

大規模ユーザの滞在情報に基づくエリアの特徴付けと COVID-19による影響分析

庄子 和之^{1,a)} 青木 俊介² 米澤 拓郎¹ 河口 信夫^{1,2}

受付日 2021年1月7日, 採録日 2021年7月7日

概要: 都市や地域の各エリアに人がどのように滞在し、どのように利用しているかを知ることは、マーケティングや商圏分析、出店判断などの商業的利用に加え、都市設計や交通政策などの自治体の政策判断など、幅広い分野で有用であり、これまでは大規模なアンケート調査などで実現されてきた。しかし、時間経過にともなう様々な事象（都市の発展、季節の変化、パンデミックの発生）によるエリア利用形態の変化を検知するには多大なコストが必要となり、その定常的な利用は現実的ではない。本研究は、大規模ユーザの移動履歴情報から滞在情報を抽出し、エリアを特徴付ける手法（Area2Vec）を提案する。本手法は Word2Vec アルゴリズムを参考として、到着時刻と滞在時間の情報からエリアの分散表現を構築する。この分散表現により、都市の機能分類に加え、滞在行动の時間的変化の観測・分析が可能になる。評価実験として、宮城県仙台市の国分町を対象にしたエリアの機能分類を行い、その有用性を確認した。また、COVID-19 による人々の滞在行动の変化を調査するため、国分町と東京都新宿区の歌舞伎町を対象に検証を行い、人の滞在数の減少に加え、滞在時刻の夜から昼へのシフトを確認した。

キーワード: アーバンコンピューティング, 時空間データマイニング, 人流

Area Modeling Using Stay Information for Large-scale Users and Analysis for Influence of COVID-19

KAZUYUKI SHOJI^{1,a)} SHUNSUKE AOKI² TAKURO YONEZAWA¹ NOBUO KAWAGUCHI^{1,2}

Received: January 7, 2021, Accepted: July 7, 2021

Abstract: Understanding how people stay and use each area in a city or region is not only for commercial use such as marketing, trade area analysis, and store opening decision, but also for local governments such as urban design and transportation policy. It is useful in a wide range of fields such as policy making, and has been realized by large-scale questionnaire surveys. However, it requires a great deal of cost to detect changes in area usage patterns due to various events over time (urban development, seasonal changes, pandemics), and its regular use is not realistic. This study proposes a method (Area2Vec) that extracts stay information from the movement history information of large-scale users and characterizes the area. This method uses the Word2Vec algorithm as a reference to construct a distributed representation of the area from the arrival time and stay time information. This representation makes it possible to observe and analyze temporal changes in staying behavior in addition to functional classification of cities. As an evaluation experiment, we classified the functions of the area in Kokubuncho, Sendai City, Miyagi Prefecture, and confirmed its usefulness. In addition, in order to investigate changes in people's staying behavior due to COVID-19, we conducted a verification targeting Kokubuncho and Kabukicho in Shinjuku-ku, Tokyo, and in addition to reducing the number of people staying, from night to noon at the time of stay. The shift of was confirmed.

Keywords: urban computing, spatiotemporal data mining, human mobility

¹ 名古屋大学大学院工学研究科情報・通信工学専攻
Graduate School of Engineering, Nagoya University, Nagoya,
Aichi 464-0814, Japan

² 名古屋大学未来社会創造機構
Institutes of Innovation for Future Society, Nagoya University,
Nagoya, Aichi 464-8601, Japan

1. はじめに

都市は様々な使われ方をするエリアから形成されている。

^{a)} shoji@ucl.nuee.nagoya-u.ac.jp

たとえば、平日の日中に多くの人を訪れる「オフィスエリア」や夜に賑わいをみせる「繁華街」、それ以外にも「住宅エリア」や「ショッピングエリア」などがあげられ、都市とはその集合体と見なすことができる。そのため、エリアの使われ方を分析し把握することは、都市の機能分類だけでなく、様々な分野で有効な手段となる。しかし、エリアの使われ方は時間経過にともなう様々な事象（都市の発展、季節の変化、パンデミックの発生）の影響を受け変化する。COVID-19がその際たる例である。人々は外出の自粛を行い、飲食店や娯楽施設から人が減少した。また、リモートワークの環境が整い自宅で仕事をしはじめ、昼夜を問わず自宅にすることが増えた。エリアの使われ方の変化の検知は、店舗側のマーケティング戦略にも役立ち、さらに、都市計画や政府の施策のための情報源としても有効である。したがって、エリアに対し、オフィスエリアやショッピングエリアといった機能を適切に反映させ、かつ、エリアの使われ方の変化をとらえることができるようにエリアをモデリング（物事や現象を他の方法で表現し抽象化すること）することが重要である。また、エリアモデリングの結果を類似度算出といった計算を行ったり、機械学習の特徴量に転用したりするには、エリアをベクトルで表現するのが望ましいと考えられる。

エリアをその使われ方から特徴付ける既存手法には課題が存在する。それは時間経過から発生する事象によるエリアの使われ方の変化をとらえることができないというものである。エリアの使われ方を分析するにあたり、既存研究ではPOI（Point of Interest）データがよく用いられる [1], [2], [3]。POIデータとは、地図上の特定のポイントのことであり、世の中に存在するあらゆるものがPOIになりうるが、一般的には目標物を指すことが多く、本論文では店舗名またはその種別ラベル（飲食店、学校など）を意味する。人々の生活スタイルは時間とともに変化する、エリアの使われ方も変化するはずだが、POIデータは静的に定義された情報であるため、POIデータを用いた手法ではその変化をとらえることができない。また、エリアの特徴を十分に反映できないという課題もある。エリア間の移動遷移データもエリアの特徴付けにはよく用いられる [4], [5], [6] が、あるエリアからあるエリアへの移動したという情報のみでは、各エリア内での人々の行動は考慮されない。

そこで我々は、滞在の観点から見たエリアの使われ方を基に、エリアを特徴付け、分散表現とするためのエリアモデリング手法 *Area2vec* を提案する。*Area2vec* は、*Word2Vec* [7] のアルゴリズムを参考にしたもので、エリアの分散表現を作成する。したがって、同じような滞在（使われ方）が行われるエリアどうしは、ベクトル空間上で近くに配置されることになる。使用する滞在情報とは、「曜日」、「到着時刻」、「滞在時間」の3つの滞在に関する時間情報である。本研究では、各エリアへの不特定多数のユーザの滞在情報

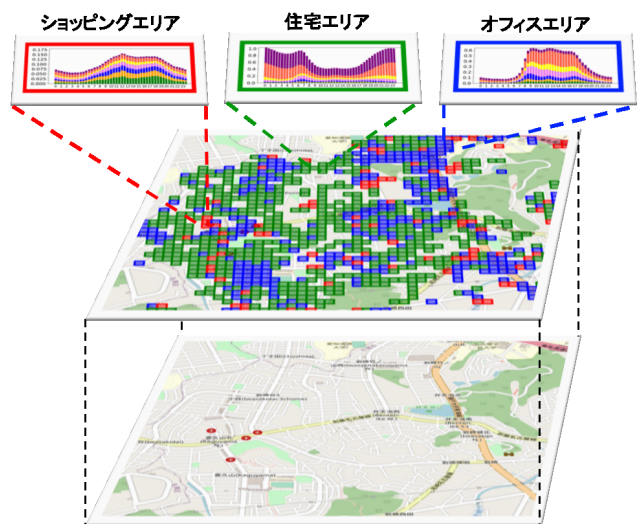


図 1 エリアモデリングの概要

Fig. 1 The overview for area modeling.

を用いることで、エリアの様々な特徴が反映されたモデリングが可能であるという仮説をたてる。たとえば、平日に朝から夕方まで長時間の滞在が行われるエリアはオフィスエリアだと推定できる。また、平日・休日を問わず、夜中に長時間の滞在が行われるエリアは住宅エリアだと推定できる。その結果、POIデータを用いず、時間経過にともなう事象の影響に対応したエリアの特徴付けが可能になる。図 1 に、本研究により実現されるエリアモデリングの概要を示す。滞在の観点からエリアは特徴付けされ、任意の個数でクラスタリングされる。そして、クラスタごとに色分け、さらに各クラスタの特徴をグラフ化することで各エリアの特徴の推定を可能にする。このような手法を本研究では実現する。本論文では、エリアの使われ方を滞在の観点から分散表現化したものを、*UAS* (the Usage of Area with Stay information) と呼ぶ。作成したエリアの分散表現をクラスタリングすることで、同じような使われ方のエリアをまとめあげて抽象化でき、*UAS* に解釈の付与が可能になる。たとえば、クラスタ 1 に割り当てられた *UAS* は「住宅エリア」、クラスタ 2 に割り当てられた *UAS* は「オフィスエリア」と解釈が付与されることになる。

我々は、(i) エリアごとの機能の特徴をとらえることは可能か、(ii) 時間経過にともなう事象の影響によるエリアの使われ方の変化をとらえることは可能か、という 2 つの観点から提案手法の評価実験を行う。我々が使用する位置情報データはスマートフォンから収集された GPS データであり、宮城県仙台市の国分町と東京都新宿区の歌舞伎町を対象にした実験を行った。(i) に関しては、抽出された特徴から解釈の付与を行うと人間の感覚と一致したエリアの機能分類が可能であることを確認できた。つまりこの結果から、都市計画や都市の機能分類の分野における提案手法の有効性が示された。また (ii) に関しては、COVID-19 の影響によるエリアの使われ方の変化を見ることで、月を追うごと

に人々の行動が変化していること、さらにそれがどのような変化であるかをとらえることができた。つまりこの結果から、マーケティングや政府の施策といった、状況変化を迅速に察知しなければいけない分野への提案手法の有効性が示された。

本研究による貢献は次の3つである。

- (1) 滞在の観点から見たエリアの使われ方を基に、エリアを特徴付け、分散表現とする手法 Area2Vec を開発したこと。POI データを必要とせず、時間経過にともなう事象の影響に対応した新しいエリアモデリング手法である。
- (2) 大規模ユーザの位置情報データを使用し、都市の機能分類を通して、提案手法が有効なエリアモデリング手法であることを証明したこと。
- (3) COVID-19 の影響による人々の行動の変化を通して、提案手法がエリアの使われ方の変化の観測・分析に有効であることを証明したこと。

本論文の構成は次に示すとおりである。まず2章で位置情報データを使った関連研究の紹介をする。3章では UAS の作成手法について解説し、4章でデータセットの説明と提案手法の評価実験を行う。最後に5章でまとめと今後の展望を述べる。

2. 関連研究

ユビキタスコンピューティングの発展により、スマートフォンやバス、タクシー、SNS から収集されたデータを使った都市や移動に関する研究がさかに行われ [8], [9], [10], 移動データの利活用の需要は、都市計画やマーケティング、交通管理、災害対策など様々な分野で増加している。たとえば、ユーザモデリング [11], [12], [13], [14] や潜在顧客の推定 [15], 都市ダイナミクスの予測 [16], POI レコメンド [17], 都市の異常検知 [18] などがあげられる。

一方で、我々はエリアモデリングに焦点を当てている。都市とは様々な使われ方をするエリアから形成されている。そのため、エリアの使われ方を把握し分析することは、都市の機能分類において有効な手段となる。Yuan ら [1] は、タクシーの乗降データによるエリア間の移動遷移データと POI データを用い、トピックモデルを活用することで、異なる機能を有する地域を発見するための手法 DRoF (Discovers Regions of different Functions) を提案している。Pan ら [4] は、従来まで行われていたリモートセンシングデータを用いた都市機能の分類について、その分類項目の少なさや人々の行動が反映できないといった問題点を指摘し、タクシーの乗降データを使った都市の機能の分類を行っている。Yao ら [5] と Crivellari ら [6] は、エリア間の移動遷移データを用い、Word2Vec を活用することで、エリア間移動の前後関係（どこからどこへ移動したか）を考慮し、エリアの分散表現を作成するための手法を提案し

ている。Zhai ら [2] は、POI の分散表現を作成するための手法である Place2Vec [19] を活用し、NA (Neighborhood Area) スケールで街の機能の分類を行っている。

上述の研究は、POI データを使用することで地理空間情報からエリアの使われ方の特徴付けを行い、また、エリア間の移動遷移データを使用することでエリア間移動の前後関係（どこからどこへ移動したか）からエリアの使われ方の特徴付けを行っている。しかし、本研究は従来のエリアモデリング手法とは異なり、滞在の観点からエリアの特徴付けを行うものである。滞在情報からエリアの使われ方の特徴付けを行うことで、POI データという、外的要因ではただちに変化しない情報を用いた手法とは異なり、時間経過にともなう様々な事象による人々の行動の変化を検知できるエリアモデリング手法となる。また、エリア間の移動遷移データにはタクシーの乗降データが多く用いられている。しかし、この情報は降りた場所と行きたい場所が必ずしも一致するとは限らないという欠点がある。さらに乗降したその一瞬の断片的な情報のみを使用することになるため、タクシーに乗る直前までいた場所、またはタクシーを降りた先でどのような行動がとられたかは不明である。その結果、エリアモデリングを行う際、間違っただけの特徴が反映される可能性がある。しかし、提案手法は滞在情報、つまり人の行動というエリアの使われ方に近い情報を利用するため、詳細なエリアの特徴付けが可能になる。

3. 提案手法

本章では、本研究が提案するエリアモデリング手法 Area2Vec の詳細について解説する。Area2Vec は、Word2Vec [7] のアルゴリズムを参考にしたものである。Word2Vec とは、単語の分散表現を作成するための技術である。単語の分散表現とは、単語を高次元の実数ベクトルで表現する技術をいう。これまで、入力層と出力層に渡されるデータを工夫することで、様々なドメイン（ユーザ [12], POI [19], 地域 [6]) を分散表現として扱う手法が提案されてきた。Word2Vec は、注目単語の周辺の単語が注目単語の意味情報として有力であるという仮説を基に、注目単語の周辺情報を学習させることで、単語の分散表現を作成している。Area2Vec では、注目エリアへの人々の滞在情報が注目エリアの意味情報として有力であるという仮説を基に、注目エリアへの人々の滞在情報を学習させ、エリアの分散表現の作成を目指す。Word2Vec には skip-gram と continuous-bag-of-words が含まれているが、Area2Vec には skip-gram を使用する前提で以下説明を行う。

本研究の目的は、滞在の観点から見たエリアの使われ方を基に、エリアの特徴付けを行い、エリアの分散表現を作成することである。本研究で用いる滞在情報は「曜日」、「到着時刻」、「滞在時間」の3つである。これらの滞在情報は、エリアの使われ方が大きく反映される情報である




図 2 Area2Vec のアーキテクチャ
Fig. 2 The architecture of Area2Vec.

と考えられる。一方で、本手法には制限も存在する。それは、同じカテゴリに属する施設が存在する 2 つのエリアについて、そこで行われる滞在の傾向が異なる場合、ベクトル空間上でこの 2 つのエリアは離れて配置されてしまうことである。たとえば、「レストラン」と分類される 2 つの店が存在するとき、一方が並ばずに入れるレストラン、もう一方が行列ができ待ち時間が長いレストランである場合、これら 2 つの分散表現はベクトル空間上で近くに配置されることはない。また、本手法はエリア間の移動遷移によるエリアどうしの関係性を無視しているため、移動の前後関係が考慮できないことも制限となりうる。たとえば「家」と「オフィス」の往復は多くの人々が毎日のように行う移動であり、ここから「家」の次は「オフィス」、逆に「オフィス」の次は「家」という前後関係が出来上がり、この関係性はエリアを特徴付けるうえで重要なものだと考えられる。しかし、本手法ではエリアへの滞在情報しか用いないため、この考慮はできない。そこで本研究は、滞在情報という施設利用の実態に即した特徴によるエリアモデリングの実現に焦点をおくことで、既存手法とは相補的な手法として位置づけることを目指す。

図 2 に提案手法に合わせたエリアの分散表現を作成するためのニューラルネットワークを示す。入力層と隠れ層の間の重みは $|N| \cdot |d|$ の行列であり、隠れ層と出力層の間の重みは $|N'| \cdot |d|$ の行列である。 N 、 N' 、 d はそれぞれ、モデリング対象となるエリア数、出力層のノード数、エリアの分散表現の次元数を示す。出力層のノード数 N' は、使用する情報によって変化する。本研究では、表 1 に示す滞在に関する時間情報を用いるため、出力層の各ノードはそれぞれ次の固有の情報を持つことになる：平日 (or 休日) の x 時から y 時間の滞在。ただし、滞在時間が 720 分以上の場合、例外的に到着時刻は考慮せず、曜日のみを考慮する設定にした。理由は、720 分以上の滞在は、発生する回数が少ないためである。発生する回数が少ない状態に到着時刻まで考慮した場合、学習の際、同じ滞在情報をターゲットにする予測がほとんど発生しないため、エリア間で

表 1 滞在に関する時間情報

Table 1 Information for area modeling.

曜日	平日, 休日
到着時刻	0:00~1:59, 2:00~3:59, ..., 20:00~21:59, 22:00~23:59
滞在時間	~29 min, 30~59 min, 60~119 min, 120~240 min, 240~359 min, 360 min~719 min, 720 min~

相関が得られないという問題が発生する。また、720 分以上の滞在は、何時からその滞を開始してもあまり違いがないと判断したことも理由の 1 つである。あるエリアを入力したとき、そのエリアへの滞在情報を予測するように学習を進める。これにより、学習後の入力層と隠れ層の間の重みが、多くの人々の「使われ方」が反映されたエリアの分散表現になる。ここで用語を 1 つ定義する。

定義 UAS (the Usage of Area with Stay information): 各エリアの分散表現のことである。各分散表現には滞の観点から見た多くの人のエリアの使われ方が反映されているためこのように名付けた。

UAS の次元数はハイパーパラメータである。本研究では次元数を 4 に設定した。理由は文献 [20] で述べられている以下の式を用いたためである。

$$embedding_dimensions = number_of_categories^{0.25}$$

この数式が意味することは、分散表現の次元数の目安はクラス数、つまり出力側のノード数を 4 分の 1 乗した値だということである。本来、Word2Vec ではクラス数 (出力側のノード数) は単語数になるが、Area2vec では曜日、到着時刻、滞在時間の全組み合わせ、 $2 \times 12 \times 6$ (720 分以上の滞在を除外) + 2 (曜日のみを考慮した 720 分以上の滞在) = 146 となる。そのため、上記の式を適用すると Area2Vec で作成する分散表現に必要な次元数は $146^{0.25} \approx 3.48$ となる。しかし、この値は整数である必要があり、小数点以下を切り捨て 3 次元とした場合、エリアの情報をすべて反映させるには次元数が足りない可能性がある。そのため、少なくとも 4 次元が必要であると判断した。

学習データセットには one-hot ベクトルを使用するが、

そのために滞在に関する「エリア情報」と「時間情報」をエンコードする必要がある。エリア情報に関しては、各エリアにはIDが割り振られるため、 N 次元ベクトルの対応する箇所に1が立ったone-hotベクトルで表現される。滞在に関する時間情報については、表1で示される情報の全組合せ数(=146)の次元数を持ったベクトルが用意され、対応する箇所に1が立ったone-hotベクトルで表現される。つまり、入力層には滞在が行われたエリアIDを表現したone-hotベクトルが入力され、出力層にはそのエリアへの滞在に関する時間情報を表現したone-hotベクトルが入力される。これによりArea2Vecの学習が行われる。

次にArea2Vecから作成された分散表現の正規化(単位ベクトルへの変換)を行う。この操作を行う理由は次のとおりである。Area2Vecから得られた分散表現のユークリッドノルムは、学習に用いられるデータ量に応じて長さが変化する。つまり、データが多いエリアの分散表現はノルムが長くなり、逆にデータが少ないエリアの分散表現はノルムが短くなる、という特徴がある。そのため、同じような使われ方をしているエリアでも、データ量が異なると、ベクトル空間上で近くに配置されない恐れがある。この問題を解決するために分散表現の正規化を行う。

最後に、完成したエリアの分散表現をクラスタリングする。この処理を行う理由は次のとおりである。UASは4次元のベクトルで表現されているが、ベクトルを個別に見てもそこに反映された意味を汲み取ることはできない。そのため、似た特徴を持つエリアをまとめることで、抽象度を上げ、情報量を抑える必要がある。これがクラスタリングを行う理由である。これにより、各クラスタに所属するUASへの解釈の付与が可能になる。たとえば、クラスタ1に割り当てられたUASは「住宅エリア」、クラスタ2に割り当てられたUASは「オフィスエリア」のように解釈の付与が可能になる。必要なクラスタ数については、欲している情報の抽象度によって変化してくると、我々は考えている。大雑把な都市の機能分類を行いたい場合はクラスタ数は少なくてもよいが、各UASの細かい違いまで見たい場合はクラスタ数を増やす必要がある。提案手法の評価を行う次章では、少ないクラスタ数で都市の機能分類を行い、さらに徐々にクラスタ数を増やすことで抽象度が下がり、別の特徴を持ったUASが出現することを確認している。また、さらにクラスタ数を増やすことで、人々の細かい行動の変化をUASから検知できることを確認している。

4. 評価

4.1 実験

本章では、提案手法であるエリアモデリング手法Area2Vecがエリアの特徴をとらえることができているかを実験的に確認し、UASの有用性を評価する。

4.1.1 GPS データ

我々が使用するデータは、事前に同意を得たユーザのスマートフォンにインストールされたアプリから収集されたGPSデータである。GPSデータ T は、次に示すタイムスタンプ付き座標の連続である： $T = p_0 \rightarrow p_1 \rightarrow \dots \rightarrow p_k$ (ただし $p_i = (x, y, t)$, $i = 0, 1, \dots, k$)。(x, y)はそれぞれ緯度と経度であり、 t はタイムスタンプである(ただし、 $p_{i+1}.t > p_i.t$)。


エリアの分散表現をArea2Vecを用いて作成するには、GPSデータから滞在場所の推定を行う必要がある。滞在場所の推定は文献[21]の手法を用いた。滞在場所 SP は、次に示す滞在情報の連続である： $I = (x, y, d, s, a)$, $SP = I_0, I_1, \dots, I_n$ (n の値は滞在場所の個数を表すためユーザによって異なる)。(x, y, d, s, a)は、それぞれ緯度、経度、滞在時間、到着時刻、滞在エリア情報を示す(ただし、 $I_i.s > I_{i+1}.s$, $0 \leq i \leq n$)。

4.1.2 対象都市

本論文では(i)エリアごとの機能の特徴をとらえることは可能か、(ii)時間経過にともなう事象の影響によるエリアの使われ方の変化を検知することは可能か、という2つの観点から提案手法の有効性の評価を行っていく。(i)に関しては、宮城県仙台市の国分町(図3(a)の赤枠、900m×1,100m)を実験対象とした。国分町には次にあげる機能を持つエリアが存在する：ショッピングエリア(百貨店や



(a) 国分町



(b) 歌舞伎町

図3 評価実験を行った地域

Fig. 3 The regions used in experiment for evaluation.

アーケード街), 繁華街 (夜の街), 住宅街, オフィス街. 使用するデータは, 2020年3月に収集されたデータである. このデータのレコード数は5,181,619レコードであり, 7,348ユーザが含まれていた. そして, 滞在場所の推定を行うと135,702個の滞在が確認できた.

(ii) に関しては, 国分町と東京都新宿区歌舞伎町 (図3(b)の赤枠, 600m × 800m) を実験対象とし, COVID-19の影響によるエリアの使われ方の変化を見ていく. 歌舞伎町は, 「夜の街」に代表されるエリアであり, COVID-19の影響を大きく受けていると考えられる. このエリアの分析は, 店舗や政府がCOVID-19に対する対策を講じるのに役立つはずである. 国分町のデータは, 2020年3月~2020年7月の期間で収集されたものを使用する. このデータのレコード数は21,137,761レコードであり, 7,348ユーザが含まれていた. そして, 滞在場所の推定を行うと538,934個の滞在が確認できた. 歌舞伎町のデータは, COVID-19の影響をまったく受けていない2019年4月とCOVID-19による緊急事態宣言が発令された2020年4月に収集されたものを使用する. 2019年4月のデータは, 5,361,112レコードあり, 17,897ユーザが含まれていて, 滞在場所の推定を行うと138,082個の滞在が確認できた. 2020年4月のデータは, 2,482,401レコードあり, 7,734ユーザが含まれていて, 滞在場所の推定を行うと57,100個の滞在が確認できた.

本研究では, 場所も期間も異なるデータを使用しているが, その理由は次のとおりである. まず, 2020年3月~2020年7月の期間のデータを使用する理由は, COVID-19前とCOVID-19後を比較し, 数カ月にわたる人々の行動の変化を分析するためである. 次に, 2019年4月と2020年4月の期間のデータを使用する理由は, 前述の変化が季節的なものだけが原因ではないことを確認するためである. そして, 上述の2つの期間でそれぞれ異なる地域を用いる理由は, 実験結果から得られる知見の説得力を補強するためである.

4.2 UASの作成

本節では4.1.2項で述べたとおり, 宮城県仙台市の国分町を対象にエリアモデリングを行い, 都市の機能分類において人間の感覚と一致したものになるかを確認していく.

我々はこの街をメッシュ化し, 各マスに対し分散表現を作成することとした. メッシュとは特定の距離を一辺に持つ正方形で, 地表を網目状に覆って分割したものを指す. 各マスの大きさは一辺50mとした. GPSデータには測位誤差があり, マスのサイズが小さすぎると, 滞在の判定が間違ったマスのものとなる可能性がある. そのため, この問題が発生しないようにマスの大きさを50mという大きめの設定にした. マスの総数は396個であったが, 行われた滞在が100回未満のマスを除くことで, 241個まで

減らした. この制限を設けることで, 計算量を減らすことができる. また, 少数のユーザによる偏った特徴付けが行われることを防ぐ効果もある. 以降は各マスを「エリア」と称し, 提案手法を用いて作成した241個のエリアのUASについて分析を行った結果である.

分散表現が完成したら, 次はクラスタリングを行う. クラスタリングには, k-meansを使用した. 4次元のベクトルで表現されていたUASは, クラスタリングによりクラスタごとに意味のまとまりができ, 解釈が容易になる. 241エリアのUASのクラスタリング結果を図4に示す. 図4(a)の積層グラフは, 各クラスタに含まれるエリアにおける滞在時間別のユーザの人数の分布を示している. 左側のカラムが平日について, 右側のカラムが休日についてである. 横軸は時間を表していて, ビンは30分である. 縦軸は人数を表している. 縦軸に関して, 各クラスタに所属しているエリアの数には違いがあるため, エリアの数で割ることで正規化を行っている. また, 平日と休日は日数が違うため, それぞれの収集期間内の日数で割ることで正規化を行っている. つまり, このグラフは1エリアあたり, かつ1日あたりの滞在時間別のユーザの人数の分布を表している. この処理により, クラスタ間でのグラフの比較と平日休日間でのグラフの比較が可能になる. また注意として, 長時間滞在を行っている人は複数のビンに現れている. たとえば, 午前10から午後12の滞在を行った人がいた場合, ビンは30分であるため, 20個目のビンから24個目のビンのすべてに同一人物がカウントされている. このグラフを用いることで, 各クラスタに含まれるエリアの特徴が解釈可能になる.

以降は, 各クラスタに割り当てられたエリアへの解釈を行っていく. 今回はクラスタ数を4に設定した. クラスタ数を4にした理由は, 4.1.2項で述べたとおり, この街の機能を大雑把に分類すると4つ (ショッピングエリア, 繁華街, 住宅街, オフィス街) に分けることができ, これを確認するためである.

cluster1: 以下に列挙した理由から, 居酒屋や接待をともなう飲食店, クラブなどから構成される「繁華街」だと解釈できる.

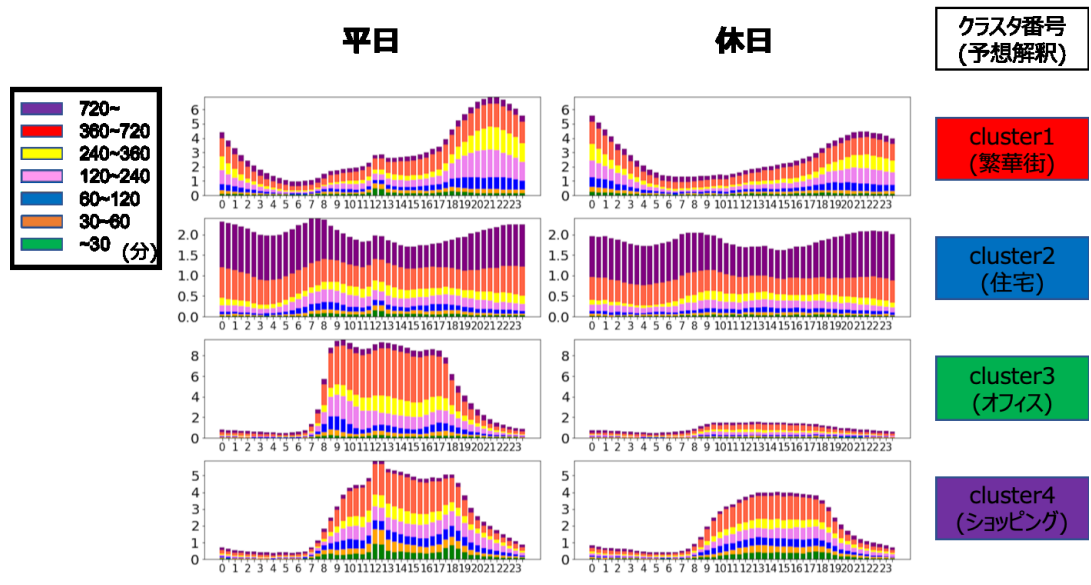
- 昼と夜の人数差.
- 21時をピークにした夜中の長時間の滞在.

cluster2: 以下に列挙した理由から, 主婦により特徴付けられた「住宅エリア」であると解釈できる.

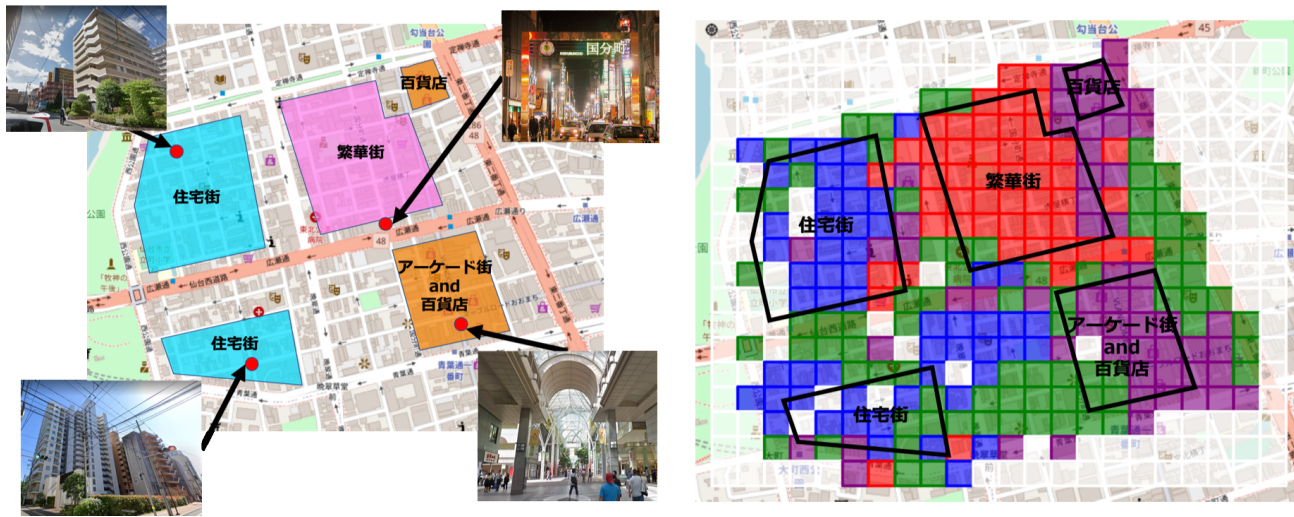
- 平日と休日の両方で1日を通しての12時間を超える滞在.
- 短時間の滞在が少ない.

cluster3: 以下に列挙した理由から, 会社勤めの人によって使われる「オフィスエリア」であると解釈できる.

- 8時くらいからの長時間の滞在.
- 夜中と休日の人数の少なさ.



(a) 各クラスタに割り当てられているエリア使われ方を示した積層グラフ



(b) エリアの分散表現をクラスタ毎に色分けした結果を描画したマップ

図 4 エリアの分散表現のクラスタリング結果
 Fig. 4 The clustering result of area modeling.

cluster4 : 以下に列挙した理由から、飲食店を含む「ショッピングエリア」であると解釈できる。

- 日中の短時間の滞在.
- 休日でも人が多い.
- 食事時の人数の増加.

また、図 4(b) には上述のクラスタリング結果を地図上に描画したものを示す。左の地図は国分町の機能を大雑把に分類した際の様子を表している。右の地図は各エリアを所属するクラスタごとに色分けした様子を表している。この2つの地図を比較すると、おおよそ期待どおりのエリアの特徴付けが行えていることがうかがえる。繁華街が広がる場所は赤色 (*cluster1*) が割り当てられ、住宅街が広がる場所は青色 (*cluster2*) が、アーケード街と百貨店は紫色 (*cluster4*) が割り当てられている。また、大きな道路沿いにはオフィスビルが点在しているのだが、そのあたり

は緑色 (*cluster3*) が割り当てられている。以上より UAS には、この街の4つの機能 (ショッピングエリア、繁華街、住宅街、オフィス街) の特徴が反映された適当なエリアの分散表現であることが見て取れる。白色のエリアは4.2節で述べた滞在が100回未満の分析対象から除外されたエリアである。

また、UAS は単純なエリアの機能分類に役立つだけでなく、クラスタ数を変更することで自由に抽象度を変え、都市の機能分類の詳細さを調節できる点が強みでもある。そこで、以降はクラスタ数を変更した際の違いを見ていく。図 5 にクラスタ数を5と6に設定した際の各クラスタの特徴を積層グラフに反映させたものを示す。まずクラスタ数5のとき (図 5(a)) を見てみる。クラスタ数5の場合、UAS の特徴は5つに分かれる。*cluster5* 以外は、クラスタ数4のときと同じ解釈の付与が行えると思われるが、*cluster5*

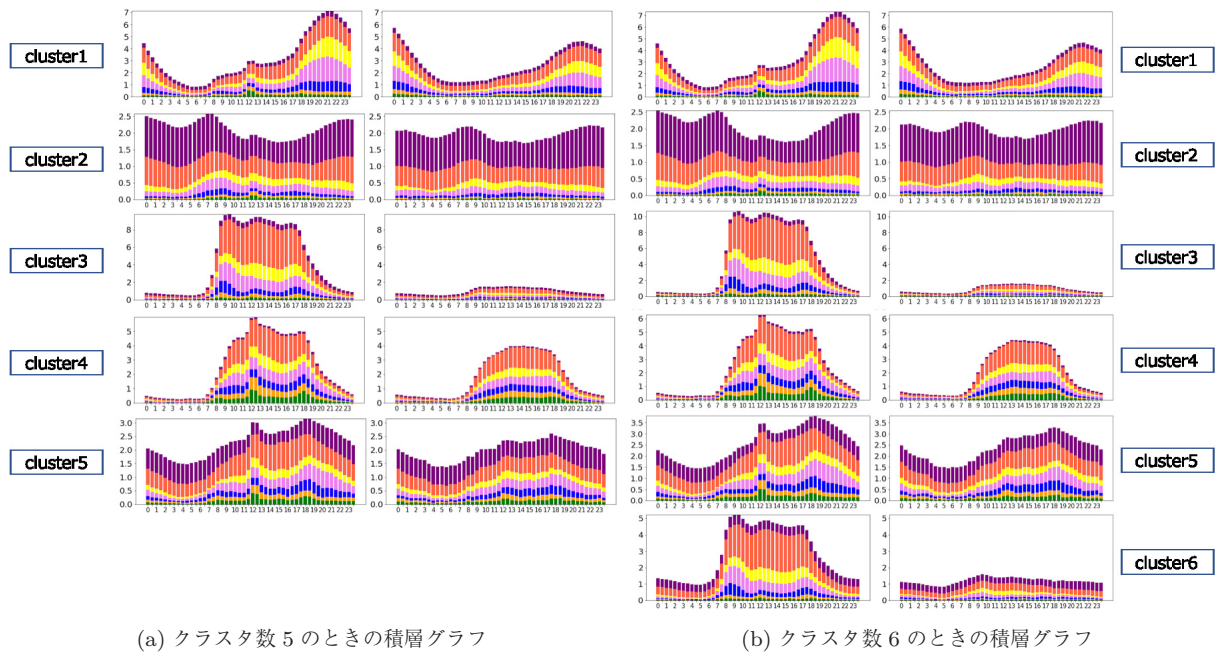


図 5 クラスタ数を変化させた際のクラスタリング結果
 Fig. 5 The clustering result when the number of clusters is changed.

は少し異なる。cluster5 は、0 時を回った夜中にも人が多いという特徴がある。また、平日は食事時に人が増え、さらに 1 日を通して長時間の滞在も目立つ。つまり、このクラスタに割り当てられたエリアは、繁華街もしくはそこに面した場所に立地した飲食店や住宅の特徴が反映されていると推察できる。次にクラスタ数 6 のとき (図 5(b)) を見てみる。クラスタ数 6 の場合、UAS の特徴を 6 つに分かれる。cluster6 以外は、クラスタ数 5 のときと同じ解釈の付与が行えると思われるが、cluster6 は少し異なる。cluster6 は、cluster3 と似ているが、cluster3 と比較すると、720 分以上の滞在が頻繁に発生していて、さらに休日に滞在が行われる割合が高いことが分かる。つまり、このクラスタに割り当てられたエリアは、「オフィスエリア」の中でも長時間の滞在が頻繁に発生し、かつ、休日の出勤も行われる場所であると考えられる。このように、クラスタ数を増やすことで抽象度を下げることができ、より詳細な都市の機能分類が可能になることが UAS の利点である。

4.3 COVID-19 の影響によるエリアの使われ方の変化

COVID-19 の影響により人々の行動がどのように変化したかについて、エリアの使われ方の変化を見ることで分析を行っていく。分析対象の都市は 2 つある。1 つ目の都市は、前節に引き続き宮城県仙台市の国分町である。2 つ目の都市は、東京都新宿区歌舞伎町である。以降はこれら 2 つの都市についてそれぞれ分析を行っていく。

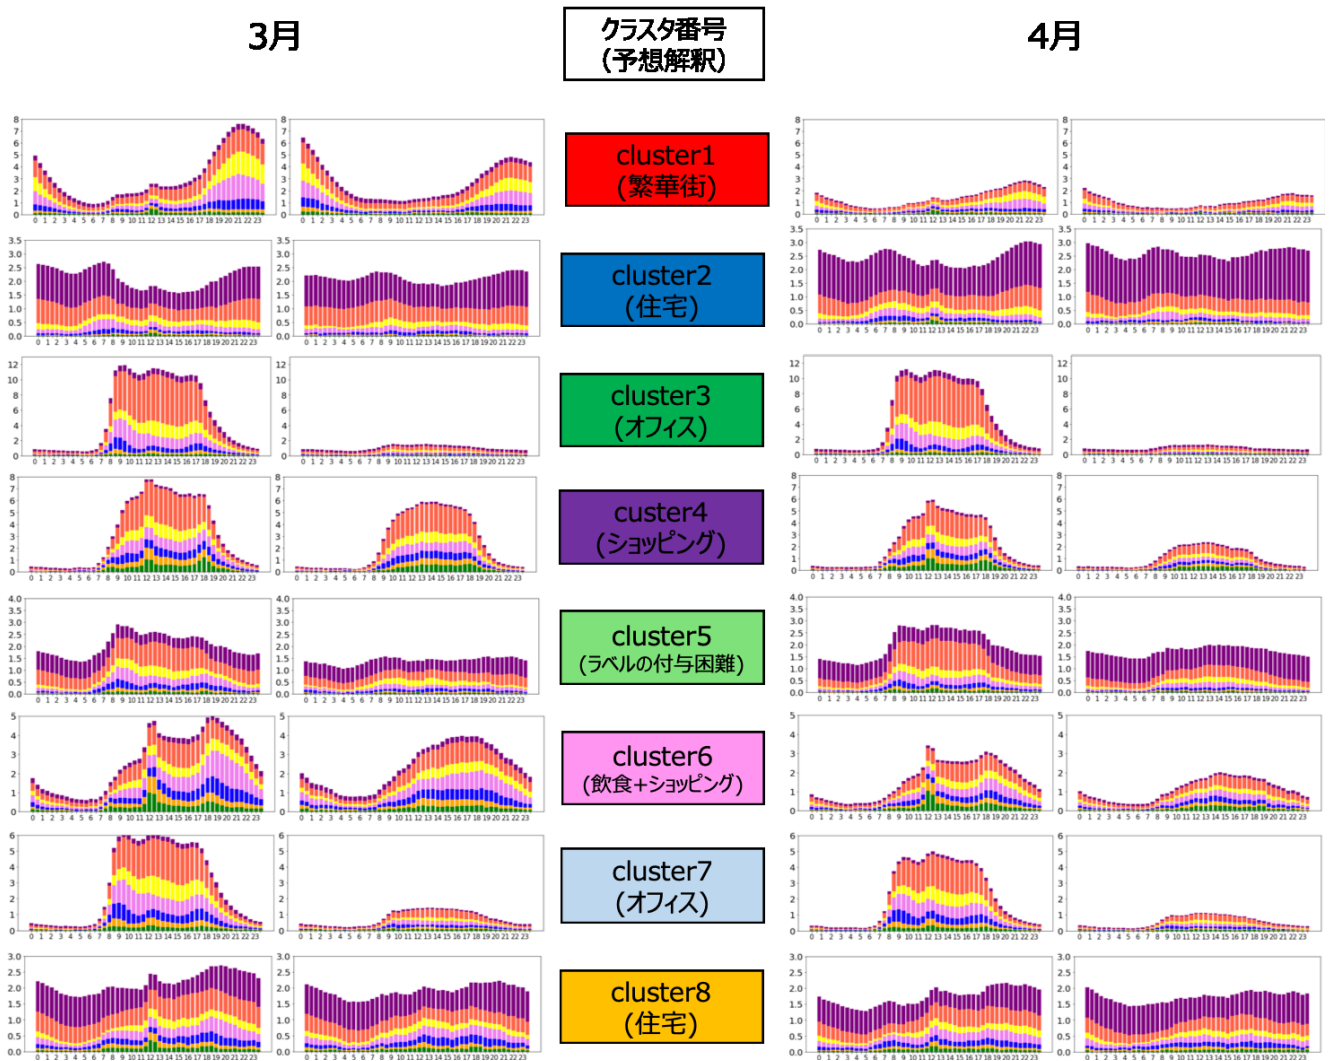
4.3.1 国分町

4.2 節と同様に、対象エリアのメッシュ化 → UAS の作成 → クラスタリングという流れの処理を行っていく、各

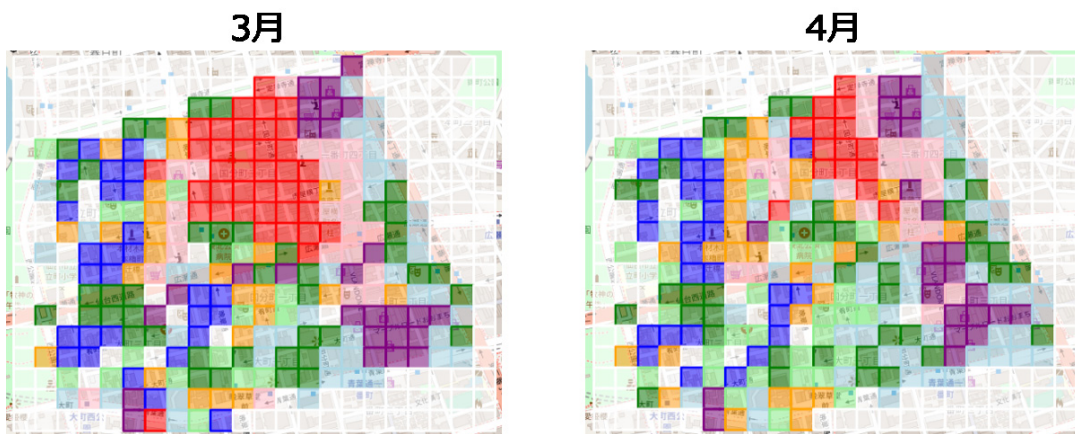
クラスタの特徴を積層グラフに反映させたものが図 6(a) である。本節では、まず初めに 3 月と 4 月の比較を行う。4.2 節とは異なり細かい人々の行動の変化をとらえるためにクラスタ数は 8 に設定した。クラスタリング結果を色分けし、地図上にマッピングしたものが図 6(b) となる。

これらの図から分かる人々の行動の変化は次のとおりである。積層グラフ (図 6(a)) から分かることとして、まず初めに cluster4 (ショッピングエリア) に関して、休日の人の数が大きく減少している。このことから、休日の不要不急の外出は自粛されていたことが分かる。また、cluster1 (繁華街) と cluster6 (飲食店+ショッピングエリア) については、全体的に大きく人数が減少していることから、こちらも同様に人々は外出の自粛が余儀なくされていることが読み取れる。次に cluster7 (オフィスエリア) に関しても、人数が減少している。このことから、仕事に来る人が減少したことが分かる。もしかしたら、リモートワークをする人が増えたといえる可能性もある。最後に cluster2 (住宅エリア) に関して、他のクラスタとは異なり人数が増加している。つまり、外出自粛の要求を受け、家にいることが多くなった結果だと考えられる。

次にクラスタリング結果が反映された地図 (図 6(b)) を用い分析を行っていく。赤色のエリア (cluster4、繁華街) が大きく減少していることが分かる。つまり、不要不急の外出自粛の要請を受け、夜に繁華街に遊びに来る人が減ったことを意味する。次のステップとして、3 月で繁華街だった場所は 4 月ではどのような使われ方をしているか、ということを見ていく。マップを見るとそれが推測できる。まず、繁華街の西と南を見ると水色 (cluster7、オフィスエ



(a) 3月と4月の各クラスターに割り当てているエリアの使われ方を示した積層グラフ



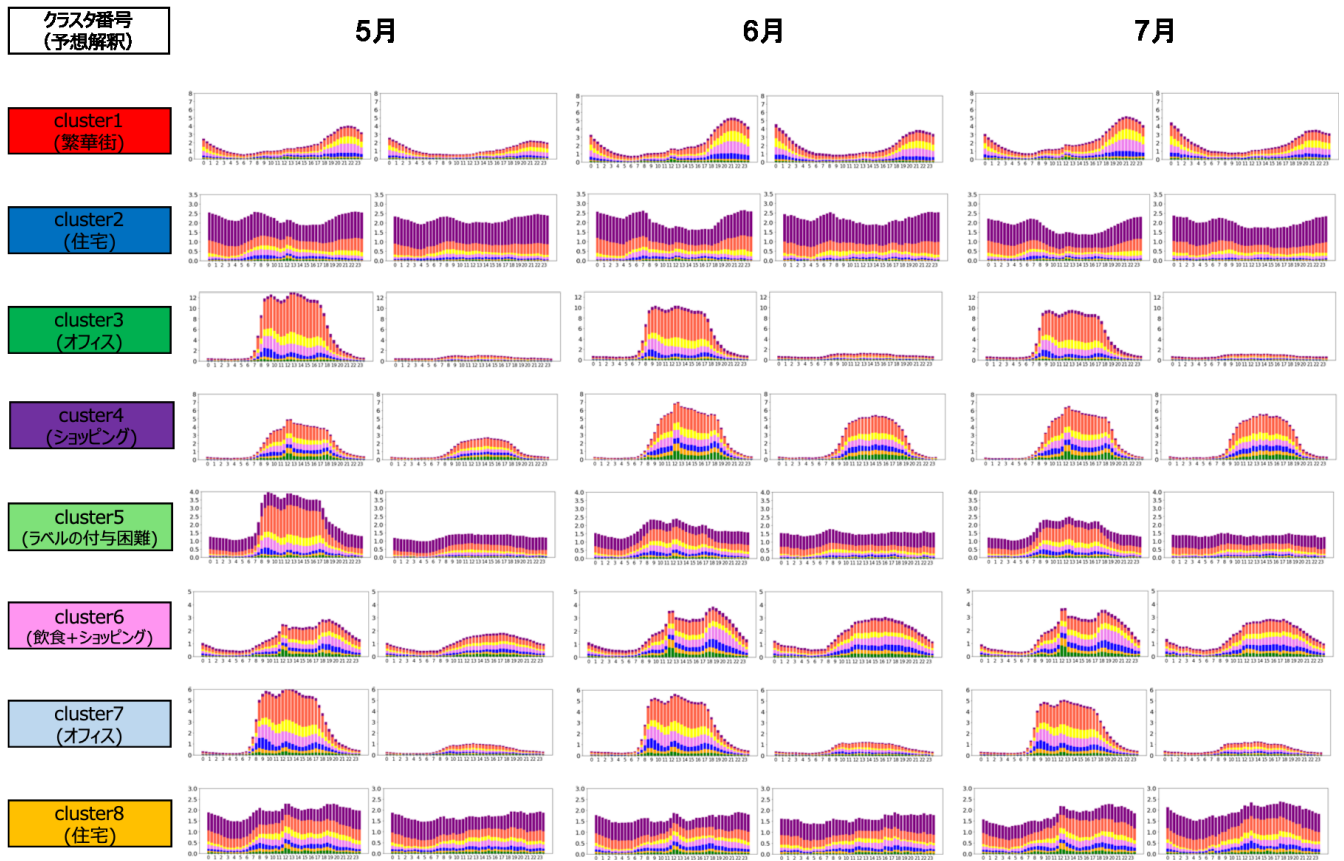
(b) 3月と4月のエリアの分散表現をクラスター毎に色分けした結果を描画したマップ

図 6 国分町の3月から4月にかけての COVID-19 の影響によるエリアの使われ方の変化

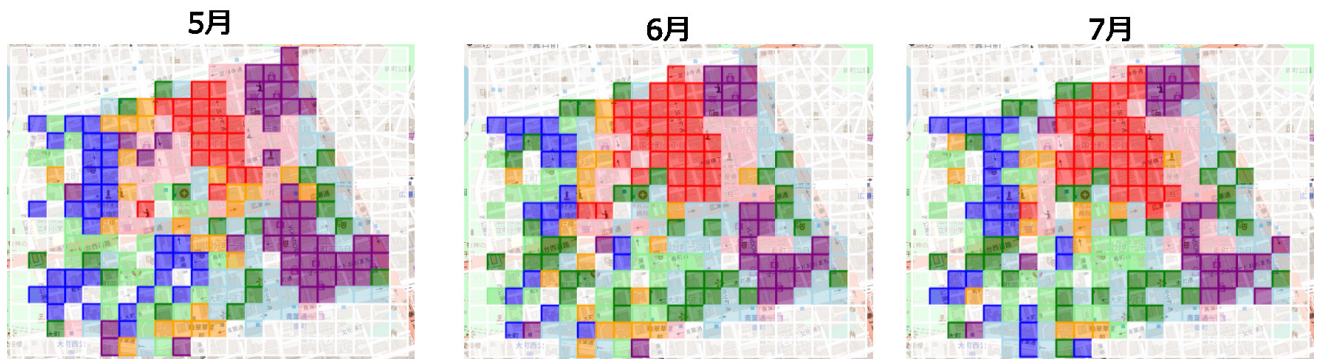
Fig. 6 The changes in area usage due to the influence of COVID-19 from March to April in Kokubuncho.

リア)と橙色 (*cluster8*, 住宅エリア)などに置き換わっていることが分かる。このことから、このエリアは繁華街に遊びに来た人ではなく、そこにあるオフィスで働く人やそ

こに住む人が多数派になり、UASにはオフィスで働く人やそこに住む人の行動特徴が色濃く反映されたと推察できる。次に、繁華街の東側を見ると桃色のエリア (*cluster6*,



(a) 5～7月の各クラスターに割り当てているエリアの使われ方を示した積層グラフ



(b) 5～7月のエリアの分散表現をクラスター毎に色分けした結果を描画したマップ

図 7 国分町における 5 月から 7 月にかけての COVID-19 の影響によるエリアの使われ方の変化

Fig. 7 The changes in area usage due to the influence of COVID-19 from May to July in Kokubuncho.

飲食店+ショッピングエリア)に置き換わっていることが分かる。つまり、このエリアに来る人の行動が夜型から昼型へシフトしたと推察できる。

図 7 には、さらに 5 月から 7 月までの各月のデータから作成した積層グラフ (図 7(a)) とクラスタリング結果が反映された地図 (図 7(b)) を示しておいた。図 7(a) の縦軸の値を見ると、繁華街やショッピングエリアへの人の流入量は徐々に回復しているが、COVID-19 の影響を受ける前に戻るにはもう少し時間がかかることが予想できる。しかし、図 7(b) を見ると、エリアの使われ方は元に戻って

ることが分かる。つまり、積層グラフの縦軸の値とクラスタリング結果が反映された地図は、外出自粛をまだ行っている人がいることを示しているが、逆に元の生活に戻った人がいることも同時に示している。

しかし、これまで述べてきた人々の行動の変化は、季節的なものの可能性が否定できない。そのため、次は他の地域で 2019 年 4 月と 2020 年 4 月の同じ季節のデータと比較してみることで、COVID-19 の影響がどれだけあるのかを調査していく。

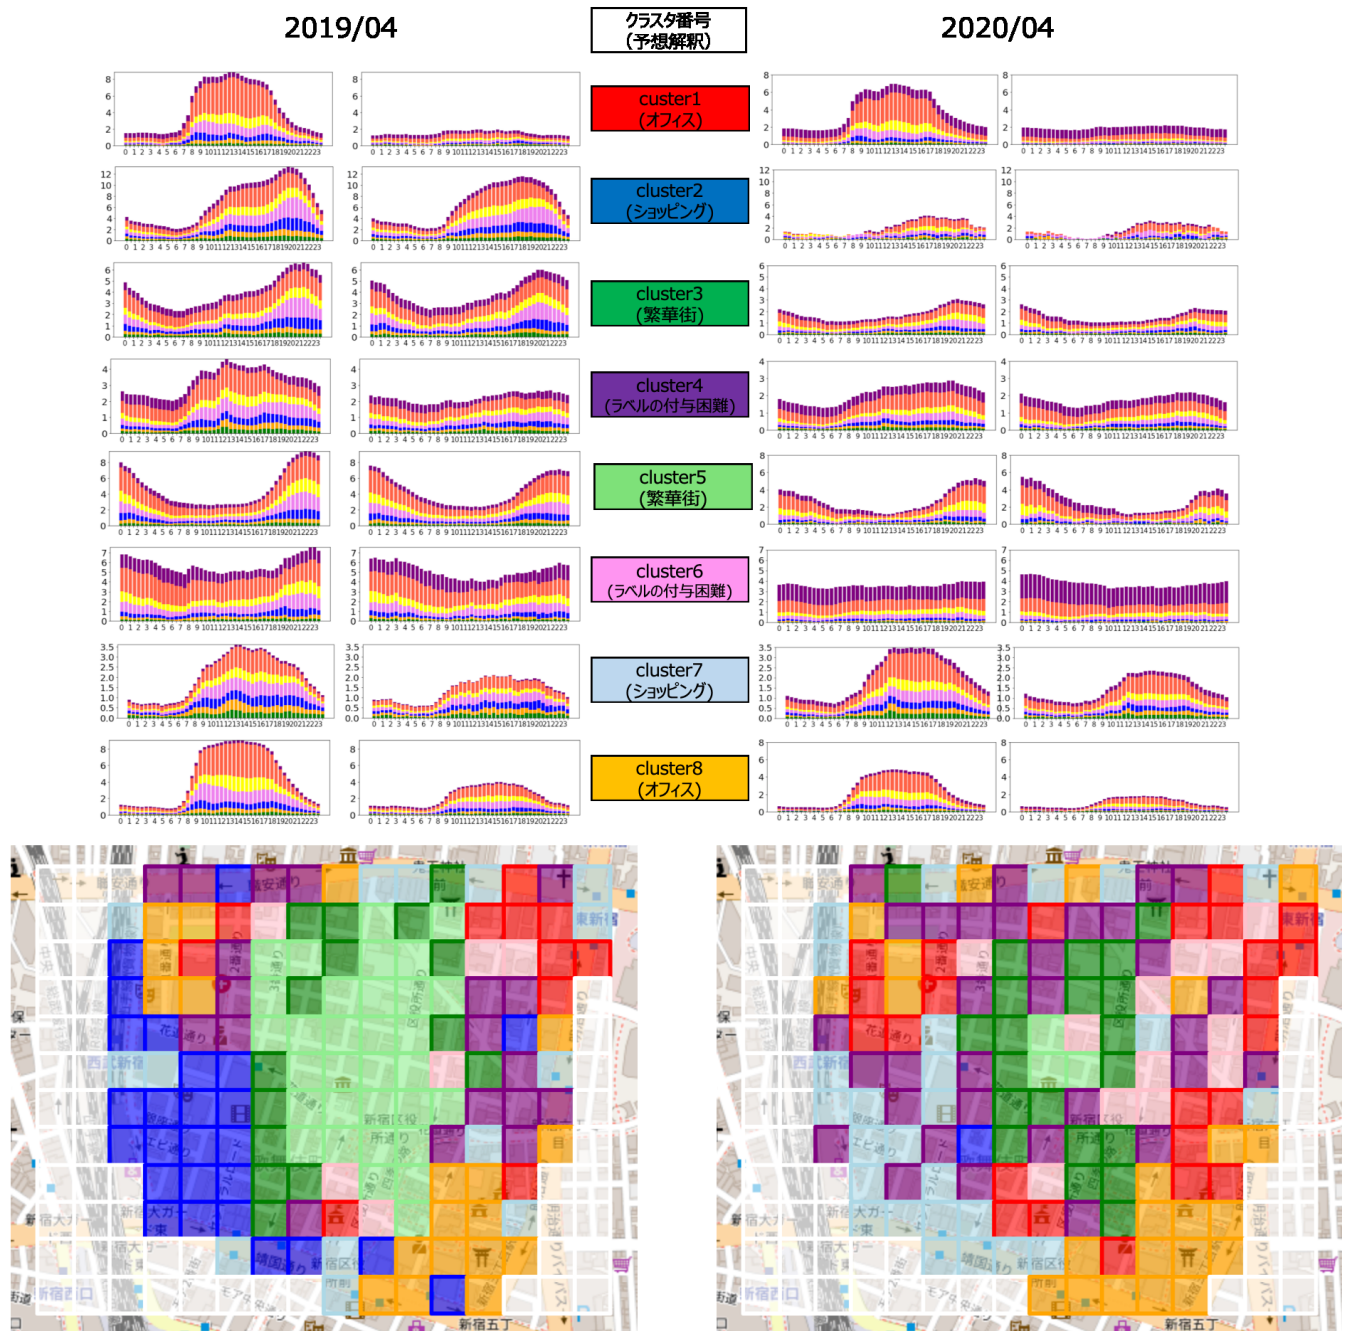


図 8 歌舞伎町における COVID-19 の影響によるエリアの使われ方の変化

Fig. 8 The changes in area usage due to the influence of COVID-19 in Kabukicho.

4.3.2 歌舞伎町

歌舞伎町の 2019 年 4 月と 2020 年 4 月について、それぞれの結果を積層グラフと地図上に図示したものを図 8 に示す。クラスター数は 4.3.1 項と同様に 8 に設定した。これらの図から分かる人の行動の変化は次のとおりである。積層グラフから分かることとして、まず初めに、720 分以上の滞在（積層グラフの紫色の層）が全体的に目立つようになっている。これが意味することは、そこを利用する人々の滞に関して、短・中時間の滞を行う人より、長時間の滞を行う人の割合が増えたということである。いい換えると、そこを利用する客（短時間の滞在）が減少し、従

業員（長時間の滞在）の行動が多数派を占めるようになったといえる。もう 1 つ分かることは、どのクラスターを見ても人数が減少しているということである。これが意味することは、歌舞伎町の人々の流入量が全体的に減少したということである。2019 年と 2020 年では、データ量がまったく異なるため、そこから人の流入量がどのように変化したか予想可能だが、提案手法では図を見ることで直感的な分析が可能になる。

次にクラスタリング結果が反映された地図から分かることとして、緑色と黄緑色（cluster3 と cluster5、両方とも繁華街）が減少し、紫色（cluster4、ラベルの付与困難）に

変化している。これが意味することは、ほとんど夜中に利用されていた場所だったが、昼間に利用する人々の行動が反映されるくらいまで夜中の利用が減ったということである。桃色 (*cluster6*, ラベルの付与困難) に変化している部分も存在するが、これはそこに住む人や店舗の経営者など、そこに長時間滞在している人たちの特徴が客の行動特徴より大きく反映されたと考えられる。また、各施設に焦点を当てると、「東宝ビル (映画館) (地図上の A)」は、青色 (*cluster2*, ショッピングエリア) から水色 (*cluster7*, ショッピングエリア) に変化していることが分かる。つまり、メインの利用時間帯が夕方にあったが、それが昼間にシフトしたことが読み取れる。また「区役所 (地図上の B)」に関しては、変化せず、赤色 (*cluster1*, オフィスエリア) のままである。つまり、区役所は COVID-19 の渦中でも、仕事を止めることができないために働き続けていることが分かる。

本節では歌舞伎町の 2019 年 4 月と 2020 年 4 月の違いを見てきたが、同じ時期にもかかわらず、人々の行動は大きく変化していることが分かる。すなわち、これは COVID-19 の影響が大きく関係していると推察できる。4.3.1 項では、国分町の数カ月にわたる人々の行動の変化を見たが、それが季節的な影響だけでなく、COVID-19 の影響も大きく受けていたといえる。

本章では、本論文で提案したエリアモデリング手法を使って、COVID-19 の影響による人々の行動の変化を 2 つの都市 (国分町と歌舞伎町) を例にあげて見てきた。全体を通して提案手法を用いることで判明したことは次のことがあげられる。まず、COVID-19 の影響を受け、人の流入量が大きく減少したことがあげられる。さらに、人々の行動は全体的に昼間にシフトしたことが分かった。つまり、COVID-19 の中で、夜に繁華街に行くといった不要不急の外出を、人々は自粛していると推察できる。しかし、月日が経つと、人の流入量が回復しきれていないという事実から自粛をまだ続けている人がいることが伺える一方で、ある一定数は元の生活スタイルに戻りつつあるという事実が判明し、個々人の COVID-19 への危機感に乖離があることが判明した。

5. まとめ

本論文では、滞在の観点から見たエリアの使われ方を基に、エリアを特徴付けるための手法を提案した。これは Word2Vec のアルゴリズムを参考にしたもので、エリアの分散表現を作成する。学習には「曜日」、「到着時刻」、「滞在時間」の 3 つの滞在に関する時間情報を用いた。その結果、滞在情報からエリアの特徴付けが可能になり、POI データの収集の手間とコストが削減できるだけでなく、時間経過にともなう事象 (都市の発展、季節の変化、パンデミックの発生) の影響にも対応したエリアモデリングとなる。提

案手法を用いることで、図と数値から直感的にエリアの使われ方とその時間経過による変化の把握が容易になり、都市計画やマーケティングなどの分野での位置情報データのさらなる利活用が広がると期待している。

提案手法の評価実験では、エリアの使われ方の特徴抽出と COVID-19 の影響によるエリアの使われ方の変化の調査を行った。前者については、宮城県仙台市の国分町を対象に行った。国分町は大雑把に 4 つの機能区分 (ショッピングエリア, オフィスエリア, 住宅エリア, 繁華街) に分割できることが分かっているが、提案手法を用いることで、これらを視覚的に認識可能になることが示された。後者については、国分町に加え、東京都新宿区の歌舞伎町を対象に行った。国分町では人の流入量が減少していることや、それにともない訪問者よりそこで働く従業員が多数派を占め、彼らの行動が反映されたエリアの分散表現が得られたこと、さらに人々の行動が夜から昼にシフトしたことが、図と数値から直感的に見て取れた。そして、月を追うごとに元の生活に戻っていく様子もとらえることができた。これは、自粛疲れや危機感の薄れからくるものだと考えられる。歌舞伎町でも同様に人の流入量の減少や活動時間軸の昼間へのシフトなどが見て取れた。

今後の取り組みとしては、次の 2 つがあげられる。1 つ目は、移動の前後関係を考慮したエリアの特徴付けを行うことである。人々の行動にはある程度の規則性 (朝は「家」から「オフィス」に移動し、夕方は逆に「オフィス」から「家」に移動) があり、これはエリアを特徴付ける際、有効な情報だが提案手法ではこれが考慮できていない。これが考慮できれば、さらに詳細なエリアモデリング手法になると期待できる。2 つ目は、本論文で提案したエリアモデリングで得られた結果を、移動遷移として表現し、個々のユーザに焦点を当てたユーザモデリングまで拡張することがあげられる。提案手法を用いれば、従来使われていた POI ラベルや滞在目的に代わり、訪問場所はベクトルで表現できる。つまり、ユーザの移動遷移がベクトル遷移となるため、プライバシーを考慮した分析が可能になるため、第三者も扱える形になり、パーソナルデータのさらなる利活用につながると考えられる。

謝辞 本研究の一部は、JST CREST (JPMJCR1882)、総務省 SCOPE、NICT 委託研究 (222C0101) により支援していただいております。また、データ提供にご協力いただきましたプログウォッチャー社に感謝します。

参考文献

- [1] Yuan, J., Zheng, Y. and Xie, X.: Discovering Regions of Different Functions in a City Using Human Mobility and POIs, *Proc. 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD'12*, Association for Computing Machinery, pp.186–194 (online), DOI: 10.1145/2339530.2339561 (2012).

- [2] Zhai, W., Bai, X., Shi, Y., Han, Y., Peng, Z.-R. and Gu, C.: Beyond Word2vec: An approach for urban functional region extraction and identification by combining Place2vec and POIs, *Computers, Environment and Urban Systems*, Vol.74, pp.1–12 (online), DOI: <https://doi.org/10.1016/j.compenvurbsys.2018.11.008> (2019).
- [3] Yao, Y., Li, X., Liu, X., Liu, P., Zhaotang, L., Zhang, J. and Mai, K.: Sensing spatial distribution of urban land use by integrating points-of-interest and Google Word2Vec model, *International Journal of Geographical Information Science*, Vol.31, pp.1–24 (online), DOI: [10.1080/13658816.2016.1244608](https://doi.org/10.1080/13658816.2016.1244608) (2016).
- [4] Pan, G., Qi, G., Wu, Z., Zhang, D. and Li, S.: Land-Use Classification Using Taxi GPS Traces, *IEEE Trans. Intelligent Transportation Systems*, Vol.14, No.1, pp.113–123 (online), DOI: [10.1109/TITS.2012.2209201](https://doi.org/10.1109/TITS.2012.2209201) (2013).
- [5] Yao, Z., Fu, Y., Liu, B., Hu, W. and Xiong, H.: Representing Urban Functions through Zone Embedding with Human Mobility Patterns, *Proc. 27th International Joint Conference on Artificial Intelligence, IJCAI-18*, International Joint Conferences on Artificial Intelligence Organization, pp.3919–3925 (online), DOI: [10.24963/ijcai.2018/545](https://doi.org/10.24963/ijcai.2018/545) (2018).
- [6] Crivellari, A. and Beinat, E.: From Motion Activity to Geo-Embeddings: Generating and Exploring Vector Representations of Locations, Traces and Visitors through Large-Scale Mobility Data, *ISPRS Int. J. Geo Inf.*, Vol.8, p.134 (2019).
- [7] Mikolov, T., Sutskever, I., Chen, K., Corrado, G.S. and Dean, J.: Distributed representations of words and phrases and their compositionality, *Advances in Neural Information Processing Systems*, pp.3111–3119 (2013).
- [8] Toch, E., Lerner, B., Zion, E.B. and Ben-Gal, I.: Analyzing large-scale human mobility data: A survey of machine learning methods and applications, *Knowledge and Information Systems*, Vol.58, pp.501–523 (2018).
- [9] Zhou, Y., Lau, B.P.L., Yuen, C., Tuncer, B. and Wilhelm, E.: Understanding Urban Human Mobility through Crowdsensed Data, *IEEE Communications Magazine*, Vol.56, No.11, pp.52–59 (online), DOI: [10.1109/MCOM.2018.1700569](https://doi.org/10.1109/MCOM.2018.1700569) (2018).
- [10] Wang, J., Kong, X., Xia, F. and Sun, L.: Urban Human Mobility: Data-Driven Modeling and Prediction, *ACM SIGKDD Explorations Newsletter*, Vol.21, pp.1–19 (online), DOI: [10.1145/3331651.3331653](https://doi.org/10.1145/3331651.3331653) (2019).
- [11] Becker, R., Cáceres, R., Hanson, K., Isaacman, S., Loh, J.M., Martonosi, M., Rowland, J., Urbanek, S., Varshavsky, A. and Volinsky, C.: Human Mobility Characterization from Cellular Network Data, *Comm. ACM*, Vol.56, No.1, p.74–82 (online), DOI: [10.1145/2398356.2398375](https://doi.org/10.1145/2398356.2398375) (2013).
- [12] Esuli, A., Petry, L.M., Renso, C. and Bogorny, V.: Traj2User: exploiting embeddings for computing similarity of users mobile behavior, *ArXiv*, Vol.abs/1808.00554 (2018).
- [13] Xiao, X., Zheng, Y., Luo, Q. and Xie, X.: Finding similar users using category-based location history, pp.442–445 (online), DOI: [10.1145/1869790.1869857](https://doi.org/10.1145/1869790.1869857) (2010).
- [14] Zion, E.B. and Lerner, B.: Identifying and predicting social lifestyles in people’s trajectories by neural networks, *EPJ Data Science*, Vol.7, pp.1–27 (2018).
- [15] Feng, S., Cong, G., An, B. and Chee, Y.M.: POI2Vec: Geographical Latent Representation for Predicting Future Visitors, *AAAI* (2017).
- [16] Shimosaka, M., Maeda, K., Tsukiji, T. and Tsubouchi, K.: Forecasting Urban Dynamics with Mobility Logs by Bilinear Poisson Regression, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp ’15*, Association for Computing Machinery, p.535–546 (online), DOI: [10.1145/2750858.2807527](https://doi.org/10.1145/2750858.2807527) (2015).
- [17] Li, H., Ge, Y., Hong, R. and Zhu, H.: Point-of-Interest Recommendations: Learning Potential Check-Ins from Friends, *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD ’16*, Association for Computing Machinery, pp.975–984 (online), DOI: [10.1145/2939672.2939767](https://doi.org/10.1145/2939672.2939767) (2016).
- [18] Zhang, H., Zheng, Y. and Yu, Y.: Detecting Urban Anomalies Using Multiple Spatio-Temporal Data Sources, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol.2, No.1 (online), DOI: [10.1145/3191786](https://doi.org/10.1145/3191786) (2018).
- [19] Yan, B., Janowicz, K., Mai, G. and Gao, S.: From ITDL to Place2Vec: Reasoning About Place Type Similarity and Relatedness by Learning Embeddings From Augmented Spatial Contexts, *Proc. 25th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, SIGSPATIAL ’17*, Association for Computing Machinery, (online), DOI: [10.1145/3139958.3140054](https://doi.org/10.1145/3139958.3140054) (2017).
- [20] GoogleDevelopers: Blog of our latest news, updates, and stories for developers (2017), available from (<https://developers.googleblog.com/2017/11/introducing-tensorflow-feature-columns.html>).
- [21] 岩田紗瑛, 新田知之, 高山敏典, 柳澤政生, 戸川 望: 疎な GPS 測位情報を対象にした測位精度と短時間滞在除去に基づく滞在地推定手法, マルチメディア, 分散協調とモバイルシンポジウム 2017 論文集, Vol.2017, pp.523–531 (2017).



庄子 和之

2019年名古屋大学工学部電気電子・情報工学科卒業を経て、同大学大学院博士前期課程学生。



青木 俊介

2020年カーネギーメロン大学計算機工学科 (Electrical & Computer Engineering) Ph.D. 取得。船井情報科学振興財団奨励学生。2020年11月より名古屋大学未来社会創造機構特任助教。自動運転システム, サイバーフィジカル

システムに関する研究に従事。



米澤 拓郎 (正会員)

2010年慶應義塾大学大学院政策・メディア研究科後期課程博士号取得後、同大学院特任助教、特任講師、特任准教授を経て、2019年より名古屋大学大学院工学研究科准教授。主に、ユビキタスコンピューティングシステム、ヒューマンコンピュータインタラクション、センサネットワーク等の研究に従事。ACM 会員。



河口 信夫 (正会員)

1990年名古屋大学工学部電気電子工学科卒業。1995年同大学大学院工学研究科情報工学専攻博士課程満了。同年同大学工学部助手、同大学講師、准教授を経て、2009年より同大学大学院工学研究科教授。NPO 位置推定サービス研究機構 Lisra 代表理事。モバイルコミュニケーション、ユビキタスコンピューティング、行動センシングの研究に従事。博士(工学)。ACM, IEEE, 人工知能学会, 日本ソフトウェア科学会, 電子情報通信学会, 日本音響学会各会員。本会シニア会員。