

深層学習によるリンク交通量からOD交通量の推定手法

阿倉 佑樹¹ Choochootkaew Sunyanan¹ 天野 辰哉¹ 山口 弘純¹ 廣森 聡仁¹ 東野 輝夫¹
西村 友佑² 諏訪 晃² 長村 吉富² 竹嶋 進² 高井 峰生³

概要：高度な事故低減機能を有する先進車両や自動運転車両が今後社会に普及すると考えられている。それらの車両が広域の交通に与える影響を調査するためには、実道路マップと現実の車両交通を再現した交通シミュレーションが不可欠となる。交通シミュレーションにおいて現実の車両交通を再現するためには、各車両の出発地と目的地を表す OD 交通量情報が必要となるものの、実際の OD 情報を取得することは容易でない。これに対し本研究では、深層学習により都市域におけるリンク交通量から対応する OD 交通量の推定を行う手法を提案する。リンク交通量は渋滞情報との親和性が高く、路側機や交通量調査等で比較的入手可能性が高い。我々は交通シミュレータを用いて大阪市の一部の道路地図に基づく交通流データセットの作成を行い、収集したリンク交通量と OD 交通量を用いた深層学習モデルの構築を実施している。シミュレーションデータを用いた評価の結果、構築したモデルは高精度で OD 交通量推定が可能であることを示した。さらに都市全体のリンク交通量データの 50%程度があれば 80%の精度で OD 交通量を把握できることを確認した。

1. はじめに

高度な事故低減機能を有する先進車両や自動運転車両が、今後社会に普及すると考えられる。それら車両は実環境で走行する前に、シミュレーションを用いて、実環境でどの程度事故率低減に寄与するかを評価できることが望ましい。実環境の地理情報を用いた交通シミュレーションには、車両の出発地と目的地を表す OD 情報が必要となる。

各地点間の OD 情報をまとめた OD マトリックスと呼ばれ、パーソントリップ調査 (PT 調査) により実測されている。しかし、PT 調査はアンケート形式による調査であり、実施のための労力が大きいため数年に一度のような低頻度で行われ、イベントなどによる変化する OD 情報を取得することは難しい。そのため、GPS (Global Positioning System) やセルラーデータを用いて OD を推定する手法が提案されている。これらのデータは正確な位置情報を提供できることから、車両の OD マトリックスを推定する [1] だけでなく、移動手段などの様々な情報の推定 [2] も可能となる。しかし一方で、これらは位置トレースデータであることから、データ提供者の居住地やよく訪れる場所など

プライバシーに関する情報を含む場合が多く、したがってその可用性は低くなる傾向にある。

そこで本研究では、リンク交通量を用いて OD マトリックスの推定を行う。リンク交通量は、渋滞情報や断面交通量などとして近年比較的入手が容易となっている。OD 交通量の推定はしばしば解析的に行われる [3] ことが多いものの、それらの手法ではあらかじめ事前に高精度な OD 交通量が既知であることを前提としたり、あるいは OD 交通量からリンク交通量が一意に決まるといった仮定をおくなどの制約がある。

本研究では、交通流シミュレータを用い、対象地区環境において生成できる様々な交通流データを用いてデータセットを作成する。交通流シミュレータに多様な OD 交通量を与え、その結果生成されるリンク交通量を組とし、リンク交通量から、それに最も近い OD マトリックスを決定する分類器を構成する。大阪市中心区を対象地区とし、パーソントリップ調査の値をもとに 108 に分類した OD マトリックスのクラスに対してデータセットを作成し、推定を行ったところ、対象地区の道路トポロジの影響もあり、クラス分類の精度は最高精度を達成した。さらに、リンク全体に対し、50%のリンク交通量があれば精度が 80%を維持できることを確認した。

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

² 住友電気工業 (株)
Sumitomo Electric Industries, LTD.

³ カリフォルニア大学 ロサンゼルス校
University of California, Los Angeles

2. 関連研究

2.1 GPS や携帯電話データを用いた OD 推定

GPS は時空間的に高精度な位置情報を提供するため、様々な OD マトリックスに関する研究が存在する。文献 [4] では、GPS のトレースデータを用いて、次の時刻の OD マトリックスを逐次的に推定している。また、文献 [5] では、GPS レベルの高精度な位置情報は必要ないとして Bluetooth や WiFi によって推定された位置情報に対し、カルマンフィルターを用いることで、OD マトリックスを推定している。文献 [6] では、GPS を用いて災害時における人々の 2 地点間移動を取得し、その 2 点間の避難経路を推定している。この研究では、東日本大震災を対象に 1 ヶ月間の避難者のトリップを誤差 5% 以下の精度で推定している。

一方、携帯電話の通話履歴を用いた研究として [7] などがある。[7] では人の行動と社会性の密接な相関を考慮し人の動きを予測する手法を提案している。また、基地局に蓄積される CDR と呼ばれる記録を用いて行動推定を行う研究 [1] も知られている。また、通信履歴を用いて人々の OD だけでなく移動手段も推定した研究 [2] などもある。[2] では、通信履歴が時間的にも空間的にも粗い携帯電話基地局の接続データにみられる様々な特徴を活用し交通手段を推定している。これらのデータは位置トレースデータであるため、プライバシーに関わる情報を含む可能性がある。したがって、データの可用性や収集・活用といった観点で容易でないといった課題がある。

2.2 リンク交通流を用いた OD 推定

文献 [3] では、リンク交通量から粒度（例えば交差点間レベル）の OD マトリックスを解析的に推定する手法を提案している。また何割程度のリンク交通量があれば OD マトリックスが推定可能かも調査している。しかしながら、同手法での OD マトリックスは広域の情報（地域レベル）ではないため、本手法に適用することは容易でない。また、参照可能な一部の OD マトリックス情報を保持していることが前提であるが、広域情報における同情報の入手は容易でない。また、リンク交通量から一般化最小二乗モデル (GLS) [8]、最大エントロピーモデル [9]、ベイジアン理論 [10] を用いて OD マトリックスの推定を行う方法も提案されている。しかし、これらでは、OD 交通量から生成されるリンク交通量は常に一意であり、都市の道路交通網における自然な交通流に対応できないといった課題がある。文献 [11] は、高速道路のような経路選択が少ないようなネットワークに対応可能な OD マトリックス推定手法を提案しているが、都市部のような経路選択が多様な環境における適用は難しい。

3. 提案手法

3.1 概要

OD マトリックスの地域粒度は手法により異なり、交差点レベルのものから都市レベルのものまで多様である。本研究ではメインゾーンとよばれる例えば区レベルの地域間の OD マトリックスを扱う。メインゾーン内には出発・終着点を複数設置可能とすることで、メインゾーン内外の自然な交通流の再現をはかる。深層学習を用いてリンク交通量から OD マトリックスを推定するモデルを構築するためには、リンク交通量とそれに対応する OD マトリックスの組からなるデータセットが必要となる。しかし現実環境におけるそのようなデータセットの入手は前述の議論などから容易でないため、交通流シミュレータと現実環境の道路網地図を用いてそれらのデータを生成する。

シミュレータでは対象地区の様々な OD マトリックスを機械的に作成し、シミュレーションを実施することにより、それに対応するリンク交通量を作成する。類似する OD マトリックスの各集合を 1 クラスとし、リンク交通量に対し、対応するクラス名を与えたデータセットを用い、深層学習によりリンク交通量に対するクラス分類を行う分類器を構築する。本研究の最終的な目標は、実世界のリンク交通量を入力することで、対応する OD マトリックスを得ることである。リンク交通量が例えば渋滞統計システムや一部のプローブデータなどから得られれば、対応する OD マトリックスを得ることができる。例えばそれを基にして様々な OD マトリックスを生成すれば、現実的かつ多様な交通流再現シミュレーションなどが可能となり、都市の交通解析や再現に有用となる。

3.2 データセットの作成

提案手法では、交通シミュレータ **Visum** [12] を用いてデータセットを作成した。Visum はマクロ交通シミュレータであり、都市部のような広範囲のシミュレーションに適している。対象領域は大阪駅付近を中心とした大阪市面積の約半分程度の領域とした。大阪市は日本で有数の大都市であり、2025 年に大阪万博が開催されるため、都市レベルの OD 交通量の情報は有用であると考えられる。データセットの作成の手順として、まずリンク（道路セグメント）とノード（交差点など）から道路ネットワークを構成し、ノードの一部をゾーン（車両の発生あるいは終着点）とする。次に、道路ネットワーク上で複数の OD マトリックスを作成する。各 OD マトリックスに対し、経路割当てシミュレーションを実施することで、その OD マトリックスに対応するリンク交通量を作成できる。

3.2.1 リンクの作成

リンク情報はオープンストリートマップ (OSM) [13] の




図 1 対象地区の道路ネットワーク




図 2 大阪市中心 4 区のメインゾーンとゾーン

表 1 メインゾーンとそれらに含まれるゾーン数

No.	名称	ゾーン数
1	大阪市都心 2 区	101
2	大阪市準都市	18
3	大阪市北部	36
4	大阪市東北部	52

データを用いて作成した。本研究では、国道、府道、一般地方道、および片側車線が二車線以上の道路のみを用い、それら以外は除外した。この結果構成された道路ネットワークを図 1 に示す。

3.2.2 ゾーンの作成

ゾーンは車両の出発点や終着点を表し、車両はゾーンから他のゾーンに向かって走行する。ゾーンはいずれかのメインゾーンの内部の地点であり、メインゾーンはパーソントリップ調査で利用される地区の範囲を表す単位である。本稿におけるメインゾーンは、そのパーソントリップ調査で用いられる地区（大区域～小区域）の中でも最小である小区域を用いた。作成した大阪市のメインゾーンの名称とメインゾーン内のゾーン数を表 1 に示す。

現実環境に近い車両の発生や消滅をメインゾーン内で再現するためには、メインゾーンから発生する交通量を車両の出発点・終着点である各ゾーンにどのように分配するかが重要となる。ゾーン決定においては、人々の興味・関心がある地点である POI を用いた。POI の種別と位置情報は OSM のデータを利用し作成した。車両は POI の地点間で移動することから、ゾーンの特定箇所への極端な集中を避けるために種別と地理的観点から利用する POI データを手動で調整した。種別的観点では、人々が日常的に利用する地点であることが好ましいため、平日利用することが多いと想定される住宅地やパーキングエリア、工場などを選んでいく。また、休日向けには公園等を用いている。なお、各 POI には出発点あるいは目的点のいずれかの役割を持たせることなく、双方向の交通を生成することとした。地

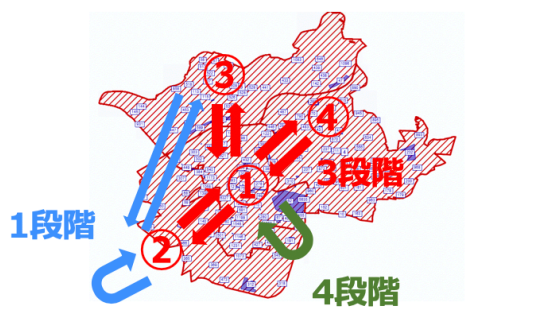
理的観点では、OSM に登録されている POI には地理的な偏りがあることから、ゾーンが一樣に分散するように POI を選択した。最終的なゾーンを図 2 に示す。メインゾーンからの交通量の分配方法については 3.2.5 節で説明する。

3.2.3 OD マトリックスの作成

OD マトリックスは日によって一意ではないものの、大都市においては一定の傾向はみられ、極端な OD マトリックスは通常発生しない。したがって、本稿ではパーソントリップの OD マトリックスをベースとし、以下のような方針に基づき、その交通量を様々に変化させることで、一定の交通傾向を有しながら異なる複数の OD マトリックスを生成した。まず、本研究のリンク交通量の測定対象は中央のメインゾーン（図 5 の中央の 1 番、メインゾーン 1 とよぶ）であるとし、メインゾーン 1 に大きく影響を与えない交通量（残りのメインゾーン 2~4 間の交通量、図 5 におけるマトリックスの青色セルに相当）はパーソントリップ調査の値で固定する。また、中心地であるメインゾーン 1 と他のメインゾーン間の交通量（図 5 の赤色セル）を同調査の実数値を参考に、小さい（5000）、普通（10000）、多い（15000）の 3 段階に変化させた。さらに、メインゾーン 1 に対する出勤退勤の車両数は同数であるとし、メインゾーン 1 と他のメインゾーン間の双方向の交通量が一致するとした。最後に、同調査において、平日と休日で大きく値が異なった交通量（図 5 の緑セル）を休日の 2 段階（20000,30000）および平日の 2 段階（40000,50000）、計 4 段階に変化させる。これらの組み合わせにより、合計 108 の OD マトリックスを生成した。

3.2.4 1 時間粒度の OD マトリックスの生成

VICS など一般的なリンク交通量は長くととも 1 時間単位程度の粒度で取得可能であるため、前述の方法で生成した 1 日粒度の OD マトリックスから、1 時間粒度のマトリックスを生成する。具体的には、交通センサス [14] のリンク交通量データを参考に、5:00 に発生車両数が増加し始め、



OD	①	②	③	④
①	4段階	3段階	3段階	3段階
②	①→②と同じ	固定	固定	固定
③	①→③と同じ	固定	固定	固定
④	①→④と同じ	固定	固定	固定

図 3 メインゾーンおよび異なる OD マトリックスの生成方針

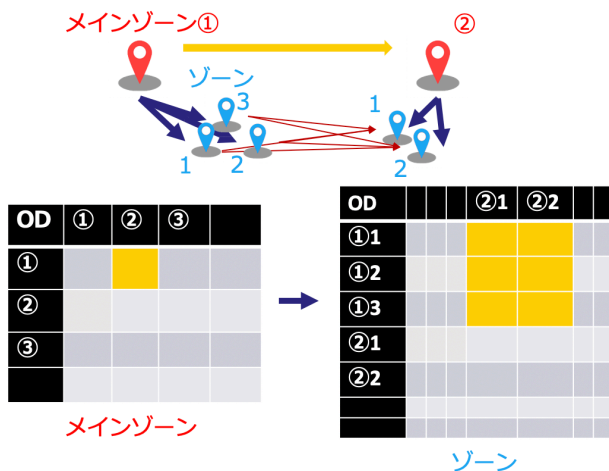


図 4 メインゾーン間 OD マトリックスからゾーン間 Od マトリックスの生成

走行車両数が 9:00 にピークに到達し、12:00 には少し減少し、18:00 に 2 回目のピークに到達した後、翌日の 4:00 にかけて徐々に減少する傾向を把握した。この傾向を再現するように、OD マトリックスを 1 時間単位で経験的に分割した。

3.2.5 ゾーン間 OD マトリックスの生成

最後に、メインゾーンの車両発生を各ゾーンにランダムに割り当てる。それらのランダム割り当てを複数生成することで、一つの OD マトリックス（メインゾーンレベル OD マトリックス）に対し、ゾーンレベルの OD マトリックスを複数生成する（図 4）。

3.2.6 経路割り当て

最後にゾーン間経路の割り当てを行うことで、シミュレーションに必要な情報をすべて得ることができる。その手法として、動的な利用者均衡法である *Dynamic Stochastic*




図 5 経路割り当てにより計算された交通量

Assignment [15] を用いた。利用者均衡とは、利用者の全員が全ての道路の交通状況を把握しており、現在地点から目的地まで一番早く到達可能なルートを選択できるという考え方である。それにより、最短経路の道路に渋滞が生じている場合は、渋滞に巻き込まれないように他の道を選択して目的地に早く着くようになる。また、割り当てにおける「動的」とは、経過時刻ごとの経路割り当てを行う際に、前の時刻の車両を考慮することであり、それら車両数を「抵抗」として捉え、それらの抵抗を加味した上の旅行時間を計算する。

3.3 分類器の構築

3.2.3 節で作成した 108 の OD マトリックスをクラスとし、与えられたリンク交通量に対し、それがどのクラスの OD マトリックスにより生成されたものかの判定を行う分類器を構築する。そのモデルとして、DNN と CNN および LSTM を用い、実験ではそれらの分類性能を比較する。

分類器の入力情報は、各リンクの 1 時間ごとの交通量を表す二次元マトリックスであり、各セルは、対応するリンクの対応する時刻においてそのリンクを通過した車両台数を表す。分類器の出力は、長さがクラス数の 108 である one-hot vector である。

また、分類器の最適化アルゴリズムとして ADAM を、各全結合層の活性化関数は ReLU を、最後の全結合層には softmax 関数を採用した。損失関数として交差エントロピーを採用した。

3.3.1 DNN による分類器

DNN として、図 6 および表 2 のように、入力層と 3 つの全結合層から成るネットワークを用いた。入力層では、平滑化を行い次元の配列に変換する。第 2 および第 3 層は全結合層であり、各ユニット間を密に接合しているため分類モデルの表現力が高まる一方で過学習を生じやすい。そこで、各全結合層において半数のユニットをドロップア

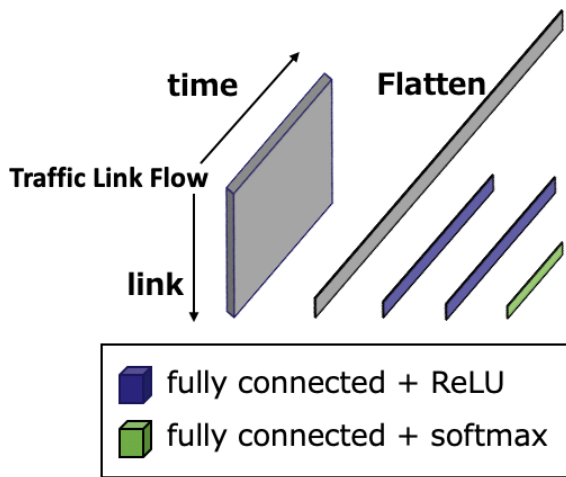


図 6 DNN

表 2 DNN Layers

Layer	Output Shape	# of Param
Flatten	(None, 129072)	0
Dense	(None, 512)	66085376
Dropout	(None, 512)	0
Dense	(None, 512)	262656
Dropout	(None, 512)	0
Dense	(None, 108)	55404




図 7 CNN

表 3 CNN Layers

Layer	Output Shape	# of Param
Conv	(None, 5378, 16)	1936
Pooling	(None, 2689, 16)	0
Conv	(None, 2689, 64)	0
Pooling	(None, 1345, 64)	5184
Flatten	(None, 86080, 16)	0
Dense	(None, 108)	9296748

ウトし、過学習を抑制した。

3.3.2 CNN による分類器

CNN は、図 7、表 3 の構成で学習させた。このモデルでは、各リンクの時間軸方向に対して畳み込みを行うことで、リンクごとの時間軸方向の特徴を抽出できるようにした。

3.3.3 LSTM による分類器

LSTM として、図 8 および表 4 のように、DNN モデル

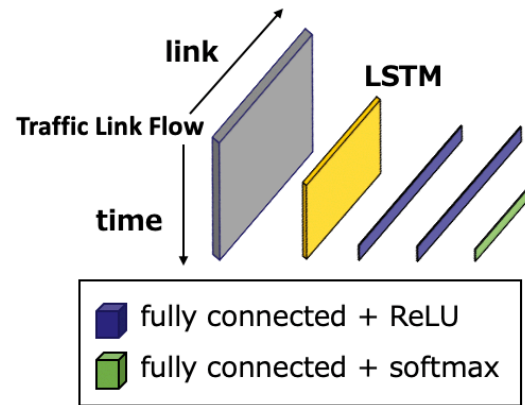


図 8 LSTM

表 4 LSTM Layers

Layer	Output Shape	# of Param
LSTM	(None, 2048)	60841984
Dense	(None, 512)	1049088
Dropout	(None, 512)	0
Dense	(None, 512)	262656
Dropout	(None, 512)	0
Dense	(None, 108)	55404

の平滑化層のかわりに LSTM 層を用いた。この LSTM 層は、時間的に連続する値から次の値を計算するために使用される層であり、各リンクの 5:00 から翌日の 4:00 までの交通量を入力とし、リンク毎に 1 日の時間変動特徴量を有したベクトルを生成する。このベクトルを前述の DNN の入力とすることで、時間変動を捉えた分類が可能になると期待される。

4. 性能評価

メインゾーン間 OD マトリックス (全 108 クラス) に対し、各クラスにおいて、ゾーンへの車両数割合を変えることで生成された 108 のゾーン間 OD マトリックスを生成し、全 11,664 のゾーン間 OD マトリックスをデータセットとした。ランダムに抽出した 10% のマトリックスをテストデータ、10% を検証用データ、残り 80% を訓練用データとして使用した。

4.1 評価シナリオ

本研究の最終的な目標は、実環境のリンク交通量を入力として用いることであるが、実環境のリンク交通量において、すべてのリンクの交通量が取得可能と仮定することは現実的でない。そのため、一部のリンク交通量のみからなるテストデータ (欠損ありのテストデータ) に対しても、どの程度の精度で OD マトリックスを推定できるかも調べる。欠損の生成方法として、一部のリンク情報が全時刻で欠損するケースと、ある時刻で全リンクの情報が欠損するケースを考慮する。欠損データは交通量を 0 とした。

表 5 Accuracy

モデル	テストデータ	PT 調査
DNN	1.0	1.0
CNN	0.988	1.0
LSTM	0.876	1.0




図 9 大阪市の道路トポロジ

4.2 分類精度の評価

分類精度を表5に示す。いずれのモデルでも高精度で分類が行えることがわかる。DNNが最も高い精度を達成した理由として、作成した大阪市中心4区の道路トポロジーの特性が関与していると考えられる。今回の対象区間では図9のようにメインゾーン間に川が流れており、メインゾーン間の道路は数カ所の橋に限られている。その結果、一部の主要な道路に交通が集中し、その特徴が分類しやすいものであったと考えられる。

また、リンク交通量が欠損したデータを用いた精度評価も行った。リンク交通量の欠損により精度が低下すれば、そのリンクが分類器における重要な特徴量を有することがわかる。図10に、隣接する10リンクの交通量を全時刻で欠損させた場合の精度を、図11に各リンクの交通量を示す。これらのグラフを比較すると、特にCNNでは、交通量の多い道路の欠損が精度に大きく影響することがわかる。そのため、ある道路に集中した交通量が分類性能に大きく影響を与えているといえる。

また、データ欠損率に対する精度の変化を図12に示す。この評価では、リンク交通量が小さいリンクから順にその全時刻の交通量データを欠損させている。CNNは、半数のリンクの交通量情報があれば、80%程度の精度を維持できることが確認できた。また、図13は逆に交通量が多い道路順に欠損させた場合の結果である。道路トポロジーにより交通量が多いリンクの特徴が精度に影響を与えやすいことは確認できているため、小さい順の場合よりは影響度が高い。特に、DNNとCNNはデータ欠損に対する精度低下が




図 10 各リンク交通量の欠損における精度

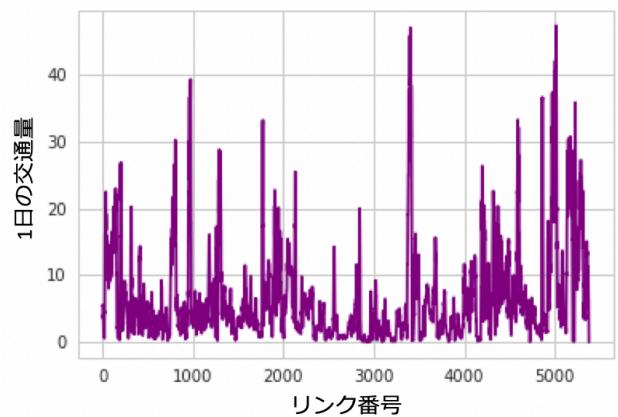


図 11 各リンクの1日あたりの交通量




図 12 リンク交通量の欠損率に対する精度の変化（交通量が少ない順で欠損させた場合）

大きい。LSTMは各リンクの時間変化の特徴を捉えていることからそれらに比べて精度の低下度合いが小さいことがわかった。

最後に、図14に一部の時間のすべてのリンク情報を損失させた場合の精度変化を示す。DNN、LSTM共に、通勤ラッシュなどの交通量が多く変化している午前の部分の交通量変化が大きい時間帯の欠損に大きな影響を受けたこ




図 13 リンク交通量の欠損率に対する精度の変化（交通量が多い順で欠損させた場合）




図 14 各時刻のデータ欠損に対する精度

とがわかった。

5. おわりに

本研究では、深層学習を用いてリンク交通量から OD マトリックスを推定する手法を提案した。深層学習の訓練用データとして必要なデータセットを交通流シミュレータを用いて作成する方法を示し、大阪市中心部において、パーソントリップデータをもとにした 108 種類の OD マトリックスを生成した。生成したデータセットを用いて訓練した深層学習モデルを用いた推定性能評価を行った結果、領域全体の 50% のリンク交通量が測定可能であれば、80% 程度の精度を達成できることを確認した。今後は、実環境のリンク交通量を本モデルに入力した時の精度調査を実施する予定である。

謝辞

本研究成果は国立研究開発法人情報通信研究機構 (NICT) の日米共同公募委託研究「スマートコミュニティを支える高信頼ネットワーク構成技術の研究開発」により得られたものです。

参考文献

- [1] Yamada, Y., Uchiyama, A., Hiromori, A., Yamaguchi, H. and Higashino, T.: Travel estimation using Control Signal Records in cellular networks and geographical information, *Proceedings of Wireless and Mobile Networking Conference (WMNC)*, pp. 138–144 (2016).
- [2] Zhao, Y., Wang, X., Li, J., Zhang, D. and Yang, Z.: CellTrans: Private Car or Public Transportation? Infer Users' Main Transportation Modes at Urban Scale with Cellular Data, Vol. 3, No. 3 (2019).
- [3] LIOU, H. T. and HU, S. R.: Inferring Network Origin-Destination Matrices Using Partial Link Traffic Flow Information, *Journal of the Eastern Asia Society for Transportation Studies*, Vol. 8, pp. 466–481 (2010).
- [4] Moreira-Matias, L., Gama, J., Ferreira, M., Mendes-Moreira, J. and Damas, L.: Time-evolving O-D matrix estimation using high-speed GPS data streams, *Expert Systems with Applications*, Vol. 44, pp. 275 – 288 (2016).
- [5] Barcelo, J., Montero, L., Marques, L. and Carmona, C.: A Kalman-Filter Approach For Dynamic OD Estimation In Corridors Based On Bluetooth And Wifi Data Collection, *Proceedings of World Conference on Transportation Research (WCTR)*, pp. 11–15 (2010).
- [6] Horanont, T., Witayangkurn, A., Sekimoto, Y. and Shibasaki, R.: Large-Scale Auto-GPS Analysis for Discerning Behavior Change during Crisis, *IEEE Intelligent Systems*, Vol. 28, No. 4, pp. 26–34 (2013).
- [7] Zhang, D., Chen, M., Guizani, M. and Xiong, H.: Mobility prediction in telecom cloud using mobile calls, *IEEE Wireless Communications*, Vol. 21, No. 1, pp. 26–32 (2014).
- [8] Sherali, H. D. and Park, T.: Estimation of dynamic origin-destination trip tables for a general network, *Transportation Research Part B: Methodological*, Vol. 35, No. 3, pp. 217 – 235 (2001).
- [9] Rao, W., Wu, Y.-J., Xia, J., Ou, J. and Kluger, R.: Origin-destination pattern estimation based on trajectory reconstruction using automatic license plate recognition data, *Transportation Research Part C: Emerging Technologies*, Vol. 95, pp. 29 – 46 (2018).
- [10] Castillo, E., Menéndez, J. M., Sánchez-Cambronero, S., Calviño, A. and Sarabia, J. M.: A hierarchical optimization problem: Estimating traffic flow using Gamma random variables in a Bayesian context, *Computers & Operations Research*, Vol. 41, pp. 240 – 251 (2014).
- [11] Savrasovs, M. and Pticina, I.: Methodology of OD Matrix Estimation Based on Video Recordings and Traffic Counts, *Procedia Engineering*, Vol. 178, pp. 289 – 297 (2017).
- [12] PTV Group: PTV Visum, <http://vision-traffic.ptvgroup.com/en-us/products/ptv-visum/> (accessed February 4, 2020).
- [13] OpenStreetMap Foundation Japan (OSMFJ): OpenStreetMap, <http://www.openstreetmap.org/> (accessed February 4, 2020).
- [14] Traffic Engineering Division, R. D.: The FY2010 Road Traffic Census Results of the General Traffic Volume Surveys (Overview), <http://www.nilim.go.jp/english/annual/annual2012/84.pdf>.
- [15] Lim, Y.: Multiple User-Class Dynamic Stochastic Assignment for a Route Guidance Strategy, *Convergence and Hybrid Information Technologies* (Crisan, M., ed.), IntechOpen, Rijeka, chapter 4 (2010).