

車両プローブ情報に基づく 信号待ち車列長変動の分析モデル

丹下 智之¹ 廣森 聰仁¹ 梅津 高朗² 山口 弘純¹ 東野 輝夫¹

概要：近年、道路交通における効率性や快適性の向上を目指し、高度交通システム(ITS)に関する研究が多数実施されている。なかでも、カーナビゲーションシステムなど、個々の車両に搭載された各種センサから、走行速度や位置情報など走行車両についての様々な情報をリアルタイムに収集するプローブカーシステムが注目を集めている。本研究では、信号機に起因する交通渋滞について、赤信号中における車列長の増大と、青信号になり車両が順次発進することによる車列長の減少についてモデル化し、各信号サイクルにおける車列長を推定する手法を提案する。提案手法では、信号への車両の到着はポアソン過程にしたがうと仮定し、各信号サイクルについて車列長の推定を行う。提案手法の性能を評価するため、交通シミュレータを用いて評価実験を行った。実験では、車両群の一部をプローブカーとして無作為に抽出し、それらの走行軌跡情報をプローブカーデータとして、提案手法により車列長の推定を行った。その結果、誤差5台程度の精度で車列長が推定できることを示した。

Analysis Model of the Fluctuation of Queue Length at Signals Based on Vehicle Trajectories

TOMOYUKI TANGE¹ AKIHITO HIROMORI¹ TAKAAKI UMEDU² HIROZUMI YAMAGUCHI¹
TERUO HIGASHINO¹

1. はじめに

近年の高度交通システム(Intelligent Transportation Systems, ITS)の発展により、道路交通における人々の快適性や安全性が日々向上している。我が国における代表的な高度交通システムとして、道路交通情報通信システム(Vehicle Information and Communication System, VICS)が挙げられる[1]。このシステムでは、光ビーコンやループ式車両感知器といった固定型のセンサを道路に設置し、交通情報をリアルタイムに把握・提供することで道路網上の交通流の円滑性・安全性の向上が実現されている[2,3]。しかしながら、センサを利用するシステムは、センサが設置された道路に関する交通状況のみしか得られないため、広範囲に渡り交通状況を把握する用途には不向きである。

一方、道路上に設置されたインフラに頼らないシステムとして、プローブカーシステムが注目されている。プローブカーとは、GPSや速度計などのセンサに加えて無線通信機器を搭載し、位置情報や速度情報などの様々な情報を収集する車両である。プローブカーシステムでは、個々のプローブカーが走行した道路についての交通状況を把握できるため、複数のプローブカーを組み合わせることで広範囲の道路状況を把握することができる。プローブカーから収集されたデータ(以下プローブカーデータ)を活用することで、道路交通の円滑化を図る取り組みが数多く実施されている[4,5]。商用のプローブカーシステムの一つとして、本田技研工業株式会社の“インターナビ”が挙げられる[6]。このシステムでは、システム利用者の車両にセンサを搭載し、収集された統計情報とVICS情報に基づいた渋滞予測や、目的地により早く到着可能な経路の案内など、ドライバーにとって有益な情報を提供している。同様に、他の各社のカーナビゲーションシステムにおいても、プローブカーデータが利用され、広く活用されている。特に、道路

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

² 滋賀大学 経済学部
Faculty of Economics, Shiga University

の混雑状況に応じて、目的地までの最短経路を提示するサービスは、快適な道路交通を実現するため欠かせないものである。

これまでにもプローブカーの走行軌跡情報を用いて旅行時間や交通量などの交通状況の把握を試みる研究が多数実施されている。しかし、車両全体に占めるプローブカーの割合は、現状では 1 % 程度であり、僅かな走行軌跡情報から車両全体の交通状況を把握することは容易ではない。文献 [7,8]においては、過去に蓄積されたプローブカーデータと現在のプローブカーデータを比較することで、現在の交通状況を把握する手法を提案している。また、Ryan [9] らは、マルコフモデルを用いて、プローブカーの走行軌跡情報から交通状況の推定、予測を行っている。これらの手法では、過去に収集した車両走行軌跡情報を用いてモデルのパラメータを推定しているため、交通事故の発生時など、交通状況が通常時と大きく異なる場合に適応することは困難である。

本研究では、信号機を起点として生じる交通渋滞について把握するため、赤信号中に車両が到着することによる車列の増大と、青信号になり車両が順次発信していくことによる車列の減少についてモデル化を行い、プローブカーの走行軌跡情報から信号待ち車列長の変動について分析を行う手法を提案する。各信号サイクルでの信号待ち車列長を把握することで、旅行時間の推定精度向上や、リンク交通量の推定、また、それらの信号サイクル間での変動を推定することができると考えられる。提案手法では、信号待ち車列のモデルを用いて車両の信号前での停止・発進の挙動を把握することで、各信号サイクルごとに車列長・青信号終了時まで通過できずに残った車両の台数の推定を行う。信号待ち車列のモデル化にあたり、車両はポアソン過程にしたがって到着することを仮定している。プローブカーの停止時間・停止位置から、ポアソン過程のパラメータを算出し、帰納的に各サイクルごとの交通状況を複数サイクル単位でリアルタイムに推定する。

提案手法の性能を評価するため、交通シミュレータ Visum [10] を用いて信号待ち車列長を推定し、その推定精度について考察を行った。評価実験では、走行する車群から無作為に抽出した走行軌跡情報をプローブカーデータとみなし、この情報に対して提案手法を適用した。評価実験の結果、リンク上に十分車両が存在すれば、平均車列長 20 台程度に対して、誤差 3 台程度で最大車列長を推定できることが示された。

2. 関連研究

交通状況を把握する手法としては、道路や交差点に設置された車両感知器など固定型のセンサを利用する手法が挙げられ、様々な取り組みが為されている [11,12]。これらの手法は、同一車両を道路に配置された二つのセンサで感

知し、その走行速度を把握することで、交通状況を把握するものである。交通状況を表す指標の一つとして、ある地点からある地点の移動に要する通行時間を旅行時間が挙げられ、固定型センサを利用し、旅行時間を推定する手法がいくつか提案されている [12–14]。Kwon らの手法 [12] は、過去に蓄積された旅行時間と車両検知器から取得した車両の存在情報から、線形回帰により旅行時間を予測する手法である。実際のデータを基に、提案手法により旅行時間を予測した結果、20 分後の旅行時間であれば高精度に予測できることを示している。また、Rice ら [13] は、未来の旅行時間が現在の旅行時間に線形に依存する性質を利用し、高速道路の各セグメントにおける現在の旅行時間を予測する手法を提案している。また、各セグメントに対する予測だけでなく、隣接するセグメントの旅行時間を考慮することにより、一時間後の旅行時間を 10 パーセント程度の誤差で予測できることを示している。Wang ら [14] は、カルマンフィルターを用いることにより、天気、速度規制などの外部要因の動的な変動を考慮しており、様々な状況に応じて、適切に旅行時間を予測可能なモデルを提案している。一方、都市部の交通量を推定する手法として、都市に密に配置されたセンサの接続関係を考慮し、これらを状態空間モデルとしてモデル化することで、交通量の変化を予測する手法も提案されている [15]。性能評価実験では、単純な自己回帰移動平均モデル (ARIMA) による交通量の予測と比較し、提案手法により、最大で平均絶対誤差率を 8 パーセント改善できたことを示している。このように、あらかじめ道路に設置された様々なセンサを用いることによって交通状況を予測する手法は数多く提案されており、特定の道路に対しては、交通状況を高精度に予測できることが示されている。しかしながら、これらの手法は、センサが設置されていることを前提としており、広範囲の交通状況を把握するためには、多数のセンサを配置する必要があり、センサ自体のコストだけでなく、センサを設置するコストも問題となる。

一方、電波・光ビーコン、ループ式車両感知機などのような道路網に設置する固定型のセンサと異なり、プローブカーは、広範囲に渡るデータをリアルタイムかつ低コストで収集することが可能であり、プローブカーシステムを活用した特徴的な取り組みとして、都市を対象とした広域の交通調査が挙げられる [16,17]。Fabritiis ら [16] は、ローマの環状高速道路において、600,000 台以上の車両から収集された 3 分間隔のプローブカーデータから、交通状況の推定と予測を行う手法を提案している。提案する手法は、ニューラルネットワークを利用したパターンマッチングに基づく手法で、30 分後の平均速度を 3.5 から 9.5 [km/h] 程度の誤差で予測できることを示している。Yokota ら [17] は、300 台のトラックからプローブカーデータを収集し、プローブカーが通過する頻度に基づき道路網を二つのモデル

に分類している。これらのモデルを活用することにより、京阪神におけるプローブデータの密度、平均通過時間、平均通過スピードを精度よく推定できることを示している。Lee ら [18] はプローブカーデータを蓄積し、データマイニング手法を活用することで交通量の変化パターンをリアルタイムに発見する手法を提案している。

また、より詳細に交通状況を把握するために、リンクレベルでの交通状況を推定する取り組みも多数実施されている。例えば、交差点における車列の長さを推定することにより、各交差点の混雑の程度を把握する手法がいくつか提案されている [19–21]。Comert ら [19] は、各リンクにおいて観測されたプローブカーの停止位置に基づき、交差点における車列の長さを確率モデルとして定式化することにより、車列の長さを予測している。Cheng ら [20] はショックウェーブ理論 [22] に基づき、プローブカーにより得られる走行軌跡から、車列が伸縮する様子を数理的にモデル化することにより、車列の長さを推定する手法を提案している。Unal ら [23] も同様にショックウェーブ理論に基づき、車列の長さを推定する手法を提案しており、プローブカーが 3 割程度存在する際には、高い精度で車列の長さを推定できることを示している。さらに、交差点に設置された固定型のセンサを活用した手法も提案されており、Cai ら [21] は 10% 程度の誤差で車列の長さを推定できることを示している。また、各リンクの旅行時間を推定する手法も多数提案されている。Nakata ら [24] は、長期間蓄積したプローブカーデータから、日、週、季節など異なる周期の交通流の変動を抽出し、それらに基づきリンク旅行時間を予測する手法を示している。Uno ら [7] も同様に長期間蓄積したプローブカーデータを活用したものであり、定められたスケジュールに基づき運行するバスから得られるプローブカーデータを蓄積することで、地理空間と時空間の両方を網羅したデータベースを構築し、高い精度でリンク旅行時間を予測できることを示している。Lee ら [8] は、蓄積されたプローブカーデータから、データマイニング手法を活用することで、交通量の変化パターンを発見し、それらに基づきリアルタイムにリンク旅行時間を予測する手法を提案している。

このように、プローブカーデータを用いて交通状況を把握及び予測する手法は多数提案されているが、これらが多くが過去に蓄積したプローブデータとリアルタイムなデータを比較することで実現されており、交通事故などの突発的な状況変化を適切に把握できない。これに対し、本研究では、過去のデータを蓄積及び分析することなく、個々のプローブカーの詳細な走行軌跡を分析することで、詳細な信号待ち車列の把握を実現している。

3. 信号待ち車列長の推定

本章では、各信号サイクルにおいて、赤信号中に車両が

到着することによる車列長の増大と、青信号で車両が発進することによる車列長の減少についてのモデル化について述べ、これを用いた車列長の推定方法を説明する。本モデルでは、各車両はポアソン過程にしたがって到着すると仮定し、プローブカーの停止位置から車両の到着率を算出する。そして、この値を基にして各信号サイクルにおける車列長の推定を行う。また、定式化を行うにあたって、まず、本研究における信号待ち車列の定義と、信号機前の車列の挙動について説明する。

3.1 信号待ち車列の定義

まず、本研究における車列の定義について説明する。信号待ち車列とは、赤信号のときに停止している車両群のことを表す。なお、本研究では、速度があらかじめ定めたしきい値 s [km/h] を下回った車両については十分に減速しており、停止しているとみなす。信号へ接近するプローブカーの速度が s を下回った際に、そのプローブカーは車列の末尾に加わったと見なし、その瞬間の車両位置から、その時点での車列長を計算する。なお、本稿では $s = 2$ [km/h] をしきい値として用いる。

3.2 信号待ち車列長の形成と解消

図 1 および図 2 は、それぞれ非混雑時、混雑時における車列長の時間変化を単純に表したものであり、横軸は時間、縦軸は車列長を表している。赤信号にサイクルにおいて車列長は増大し、青信号になる直前に車列長はそのサイクルにおける最大車列長に到達する^{*1}。そして、青信号の間は車両が順次発進することで車列長は減少する。非混雑時においては、1 回の赤信号サイクルで成長した車列は次の青信号サイクルですべて捌ける。一方で、図 2 に示すような混雑時では、青信号サイクル中にすべての車列が信号機を通過せず、捌け残り車両が生じる。捌け残り車両の発生は、青信号サイクルで通過することのできる車両台数の最大値(キャパシティ)を超える車列が形成されたためである。このキャパシティが各サイクルごとで不变であるとすると、各信号サイクルにおける最大車列長とそのキャパシティを算出することで、これらの差から捌け残り台数を推定できると考えられる。

3.3 モデル化における仮定

モデル化を行うにあたって、以下のことを仮定する。
車両の平均車頭距離は既知 車両が信号待ち車列において、前から何台目に停車しているかを求めるため、本研究では、車両の信号機までの距離と、停止時の平均車頭距離(車両の先頭から、後続車の先頭までの距離)を用

^{*1} 青信号の間に発進する台数以上の車両の到着があった場合は、なおも車列長が伸び続ける可能性があるが、提案手法では赤信号終了時の車列長を最大と呼ぶことにする。

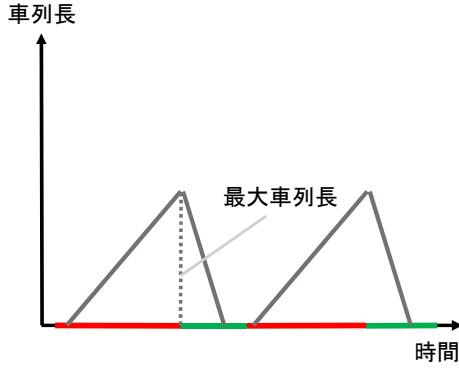


図 1 車列長の変動（非混雑）

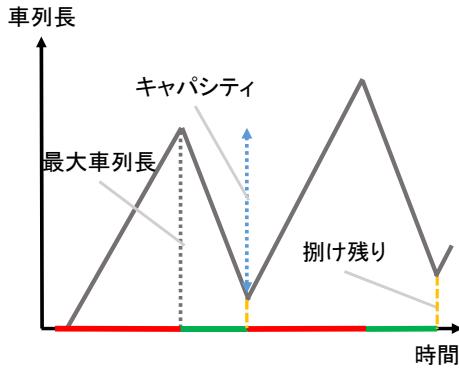


図 2 車列長の変動（混雑）

いる。本研究では、リンクに到着しうる車両の平均車頭距離 L [m] は統計データなどから得られているものとする。

信号の情報は既知 赤信号のスケジュール、すなわち、赤信号の開始時刻および持続時間、青信号の開始時刻および持続時間はそれぞれ既知であるとする。また、信号と停止線の位置も既知であり、何らかの形で提案システムから利用可能なデータとして存在するとする。

車両位置の計測誤差は十分に小さい 車両軌跡の位置情報は、十分に精度が高いものとする。それにより、プローブカーの位置から前方の停止線までの距離と平均車長 L から、プローブカーの前方に停車中の車両台数を正確に求められるものとする。

捌け残り台数の初期値は 0 提案手法では、車列長の推定を開始した時点では、リンクは十分に空いており、捌け残り車列は存在しないものとする。もし捌け残り車両が存在していた場合には、推定初期の推定結果は比較的大きな誤差を含むこととなるが、この誤差は時間経過と共に解消できる。

3.4 信号待ち車列長の変化の定式化

車両軌跡情報を基に信号待ち車列長を推定するための、車列長の変化についての定式化を行う。以下、信号が赤に変わった瞬間から、次の赤信号の開始までを 1 つの信号サ

イクルとし、各サイクルには通し番号を付与し、以下では i 番目のサイクルをサイクル i というように称する。

3.4.1 最大車列長の定式化

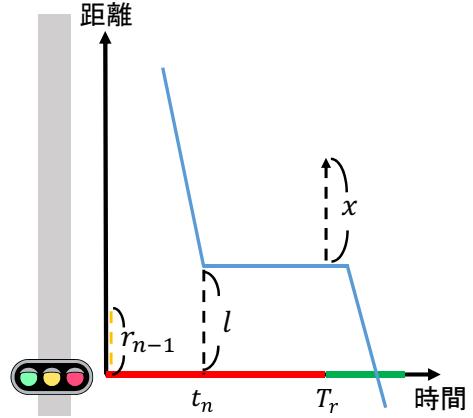


図 3 赤信号で停止した車両軌跡

信号サイクル n において、プローブカーが時刻 t_n に、停止線から l 台目で車列に到着した場合について考える。図 3 における青線は、プローブカーの車両軌跡を表しており、横軸は時間、縦軸は信号機からの距離を表している。車両の到着がポアソン過程に従うと仮定した場合、このとき 1 秒あたりの車両の平均到着率 λ_a は以下の式で表すことができる。

$$\lambda_a = \frac{l - r_{n-1}}{t_n} \quad (1)$$

ここで、 r_{n-1} はサイクル $n-1$ において生じた捌け残り台数を表す。また、サイクル n の赤サイクルが終了するまでの車両の到着率は以下のように表すことができる。

$$\lambda = \lambda_a \cdot (T_r - t_n) \quad (2)$$

なお、 T_r は赤サイクルの長さを表す定数である。ここで、各車両がポアソン過程にしたがって到着すると仮定しているため、時刻 t_n から赤サイクル終了までに新たに x 台到着する確率 $P_a(x)$ は以下のような確率分布で表すことができる。

$$P_a(x) = \frac{\lambda e^{-\lambda}}{x!} \quad (3)$$

ゆえに、赤サイクル終了時の最大車列長は以下の確率分布で表される。

$$P_{max}(x) = \frac{\lambda e^{-\lambda}}{(x-l)!} \quad (x - l \geq 0) \quad (4)$$

同じ赤信号サイクルにおいて、2 台以上の車両が停止した場合については、その車両が到着したときの到着率を求め、ポアソン分布のパラメータについて最尤推定を行う。例として、車両 k が時刻 t_k に車列 l_k 台目で停止し、その後車両 $k+1$ が時刻 t_{k+1} に車列 l_{k+1} 台目で停止したとする。このときこの車両 k が車列に参加してから車両 $k+1$ が車

列に到着するまでの間の到着率 λ_k は以下の式で表すことができる。

$$\lambda_k = \frac{l_{k+1} - l_k}{t_{k+1} - t_k} \quad (5)$$

このようにして、すべての車両間での到着率を求めるとき、ポアソン分布のパラメータの最尤推定量 $\hat{\lambda}$ は標本平均で求めることができるので、以下の式でサイクル内の到着率を求める。

$$\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i \quad (6)$$

3.4.2 挪け残り台数の定式化

最大車列長の確率分布 $P_{max}(x)$ が決定すれば、抜け残り台数についても定式化を行うことが出来る。抜け残り台数は、最大車列長の他に、青信号に変わってから車列における最後尾の車両が動き出すまでに新たに車列に加わる台数から、青信号中に信号機を通過する台数を引くことで求まる。青信号中に信号機を通過した台数（キャパシティ）の算出は次の節で説明する。ここでは、前者の台数について説明する。

図 4 は、図 3 と同様に、信号機前での複数台の車両軌跡を表したものであり、横軸を時間、縦軸を信号からの距離とし、各青線が、個々の車両の挙動を示している。図 4 における灰色の実線は、停止中の車両が加速を行う地点を結んだものであり、この地点は、時間経過によって徐々に信号機から後方方向へ伝播していることがわかる。この伝搬はショックウェーブと呼ばれ、一定の速度で伝播することが知られている。赤信号サイクルで l 台目に停車した車両が時刻 t において加速を始めたとする。このとき、ショックウェーブの速度 v_s [台/s] を以下の式で近似する。

$$v_s = \frac{l}{t - Tr} \quad (7)$$

また、最大車列長の確率分布 $P_{max}(x)$ の期待値を最大車列長として、青信号に変わってから車列の最後尾が動き出すまでの時間 t_e は以下の式で表される。

$$t_e = \frac{E(P_{max}(x))}{v_s} \quad (8)$$

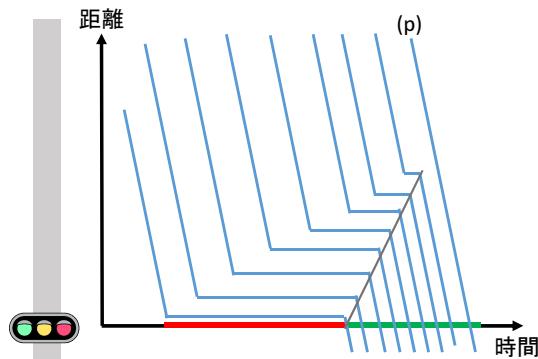


図 4 車両の走行軌跡

よって、図 3 のような軌跡が得られた場合の、車列における最後尾の車両が動き出すまでに構成される新たな車列の長さ $P_e(x)$ は、 λ' を用いて以下のように表される。

$$P_e(x) = \frac{\lambda' e^{-\lambda'}}{(x - l)!} \quad (x - l \geq 0) \quad (9)$$

$$\lambda' = \lambda_a \cdot (Tr + t_e - t_n)$$

抜け残り台数 $P_r(x)$ は、この式にキャパシティ c を用いて、以下の式で表される。

$$P_r(x) = \frac{\lambda' e^{-\lambda'}}{(x - l + c)!} \quad (10)$$

$$x - l + c = 0 \quad \text{if } x - l + c < 0$$

また、以下の式で示すように、この確率分布から求めた期待値を次サイクル開始時の抜け残りとする。

$$r_{n+1} = E(P_r(x)) \quad (11)$$

なお、プローブカーが図 4 中の (p) で示すように、停止することなく停止線を通過した場合、そのプローブカーが到着した時点で信号待ち車列は解消していることがわかる。よって、サイクル n においてプローブカーが停止することなく通過すれば、サイクル n 中の抜け残り車列はすべて信号を通過したことがわかり、 $r_{n+1} = 0$ と決定できる。

3.4.3 キャパシティの算出

プローブカーが停止線前で 2 回以上停止した場合には、 k 回目の停止位置と、 $k + 1$ 回目の停止位置の差から、上述した信号のキャパシティ c を推定することができる。例えば、 k 回目の停止は停止線から l_k 台目、 $k + 1$ 回目の停止は停止線から l_{k+1} 台目であったとする。このとき、プローブカーが l_k 台目から移動したのは信号が青に変わり、前方の車両が移動したためであると考えられる。その後、 l_{k+1} 台目で停止したのは、信号が赤に変わり、前方の車両が停止したためと考えられる。よって、1 回の青信号サイクルで $l_k - l_{k+1}$ 台の車両が停止線を通過したと推定でき、 $l_k - l_{k+1}$ が青信号のキャパシティとみなせることがわかる。

また、停止線前で複数回停止する車両が存在しない場合には、代わりに 1 回停止した軌跡情報を用いる。図 4 で示しているように、各車両が加速を行う地点が伝播する速度は、一定であると考えられる。また、加速後の各車両の速度に大きなばらつきがなければ、青信号に切り替わった後に停止線を通過する車両台数は、時間に比例するといえる。よって、プローブカーが l 台目で停止後、サイクルが始まってから t_p 秒後において停止線を通過したとき、青信号キャパシティ c は以下の式で近似することができる。

$$c = \frac{l}{t_p - Tr} \quad (12)$$

3.5 複数サイクルの車列長推定結果の統合

このような車列長の変動モデルを用いて各信号サイクル毎に車列長の推定を行うにあたって、プローブカーが毎信号サイクル到着する場合は上記の式を漸化式として解き、車列長を求めることができる。しかし、プローブカーが通過せず、情報が得られない信号サイクルが存在する場合や、ある信号サイクルで推定した結果と、その次の信号サイクルでプローブカーによって観測された結果が大きく異なり、矛盾が生じる場合などが存在する。このときの車列長の推定方法について説明する。

3.5.1 一部のサイクルで情報が得られる場合

リンクへの流入交通量は、1日単位で見ると深夜帯や通勤時間などによって大きく異なると考えられるが、数分程度のサイクル時間単位では急激に変化せず、十分緩やかに変化すると仮定できる。よって、プローブカーが到着しない信号サイクルでは、直前のサイクルにおける到着率を用いて計算を行う。

3.5.2 推定結果に矛盾が見られる場合

図5は、ある信号サイクルbにおいて、前サイクルの推定捌け残り台数と到着したプローブカーの停止位置に矛盾がある場合の例である。縦軸と横軸はそれぞれ図4と同じで、青い直線はプローブカーから得られた車両軌跡を示している。サイクルaにおけるプローブカーの移動軌跡から、漸化式として各サイクルの捌け残り台数を求め、サイクルbの開始時における捌け残り台数が図中の破線で表されている。この推定結果が正しければ、プローブカーはこの捌け残り車列の最後尾より後ろで停止しなければならず、そうでなければ、推定結果が誤っていることになる。このような場合には、サイクルaにおける λ の推定が間違っていたとみなし、サイクルaからサイクルbまでの λ の値を推定し直す。提案手法では、サイクルaからサイクルbの間に、常に捌け残りが存在し、車両の到着率 λ が一定であると仮定し、以下の式から、式(13)で示す λ を、その間の λ の値とする。

$$l_a + (T - t_a) \cdot \lambda + t_b \cdot \lambda - c \cdot (b - a) = l_b$$

$$\lambda = \frac{c \cdot (b - a) - l_a + l_b}{T - t_a + t_b} \quad (13)$$

また、上記のような明らかな矛盾が見られる場合だけでなく、算出した到着率 λ が、非現実的に大きな値になる場合や、逆に直前の λ と比較して極端に小さくなる可能性も考えられる。そういう誤差が大きいと思われる λ についても、しきい値を設けるなどして検出し、上述の方法などで再計算すべきであるが、本稿では取り扱わず今後の課題とし、ここでは明らかな矛盾のない限り、求めた λ はすべてそのまま採用することにする。

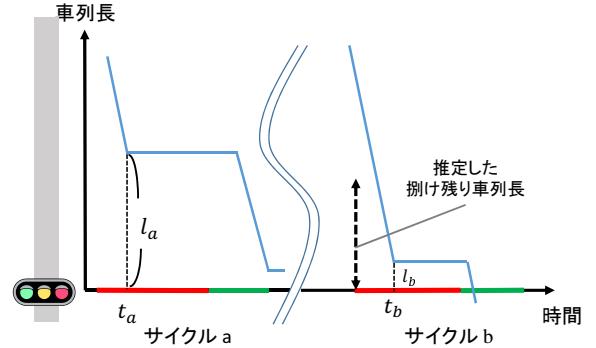


図5 推定結果に矛盾が見られる例

4. 交通状況の変化の検知

本章では、複数の信号サイクル単位間で、流入交通量に変化がないかを判定する手法について説明する。3章で述べた方法で、各サイクルにおける車両の到着率 λ を推定し、この λ の変化を2標本 t 検定を用いることで流入交通量の変化を検知する。

交通量は、数サイクルの間では大きく変化しないと考えられるので、検出の基準とするサイクル数 k を定め、ある k サイクルと、その直後の k サイクルの間で到着率に変化があるかどうかを判定する。具体的には、検出の開始を x サイクル目とした場合、サイクル x からサイクル $x+k-1$ までの到着率が λ_1 、その次の k サイクル分、すなわち、サイクル $x+k$ からサイクル $x+2k-1$ までの到着率を λ_2 とする。交通量が変化せず、 $\lambda_1 = \lambda_2$ であれば、この2群間に大きな違いは見られず、逆に、交通量が変化して、 $\lambda_1 \neq \lambda_2$ であれば、2群間に差が見られると考えられる。そこで、この2群間に差があるかどうかを t 検定を用いて検定する。以下の帰無仮説を設定し、帰無仮説が棄却されれば2群間に差があるとし、交通量が変化したとみなす。なお、このとき2群の平均 $\bar{\lambda}_1$ と $\bar{\lambda}_2$ について、 $\bar{\lambda}_1 > \bar{\lambda}_2$ の関係にあれば交通量が減少しているとみなし、そうでなければ交通量が増加しているとみなす。

$$H_0: \lambda_1 = \lambda_2 \quad (14)$$

5. 性能評価

本章では、提案手法の有効性を検証するため、交通シミュレータVissim [10]を用いて評価実験を行った。実験では、Vissimにより生成した車両群の走行軌跡情報を用いて、提案手法による車列長の推定を行った。この実験は、複数のシナリオのもとで行い、それらの走行軌跡情報に対して提案手法によって推定した最大車列長と捌け残り車列長について考察を行う。

5.1 シミュレーション環境

シミュレーション環境を表 1 に、実験におけるシナリオを表 2 に示す。直線上のリンクには信号機がひとつ設置されており、このリンクを通過する車両軌跡の中から無作為に抽出したものをプローブカーとみなして、提案手法による車列長の推定を行った。なお、プローブカーとして選出する車両の偏りによって、結果に差異があると考えられるので、複数回異なるパターンでプローブカーの抽出を行い、その平均値を算出した。

表 1 シミュレーション環境

リンクの形状	直線一車線
リンクの長さ	400 m
信号サイクルの内容	赤 80 秒、青 40 秒
シミュレーション時間	4800 秒 (40 サイクル)
プローブカー混入率	1 % から 20 % の 9 段階
停止時の車両の専有距離	6.6 [m]

表 2 実験シナリオ

シナリオ	流入交通量
交通量一定 (非混雑)	360 [veh/h]
交通量一定 (やや混雑)	620 [veh/h]
交通量一定 (混雑)	700 [veh/h]
交通量変動 (混雑→非混雑)	360 → 800 → 360 [veh/h]
交通量変動 (非混雑→混雑)	800 → 360 → 800 [veh/h]

5.2 プローブカーが毎サイクル到着する場合の推定精度
プローブカーを無作為に抽出した場合の推定結果を評価する前に、参考としてプローブカーが毎サイクル到着するときの推定精度について議論する。まず、「交通量一定(やや混雑)」のシナリオにおいて、プローブカーが毎サイクル到着する場合における車列長の推定結果の例を示す。ここでは、各サイクルの到着車両からそれぞれ 1 台をランダムに選出してプローブカーとした。なお、最大車列長については得られた確率分布の期待値を推定値としている。図 6 および図 7 は、横軸はサイクル数、縦軸はそれぞれ各サイクルにおける最大車列長と捌け残り車列長を表している。このとき、平均絶対誤差はそれぞれ 2.40 [台], 0.88 [台] である。

このように各シナリオについて平均絶対誤差を求め、さらに、異なるプローブカーの抽出パターンで複数回実験を行い、その平均をとったものを表 3 に示す。表から分かるように、プローブカーが毎サイクル到着すると、いずれのシナリオにおいても平均絶対誤差 3 台以内程度で最大車列長および捌け残り車列長を求めることができるといえる。

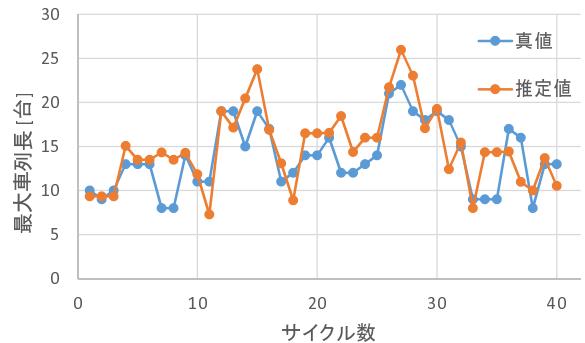


図 6 最大車列長推定結果の例

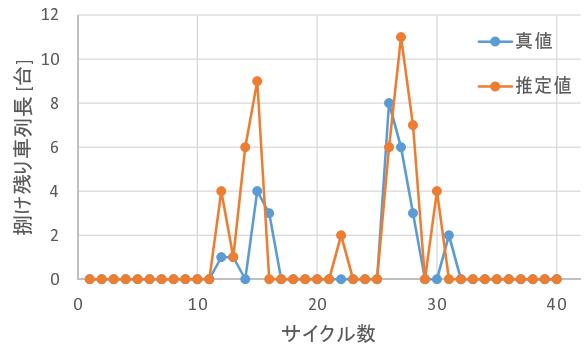


図 7 残け残り車列長推定結果の例

表 3 車列長の平均絶対誤差

シナリオ	最大車列長の平均絶対誤差 [台]	捌け残り車列長の平均絶対誤差 [台]
交通量一定 (非混雑)	3.74	0.03
交通量一定 (やや混雑)	2.42	0.80
交通量一定 (混雑)	2.85	2.40
交通量変動 (混雑→非混雑)	2.21	0.34
交通量変動 (非混雑→混雑)	2.12	0.17

5.3 最大車列長の推定精度

図 8 に、各プローブカー混入率における最大車列長の絶対誤差を示す。いずれのシナリオにおいても、プローブカー混入率が高くなれば車列長をより正確に推定することができる。非混雑時における誤差が比較的大きいが、これは、そもそも流入交通量が少ないために、リンクに存在する車両自体が少ないので、必然的にプローブカーの数が少くなり、得られる情報が減少したためであると考えられる。

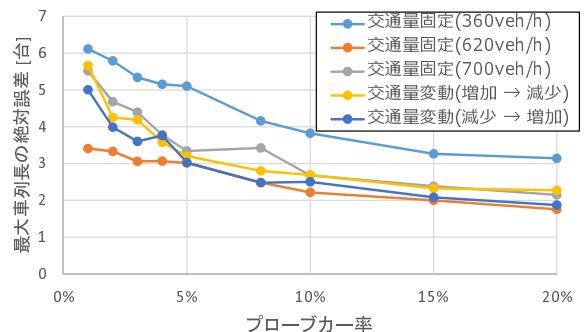


図 8 最大車列長の相対誤差

5.4 拖け残り車列長の推定精度

図 9 に、各プローブカー混入率における最大車列長の絶対誤差を示す。拖け残りが多く存在する混雑状態においては絶対誤差が大きくなっているが、プローブカー混入率が低くても、誤差 5 台以内で推定できることがわかった。それ以外の場合では、プローブカー混入率が低くても、誤差 1 台程度の高い精度で推定できていることがわかった。また、例として、混雑状態における、プローブカー率 3 % で平均絶対誤差が 3.48 となるときの各サイクルの拖け残り車列長の推定結果を図 10 に示す。図の横軸はサイクル数を、縦軸は拖け残り台数を表している。この実験では、サイクル 22~26 ではプローブカーは到着しなかった。そのため、車列長が実際よりも長く推定されてしまったサイクル 21 からサイクル 26 まで、推定車列長が長いままとなってしまい、その間全ての超過分が積算された結果、誤差が大きくなつたと考えられる。

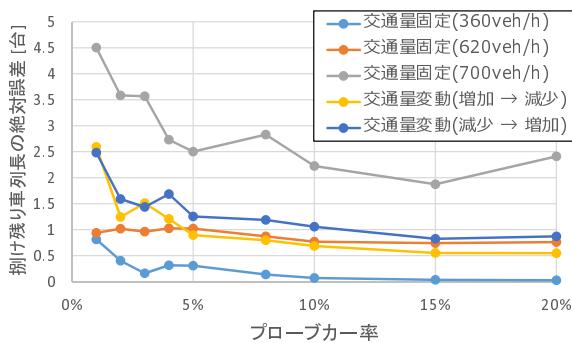


図 9 拖け残り車列長の相対誤差

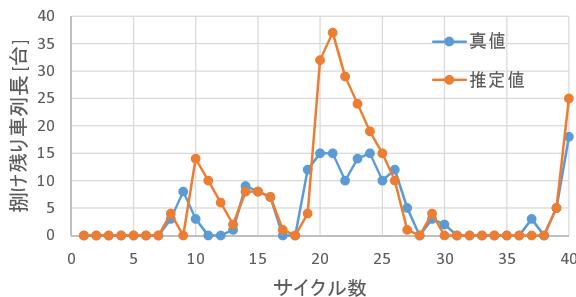


図 10 プローブカー率 3% における拖け残り車列長の推定例

5.5 交通状況変化の検知精度

実験では、10 サイクルごとに流入交通量に変化があったかどうかを検定を行った。検定結果が実際にシミュレータで発生させた交通量の変化と一致したときを正解、そうでなかつたとき不正解とし、その正解率を評価指標とする。図 11 に、各シナリオにおける、プローブカー混入率を変化させたときの検知結果の正解率を示す。交通量が変動するシナリオにおいては、プローブカー混入率が 10 % 程度あれば 80 % 以上の正解率で流入交通量の変化を検知す

ることことができた。しかし、プローブカー混入率が低い場合においては、特に交通量に変動があるシナリオでの正解率が 30 % から 60 % 程度であった。また、交通量一定のシナリオにおいて、プローブカー混入率が高くなると正解率が落ちる現象が見られる。これは、長期的に見た交通量が一定であつても、細かい時間ごと区切ると交通量に差がみられ、この差を検知したために不正解となったケースが多く発生したためであると考えられる。

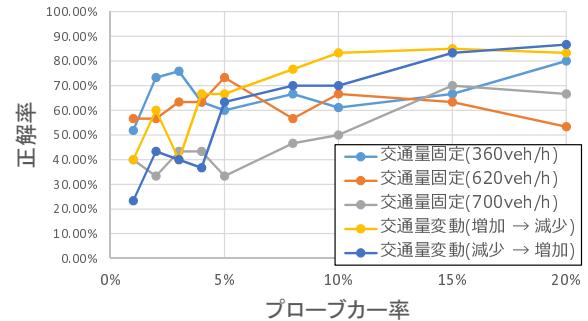


図 11 交通量変化検知の正解率

6. おわりに

本研究では、信号待ち車列の形成モデルとプローブカーの走行軌跡情報を用いて、各サイクルの最大車列長および拖け残り車列長を推定し、流入交通量の変化を検知する手法を提案した。また、提案手法の性能を評価するために交通シミュレータ Vissim を用いて作成した仮想のデータに対し、提案手法を適用するシミュレーション実験を行い、その推定精度と、流入交通量の変化を検知した際の正解率について考察した。その結果、毎サイクルにプローブカーが到着する場合には平均車列長 15 から 20 台程度に対して誤差 3 台程度で車列長を推定できることができた。また、リンク上に十分な数の車両が存在すれば、誤差 5 台以内程度で最大車列長を推定できることができた。

今後の課題として、より正確な信号待ち車列長のモデル化を検討する。また、このモデルが現実世界でどの程度適用できるのかを検証するため、実地実験が必要であると考えられる。さらに、複数のリンクとそれらの関係を想定したモデル化についても検討する。

謝辞

本研究は文部科学省国家課題対応型研究開発推進事業「次世代 IT 基盤構築のための研究開発」「社会システム・サービスの最適化のための IT 統合システムの構築」(2012 年度～2016 年度) の助成を受けたものです。

参考文献

- [1] 道路交通情報通信システムセンター. VICS. <http://www.vics.or.jp/about/>.

- [2] 北村隆一. 交通工学. オーム社, 2008.
- [3] 星埜 和 (編) . 交通工学ハンドブック. 交通工学研究会, 1984.
- [4] 橋本 浩良, 河野 友彦, 門間 俊幸, 上坂 克巳. 交通円滑化対策のためのプローブデータの分析方法に関する研究. 平成 22 年度国土交通省国土技術研究会.
- [5] 田宮 佳代子, 瀬尾 卓也. プローブカーデータを活用した都市内一般道路の qv 特性について. 土木学会第 57 回年次学術講演会, IV-385, 2002.
- [6] 本田技研工業株式会社. Internavi. <http://www.honda.co.jp/internavi/>.
- [7] Nobuhiro Uno, Fumitaka Kurauchi, Hiroshi Tamura, and Yasunori Iida. Using Bus Probe Data for Analysis of Travel Time Variability. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, Vol. 13, No. 1, pp. 2–15, 2009.
- [8] Wei-Hsun Lee, Shian-Shyong Tseng, and Sheng-Han Tsai. A Knowledge Based Real-Time Travel Time Prediction System for Urban Network. *Expert Systems with Applications*, Vol. 36, No. 3, pp. 4239–4247, 2009.
- [9] Ryan Herring, Aude Hofleitner, Pieter Abbeel, and Alexandre Bayen. Estimating arterial traffic conditions using sparse probe data. In *Proceedings of the 13th International IEEE Conference on Intelligent Transportation Systems (ITSC 2010)*, pp. 929–936, Madeira Island, Portugal, 2010. IEEE.
- [10] Vissim. Traffic Simulation with PTV Vissim for Efficient Junction Design.
- [11] 大口敬. 「交通渋滞」徹底解剖. 交通工学研究会, 2005.
- [12] Jaimyoung Kwon, Benjamin Coifman, and Peter Bickel. Day-to-day travel-time trends and travel-time prediction from loop-detector data. *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1717, No. 1, pp. 120–129, 2000.
- [13] John Rice and Erik van Zwet. A simple and effective method for predicting travel times on freeways. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 5, No. 3, pp. 200–207, 2004.
- [14] Yibing Wang, Markos Papageorgiou, Albert Messmer, Pierluigi Coppola, Athina Tzimitsi, and Agostino Nuzzolo. An adaptive freeway traffic state estimator. *Automatica*, Vol. 45, No. 1, pp. 10–24, 2009.
- [15] Anthony Stathopoulos and Matthew G. Karlaftis. A multivariate state space approach for urban traffic flow modeling and prediction. *Transportation Research Part C: Emerging Technologies*, Vol. 11, No. 2, pp. 121–135, 2003.
- [16] Corrado de Fabritiis, Roberto Ragona, and Gaetano Valenti. Traffic estimation and prediction based on real time floating car data. In *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems (ITSC 2008)*, pp. 197–203, Beijing, China, 2008. IEEE.
- [17] Takayoshi Yokota and Dai Tamagawa. Constructing Two-Layered Freight Traffic Network Model from Truck Probe Data. *International Journal of Intelligent Transportation Systems Research*, Vol. 9, No. 1, pp. 1–11, 2011.
- [18] Wei-Hsun Lee, Shian-Shyong Tseng, and Sheng-Han Tsai. A knowledge based real-time travel time prediction system for urban network. *Expert Systems with Applications*, Vol. 36, No. 3, pp. 4239–4247, 2009.
- [19] Gurcan Comert and Mecit Cetin. Analytical Evaluation of the Error in Queue Length Estimation at Traffic Signals From Probe Vehicle Data. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 12, No. 2, pp. 563–573, 2011.
- [20] Yang Cheng, Xiao Qin, Jing Jin, Bin Ran, and Jason Anderson. Cycle-by-Cycle Queue Length Estimation for Signalized Intersections Using Sampled Trajectory Data. *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 2257, pp. 87–94, 2012.
- [21] Qing Cai, Zhongyu Wang, Lingyu Zheng, Bing Wu, and Yinhai Wang. A Shockwave Approach to Estimating Queue Length at Signalized Intersections by Fusing Data of Point and Mobile Sensors. In *Proceedings of the 93rd Annual Meeting of Transportation Research Board*, Washington D.C., USA, 2014.
- [22] M. J. Lighthill and G. B. Whitham. On Kinematic Waves, I. Flood Movement in Long Rivers. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, Vol. 229, No. 1178, pp. 281–316, 1955.
- [23] Ozhan Unal and Mecit Cetin. Estimating Queue Dynamics and Delays at Signalized Intersections from Probe Vehicle Data. In *Proceedings of the 93rd Annual Meeting of Transportation Research Board*, Washington D.C., USA, 2014.
- [24] Takayuki Nakata and Jun-ichi Takeuchi. Mining Traffic Data from Probe-Car System for Travel Time Prediction. In *Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'04)*, pp. 817–822, Seattle, USA, 2004.