

交通監視カメラを用いた市街地の車両モビリティ合成手法

林 和輝¹ 廣森 聡仁¹ 山口 弘純¹ 鈴木 理基² 北原 武²

概要：次世代の交通システムはスマートシティや Society5.0 における重要なコンポーネントであり、その実現に向けて様々な研究開発が行われている。EV の普及による CO₂ 排出量削減量の検証などを始め、それらの取り組みの多くは、地域や都市レベルの大規模なマイクロ交通データを活用し、課題発見や全体最適化などを行うことを想定している。しかし、個々の車両の挙動データを地域レベルで収集することはコストやプライバシーの観点から容易でない。本研究では、地理的に分散配置された複数の交通監視カメラから得られる映像を解析し、そこから得られるデータを用いて対象地域全体の車両モビリティを自動的に合成する手法を提案する。提案手法では、それらの固定カメラから得られた映像に対し、通行車両数や方向、速度を抽出する映像トラッキングを適用する。また、市街地における車両の発着地点間の経路候補をマクロ交通シミュレータを用いて探索する。最後にマイクロ交通シミュレータを用いて、測定した交通量と生成した交通量間の平均絶対パーセント誤差 (MAPE) が最小となるよう、マイクロ車両モビリティを生成する。兵庫県豊岡市出石地区を対象に評価を行った結果を報告する。

1. はじめに

車両の交通状態を把握することは、安全・便利・効率的な交通システムを構築するための重要なポイントとなる。特に、道路計画や都市計画の多くは、交通渋滞の改善や交通安全の向上、効率や利便性の向上を目的としており、都市の発展や経済効果が期待されている。スマートシティ化に向けた取り組みとして、自動車充電スタンドの配置最適化 [1]、都市のモビリティ解析 [2]、スマートグリッドシステム [3]、マルチモーダル交通 [4] などがある。これらのようなアプリケーションの研究・開発には、様々な方法で取得した対象地域のトラフィックデータが利用される。また、エネルギーや時間、コストなどを最適化するために、車両の動きをどのように制御するかに焦点を当てている研究もある [5]。

それらの研究では、既存のトラフィックサーベイなどで得られる限定された車両のみに関するデータや、いわゆる巨視的な移動のみを対象としたデータではなく、各車両の走行挙動をモデル化した細粒度な車両モビリティデータを広域で活用することが求められる。例えば、自動運転車の混入により地域の交通全体がどのような影響を受けるかの評価などでは、自動運転車両および従来の車両それぞれの挙動をモデル化し、それらの混在走行がもたらす渋滞解消あるいは新たな渋滞発生などを理解する必要がある。さ

らに、道路環境や交通状態は対象地域（スマートシティの場合は都市全体）で見られる道路ネットワークや渋滞などの状況を反映するべきである。しかし、コストやプライバシーなどの様々な理由により実際の各車両からデータを得ることが困難であり、このようなデータセットを提供することも困難である。例えば、車両の移動軌跡を取得するためには GPS が活用されることがあるが、クラウドソーシングでは、プライバシーの問題（ユーザーオプトアウトの場合）やデータ不足問題（ユーザーオプトインの場合）のため、利用可能なデータはバスやタクシーなどの公共交通機関のものがほとんどである [6]。また、パーソントリップ調査は、人々の出発地や目的地を得ることができるが、コストの問題のため通常 10 年で 2 回程度の頻度でしか行われぬ。

この解決のため、本稿では、地理的に分散配置された交通監視カメラから得られる映像を用いて市街地全体を対象としたマイクロな車両モビリティを自動的に合成する手法を提案する。我々は、交通監視カメラの映像から道路の交通量を計測できる車両トラッキングシステムを開発した。また、マクロ交通シミュレータを用い、市街地での出発地-目的地間の経路計算を行い、経路の候補群を用いて、各道路を通過する確率を得る。この確率と各発着地間の交通量 (OD 交通量) から各道路の交通量を求めることができるが、その際、OD 交通量をパラメータとし、観測地点で計測した実交通量と、上記で得られた予測交通量との平均絶対パーセント誤差 (MAPE) を最小化するような OD 交通

¹ 大阪大学大学院情報科学研究科

² KDDI 総合研究所

量を発見する。その OD 交通量を用いたマイクロ交通シミュレーションを行うことで、当該地域でのマイクロ車両モビリティを得ることができる。

本稿は以下のように構成される。2 章では関連研究について述べ、3 章では提案手法を示す。4 章では評価環境を示し、5 章で結果と考察を示す。最後に 6 章で結論と将来の展望を示す。

2. 関連研究

2.1 データ収集

スマートシティ化や ITS のための取り組みは多岐にわたる。いくつかの例を表 1 に示す。これらの取り組みのためには様々な形式の交通データが用いられる。利用されるデータの取得方式と特徴を表 2 に示す。表 2 に示すように、交通データを取得する場合にはコストとプライバシーが課題となる。本研究では既設置の交通監視カメラなどのデータを活用することができる。したがって、車両プローブデータなどを用いることなく、かつ一定の再現度で実環境の車両データに近いデータを作成できる利点がある。

2.2 交通量推定

交通シミュレーションは、交通計画・交通運用などで多く活用されている。一般に実地域の交通をシミュレーションするためにはいくつかのパラメータが必要となるが、中でも出発・目的地間の交通量（OD 交通量）は、交通状態を再現するために重要となる。ここで OD とは、車両の出発地（Origin）と目的地（Destination）を意味する。広域の OD 交通量はパーソントリップ調査等から得られるが、粒度および調査実施頻度が低いため、本研究が目指す目的のモビリティを生成するには不十分である。これに対し、OD 交通量推定のための様々な研究が行われている。道路交通量を用いた OD 交通量の推定に関しては、最小二乗法 [13] やエントロピーベースの手法 [14,15]、古典的な統計手法 [16]、ベイズ理論に基づく統計手法 [17] など。その多くが数理計画法に基づいている。しかし、これらは数理モデル化を主目的としており、実環境に近い交通データを生成する用途には適さないといった課題がある。本研究では、複数地点のカメラから得られる映像を解析して得られる複数の道路リンクの実トラフィックデータを活用する。また、あらかじめ出発・目的地（OD 地点・ゾーン）の候補となる地点を決定し、その間の経路を計算する。この経路と道路交通量に基づいて観測した道路交通量と算出する交通量間の MAPE を最小とする OD 交通量を求めることで、実環境におけるモビリティデータ生成に取り組んでいる点で過去のアプローチとは大きく異なる。

3. 提案手法

本研究では地理的に分散配置された交通監視カメラから

交通量を求めるための車両トラッキングを行う。その後、シミュレータで計算した経路を用いて、OD 交通量を算出する。その OD 交通量を用いて作成したシミュレーションから得られる道路交通量と、観測した道路交通量間の RMSE を最小化する OD 交通量を求める。この OD 交通量を用いてシミュレーションを実施し市街地の交通モビリティを再現する。提案手法の概要を図 1 に示す。

3.1 OD 情報

OD 情報の概念図を図 2 に示す。OD 情報とは、出発地（Origin, O）の集合、目的地（Destination, D）の集合、およびそれらのすべての組に対する車両交通量を表す。ここで、出発地または目的地である地点を OD 地点（あるいはゾーン）とよぶ。ある O 地点と D 地点の組み合わせを OD ペアとし、OD ペア間の車両交通量を OD 交通量とよぶ。OD 情報を行列形式で表現したものを OD 行列とよぶことにする。

OD 情報を基にしたシミュレーションの実施を図 3 に示す。OD 情報を用いることでマクロ交通シミュレータによる経路計算を行うことが可能となる。その経路を用いて、マイクロ交通シミュレータより、車両の 1 台 1 台の軌跡や各地点での速度などの走行挙動を取得・可視化することが可能となる。

3.2 車両トラッキングと交通量の数値化

モビリティ合成の対象となる市街地の交通量を得るため、道路や駐車場の出入り口などに交通監視カメラを設置し、左右車線も区別した N 箇所のリンクを撮影する。本手法では 1 日単位でモビリティを再現するとし、対象日において、単位時間ごとに映像を撮影する。撮影を開始した各時刻を $(0, \dots, t, \dots, T-1)$ とする。

次に、撮影した映像に対して、車両の認識を行うための物体検出を行う。本手法では YOLOv5 [18]^{*1} の学習済みモデルを利用した。物体検出の様子を図 4 に示す。

その後、得られたバウンディングボックスを基に車両トラッキングを行う。物体検出時に “car”, “bus” および “truck” として検出されたオブジェクトに対して処理を行う。映像の前後のフレーム間の位置・大きさの差、IoU (intersection over union) がしきい値を満たす時、後続フレームのバウンディングボックスを同一車両として ID 付けするなどのトラッキングを実施する。

映像内の車両をトラッキングした後、動画内で指定したライン（仮想線）を通過した車両数をカウントする。仮想線を通過するごとに、車両 ID と通過時刻を記録する。したがって、実空間における 2 線間の実際の距離を測ることで、2 線間を通過する時間を計算し、速度を推定することが

*1 <https://github.com/ultralytics/yolov5>

表 1 スマートシティ化に関する研究

テーマ	研究概要
自動車充電スタンドの配置最適化 [1]	充電設備を必要とする電気自動車 (EV) に対して、最適な充電ステーションを探索する問題を多目的最適化問題としてモデル化した。
モビリティ解析 [2]	異なる都市機能区における自動車の種類と台数の空間-時間パターンと交通関連の大気汚染物質排出の関係を探る。
スマートグリッドシステム [3]	深層学習に基づく EV 充電ナビゲーションを提案し、EV 充電ステーションでの総移動時間と充電コストの最小化を行う。
マルチモーダル [4]	高度旅客者情報システム (ATIS) のための汎用マルチモーダル交通ネットワークモデルを開発・評価する。

表 2 交通データの取得方式と特徴

取得方式	特徴
パーソントリップ調査 [7,8]	主に政府や自治体による調査で、人の動きに着目した調査である。移動の目的や時間帯・移動手段などを得る。コストが高く、通常 10 年に 1 から 2 回程度実施される。
交通監視カメラ [9,10]	道路や交差点などにカメラを設置し、撮影した動画から情報を抽出する。カメラの台数が多いほど交通状態を適切に把握できる。設置・運用コストや撮影によるプライバシーの問題が懸念される。
GPS [6]	各車両や人の位置が正確に捉えられる。また、軌跡を追うことで出発・目的地やその間の経路を得る。個人がいつでもどこにいるかわかるため、プライバシーの問題が懸念される。
セルラー通信 [11]	携帯電話のセルラー通信から出発・目的地やその間の経路を得る。個人の利用履歴や場所が分かり、プライバシーの問題が懸念される。
Bluetooth [12]	Bluetooth 通信を用い、IoT 機器を通して得たデータを用い交通量などを推定する。IoT 機器の増加により利用可能なデータが増加している。利用デバイスごとに個人情報が含まれる場合もあり、プライバシーの問題が懸念される。

できる。また、2 線間を通過する時間より、車両の走行方向も取得できる。トラッキングの様子を図 5 に示す。これにより、 $[t, t+1)$ の各リンクの交通量 $V_{link}^t (1 \leq link \leq N)$ を数値化する。

3.3 車両交通シミュレーション

交通ネットワークはリンクとノードで構成される。リンクとノードは対象地域のベクターデータを OSM から取得する。その後、OD 地点と成り得るゾーンを Z 箇所設定する。ゾーンは対象地域内外を接続する地点や主要な駐車場とする。

ゾーン間を移動する交通量、すなわち OD 交通量を行列形式で表した $[t, t+1)$ の OD 行列は、

$$\mathbf{x}^t = \begin{pmatrix} x_{1,1}^t & x_{1,2}^t & \cdots & x_{1,Z}^t \\ x_{2,1}^t & x_{2,2}^t & \cdots & x_{2,Z}^t \\ \vdots & \vdots & \ddots & \vdots \\ x_{Z,1}^t & x_{Z,2}^t & \cdots & x_{Z,Z}^t \end{pmatrix} \quad (1)$$

と表される。この \mathbf{x}^t を求め、交通シミュレーションを行う。

3.4 OD 交通量の最適化

経路計算のためのマクロ交通シミュレータと微視的な挙

動を得るためのミクロ交通シミュレータを用いて、OD 行列 \mathbf{x}^t の最適化を行う。まず、求める OD 行列のサイズと等しいサイズの仮 OD 行列 $\mathbf{x}_{tmp} \in \mathbb{R}^{Z \times Z}$, $x_{tmp,i,j} = x_{tmp}$, $(1 \leq i, j \leq Z)$ を用い、経路計算を行う。経路計算は Dynamic stochastic assignment [19] を用いる。経路計算の結果と、仮 OD 行列を用いてミクロ交通シミュレーションを行い、各車両の軌跡を取得する。取得した軌跡より、各 OD ペア間を移動する車両のうち、各リンクを通過する車両の確率 $p_{o,d,link}$, $(1 \leq o, d \leq Z, 1 \leq link \leq N)$ を得ることができる。ここで、 $p_{o,d,link}$ は

$$p_{o,d,link} = v_{tmp,o,d,link} / x_{tmp} \quad (2)$$

と表される。なお、 $v_{tmp,o,d,link}$ は各 OD ペア間を移動する車両のうち、各リンクを移動する車両交通量である。

$p_{o,d,link}$ を用いて、 $[t, t+1)$ の各リンクを移動する交通量は、

$$\hat{V}_{link}^t = \sum_{o=1}^Z \sum_{d=1}^Z x_{o,d}^t p_{o,d,link} \quad (3)$$

と表される。

この値と、カメラ映像からトラッキングシステムを通じて得た実交通量 V_{link}^t との MAPE を最小化する \mathbf{x}^t を求め

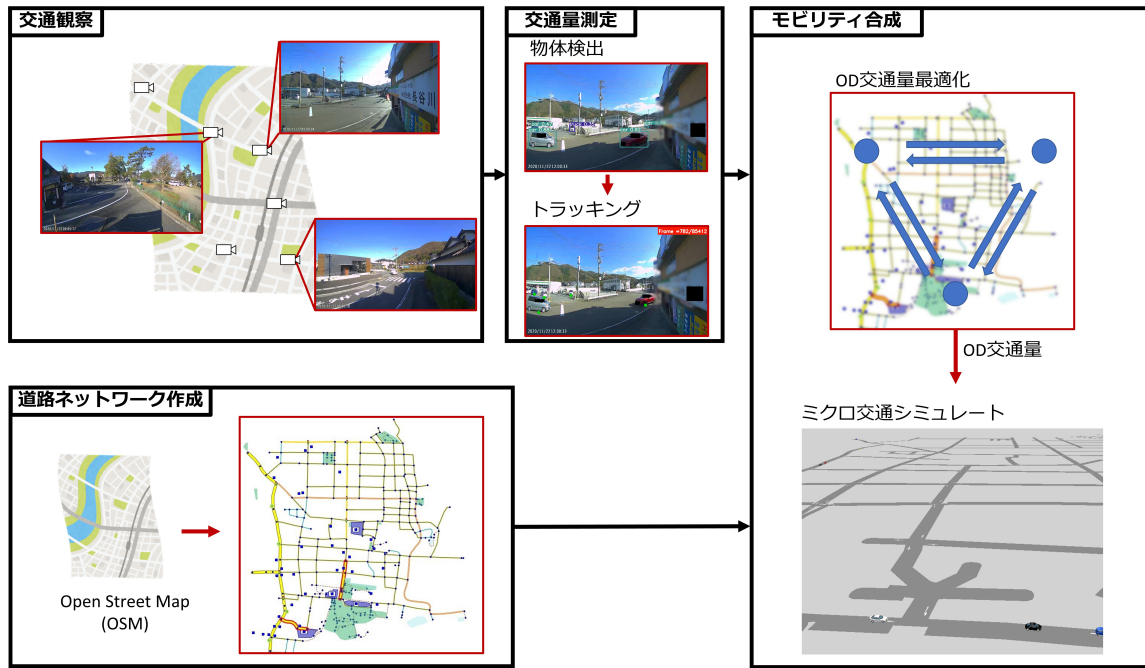


図 1 提案手法の概要




図 2 OD 情報

る。最適化関数は次のように表される。

$$\underset{x}{\text{minimize}} \quad MAPE^t = \sqrt{\frac{100}{N} \sum_{link=1}^N \left| \frac{\hat{V}_{link}^t - V_{link}^t}{\hat{V}_{link}^t} \right|} \quad (4)$$

各時間に対して同様に最適化を行う。得られた OD 行列 x^t をシミュレータの入力に用いシミュレーションを実施することで、対象地域のモビリティを再現する。

4. 評価環境

4.1 評価指標

3.2 節で交通量を数値化したトラッキング結果と 3.3 節で合成したモビリティの結果に対してそれぞれ評価を行う。トラッキングでの数値化の評価では、実際の交通量とトラッキングで得られた交通量間の絶対誤差 ((5) 式) と

パーセント誤差 ((6) 式) を評価指標とした。

$$\epsilon_{tracking} = |V_{truth} - V_{tracking}| \quad (5)$$

$$\text{percent_error} = \epsilon_{tracking} / V_{truth} \quad (6)$$

ここで、 V_{truth} は映像中で、仮想線を通じた車両の実際の台数であり、 $V_{tracking}$ はトラッキングにより得られた車両の台数である。本研究では、車両の軌跡より正確な台数を測定することが重要となるため、MOAT や ML などの評価指標を用いない。

合成モビリティの評価では、トラッキングで数値化した各リンク交通量を真値とし、マイクロ交通シミュレーションから得られる各リンク交通量との絶対誤差 ((7) 式) と、時間 $[t, t+1]$ の二乗平均平方根誤差 (RMSE, (8) 式) と MAPE ((9) 式) を評価指標とした。

$$\epsilon_{mobility} = |V_{tracking} - V_{mobility}| \quad (7)$$

$$RMSE^t = \sqrt{\frac{1}{N} \sum_{link=1}^N (\hat{V}_{link}^t - V_{link}^t)^2} \quad (8)$$

$$MAPE^t = \sqrt{\frac{100}{N} \sum_{link=1}^N \left| \frac{\hat{V}_{link}^t - V_{link}^t}{\hat{V}_{link}^t} \right|} \quad (9)$$

ここで、 $V_{mobility}$ はマイクロ交通シミュレーションから得られるリンク交通量である。

4.2 データセット

本研究では、観光地として栄える兵庫県豊岡市出石を対

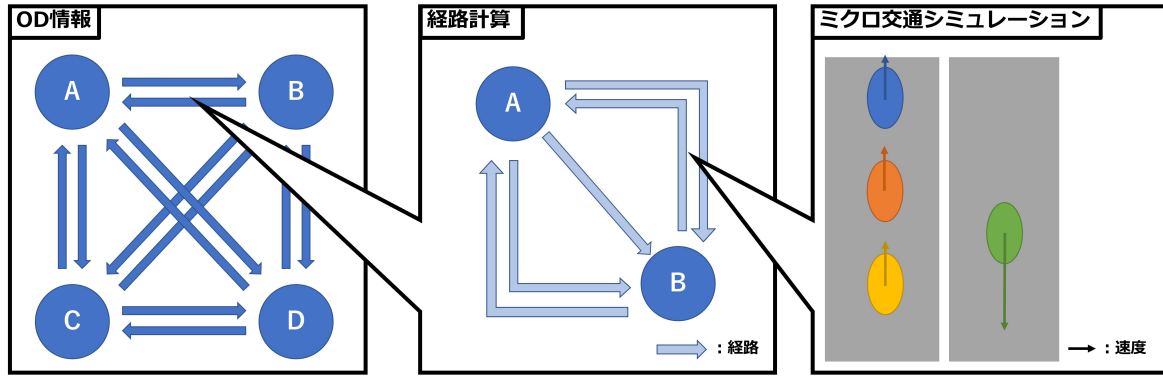


図 3 OD 情報を基にしたシミュレーション




図 4 物体検出の様子



図 5 トラッキングの様子

象に手法の評価を行った。出石地区へは名物の出石そばや歴史的な街並みを求めて多くの観光客が訪れる。交通監視カメラの設置位置を図 6 に示す。図 6 に示すように、道路 7 か所と駐車場の出入口 4 か所の計 11 か所にカメラを設置した。撮影期間は 2020 年 11 月 1 日から 2020 年 12 月 20 日であり、各日の撮影時間は午前 9 時から午後 5 時の 8 時間である。撮影は 1 時間ごとに行った。

ゾーンに設定した位置を図 7 に示す。ゾーンは観光客の主要な出入口となる西側の 3 地点と 4 か所の主要な駐車場の計 7 か所とした。

交通シミュレーションには PTV 社の VISUM (マクロ交通シミュレータ) と VISSIM (ミクロ交通シミュレータ) を用いた。また、仮 OD 行列の各要素は $x_{tmp_{i,j}} = 240$ ($i \neq j$), $x_{tmp_{i,i}} = 0$ とした。

(4) 式は、Python のライブラリである Pytorch を用いて計算した。最適化アルゴリズムには Adam [20] を使い、初期学習率 0.1 とした。

5. 結果と考察

5.1 車両トラッキング精度

車両トラッキングの評価を行うため、繁忙な休日の 12 時から 12 時 15 分までの実際の交通量とトラッキングで得られた交通量間の絶対誤差とパーセント誤差を表 3 に示す。

表 3 トラッキング精度

カメラ位置	真値	検出	絶対誤差	パーセント誤差 [%]	
A	右車線	56	49	7	12.50
	左車線	109	106	3	2.75
B	右車線	100	91	9	9.00
	左車線	50	27	23	46.00
C	右車線	58	47	11	18.97
	左車線	70	60	10	14.29
D	右車線	10	8	2	20.00
	左車線	11	10	1	9.09
E	右車線	10	10	0	0.00
	左車線	16	3	13	81.25
F	右車線	1	6	5	500.00
	左車線	29	17	12	41.38
G	右車線	11	10	1	9.09
	左車線	11	0	11	100.00
P1	入口	12	12	0	0.00
	出口	9	6	3	33.33
P2	入口	5	4	1	20.00
	出口	5	3	2	40.00
P3	入口	13	0	13	100.00
	出口	13	0	13	100.00
P4	入口	19	17	2	10.53
	出口	11	3	8	72.73

カメラは通常の監視カメラと同様の方法で設置されたため、撮影した映像の一部は YOLOv5 で行う物体検出において不適切である場合も多かった。例えば、カメラ P3 の

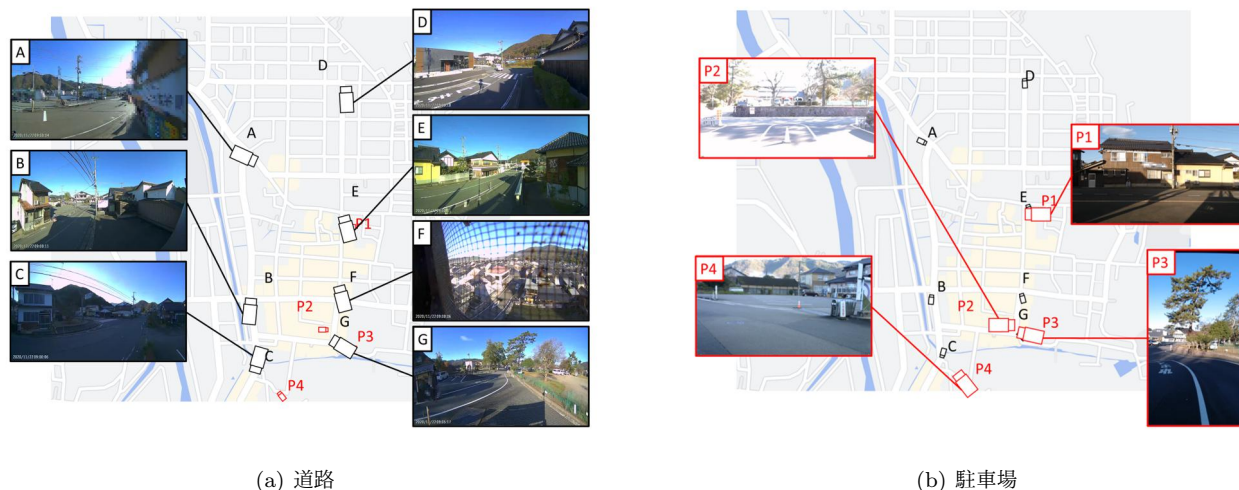


図 6 交通監視カメラの設置位置

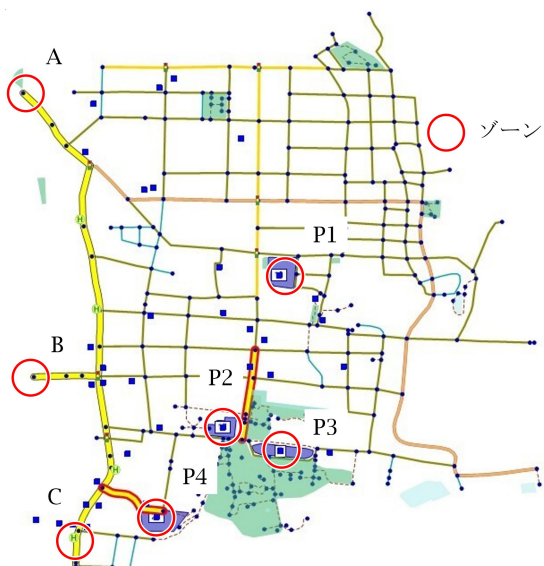


図 7 ゾーン位置

前方はシャッターで塞がれており、うまく車両が検出されなかったためトラッキングの精度が低下している。また、カメラ F は落下防止ネットが前方にあり、車両検出に大きな影響を与える。その他の誤差は主に遮蔽（オクルージョン）が原因と考えられる。見通しが確保され、オクルージョンが発生しにくいカメラ D 地点や、カメラ P1 地点、カメラ P2 地点では誤差が 3 台以下と高精度な検出を実現している。

5.2 交通シミュレーション

表 3 に示す 22 レーンのうち 14 レーンに基づいて OD 行列の最適化を行った。除外される車線は次の 8 つである。

- カメラ D : 両車線
- カメラ E : 左車線
- カメラ F : 右車線
- カメラ G : 左車線

- カメラ P3 : 両車線
- カメラ P4 : 出口

経路確率計算の結果を基に (4) 式で表される最適化を行った結果を表 4 に示す。

時間	MAPE [%]
9:00-10:00	21.13
10:00-11:00	17.80
11:00-12:00	11.06
12:00-13:00	8.33
13:00-14:00	8.43
14:00-15:00	7.73
15:00-16:00	7.75
16:00-17:00	9.51

この結果得られた OD 行列を用いてマイクロ交通シミュレーションを行った。シミュレーションの様子を図 8 に示す。また、シミュレーションから各リンクの交通量を抽出し、トラッキングから得られた交通量と RMSE と MAPE を算出した。その結果を表 5 に示す。

時間	RMSE	MAPE [%]
9:00-10:00	24.80	30.07
10:00-11:00	36.91	25.87
11:00-12:00	46.95	13.50
12:00-13:00	37.57	11.10
13:00-14:00	23.36	9.34
14:00-15:00	22.24	10.27
15:00-16:00	16.91	9.02
16:00-17:00	14.53	11.73

表 5 に示すように、本手法によって、観測地点が少ない市街地でも、RMSE は約 47 以下、MAPE は約 30 % 以下




図 8 シミュレーションの様子

となるモビリティが合成できた。

カメラでの交通量観測の精度を向上させることで、合成モビリティの精度は向上すると考えられる。合成モビリティの精度はカメラの設置台数や設置位置にも依存すると考えられる。また、シミュレーション上の道路や駐車場の制限速度やキャパシティなどを適切に与えるなど、モビリティの精度を向上させると考えられる要因を議論する余地があり、これらの点は今後の研究課題である。

6. おわりに

本稿では、地理的に分散配置された交通監視カメラから得られる映像を用いて市街地全体を対象としたミクロな車両モビリティを自動的に合成する手法を提案した。撮影した映像から車両数、速度、向き、車線を取得可能な車両トラッキングシステムを開発し、見通しが良く、オクルージョンが発生しにくい状況下では高精度で交通量検出が可能であることを示した。また、それにより得られた複数道路での交通量を用いて、OD 行列の最適化を行い、それを用いたミクロ交通モビリティデータを合成した。その結果、合成したモビリティは RMSE が約 47 以下、MAPE が約 30 % 以下となった。合成したモビリティが実際の交通状態をどれほど十分に再現しているかを検証することは今後の課題である。また、シミュレーション上の道路や駐車場の制限速度やリンクキャパシティなどを適切に与え、より精度の高いモビリティを合成することも当面の課題である。

謝辞

本研究の一部は、JST, CREST, JPMJCR21M5 の支援を受けたものです。また、カメラからの映像データは、地域交通の改善を目的とし、兵庫県豊岡市出石の協力を得て、個人特定が不可能なデータとして提供いただいたものです。ご協力に感謝の意を表します。

参考文献

- [1] Moghaddam, Z., Ahmad, I., Habibi, D. and Phung, Q. V.: Smart Charging Strategy for Electric Vehicle Charging Stations, *IEEE Transactions on Transportation Electrification*, Vol. 4, No. 1, pp. 76–88 (online), DOI: 10.1109/TTE.2017.2753403 (2018).
- [2] Song, J., Zhao, C., Lin, T., Li, X. and Prishchepov, A. V.: Spatio-temporal patterns of traffic-related air pollutant emissions in different urban functional zones estimated by real-time video and deep learning technique, *Journal of Cleaner Production*, Vol. 238, p. 117881 (online), DOI: <https://doi.org/10.1016/j.jclepro.2019.117881> (2019).
- [3] Qian, T., Shao, C., Wang, X. and Shahidehpour, M.: Deep Reinforcement Learning for EV Charging Navigation by Coordinating Smart Grid and Intelligent Transportation System, *IEEE Transactions on Smart Grid*, Vol. 11, No. 2, pp. 1714–1723 (online), DOI: 10.1109/TSG.2019.2942593 (2020).
- [4] Zhang, J., Liao, F., Arentze, T. and Timmermans, H.: A multimodal transport network model for advanced traveler information systems, *Procedia-Social and Behavioral Sciences*, Vol. 20, pp. 313–322 (2011).
- [5] Kuutti, S., Bowden, R., Jin, Y., Barber, P. and Fallah, S.: A Survey of Deep Learning Applications to Autonomous Vehicle Control, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 22, No. 2, pp. 712–733 (online), DOI: 10.1109/TITS.2019.2962338 (2021).
- [6] Li, X., Kurths, J., Gao, C., Zhang, J., Wang, Z. and Zhang, Z.: A hybrid algorithm for estimating origin-destination flows, *IEEE access*, Vol. 6, pp. 677–687 (2017).
- [7] Park, K., Ewing, R., Scheer, B. C. and Tian, G.: The impacts of built environment characteristics of rail station areas on household travel behavior, *Cities*, Vol. 74, pp. 277–283 (online), DOI: <https://doi.org/10.1016/j.cities.2017.12.015> (2018).
- [8] Ewing, R., Tian, G., Goates, J., Zhang, M., Greenwald, M. J., Joyce, A., Kircher, J. and Greene, W.: Varying influences of the built environment on household travel in 15 diverse regions of the United States, *Urban Studies*, Vol. 52, No. 13, pp. 2330–2348 (online), DOI: 10.1177/0042098014560991 (2015).
- [9] Ristani, E., Solera, F., Zou, R., Cucchiara, R. and Tomasi, C.: Performance Measures and a Data Set for Multi-target, Multi-camera Tracking, *Computer Vision – ECCV 2016 Workshops* (Hua, G. and Jégou, H., eds.), Cham, Springer International Publishing, pp. 17–35 (2016).
- [10] Ristani, E. and Tomasi, C.: Features for Multi-Target Multi-Camera Tracking and Re-Identification, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2018).
- [11] Fekih, M., Bellemans, T., Smoreda, Z., Bonnel, P., Furno, A. and Galland, S.: A data-driven approach for origin-destination matrix construction from cellular network signalling data: a case study of Lyon region (France), *Transportation*, Vol. 48, No. 4, pp. 1671–1702 (2021).
- [12] Barceló, J., Montero, L., Marqués, L. and Carmona, C.: Travel time forecasting and dynamic origin-destination estimation for freeways based on bluetooth traffic monitoring, *Transportation research record*, Vol. 2175, No. 1, pp. 19–27 (2010).
- [13] Cascetta, E. and Nguyen, S.: A unified framework for

- estimating or updating origin/destination matrices from traffic counts, *Transportation Research Part B: Methodological*, Vol. 22, No. 6, pp. 437–455 (1988).
- [14] Van Zuylen, H. J. and Willumsen, L. G.: The most likely trip matrix estimated from traffic counts, *Transportation Research Part B: Methodological*, Vol. 14, No. 3, pp. 281–293 (1980).
- [15] Xie, C., Kockelman, K. M. and Waller, S. T.: A maximum entropy-least squares estimator for elastic origin-destination trip matrix estimation, *Procedia-Social and Behavioral Sciences*, Vol. 17, pp. 189–212 (2011).
- [16] Hazelton, M. L.: Estimation of origin–destination matrices from link flows on uncongested networks, *Transportation Research Part B: Methodological*, Vol. 34, No. 7, pp. 549–566 (2000).
- [17] Maher, M. J.: Inferences on trip matrices from observations on link volumes: a Bayesian statistical approach, *Transportation Research Part B: Methodological*, Vol. 17, No. 6, pp. 435–447 (1983).
- [18] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A.: You Only Look Once: Unified, Real-Time Object Detection, *Proc. of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788 (2016).
- [19] Cascetta, E. and Cantarella, G. E.: A day-to-day and within-day dynamic stochastic assignment model, *Transportation Research Part A: General*, Vol. 25, No. 5, pp. 277–291 (online), DOI: [https://doi.org/10.1016/0191-2607\(91\)90144-F](https://doi.org/10.1016/0191-2607(91)90144-F) (1991).
- [20] Kingma, D. P. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014).