

交通流理論の状態空間モデルへの拡張

川崎洋輔¹・原祐輔²・桑原雅夫³

¹正会員 東北大学大学院 情報科学研究科 博士後期課程 (〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: kawasaki-y@plan.civil.tohoku.ac.jp

²正会員 東北大学大学院助教 情報科学研究科 (〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: hara@plan.civil.tohoku.ac.jp

³正会員 東北大学大学院教授 情報科学研究科 (〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: kuwahara@plan.civil.tohoku.ac.jp

本研究では、交通流理論モデルを状態空間モデルに拡張し、リアルタイムに交通状態を推定する手法を提案する。ベースとするシステムモデルは、交通流理論に基づいたVariational Theory(VT)を用いる。VTは、パラメータが固定されているモデルのため、逐次変化する交通状態をリアルタイムに推定することは困難である。そこで、本研究は、VTを状態空間モデルに拡張し、パーティクルフィルタにより、プローブ車両の軌跡データと同化させることで、リアルタイムな交通状態推定手法の構築を試みた。

Key Words : *kinematic wave theory, state space model, particle filter, probe vehicle trajectory*

1. はじめに

道路の交通状態を把握するセンサーとして古くから車両感知器がある。車両感知器は、全車両の交通量や速度の観測が可能であるが、観測箇所がセンサー設置点のみであり、区間としての状態の把握はできない。さらに高速道路は比較的密に設置されているが、街路は設置されていない場所が多いといった観測場所の制約もある。また、プローブデータは個々の車両の状態をリアルタイムに観測可能であるが、あくまで全車両の中のサンプルデータの位置づけである。

交通流理論に基づいたシミュレーションモデルは、車両感知器やプローブデータ等の観測データを入力することで、多様な現象を考慮でき、全車両の交通状態の推定が可能である。ただし、観測データを完全に再現するような完璧なシミュレーションモデルを構築することは困難である。こうした観測データとシミュレーションモデルの問題点を解決するために、観測データとシミュレーションモデルを統合してシミュレーションモデルの改善を図るデータ同化というアプローチ¹⁾がある。

本研究では、観測データと交通流理論のモデルを用いて、データ同化のアプローチでリアルタイムに全車両の交通状態を推定する手法を提案する。リアルタイムに交通流が把握できれば、動的な交通マネジメントへ貢献できる。

次に、本研究で用いる交通流理論のモデルについて述

べる。交通流理論モデルを効率的に計算する手法として、Daganzo²⁾によりVariational Theory (以降VTという)が提案されている。VTは、時空間上の累積交通量(車両軌跡)を解析的に推定する手法である。Mehran et.al.⁴⁾⁵⁾は、一般道を対象として、信号、車両感知器およびプローブデータをVTに取り込み、時空間上の累積交通量(車両軌跡)を推定する手法を提案している。本手法では、プローブ車両の速度低下状況を取り込むことで、渋滞を表現している。しかしながら、本手法では、区間途中で出入りのない状態であっても、プローブ車両間の軌跡に不自然なギャップが生じることがわかっている。VTでは、入力データであるFundamental Diagram(以降FDという)に基づき全車両は、同じ速度で走行するものとし、累積交通量が計算される。しかしながら、実際は、各車両の速度はばらばらな状態であるため、FDの設定速度と実際の車両速度との間で誤差が生じる。この誤差が時間推移に応じて拡大するため、モデルと観測データで乖離が生じ、ギャップが発生していると考えられる。

そこで、本研究では、区間途中で出入りのない一般道を対象として、VTを状態空間モデルに拡張し、データ同化することで、交通流理論のモデルと観測データの乖離の改善を試みた。

最後に、交通分野におけるデータ同化やリアルタイム交通状態推定関連の研究と本研究の位置づけについて整理する。Chen et al.⁶⁾は、高速道路を対象に、観測旅行時間(最新データ)とアーカイブされた過去の旅行

時間変動を評価する尤度関数を構築し、現在の旅行時間と類似性の高い過去の旅行時間変動をパターンマッチングし、リアルタイムな旅行時間推定(短期予測)を試みている。Donga et al.⁷⁾は、都市高速道路ネットワークを対象とし、非渋滞時のフローレートや渋滞時の速度を推定する状態空間モデルを提案している。その他、プローブデータや車両感知器データを融合解析し、交通量や旅行時間、速度等を推定している研究は幾つかあり⁸⁾、これらの推定手法を体系的に整理した論文⁹⁾もある。

いずれの研究もアクセスコントロールされた高速道路を対象とし、交通状態として、交通量や旅行時間または速度を推定している。本研究は、一般道路を対象とし、推定する交通状態を時空間上の累積交通量(車両軌跡)としている点が異なる。

2. 本研究における状態空間モデルの考え方

(1) 一般状態空間モデルについて

一般状態空間モデル(以降、状態空間モデルという)とは、時系列モデルの枠組のモデルである。状態ベクトル \mathbf{x}_t と観測ベクトル \mathbf{y}_t で構成される。状態ベクトルは、観測出来ない変数のベクトルであり、観測ベクトルは、観測値により構成されたベクトルである。状態空間モデルでは、状態ベクトルと観測ベクトルとの関係を表した観測モデルと、状態ベクトルの時間推移を表したシステムモデルとを、それぞれ条件付き分布としてモデル化する。そして、時刻 t までの観測ベクトルが得られた時に、事後分布を算出し、事後分布を最大化するような状態ベクトルを推定する。観測モデル、システムモデルの関係のグラフィカル表現を図-1に示す。事後分布 $p(\mathbf{x}_t | \mathbf{y}_t)$ は、図-1のモデルの仮定とベイズの定理より式(1)のように示される。

$$p(\mathbf{x}_t | \mathbf{y}_t) \propto p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) \\ = p(\mathbf{y}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) d\mathbf{x}_{t-1} \quad (1)$$

右辺の中で、 $p(\mathbf{y}_t | \mathbf{x}_t)$ は観測モデル、 $p(\mathbf{x}_t | \mathbf{x}_{t-1})$ はシステムモデル、 $p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})$ は、 $t-1$ 時(1期前)における推定結果を示す。

以上より、状態空間モデルでは、観測モデル、システムモデルの構築と事後分布の計算手法の検討(積分の具体的な計算方法の構築)が必要である。

(2) 本研究における状態空間モデルの仮定

まず、システムモデルの状態ベクトルを定義する。

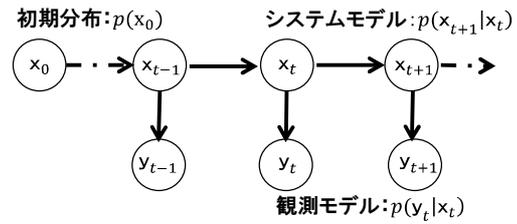


図-1 システムモデルと観測モデル

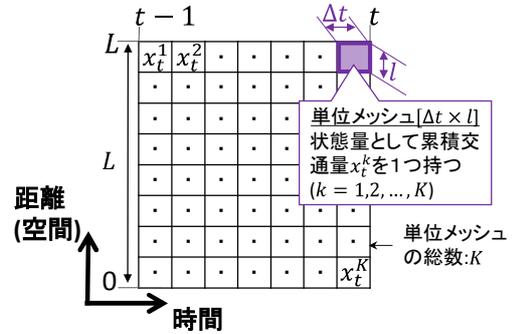


図-2 t 時の状態空間(時空間メッシュ)

本研究では、システムモデルの状態量を時空間上の累積交通量と定義する。

システムモデルのスキャンインターバルのインデックスを t と定義する。以降のシステムモデルの時間推移は、 $\{..t-2, t-1, t, t+1, t+2.. \}$ のように表現する。

$t-1 \sim t$ および距離 $0 \sim L$ で囲まれた時空間を考える。その時空間を単位時間 Δt 、単位距離 l で分割する。この $\Delta t \times l$ のメッシュを単位メッシュと定義する。この単位メッシュで構成された時空間を t 時の状態空間(以降時空間メッシュという)として定義する(図-2)。単位メッシュは一つの累積交通量(状態量) $x_t^{(k)}$ を持つと仮定する。 t はシステムモデルのスキャンインターバルのインデックス、 k は時空間メッシュに存在する単位メッシュのインデックスを示す。そして、 t 時の時空間メッシュにおける $x_t^{(k)}$ の集合を状態ベクトル \mathbf{x}_t と定義する。 t 時に単位メッシュが K 個あるとすると、状態ベクトル \mathbf{x}_t は K 次元のベクトルとして、以下のように示される。

$$\mathbf{x}_t = (x_t^{(1)} \dots x_t^{(k)} \dots x_t^{(K)})^T \quad (2)$$

ここで、 $k = 1, 2, \dots, K$ である。

次に、観測ベクトルを定義する。観測値は、システムモデルと同様の時空間メッシュにおいて単位メッシュごとに観測される累積交通量と定義する。なお、1つの単位メッシュでは、1つの観測値しか観測できないものと仮定する。観測値の数は時間 t に依存するため、 t 時の

時空間メッシュにおける観測値の数を M_t 個と表現する。そうすると、観測ベクトル \mathbf{y}_t は M_t 次元のベクトルとして以下のように示される。

$$\mathbf{y}_t = (y_t^{(1)} \dots y_t^{(m)} \dots y_t^{(M_t)})^T \quad (3)$$

$$K \geq M_t \quad (4)$$

ここで、 m は t 時の観測値のインデックスであり、 $m = 1, 2, \dots, M_t$ である。 t はシステムモデルのスキャンインターバルのインデックスを示す。式(4)に示す通り、一般的には、 $K \geq M_t$ となる。そこで、観測モデルでは、状態量の全変量から観測される変量を取り出すような $K \times M_t$ の観測行列 H_t を導入する。観測行列内の値は、データが観測されれば1、観測されなければ0をとるものと定義する。例えば、 t 時において、以下に示す3次元($K = 3$)の状態ベクトル \mathbf{x}_t 、 $x_t^{(k)}$ のインデックス $k = 1, 2$ に対応した観測値が得られた場合 ($M_t = 2$) の観測ベクトル \mathbf{y}_t を考える。

$$\mathbf{x}_t = (x_t^1 \quad x_t^2 \quad x_t^3)^T \quad (5)$$

$$\mathbf{y}_t = (y_t^1 \quad y_t^2)^T \quad (6)$$

状態ベクトル、観測ベクトルが式(5)、(6)のように与えられた場合、 t 時の観測行列 H_t は、以下の通り 3×2 の行列となる。

$$H_t = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} \quad (7)$$

状態ベクトル \mathbf{x}_t と観測ベクトル \mathbf{y}_t の対応イメージを図-3に示す。以上より本研究では、非線形のシステムモデル、線形の観測モデルを仮定し、以下のように示す。

$$\mathbf{x}_t = f(\mathbf{x}_{t-1}, \mathbf{v}_t) \quad (8)$$

$$\mathbf{y}_t = H_t \mathbf{x}_t + \mathbf{w}_t \quad (9)$$

ここで、 \mathbf{v}_t はシステムノイズ、 $f(\cdot)$ はシステムモデルの関数である。 H_t は観測行列、 \mathbf{w}_t は観測ノイズである。システムモデルの関数は、交通流理論をベースとしたVTを用いる。VTは、 $t-1$ 時の状態空間の累積交通量を基に、 t 時の累積交通量(全ての単位メッシュの累

積交通量)を算出できるモデルである。VT、システムノイズ、観測ノイズ等の内容については後述する。

(3) 事後分布(フィルタリング)の計算方法

本研究では、パーティクルフィルタにより事後分布を求める。パーティクルフィルタとは、時系列フィルタの一つで、事前分布や事後分布(条件付き分布)を多数のパーティクル(サンプル)でモンテカルロ近似表現するものである¹⁾²⁾¹⁰⁾。カルマンフィルタの強い制約を無くし、非線形モデルや非正規分布のノイズであっても適用可能といった特徴がある。パーティクルフィルタでは、式(8)(9)で示した状態空間モデルを用いて以下の手順で対象の状態推定を行う。

- 1) 初期分布 $p(\mathbf{x}_0)$ に従い、初期状態 $\mathbf{x}_{00}^{(i)}$ ($i=1, 2, \dots, N$) のパーティクルを生成
- 2) システムモデルにより各パーティクルの一期先の状態 $\mathbf{x}_{t|t-1}^{(i)}$ を予測
- 3) 観測モデルに対応する尤度関数 $p(y_t | x_t^{(i)})$ より、各パーティクルの重み $\omega_t^{(i)}$ を算出
- 4) 算出した重み $\omega_t^{(i)}$ に応じて、パーティクルを復元抽出し、パーティクル $\mathbf{x}_{t|t}^{(i)}$ をリサンプリング
- 5) $t = t+1$ とし、計算終了まで2)~4)を繰り返す。

ここで、 i はパーティクルのインデックスを示す。パーティクルフィルタのサイクルを図-4に示す。

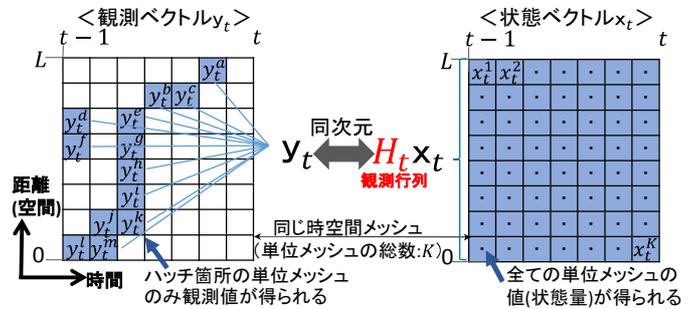


図-3 観測ベクトルと状態ベクトルの対応イメージ

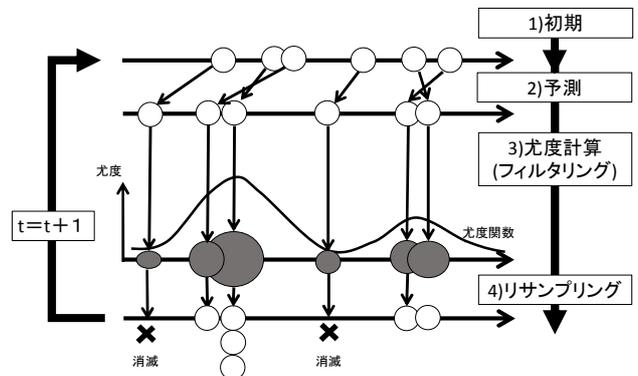


図-4 パーティクルフィルタのサイクル

※参考文献2)に掲載されている図を基に作成

(4) 予測結果の算出

本研究における状態変量 \mathbf{x}_t の予測値は、事後分布の平均値(事後平均値)を出力する。

3. 状態空間モデルの構築

(1) VT(Variational Theory)の概要

ここでは、VTの概要について説明する。VTの詳細な内容については、参考文献3)4)5)を参照されたい。

まず、時空間上にFDを配置した時空間ネットワークを考える。FDの頂点をノード、ノード間を接続する辺をリンクとし、各リンクにコスト(累積交通量)を付与する。そして、ノード間の最短経路探索によりタイムスペース上のノードの累積交通量を算出する。例えば、ネットワーク上の任意の2点のノードBPを考える。なお、B点での時刻を t_B 、P点での時刻を t_P とするとBP間の時刻の関係は、 $t_B < t_P$ である。P点における累積交通量は式(10)により算出される。

$$NP = \inf_B \{NB + \Delta BP\} \quad (10)$$

ここで、NP、NBはそれぞれノードB,Pにおける累積交通量、 ΔBP はB~P間のコスト(最短経路コスト)を示す。式(10)は、ノードBの累積交通量を境界条件として与え

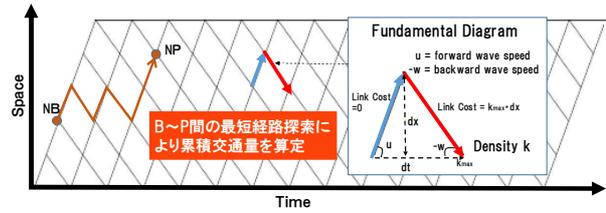


図-5 VTによる累積交通量の算出

ればノードPの累積交通量を一意に算出できることを示している。このようにVTは、境界条件等の入力データが変化しなければ、一意の解が得られるモデルである。VTにより全ノードの累積交通量を算定した後に累積交通量が同じ点を結んでいけば車両軌跡となる。VTによる累積交通量の算出イメージを図-5に示す。

(2) システムモデル

VTを活用したシステムモデルの内容について述べる。システムモデルは、状態ベクトル \mathbf{x}_{t-1} と \mathbf{x}_t の時間推移(一期先予測)を表現し、システムノイズにより、 \mathbf{x}_t の予測分布を生成するモデルである。ここでは、提案するシステムモデルを時間推移と、予測分布の生成の2段階に分けて説明する。

まず、時間推移のイメージについて説明する。説明を簡単にするために、システムノイズを与えない通常のVT(出力される解が一意)をシステムモデルとして考える。時間推移を、 $\{0, t-1, t, t+1\}$ とする。

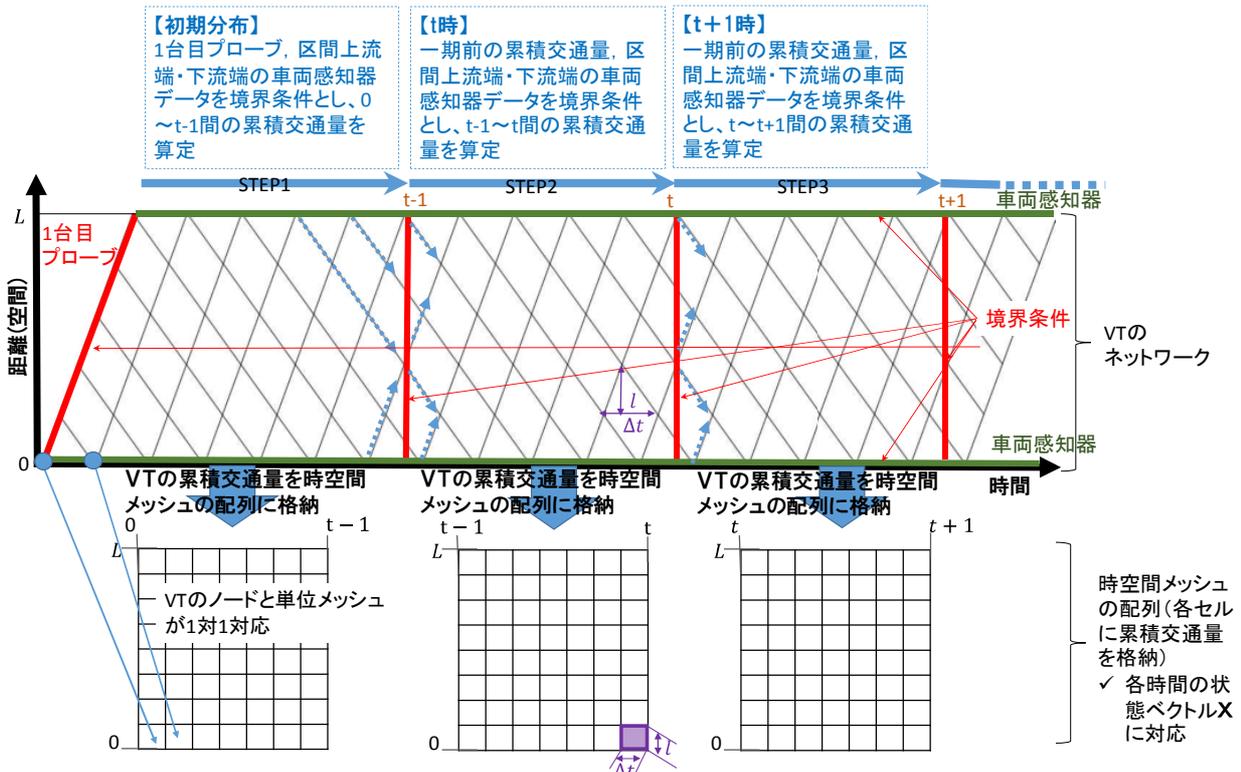


図-6 システムモデル(VT)の時間更新イメージ

まず、初期段階の $t-1$ 時($0 \sim t-1$)では、区間上流端・下流端の車両感知器データ(累積交通量)と対象区間を通過する1台目のプローブ上の軌跡上の単位メッシュの累積交通量を1台と仮定し、それらを境界条件として与えて、初期状態の累積交通量を算出する。そして算出された各ノードの累積交通量を、時空間メッシュの配列に格納し、対象時間を1ステップ推移させる。 t 時($t-1 \sim t$)では、一期前の累積交通量、区間の上流端・下流端の車両感知器の累積交通量を境界条件として与え、対象エリア内の累積交通量を求める。そして、初期と同様に時空間メッシュ配列にデータを格納し、時間を1ステップ推移させる。この t 時の時空間メッシュ配列の累積交通量は、式(2)で定義した状態空間ベクトル \mathbf{x}_t に対応する。 $t+1$ 時($t \sim t+1$)においても同様に t 時の累積交通量と区間上流端・下流端の車両感知器を境界条件とし、累積交通量を求め、その結果を配列に格納し、次の時間ステップに推移する。以上の操作を繰り返すことで、システムモデルの時間を推移させる。以上のシステムモデルの時間推移のイメージを図-6に示す。

次に、予測分布の生成方法を説明する。前節でも述べたようにVTは1パターンを入力データに対して解を一意に算出するモデルである。したがって、仮にVTに確率的にデータを入力することが出来れば、解が確率的に出力されると考えられる。そこで本研究では、確率的に与える入力データ(システムノイズ)として、予め様々なパターンのFDを生成しておき、VTでの計算時に確率的にFDを選択して入力するシステムモデルを提案する。FDの選択方法は次節で説明する観測モデルの尤度の大きさに応じて確率的に選択する。例えば、尤度の高い状態ベクトル \mathbf{x}_t の入力データとなったFDは、高い確率で選択される。これらの処理は、パーティクルフィルタにおけるリサンプリングのステップに相当する。なお、このシステムモデルでは、FDの他に1台目プローブ車両軌跡データと対象区間の上流端と下流端にある車両感知器データ(累積交通量)を境界条件として入力する。システムモデルの出力イメージを図-7に示す。

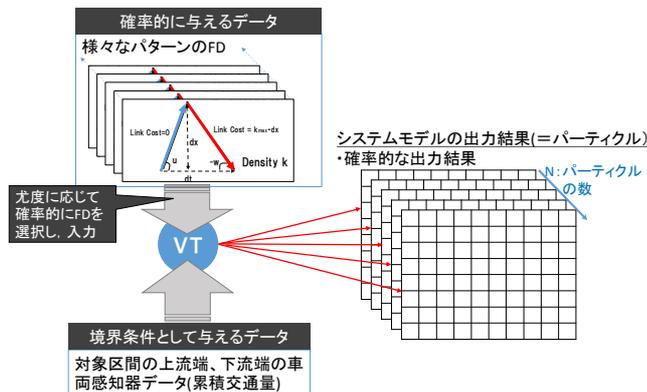


図-7 システムモデル出力イメージ

(3) 観測モデル

ここでは、観測モデルの内容について述べる。本研究における観測モデルの設定条件を以下に示す。

- ・ 観測値を取得するためのセンサーは、プローブ機器(GPS)と区間上流端・下流端の車両感知器とする。
- ・ 観測値は、システムモデルの1スキャンインターバル(例えば、 $t-1 \sim t$)間に走行するプローブ車両軌跡上の累積交通量とする。
- ・ 観測対象とするプローブ車両は対象区間の上流端から流入してきたもののみとする。(区間途中で流入してきたプローブ車両は対象外)
- ・ プローブ車両軌跡に対応した、単位メッシュごとの累積交通量(y_1, y_2, \dots, y_n)が観測されると仮定する。この観測値 y の集合が、式(3)で定義した観測ベクトル \mathbf{y}_t である。
- ・ 区間途中での出入り交通はないと仮定する。そのため、プローブ車両軌跡上の累積交通量は、観測誤差がなければ上流の車両感知器の累積交通量に等しい。
- ・ 観測ベクトルは、式(9)に示すように状態ベクトルに観測誤差が付与されたものが観測されると仮定する。
- ・ 単位メッシュごとの観測値(y_1, y_2, \dots, y_n)の、観測誤差は、独立な正規分布 $N(0, \sigma^2)$ と仮定する。

t 時の時空間メッシュにおいて、プローブ車両が1台走行した場合の累積交通量の観測イメージを図-8に示す。

上記と式(3)、(9)より、尤度関数は以下のように示される。

$$p(\mathbf{y}_t | \mathbf{x}_t) = \prod_{m=1}^{M_t} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2} (y_t^{(m)} - (H_t \mathbf{x}_t)^{(m)})^2\right\} \quad (11)$$

ここで、 σ^2 は正規分布の分散、 m は観測値のインデックス、 M_t は t 時の観測値の数を示す。また、 $(H_t \mathbf{x}_t)^{(m)}$ は $H_t \mathbf{x}_t$ の m 番目の要素を示す。

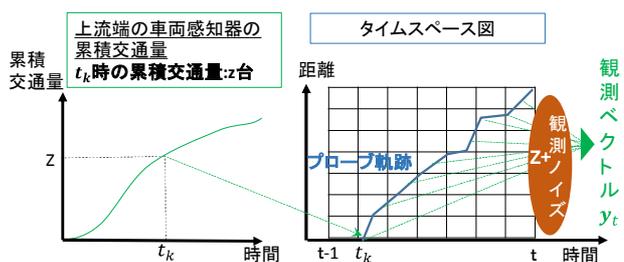


図-8 プローブ車両軌跡による累積交通量の観測イメージ

(4) 交通状態推定アルゴリズム

(1)~(3)節で述べた内容を踏まえ、図-9に本研究で提案する交通状態推定手法のアルゴリズムを示す。

4. ケーススタディによる提案手法の動作確認

ここでは、提案した手法を実フィールドへ適用し、提動作確認を行った。

適用対象は、東京都駒沢通り(延長1.2kmの区間)の2006年9月1日の8:45~9:15の30分間とした。なお、対象時間において区間途中の交差点での出入り交通量は、数台程度となっており、交通流に大きな影響は与えない状況であった。パーティクル数は1,000とした。システムモデルの入力データは、区間上下端の車両感知器、信号現示データとFDとした。FDは、既往手法において最も交通流の再現値の高かったものをベースに最大捌け量をランダムに変化させた1,000パターンを生成した。観測データは、同区間を走行するプローブ車両4台の軌跡データを用いた。

既往手法⁹⁾で推定した車両軌跡を図-10、提案した手法による車両軌跡の推定結果を図-11に示す。この結果を見ると、既往手法において生じていたギャップが提案手法においては、解消していることがわかる。

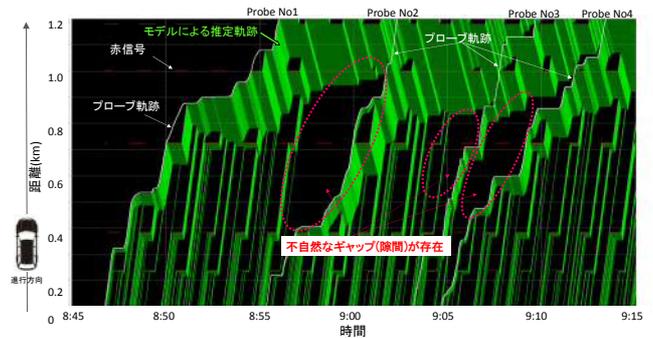


図-10 既往手法による車両軌跡推定結果

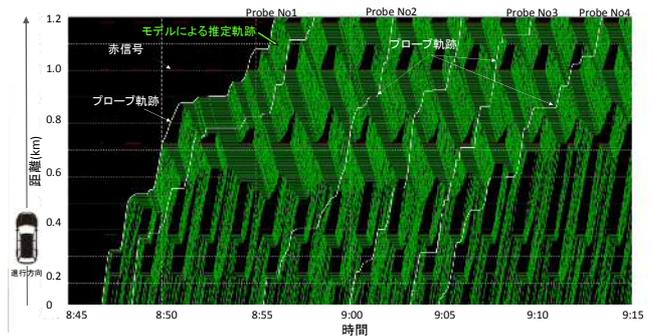


図-11 提案手法による車両軌跡推定結果

Input Data:

- ネットワーク条件(区間延長)
- 信号現示データ
- 区間上流端・下流端の車両感知器データ(累積交通量)
- プローブ車両軌跡データ
- パーティクル数: N
- 多様なパターンの $FD^{(i)}(i = 1, 2, \dots, N)$

STEP1:初期状態のパーティクル生成

- $t = 0$
- $FD^{(i)}$ の選択確率を一律 $1/N$ にセット
- [for: $i = 1 \sim N$] 1台目プローブ車両軌跡、車両感知器データおよび $FD^{(i)}$ を入力データとして、システムモデルにより初期状態のパーティクル $x_{i0}^{(i)}$ (時空間メッシュの累積交通量) を生成

STEP2:予測分布の生成

- [for: $i = 1 \sim N$] 下記データを入力し、システムモデル(VT)により状態ベクトル $x_{i|t-1}^{(i)}$ を算出
 - ✓ 1期前の状態ベクトル $x_{i|t-1}^{(i)}$ 、車両感知器データ
 - ✓ 確率的に選択された $FD^{(i)}$ のデータ

STEP3:尤度の算定

- プローブ車両が観測された場合、以下の手順で尤度を算定、観測されない場合は、STEP5へ
- [for: $i = 1 \sim N$] 尤度関数により、パーティクルの重み $\omega_t^{(i)}$ を算出
- [for: $i = 1 \sim N$] 重み $\omega_t^{(i)}$ を正規化した $\phi_t^{(i)}$ を算定 ($FD^{(i)}$ の選択確率を $\phi_t^{(i)}$ に更新)

STEP4:リサンプリング(for: $i = 1 \sim N$)

- [for: $i = 1 \sim N$] $\phi_t^{(i)}$ の大きさに応じて、パーティクルを復元抽出し、リサンプリング ($FD^{(i)}$ を確率的に選択)

STEP5:時間ステップの推移

- $t = t + 1$ とし、計算終了までSTEP2~STEP4を繰り返す。

注1) i はパーティクルのインデックス
 注2) [for: $i = 1 \sim N$] が文頭に記載されている処理は、処理を N 回繰り返す(パーティクルのインデックスを $1, 2, \dots, N$ まで更新すること)を示す

図-9 交通状態推定アルゴリズム

5. おわりに

本研究では、交通流理論に基づいたVTを状態空間モデルに拡張し、一般道の時空間上の累積交通量(車両軌跡)をリアルタイムに推定する手法を提案した。今後の課題は以下のように考える。

1) クロスバリデーションの実施

本稿では、提案手法を駒沢通りに適用し、モデルの動作検証を行った。本手法の妥当性を検証するには、様々なシチュエーションにおけるモデルの精度検証が必要である。そのため、以下の方法でモデル検証を行う。

マイクロ交通流シミュレーションにより、全車両の車両軌跡が既知のデータを生成する。その車両軌跡データから観測データをランダムに抽出する。抽出した車両軌跡データを用いて、残りの車両軌跡を本手法により推定し、推定精度を分析する。これを複数回繰り返す、モデルの精度検証(クロスバリデーション)を行う。あわせて、既往の時系列モデル等との精度比較も必要と考える。

2) 区間途中の出入り交通量の考慮(モデルの高度化)

本稿では、区間途中の出入り交通量はないと仮定し、手法の構築を行った。しかしながら、実際の一般道では、交差点や沿道施設からの出入りが存在する。そのため、出入り交通量の影響を考慮したシステムモデルの構築が

必要である。本稿で提案したシステムモデルは、時空間上の累積交通量を推定するものであり、区間途中の出入り交通量の影響を累積交通量の変化で加味することも可能と考える。あわせて区間途中で合流したプローブ車を評価する観測モデル(尤度関数)を構築することも必要と考える。

3) 様々な地域への展開

本稿で提案した手法を様々な地域に適用し、モデル性能を検証するとともに、新たな課題の抽出・対応を行うことが必要と考える。

謝辞: 研究に際し、三谷卓摩助教(東北大学)、堀口良太氏(株式会社アイ・トランスポート・ラボ)より貴重な意見をいただいた。また、本研究は、独立行政法人 情報通信研究機構(NICT)の「ソーシャル・ビッグデータ利活用・基盤技術の研究開発(課題 178A09)」および平成 26 年度 戦略的創造研究推進事業 (CREST, JST)の「大規模・高分解能数値シミュレーションの連携とデータ同化による革新的地震・津波減災ビッグデータ解析基盤の創出」プロジェクトより助成を受けたものである。ここに記して感謝の意を表す。

参考文献

- 1) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田亮: データ同化入門—次世代のシミュレーション技術—, pp.47-77, 朝倉書店, 2011
- 2) 樋口知之: 予測にいかす統計モデリングの基本—ベイズ統計入門から応用まで—, pp63-93, 講談社, 2012.
- 3) Daganzo, C. F.: On the Variational Theory of Traffic Flow: Well-Posedness, Duality and Applications, American Institute of Mathematical Sciences, Vol. 1, No.4, pp.601-619, 2006.
- 4) Mehran, B., Kuwahara, M. and Naznin, F.: Implementing Kinematic Wave Theory to Estimate Vehicle Trajectories from Fixed and Probe Sensor Data, Transportation Research Part C 20(2012) 144-163, 2012.
- 5) Mehran, B. and Kuwahara, M.: Fusion of probe and fixed sensor data for short-term traffic prediction in urban signalized arterials, Special Issue for the International Journal of Urban Sciences on Urban Transportation, DOI:10.1080/12265934.2013.776291, 2013.
- 6) Chen, H. and Rakha, H. A.: Real-time travel time prediction using particle filtering with a non-explicit state-transition model, Transportation Research Part C 43 (2014) 112-126, 2014.
- 7) Donga, C., Shaob, C., Richardsa, S. H. and Hanc, L. D.: Flow rate and time mean speed predictions for the urban freeway network using state space model, Transportation Research Part C 43 (2014) 20-32, 2014.

- 8) 例えば, Patirea, A. D., Wrighta, M., Prodhommea, B. and Bayenb, A. M.: How much GPS data do we need?, Transportation Research Part C (2015), 2015.
- 9) Vlahogianni, E. I., Karlaftis, M. G. and Golias, J. C.: Short-term traffic forecasting: Where we are and where we're going, Transportation Research Part C 43 (2014) 3-19, 2014.
- 10) Kitagawa, G.: Monte Carlo Filter and Smoother for Non-Gaussian Nonlinear State Space Models, Journal of Computational and Graphical Statistics, Vol. 5, No. 1, pp. 1-25, 1996.

(2015.4.24 受付)