

論文 / 著書情報
Article / Book Information

論題(和文)	プローブカーの車載カメラ情報等を活用した交通流モニタリング手法の概念実証実験
Title	
著者(和文)	瀬尾 亨, 日下部 貴彦, Nguyen, L. X., 朝倉 康夫
Authors	Toru Seo, Takahiko Kusakabe, Xuan Long Nguyen, Yasuo Asakura
出典 / Citation	第12回ITSシンポジウム2014, , ,
Citation(English)	, , ,
発行日 / Pub. date	2014, 12
Note	本著作物は第12回ITSシンポジウム2014の発表論文である

プローブカーの車載カメラ情報等を活用した 交通流モニタリング手法の概念実証実験

瀬尾 亨^{*1} 日下部 貴彦^{*1} Nguyen Xuan Long^{*1} 朝倉 康夫^{*1}
東京工業大学^{*1}

カメラ等の車載機器から走行車両の周辺状況を自動認識する技術の研究開発が進展している。当技術は運転支援や車車間・路車間協調システムの重要な要素技術であり、今後の普及が見込まれる。本稿では、当技術の活用法として、車載カメラ等によって得られる局所的な車両周辺状況（例：車間距離）から大域的な交通状態（例：流率）を推定する手法を述べる。また、首都高速都心環状線とベトナム一般道という全く性質の異なる2か所にカメラ搭載プローブカーを走行させた実道実験結果に基づき、推定手法の精度を定量的に検証した。その結果、提案した推定手法は両路線にて同様の傾向を示し、プローブ混入率と分解能次第では高精度で交通状態の推定が可能であった。

Traffic flow monitoring method utilizing video cameras mounted on probe vehicles: Proof-of-concept experiments

Toru Seo^{*1} Takahiko Kusakabe^{*1} Long Xuan Nguyen^{*1} Yasuo Asakura^{*1}
Tokyo Institute of Technology^{*1}

Abstract Recent technological development enable us to observe surrounding environment of a running vehicle. The typical examples of methods for the observation are on-vehicle cameras and image recognition techniques for advanced driving assistance systems (ADAS). This paper proposed a probe vehicle-based traffic state (i.e., flow, speed, density) estimation method by assuming that probe vehicles can measure spacing. The proposed method was validated by proof-of-concept experiments in actual roads in Tokyo and Vietnam. According to the results, the proposed method showed similar characteristics under various traffic conditions. The method could precisely estimate the traffic states regarding the probe vehicle penetration rate and the estimation resolution.

Keyword: Probe vehicle, Traffic state estimation, Advanced driver assistance system

1. はじめに

1.1 背景

車載機器により収集できる情報が質的にも多様化しつつある。これまでは、位置や自車運転挙動といった情報が収集・活用されてきたが、近年の運転支援システム¹⁾の発展とともに、新たなセンサーによる自車周辺状況に関する情報の収集が可能となっている。その具体例として車載カメラが挙げられ、その解析技術例として高精度地図の自動更新²⁾、路面劣化状況判別³⁾、車間距離測定^{4), 5)}などが開発されている。また、このような車載機器で得られる動的情報を統合し、様々な目的に活用するための基盤として、ダイナミックマッ

ピング⁶⁾と呼ばれる枠組みも提案されている。

本研究は、このような自車周辺状況観測について、交通流観測の観点から着目する。すなわち、車頭距離は局所的な交通密度の逆数であることから、本技術をプローブカーの観測手段に組み込むことで、流率や密度を推定する方法が提案されている⁷⁾。この方法論が実用化されると、移動体観測のみにより広範囲に渡って流率、密度、速度といった交通流の基本状態量を恒常的に収集（モニタリング）できることにつながるため、既存の交通流モニタリング手法として非常に有効であると考えられる（既存手法である車両感知器では広範囲の観測が難しく、GPS 搭載プローブカーでは流率・密度の観測が難しい）。

1.2 目的

本研究の目的は、車間距離測定プローブカーによる交通流観測手法、特に流率や密度の推定手法の構築と、その定量的検証である。推定手法は、先行研究⁷⁾の手法の問題点を解決すべく改善したものとする。先行研究⁷⁾の手法は、交通量保存則を表現するため、交通状態推定の分解能がプローブカー位置によって規定されるという点があった。これは、推定の分解能を自由に設定できない上に、交通流が不連続となる箇所（例：分合流地点）での推定精度が悪化するという問題を引き起こしていた⁸⁾。

推定手法の検証は、首都高速都心環状線とベトナム一般道という全く性質の異なる2か所での実道実験結果に基づくものとする。これにより、多様な道路・運転者・車両特性のもとでの特性を明らかにできる。

2. 交通状態推定手法

車間距離測定プローブカーは、自車の位置と先行車両との車頭距離を連続的に観測するとする。そのプローブデータから交通状態を推定する。これらの前提は先行研究⁷⁾にて置いたものと同一である。

交通状態の推定量として、Edieの定義⁹⁾（地点流率や空間密度などを任意の時空間へと一般化したもの）に基づき、以下を定義する。

$$\hat{q}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (1)$$

$$\hat{k}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (2)$$

$$\hat{v}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})} \quad (3)$$

ここに、

$\mathbf{A}$: 任意の時空間領域

$q(\mathbf{A})$: 領域 $\mathbf{A}$ 内部の時空間平均流率

$k(\mathbf{A})$: 領域 $\mathbf{A}$ 内部の時空間平均密度

$v(\mathbf{A})$: 領域 $\mathbf{A}$ 内部の時空間平均速度

$d_n(\mathbf{A})$: 領域 $\mathbf{A}$ 中での車両 n の総走行距離

$t_n(\mathbf{A})$: 領域 $\mathbf{A}$ 中での車両 n の総走行時間

$|\mathbf{a}_n(\mathbf{A})|$: 領域 $\mathbf{A}$ 中での車両 n とその前車との間の時空間領域の面積

$\mathbf{P}(\mathbf{A})$: 領域 $\mathbf{A}$ 中に存在する全プローブカーの集合

である。なお、 $\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})| > 0$ が前提条件である。ここで、これらの推定量 $\hat{q}(\mathbf{A})$, $\hat{k}(\mathbf{A})$ は不偏推定量ではない。すなわち、

$$E[\hat{q}(\mathbf{A})] - q(\mathbf{A}) \approx \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{\text{Var}[|\mathbf{a}_n(\mathbf{A})|/d_n(\mathbf{A})]}{E[|\mathbf{a}_n(\mathbf{A})|/d_n(\mathbf{A})]^3} \quad (4)$$

$$E[\hat{k}(\mathbf{A})] - k(\mathbf{A}) \approx \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{\text{Var}[|\mathbf{a}_n(\mathbf{A})|/t_n(\mathbf{A})]}{E[|\mathbf{a}_n(\mathbf{A})|/t_n(\mathbf{A})]^3} \quad (5)$$




Fig.1 プローブデータと時空間領域 $\mathbf{A}$

と近似される偏りを持っている（導出は補注*1を参照のこと）。また、推定量 $\hat{q}(\mathbf{A})$, $\hat{k}(\mathbf{A})$ の二乗平均誤差 RMSE は

$$\text{RMSE}(\hat{q}(\mathbf{A})) \approx \frac{1}{E[|\mathbf{a}_n(\mathbf{A})|/d_n(\mathbf{A})]^2} \sqrt{\frac{\text{Var}[|\mathbf{a}_n(\mathbf{A})|/d_n(\mathbf{A})]}{|\mathbf{P}(\mathbf{A})|}} \quad (6)$$

$$\text{RMSE}(\hat{k}(\mathbf{A})) \approx \frac{1}{E[|\mathbf{a}_n(\mathbf{A})|/t_n(\mathbf{A})]^2} \sqrt{\frac{\text{Var}[|\mathbf{a}_n(\mathbf{A})|/t_n(\mathbf{A})]}{|\mathbf{P}(\mathbf{A})|}} \quad (7)$$

と近似できる（導出は補注*2を参照のこと）。

時空間領域 $\mathbf{A}$ の設定法には様々なものが考えられるが、本論文では時間幅 Δt 、空間幅 Δx の時空間上の矩形とする（図1）。

本手法の特徴は以下とまとめられる：

- 移動体観測のみに基づき量的情報を推定可能
- 任意の時空間分解能での交通状態が推定可能
- 仮定している要素が少ない

2点目に関して、これにより状況に応じて様々な目的に応用可能な状態量（例：5分間交通量、1時間交通量）の推定が可能であり、かつ「分合流部で推定精度が悪化する点」を回避できる。3点目に関して、本研究は q - k 関係に一切の仮定を置いていない。もし q - k 関係を高精度に仮定することが出来れば、GPS プローブカーの観測のみからでも交通状態の推定が可能である¹⁰⁾。ただし、 q - k 関係を常時高精度に把握することは一般に難しい。そのため、本手法は様々な性質の交通流に対して適用できうる頑健な手法であると考えられる。

3. 実道実験の実施状況

実施した実道実験について、車両と実験路線の設定を述べる。

3.1 プローブカー

車間距離測定プローブカー（以下、プローブ）には、GPS ロガーと単眼カメラを搭載した車両を用いる。プ

ローブは 15 秒毎に自車両の位置・速度、先行車両との車頭距離を測定する。

位置は GPS ロガーにより測定する。その際、GPS 測位された点をそれに最も近い走行経路上の点へとマッチングさせて測定する。

車間距離測定を実現する技術には既に様々なものが開発されているが、本研究では手作業による以下の手法を用いる。この手法は画像上に写った先行車両の見かけ上の大きさとそれに対する実距離の関係に基づき、車頭距離 s を単眼カメラの撮影画像（レンズ歪み補正済み）の分析結果から下式により導出するものである。

$$s = \frac{2wp_0}{p \tan(\theta_0/2)} + l \quad (8)$$

ここに、

p : 先行車両の見かけ上の車体サイズ [pixel]

w : 先行車両の実際の車体幅サイズ [m]

l : 先行車両の車長 [m]

p_0 : 撮影画像サイズ [pixel]

θ_0 : カメラレンズの画角 [rad]

である。この内、 p_0, θ_0 は既知であるため、測定の誤差になりうる要素は l, p, w である。 p は手作業で検出し、 l, w は経験的に知られている平均車両サイズから仮定する。なお、先行車両が存在しない場合（例：あまりに遠いため検出不可能な場合、カーブにより見えない場合）、暫定的に $s = 100\text{m}$ とする。

3.2 高速都心環状線

高速都心環状線にて、2013 年 9 月 24 日（火）の 15:00～16:00 に実道実験を実施した。

高速都心環状線は東京都心に位置する都市高速道路である（図 2(a)）。観測区間は内回り方向の霞が関トンネル出口付近（谷町 JCT 上流部）から千代田トンネル入口付近（竹橋 JCT 付近）の走行車線、計 11 km である。

本路線は路側超音波感知器を用いた定点観測網が整備されており（時間分解能：1 分，空間分解能：車線毎に平均 250 m），この観測結果を真値とみなす。

プローブとして、単眼カメラと GPS ロガーを装備した普通車 20 台を使用し、各車両が平均 3 周の周回走行を行った。このとき、プローブの流率は 42.1 veh/h/lane であり、車両感知器データから概算される全車両の流率 1255 veh/h/lane と比較すると、プローブ混入率は約 3.5% となる。図 2(b) に車載カメラの画像例を示す。また、プローブカーによって観測された time-space diagram の一部を図 2(c) に示す。ここに、横軸は時間、縦軸は空間、実線はプローブの軌跡、青領域はプローブとその同一車線先行車両との間の時空間領域である。

なお、本実験実施状況の詳細は瀬尾ら⁸⁾にて記述されており、あわせて参照されたい。

3.3 Pasteur 通り

ベトナム、ホーチミン市の Pasteur 通りにて、2014 年 3 月 7 日（金）の 16:00～17:30 に実道実験を実施した。

Pasteur 通りは、ホーチミン市中心部に位置する一般道である（図 3(a)）。本路線は四輪車用 2 車線と二輪車用 1 車線からなる延長約 1.5km の信号有一方通行道路である。車種別車線が設定されているものの、厳密に分離しての運用はされてはおらず、四輪車と二輪車の混合流となっている。そのため、高速都心環状線と比較し、交通流特性が著しく異なることが予想される。

交通流率の真値を得るため、本路線の二地点（図 3(a)中の灰色丸）にて路側ビデオカメラにより交通量を測定した。


プローブとして、単眼カメラと GPS ロガーを装備したタクシー 10 台を使用し、各車両が平均 3 周の周回走行を行った。これは、定点観測によって得られた交通量（約 600 veh/h）と比較すると約 2% のプローブ混入率に相当する。図 3(b) に車載カメラの画像例を示す。また、プローブによって観測された time-space diagram の一部を図 3(c) に示す。ここに、青領域はプローブとその同一車線先行四輪車との間の時空間領域を意味する。高速都心環状線の time-space diagram（図 2(c)）と比較し、乱雑な交通流であることがわかる。その原因には信号、混合流、運転者特性が考えられる。

4. 推定結果

4.1 高速都心環状線

全てのプローブデータを用い、(5 min, 500 m) 分解能で密度を推定した結果を図 4(a) に示す。感知器の観測値（図 4(b)）と比較し、交通現象を良く再現できていることがわかる（例：8km 付近を先頭とした渋滞の延伸）。また、本推定手法は任意分解能での推定が可能であるため、先行研究⁷⁾の推定手法の問題であった「分合流地点での推定誤差」が見られないことがわかる。


様々なプローブ混入率 P と時空間分解能 $(\Delta t, \Delta x)$ の設定のもとでの流率の推定誤差を表 1 に示す。ここで、推定誤差の RMSPE は二乗平均平方誤差率、Bias は偏りを意味し、それぞれ $\text{RMSPE}(\hat{\theta}) = \sqrt{E[(\hat{\theta} - \theta)^2]}$ 、 $\text{Bias}(\hat{\theta}) = \sqrt{E[\hat{\theta} - \theta]}$ と定義される。低いプローブ混入率の推定誤差は、プローブをランダムに間引いて推定する作業を 20 回行い、その全ての結果から算出した。表 1 からは、プローブ率が高いほど、分解能が粗いほど推定精度が良い傾向があるとわかる。例えば、プローブ混入率 3.5% あれば、都市内高速のような密な車両感知器に相当する (5 min, 500 m) 分解能での推定がある程度の精度で可能であった。一方、プローブ混入率 0.2%（プローブカーが 1 時間当たり 2 台走行）のときは、1 時間交通量が高精度で推定可能であった。偏りについては、推定量は過大推定される傾向をもっている（式 (4)）が、推定結果は過小推定の傾向にある。これは、プローブカーの運転挙動に偏りがあり、他車両と比較し 10% ほど低速であったためと考えられる。いずれにせよ、真の平均流率が 1255 veh/h であったことを考えると、偏りは大きくないといえる。



(a) 地図




(b) 車載カメラ画像の例



(c) time-space diagram の例


Fig.2 高速都心環状線での実道実験



(a) 地図



(b) 車載カメラ画像の例



(c) time-space diagram の例

Fig.3 Pasteur 通りでの実道実験

Table 1 高速都心環状線での流率の推定結果

P	Δt	Δx	RMSPE($\hat{q}$)	Bias($\hat{q}$)
	[min]	[m]		[veh/h]
0.2%	5	500	42.8%	44.3
0.2%	60	11000	16.4%	-159.0
1.0%	5	500	43.1%	21.1
1.0%	60	11000	11.6%	-134.5
3.5%	5	500	26.3%	-82.4
3.5%	60	11000	12.9%	-161.4

Table 2 Pasteur 通りでの流率の推定結果

P	Δt	RMSPE($\hat{q}$)	Bias($\hat{q}$)
	[min]		[veh/h]
0.2%	5	57.9%	63.8
0.2%	60	42.0%	91.0
1.0%	5	52.7%	52.9
1.0%	60	18.4%	-11.4
2.5%	5	55.4%	14.3
2.5%	60	7.9%	-20.5

4.2 Pasteur 通り

全てのプローブデータを用い、5 min 分解能で地点通過累積台数を推定した結果を図 5 に示す。図中の点線はそれぞれの地点で路側観測により得た真の累積台数である。真値と推定値の傾向は概ね類似していることがわかる。

様々なプローブ混入率 P と時間分解能 Δt の設定のもとでの流率の推定誤差を表 2 に示す。高速都心環状線での結果 (表 1) と同様に、プローブ率が高いほど、分解能が粗いほど推定精度が良い傾向があるとわかる。

しかし、全体的に高速都心環状線での結果と比較すると推定精度が低い。これは、交通流が乱雑であり、車両毎に経験する車間距離に大きな分散があるためと考えられる (式 (6))。そのため、高分解能での推定には問題がみられるが、 $|\mathbf{P}(\mathbf{A})|$ が大きくなる低分解能での推定は高精度という結果となった。

5. おわりに

本研究では、カメラ等の車載機器により車間距離が測定できることに着目し、移動体観測のみによる任意分解能での交通状態の推定手法を述べた。また、高速




Fig.4 高速都心環状線の密度の time-space diagram




Fig.5 Pasteur 通りでの地点通過累積台数

都心環状線とベトナム一般道という全く性質の異なる2路線にて実道実験を実施し、提案するプローブデータを収集した。そして、得られたデータに基づき交通状態を推定し、定点観測データと比較することでその性質を検証した。その結果、両路線共に、プローブ率が高いほど、また分解能が粗いほど推定精度が良いという傾向を定性的にも定量的にも示した。本推定手法は q - k 関係といった外生的仮定に依存していないため、これらの極端に性質の異なる路線で同様の性質を示したと考えられる。具体的には、高速都心環状線では、数%のプローブ混入率であれば分単位の交通状態がある程度の精度で推定可能であった。0.2%という低いプローブ混入率の場合には、時間単位の交通状態が高精度で推定可能であった。一方、ベトナム一般道は、交通流の乱雑さのために高速都心環状線と比較し推定精度が低い傾向にあった。それでも、1%のプローブ混入率であれば、時間単位の交通状態が高精度で推定可能であった。

今後の課題としては、まず自動的・機械的な車間距離測定技術の導入が考えられる。交通流の乱雑さに起因する誤差の緩和(平滑化)には、車間距離測定プローブカーの観測データに基づき q - k 関係を内生的に逐次推定した上で、交通流モデルとのデータ同化手法⁽¹⁾を

適用することが有効と考えられる。

謝辞

高速都心環状線の車両感知器データは首都高速道路(株)に提供頂いた。ベトナムでの実道実験はホーチミン市工科大学の Dr. Van Hong Tan に協力頂いた。本研究の一部は(独)日本学術振興会の特別研究員(DC2)制度の助成を受けている。ここに感謝の意を表します。

補注 *1

式(4)に示した推定量 $\hat{q}(\mathbf{A})$ の偏りの近似値を導出する。 $|\mathbf{a}_n(\mathbf{A})|$ について、 $|\mathbf{a}_n(\mathbf{A})| \simeq d_n(\mathbf{A})\bar{h}_n(\mathbf{A})$ との近似が成り立つ。ここに、 $\bar{h}_n(\mathbf{A})$ はプローブ n の領域 $\mathbf{A}$ 中での平均車頭時間である。 $d_n(\mathbf{A})$ と $\bar{h}_n(\mathbf{A})$ が統計的に互いに独立であると仮定すると、真の流率 $q(\mathbf{A})$ は

$$\begin{aligned}
 q(\mathbf{A}) &= \frac{E[d_n(\mathbf{A})]}{E[|\mathbf{a}_n(\mathbf{A})|]} \\
 &\simeq \frac{E[d_n(\mathbf{A})]}{E[d_n(\mathbf{A})\bar{h}_n(\mathbf{A})]} \\
 &\simeq \frac{1}{E[\bar{h}_n(\mathbf{A})]} \quad (*)1
 \end{aligned}$$

と近似できる。同様に、式 (1) も以下のように近似できる。

$$\hat{q}(\mathbf{A}) \simeq \frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]} \quad (*2)$$

ここに、 $E_{\mathbf{P}(\mathbf{A})}[\theta_n]$ は $\{\theta_n \mid \forall n \in \mathbf{P}(\mathbf{A})\}$ の平均である。

ところで、 $f(X) = 1/X$ の $E[X]$ 周りでの Taylor 級数は以下である。

$$\frac{1}{X} = \frac{1}{E[X]} - \frac{1}{E[X]^2} (X - E[X]) + \frac{1}{E[X]^3} (X - E[X])^2 - \frac{1}{E[X]^4} (X - E[X])^3 + \dots \quad (*3)$$

両辺の期待値をとると、

$$E\left[\frac{1}{X}\right] = \frac{1}{E[X]} - 0 + \frac{Var[X]}{E[X]^3} - 0 + \dots \quad (*4)$$

である。 X に $E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]$ を代入し、4 次項以降を省略すると、プローブがランダムサンプリングされているとき $E[E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]] = E[\bar{h}_n(\mathbf{A})]$ 、 $Var[E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]] \simeq Var[\bar{h}_n(\mathbf{A})]/|\mathbf{P}(\mathbf{A})|$ であることから、

$$E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]}\right] \simeq \frac{1}{E[\bar{h}_n(\mathbf{A})]} + \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{Var[\bar{h}_n(\mathbf{A})]}{E[\bar{h}_n(\mathbf{A})]^3} \quad (*5)$$

が得られる。

以上、式 (*1)、式 (*2)、式 (*5) より、

$$E[\hat{q}(\mathbf{A})] \simeq q(\mathbf{A}) + \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{Var[\mathbf{a}_n(\mathbf{A})]/d_n(\mathbf{A})}{E[\mathbf{a}_n(\mathbf{A})/d_n(\mathbf{A})]^3} \quad (*6)$$

が導ける。これは推定量 $\hat{q}(\mathbf{A})$ の偏りの近似値である (ちなみに、 $\hat{q}(\mathbf{A})$ は式 (*4) の 2 次項以降を省略し同様の代入をしたものであり、1 次近似といえる)。推定量 $\hat{k}(\mathbf{A})$ の偏りの近似値も同様に導出できる。

補注 *2

式 (6) に示した推定量 $\hat{q}(\mathbf{A})$ の RMSE の近似値を導出する。 $\hat{q}(\mathbf{A})$ の RMSE は $RMSE(\hat{q}(\mathbf{A})) = \sqrt{E[(q(\mathbf{A}) - \hat{q}(\mathbf{A}))^2]}$ で定義され、

$$\begin{aligned} RMSE(\hat{q}(\mathbf{A})) &= \sqrt{E[(q(\mathbf{A}) - \hat{q}(\mathbf{A}))^2]} \\ &= \sqrt{E\left[\left(\frac{1}{E[\bar{h}_n(\mathbf{A})]} - \frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]}\right)^2\right]} \\ &= \sqrt{\frac{1}{E[\bar{h}_n(\mathbf{A})]^2} - \frac{2}{E[\bar{h}_n(\mathbf{A})]} E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]}\right] + E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]^2}\right]} \\ &\simeq \sqrt{\frac{1}{E[\bar{h}_n(\mathbf{A})]^2} - \frac{2}{E[\bar{h}_n(\mathbf{A})]} \left(\frac{1}{E[\bar{h}_n(\mathbf{A})]} + \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{Var[\bar{h}_n(\mathbf{A})]}{E[\bar{h}_n(\mathbf{A})]^3}\right) + E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]^2}\right]} \\ &= \sqrt{E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]^2}\right] - \frac{1}{E[\bar{h}_n(\mathbf{A})]^2} - \frac{2}{|\mathbf{P}(\mathbf{A})|} \frac{Var[\bar{h}_n(\mathbf{A})]}{E[\bar{h}_n(\mathbf{A})]^4}}. \quad (*7) \end{aligned}$$

と変形できる。補注*1 と同様に、 $f(X) = 1/X^2$ の $E[X]$ 周りでの Taylor 級数の両辺の期待値をとり、 X に $E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]$ を代入し、4 次項以降を省略すると、

$$E\left[\frac{1}{E_{\mathbf{P}(\mathbf{A})}[\bar{h}_n(\mathbf{A})]^2}\right] \simeq \frac{1}{E[\bar{h}_n(\mathbf{A})]^2} + \frac{1}{|\mathbf{P}(\mathbf{A})|} \frac{3Var[\bar{h}_n(\mathbf{A})]}{E[\bar{h}_n(\mathbf{A})]^4} \quad (*8)$$

が得られる。

以上、式 (*7) と式 (*8) より、

$$RMSE(\hat{q}(\mathbf{A})) \simeq \frac{1}{E[\mathbf{a}_n(\mathbf{A})/d_n(\mathbf{A})]^2} \sqrt{\frac{Var[\mathbf{a}_n(\mathbf{A})/d_n(\mathbf{A})]}{|\mathbf{P}(\mathbf{A})|}} \quad (*9)$$

が導ける。推定量 $\hat{k}(\mathbf{A})$ の RMSE の近似値も同様に導出できる。

参 考 文 献

- 1) オートパイロットシステムに関する検討会: オートパイロットシステムの実現に向けて中間とりまとめ, 国土交通省, 2013.
- 2) 小島祥子, 目黒淳一, 鈴木徳祥, 寺本英二: 汎用 GPS と車載カメラ画像を用いた高精度地図生成手法の提案: 基本概念と可能性検討, 電子情報通信学会技術研究報告. ITS, Vol. 110, No. 469, pp. 35–40, 2011.
- 3) 浅田拓海, 亀山修一: 走行車両から撮影した画像を用いた道路区画線診断方法の開発, 土木学会論文集 D3, Vol. 68, No. 4, pp. 358–368, 2012.
- 4) 実吉敬二, 塙圭二, 十川能之, 荒井一真: ステレオ画像を用いた運転支援のための前方状況認識システム, 電子情報通信学会技術研究報告. PRMU, Vol. 97, No. 41, pp. 39–46, 1997.
- 5) Yokoi, K., Suzuki, Y., Sato, T., Abe, T., Toda, H., and Ozaki, N.: A camera-based probe car system for traffic condition estimation, in *Proceedings of 20th ITS World Congress*, 2013.
- 6) 柴田潤: 注目される Local Dynamic Map の概念と世界標準化の動き, DRM セミナー, 日本デジタル道路地図協会, 2010.
- 7) 瀬尾亨, 日下部貴彦, 朝倉康夫: 車間距離を計測するプローブカーを前提とした交通状態の推定手法, 土木学会論文集 D3 (土木計画学), Vol. 69, No. 5, pp. I.809–I.818, 2013.
- 8) 瀬尾亨, 日下部貴彦, 朝倉康夫: 車間距離測定プローブカーを用いた都市高速道路の交通流観測実験報告, 第 34 回交通工学研究発表会論文集, pp. 277–283, 2014.
- 9) Edie, L.: Discussion of traffic stream measurements and definitions, in Almond, J. ed. *Proceedings of the 2nd International Symposium on the Theory of Traffic Flow*, pp. 139–154, 1963.
- 10) 小林桂子, 和田健太郎, 桑原雅夫: プローブ車両軌跡データをを用いた交通の量的把握, 土木計画学研究発表会・講演集, Vol. 50, 2014.
- 11) 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.