

隠れマルコフモデルを用いた複数個体による
高信頼環境情報の推定技術

Estimation Technique of the High Reliable Environment Information
by Multiple Individuals using Hidden Markov Model

西田 武央[†] 奥出真理子[†]
Takehisa Nishida Mariko Okude

1. はじめに

制御システムの自動化・複雑化・大規模化及び知能化が進んでいる。本研究は、制御システムとして、知能化制御[1]に、人為的操作に対する安全検証機能[2]を付加した安全検証型適応制御システム[3]において、特に制御システムが移動する個体である場合を対象としており、知能化制御へ提供するための高信頼な環境情報の推定技術を提案する。この制御システムの高信頼化を実現するためには、移動する個体に対する高信頼な環境情報（個体単独では観測できない外部環境情報）が必要となる。

本発表では、移動する複数個体による周辺環境の観測結果を統合して、高信頼な環境情報を推定する技術について提案する。複数個体による観測結果を隠れマルコフモデルで表現し、観測情報の欠落に対する補完や近い将来における観測情報を推定する。さらに、提案手法の動的に情報が更新される地図への適用についても述べる。

2. 課題とアプローチ

本研究の目的は、ある環境内で動作する移動する個体による外部環境の観測結果を統合・共有して、高信頼な環境情報を構築し、入力情報として制御システムに提供することである。高信頼な環境情報の構築のイメージを図 1 に示す。個体が動作する環境内には、他の個体が複数存在している。個体 A は図中の左右方向に移動するが、その可動域には点 X が存在しており、個体 A の移動のためには点 X の情報を知る必要がある。このとき、環境情報を他の個体、例えば、可動範囲が一部重複する個体 B と共有することができる。点 X は個体 A と個体 B どちらも観測可能であるが、時刻 t_1 においては、個体 A と個体 B のどちらの検出範囲にも点 X は含まれない（点 X に関する観測情報が欠落する）。このため、点 X における環境情報は、次に個体 A または個体 B が観測するまでは欠落する。個体 A の移動においては、点 X が個体 A の検出範囲内に含まれるよりも前の時点で点 X の状態を知ることができれば、個体 A をより効率的に制御できる可能性がある。

そこで本研究では、図 2 に示すように、移動する複数の個体による観測情報を時空間で統合し、隠れマルコフモデルを用いて欠落した観測情報の補完及び将来の環境情報の推定を行う方式を検討した。隠れマルコフモデルについては、図 3 に示すように潜在変数の状態数が 2 ($x(t) \in \{x_1, x_2\}$)、観測値の状態数が 3 ($y(t) \in \{y_1, y_2, y_3\}$) のモデルとした。潜在変数は環境内にオブジェクトの存在の有無とし、観測状態はそのオブジェクトの (1) 存在を観測した状態、(2) 存在しないことを観測した状態、(3) 存在の判別不可の状態の 3 状態とした。




図 1 環境情報構築のイメージ

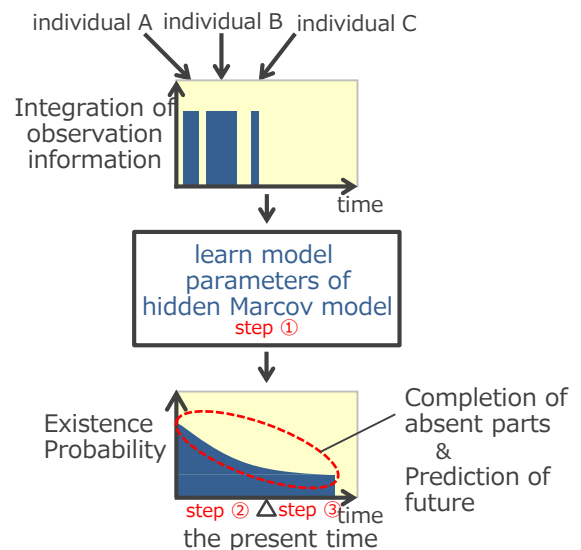


図 2 隠れマルコフモデルを用いたアプローチ

[†] (株) 日立製作所: Hitachi, Ltd.

ここで,

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \dots\dots\dots(1)$$

は遷移行列であり, 遷移確率 a_{ij} は潜在状態 i から潜在状態 j へ遷移する確率を示す。また,

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \end{bmatrix} \dots\dots\dots(2)$$

は出力行列であり, 出力確率 b_{jk} は潜在状態 j において観測状態 k を観測する確率を示す。ここで, 移動体に備えられた環境を認識するセンサが誤検知や不検知を含まない理想的なものであれば, $b_{12} = b_{21} = 0$ となる。 b_{13} 及び b_{23} , すなわち, オブジェクトの存在を判別不可となる確率は, 環境内に存在する当該のオブジェクトを遮蔽するもの, 例えば, 環境内を移動する個体の数などに影響を受ける。なお, 遷移確率及び出力確率について, 以下が成り立つ。

$$\sum_{j=1}^2 a_{ij} = 1 \dots\dots\dots(3)$$

$$\sum_{k=1}^3 b_{jk} = 1 \dots\dots\dots(4)$$

上記の遷移行列 A に基づいて, 将来におけるオブジェクトの将来の状態を推定することにより, 制御システムに対する高信頼な環境情報を構築する。

提案手法は以下の 3 ステップを持つ (図 2 の step ①~③に対応)。

①学習ステップ

複数の個体から得られる環境情報から, 隠れマルコフモデルのモデルパラメータ (遷移行列及び出力行列) を学習する。

②復号ステップ

学習ステップで得られたモデルパラメータに基づいて, オブジェクトの存在の判別不可の状態におけるオブジェクトの存在を推定する。

③予測ステップ

学習ステップで得られたモデルパラメータに基づいて, 現時点以降の将来の任意の時刻におけるオブジェクトの存在確率を推定する。




図 3 隠れマルコフモデル

3. 動的に情報が更新される地図への適用

前章で示した隠れマルコフモデルを用いた高信頼な環境情報の構築手法を, 動的に情報が更新される地図へ適用する。図 4 に示すような構成を持つダイナミックマップ^{[4][5]}はこの地図の一例である。本研究で対象とするオブジェクトは, ダイナミックマップにおける準動的または準静的オブジェクトに対応する。

Highly dynamic data(< 1 sec)
ITS Read-ahead information(Nearby vehicle, Pedestrian, Signal, etc.)
Transient dynamic data(< 1 min)
Accident, Traffic jam, Narrow weather, etc.
Transient static data(< 1 hour)
Traffic regulation, Road Construction, Wide weather, etc.
Permanent static data(< 1 month)
Road Surface, Lane, 3-D structure, etc.

図 4 ダイナミックマップの構成

自動車の自動運転を例にとる。図 5 において, 自車両 A は自動運転車両であるとする。自車両 A 周辺の外部環境認識を自車両のみで行うと, 路上駐車され, 道路上の障害物となっている車両 C が先行車両 B による遮蔽で見えない場合がある。この場合, 先行車両 B が車線変更により車両 C を回避して初めて自車両 A が車両 C を認識することになる。この時, 例えば後続車両 D ~ F が来ると, スムーズな車線変更ができない状況に陥る可能性がある。このような状態を避けるため, 道路上を走行する個体間で, 環境情報を共有することにより, 余裕をもって車線変更することが望ましい。

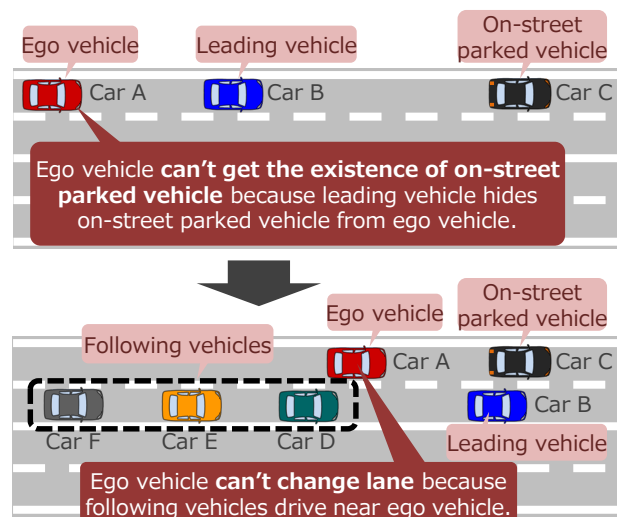


図 5 スムーズな車線変更ができない例

一方で、環境情報を単に共有すると、結果として無駄な制御をしてしまう可能性がある。図 6 に示すように、道路上の障害物となっている車両 C と自車両 A の距離が離れている場合、車両 C の情報の共有により予め車線変更をしたとしても、車両 C の位置を自車両 A が通過するときに車両 C が移動済みであれば、自車両 A の車線変更は無駄となる。

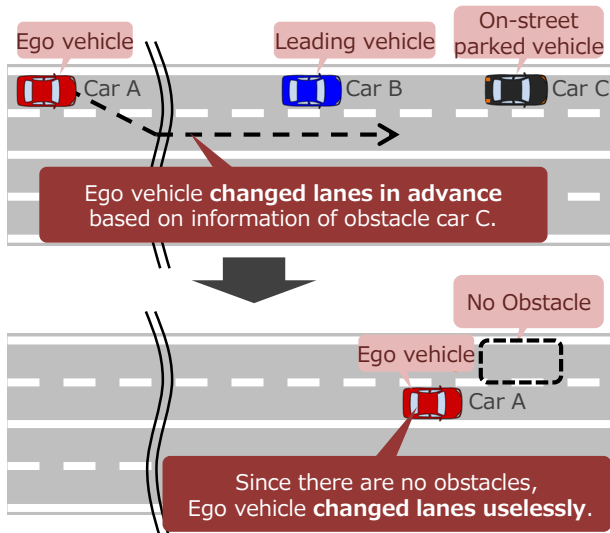


図 6 無駄な車線変更となる例

そこで本研究では、動的に情報が更新される地図に含まれるオブジェクト情報に対して、前章の手法を適用し、走行上の障害となりうるオブジェクトの存在情報を管理するデータベースを構築する。図 7 に提案手法を動的に情報が更新される地図へ適用する例を示す。図の上部は、自車両が破線で示される経路上を走行することを示している。図中の A から D は道路上の障害物となっているオブジェクトである。図のように、自車両はオブジェクト B とオブジェクト D の位置を通過する。これらのオブジェクトは過去に観測されているが、現時点以降の存在はわからないため、提案手法の①学習ステップにより学習された隠れマルコフモデルのモデルパラメータを用いて将来の存在確率を予測する。図 8 に予測の例を示す。

オブジェクトを初めて観測した時点 $t=0$ において、オブジェクトは存在するため、その存在確率は $x_1(0) = 1.0$ となる。1 ステップ経過後の $t=1$ においては、確率 a_{11} でオブジェクトが存在し続けるため、存在確率は $x_1(1) = x_1(0) a_{11}$ となる。さらに 1 ステップ経過後の $t=2$ では $x_1(2) = x_1(1) a_{11}$ 、 t_1 ステップ経過後の $t=t_1$ では、 $x_1(t_1) = x_1(t_1 - 1) a_{11}$ となる。これを一般化すると、 $t = t_1$ において、次式を得る。

$$x_1(t_1) = a_{11}^{t_1} \dots \dots \dots (5)$$

さらに、時刻ベースで考えると、時刻 T において初めて観測したオブジェクトについて、時刻 t におけるオブジェクトの存在確率 p は、次式にて演算する。

$$p = a_{11}^{(T-t)/s} \dots \dots \dots (6)$$

ここで s は 1 ステップあたりの所要時間である。これにより、図 7 下部に示されるように、オブジェクトは時間の経過に応じて存在確率が小さくなっていく。この存在確率に応じて、自車の走行時の障害となりうるオブジェクトの存在を推定する。ゆえに、図 5 に示したようなスムーズな車線変更ができない状況を回避するとともに、時間の経過を考慮することで、オブジェクトの位置に到達時には消えているようなオブジェクトを予測して、図 6 に示したような無駄な車線変更を解消することが可能となる。なお、このモデルパラメータは、オブジェクトの種別や道路の特徴、時刻などの他、交通ルール、交通状態に応じて保持することが望ましい。

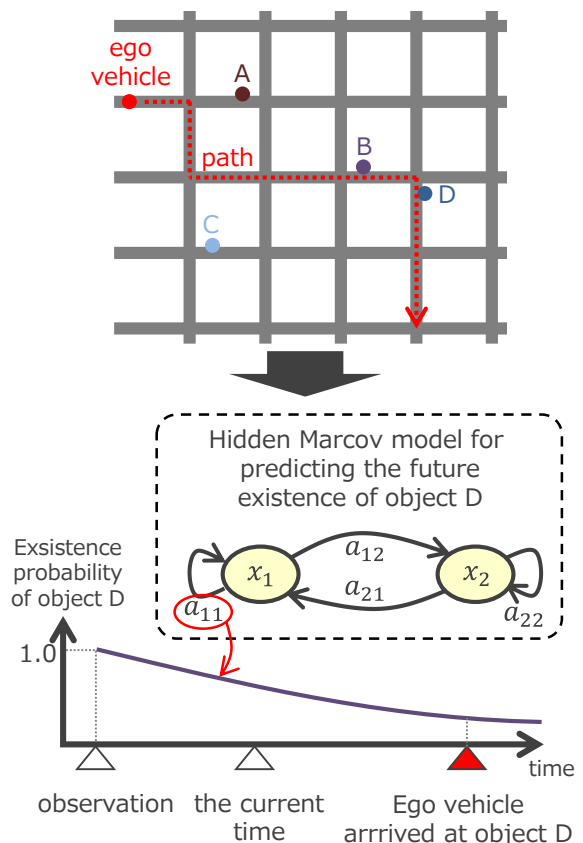


図 7 動的に情報が更新される地図への適用例




図 8 将来の存在確率の予測

このような動的に情報が更新される地図に提案手法を適用するにあたって、提案手法における学習ステップ①を実施できない場合がある。道路環境上を走行する車両が少ないと、観測情報が得られないため、モデルパラメータの学習は困難となる。学習ステップ①からモデルパラメータが得られないと、復号ステップ②や予測ステップ③も実施することができない。そこでこの課題に対して、オブジェクトの性質や環境に応じて、学習なしでモデルパラメータを設定する方法を提案する。

図 9 に示すようなオブジェクトが道路工事現場の場合、このオブジェクトは道路上に長時間存在する。このため、モデルパラメータの遷移行列 A を以下のように設定する。

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \dots\dots\dots(7)$$

上記の遷移行列では、一度観測すると、以後どの時刻においても存在確率は 1 となる。このオブジェクトが無くなったことを観測するまでは存在したと仮定し、再度遷移行列を学習すれば良い。




図 9 オブジェクトが工事現場の例

図 10 に示すような吹雪などによる視界不良の場合、オブジェクトの観測に影響が出る。前章にて述べたように、移動体に備えられた環境を認識するセンサが誤検知や不検知を含まない理想的なものであれば、 $b_{12} = b_{21} = 0$ となるが、図のような状況においては、状況に応じた誤検知率、不検知率を反映して出力行列を設定する。例えば、誤検知率が 3%、不検知率が 5% で、かつ道路上のオブジェクトに対して遮蔽が生じないことを仮定したとき、出力行列を以下のように設定する。

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \end{bmatrix} = \begin{bmatrix} 0.95 & 0.05 & 0.0 \\ 0.03 & 0.97 & 0.0 \end{bmatrix} \dots\dots\dots(8)$$




図 10 視界不良の例

図 11 に示すようなオブジェクトが踏切により停止している場合、踏切が開くまではその場に留まると推測される。踏切において、遮断機が下りてから上がるまでの時間は電車の運行計画や運転状況によって決まる。そこで、運行状況や運転計画の取得、またはこれまでの(曜日や時刻毎の)経験(実績)から、遮断機が上がるまでの時間 τ を取得し、次の式を解くことにより遷移行列の a_{11} を設定する。

$$a_{11}^{\tau} = \alpha \dots\dots\dots(9)$$

ここで、 α は $0 < \alpha < 1$ を満たす設計値であり、遮断機が下りてから上がるまでの時間 τ 経過後の存在確率である。例えば、 $\tau = 120$ 秒経過後の存在確率を 50% とし、隠れマルコフモデルの 1 ステップあたりの時間間隔を 1 秒とすると、 $a_{11}^{120} = 0.5$ を解けば良い。従って、 $a_{11} = 9.94 \times 10^{-1}$ となる。このとき、(3)式より、 $a_{12} = 5.76 \times 10^{-3}$ となる。このとき、遷移行列 A は以下となる。

$$A = \begin{bmatrix} 9.94 \times 10^{-1} & 5.76 \times 10^{-3} \\ a_{21} & a_{22} \end{bmatrix} \dots\dots\dots(10)$$

遷移行列における a_{21} 及び a_{22} は未定のままであるが、予測フェーズにおいては、 a_{11} の値がわかれば式よりオブジェクトの将来の存在確率を算出可能となる。

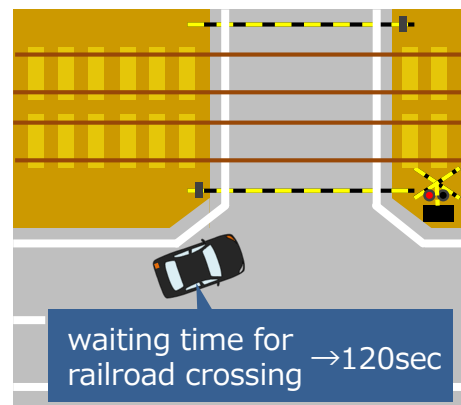


図 11 オブジェクトの要因が踏切の例

上記のようにオブジェクトの特徴に合わせてモデルパラメータを設定することで、学習ステップ①を実施できない場合にも対応することが可能となる。

4. おわりに

制御システムの高信頼化を実現するための高信頼な環境情報の推定技術を提案した。提案技術では、隠れマルコフモデルを用いることにより、欠落した観測情報(現況)を補充し、かつ将来の観測情報を推定することが可能となる。

また、本技術の動的に情報が更新される地図への適用にあたり、観測情報を得られない場合におけるオブジェクトの特徴に応じてモデルパラメータを学習なしで設定する手法を提案した。今後は実験等により本手法を評価する予定である。

参考文献

- [1] 金川, 人工知能の制御へのより安全な適用について, FIT2017, 1B-3, (2017).
- [2] 広津他, 深層学習を活用した高精度知能化制御の提案, FIT2017, 2D-1, (2017).
- [3] 中川, 組み込みシステム向け異常検知方式, FIT2017, 4E-7, (2017).
- [4] SIP-adus “SIP 自動走行システムの活動”, <http://www.sip-adus.jp/about/active/pdf/doc1.pdf> (2015).
- [5] 渡辺, 高木, 手嶋, 二宮, 佐藤, 高田, “協調型運転支援のための交通社会ダイナミックマップの提案”, 第 7 回データ工学と情報マネジメントに関するフォーラム講演論文集, (2015).