

旅客来訪領域の Hotspot 検出と施設立地の変化に基づく COVID-19 の影響の分析

一万田 凌¹・塚井 誠人²

¹ 学生会員 広島大学大学院 先進理工系科学研究科 (〒739-8527 広島県東広島市鏡山 1-4-1)
E-mail:m216915@hiroshima-u.ac.jp

² 正会員 広島大学大学院准教授 先進理工系科学研究科 (〒739-8527 広島県東広島市鏡山 1-4-1)
E-mail:mtukai@hiroshima-u.ac.jp

COVID-19 によって都市内各地区で不均一に人流が変化している。都心の人流減少は短期的には経済活動の停滞につながるほか、中長期的には人流と都市施設配置の間のミスマッチによって施設の混雑や遊休などの不効率が発生する。今後の社会で計画的な都市空間利用を進めるには、都市域全体を網羅した人の集積地点を検出する手法の開発が必要となる。本稿では、まず既存のエシェロン解析を用いて、東京都市圏を対象に周辺よりも顕著に人口が集積する地点(メッシュ単位)を探索する。次に、人口集積地点における人流データに NMF を適用し、滞在人口の時間変動パターンを抽出する。さらに、テレポイントデータによる施設立地情報に関する分析と併せて、人流集積地点と施設立地の対応の観点から COVID-19 の影響を明らかにする。

Key Words: Mobile spatial statistics, Echelon analysis, Telepoint data

1. はじめに

2022 年 9 月現在、新型コロナウイルス感染症(以下、COVID-19)の感染者数は高上りしており、我々の社会経済活動に一定の影響を与え続けている。一方、2020 年に比べると移動制限や外出自粛等の抑制措置は緩和されており、COVID-19 と共存する社会が始まっている。社会の変化は、人口が集中する大都市内各地での不均一な人流変化として現れている。たとえば利用者や行政が感染を懸念する施設が多い地区では人流の減少が著しい一方で、リモートワーク等の影響で住宅地では日中の在宅者が多い。都心の人流の減少は短期的には経済活動の停滞を招くほか、中長期的には人流と COVID-19 以前に整備された都市施設配置の間のミスマッチを起し、施設の混雑や有休などの不効率が生じると考えられる。

今後の社会において計画的な都市空間利用を進めるためには、都市域全体を網羅した人の集積地点を検出する手法の開発が必要となる。本発表では、COVID-19 によって生じた都市内の人流変化と都市施設立地変化の相関を明らかにする。この成果に基づけば、今後の COVID-19 と共存する社会への適応への示唆や、人々の集積とミスマッチが生じる地点・施設(業種)に対する新たな政策の発見につながると考えられる。

2. 既往研究の整理と本研究の位置づけ

COVID-19 下における人の集積に関する既往研究として、後藤ら¹⁾は、広島県を対象として、モバイル空間統計²⁾を用いて、第一回目の緊急事態宣言前、期間中、後における人々の昼間滞在人口の変化について分析した。この研究では、土地利用別の滞在人口の変化に関する特徴を明らかにしている。根本ら³⁾は、茨城県つくば市を対象に、モバイル空間統計を用いて外出制限の効果を分析し、住宅地や商業施設・研究機関・大学の立地する地区などの土地利用別に人口流動の変化を明らかにしている。しかし、これらの既往研究は、COVID-19 下における人流変化について土地利用に着目した分析にとどまっており、詳細な施設(業種)に着目した分析はできていない。

エシェロン解析を用いた既往研究として、小田ら⁴⁾は、空間の位相的構造を階層的に表現できるエシェロン解析を用いて、森林を構成する樹林蓋を同定する手法を提案するとともに、森林の階層構造および不均一性を明らかにしている。また、Takemura ら⁵⁾は、都道府県別の COVID-19 感染者数についてエシェロン解析を適用し、クラスターの発生位置や周期を可視化するとともに、クラスターの発生原因を考察している。しかし、これらの既往研究を含め、モバイル空間統計などで把握できる詳細な時空

間単位の人流や滞在人口に関するデータにエシェロン解析を適用した研究は未だ見られない。

施設立地に関する既往研究として、テレポイントデータ（以下、TPD）を用いる研究が進められている。TPD は、業務目的の固定電話の所在地、業種等のポイントデータであり、2010 年以降の毎年についてその推移を明らかにできる。定梶ら⁹⁾は、TPD を 36 業種に再分類して施設の集積を用意した上で、駅の乗降者数と駅周辺の施設集積の相関を明らかにしている。また、宮本ら⁷⁾は、重回帰分析等を用いて、再開発事業の特性を示す変数と TPD から得られる周辺商業集積に与える波及効果の関係を明らかにしている。しかし、これらの既往研究は、詳細な施設データを用いているものの鉄道駅周辺や再開発事業地域周辺に限定した分析であり、都市域全体を網羅した施設立地の分析になっていない。また、後述する本研究のように、電話番号をある種の人口とみなした分析が行われているわけではない。

上述した既往研究に対する本研究の特徴は、都市内全体を網羅した滞在人口データについて、エシェロン解析を適用して今後の都市計画や施設立地問題へのエビデンスにしようとする点、および、詳細な施設（業種）レベルでの COVID-19 の影響の有無を明らかにする点である。

本稿では、まず、モバイル空間統計から得られる 4 次メッシュ（500m）における滞在人口について、エシェロン解析を用いた Hotspot 検出手法を適用し、人流集積地点を検出する。次に、非負値行列因子分解（NMF）を人流集積地点に適用し、滞在人口の時間変動パターンを抽出する。最後に、TPD に基づく施設立地の変化と併せて人流への COVID-19 の影響を分析する。なお、施設立地の変化に関する詳細な分析は作成中のため、発表時に報告する。

3. 分析対象地と使用データ

本研究では、COVID-19 の影響を強く受けたと考えられる、人口が多く集中する都市域内の人口集積地点を検出するため、東京都市圏（東京都 23 区および横浜市・川崎市を含む）を分析対象とする。図-1 に分析対象地の概略を示す。対象メッシュ数は全体で 5375 メッシュであった。使用データはモバイル空間統計および TPD であり、共に 4 次メッシュ（500m）単位で扱う。

モバイル空間統計は NTT ドコモが開発した人口統計であり、携帯電話基地局下の在圏情報から得られる。1 時間ごとの滞在人口を 24 時間 365 日把握できる。COVID-19 前後で人流集積地点の変化を比較するため、対象期間を 2019 年 5 月第 4 週および 2020 年 5 月第 4 週と設定する。なお、時刻別に 5 日間の平均滞在人口を算出した。

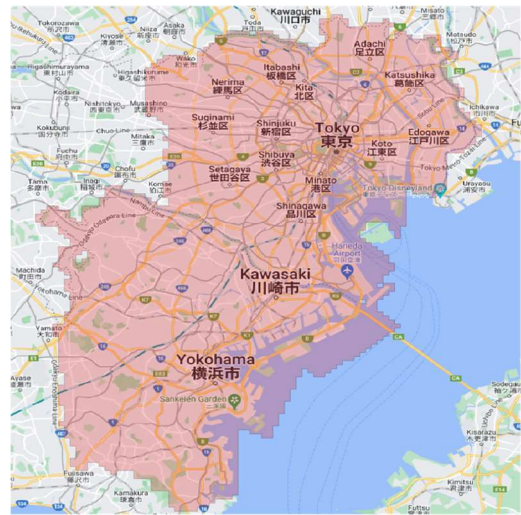


図-1 分析対象地（東京都市圏）


TPD は株式会社ゼンリンが提供している座標付電話 DB であり、電話番号のポイントデータである。属性として、電話番号に紐づく名称や業種コード、位置座標、電話帳初回登録日などがある。本研究では、これらポイントデータについて緯度経度座標から 4 次メッシュへの変換も実施した。データの観測時点は、2019 年（2 月）および 2020 年（8 月）である。TPD が多い地点≒施設が多い地点と仮定すれば、人流と施設立地の関係を分析できると考えられる。TPD を使用する狙いは、①施設立地と人口集積地点の相関を把握すること、②COVID-19 の影響で施設（店舗）が倒産・移転など、立地変化が生じている地点と人口集積地点の相関を把握することである。

4. 分析手法

(1) エシェロン解析に基づく Hotspot 検出手法

Hotspot は、地理情報に紐づく属性値（たとえば時間帯別の人流や都市施設数など）が他地点と比較して顕著に高い地点、またはその近傍を含む領域を指す。Hot spot の同定には kulldorff⁸⁾によって提唱された空間スキャン検定を用いる。なお、Hot spot 検定を連続空間上に分布する点にも適用する際の方法論は、本研究が想定する離散空間上の領域の場合とは異なる。本稿ではポイント情報ではなく、メッシュを対象とする Hot spot 検出手法を検討する。

既存の Hotspot 手法において対象領域をメッシュとした場合、計算回数が多い、また、1 メッシュを越える領域への人の集積地点の検定にならないという問題が生じる。そこで、栗原ら¹⁰⁾はエシェロン解析を組み込んだ Hotspot 検出手法（エシェロンスキャン）を示した。本研究では、この方法を用いる。



エシェロン解析^{10),11)}は、分析対象領域をピーク（属性値が高い地点）とそのファウンデーション（ピークとピークを繋ぐ周辺部分）に分割する手法である。具体的には、設定された近傍情報と解析のアルゴリズム¹²⁾に沿って、領域内の最小領域を統合してピークおよびファウンデーションを形成していく。エシェロン解析を用いると、統計的観点から他地点と比較して有意に属性値が高いと判断された Hotspot(s)領域を抽出できる。

本研究では、モバイル空間統計から得られる滞在人口データに本手法を適用し、他地点に比べて顕著に人が集積する地点（エシェロン）を検出する。なお、Hotspot の検出手法の概要およびエシェロン解析のアルゴリズムの詳細については、一万田ら¹³⁾を参照してほしい。

(2) 非負値行列因子分解

非負値行列因子分解（Non-negative Matrix Factorization, 以下 NMF）は、非負値の行列データを、パターンとパターン別の重みに分解して同時に抽出する手法であり、Lee ら¹⁴⁾によって提唱された。この方法で得られる出力（分解後のパターンとその重み）は非負値に限られ、解釈がしやすいという利点がある。

本研究では、(1)で検出する人口集積地点（エシェロン）における滞在人口に NMF を適用する。図-2 に、本研究における NMF のイメージを示す。図-2 に示すように、行方向に時刻別の時間情報を、列方向にエシェロン別の空間情報を並べた行列データ X を作成する。この入力データ X から得られる出力データは、時間的特徴の分布を表すパターン $m \times k$ の行列 H と、パターンごとの滞在人口負荷量の分布を表す $k \times n$ の行列 W である。前者からは時間的特徴とパターンの関連性が、後者からはパターンごとに負荷量が高い滞在人口情報が、それぞれ判明する。なお、本研究ではモバイル空間統計を 2 年分利用している（2019 年と 2020 年のデータをスタックしている）ため、同一時刻・同一メッシュに 2 個ずつ人口データが存在する。なお、分析者が決定するパターン数 k は k と損失距離に関するエルボー図と、パターン間の特徴の違いに基づいて定めた。

5. 分析結果

(1) エシェロンの検出

エシェロン解析への入力データとして、2019 年と 2020 年それぞれの人流の特徴を把握できる代表時刻として 11 時と 23 時を設定する。この結果、2 年次 2 時点の計 4 時点についてエシェロンを形成した。この設定は、人々が主に外出や通勤を行う昼間と、主に帰宅して家に滞在する夜間のそれぞれの特性を考慮するためである。

エシェロンの設定条件として、①各メッシュの近傍情報、②モンテカルロシミュレーション回数、③有意水準、④単位エシェロンあたりメッシュ数の上限を定めなければならない。①～③については、それぞれ、8 近傍（キング）、99 回、1%と設定した。④は、妥当な値の事前想定が困難なため、以下の手続きによって設定した。まず、4 時点それぞれで、単位エシェロンあたりメッシュ数の上限を徐々に増加させながらエシェロンを形成する。次にそれぞれの時点で、上限を満たすエシェロンが初めて 1 つになったときの上限メッシュ数を採用する。つまり、この手順で求まるエシェロンの最大メッシュ数は真の値よりも小さくなる。

一連の試行により、単位エシェロンあたりメッシュ数の上限を増やすと小さなエシェロン同士が結合されて大きなエシェロンが形成されることがわかった。しかし、大きなエシェロンを形成することは、顕著に人が集積している地点を解析する本研究の狙いにとってそれほど重要ではない。そこで本分析では計算の簡便さを優先して、上記の手続きにて上限メッシュ数を定義した。

図-3 に、4 時点のエシェロンを統合して得られたエシェロンの空間分布を示す。図-3 より、東京都の主要区で

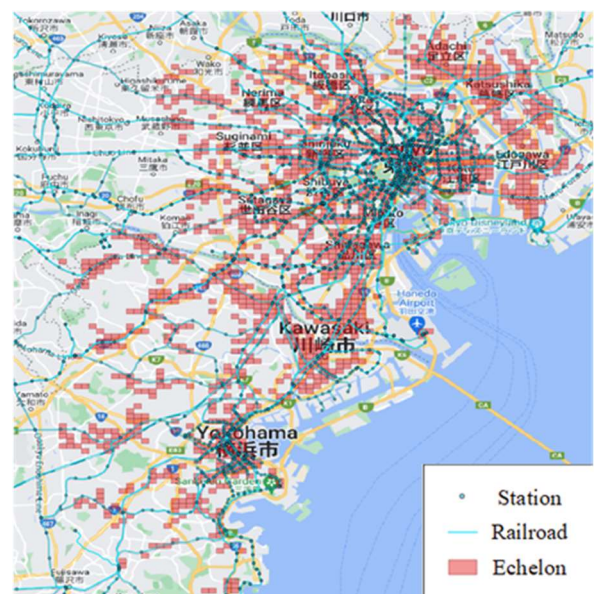


図-3 エシェロンの空間分布（4 時点統合）

ある千代田区、新宿区、渋谷区、港区や横浜駅、川崎駅周辺を中心にエシェロンが形成されていることや、駅および路線周辺にエシェロンが形成されていることがわかる。一部、郊外にもエシェロンが形成されているが、これらの地域には、住宅地などの人を集積させる施設があると考えられる。なお、エシェロンメッシュ総数は 1513 メッシュであり、これは全メッシュ中の約 28%にあたる。

(2) 滞在人口の時間変動パターン

形成したエシェロンに対して、モバイル空間統計の滞在人口データを 24 時間分付与して NMF を適用する。具体的には、空間情報にエシェロン (1513 メッシュ×2 年分) を、時間情報に 0 時から 23 時の時刻別平均滞在人口 (5 月第 4 週の平日 5 日分の毎時/5 サンプル) を 2 年分スタックし、行列データ (24 行, 3026 列) を作成する。これにより、2019 年と 2020 年のそれぞれの特徴を考慮した時間変動パターンを抽出する。

図 4 に NMF の出力で得られる行列 H (パターン別に基準化済み) についてパターン別の値の時間推移を示す。今回、8 つの時間変動パターンが抽出され、各パターンの行列 H の値が高い時間帯 (ピーク時間帯) をもとに命名した。たとえば、パターン Morning は 7 時~8 時がピークとなるパターンである。なお、エシェロン解析を適用せず、全データに NMF を適用してパターン抽出を行った結果と比較したところ、エシェロン解析を事前に実施した方が、理解しやすい時間変動パターンを抽出できた。これは、人が極端に少ないメッシュ等がある場合、NMF にてそれら特異なメッシュの特徴も加味されるという、人流集積地点の相対的な少なさによる分析の歪み

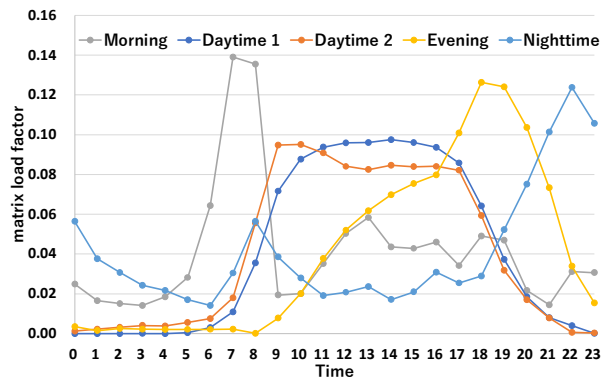


図 4 時間変動パターン

をエシェロン解析によって解消できたためと考えられる。図 5~図 7 に行列 W から得られる 2019 年および 2020 年における重み (人口) の空間分布のうち抜粋したものを示す。なお、凡例に関する人口のスケールは、滞在人口の多い年次に合わせた。

パターン Daytime 1 (図 5) では、両年とも東京駅周辺の千代田区、新宿区、渋谷区、港区、横浜市など、特に人々が昼間に滞在する地区に人口が集中していることがわかる。両年とも分布の傾向は大きく変わっていないが、滞在人口の集積量が 2020 年になって大きく減少している。昼間は人々が最も外出する時間帯のため、外出自粛の影響が強く現れたと考えられる。パターン Nighttime (図 6) では、2019 年に東京都中心部、新宿区、渋谷区に滞在人口が集中していた一方で、2020 年には急激に滞在人口が減少している。これは、夜に飲食店で食事をしたり、仕事終わりに買い物をしたりする人々が減少したことを表す。パターン Morning and Evening (図 7) では

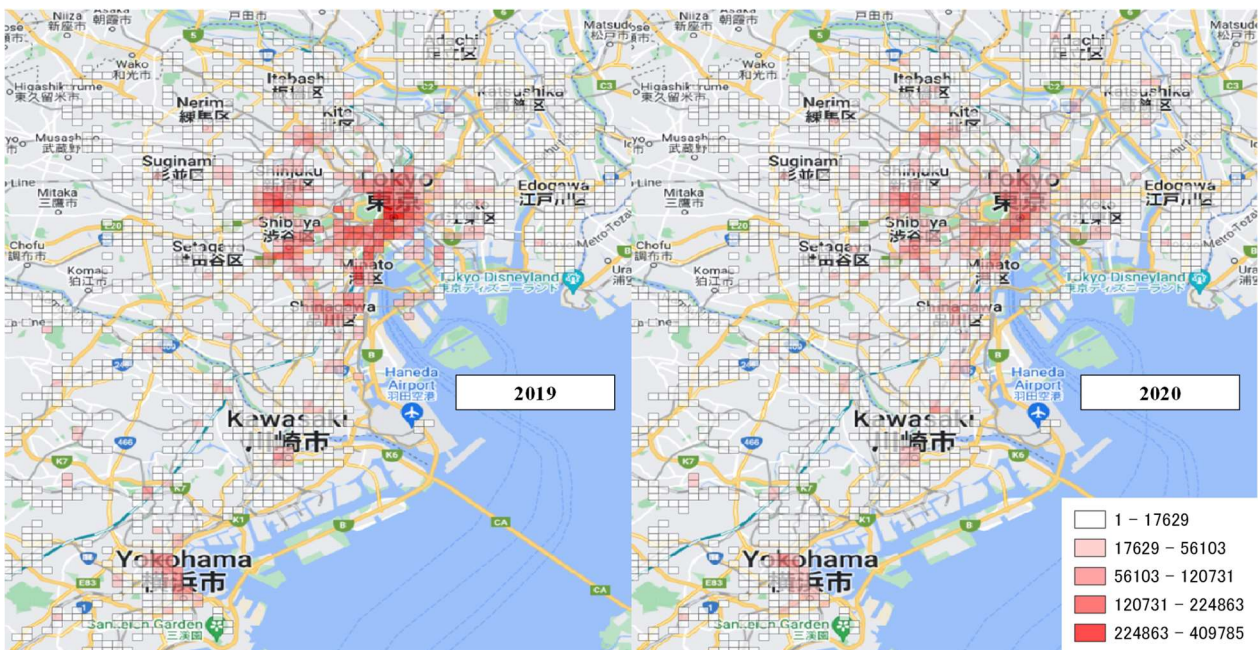


図 5 空間分布 (行列 W , Daytime 1)

2019 年に、山手線および横浜駅、川崎駅があるメッシュ
 周辺で滞在人口が集中している一方で、2020 年では全体的
 的に人口が減少している。このパターンは朝と夕方がピ

ークとなっており、通勤および退勤の時間帯と重なって
 いる。そのため、COVID-19 によって在宅勤務等が普及
 した影響を示すと考えられる。

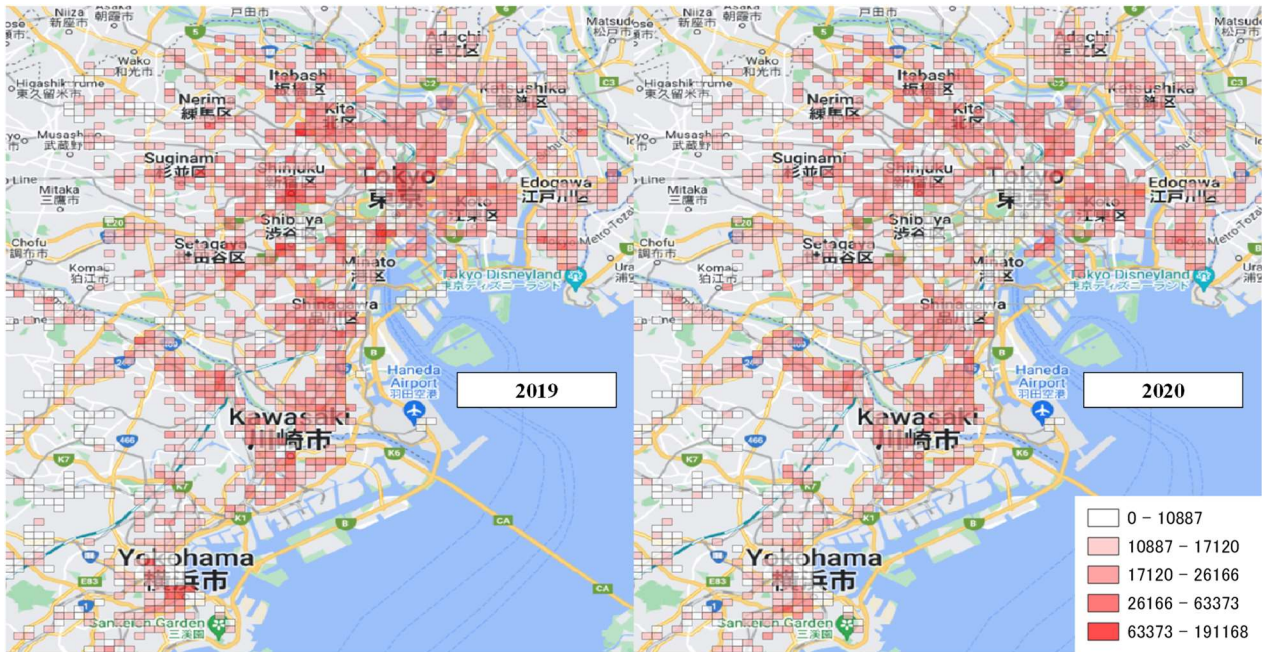


図-6 空間分布 (行列 W, Nighttime)

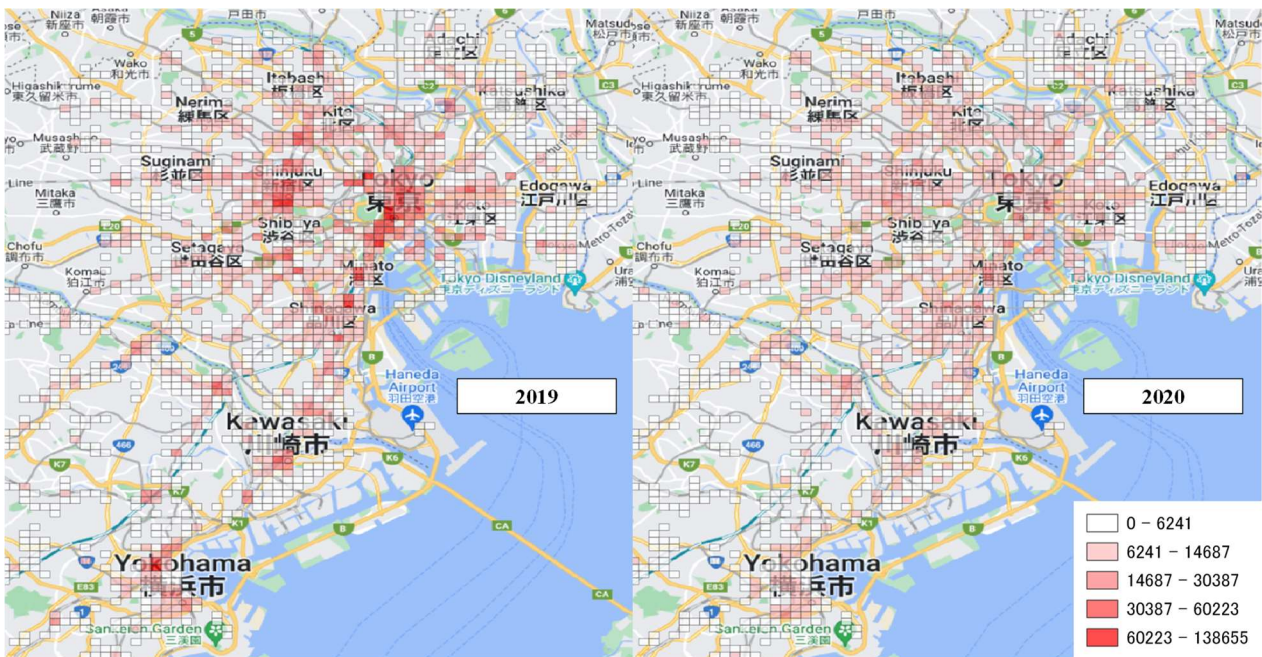


図-7 空間分布 (行列 W, Morning and Evening)

(3) エシェロンと施設立地の相関

今回、TPD の 2 年分について、以下の処理を行った。なお、単一の電話番号に対して異なる事業所名が付されているような重複番号のケースでは、簡単のため事業所・電話番号とも冒頭の 1 つのみを残し、残りを削除した。

1.	電話番号をキーとし、2019 年のデータに 2020 年のデータをテーブル結合。
2.	年次間において、名称・業種コード・メッシュが変化したらダミー変数 1 (変化していない場合はダミー変数 0) を与えた。 電話番号 1 つを 1 でカウントする集計も行った。 (=電話番号の単純集計)
3.	メッシュについては全体で 50%以上が年次間で変化がなかったため、年次間で不変のメッシュについてスクリーニング。(=回はメッシュの変化が起きていた電話番号を誤差として排除。)
4.	メッシュごとに、その他の項目のダミー変数を集計。(=ピボットテーブル集計)

図-8 に、都心部におけるエシェロンと TPD 集積を示す。主要区や駅周辺に多く電話番号は集積している。つまり、施設が多く集積する地域には TPD も多く集積する

傾向がある。TPD 集積は人流に基づいて算出したエシェロンのメッシュと重複する地点が多く、両者の相関が高い傾向もわかる。今後は業種コードにスクリーニングをかけて、業種別の人流の変化を明らかにする。

図-9 に、都心部におけるエシェロンと TPD における業種コード変化メッシュを示す。なお、上述の削除処理のため、TPD 業種コード変化の処理手順による誤差が生じていることに留意する。年次間で業種コードに変化があったものの自体の総数は少なく、変化のあったメッシュは駅周辺を中心に存在するが、その一部はエシェロンとは重なっていない。これらの地点についてはより詳細な分析(業種コードのスクリーニングなど)を進める必要がある。

図-10 に、経済センサスから得られる従業者数データ(全産業)と TPD 集積の散布図を示す。これはエシェロンとなる 1513 メッシュそれぞれのメッシュにおける従業者数と TPD 数の相関を表す。両者の相関は高くなく、これだけでは、TPD 集積が都市施設の集積と一致するとは判断し難い。今後は業種別に相関を詳細に見る必要がある。

本稿作成時点では、立地変化と COVID-19 の関係について詳しくは議論できないが、発表時までには 2021 年のデータも追加し、残りの分析を進める。

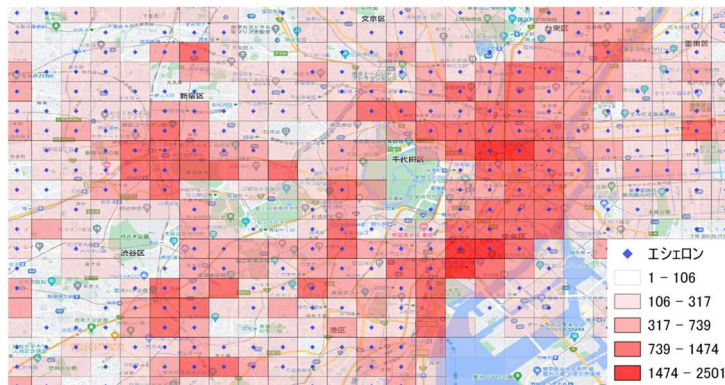


図-8 エシェロンと TPD 集積 (都心部)

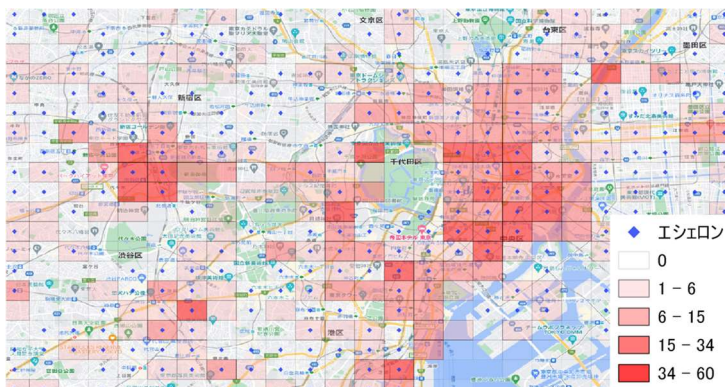


図-9 エシェロンと業種変化 (都心部)




図-10 従業者数と TPD 数の関係

6. おわりに

本研究では、エシエロン解析を組み込んだ Hotspot 検出手法を人流データに適用することで、統計的に有意な人流集積地点を検出できた。また、NMF によって人流集積地点における人々の時間変動パターンを抽出し、時間帯別の特徴を捉えることができた。各パターンの占める重み人口を COVID-19 前後で比較することで、人流変化を定量的に示した。

その結果、一定以上の人が集積する地点をエシエロン解析にて検出した上で NMF を適用することで、より理解しやすい時間変動パターンを抽出できた。さらに TPD を用いることで、人の集積地点と施設の集積の関係や、COVID-19 前後で業種変化のあった施設の地点も明らかにできた。ただし、TPD は施設立地の変化が小さく、現段階では、大きな成果は見られなかった。今後は 2021 年のデータ等も追加することで、発表時までには新たな知見を得られるよう引き続き分析を進める。

謝辞：本研究を実施するにあたって、株式会社ドコモ・インサイトマーケティングからモバイル空間統計データを、東京大学空間科学研究センター CSIS からテレポイントデータを提供いただいた。ここに記して謝意を表す。

参考文献

- 1) 後藤拓, 田村将太, 田中貴宏, 塚井誠人: 新型コロナウイルス感染症による都市内の昼間滞在人口分布の変化-コロナ収束後の都市のあり方検討に向けて-, 日本建築学会技術報告集, Vol.28, No.69, pp.906-911, 2022.
- 2) NTT ドコモ: モバイル空間統計に関する情報, https://www.nttdocomo.co.jp/corporate/disclosure/mobile_spatial_statistics/, (アクセス: 2021 年 1 月 28 日).
- 3) 根本裕都, 藤井さやか, 佐野雅人, 鈴木勉, 雨宮護, 大澤義明: COVID-19 による外出制限が人口流動に及ぼす影響 2020 年 4 月の緊急事態宣言期間中のつくば市の事例分析, 日本都市計画学会都市計画論文集 Vol.56, No.3, 2021.
- 4) 小田牧子, 石岡文生, 正木隆, 栗原考次: データ分析の理論と応用, Vol.2, No.1, pp.17-31, 2012.
- 5) Takemura, Y., Ishioka, F., and Kurihara, K.: Detection of space-time clusters using a topological hierarchy for geospatial data on COVID-19 in Japan, Japanese Journal of Statistics and Data Science 5, pp.279-301, 2022.
- 6) 定梶圭, 巖先鏞, 鈴木勉: 施設集積に基づいた鉄道駅の類型化と拠点性に関する研究, 日本都市計画学会 都市計画論文集, Vol.56, No.2, 2021.
- 7) 宮本勇希, 吉川徹, 讃岐亮: 地方都市における市街地再開発事業の建築物の特性と周辺商業集積の変化の関連性-商業集積の施設数変化に着目して-, 日本建築学会計画系論文集, Vol.87, No. 793, pp.596-607, 2022.
- 8) Kulldorf, M.: A spatial scan statistics, Communications in statistics: Theory and Methods, Vol.26, No.6, pp.1481-1496, 1997.
- 9) 栗原考次, 石岡文生: エシエロン解析 (統計学 One point), 共立出版, 2021.
- 10) WAYNE MYERS, G .P. PATIL and KYLE JOLY: Echelon approach to areas of concern in synoptic regional monitoring, Environmental and Ecological Statistics 4, pp.131-152, 1997.
- 11) Kurihara, K.: Classification of Geospatial Lattice Data and their Graphical Representation, Classification, Clustering, and Data Mining Applications, pp.251-258, 2004.
- 12) Ishioka, F., Kurihara, K., Sutio, H., Horikawa, Y., Ono, Y.: Detection of hotspots for 3-dimensional spatial data and its application to environmental pollution data, Journal of Environmental Science for Sustainable Society 1, pp.15-24, 2007.
- 13) 一万田凌, 塚井誠人: エシエロン解析に基づく都心地区への都市間旅客来訪地点の分析, 第 64 回土木計画学研究発表会・講演集, CD-ROM, 2021.
- 14) Daniel D. Lee and H. Sebastian Seung: Learning the parts of objects by non-negative matrix factorization, Nature, Vol.401, pp.788-791, 1999.

(? 受付)