的な特性を確認することを目的に、fig.3 に示す片側 2 車線ずつの 4 車線直線道路の 200m 区間で評価する。移動推定モデルを生成する単位であるセルは、横方向 0.8m(1 車線幅の 1/4)  $\times$  進行方向 2m とし、16  $\times$  100 セルに分割する。観測データは、SUMO によるシミュレーション 250 秒間の車両軌跡とする。なお、車両の密度に変化をつけるため、両車線それぞれの流入点に信号を用意し、周期的に流入停止を行っている。また、レーン移動を促すため、1 つのレーン上に停車中の車両を 1 台挿入し、追い越しレーンへ強制的に車線変更するようにしている。その他シミュレーション条件を table3 に、実行時の移動軌跡を fig3 に示す。

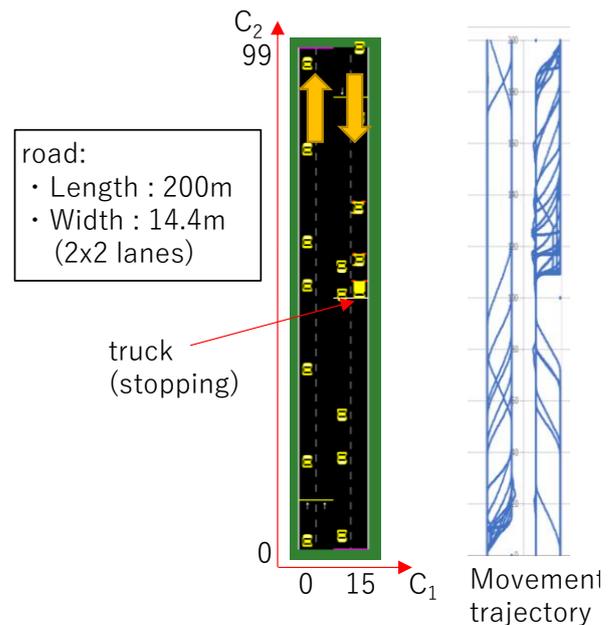


fig.3 評価道路環境

table.3 シミュレーション条件

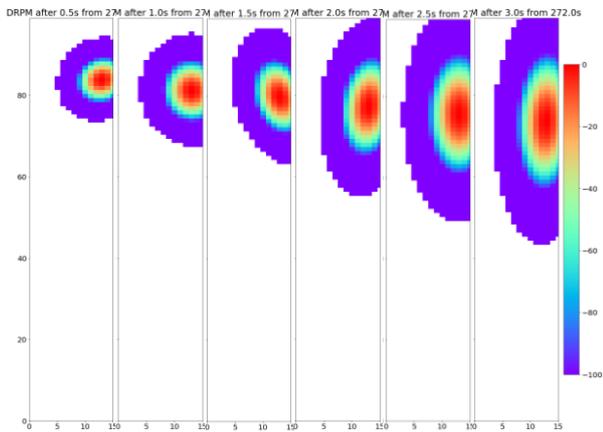
model	parameter	value
road	lane	2x2 (3.2 m/lane)
	length	200 m
	signal	B20/Y3/R5 sec
mobility devises	length	5 m
	max speed	10 m/s(36 km/h)
	speed $\sigma$	0.5 m/s
	device density	0.3 devices/sec
stopped truck	length	7m
	position	(15, 50)

### 5.3 DRPM の生成

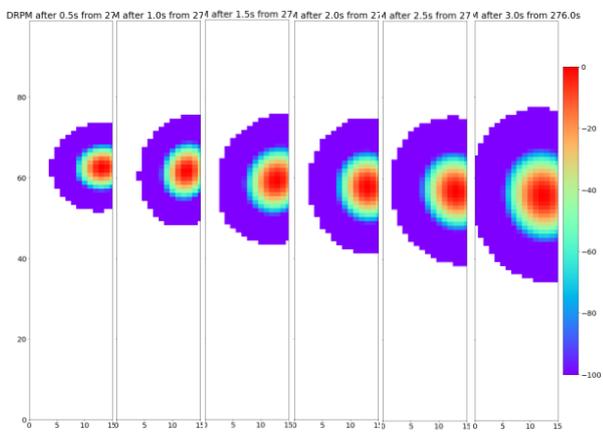
事前分布としては、全セル共通に、観測時からの予測経過時間を  $t(t = 0.5, 1.0, \dots, 3.0)$  として、平均移動距離  $\mu = (2.5t, 0)$ 、分散を横方向  $\sigma_{11}^2 = t^2$ 、進行方向  $\sigma_{22}^2 = (2.5t)^2$  (いずれも単位はセル数) とし、経過時間とともに線形に分散が増大する分布とした。

次に、SUMO のシミュレーションタイムステップを 0.1 秒刻みとして実行し、得られた車両軌跡情報を元に、各セルを始点に予測経過時間後の移動先セル位置を観測データとして抽出した。このデータをもとに尤度を求め、マルコフ連鎖モンテカルロ法によるサンプリングを実施した。サンプリングデータ抽出には、ランダムウォーク MH 法を用いている。サンプル数を 10 万個とし、バーンイン期間を 1000 サンプルングとしている。fig.4 に、サンプリングデータの分布より生成した移動推定モデルを示す。グラフは確率を対数表現しており、赤色が高確率を示す。また、左から、0.5, 1.0, 1.5, 2.0, 2.5, 3.0 秒経過後の予測となっており、(a)(b)とも、上から下へ進行するレーンの、進行方向左レーンを示すセルである。

(a)の位置では、レーンを維持するデバイスが多いことと、流入点に設置した信号により速度のばらつきが多いことから、モデルも縦長の分布となっている。一方(b)の位置では、



(a)model of cell (13,85)



(b)model of cell (13, 65)

fig4. 各セルの移動推定モデル

速度は安定しつつ  $C_2=50$  の左車線に停車しているトラックを避けるため右車線への移動をするデバイスが発生していることから、やや幅の広い分布となっている。

以上のように、事前分布は同じであった各セルの移動推定が、事後分布では観測データをもとに各セルの状況に応じて変化していることがわかる。

本モデルを利用し、モデル作成のための観測データとしては使っていない 250 秒後のシミュレーションにおける DRPM の生成例を fig.5 に示す。グラフの表現方法は fig.4 と同じである。黒い三角は、シミュレーションによる経過時間のデバイスの位置、すなわち正解値である。図に示す通り、多くは高リスクを示す赤色の領域に正解位置が含まれており、正しく予測されていることがわかる。しかしながら、一部対数値で -40 を示す緑色の領域に含まれるものがあるので、-50 以下の青から紫および白の領域を安全空間とするのが望ましいと考える。

### 5.4 移動予測の正解率

次に、安全空間の境界と予測精度の関係を明らかにする。交通流シミュレーションを繰り返し、異なる時間帯の 100 シーンの交通状況に対し、観測からの経過時間毎にデバイス位置のリスク値を評価する。また、モビリティデバイスの密度を Low=0.1, Mid=0.3, High=0.5 devices/sec と変化させ、密度の違いについても評価する。

結果をリスク値に対する累積度数分布として fig.6 に示す。横軸に示されたリスク値を安全領域の境界としたときに、縦軸の示す累積度数分布が正解率すなわち精度と考えることができる。上からモビリティデバイス密度を低, 中, 高の順に示し、各図のなかで経過時間毎別の分布を示している。いずれの密度においても、経過時間が増大する程立ち上がりが遅くなるが、リスク値 -40 でいずれも正解率が 99.5% 以上に達する。すべての条件を包含したデバイス数約 17,000 台のリスク判定の正解率は、安全空間の境界をリスク値 -40 とした場合に、99.9% となることがシミュレーションより示された。

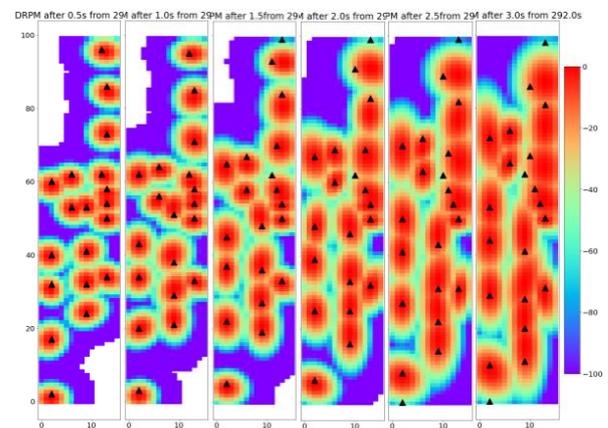


fig5. 動的リスクポテンシャルマップの生成例

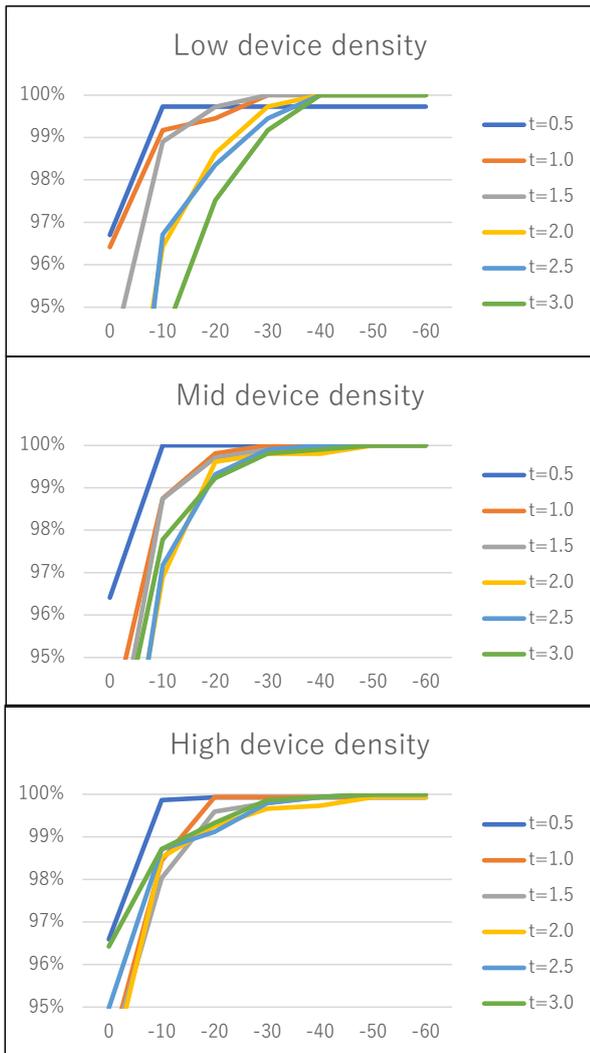


fig6. 移動予測の正解率

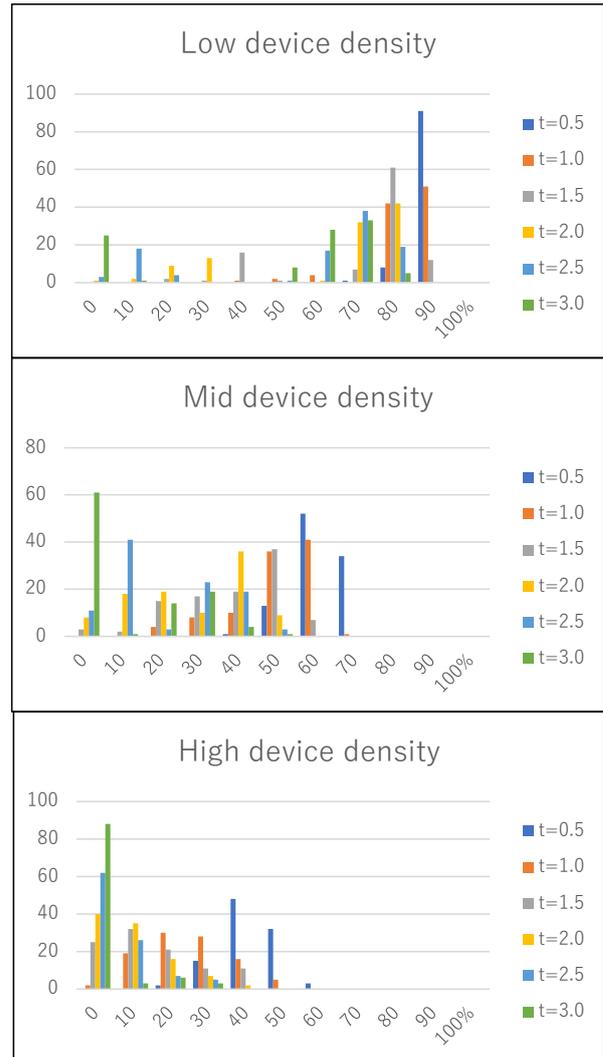


fig.7 安全空間の出現割合

### 5.5 安全空間の出現割合

安全空間の境界をリスク値-40とした場合に、自車が安全に回避できる空間はどれ程残っているかを評価するため、前空間に対する安全空間(リスク値-40よりも小さい空間)の割合を評価する。評価環境,条件は前節までと同一とし,モビリティデバイス密度が低,中,高の各条件における100シーンの交通状況に対し,経過時間ごとの安全空間の割合を抽出する。結果を安全空間の割合に対する度数分布として,fig.7に示す。低密度の場合は,3秒後の予測に対しても安全空間として60~70%が確保されているが,中密度からは全く確保できない場合が増しており,操舵回避の選択が難しいことがわかる。したがって,現状のDRPMの能力においては,モビリティデバイス密度が0.1devices/secの比較的開いた交通状況において,緊急時の操舵回避に利用できる状態である。さらに密度の高い環境でも操舵回避の選択肢を用意するためには,二次元正規分布モデルの見直しや,交通状況に応じたモデルの切り替えなどの改善を加え,予想精度を高める必要がある。

### 5.6 回避行動時間の考察

最後に,検出から回避判断,行動までを1秒以内に開始する必要がある瞬間的な危険回避を,遠隔から提供するDRPMによって実現できるかという根本の命題について,考察する。DRPMは,モビリティデバイスからのセンサ情報や,インフラカメラ等による交通監視情報によって現状のデバイス位置を把握する。これは,fig.1に示した遠隔オペレータへの情報伝達遅延 $m_2$ に等しい。次に,デバイス位置をセル座標に変換し,デバイスが存在するセル座標の移動予測モデルを参照し,分布関数より各座標の確率密度を求め,マップに加算する。これを確認できるデバイスの数だけ繰り返す。本処理は,サーバにて周期的に繰り返されるため,最悪,処理開始が周期時間だけ遅れる。さらに演算遅延として,(デバイスの数・セル座標の粒度・求める経過時間サンプル数)を計算機の演算性能で割った値に比例した時間を要する。DRPMの配信周期を1秒とし,演算遅延を今回の評価環境から取得すると,デバイス密度低=平均7devices,16,000セル,3sec/0.5sec=6サンプルにおける

PC レベルの実測で 100 ミリ秒程度であることから、全体で 1.1 秒となる。最後に DRPM をデバイスへ伝送するため fig.1 における  $m_3$  の時間を要する。よってデバイスが受け取る DRPM の遅延は  $m_1+m_3$ +サーバ計算時間となりおよそ 1.6 秒以下と見積もることができる。したがって、経過時間 3 秒までの DRPM を 1 秒周期で各モビリティデバイスへ配信し続けた場合、経過時間 1.5 秒までの DRPM は間に合わない可能性があるが、2.0 秒から先の DRPM は有効であり、モビリティデバイスは突然現れた障害物に対し、DRPM を参照し、fig.1 におけるドライバーと同レベルの自律判断で回避行動をとることができる。

また、この場合に要求される通信伝送容量は、DRPM の 1 セルを 1byte のビットマップデータとして、 $1,600\text{Byte}/\text{sec} \cdot 6 \text{ サンプル} = 9,600\text{Byte}/\text{sec}$  と小さく、通信負担になり得ない。

## 6. おわりに

モビリティデバイスの遠隔運転による現場無人化の実現に向け、緊急回避時の行動判断を支援するための情報として、動的リスクポテンシャルマップを提案した。フィールドを領域分割したセル単位に移動推定モデルを生成し、現状のモビリティデバイスの位置にあわせてモデルを重ね合わせることで、フィールド全体のデバイス移動予測を求める。モデル生成には、ベイズ推定を用い、統計情報による事前確率と、直近の現場の交通情報をデータとして事後確率を求める。交通流シミュレータ SUMO を用いて、交通環境を模擬し、他のモビリティデバイスとの衝突リスクが低く緊急回避に利用できる安全空間と衝突リスクが高く緊急回避での利用を避けるべき空間の境界条件を設定して、そのときの移動予測の正解率と、安全空間の割合を評価した結果、正解率は 99.9% に対し、デバイス密度が低い（秒あたり 0.1 台の流入量）場合において 70% 程度が安全空間と判定され、有効性を示すことができた。一方で、秒あたり 0.3 台以上の流入量においては安全空間を十分に確保できず、緊急時の操舵回避は難しいという評価結果を得た。より高い密度の交通環境で操舵を含めた回避判断を支援するためには、移動予測モデルの改善が必要である。また、考察で試算したリアルタイム性能についても、今後実測レベルで証明していく予定である。

## 参考文献

- [1] “日本の通勤地獄が労働生産性を下げている？ 経済損失の試算は 1 日あたり 1424 億円”。<https://www.newsweekjapan.jp>, (参照 2021-4-9)
- [2] “Long commutes costing firms a week’s worth of staff productivity”。<https://www.vitality.co.uk>, (参照 2021-4-9).
- [3] “建設機械の遠隔操作に関する実用化検証開始について”。<https://www.kobelcoem-global.com>, (参照 2021-4-9)
- [4] “5G を活用して 3 種類の建設機械を遠隔操縦する実証実験を開始”。<https://japan.hitachi-kenki.co.jp>, (参照 2021-4-9)

- [5] “Levels of Driving Automation”, J3016 Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, 2018 Revision, <https://www.sae.org>
- [6] 高田 広章, 佐藤 健哉. ダイナミックマップ—自動走行/協調運転支援のための情報プラットフォーム. システム制御情報学会, 2016, vol. 60, no. 11, p. 457-462
- [7] R.A.Gupta and M.Y.Chow, "Networked Control System: Overview and Research Trends," IEEE Transactions on Industrial Electronics, vol.57, no. 7, pp.2527-2535, 2010.
- [8] H. Yoshida, K. Kumagai, and K. Satoda, "Dynamic State-Predictive Control for a Remote Control System with Large Delay Fluctuation," IEEE ICCE, Jan. 2018.
- [9] K. Kumagai, H. Yoshida, and K. Satoda, "Adaptive Remote Control of a Mobile Robot System with Delay Fluctuation," IEEE ICCE, Las Vegas, Jan. 2018.
- [10] T. Yoshimoto, H. Yoshida, T. Innami, "Improving Workload of Long-Distance Remote Construction Through a WLAN and the Internet," IEEE CCNC, Jan. 2019.
- [11] P. Raksincharoensak, T. Hasegawa, M. Nagai, "Motion Planning and Control of Autonomous Driving Intelligence System Based on Risk Potential Optimization Framework," International Journal of Automotive Engineering, vol. 7, no. 1, pp.53-60, 2016
- [12] “高齢者の自立を支援し安全安心社会を実現する自律運転知能システム”。[http://web.tuat.ac.jp/~s-innova/pdf/symposium2016\\_inoue.pdf](http://web.tuat.ac.jp/~s-innova/pdf/symposium2016_inoue.pdf), (参照 2021-4-9)
- [13] 堀田 勇樹, 早瀬 茂規, 工藤 真. 車載用電子制御装置, P2020-53069, 日本国特許庁
- [14] L. Statisticat, “Bayesian Inference,” <https://cran.r-project.org/web/packages/LaplacesDemon/vignettes/BayesianInference.pdf>.
- [15] “道路交通センサス”。国土交通省関東地方整備局. <https://www.ktr.mlit.go.jp>, (参照 2021-4-10)
- [16] “Eclipse SUMO - Simulation of Urban Mobility”。[https://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931\\_read-41000](https://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931_read-41000), (参照 2021-4-11)