

# プローブカーと感知器のデータに基づくキャリブレーション不要な交通状態推定手法

瀬尾 亨<sup>1</sup>・杉本 佳昭<sup>2</sup>

<sup>1</sup>正会員 東京大学大学院助教 社会基盤学専攻 (〒113-8656 東京都文京区本郷 7-3-1)  
E-mail: seo@civil.t.u-tokyo.ac.jp

<sup>2</sup>非会員 本田技研工業株式会社 (〒152-8552 東京都港区赤坂 5-3-1 赤坂 Biz タワー 27F)

交通状態推定とは、部分的に観測された交通データに基づき道路交通システム全体の状態を推定する問題であり、交通管理上重要な情報をもたらす。しかし、既存の交通状態推定手法の多くは、適用に際し交通流理論やデータ加工の知識を必要とするほか、理論やデータ形式に関連するキャリブレーション方法の不明確な技術的変数が多く、その実適用は容易ではない。本研究では、単純かつ合理的な理論に基づき、キャリブレーションすべき変数がなく、かつ比較的一般的なデータ形式を入力できる交通状態推定手法を提案する。本手法は、近年注目されているプローブデータを主な入力とし、少数の感知器のデータと組み合わせるものである。提案手法を高速道路車両軌跡データと一般道のプローブデータに適用し、その精度を検証した。

**Key Words:** traffic state estimation, data-driven, probe vehicles, connected vehicles

## 1. はじめに

交通状態推定とは、部分的に観測された交通データに基づき道路交通システム全体の状態を推定する問題であり、交通管理上重要な情報をもたらす<sup>1)</sup>。特に、そのデータ取得範囲の大きさから車載 Global Navigation Satellites System (GNSS) に基づくプローブカーの観測データ、プローブデータを用いた手法が数多く提案されている<sup>2)-8)</sup>。

しかし、既存の交通状態推定手法を実際に適用するのは難しい場合が多い。その理由として、モデルパラメータキャリブレーションの困難さと入力とする交通データの準備の困難さが挙げられる。交通状態推定手法は多くの場合交通流モデルを基礎に置いているが、そのモデルパラメータ(例:交通容量)は事前にキャリブレーションする必要がある場合が多い。しかし、そのようなキャリブレーションは常に可能というわけではなく、さらにキャリブレーション自体に交通流モデル・理論についての細かい知見が必要であるという課題がある。また、入力とする交通データには車両感知器のデータやプローブデータがあるが、それらのデータ形式(特にプローブデータの形式)は多様で複雑である。そのため、収集されている生データを交通状態推定手法の入力形式に変換するのが煩雑であったり、交通流理論についての知見が必要であるという課題がある。

交通状態推定についての実務的必要性としては、地方高速道や一般道など感知器の少ない道路の交通情報

収集<sup>9),10)</sup>や情報が少なく急を要する災害時の交通マネジメント<sup>11)</sup>が挙げられると考えられる。このような条件下で交通状態推定手法を適用するためには、前掲の課題は大きな問題になりうる。


そこで本研究ではモデルパラメータキャリブレーションが不要で、簡易な形式のデータを入力とする交通状態推定手法を提案する。提案手法はプローブデータを活用するデータ駆動型の保存則に基づいており、モデルパラメータがごく少数しかない。そして、入力データは感知器により収集された集計流率もしくは密度と、プローブにより収集された集計平均速度であり、いずれも作成が容易である。推定の枠組みにはカルマンフィルタと平滑化を採用し、感知器が少数であっても高精度な推定が可能なものとする。

## 2. 方法


### (1) 問題設定

本手法では、一本の道路リンクを対象として以下の状況を考える。十分な量のプローブカーデータがあり、このリンク上の速度分布がわかっている。感知器が最低一つ設定されており、その地点の流率または密度がわかっている。この時、任意の時刻におけるリンクの任意の地点の流率と密度を推定したい。

本手法の基本的な考え方は以下の通り。まず、推定の枠組みには交通流モデルとのデータ同化による方法<sup>12)</sup>を用いる。交通流モデルとして、プローブデータの速度



(a) フィルタリング



(b) 平滑化

図-1: データ同化による推定における感知器情報の伝播方向。

を既知としたデータ駆動型保存則<sup>13)-16)</sup>を用いる。本モデルの長所は流率密度関係や OD 表のようなパラメータ・需要情報が存在しないことである。そして、データ同化のフィルタリングと平滑化を併用することにより、感知器が一つであっても高精度なオフライン推定ができる手法とする。

フィルタリングと平滑化を併用することの長所は以下の通り。フィルタリングとは時刻  $t$  の状態を時刻  $t$  までに得られたデータを用いて逐次推定することであり、オンライン・リアルタイム推定手法はフィルタリングを用いることが多い。平滑化とは時刻  $t$  の状態を時刻  $s > t$  までに得られたデータを用いていわば過去に遡って推定することであり、事後的に過去の状態を再現するオフライン推定に用いられる。一般に、平滑化の方が用いるデータが多いため推定精度が高いことが知られている。さらに、交通状態推定では平滑化には特有のメリットがある。それは、一つの感知器から得られた情報を有効に使えるということである。フィルタリングのみの推定の場合、交通状態伝播速度の法則<sup>17), 18)</sup>より、ある感知器から得られた情報はその下流側の推定に比較的有用である (図-1a)。一方、平滑化は過去に遡る形で推定するため、ある感知器から得られたその上流側の推定に比較的有用になる (図-1b)。よって、フィルタリングと平滑化を併用することである感知器の情報を上流と下流両方向の推定に有効に用いることができると考えられる。

	A	B	C
1	t	x	v
2	0	0	23.3
3	0	100	18.9
4	0	200	17.9
5	0	300	18.7
6	0	400	19.0
7	0	500	19.8
8	0	600	20.3
9	0	700	20.5
10	0	800	21.1
11	0	900	18.1
12	4	0	23.3
13	4	100	21.8
14	4	200	19.5
15	4	300	18.3
16	4	400	19.3
17	4	500	18.9
18	4	600	19.5
19	4	700	20.7
20	4	800	20.7
21	4	900	18.9
22	8	0	23.3
23	8	100	22.3

図-2:  $v(t, x)$  のデータ形式の例。t 列は時刻, x 列は位置, v 列はその時刻・位置における平均速度を意味する。

ただし、平滑化はオフライン推定にしか用いることができないという限界がある。そこで、提案手法は交通状態の事後的な評価に有用であると考えられる。なお、提案手法から平滑化を省略するのは容易であり、そのようにすることでオンライン推定への適用も容易に可能である。

## (2) 推定アルゴリズム

本手法の入力は以下の通りとする：

- 推定の時間分解能： $\Delta t$
- 推定の空間分解能： $\Delta x$
- 上記時空間分解能で集計された感知器の流率もしくは密度データ： $q(t, x)$  or  $k(t, x)$
- 上記時空間分解能で集計されたプローブ速度データ： $v(t, x)$
- 推定の時間・空間範囲： $t_{\min}, t_{\max}, x_{\min}, x_{\max}$

ここで、入力データ  $q(t, x), k(t, x), v(t, x)$  は一定時間・空間毎に集計された交通状態量であり、例えば図-2に示すような単純な表として準備できる。数値的安定性を確保するため、 $\Delta x$  の値は  $\Delta t \times$  最大速度の値よりも大きい必要がある。

出力は以下の通りとする：

- 上記時空間分解能で集計されたリンク内の各位置

の流率・密度： $q(t, x), k(t, x)$

本手法を適用するには以上の知識があれば十分である。

以下ではアルゴリズムの詳細を述べる。まず、定式化に当たり、以下の線形ガウス状態空間モデルを考える。

$$\mathbf{x}_n = F_n \mathbf{x}_{n-1} + \boldsymbol{\nu}_n \quad (1)$$

$$\mathbf{y}_n = H_n \mathbf{x}_n + \boldsymbol{\omega}_n \quad (2)$$

ここに、 $\mathbf{x}_n$  はタイムステップ  $n$  の状態ベクトル、 $F_n$  は同じくシステムモデル、 $\boldsymbol{\nu}_n$  は同じくシステムノイズ、 $\mathbf{y}_n$  は同じく観測ベクトル、 $H_n$  は同じく観測モデル、 $\boldsymbol{\omega}_n$  は同じく観測ノイズである。

状態ベクトルは

$$\mathbf{x}_n = (\dots, k_i^n, \dots) \quad (3)$$

と定義する。ここに、 $k_i^n$  はタイムステップ  $n$ 、位置  $i$  の交通密度であり、 $k_i^n \equiv k(n\Delta t, i\Delta x)$  である。

観測ベクトルは

$$\mathbf{y}_n = (\dots, \hat{k}_i^n, \dots) \quad (4)$$

と定義する。ここに、 $\hat{k}_i^n$  はタイムステップ  $n$ 、位置  $i$  で感知器により観測された交通密度である。ただし、感知器がタイムステップ  $n$ 、位置  $i$  で流率  $\hat{q}_i^n$  を観測している場合、 $\hat{k}_i^n$  は  $\hat{k}_i^n = \hat{q}_i^n / v_i^n$  により求める。ここで、 $v_i^n$  はタイムステップ  $n$ 、位置  $i$  の平均速度であり、プローブデータから算出される。また、感知器がタイムステップ  $n$ 、位置  $i$  でオキュパンシ  $\hat{\delta}_i^n$  を観測している場合、 $\hat{k}_i^n$  は  $\hat{k}_i^n = \delta \hat{\delta}_i^n$  により求める。ここで、 $\delta$  は所与の平均最小車頭距離である。

システムモデルは車両保存則

$$\frac{\partial k}{\partial t} + \frac{\partial kv}{\partial x} = 0 \quad (5)$$

を風上差分法<sup>19)</sup>により離散化したもの

$$k_i^{n+1} = \frac{1}{2} (k_{i-1}^n + k_{i+1}^n) + \frac{\Delta t}{2\Delta x} (k_{i-1}^n v_{i-1}^n - k_{i+1}^n v_{i+1}^n) \quad (6)$$

とする。前述の通り、 $v_i^n$  はプローブデータから算出される平均速度である。式 (6) は  $k$  についての線形式であるので、適切な行列  $F_n$  を用いて  $\mathbf{x}_n = F_n \mathbf{x}_{n-1}$  と表せる。

観測モデル  $H_n$  は要素が 0 か 1 の対角行列である。 $(i, i)$  要素はその位置で感知器により密度が観測されていれば 1、それ以外るとき 0 とする。

ノイズ  $\boldsymbol{\nu}_n$  と  $\boldsymbol{\omega}_n$  はそれぞれ分散が所与で独立な正規分布に従うとし、 $\boldsymbol{\nu}_n$  の分散共分散行列を  $Q_n$ 、 $\boldsymbol{\omega}_n$  の分散共分散行列を  $R_n$  とする。このうち観測ノイズ  $\boldsymbol{\omega}_n$  はデータの信頼性から与えることができる。システムノイズ  $\boldsymbol{\nu}_n$  は外生的に仮定せざるを得ないが、類似手法を用いた既往研究<sup>16)</sup>によればこの値は一定範囲内であれば推定結果に大きな影響を及ぼさないとされている。シ

ステムモデルは理論上正確でノイズが本来存在しないためと考えられる。

以上の設定のもと、 $\mathbf{x}_n (\forall n)$  を  $\mathbf{y}_n (\forall n)$  に基づき推定する。そのために、Kalman フィルタと固定区間平滑化を組み合わせた手法<sup>20)</sup>を用いる。

Kalman フィルタは、タイムステップ  $n_{\text{now}}$  の状態  $\mathbf{x}_{n_{\text{now}}}$  をそれ以前の観測データ  $\mathbf{y}_n (\forall n \leq n_{\text{now}})$  が与えられたもとで推定する。これはリアルタイム推定に相当する。そのアルゴリズムは以下のようにまとめられる。 $n = 1, 2, \dots, n_{\text{max}}$  に対して、

$$\mathbf{x}_{n|n-1} = F_n \mathbf{x}_{n-1|n-1} \quad (7)$$

$$V_{n|n-1} = F_n V_{n-1|n-1} F_n^\top + Q_n \quad (8)$$

$$K_n = V_{n|n-1} H_n^\top (H_n V_{n|n-1} H_n^\top + R_n)^{-1} \quad (9)$$

$$\mathbf{x}_{n|n} = \mathbf{x}_{n|n-1} + K_n (\mathbf{y}_n - H_n \mathbf{x}_{n|n-1}) \quad (10)$$

$$V_{n|n} = V_{n|n-1} - K_n H_n V_{n|n-1} \quad (11)$$

を順次計算する。ただし、 $n_{\text{max}}$  は最終タイムステップ、 $\mathbf{x}_{n|n-1}$  は  $\mathbf{x}_n$  の事前分布の平均値、 $\mathbf{x}_{n|n}$  は  $\mathbf{x}_n$  の事後分布の平均値、 $V_{n|n-1}$  は  $\mathbf{x}_n$  の事前分布の分散共分散行列、 $V_{n|n}$  は  $\mathbf{x}_n$  の事後分布の分散共分散行列、 $K_n$  はカルマンゲインである。式の導出や詳細な意味については樋口<sup>20)</sup>を参照されたい。

次に、固定区間平滑化は、タイムステップ  $n (0 \leq n \leq n_{\text{max}})$  の状態  $\mathbf{x}_n$  を全ての観測データ  $\mathbf{y}_n (\forall n)$  が与えられたもとで推定する。これは過去にさかのぼって改めて推定しなおすことに相当する。そのアルゴリズムは以下のようにまとめられる。Kalman フィルタの結果  $\mathbf{x}_{n|n}$  および  $V_{n|n}$  が所与のもとで、 $n = n_{\text{max}} - 1, n_{\text{max}} - 2, \dots, 0$  に対して、

$$A_n = V_{n|n} F_{n+1}^\top V_{n+1|n}^{-1} \quad (12)$$

$$\mathbf{x}_{n|n_{\text{max}}} = \mathbf{x}_{n|n} + A_n (\mathbf{x}_{n+1|n_{\text{max}}} - \mathbf{x}_{n+1|n}) \quad (13)$$

$$V_{n|n_{\text{max}}} = V_{n|n} + A_n (V_{n+1|n_{\text{max}}} - V_{n+1|n}) A_n^\top \quad (14)$$

を順次計算する。ただし、 $\mathbf{x}_{n|n_{\text{max}}}$  は  $\mathbf{x}_n$  の事後確率最大解の平均値、 $V_{n|n_{\text{max}}}$  は  $\mathbf{x}_n$  の事後確率最大解の分散共分散行列である。

$\mathbf{x}_{n|n_{\text{max}}}$  がオフライン推定で求めたい解、 $\mathbf{x}_{n|n}$  がオンライン推定で求めたい解である。

### 3. 検証

実データを用いたケーススタディにより提案手法の性質を検証する。実データとして、高速道路上で収集された全車両軌跡データと、一般道で収集されたプローブデータを用いる。




図-3: 高速道路：対象区間 (出典：<https://zen-traffic-data.net/outline/>)




図-4: 高速道路：真の速度




図-5: 高速道路：真の密度




図-6: 高速道路：推定された密度

### (1) 高速道路でのケーススタディ

元データとして Zen Traffic Data (ZTD)<sup>21)</sup>を用いる。本データは、阪神高速道路の池田線塚本ジャンクション付近(図-3)で多数のカメラによって収集された全

車両軌跡データであり、区間長は約 2km、車線数は片側 2 車線、時間は日中の 1 時間である。ただし、提案手法は分合流がないことを前提としているので、合流箇所よりも上流側の 1km 区間のデータを利用する。その区間の速度と密度を図-4、図-5 に示す。前半は自由




図-7: 高速道路：密度の比較

流状態、後半は渋滞状態にある。

以上の元データから以下のように検証用データを作成した。まず、 $\Delta t = 4$  (s)、 $\Delta x = 100$  (m) と設定する。そして、プローブデータにより速度が正確に既知であるとみなし、ZTD から  $v(t, x)$  を直接算出する。このデータはそして、区間の中間地点 ( $x = 500$  (m)) に速度と流量を測定する感知器があるとみなし、この箇所の ZTD から  $k(t, x)$  を算出する。

本手法により推定された密度の時空間図を図-6 に示す。真値 (図-5) と比較すると、非常に正確な推定ができていることがわかる。真値と推定値を散布図として比較した結果を図-7 に示す。こちらも正確であることがわかる。Mean Absolute Percentage Error (MAPE) は 18.0% であった。

以上から、プローブデータが正確であれば本手法は高速道路上で高い精度を発揮することが示唆された。

## (2) 一般道路でのケーススタディ

元データとして、本田技研工業によって収集されたプローブデータを用いる。本データは、インターネット等から携帯電話網を介して収集・蓄積し、個人を特定できないよう匿名化および統計化して利用したものである。より具体的には、車載 GNSS 等から取得した位置情報や方位をカーナビゲーションシステム内でマップマッチング処理したものを、一定時間ごとに一定間隔に分割した道路区間上で集計し、速度・通過台数データとしたものである。

区間は鎌倉市の若宮大路 (神奈川県道 21 号線) の滑川交差点から下馬交差点までの約 850m 区間の北方向とした (図-8)。本区間は概ね片側一車線であり、両端および区間中に信号交差点が存在し、日中は大きい交通需要により渋滞が発生している。プローブデータは 5 分単位  $\times$  100m 単位に集計された形で収集されており、2018 年 6 月 2 日には箇所によるが概ね 200 台程度のプローブカーがこの区間を通過した。また、本区間には感知器が上流端、下流端、中間地点の 3 か所に設置され、それぞれ断面交通量を測定している<sup>22)</sup>。

本区間で収集されたプローブデータと感知器データから以下のように検証用データを作成した。期間は 2018 年 6 月 2 日の早朝から深夜にかけてとする。まず、分解能は  $\Delta t = 5$  (s)、 $\Delta x = 100$  (m) とする。そして、プローブデータから  $v(t, x)$  を算出した。その時空間図を図-9 に示す。  $t = 220000$  (s)、すなわち 12 時頃から待ち行列が形成され、 $t = 240000$  (s)、すなわち 17 時過ぎまで渋滞状態が継続している。プローブ数は少ないものの合理的な動的な速度情報が把握できていると考えられる。また、感知器データの交通量情報とプローブデータの速度情報を組み合わせ密度  $k(t, x)$  を算出した。



図-8: 一般道：対象区間




図-9: 一般道：プローブカーが測定した速度

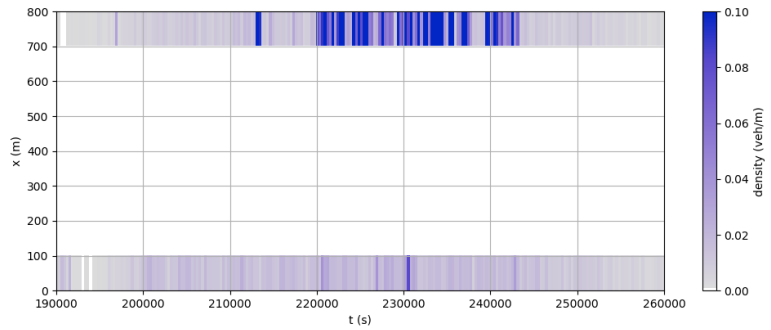


図-10: 一般道：検証用感知器により算出された密度




図-11: 一般道：推定された密度




図-12: 一般道：検証用感知器地点の密度の比較

この際、3つの感知器のデータのうち中間地点の1つのもを推定用の入力データ、残り2つを検証用の真値データとして用いる。真値データの時空間図を図-10に示す（白色は感知器のない区間である）。

本手法により推定された密度の時空間図を図-11に示す。速度データ（図-9）とほぼ対応する形で渋滞している状態が推定された。また、真値データ（図-10）の箇所の密度が概ね類似していることがわかる。真値と密度を比較すると図-12となり、推定結果が概ね正確であることがわかる。MAPEは27.6%であった。

以上から、プローブカー数が限られた一般道であってもある程度の精度での推定が可能であると示唆された。

## 4. おわりに

本研究では、限られた車両感知器とプローブカーデータに基づき交通状態を推定する手法を提案した。本手法はデータ駆動型であり、キャリブレーションすべきモデルパラメータを持たないという特徴を持っている。

高速道路および一般道の実データを用い本手法の性質を検証した。その結果、プローブデータが正確であれば本手法は高速道路上で高い精度を発揮することや、プローブカー数が限られた一般道であってもある程度の精度での推定が可能であると示唆された。

今後の展開として、ネットワークへの拡張が考えられる。ネットワークのどこかに感知器が存在すれば、ノード保存則の考慮により感知器が一つもないリンクの状態を推定できると期待されるためである。

**補注:** 著者の貢献は以下の通り。瀬尾亨は研究全体の設計、方法の開発、方法の検証、論文全体の執筆を担当した。杉本佳昭は第3.(2)節で用いたデータの収集と加工、第3.(2)節の一部の執筆を担当した。全著者が投稿版の原稿を確認した。

**謝辞:** 本研究は国土交通省新道路技術会議の研究課題「学習型モニタリング・交通流動予測に基づく観光渋滞マネジメントについての研究開発」とJSPS 科研費20H02267の助成を受けた。

### 参考文献

- 1) Seo, T., Bayen, A. M., Kusakabe, T., and Asakura, Y.: Traffic state estimation on highway: A comprehensive survey, *Annual Reviews in Control*, Vol. 43, pp. 128–151, 2017.
- 2) Nanthawichit, C., Nakatsuji, T., and Suzuki, H.: Application of probe-vehicle data for real-time traffic-state estimation and short-term travel-time prediction on a freeway, *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1855, No. 1, pp. 49–59, 2003.
- 3) Work, D. B., Tossavainen, O.-P., Blandin, S., Bayen, A. M., Iwuchukwu, T., and Tracton, K.: An ensemble Kalman filtering approach to highway traffic estimation using GPS enabled mobile devices, in *IEEE 47th Conference on Decision and Control*, pp. 5062–5068, 2008.
- 4) Yuan, Y., van Lint, J. W. C., Wilson, R. E., van Wageningen-Kessels, F., and Hoogendoorn, S. P.: Real-time Lagrangian traffic state estimator for freeways, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 13, No. 1, pp. 59–70, 2012.
- 5) Seo, T., Kusakabe, T., and Asakura, Y.: Estimation of flow and density using probe vehicles with spacing measurement equipment, *Transportation Research Part C: Emerging Technologies*, Vol. 53, pp. 134–150, 2015.
- 6) 和田健太郎, 小林桂子, 桑原雅夫: プローブ車両軌跡データのみを用いた交通の量的把握, 生産研究, Vol. 67, No. 2, pp. 143–147, 2015.
- 7) 竹之内篤, 桑原雅夫: 移動体データのみを用いた交通状態推定手法の研究, 土木計画学研究・講演集, Vol. 53, 2016.

- 8) Kawasaki, Y., Hara, Y., and Kuwahara, M.: Traffic state estimation on a two-dimensional network by a state-space model, *Transportation Research Part C: Emerging Technologies*, 2019.
- 9) 中川浩, 後藤誠, 松下健介, 土井元治: プローブと車両感知器データの融合による交通状態推定と情報提供, 交通工学, Vol. 52, 交通工学研究会, pp. 53–56, 2017.
- 10) 岩岡浩一郎, 弘津雄三, 平田忠史, 中邑正樹: 路上機器減少を背景とした仮想的な車両感知器情報推計手法の検討, 第17回ITSシンポジウム2019, 2019.
- 11) 力石真, 浦田淳司, 吉野大介, 藤原章正: 交通ネットワーク被災時の発生・集中・内々交通量及び旅行時間の変動特性, 土木計画学研究講演集, Vol. 60, 2019.
- 12) 福田大輔: データ同化アプローチによる交通状態の推定に関する研究動向, 交通工学, Vol. 47, No. 2, pp. 33–38, 2012.
- 13) Astarita, V., Bertini, R. L., d’Elia, S., and Guido, G.: Motorway traffic parameter estimation from mobile phone counts, *European Journal of Operational Research*, Vol. 175, No. 3, pp. 1435–1446, 2006.
- 14) Qiu, T., Lu, X.-Y., Chow, A., and Shladover, S.: Estimation of freeway traffic density with loop detector and probe vehicle data, *Transportation Research Record: Journal of the Transportation Research Board*, No. 2178, pp. 21–29, 2010.
- 15) Seo, T. and Kusakabe, T.: Probe vehicle-based traffic state estimation method with spacing information and conservation law, *Transportation Research Part C: Emerging Technologies*, Vol. 59, pp. 391–403, 2015.
- 16) Bekiaris-Liberis, N., Roncoli, C., and Papageorgiou, M.: Highway traffic state estimation with mixed connected and conventional vehicles, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 17, No. 12, pp. 3484–3497, 2016.
- 17) Lighthill, M. J. and Whitham, G. B.: On kinematic waves. II. a theory of traffic flow on long crowded roads, *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, Vol. 229, No. 1178, pp. 317–345, 1955.
- 18) Richards, P. I.: Shock waves on the highway, *Operations Research*, Vol. 4, No. 1, pp. 42–51, 1956.
- 19) LeVeque, R. J.: *Numerical methods for conservation laws*, Springer Basel AG, 1992.
- 20) 樋口知之 (編) データ同化入門, 朝倉書店, 2011.
- 21) 阪神高速道路 (株): Zen Traffic Data, 2018a. <https://zen-traffic-data.net>, accessed 2018-09-03.
- 22) 日本道路交通情報センター: 断面交通量情報, 2018b. 2018-11-28 アクセス.

(2020. 10. 2 受付)

# Calibration-free traffic state estimation using probe vehicle data and detector data

Toru SEO and Yoshiaki SUGIMOTO