

Non-Negative Tensor Factorization を用いた ドックレス型マイクロモビリティの利用形態分類手法の検討

牛島 秀暢^{1,a)} 青木 俊介² 西山 勇毅^{1,b)} 瀬崎 薫^{1,3,c)}

概要: 交通やインフラ, スマートフォンなどから得られる様々なデータを統合的に活用し, 都市計画の継続的な改善に役立てるという都市コンピューティングが注目されている. 都市コンピューティングは少子高齢化と過疎化が進行する日本においても公共インフラを有効活用し都市を維持するためにも有効である. 限られた公共インフラを活用するためには人々の移動目的を推定し, 交通リソースを最適化する必要があるが, 既存の IC カードなどの交通データでは推定粒度に限界があった. こうした状況の中, 特定の返却場所を持たないドックレス型のマイクロモビリティが急速に普及している. ドックレス型マイクロモビリティは平均移動距離が 500m 程度と短く, 直接目的地に向かうため, より詳細な移動行動が検出可能である. 本研究では, マイクロモビリティが都市空間で離散的に分布する点に着目した. そして, 細かく単発的な移動行動を大域的に分析することで潜在的な移動パターンがあることを, Non-Negative Tensor Factorization と呼ばれる教師なし学習を用いることで明らかにした.

キーワード: ITS, e-scooter, Micromobility, Mobility-as-a-Service, 都市コンピューティング

HIDENAGA USHIJIMA^{1,a)} SHUNSUKE AOKI² YUUKI NISHIYAMA^{1,b)} KAORU SEZAKI^{1,3,c)}

1. はじめに

都市コンピューティングは, 都市で生成された交通, 土木, 経済などの異種データをコンピュータを通して統合的に解析し, 都市における問題の解決を目指すという研究分野である. 都市をセンシングする事で, 都市計画者が想定していなかった問題を浮き彫りにし, 都市運営をより合理的にすることが可能になると言われている. なかでも, 公共交通は社会構造の変化から, 需要が変動しやすく都市コンピューティングの重要な課題の一つである.

限られた都市インフラを有効活用するためには, 人々の移動目的を推定し, 交通行動を最適化する必要がある. 交

通行動推定に於いては, これまで様々なアプローチが取られてきた. 伝統的には, パーソントリップ (PT) 調査や国勢調査, 道路交通センサス等のアンケートベースの研究がなされてきた [1]. しかし, アンケートは, 回答者のバイアスやモチベーションに影響を受けるため, 正確性に欠ける事が問題である [2]. また, 交通系 IC カードの普及から乗降データによる行動予測の研究も行われてきた. しかし, 鉄道の路線上での行動分析にとどまる事が難点であった. 特に, 1km 未満の移動行動については推定が非常に困難であった. 一方で, 2017 年頃から E-scooter や自転車を用いたドックレス型マイクロモビリティが世界各国で急速に普及している. ドックレス型マイクロモビリティは平均移動距離が 500m 程度であり, 返却先が限定されておらず目的地で直接下車できる事から, これまでにない粒度で移動情報を得ることが可能になってきた.

一方, ユーザの急増による, 交通事故の増加 [3], [4] や特定地域への車両集積による景観の悪化とそれに伴う, 歩行者の通行を妨げ [5] など様々な問題が発生しており, 各都市の交通状況によって潜在的に様々な利用パターンが存在すると考えられる. 地方自治体などの都市計画者がドック

¹ 東京大学生産技術研究所
Institute of Industrial Science, the University of Tokyo,
Meguro-ku, Tokyo, JAPAN

² カーネギーメロン大学
Carnegie Mellon University, Electrical & Computer Engineering,
Pittsburgh, USA

³ 東京大学空間情報科学研究センター
Center for Spatial Information Science, the University of
Tokyo, Kashiwa-shi, Chiba, JAPAN

a) hidenaga.ushijima@mcl.iis.u-tokyo.ac.jp

b) yuukin@iis.u-tokyo.ac.jp

c) sezaki@iis.u-tokyo.ac.jp

レス型マイクロモビリティを都市の公共インフラの一つとして有効活用するためには、都市計画者自身が潜在的な利用パターンを把握する必要があると考えられている。

本研究の目的は、都市での人々の移動行動を把握するために、ドックレス型マイクロモビリティの潜在的な利用パターンの検出を行う。仮説として、鉄道やバスといった既存公共交通との相互利用パターンの検出ができる可能性があると考えられる。また、移動行動を推定する事ができれば、事故や渋滞などの問題発生を予め予測する事ができる可能性がある。さらに、ドックレス型マイクロモビリティの短距離移動ルート間を結ぶことで、新たな路線バスの需要が明らかになる可能性が挙げられる。

本研究では、アメリカ合衆国イリノイ州シカゴ市のマイクロモビリティに関するオープンデータとワシントンDCのオープンデータを用いた。クラスタリング手法として Non-Negative Tensor Factorization (NTF) を採用し潜在的な移動パターンを分類した。本稿の貢献は以下2点である。

- 住民と観光客の移動行動を分離し、特徴を抽出した
- NTF を用いて限られたデータから潜在的な移動パターンを分類できる可能性を明らかにした

2. 関連研究

交通データを用いて都市の交通情報を把握し都市計画に活用する様々な研究が盛に行われている。特にバスや鉄道、タクシーなどの公共交通機関の交通データは公共性が高いことから、オープンデータ化が進んでおり、それらを用いた人の移動の解明が行われている。また、伝統的な公共交通データだけでなく、近年普及している新しい移動形式である、ライドシェアリングサービスの利用状況を用いた都市の交通状況の解析も行われている。既存の、交通系データセットを用いた移動様式解析とライドシェアリングサービスの解析に関する取組についてまとめる。

2.1 交通系データセットを用いた移動様式分析

タクシーやライドシェアリングデータは、乗降履歴から個人単位での End-to-End の移動行動や、アプリケーションでの検索と呼び出しによる移動需要の抽出が用意であることから活発に研究が行われている。中国北京市におけるタクシー走行データを用いて都市の変化を解析 [6] した研究や、ライドシェアリングのデータを用いて待ち時間を予測する研究 [7], [8], タクシーの高効率な運用や貨客混載 [9], [10] などについて議論がなされている。また、バスや鉄道などのように、予めルートが決められており、停車点周辺の目的に対して移動する行動がある。バス走行データを用いて、イベント発生時の都市解析 [11] や NMF を用いた IC カードデータ解析などがある [12], [13], [14], [15]。加えて、交通データとユーザのスマートフォンから得られる

Bluetooth や WiFi, GNSS と組み合わせる事で、将来的な交通需要や渋滞、事故の推定を行う研究 [16], [17], [18], [19] も存在する。こうした研究は、都市における大域的な人の流れの把握に貢献してきた。しかし、短距離移動に関してはデータ収集手段が限られており十分な研究がなされていない。

2.2 ドックレス型マイクロモビリティの利用状況調査

ドックレス型マイクロモビリティに関する研究は、返却場所が限定されているバイクシェアリングに関する研究から始まり、その後自転車を使ったドックレス型マイクロモビリティ、E-scooter を使ったドックレス型マイクロモビリティへと広がってきた。McKenzie ら [20], [21] は、返却場所固定型バイクシェアリングとドックレス型マイクロモビリティとの時空間的都市解析を行った。また、Mathew らは天候がドックレス型マイクロモビリティの利用様態に与える影響を明らかにした [22]。Zehr らはドックレス型マイクロモビリティのタイヤの形状と路面との関係を明らかにした [23]。加えて、ドックレス型マイクロモビリティに関連する都市政策や、再配置問題などの研究がなされている [24], [25], [26], [27]。しかし、こうした研究はあくまで一つの都市におけるドックレス型マイクロモビリティの利用傾向を切り取って報告したものであり、特徴量を抽出し移動行動をパターン化するという試みは未だなされていない。

3. ドックレス型マイクロモビリティの潜在的な利用パターン検出

ドックレス型マイクロモビリティを都市の公共インフラの一つとして有効活用するためには、地方自治体などの都市計画者が潜在的な利用パターンを把握する必要があると考えられる。

公共交通データに対して NMF を利用することで、公共交通機関の潜在的な利用パターンや需要の検出と予測 [11], [12], [13], [14], [15] が行われている。しかしながら、公共交通機関のデータは、出発・到着地点が予め決められた移動であり、ドックレス型マイクロモビリティにおける移動とは種類が異なる。または、タクシーに代表される自動車旅客サービスは、ドックレス型マイクロモビリティと同様に出発・到着地が決められていない移動であるが、自動車移動のほとんどは移動距離が 1km 以上の移動が多く、平均移動距離が 500m のマイクロモビリティとは利用目的が異なると考えられる。

ドックレス型マイクロモビリティの潜在的な利用パターン分類に関する研究は、著者の知る限りではまだ十分に行われておらず、今後の各都市でのマイクロモビリティのスムーズな導入と既存インフラとの共存に向けて、潜在的な利用パターンの分類手法の構築は必要不可欠である。

表 1 収集データの都市間比較

都市名	シカゴ	ワシントン DC
期間	2019年6月~9月	2019年11月 ~2020年1月
サービス名称	ird, Bolt, gruv, JUMP,Lime,Lyft, Sherpa, Spin, VeoRide, Wheels	JUMP
トリップ数	664,975	95,174
収集方法	Chicago Open Data	APIを用いた クローリング

表 2 API データ形式

要素	データ型	例
Timestamp	String	1587370701
Bike id	String	d1e2345a-0d40-5355 -b666-892e2f4c7d07
Longitude	Float	-77.01901
Latitude	Float	38.900303
is reserved	Boolean	0
is disabled	Boolean	0
vehicle type	String	scooter
Battery Level	String	89

表 3 前処理後のデータ形式

要素	データ型	例
Start Area	String	WEST TOWN
End Area	String	NEAR WEST SIDE
Time	Int	9

4. NTF を用いたドックレス型マイクロモビリティの利用形態分類

図 1 に、ドックレス型マイクロモビリティの利用データを用いた、潜在的なドックレス型マイクロモビリティの利用パターンの分類を行う為、データ処理手順を示し、各節に詳細を記述する。

4.1 データ収集

本研究では、ドックレス型マイクロモビリティの利用データとして、ドックレス型マイクロモビリティサービスが提供されているアメリカ合衆国内のワシントン DC とシカゴの二都市における利用データを収集した。表 1 に収集データの概要を示す。

シカゴの利用データは複数のドックレス型マイクロモビリティ事業者のデータを統合したオープンデータとして提供されている*1。シカゴのデータは2019年6月から4ヶ月間行われた、Pilot Program(実証実験)時にシカゴ市が収集した664975トリップが含まれている。

一方、ワシントン DC の利用データは、JUMP と呼ばれる Uber 傘下のマイクロモビリティ事業者のデータのみを扱っている。ワシントン DC のデータは、オープンデータポータルで公開されている JUMP の空車情報 API*2 を 10 秒毎にスクレイピングし、約 3 ヶ月間収集した。JUMP の空車情報 API で公開されている情報を以下表 2 に示す。

次にトリップの乗降エリアの頻度を都市ごとにそれぞれ可視化した。図 2 に示す。

図 2 から分かるように、両都市において中心部での乗り降りが多く、そこから裾野が広がるようにトリップが分布している事が分かる。また、パイロットプログラムと呼ばれる実験的な試みということもあり、南部への車両配備は行っていないため限られたエリアでの移動が大半となっている。一方で、ワシントン DC では正式サービスとして展開しているため、トリップが広範囲に渡っている。

4.2 前処理

空車情報データから同じ BikeID を持つ車両が位置を変更した時の位置情報を、発車地点 (Origin) と到着地点 (Destination) の情報のセットを 1 トリップとした。その際に、GNSS の誤差除去を行った。衛星測位システムの誤差は、屋外に於いては、一般的に 20m 程度とされている [28]。今回は、10 秒以下のトリップは誤差として除外した。

次に、発車地点と到着地点から、E-scooter の移動時間と移動距離、バッテリー消費量を算出した。最後に、移動開始地点と到着地点を各都市における、コミュニティエリアに当てはめた。シカゴは Community Area と呼ばれる、毎に分けられた領域を元にした。ワシントン DC においては、エリアを Neighborhood Clusters[29] *3 を元 に 46 個に分割した。以下エリア分割図を図 3 に示す [30]。

以下に、前処理後のデータ形式を示す。

4.3 クラスタリング

ユーザーの属性データや、軌跡データが存在せず、スパースな位置情報データから行動を推定するために、教師なし学習の一つである Non-Negative Tensor Factorization [31] を用いたクラスタリングを行なった。これは、Non-Negative Matrix Factorization (NMF) を拡張したものである。以下に式を示す。一般に、N 個のモードを持つテンソルデータを、N 次のテンソルデータという。今回は、出発エリア、到着エリア、時間帯の 3 階テンソルデータを用いた。したがって $X = [x_{ijk}] \in R_+^{I \times J \times K}$ という式で表すことができる。ここでは、I, J, K はそれぞれのデータの要素数を表しており、 R_+ は非負値の実数値を表す。今回は代表的なテンソル因子分解手法である CP 分解を用いて因子分

*1 <https://data.cityofchicago.org/Transportation/E-Scooter-Trips-2019-Pilot/2kfw-zvte>

*2 <https://ddot.dc.gov/page/dockless-api>

*3 https://opendata.dc.gov/datasets/f6c703e2534fc3800609a07bad8f5b_17?geometry=-77.777%2C38.800%2C-76.252%2C38.987

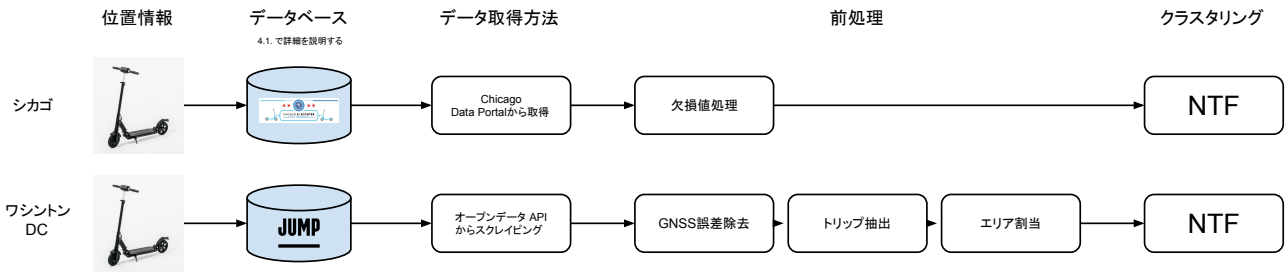


図 1 データ処理手順

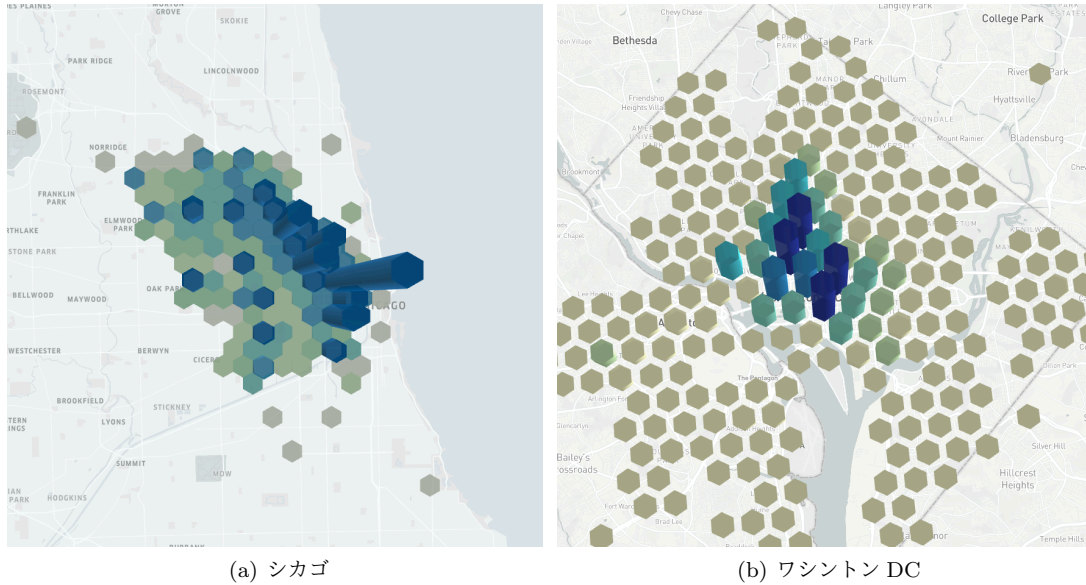


図 2 発着頻度可視化図

解を行った. この時, 各因子と要素の関係は因子行列として表現することができる. また, 各モードの因子行列 A, B, C はそれぞれ, $A = [x_s] \in R_+^{I \times R}$, $B = [x_{er}] \in R_+^{J \times R}$, $C = [x_{tr}] \in R_+^{K \times R}$ として表せる. 因子行列 A, B, C の積を $\hat{X} = [x_{ijk}] \in R_+^{I \times J \times K}$ として, 以下のように表記できる.

$$\tilde{x}_{ijk} = \sum_{k=1}^R a_{ir} b_{jr} c_{kr} \quad (1)$$

この \hat{X} と X をの誤差が小さくなるように, 因子行列を求めた. 今回は, 距離関数として一般化 KL ダイバージェンスを採用した. 一般化 KL ダイバージェンスは, ポアソン分布の負の対数尤度の定義域を実数に拡張した距離規準で, 非負の整数がポアソン分布に従う場合に用いると, 高い汎化性能を示すことが知られている [32]. したがって, 今回のような離散的な値に対して有効であると考え採用した. 以下に, 誤差関数を示す.

$$D(\mathbf{X} || \hat{\mathbf{X}}) = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \left(x_{ijk} \log \frac{x_{ijk}}{\hat{x}_{ijk}} - x_{ijk} + \hat{x}_{ijk} \right) \quad (2)$$

最終的に, 誤差 D を最小にするように更新式は定義され, 以下のように示される.

$$\begin{cases} a_{ir} \leftarrow a_{ir} \frac{\sum_{j=1}^J \sum_{k=1}^K \frac{x_{ijk} b_{ji} c_{kr}}{\hat{x}_{ijk}}}{\sum_{j=1}^J \sum_{k=1}^K \sum_{i=1}^I \frac{b_{ji} c_{kr}}{\hat{x}_{ijk}}} \\ b_{jr} \leftarrow b_{jr} \frac{\sum_{i=1}^I \sum_{k=1}^K \frac{x_{ijk} a_{ir} c_{kr}}{\hat{x}_{ijk}}}{\sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \frac{a_{ir} c_{kr}}{\hat{x}_{ijk}}} \\ c_{kr} \leftarrow c_{kr} \frac{\sum_{i=1}^I \sum_{j=1}^J \frac{x_{ijk} a_{ir} b_{jr}}{\hat{x}_{ijk}}}{\sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \frac{a_{ir} b_{jr}}{\hat{x}_{ijk}}} \end{cases} \quad (3)$$

本研究では, これらのアルゴリズムを Python を用いて実装した. それらを用いて, 移動パターンを $R = 5$ としてクラスタリングしそれぞれ比較した.

5. 結果

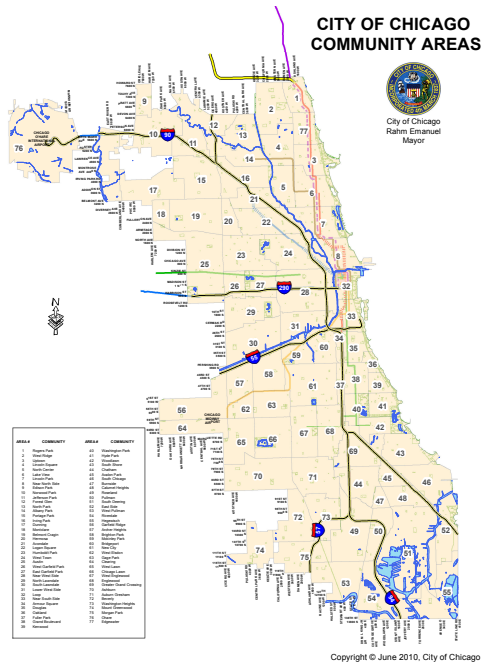
シカゴとワシントン DC それぞれのデータに対して NTF 解析を行い, クラスタ間関係性を検証した.

5.1 シカゴデータ

初めに平日と週末でデータを分類した. 図 4(a) 図 4(b) に三次元の場合に可視化図を示す. 点のサイズと色がそれぞれのデータ頻度の高さを表している.

図からも, いくつかの特徴的な移動行動が存在している事が分かる.

次に, クラスタリングを行ったそれぞれの因子の近似ベクトルの分布を図 5(a), 図 5(b) に示す.




(a) シカゴ

Map – Neighborhood Clusters




(b) ワシントン DC

図 3 エリア分割図



(a) 平日



(b) 休日

図 4 シカゴの移動パターン

平日クラスタ 3 は、午前 8 時台と午後 5 時台にピークがあり 16 番から 22 番 LOGAN エリアへの移動が多くなっている。この 16 番 IRVING PARK に当たるエリアは居住区にあたり、22 番の LOGAN SQUARE エリアは繁華街に当たる。こうした行動は、観光客等の初めてのユーザではなく、シカゴ地元住民による習慣的な行動である可能性が高い。時間帯を加味すると鉄道への乗換え等通勤退勤と紐付いた行動であると考えられる。

休日のクラスタ 1 の出発地点のピークは 17 番の DUNNING エリアと呼ばれる居住区であり、21 番の AVONDALE エリアは観光地である。したがって、この行動は観光客による周遊行動の一部である可能性が高い。

次にクラスタ 3 は、11 番の JEFFERSON PARK エリアと 13 番 NORTH PARK という大学や公園などが広がるエリアから、17 番の DUNNING エリアや、15 番の PORTAGE PARK エリアとった中規模居住区への移動行動が抽出された。

また、クラスタ 4 は移動のピークが他のものと異なり、深夜帯にも移動行動がある。これは、中心市街地から中心市街地への移動であり、外食や繁華街に向かっている行動である可能性がある。

次に休日のクラスタ 5 については、シカゴ市北部の隣り合ったエリア間の移動行動を抽出している。これはクラスタ 1 と同様に観光客による観光地から次の観光地に向けた

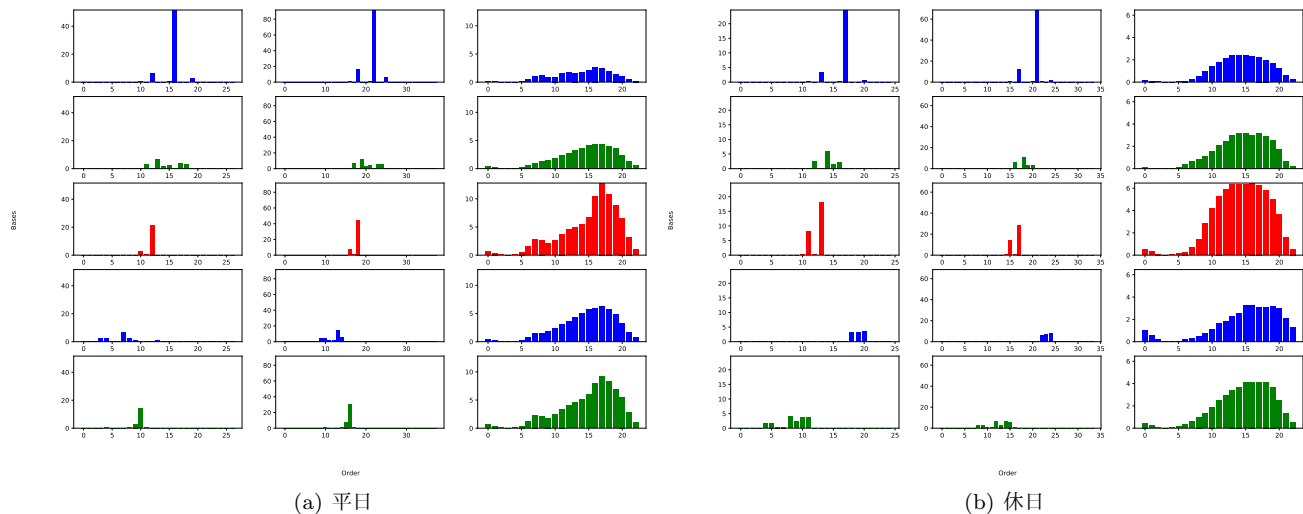


図 5 シカゴの移動パターンのクラスタリング

移動を表しているのではないかと考えられる。

5.2 ワシントン DC データ

図 6(a), 図 6(b) に示されるように同じエリア内での移動行動が多く、いくつかのクラスが存在している事が分かる。

次に、ワシントン DC の平日データを $R=5$ でクラスタリングしたものを図 7(a), 休日データを $R=5$ でクラスタリングしたものを図 7(b) に示す。

平日のクラスター 1 では、エリア 12, 13 から同じエリア 12,13 への移動が午前 8 時台と午後 17 時台に起こっている。これはシカゴの平日データと同様に通勤行動であると考えられる。また、平日のクラスター 2,3,4 も同様に通勤行動が可視化されており似通った属性の住民が居住しているエリアが明らかとなった。一方、休日データについては、エリア 12,24 から出発し同じエリア内に到着するトリップが極めて強い傾向を示している。これはクラスター 2-5 全てで同じ傾向が示されており、休日のワシントン DC では日中をピークとする同じエリア内での短距離移動をドックレス型マイクロモビリティが担っている事が明らかとなった。

6. 考察

6.1 シカゴデータについて

$R=5$ のクラスタリングでは、市民による通勤等による周期的な移動行動と、同じ場所にもどって来る周遊行動の抽出ができた。また、休日では、比較的同じような傾向が見られた。これは、シカゴデータが実証実験レベルであり、南部エリアまでドックレス型マイクロモビリティが配備されておらず、比較的狭いエリアでの移動が中心である事が要因であると考えられる。

6.2 ワシントン DC データについて

ワシントン DC のデータは、データ収集期間が寒冷期である事から移動距離が短く同じエリア内で完結するトリップが過半数を締めており、少数のエリアをまたぐ長距離トリップの傾向がクラスタリングに反映されたと考えられる。また、同じような属性のユーザの通勤行動が可視化された事からそのエリアの人口分布等からユーザ属性を更に詳細に推定が可能になった。また、休日の観光客の移動行動の分類からシャトルバス路線などに応用する事が可能となった。

7. おわりに

本稿ではドックレス型マイクロモビリティの潜在的な利用パターン分析を目的に、アメリカ合衆国のシカゴ及びワシントン DC の利用データに対して Non-Negative Tensor Factorization (NTF) を用いた解析を行った。本解析によって、ドックレス型マイクロモビリティのトリップデータを { 出発点 × 到達点 × 出発時刻 × トリップ時間 ... } とした高階テンソルとして表現・分析することが可能になった。また、トリップデータのクラスタリング結果を可視化することにより、ドックレス型マイクロモビリティを用いるユーザの移動行動を直観的に分類することが可能になった。

一方で、NTF を用いた分析ではクラスター数などのパラメータを分析者が調整・決定する必要がある。また、NTF をはじめとする因子分解を用いるデータ分析法では、主因子以外の傾向を検出・分析することが難しい。このため今後の課題として、クラスター数などのパラメータを自動で決定するノンパラメトリック手法の実装・検討が必要である。

さらに、ドックレス型マイクロモビリティは路線バス・地下鉄・乗り合いタクシーなど他の都市交通サービスに対しても大きな影響を与えていると考えられる。今後は他の

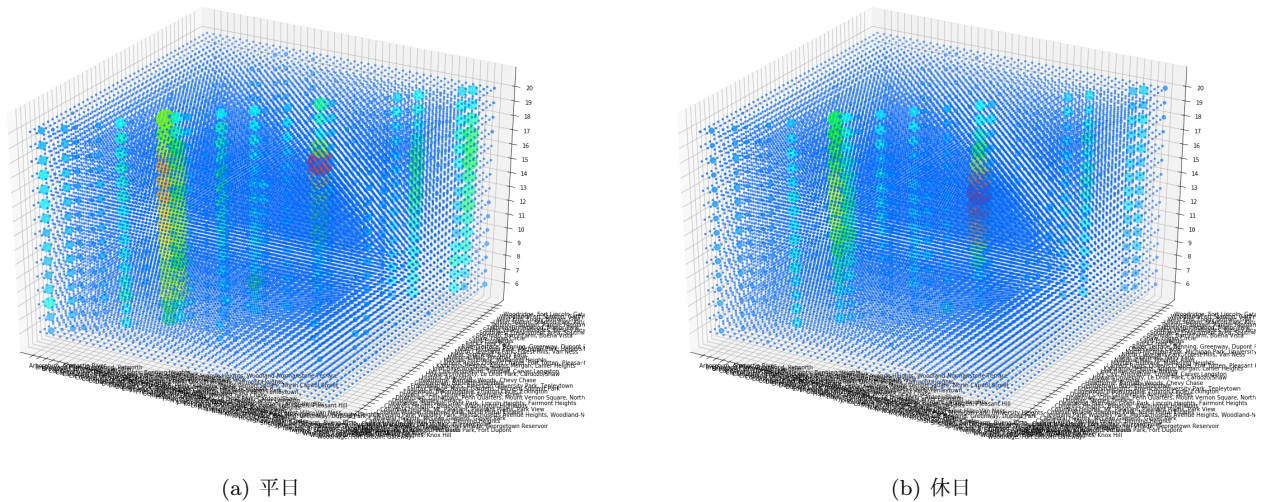


図 6 ワシントン DC の移動パターン

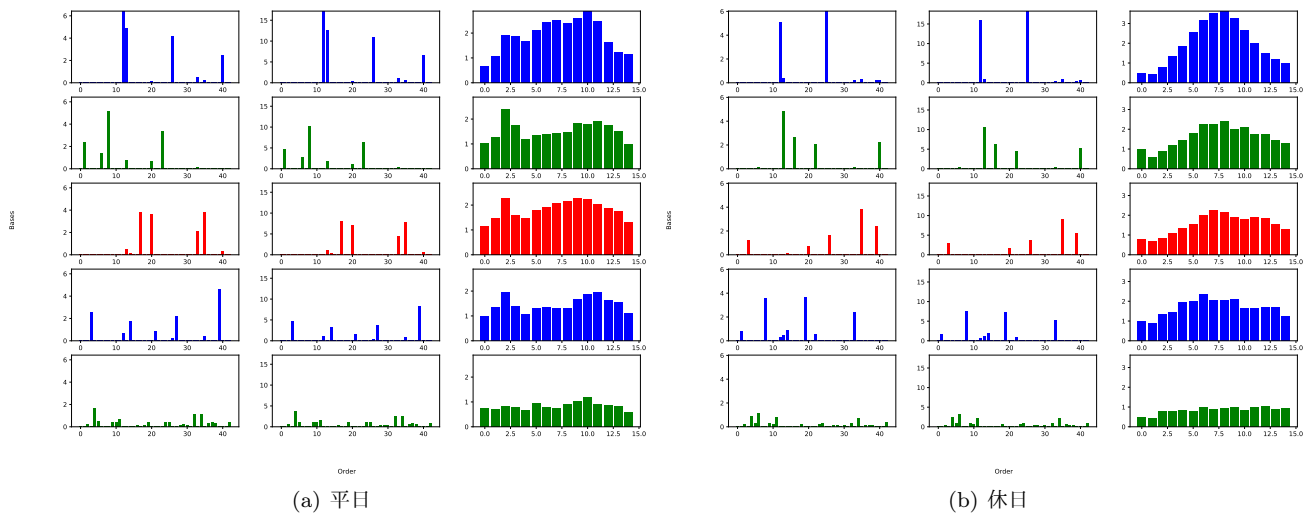


図 7 ワシントン DC の移動パターンのクラスタリング

都市交通データと合わせて複合的なデータ分析を行うことによって、より広範囲・多角的な都市解析に取り組みたいと考えている。

謝辞

本研究は JSPS 科研費 JP18H04089 の助成を受けたものである。

参考文献

- [1] 赤松惟央, 川井優, 福山俊郎: パーソントリップの交通機関利用率に関する解析, 土木学会論文報告集, Vol. 1971, No. 193, pp. 81–88 (1971).
- [2] 名取義和, 谷下雅義, 鹿島茂: パーソントリップ調査における回答誤差とその発生要因, 土木計画学研究・論文集, Vol. 17, pp. 155–162 (2000).
- [3] Namiri, N. K., Lui, H., Tangney, T., Allen, I. E., Cohen, A. J. and Breyer, B. N.: Electric scooter injuries and hospital admissions in the United States, 2014–2018, *JAMA surgery* (2020).
- [4] Sikka, N., Vila, C., Stratton, M., Ghassemi, M. and Pourmand, A.: Sharing the sidewalk: A case of E-scooter related pedestrian injury, *The American journal of emergency medicine*, Vol. 37, No. 9, pp. 1807–e5 (2019).
- [5] Moran, M. E., Laa, B. and Emberger, G.: Six Scooter Operators, Six Maps: Spatial Coverage and Regulation of Micromobility in Vienna, Austria, *Case Studies on Transport Policy* (2020).
- [6] Zheng, Y., Liu, Y., Yuan, J. and Xie, X.: Urban computing with taxicabs, *Proceedings of the 13th international conference on Ubiquitous computing*, pp. 89–98 (2011).
- [7] Zhang, L., Zhang, G., Liang, Z., Fan, Q. and Li, Y.: Predicting Taxi Destination by Regularized RNN with SDZ, *IEICE Trans. Inf. Syst.*, Vol. E101.D, No. 8, pp. 2141–2144 (2018).
- [8] Rahaman, M. S., Ren, Y., Hamilton, M. and Salim, F. D.: Wait Time Prediction for Airport Taxis Using Weighted Nearest Neighbor Regression, *IEEE Access*, Vol. 6, pp. 74660–74672 (2018).
- [9] 谷本圭志, 小澤 陽: タクシーを活用した貨客混載システムの導入可能性の評価に関する基礎的手法の構築, 都市計画論文集, Vol. 54, No. 3, pp. 665–671 (2019).
- [10] 落合純一, 金森亮, 平田圭二, 野田五十樹: 名古屋

- 市のタクシー配車データを用いた Smart Access Vehicle Service の効率性評価, 人工知能学会全国大会論文集 第 32 回全国大会 (2018), jstage.jst.go.jp, pp. 1B2OS11b03–1B2OS11b03 (2018).
- [11] Aoki, S., Sezaki, K., Yuan, N. J. and Xie, X.: An early event detection technique with bus gps data, *Proceedings of the 25th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 1–4 (2017).
- [12] Ito, K., Ito, M., Miyazaki, K., Tanimoto, K. and Sezaki, K.: Data analysis on train transportation data with non-negative matrix factorization, *2017 IEEE International Conference on Big Data (Big Data)*, ieeexplore.ieee.org, pp. 4080–4085 (2017).
- [13] Tse, R., Zhang, L. F., Lei, P. and Pau, G.: Social network based crowd sensing for intelligent transportation and climate applications, *Mobile Networks and Applications*, Vol. 23, No. 1, pp. 177–183 (2018).
- [14] Tonnelier, E., Baskiotis, N., Guigue, V. and Gallinari, P.: Smart card in public transportation: Designing a analysis system at the human scale, *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, pp. 1336–1341 (2016).
- [15] Tonnelier, E., Baskiotis, N., Guigue, V. and Gallinari, P.: Anomaly detection and characterization in smart card logs using NMF and Tweets., *ESANN* (2017).
- [16] Graells-Garrido, E., Caro, D. and Parra, D.: Inferring modes of transportation using mobile phone data, *EPJ Data Science*, Vol. 7, No. 1, p. 49 (2018).
- [17] Yamaki, S., Lin, S. and Kameyama, W.: Detection of Anomaly State Caused by Unexpected Accident using Data of Smart Card for Public Transportation, *2019 IEEE International Conference on Big Data (Big Data)*, pp. 1693–1698 (2019).
- [18] Poussevin, M., Tonnelier, E., Baskiotis, N., Guigue, V. and Gallinari, P.: Mining Ticketing Logs for Usage Characterization with Nonnegative Matrix Factorization, *Big Data Analytics in the Social and Ubiquitous Context*, Springer International Publishing, pp. 147–164 (2016).
- [19] Song, X., Kanasugi, H. and Shibasaki, R.: DeepTransport: Prediction and Simulation of Human Mobility and Transportation Mode at a Citywide Level.
- [20] McKenzie, G.: Urban mobility in the sharing economy: A spatiotemporal comparison of shared mobility services, *Computers, Environment and Urban Systems*, Vol. 79, p. 101418 (2020).
- [21] McKenzie, G.: Spatiotemporal comparative analysis of scooter-share and bike-share usage patterns in Washington, D.C., *J. Transp. Geogr.*, Vol. 78, pp. 19–28 (2019).
- [22] Mathew, J. K., Liu, M. and Bullock, D. M.: Impact of Weather on Shared Electric Scooter Utilization, *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, pp. 4512–4516 (2019).
- [23] Zehr, S. D., Mathew, J. K. and Bullock, D. M.: Quantitative Assessment of Pavement and Scooter Suspension on Ride Quality, *2019 IEEE International Conference on Connected Vehicles and Expo (ICCVE)*, IEEE, pp. 1–6 (2019).
- [24] Lee, M., Chow, J. Y. J., Yoon, G. and He, B. Y.: Forecasting e-scooter competition with direct and access trips by mode and distance in New York City (2019).
- [25] Jiao, J. and Bai, S.: Understanding the Shared E-scooter Travels in Austin, TX, *ISPRS International Journal of Geo-Information*, Vol. 9, No. 2, p. 135 (2020).
- [26] Brown, A., Klein, N. J., Thigpen, C. and Williams, N.: Impeding access: The frequency and characteristics of improper scooter, bike, and car parking, *Transportation Research Interdisciplinary Perspectives*, p. 100099 (2020).
- [27] Blickstein, S. G., Brown, C. and Yang, S.: E-scooter programs: current state of practice in US cities (2019).
- [28] 白井澄夫: 高精度衛星測位技術の動向と応用, 電子情報通信学会誌= The journal of the Institute of Electronics, Information and Communication Engineers, Vol. 92, No. 9, pp. 768–774 (2009).
- [29] Tatian, P. A., Kingsley, G. T., Turner, M. A., Comey, J. and Rosso, R.: State of Washington, DC’ s Neighborhoods (2008).
- [30] *CommunityAreasNumbers*.
- [31] 松林 達史, 幸島 匡宏, 澤田宏: 複合データ分析技術と NTF(2・完) テンソルデータの因子分解技術と実応用例, 電子情報通信学会誌= The journal of the Institute of Electronics, Information and Communication Engineers, Vol. 99, No. 7, pp. 691–698 (2016).
- [32] Combettes, P. L. and Pesquet, J.-C.: Proximal splitting methods in signal processing, *Fixed-point algorithms for inverse problems in science and engineering*, Springer, pp. 185–212 (2011).