パラメータ推定のためのデュアルフィルタの設計と

動的交通流推定への適用に関する考察

Design of Dual Filtering Framework for Parameter Estimation and its Application to Dynamic Traffic Flow Estimation

北海道大学大学院工学院	○学生員	小林	岡山	(Takashi Kobayashi)
北海道大学大学院工学研究院	正 員	中辻	隆	(Takashi Nakatsuji)

1. はじめに

ノイズを含むモデルを用いて、状態変量の推定を行う 際、カルマンフィルタに代表されるような、観測変量に よる補正を加えたフィードバック推定が有効である。さ らに、モデル内に事前設定の難しい未知のパラメータが 含まれている場合や、ノイズの分散値が大きく状態推定 に困難が生じる場合は、このパラメータ値やノイズの分 散値にもフィードバックをかけることができる。

このように、パラメータ値を状態変量と同時に推定し ていく際には、デュアルフィルタなる方法論が有効であ ると考えられる。

本稿では、まずフィードバック推定法の代表例、拡張 カルマンフィルタ、Unscented カルマンフィルタ、パー ティクルフィルタの手法論とその特色について述べ、モ デル内にパラメータ推定およびノイズの分散推定を内在 したデュアルフィルタについて提案する(第2章)。次 に、ケーススタディとして解析関数を用いての出力例と、 それに関する考察を述べる(第3章)。さらに、この結 果を元に、マクロ交通流モデルに適用するためのモデリ ングについて述べる(第4章)。最後に、まとめと今後 の課題・展開について述べる(第5章)。

2. フィードバック推定法

2-1. 状態空間モデル

フィードバック推定を行う際には、状態空間モデルとして、状態方程式(式(1))と観測方程式(式(2))を設 定する。

状態方程式: $\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}) + \mathbf{v}_k$	(1)
---	-----

観測方程式: $y_k = g(x_k) + w_k$ …(2) f(*)は非線形状態遷移行列関数であり、時刻 k から時刻 k+1 への状態変量 x_k の時間変動を表す。g(*)は非線形観 測行列関数であり、 x_k と観測変量 y_k の関係を表す。こ れらは、交通状態の推定においては、通常マクロ交通流 モデルで表される事が多い。また、 v_k は時間変化に関す る誤差行列、 w_k は観測誤差行列である。

2-2. 拡張カルマンフィルタ (EKF)

フィードバック推定法の代表例は、カルマンフィルタ ¹⁾ (Kalman Filter: KF) である。KF は 1960 年代に提唱さ れた方法論であり、コンピュータが発達する以前から一 般的となってきた。しかし、KF は線形事象しか取り扱 うことができないという点で制限が強く、実際に発生す る非線形の諸事象に対応するため、改良が数多く行われ てきている。その例としては、まず拡張カルマンフィル タ²⁾ (Extended Kalman Filter: EKF) が挙げられる。EKF では、状態方程式と観測方程式の両式にテイラー展開に よる一次近似を行い、非線形事象を線形化して計算を行 う。

$$\mathbf{x}_k \cong \mathbf{A}_{k-1}\mathbf{x}_{k-1} + \mathbf{p}_{k-1} + \mathbf{v}_{k-1} \qquad \cdots (3)$$

$$\mathbf{y}_k \cong \mathbf{C}_k \mathbf{x}_k + \mathbf{q}_k + \mathbf{w}_k \qquad \cdots (4)$$

$$\mathbf{A}_k = \frac{\partial \mathbf{f}}{\partial \mathbf{x}}$$
 $\mathbf{C}_k = \frac{\partial \mathbf{g}}{\partial \mathbf{x}}$ (5)

なお、 \mathbf{p}_k と \mathbf{q}_k は定数項である。

A

ここで、線形制限のあった KF を適用する場合、モデ ルによって予測される状態変量 \mathbf{x}_k と観測変量 \mathbf{y}_k の予測 値を式(6)および式(7)のように表すならば、状態変量は 式(8)に従って補正が行われ、推定値が算出される。

$\tilde{\mathbf{x}}_k = \mathbf{f}(\hat{\mathbf{x}}_{k-1}) + \mathbf{v}_k$	(6)
$\tilde{\mathbf{v}}_{i} = \mathbf{\sigma}(\tilde{\mathbf{v}}_{i}) \pm \mathbf{w}_{i}$	(7)

$\tilde{\mathbf{y}}_k =$	$= \mathbf{g}(\mathbf{\tilde{x}}_k)$	$+ \mathbf{w}_k$	•••((7)

 $\hat{\mathbf{x}}_k = \tilde{\mathbf{x}}_k + \mathbf{K}_k (\mathbf{y}_k - \tilde{\mathbf{y}}_k)$ …(8) K はカルマンゲインとよばれ、式(9)から式(13)によって 導かれる。

$$\mathbf{M}_{k}^{xx} = \mathbf{A}_{k-1} \mathbf{P}_{k-1} \mathbf{A}_{k-1}^{T} + \mathbf{V}_{k-1} \qquad \cdots (9)$$

$$\mathbf{M}_{k}^{xy} = \mathbf{M}_{k}^{xx} \mathbf{C}_{k}^{T} \qquad \cdots (10)$$

$$\mathbf{M}_{k}^{yy} = \mathbf{C}_{k} \mathbf{M}_{k}^{xx} \mathbf{C}_{k}^{T} + \mathbf{W}_{k} \qquad \cdots (11)$$

$$\mathbf{K}_{k} = \mathbf{M}_{k}^{xy} (\mathbf{M}_{k}^{yy})^{-1} \qquad \cdots (12)$$

$$\mathbf{P}_{k} = \mathbf{M}_{k}^{xx} - \mathbf{K}_{k} \mathbf{C}_{k} \mathbf{M}_{k}^{xx} \qquad \cdots (13)$$

 V_k および W_k は、誤差項であった v_k および w_k の共分散 行列であり、 M_k および P_k はそれぞれ状態変量の予測値 $\hat{\mathbf{x}}_k$ と推定値 $\hat{\mathbf{x}}_k$ の誤差の共分散行列を表している。この フィードバック推定法による推定フローを図 2-1 に示す。



図 2-1 フィルタによるフィードバック推定法

2-3. Unscented カルマンフィルタ (UKF)

EKF については、主に二つの問題点が指摘されている。

(1) 非線形性の強い現象においては誤差が大きくなる。

(2) 微分演算が不可能なシステムへの導入は難しい。

EKF に代わるフィードバック推定法の一つとして挙 げられるのが、Unscented カルマンフィルタ²⁾³⁾(UKF: Unscented Kalman Filter)である。UKF では微分演算を ...(15)

必要とせず、複雑なモデル構造への導入が可能となって いる。

N 次元の状態変量 x の平均値(つまり、推定された値) を $\hat{\mathbf{x}}_k$ とすれば、先程と同様 $\hat{\mathbf{x}}_k$ の誤差の共分散行列を \mathbf{P}_k とする。この P_k をコレスキー分解し、下三角行列の i列番目の平方根を σ; としたとき、以下のように、シグ マポイントとよばれるサンプル点を発生させる。

$$\boldsymbol{\sigma}_{i,P} = (\sqrt{(N+\lambda)}\mathbf{P}_k)_i \qquad \cdots (14)$$

$$\widehat{\Phi}_{0,k-1} = \widehat{\mathbf{x}}_0$$

$$\widehat{\Phi}_{i,k-1} = \widehat{\mathbf{x}}_{k-1} + \boldsymbol{\sigma}_{i,P} \quad (i = 1, \cdots, N) \quad \cdots (16)$$

$$\Phi_{i,k-1} = \hat{\mathbf{x}}_{k-1} - \boldsymbol{\sigma}_{i-N,P} \quad (i = N+1, \cdots, 2N) \quad \cdots (17)$$

$$\mathbf{\Phi}_k = \mathbf{f}(\mathbf{\Phi}_{k-1}) \qquad \cdots (18)$$

なお、λ はスケーリングパラメータであり、この変換を Unscented 変換(UT: Unscented Transform)と定義する。

UKF においては、この UT によって算出されたシグ マベクトル $\tilde{\Phi}_k$ を用いて、 $\tilde{\mathbf{x}}_k$ と \mathbf{M}_k^{xx} を統計的に算出する ことができる。

$$\tilde{\mathbf{x}}_k = \sum_{i=0}^{2n} h_i \tilde{\Phi}_k \qquad \cdots (19)$$

 $\mathbf{M}_{k}^{xx} = \sum_{i=0}^{2n} h_{i} [\tilde{\Phi}_{i,k} - \tilde{\mathbf{x}}_{k}] [\tilde{\Phi}_{i,k} - \tilde{\mathbf{x}}_{k}]^{T} + \mathbf{V}_{k-1} \cdots (20)$ なお、h;はあらかじめ決められた重み定数である。

同じ要領でシグマベクトル $\tilde{\Psi}_k$ と $\tilde{\Omega}_k$ を定義して、 \tilde{y}_k 、 \mathbf{M}_{k}^{yy} 、 \mathbf{M}_{k}^{xy} を算出することができる。

 $\mathbf{\sigma}_{i,M} = (\sqrt{(N+\lambda)\mathbf{M}_k})_i$...(21)

$$\widetilde{\Omega}_{0,\mathbf{k}} = \widetilde{\mathbf{x}}_0 \qquad \cdots (22)$$

$$\widehat{\Omega}_{i,k} = \widetilde{\mathbf{x}}_k + \boldsymbol{\sigma}_{i,M} \quad (i = 1, \cdots, N) \qquad \cdots (23)$$

$$\widetilde{\Omega}_{i,k} = \widetilde{\mathbf{x}}_k - \boldsymbol{\sigma}_{i-N,M} \quad (i = N+1, \cdots, 2N) \qquad \cdots (24)$$

$$\widetilde{\Psi}_{k} = \mathbf{g}(\widetilde{\mathbf{\Omega}}_{k}) \qquad \cdots (25)$$

$$\tilde{\mathbf{y}}_k = \sum_{i=0}^{2n} h_i \,\tilde{\Psi}_k \qquad \cdots (26)$$

$$\mathbf{M}_{k}^{yy} = \sum_{i=0}^{2n} h_{i} [\Psi_{i,k} - \tilde{\mathbf{y}}_{k}] [\Psi_{i,k} - \tilde{\mathbf{y}}_{k}]^{T} + \mathbf{W}_{k} \quad \cdots (27)$$

$$\mathbf{M}_{k}^{xy} = \sum_{i=0}^{2n} h_{i} [\tilde{\Phi}_{i,k} - \tilde{\mathbf{x}}_{k}] [\tilde{\Psi}_{i,k} - \tilde{\mathbf{y}}_{k}]^{T} \quad \cdots (28)$$

これにより、式(12)からカルマンゲイン K が算出され、 式(8)により、状態変量は $\hat{\mathbf{x}}_k$ に更新される。また、式(13) は以下のように書き換えることができる。

$$\mathbf{P}_{k} = \mathbf{M}_{k}^{xx} - \mathbf{K}_{k} \mathbf{M}_{k}^{yy} \mathbf{K}_{k}^{T} \qquad \cdots (29)$$

以上のフローをまとめて、図 2-2 に示す。



図 2-2 Unscented カルマンフィルタ

UKF における利点としては、微分演算以外に以下の ような点が挙げられる。

(1) 式(29)により、観測変量が与えられるたびに過去の 影響が誤差に反映される。よって、データの蓄積の 必要性がない。

- (2) 精度は EKF より増すことに加え、計算負荷は EKF と大差ない。
- (3) 状態方程式と観測方程式は、明確な式である必要が ない。例えば、近藤ら³⁾は観測方程式を市販交通シ ミュレータ Aimsun に設定している。

2-4. パーティクルフィルタ (PF)

パーティクルフィルタ⁴⁾ (PF: Particle Filter) も UKF と同様、EKF で問題とされていた微分演算を克服する 手段として用いられる。

PF では、モンテカルロ法によって、ある確率分布に 従う状態の確率標本(パーティクル)を発生させ、その状 態に依存している新たな観測変量を用いてベイズ的に更 新していく、ベイジアンフィルタ・システムである。

時刻kまでの観測変量の集合を $Y_k=\{y_1, \dots, y_k\}$ とすれば、 $\hat{\mathbf{x}}_{k}$ は事後確率分布 $p(\mathbf{x}_{k}|\mathbf{Y}_{k})$ を用いて次のように表される。

$$\hat{\mathbf{x}}_k = E(\mathbf{x}_k | \mathbf{Y}_k) = \int \mathbf{x}_k p(\mathbf{x}_k | \mathbf{Y}_k) d\mathbf{x}_k \qquad \cdots (30)$$

このとき、 \mathbf{Y}_k から \mathbf{x}_k の事後確率 $p(\mathbf{x}_k|\mathbf{Y}_k)$ を直接推定す ることは困難であるため、ベイズの定理を用いて次のよ うに導かれる。

$$p(\mathbf{x}_k | \mathbf{Y}_k) = \frac{p(\mathbf{y}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{Y}_{k-1})}{p(\mathbf{y}_k | \mathbf{Y}_{k-1})} \qquad \cdots (31)$$

これまでと同様に状態空間モデルの中であれば、p(y_k|x_k) は、観測方程式から与えられる。また、 $p(\mathbf{x}_k|\mathbf{Y}_{k-1})$ は、時 刻kにおける事前確率であり、次のようにあらわされる。

 $p(\mathbf{x}_{k}|\mathbf{Y}_{k-1}) = \int p(\mathbf{x}_{k}|\mathbf{x}_{k-1}) p(\mathbf{x}_{k-1}|\mathbf{Y}_{k-1}) d\mathbf{x}_{k-1} \cdots (32)$ $p(\mathbf{x}_{k-1}|\mathbf{Y}_{k-1})$ は時刻k-1における事後確率である。また、 $p(\mathbf{x}_k | \mathbf{x}_{k-1})$ は時刻k-1から時刻kへの状態推移確率であり、 状態方程式から与えられる。

このベイジアンフィルタを用いて、PF では多数の確 率標本によって近似を行う。具体的な手順は以下のとお りとなる。

いまタイムステップをk=0,1,2,…とすれば、

- 1. イニシャルサンプリング サンプル \mathbf{x}_{0}^{i} を初期分布 $p(\mathbf{x}_{0})$ から生成する。(*i* = $1, \cdots, N$
- 2. 予測サンプルの生成 状態方程式によって時刻k-1のサンプルxk-1を推移さ せ、予測サンプルを生成する。

$$\tilde{\mathbf{x}}_{k}^{i} = \mathbf{f}(\hat{\mathbf{x}}_{k-1}^{i}) + \mathbf{v}_{k}^{i} \qquad \cdots (33)$$

- 3. サンプルの重度計算 次の式に従い、サンプルに重み付けする。 $\widetilde{W}_{k}^{i} = p(\mathbf{y}_{k} | \widetilde{\mathbf{x}}_{k}^{i})$...(34) $p(\mathbf{y}_k | \mathbf{\tilde{x}}_k^i)$ は、観測方程式によって推定する。
- 4. ノーマライズ 計算された重度は、すべてノーマライズしておく。 $\widehat{W}_k^i = \frac{{}^{\nu_k}}{\sum_{j=1}^N \widetilde{W}_k^j}$

- 5. リサンプリングによる更新 サンプル集合 $\{\tilde{\mathbf{x}}_{k}^{i}\}$ から重度 \hat{W}_{k}^{i} に比例する割合でN個の 新しいサンプルxiを生成する。
- 6. 繰り返し計算 2~6のステップを繰り返す。

ある時刻kにおける xk は、次のように重度付き平均に よって、期待値として求めることができる。

 $\hat{\mathbf{x}}_{k} = E(\mathbf{x}_{k}) \approx \frac{1}{N} \sum_{i=1}^{N} \hat{\mathbf{x}}_{k}^{i} = \sum_{i=1}^{N} \widehat{W}_{k}^{i} \tilde{\mathbf{x}}_{k}^{i} \qquad \cdots (36)$

UKFとPFを比較した時、精度面ではPFが若干有利と なり、計算速度面ではUKFが有利となることが一般的に 知られている。

2-5. デュアルフィルタ (DF)

状態空間モデル内に、未知のパラメータ u が組み込 まれている場合について考える。この時、式(1)は次の ように変換される。

状態方程式: $\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}) + \mathbf{v}_k$ …(37) 多くの場合、 \mathbf{u} は推定を始める前に事前設定を行い、固 定値とてシステムは組まれる。しかし、非線形性の強い モデルや、モデル内のノイズが高い場合は事前設定が難 しく、ひとたび誤った値を与えてしまえば、その後の推 定精度に重大な影響を及ぼしかねない。

デュアルフィルタ⁵⁾ (DF: Dual Filter) は、状態変量を 推定するフィルタと平行して、もう一つパラメータを推 定するフィルタを組むことで、状態変量の推定精度を増 すためのシステムである。

パラメータ推定を組み込むにあたり、式(6)および式 (7)は以下の二式に更新される。

$\mathbf{x}_{k} = \mathbf{I}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{v}_{k}^{2}$ (38)
--	-----

$\mathbf{\tilde{v}}_{k} = \mathbf{g}(\mathbf{\tilde{x}}_{k}, \mathbf{\hat{u}}_{k-1}) + \mathbf{w}_{k}$	(39)
$\mathbf{v}_{\nu} = \mathbf{g}(\mathbf{x}_{\nu}, \mathbf{u}_{\nu-1}) + \mathbf{w}_{\nu}$	(39)

また、パラメータ推定における状態空間モデルは次の ように示される。

$\widetilde{\mathbf{u}}_k = \widehat{\mathbf{u}}_{k-1}$	$+\mathbf{v}_k^{parameter}$	(40)
$\tilde{\mathbf{y}}_k = \mathbf{g}(\hat{\mathbf{x}}_k)$, $\widehat{\mathbf{u}}_k) + \mathbf{w}_k$	(41)
このように、	相互作用を持ち	ながら時間推移していく

ことができる。

本稿では状態推定に PF を用いて、パラメータ推定で は EKF または UKF を用いるデュアルフィルタ (DF-EKF or UKF: Dual Filter with EKF or UKF) について提案 を行う。これは、状態推定が複雑なモデル構造を取るこ とが多いのに対し、パラメータ推定については比較的シ ンプルな構造を取るためで、精度とスピードに考慮した フィルタシステムといえる。

3. 解析関数を用いた推定例

3-1. パラメータ推定

出力例の一つとして、以下で与えられる解析関数^{の7)} を式(38)から式(41)に適用して分析を行う。状態遷移関 数 f(*)には、未知のパラメータuが設定されている。

$$f(x_k, u_k) = 0.5x_k + 25\frac{x_k}{1+x_k^2} + 8\cos(1.2k) + u_k\cdots(42)$$

$$g(x_k) = \frac{1}{20} x_k^2$$
(43)

v_kと**w**_kはそれぞれ、 $N(0,\sigma_v^2)$ および $N(0,\sigma_w^2)$ で与えられる正規分布に従うが、はじめに $\sigma_v^2 = 1.0$ 、 $\sigma_w^2 = 10.0$ 、さらにu = 5.0として観測データを作成する。

その後、ノイズの設定はそのままにして、"未知"のパ ラメータ *u* にある初期値を与え、デュアルフィルタにか け、その精度を比較する。

PF 部におけるサンプル数 (パーティクル数)を 100 個、パラメータに与える初期値 *u*₀を 15.0 に設定して、

x: state 25 20 DF-EKF 15 DF-UKF DPF 10 0 k: Time-step 図 3-1 状態推定結果 u: Model Parameter 16 14 12 Theoretical 10 DF-EKF 8 - DF-UKF - DPF - PF k: Time-step 図 3-2 パラメータ推定結果

パラメータ値を固定した PF、パラメータ値の推定され る DF-EKF および DF-UKF、さらに DPF も加えて四種 類について比較を行った。状態推定の結果を図 3-1 に、 パラメータ推定の結果を図 3-2 に示す。パラメータ値を 固定した場合よりも、デュアル推定を行った場合はより 精確に状態推定が成された。また、パラメータ推定につ いては、EKF の方がより真の値に収束した。UKF の方 は、より速く収束が完了したが、小刻みな変動が続く結 果となった。DPF は、UKF とほぼ同様の傾向を示した。

精度の程度を調べるため、状態推定およびパラメータ 推定の RMSE について見る。図 3-3 は、PF におけるサ ンプル数と RMSE の関係である。



図 3-3 サンプル数と RMSE

状態推定、パラメータ推定のすべての状況において DF-UKF および DPF の精度が良い結果となった。

状態推定については、DF-UKF はサンプル数が少ない 状態でも良い結果が得られた。PF、DF-EKF はサンプル 数が増えるほど精度は増したが、DF-UKF および DPF を超える結果とはならなかった。パラメータ推定につい ては、ほぼサンプル数に影響を受けなかった。

今後は、計算速度について比較する必要性がある。

3-2. システムノイズの分散推定

モデル内の未知のパラメータの一つに、システムノイ ズの分散があげられる。ノイズを伴う不完全なモデルを 取り扱うことから、状態推移を表現するシステムノイズ においては、事前に定量化して設定することが特に難し く、かつシステムに深刻な影響を及ぼすことが知られて いる。

分散推定について、状態方程式におけるシステムノイズの分散値 $\sigma_v^2 \delta$ 、DPF を用いて出力した例を図 3-4 に示す。サンプル数は 500 個とし、タイムステップは 100

平成23年度 土木学会北海道支部 論文報告集 第68号



図 3-4 システムノイズの分散推定結果

回とした。システムノイズを 1.0 に設定して観測データ を作成、また観測ノイズについては、先ほどのパラメー タ推定と同様に設定した。初期値をどのように与えても 分散値はやがて一定の値に収束していくことがわかる。 パラメータ推定と違う点は、まず収束速度が遅い点があ げられる。これは、パラメータ推定に比べて、分散値が サンプルの精度に与える影響が弱いことがあげられ、改 善の余地がある。また、システムノイズの"真の値"であ る 1.0 ではなく、1.0 よりやや大きい値に収束している こともわかる。今後、考察が必要である。

また、DF への導入は、観測方程式の記述に不明点が 残されており、今後の課題である。

4. マクロ交通流モデルへの適用

4-1. マクロ交通流モデル

これまで解析関数で行なってきたモデリングを、マク ロ交通流モデルに適用することを考える。主な先行研究 として、Anburuvel ら[®]による OD 行列の動的推定、 Pueboobpaphan ら²⁾による交通密度を代表とする交通状 態の動的推定があげられる。

直接観測することの難しい、交通密度などの交通状態 を推定する際、初歩的なマクロ交通流モデルとして First-Order Model がある。その例としては Daganzo⁹によ る CTM が挙げられる。対象とする路線をいくつかのセ グメントに分けるとき、CTM では以下の二式によって、 セグメント内の交通密度 ρ 、空間平均速度vを表す。

$$\rho_j^{t+1} = \rho_j^t + \frac{\Delta t}{\Delta L_j} (q_{j-1}^t - q_j^t + r_j^t - s_j^t) \qquad \cdots (44)$$

 $v_j^t = V_e(\rho_j^t)$ …(45) なお、jは対象とするセグメント番号、 Δt はシミュレー ションのタイムインターバル、 ΔL はセグメントの延長 (km)、rは流入台数(veh/hr)、sは流出台数(veh/hr)を表す (図 4-1 参照)。また、 $V_e(*)$ は k-v 曲線で表される。





これと同時に、セグメントの境界部に複数台設置され た車両感知器から、地点速度データ w が一定間隔で得 られるとするならば、地点速度の観測データと、式(45) による空間平均速度の予測値は、パラメータ α を用い て次のような関係で表される。

 $w_i^t = \alpha \cdot v_i^t + (1 - \alpha) \cdot v_{i+1}^t \qquad \cdots (46)$

式(44)から式(46)を状態空間モデルに当てはめること で、フィードバック推定が可能となる。ここでは、観測 データと予測値の関係に速度を用いているが、感知器か ら得られる車両カウントを用いることもできる。しかし、 路線のおかれる環境によっては、車両台数が大きく変わ ることもあり、速度データのほうが、分散が少なく、こ の場では適性とも考えられる。

4-2. パラメータ推定、ノイズの分散推定

未知のパラメータとしては、解析関数で取り上げたノ イズの分散もそうであるが、式(46)にあるパラメータ α が挙げられる。このパラメータは、上流と下流からの影 響をスケーリングするものであるが、事前設定は容易で はない。

5. おわりに

本稿では、状態空間モデル内に未知のパラメータが内 在した場合のデュアルフィルタの設計について述べ、ケ ーススタディとして解析関数を用いて、システム有効性 を示した。また、システムをマクロ交通流モデルに適用 するためのモデリングについて示した。

今後の課題としては、計算速度の比較、ノイズの分散 推定における精度向上、DFの導入、さらに交通流実デ ータを用いた場合の検証が必要である。

参考文献

- Z. Chen: Bayesian Filtering: From Kalman Filters to Particle Filters and Beyond, 2003 http://soma.crl.mcmaster.ca/~zhechen/homepage.htm
- R. Pueboobpaphan et al.: Unscented Kalman Filter-Based Real-Time Traffic State Estimation, Transportation Research Board 86th Annual Meeting, CD-ROM, 2007
- 近藤健佑ら:交通流シミュレータの API 機能を用いたモデルパラメータの較正と動的 OD 推定に関する研究、土木計画学研究・講演集、vol.44、2011
- 4) 小林剛ら:パーティクルフィルタの設計と交通流への適用に関する考察、土木計画学研究・講演集、 vol.42、2010
- S. Haykin: Kalman Filtering and Neural Networks, Wiley-Interscience, Chapter5, pp.123-173, 2001
- F. Pengpai et al.: Particle Filter-Weight Estimation and Dual Particle Filter, Intelligent Systems and Applications (ISA), pp.1-4, 2009
- M. Lei et al.: A Variable Sample Size Particle Filter, *Proc.* of IEEE International Conf. on Automation and Logistics, pp.520-526, 2008
- A. Anburuvel et al.: A Comprehensive Approach for Data Scarcity Problem in Real-Time OD Matrix Estimation, 2011
- C. F. Daganzo: The Cell Transmission Model: A Dynamic representation of Highway Traffic Consistent with the Hydrodynamic Theory, Transportation Research, vol.28B No.4, pp 269-287, 1994