

# モバイルビッグデータと個人属性データを用いた 地域ごとの来訪者特性の把握手法の提案

山中惇矢\*・秋山祐樹\*\*・山本俊行\*\*\*

## Proposal for Understanding Method of the Visitors Characteristics by Region Using Mobile Phone Big Data and Personal Attribute Data

Junya YAMANAKA\*, Yuki AKIYAMA\*\*, Toshiyuki YAMAMOTO\*\*\*

Spatial statistics at the regional mesh level are useful information for understanding the current status of an area in detail and for implementing various planning activities. In this study, we developed new spatial statistics that can estimate the personal attributes of visitors at any given time in a regional mesh unit by combining human flow data based on cell phone movement history and personal attribute data (annual income, gender, etc.) obtained from existing statistics. Furthermore, we proposed a method of clarifying the characteristics of visitors in each region by clustering the visitor attributes of each mesh as variables.

**Keywords:** モバイルビッグデータ (mobile phone big data), 統計 (statistics), 年収 (annual income), 人の動き (people movement), 個人属性 (personal attributes), クラスタリング (clustering)

### 1. はじめに

近年、国土交通省（2018）の取り組みとして「スマート・プランニング実践の手引き」（以下、SP）が実施されている。SPとは、個人単位の行動データをもとに施設配置や歩行空間等を変化させ、歩行者の回遊行動のシミュレーションを実施し、施策や取り組みを検討する計画手法のことである。従来の計画手法は、人口分布や人口密度、施設の立地状況など「静的な分析」に基づいて行われていたが、SPの計画手法では、24時間365日データを取得可能な携帯電話の移動履歴に関するビッグデータ（以下、MBD（モバイルビッグデータ））を活用し、個人の移動特性を把握した「動的な分析」に基づいて行われる。SPは時間帯別の詳細な結果を提示できるため、複数の計画案を比較した結果の説明が可能になる。

しかし、既存のMBDでは、各人に関する属性が乏しく、既存の統計が有するような属性で集計を行うことが困難であり、また個人情報保護の観点から携帯電話利用者各人の情報を取得、利用することも困難である。一方、計画を実行する上で重要なことが地域の現状を把握することである。町丁字や地域

メッシュ単位の小地域を対象とした空間統計は有用な情報であり（小西，2010）、特に地域格差の把握には、人口や世帯当たりの所得額などの指標が重要であると指摘されている（豊田，2021）。また近年では、新しい空間統計の開発も試みられている（松島ほか，2015；Cheng et al., 2017）。

そこで本研究では、把握が困難な個人情報の1つでもある各人の年収情報を、既存統計から地域メッシュ単位へダウンスケーリング（高精細化）し、同成果とMBDの結合により、各人の年収を推定する技術を開発する。さらに、それらを用いて任意の時間・場所における来訪者の所得を把握可能にする技術を開発する。すなわち従来のSPで実施されていた時間帯別人口分布による分析に留まらず、新たに時間帯別の来訪者平均年収分布の分析を可能にし、地域ごとの来訪者の所得に基づく分類（クラスタリング）を実現する。最後に、それらの分析結果を地域経済の活性化や行政サービス等の効率化に繋げられる活用法の検討を行うことで、本研究の成果が今後自治体による各種計画の検討の際に、そのように役立つ可能性があるかを明らかにする。

---

\* 学生会員 名古屋大学大学院工学研究科土木工学専攻 (Nagoya University)

〒464-0814 愛知県名古屋市千種区不老町 Tel:052-789-5111 E-mail:yamanaka.junya.v4@s.mail.nagoya-u.ac.jp

\*\* 正会員 東京都市大学建築都市デザイン学部都市工学科 (Tokyo City University)

\*\*\* 非会員 名古屋大学未来材料・システム研究所 (Nagoya University)

## 2. 研究手法

本研究の流れを図1に示す。まず、①既存統計のダウンスケーリング技術の開発し、年収データをMBDと結合できるように高精細化する。次に、②MBDの基礎的処理を行い、③MBDと年収データを結合する。さらに、各ユーザの年収情報、拡大係数、自宅勤務地以外の滞留時間割合を用いて、④東京都全域の500mメッシュ(4次メッシュ)ごとの来訪者の平均年収を推定する。最後に、東京都全域の1kmメッシュ(3次メッシュ)ごとの来訪者の平均年収を用いて⑤平均年収の類似性による地域分類の手法を開発する。そして以上の成果を用いて、東京都内に来訪する人々の年収の時系列変化を把握し、人口の時系列変化以外の方法で都市の時空間分析する新しい手法を提案する。

## 3. データの説明

本研究では、個人属性(所得・性別)とMBDを用いた分析を実施するため、以下に各データの詳細を説明する。

### 3.1 個人属性(所得・性別)データの処理

本研究では、山中ほか(2021)の手法を用いて、住宅・土地統計調査(2018年)をダウンスケーリングし、250mメッシュ(5次メッシュ)ごとの推定平均個人所得データを整備した。まず、住宅・土地統計調査の住宅の所有関係別の年間収入階級別世帯数(市区町村別)と、国勢調査の住宅の所有関係別の世帯数(町丁字別)を対応付けることで、町丁字毎の年間収入階級別世帯数を推定した。次に、町丁字毎の年間収入階級別世帯数データと250mメッシュのポリゴンデータを空間結合し、生成された領域の面積で按分することで、250mメッシュ毎の年間収入階級別世帯数割合を算出した。最後に、算出した250mメッシュ毎の年間収入階級別世帯数割合から250mメッシュ別の各世帯と各居住者の平均年収を推定した。同データによる推定結果の例を図2、図3に示す。

なお、住宅・土地統計調査は、市、区及び人口1万5千人以上の町村を対象としているため、それ以

外の地域は未収録となるが、平成30年の場合、日本全国の1,741自治体のうち、1,068自治体(61.3%)、世帯数にすると全国約5,400万世帯のうち、約5,200万世帯(96.5%)の範囲の情報を収録しており、日本全国の世帯年間収入の空間分布を網羅的に把握するのに十分な量の統計を含んでいるといえる。

### 3.2 MBD(モバイルビッグデータ)の処理

本研究では、株式会社AgoopのMBDであるポイント型流動人口データを使用する。期間は、2019年度の1年分のデータを使用して分析を行った。た

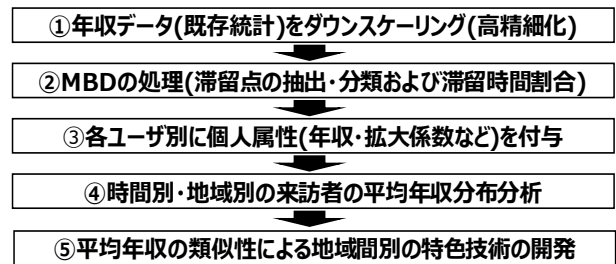


図1 本研究の流れ

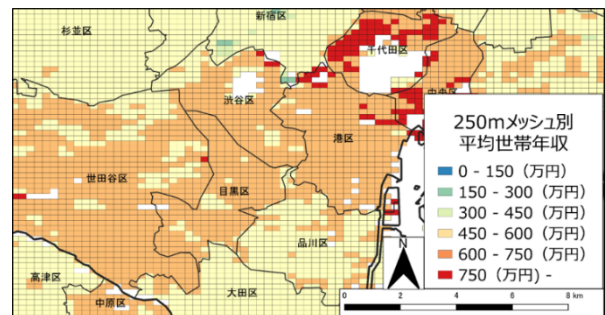


図2 世帯あたりの平均年収の推定結果  
(東京都心・250mメッシュ集計)

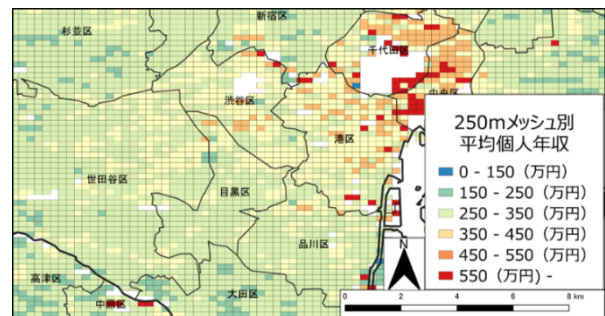


図3 一人あたりの平均年収の推定結果  
(東京都心・250mメッシュ集計)

だし、2020年2月と3月は新型コロナウイルスの影響が現れる可能性が高いため、本研究では除外し、2019年4月から2020年1月までの10か月分のデータを使用した。また、本研究では東京都を対象に分析を行うため、東京都内を通過、あるいは滞留した人のデータを使用した。このデータは、携帯電話から取得した位置情報を秘匿化・統計加工したビッグデータであり、各ユーザの移動履歴をピンポイントで把握可能である。データの処理として、まず、Akiyama et al. (2016) や Hwang et al. (2017) などを参考にしてユーザ毎に滞留点を抽出し、さらに抽出した滞留点を居住地・勤務地、その他の滞留点に分類した。また、メッシュ集計された国勢調査を用いて、各メッシュの人口をそのメッシュを居住地と推定されたユーザ数で除し、各ユーザが何人の人口を代表しているかを推定した。本研究ではこの値を「拡大係数」と呼ぶ。

### 3.3 居住地の信頼性検証

3.2で各ユーザの居住地、勤務地、その他の滞留点を抽出したが、本研究ではユーザごとに推定された居住地に基づいて、個人属性（所得・性別）データの情報を各ユーザに与える。そのため各ユーザの居住地がある程度正しく推定されていることが重要である。そこで、本研究では1kmメッシュおよび500mメッシュごとの国勢調査による人口と、それぞれのメッシュ内に含まれる3.2の処理でした居住地の数をを用いて相関分析を行った。なお、あるメッシュ $\alpha$ の居住地数 $N_\alpha$ は式1で算出した。

$$N_\alpha = \frac{\sum_{i=d_1}^{d_e} \sum_{j=1}^{k_{ai}} m_{aij}}{d_e - d_1} \quad (1)$$

$d_1$ は対象期間初日（2019年4月1日）、 $d_e$ は対象期間最終日（2020年1月31日）であり、そのため $d_e - d_1 = 306$ （日）となる。 $k_{ai}$ はメッシュ $\alpha$ 内の $i$ 日目の居住地の数、 $m_{aij}$ はメッシュ $\alpha$ 内の $d_1$ から $i$ 日目の居住地 $j$ の拡大係数である。

図4に1kmメッシュ集計の、図5に500mメッシュ集計の相関分析の結果を示す。1kmメッシュ集計




図4 国勢調査人口とMBD居住度数の比較（1kmメッシュ集計。東京都内を通過、あるいは滞留した人のみを対象。）




図5 国勢調査人口とMBD居住度数の比較（500mメッシュ集計。東京都内を通過、あるいは滞留した人のみを対象。）

は、相関係数が0.9555、決定係数が0.9111であり、500mメッシュでは、相関係数が0.9393、決定係数が0.8823であった。以上の結果から、滞留点の抽出及び、居住地の判定が概ね高い精度で実施できていることが確認できた。

#### 4. 分析手法

本研究では、3章で処理した各データを組み合わせることで、500mメッシュごとの来訪者の平均年収の時系列変化を推定可能なデータを開発した。具体的には、3.2の処理で得られた各ユーザの居住地に対応するメッシュを持つ、3.1で得られた個人属性(所得・性別)を各ユーザに紐づける。この処理により、各ユーザの所得や性別が推定可能になる。さらに居住地・勤務地以外の滞留点の滞留時間に基づいて、以下の推定を行った。なお、以下4.1~4.5の $S$ は年収、 $M$ は拡大係数、 $T$ は滞留時間割合である。

##### 4.1 $N$ 時のメッシュ別平均年収の推定

まず、 $N$ 時のメッシュ $m$ における平均年収の推定を式2で算出する。なお、滞留時間割合で重み付けをし、人口で除すことで人口の増減を考慮している。

$$I_{Nm} = \frac{\sum_{k=1}^n (S_k \times M_k \times T_k)}{\sum_{k=1}^n (M_k \times T_k)} \quad (2)$$

##### 4.2 $N$ 時のメッシュ別年収階級割合の推定

次に、 $N$ 時のメッシュ $m$ における平均年収階級別割合の推定を式3で算出する。住宅・土地統計調査と同様に9階級で年収帯を区分した。以下では、年収階級100万円未満の区分の総数を $l$ とし算出した。

$$R_{Nm(0-100)} = \frac{\sum_{i=1}^l (S_i \times M_i \times T_i)}{\sum_{i=1}^l (M_i \times T_i)} \quad (3)$$

##### 4.3 $N$ 時のメッシュ別年収階級滞留割合の推定

続いて、 $N$ 時のメッシュ $m$ における年収階級別滞留割合の推定を式4で算出する。4.2同様に9階級で年収帯を区分した。以下では、年収階級100万円未満の区分の総数を $l$ とし算出した。

$$T_{Nm(0-100)} = \frac{\sum_{i=1}^l (M_i \times T_i)}{\sum_{k=1}^n (M_k \times T_k)} \quad (4)$$

以上が、年収に関わる推定である。よって、任意の地域別時間帯別における平均年収の増減や年収区分の割合、滞留時間割合が把握可能となった。

##### 4.4 $N$ 時のメッシュ別男女割合の推定

さらに、 $N$ 時のメッシュ $m$ における男女割合の推定を式5で算出する。なお、男性の拡大係数を $Mm$ 、女性の拡大係数を $Mf$ とした。

$$\sum_{k=1}^n (Mmk \times Tk) : \sum_{i=1}^l (Mfi \times Ti) \quad (5)$$

##### 4.5 $N$ 時のメッシュ別生活圏内外割合の推定

最後に、 $N$ 時のメッシュ $m$ における生活圏内外割合の推定を式6で算出する。なお、道路技術基準を参考に、推定居住地と現在地の差が10km未満の場合を生活圏内者( $Ic$ )とし、10km以上の場合を生活圏外者( $Oc$ )と定義した。

$$\sum_{k=1}^n (Mk \times Ick \times Tk) : \sum_{i=1}^l (Mi \times Oci \times Ti) \quad (6)$$

以上で、任意の地域別時間帯別における性別や生活圏内外の来訪者割合が把握可能となった。

## 5. 推定結果の考察

### 5.1 時間帯別の結果

平日・休日の時間帯別の東京都内における来訪者の平均年収分布の結果を図6および図7に示す。平日の15時は、多くの人々が勤務地に滞在しているため、所得が高い大企業が集積している23区の業務地区に年収が高い人々が集中していることが確認できた。一方、休日の15時は人々の移動範囲が大きく広がるため、商業地域や観光地などにも所得が高い人々が広く分布していることが分かった。また、深夜の時間帯における分布は開発した平均年収分布と概ね一致していることも確認できた。

### 5.2 地域別の結果

東京都内の主要地域における来訪者の平均年収分

布の時系列変化を図8に示す。対象地域の特性をもとに分類を試みた結果、概ね地域間での類似性が確認できた。特に1日を通して来訪者の年収が高い地域では、深夜の時間帯でも活発な消費活動が見られることから、繁華街・業務地区と分類した。また、同じ地域内でも時間帯に応じて平均年収が大きく変化することが確認できた。

以上の分析により、MBDを活用することで任意の時間帯のどの地域に所得の高い人々が集中しているのかを推定することが可能になった。また、MBDと年収情報を組み合わせることで、任意の空間・時間帯別に地域の現状を把握することが可能となった。

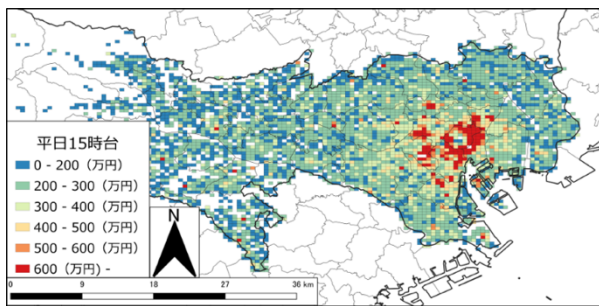


図6 平日15時における東京都民の来訪者による平均年収分布 (500m メッシュ集計)

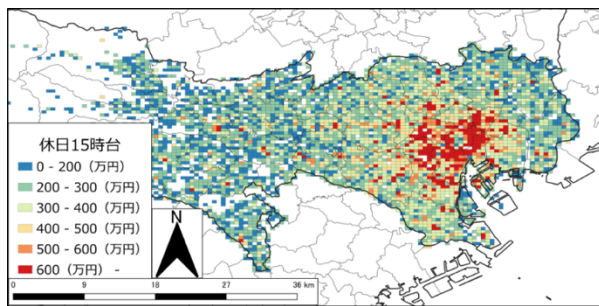


図7 休日15時における東京都民の来訪者による平均年収分布 (500m メッシュ集計)




図8 東京都内の主な地域における来訪者の平均年収分布の時系列変化

め、本研究の目的である地域経済の活性化や行政サービス等の効率化への応用が期待できるものと考えられる。

## 6. 来訪者の所得に基づいたクラスタリング

本研究では、5.2に示すような、幾つかの地区に限定したサンプリング的な分類に留まらず、東京都全域で地域分類する技術を開発する。まず、東京都全域を1kmメッシュで分割し、メッシュごとに0時から23時(24時点)の来訪者の平均年収を算出する。そして、各時点の来訪者の平均所得を変数とするクラスタリングを行うことで以上の地域分類を実現する。なお、クラスタリングの手法は教師なし分類の1つであるk-means法を採用した(MacQueen, J. B., 1967)。これはk-means法がサンプルサイズや次元数が大きい場合でも比較的高速かつ安定的にクラスタリングを行うことが可能であり(Har-Pele et al., 2010)、またこれまでに類似のクラスタリングに十分な実績を有するためである。

### 6.1 k-means法を用いたクラスター数の決定

k-means法ではクラスタリングを行う前に事前にクラスター数を与える必要がある。そこで適切なクラスター数を決定するために、まずエルボー法を用いた。その結果、クラスター数は2か3が最適であることが分かった。しかし、クラスター数を2か3に設定した場合、特に東京23区や東京市部のほぼ全域が同じクラスターに分類されるという結果になった。そこで、Kobayashi et al. (2019)の手法を参考に、まずクラスター数を10と大きい値に設定して分類を行った後に、特徴の類似するクラスター同士を統合する方法でクラスタリングを行った。図9にクラスタリングの結果を示す。この結果から平均年収が類似するメッシュ同士が同じクラスターに確かに分類されていることが確認できる。また、夜間(0時から6時)と日中の(7時から23時)の平均値を比較することで、一見類似して見えるクラスターでも、データのばらつきなどが明らかにみられることが分かる。



## 6.2 クラスター番号ごとの地域間別の類似性

続いて、類似性の高いクラスター番号ごとに、東京都内における分布を明らかにした。図 10 から図 13 にその結果を示す。まず、図 10 (c=3, c=5, c=2) で示すクラスターは、主に 23 区とその周辺に分布しており、1日を通して比較的平均年収が高い地域である。また c=3, c=5 は 23 区内の鉄道沿線に広く分布しており、駅周辺に高所得の人々が集積しやすいことが確認された。次に図 11 および図 12 に示す c=9, c=1, c=6 は、主に 23 区周辺と東京都市部に分布していた。特に c=9 は夜間の平均年収が c=1, c=6 と比べて高く、c=9 は主に市部の中心市街地や

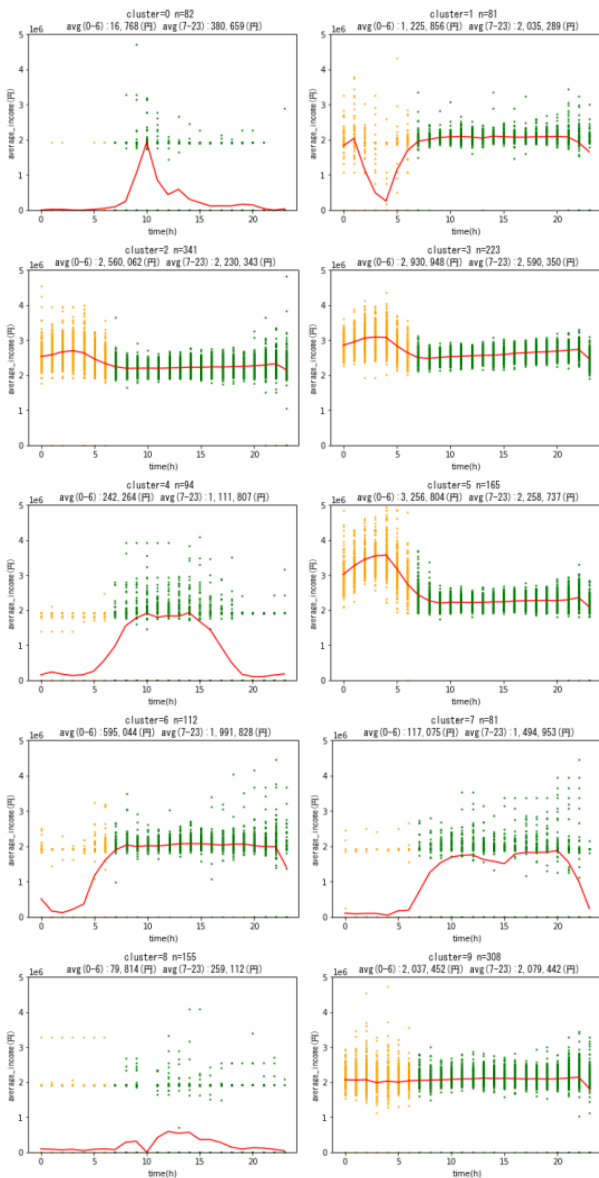


図 9 平均年収分布別クラスタリング (10 分類)

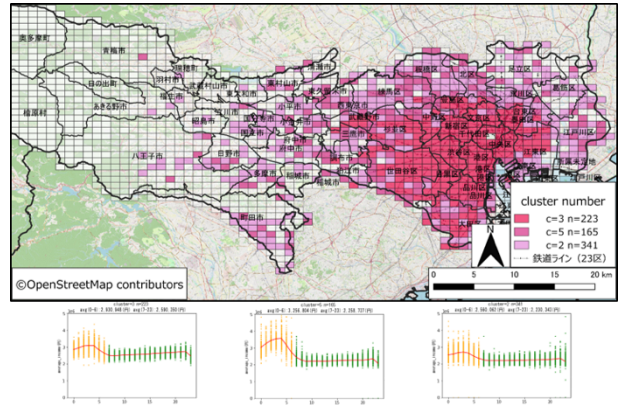


図 10 クラスター番号別可視化(c=3 c=5 c=2)

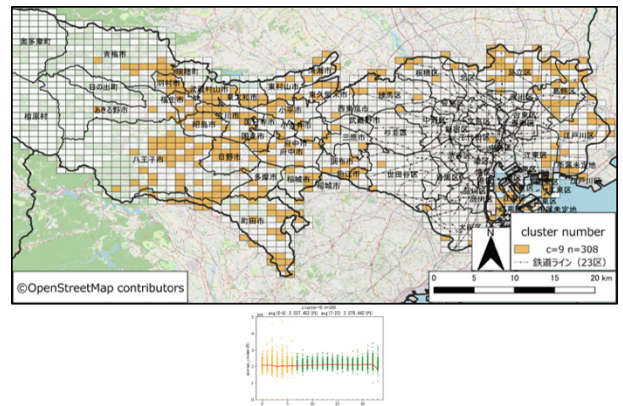


図 11 クラスター番号別可視化(c=9)

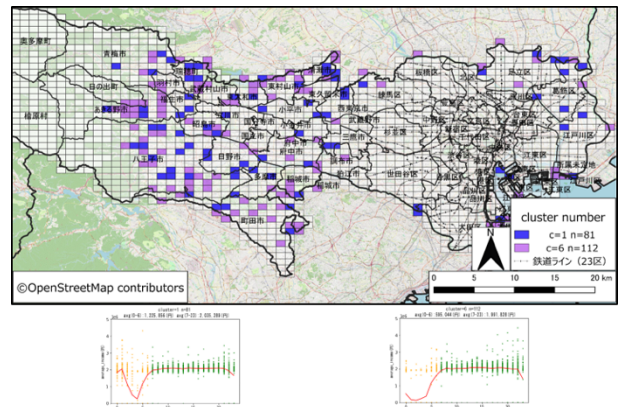


図 12 クラスター番号別可視化(c=1 c=6)

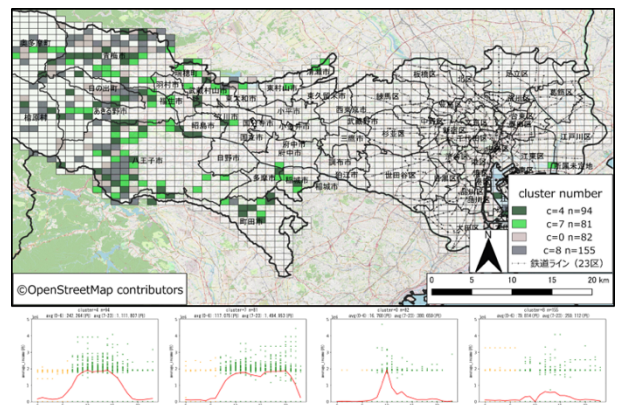


図 13 クラスター番号別可視化(c=4 c=7 c=0 c=8)

主要な駅周辺に分布していた。最後に、図 13 で示す  $c=4$ ,  $c=7$ ,  $c=0$ ,  $c=8$  は主に東京都西部（多摩地区）に分布しており、いずれのクラスターも平均年収が比較的低いことが確認された。ただし、図 13 のような地域では、時間帯によっては欠損値が多くなるため、今後はデータ数を増やし分類の信頼性を高めていく必要がある。以上に示す方法で来訪者の年収の時空間的な変化を把握することで、地域ごとの特色を把握できることを改めて確認できた。

## 7. 本研究成果を用いた来訪者特性の把握手法の提案

5 章・6 章の分析では、東京都全域を対象とし、所得という指標のもと地域分類を行った。さらに本章では、東京都内から地域を限定し、個人属性による地域特性をより詳細に把握するための方法を提案する。

まず、本章の提案において選定する地域として、商店街及びその周辺地域とした。近年の多様化・複雑化する社会において、消費者のニーズの変化は著しく、そのような変化に十分対応しきれない商店街では、来訪者の減少によってシャッター商店街化が進みつつある。また、近年では、商店街内の業種が異なる店舗に IoT センサを設置し、入場者数と購買者数を推定による賑わいモデルの構築（吉野ほか，2018）や、機械学習によるロコミ件数予測モデルの構築（榊原ほか，2021）など、商店街に関わる様々なデータを収集し、商店街の活性化に向けた分析が行われている。さらに、駅周辺では画像認識による歩行者の属性把握などの研究も進んでいる（野地ほか，2020）。

このように商店街の現状把握や活性化に資する研究として、商店街に来訪する人々の動向に注目した研究が近年数多く行われるようになりつつある。そこで、本研究でも各商店街における来訪者の特性を分析することで、商店街の現状のニーズを把握し、今後の施設設置の検討やターゲット選定時等への政策への一助となる情報の提供につながる提案を行い、その可能性や課題について議論する。

### 7.1 商店街の選定

まず、対象地域として東京都内から以下の商店街を選定した。

- ① 巣鴨商店街（豊島区）
- ② 麻布十番商店街（品川区）
- ③ アメ横商店街（台東区）

①～③の商店街を選定した理由は、まず図 3 で示した推定個人所得がそれぞれの商店街で大きく異なるためである。また、以下に示すように商店街間で地域特性が異なることから、それぞれの商店街で得られる結果に多様性が見られるものと期待されるためである。

- ①巣鴨商店街：観光客（特に高齢者）に人気がある中規模な商店街
- ②麻布十番商店街：東京都内の一般的な商店街の雰囲気とは異なる高級感を感じさせる商店街
- ③アメ横商店街：JR 上野駅という主要駅周辺に位置し、様々な属性の人々が混在しやすい環境にある大規模な商店街

### 7.2 年収階級別割合および年収階級別滞留時間割合による分析

まず、①巣鴨商店街の平常時の 16 時から 23 時における年収階級別割合（4.2 節）と、年収階級別滞留時間割合（4.3 節）の集計結果を図 14、図 15 に示す。また、①～③の商店街のイベント時（①くじら祭り、②納涼祭り、③開運感謝セール）の 16 時から 23 時における年収階級別割合（4.2 節）の集計結果を図 16、図 17、図 18 に示す。

まず、①巣鴨商店街における平常時（図 14）とイベント時（図 16）による比較では、大きな違いは見られなかったものの、イベント時の方が高収入層の割合が僅かに減っていることが分かった。また、図 15 から巣鴨商店街では、200～400（万円）の年収層が多く時間滞留していることが分かる。さらに、イベント時の各商店街を比較すると年収層の割合に差があることが確認できる。特に、麻布十番商店街は他の商店街と比べ、1000（万円）以上の年収層が全体の 2 割近くを占めていることが分かった。




図 14 巣鴨商店街における来訪者の年収階級別割合 (平常時, 16~23 時の集計)




図 17 麻布十番商店街における来訪者の年収階級別割合 (イベント時, 16~23 時の集計)




図 15 巣鴨商店街における来訪者の年収階級別滞留時間割合 (平常時, 16~23 時の集計)




図 17 アメ横商店街における来訪者の年収階級別割合 (イベント時, 16~23 時の集計)




図 16 巣鴨商店街における来訪者の年収階級別割合 (イベント時, 16~23 時の集計)

### 7.3 男女比割合および生活圏内外割合による分析

続いて, ①巣鴨商店街の 6 時から 11 時, 12 時から 17 時, 18 時から 23 時の 3 つの時間帯で平常時の男女比率 (4.4 節) と生活圏内外比率 (4.5 節) の集計結果を図 19, 図 20 に示す。図 19 から巣鴨商店街では男女の比率には大きな差はないことが分かる。また, 図 20 から夕方から深夜帯にかけて外部からの来訪者が増えていることが確認できる。

以上から, 本研究の集計データを活用し, 任意の時間帯・場所での属性把握を比較することで各地域の来訪者の特性を明らかにすることができた。またその結果から, 来訪者のニーズを把握することも可能となった。






図 19 巣鴨商店街における来訪者の男女割合 (平常時)




図 20 巣鴨商店街における来訪者の生活圏内外割合 (平常時)

#### 7.4 まとめ

以上 7.2 および 7.3 の分析結果から、以下のような提案が考えられる。まず、来訪者の所得水準に応じた店舗の出店計画や価格設定、在庫管理といったマーケティング分野や経営計画の支援に活かすことができる。また、時間帯によって変化する来訪者の性別や生活圏内外の割合に対して、例えば特別価格などを設けるなどすることで、来訪者の所得や性別にピンポイントに刺さる商品の限定販売などを実施することで、来訪者の購買行動を刺激させ商店街における消費行動を活性化させることができる可能性がある。このように、MDB と個人属性の活用により、商店街の発展を支援し、ひいてはその商店街を含む都市全体の活性化につなげることができるものと期待できる。

#### 7.5 今後の展望

本章では、平常時とイベント時の比較を行ったが、使用した MBD は東京都全域の 1 年 365 日分の情報を得ることが出来るため、季節や天候の違いによる比較や、駅周辺や商業施設周辺などといった場所による比較も可能である。さらに、業種別の店舗情報（島崎ほか、2009）や空き店舗状況などを加える事で、来訪者の属性との因果関係など新たな発見が期待できる。その一方で、商店街の集客力は、上記のような定量化できる属性から得られる物理的な情報を分析するだけでは十分に把握できない場合がある。一般社団法人中小企業診断協会（2015）によると、商店街の魅力は上述する物理的な「もの」だけで決まるものではなく、その商店街でしか体験できない「こと」によっても大きく左右されるという。すなわち、商店街の周辺環境や歴史など様々な切り口による商店街の特性把握が重要となってくるため、これらの情報をいかに分析に盛り込んでいくかも重要な課題と言えるだろう。

#### 8. おわりに

本稿では、MBD を活用した SP に資する新たな空間統計の開発方法として、任意の時間・場所における来訪者の所得を把握可能にする技術開発に取り組んだ。また、来訪者の年収の時空間的な変化に注目した新しい地域分類の手法や地域特性の把握などの提案をすることができた。今後は、MBD による分析をモデル化や指標構築を行い（峰元、2017）、より客観性を高めた定量的評価へと繋げ、新たなジオデモグラフィクスの開発に応用していきたい（Dalton and Thatcher, 2015）。その他にも、本研究の手法を更に大規模な MBD に適用することで、コロナ禍における地域経済への影響評価や、「人流データ利活用の手引き」（国土交通省、2022 年）を参考とした地方都市での課題解決にも応用していけるものと考えている。

#### 謝辞

本研究は科研費・挑戦的研究（萌芽）JSPS（19K21660）の助成を受けて実施した研究成果である。また本研究で使用したモバイルビッグデータ「ポ

イント型流動人口データ」を株式会社 Agoop より提供を受けた。以上、ここに記して謝意を表したい。

## 参考文献

一般社団法人中小企業診断協会 (2015) 東京都及びその周辺の商店街におけるにぎわい創出の方法及び今後の課題整理 報告書. <<https://www.j-smeca.jp/attach/kenkyu/honbu/h26/nigiwai.pdf>> (最終閲覧日 2022 年 8 月 27 日).

小西純 (2010) 現状把握のための小地域統計データの利用と共有-情報共有媒体としての地方公共団体統計ホームページ-, 「日本統計研究所」, 33-48.

国土交通省 (2018) スマート・プランニング実践の手引き～個人単位の行動データに基づく新たなまちづくり～【第二版】. <<https://www.mlit.go.jp/common/001255640.pdf>> (最終閲覧日 2022 年 8 月 28 日).

国土交通省不動産・建設経済局情報活用推進課 (2022) 地域課題解決のための人流データ利活用の手引き Ver1.0. <<https://www.mlit.go.jp/report/press/content/001474839.pdf>> (最終閲覧日 2022 年 8 月 27 日).

榎原千爽子・高橋信雄・神沼英里 (2021) アーケード街のデータサイエンス アーケード商店街の地理情報分析とクチコミ件数予測モデル構築, 「名古屋市立大学大学院芸術工学研究科紀要 工学芸術への誘い」, 26, 49-54.

島崎康信・関本義秀・柴崎亮介・秋山祐樹 (2009) 人の流れによる時間帯別人口と店舗数との相関関係についての研究, 「日本都市計画学会都市計画論文集」, 44(3), 781-786.

豊田哲也 (2021) 市町村別データを用いた住宅地地価の形成要因分析 所得の地域格差と世帯密度の影響に注目して, 「日本地理学会発表要旨集」, 2021s(0), 123.

野地駿吾・岸本達也 (2020) 画像認識による街路空間における歩行者の年齢, 男女比, 感情, および密度の分析, 「公益社団法人日本都市計画学会都市計画論文集」, 55(3), 451-458.

松島敏和・橋本浩良・高宮進 (2015) 移動履歴データと外生データを組み合わせた 移動目的判別シ

ステムの提案, 「第 52 回土木計画学研究発表会・講演集」, 52, CD-ROM.

峯元長 (2017) 人流データに基づく移動行動のモデル化と環境変化に適したサービス活用のための指標化, 千葉大学大学院工学研究科博士論文.

山中惇矢・古谷貴史・秋山祐樹 (2021) 住宅土地統計のダウンスケーリングによる地域メッシュ単位の世帯所得データの開発, 「第 30 回地理情報システム学会講演論文集」, A30-5-2.

吉野碧・家入祐也・菱山玲子 (2018) IoT センサを用いたデータの統合的利用による商店街の賑わい推定モデル, 「情報処理学会第 80 回全国大会」, 1X-04, 4-47 - 4-48.

Akiyama, Y., Ueyama, S., Shibasaki, R. and Adachi, R. (2016) Event Detection Using Mobile phone Mass GPS Data and Their Reliability Verification by DMSP/OLS Night light Image, “*ISPRS Annals of the photogrammetry, Remote Sensing and Spatial Information Sciences*”, III-2, 77-84.

Cheng, X., Fang, L., Hong, X. and Yang, L. (2017) Exploiting Mobile Big Data : Sources, Features, and Applications, “*IEEE Network*”, 31(1), 72-79.

Dalton, C. M and Thatcher, J. (2015) Inflated granularity: Spatial “Big Data” and geodemographics, “*Big Data & Society*”, 2(2), doi.org/10.1177/2053951715601144.

Hwang, S. and Evans, C., Hanke, T. (2017) Detecting stop episodes from GPS trajectories with gaps. “*Seeing Cities through Big Data*”, Springer: Cham, Switzerland, pp. 427-439.

Har-Pele, S. and Sadri, B. (2010) How fast is the k-means method?. “*Algorithmica*”, 41(3), 185-202.

Kobayashi, R., Miyazawa, S., Akiyama, Y. and Shibasaki, R. (2019) Identification of the Homes, Offices, and Schools from Long-Interval Mobile Phone Big Data Using Mobility Pattern Clustering, “*Accepted Short Papers and Posters from the 22nd AGILE Conference on Geo-information Science*”, 82.

MacQueen, J. (1967) Some Methods for classification and Analysis of Multivariate Observations. 1. “*Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*”, 281-297.