口頭発表

2025年11月1日(土) 14:20 ~ 15:40 | E会場(共通教育棟 A23番教室)

[E3] 移動・交通２

司会：大山 智也

14:20 ~ 14:40

[E3-01] 携帯電話位置情報データを用いた滞留施設・滞留目的の推定手法

*大村 碧[1]、大佛 俊泰[1]、岸本 まき[1]、荻野 光司[1] (1. 東京科学大学)

14:40 ~ 15:00

[E3-02] 移動履歴データから順伝播型ニューラルネットワークで抽出した地域のベクトル表現の意味解釈―ロジットモデルとの対応関係を通した検討―

*白勢 拓[1]、井上 亮[1] (1. 東北大学 大学院情報科学研究科)

15:00 ~ 15:20

[E3-03] エージェントワークフローを活用した大規模言語モデルによる擬似人流データの生成と精度向上

*瀬貫 雄介[1]、龐 岩博[1]、関本 義秀[1] (1. 東京大学 空間情報科学研究センター)

15:20 ~ 15:40

[E3-04] パーソントリップデータを用いた通院行動負担の空間分析

*吾妻 勇太[1]、山本 佳世子[1] (1. 電気通信大学大学院情報理工学研究科)

©一般社団法人地理情報システム学会

携帯電話位置情報データを用いた滞留施設・滞留目的の推定手法

大村碧[*1]・大佛俊泰[*2]・岸本まき[*2]・荻野光司[*3]

Estimating Stay Facilities and Purposes from Mobile Phone Location Data

Aoi OMURA[*1], Toshihiro OSARAGI[*2], Maki KISHIMOTO[*2], Koji OGINO[*3]

Abstract: Mobile phone location data can be collected over wide areas at high temporal resolution. However, such data primarily capture movement trajectories, while stay locations and activity purposes remain unknown. In this study, we first extract stay locations for each person from mobile phone location data and link each location to building-use information. We then develop a stay-purpose model using person-trip survey data with known purpose labels. The model achieves high performance for Work and School: recall and precision are above 80%. Key predictive factors include arrival time, age, and building usage. We apply the model to mobile phone location data to infer stay purposes. Our results show that even within the same building-use (e.g., hospitals), the stay locations with shorter dwell-times are typically classified as Clinic visits, whereas those with longer dwell-times are classified as Work. In other words, the model enables assigning different purposes to stay at the same type of facility.

Keywords: 携帯電話位置情報データ（mobile phone location data），滞留場所(stay locations)，滞留目的（stay purpose），パーソントリップ調査（person trip survey），ロジスティック回帰（logistic regression）

1. はじめに

近年，情報通信技術の普及と発展により，携帯電話位置情報ポイント型データ（移動軌跡データ）を用いて人々の移動や滞留を推定し，都市計画分野に応用する研究が多く行われている．例えば，小沢・田中（2023）は，移動軌跡データから滞留情報（滞留場所と滞留目的を含む情報）を抽出し，地域単位での集計量について分析している．しかし，ミクロな空間単位で個人の移動軌跡を分析する研究は少ない．

移動軌跡データは，広域におけるユーザの移動を把握できるものの，移動軌跡の取得頻度に粗密があり，位置座標の精度も不安定である．また，取得されたデータは単なる移動軌跡であり，ユーザの行動を解釈する上で必要な滞留施設や滞留目的などに関する情報を直接得ることは難しい．そこで，本研究では，移動軌跡データに滞留施設と滞留目的を付与する手法を提案する．

2. 滞留施設の推定方法

2.1 滞留地点の推定方法

本節では，移動軌跡データから滞留地点を抽出する方法を提案する．移動軌跡データは，ユーザに移動が見られない場合，再び動き出すまでデータ取得が一時停止されるという特徴を有する．そのため，実際には長時間滞留していても，取得点が少ない場合が多い．この特性により，ポイント密度に基づいてポイント群を抽出する手法である DBSCAN などを適用することは難しい（藤田ほか, 2012）．そのため，本稿では，以下のいずれかの条件 1，条件 2 に当てはまるものを滞留と判定する．

条件 1：複数のポイントが同一地域に一定時間以上集まっている状態を滞留と判定する．そのために，まず前時点のポイントからの乖離距離が 100m 以下であれば同一ポイント群に属するとみなす．そして，そのポイント群の合計滞留時間が閾値 τ を超える場合，滞留と判定し（図 1 (a) ①），そのポイント群を「滞留クラスタ」とする．

条件 2：データ取得が一時停止されるという特性により，条件 1 に該当しない単独のポイントであっても長時

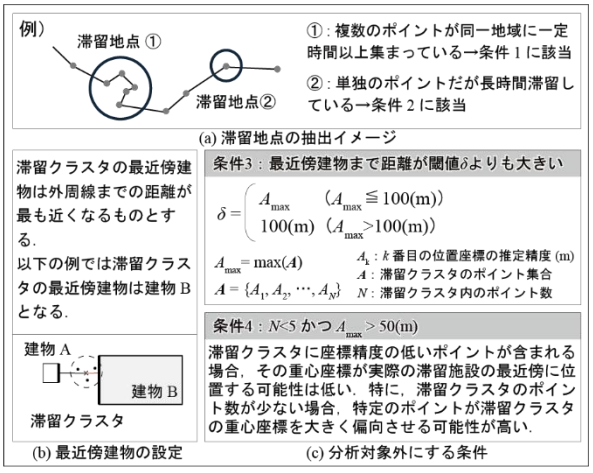


図 1 滞留場所の抽出条件

*1 学生会員 東京科学大学環境・社会理工学院（Institute of Science Tokyo）
〒152-8550 東京都目黒区大岡山 2-12-1 E-mail: omura.a.2b84@m.isct.ac.jp
*2 正会員 東京科学大学環境・社会理工学院（Institute of Science Tokyo）
*3 学生会員 東京科学大学環境・社会理工学院（Institute of Science Tokyo）

間滞留している場合がある．そこで，当該ポイントから次のポイントまでの取得間隔が閾値 τ を超え，かつユーザの移動速度 s_k が一定以下である場合，そのポイントを滞留と判定する（図 1 (a) ②）．

2.2 滞留施設の推定

周辺の建物との位置関係に基づき滞留施設を同定する方法を図 1(b)(c)に示してある．まず，滞留クラスタの重心座標の最近接の位置にある建物を特定し，滞留施設とする（図 1(b)）．この時，位置座標の精度を考慮し，条件 3，条件 4 のいずれかに該当する場合には，滞留施設の特定は困難（分析対象外）であるとみなす（図 1(c)）．

3. 滞留目的の推定方法

3.1 滞留目的推定モデルの位置付け

移動軌跡データから一定の条件を満たす滞留クラスタを抽出することで，滞留施設や到着時間・滞在時間などを推定することができる．しかし，それらの情報のみでは，滞留施設における滞留目的を推定することはできない．そこで，個人単位の滞留施設・滞留時間・滞留目的が記録された都市交通調査を用いて滞留目的推定モデルを構築し，これに移動軌跡データから得られる情報を外挿することで．滞留施設における滞留目的を付与することとする．

3.2 滞留目的推定モデルの構築

滞留目的は，来訪時刻や滞在時間といった時間的要因，年齢や性別などの個人属性，および滞在施設の用途といった場所的要因が複合的に関係していると考えられる．これら複数の要因を同時に考慮して滞留目的を確率的に推定するために，本稿では多クラスロジスティック回帰モデルを採用する．

多クラスロジスティック回帰は，一般に目的変数が複数のカテゴリをとる場合に適用され，説明変数との関係は線形和で表現される(図 2)．単純なモデル構造のため，各説明変数が滞留目的の判別にどの程度寄与しているかを推定パラメータから解釈できる点に特徴がある．この他に，ランダムフォレストやニューラルネットワークなどの手法も存在するが，パラメータ数が多くモデルが複雑でブラックボックス化しやすい．本稿では滞留目的を同定することと同時に，その同定要因を明らかにするため，解釈可能性の高いロジスティック回帰が適していると判断した．

目的変数と説明変数の概要を図 3 に示してある．モデル構築にあたり，滞留目的は，都市交通調査で採用される代表的な 7 区分に設定した．なお，施設内における滞留目的の把握を目的とするため，屋外での滞留は分析対象外とした．説明変数には，滞留時間割合や到着時刻分布といった連続的特徴量に加え，建物用途を表すダミー変数を用いた．多重共線性を回避するため，建物用途の一部を基準カテゴリとして除外した．

複数のクラス $k = 1,2,...,K$（各クラスの説明変数の数は d 個）に対して説明変数 ${}_j r_k^t = ({}_1 r_k^t, {}_2 r_k^t, ..., {}_d r_k^t)$ を用いて各クラスの確率を計算する．各クラス k に対して係数（重み）$\beta_{kj} = (\beta_{k1}, \beta_{k2}, ..., \beta_{kd})$ を持ち，クラスのスコア z_k を求め，これらのスコアを右のSoftmax関数に通して確率に変換する．求めた確率を用いてランダムに滞留目的を推定する．

$$z_k = \sum_{j=1}^{d} \beta_{kj} \, {}_j r_k^t + b_k \quad \cdots式 (1) \qquad p_k(x_i) = \frac{\exp(z_k)}{\sum_{l=1}^{K} \exp(z_l)} \quad \cdots式 (2)$$

z_k : 滞留目的 k のスコア　　β_{kj} : 滞留目的 k における説明変数 j ごとの係数（重み）
${}_j r_k^t$: 属性区分(時刻、性別年齢、トリップ番号、建物用途) t、滞留目的kにおける説明変数 j の値
d : 説明変数の総数　　b_k : 誤差項　　$p_k(x_i)$: データ i の滞留目的が k である確率
K : 滞留目的の総数

滞留目的ごとのデータ数の偏りを考慮するため，滞留目的ごとの補正係数 w_k を求める．

$$w_k = \frac{1}{\sqrt{n_k}} \quad \cdots式 (3)$$

k :移動目的
w_k :移動目的 k の補正係数
n_k : 移動目的 k のデータ数

最尤推定を目的として以下の $\overline{L(\boldsymbol{\beta_k})}'$ を最大化するパラメータ $\boldsymbol{\beta_k}$ を求める．

$$\overline{L(\boldsymbol{\beta_k})} = \frac{\sum_{i=1}^{N} w_k \log p_k(x_i)}{N} \quad \cdots式 (4) \qquad \overline{L(\boldsymbol{\beta_k})}' = \overline{L(\boldsymbol{\beta_k})} - \lambda \sum_{k,j} |\beta_{kj}| \quad \cdots式 (5)$$

k :移動目的　　$p_k(x_i)$: データ i の滞留目的が k である確率
λ :正則化強度（$\lambda > 0$）　　$\boldsymbol{\beta_k}$: 滞留目的 k の重みベクトル
N : データ数　　β_{kj} : 滞留目的 k に対応する説明変数 j の係数（重み）
w_k :移動目的 k の補正係数

具体的には確率的勾配上昇法でパラメータベクトル $\boldsymbol{\beta_k}$ を更新し，正解のクラスがなるべく高い確率になるようにパラメータを調整する．

$\beta_{kj} > 0$ のとき　$\boldsymbol{\beta_k} \leftarrow \boldsymbol{\beta_k} + \eta \left(\sum_{i=1}^{N} w_k \left[\mathrm{I}(y_i = \mathrm{k}) - p_k(x_i) \right] x_{ij} - \lambda \right)$ …式 (6)

$\beta_{kj} = 0$ のとき　$\boldsymbol{\beta_k} \leftarrow \boldsymbol{\beta_k} + \eta \left(\sum_{i=1}^{N} w_k \left[\mathrm{I}(y_i = \mathrm{k}) - p_k(x_i) \right] x_{ij} \right)$ …式 (7)

$\boldsymbol{\beta_k}$:滞留目的 k の重みベクトル　　x_{ij} : データ i の説明変数 j の値
β_{kj} : 滞留目的kに対応する説明変数 j の係数(重み)　y_i : データiの正解クラス
η : 学習率(一回の更新でどれだけ変化させるか)　$\mathrm{I}(y_i = k)$: データ i の正解クラス k なら1、違えば0
i : 各データ(全部で N 個)　　$p_k(x_i)$: データiをクラス k と予測した確率
w_k :移動目的 k の補正係数　　λ :正則化強度（$\lambda > 0$）

図 2 滞留目的の推定方法

	概要
目的変数	勤務，通学，買物等へ（買物/食事/社交），通院，送迎，帰宅，その他
説明変数 (特徴量)※	滞留時間割合，移動時間割合，到着時間割合，性別/年齢割合，トリップ順序割合
説明変数 (ダミー変数(建物用途))	住宅，文教厚生施設(公共施設，病院等)，商業系施設，工業系施設，宿泊施設，事務所系

※説明変数(特徴量)の定義と算出方法の例

＜説明変数の定義＞

滞留時間割合(${}_j r_k^t$) : 移動目的 k ごとの総数に占める特定の滞留時間 t (30分毎)のデータ数の割合
移動時間割合(${}_j r_k^t$) : 〃　特定の移動時間 t (30分毎)のデータ数の割合
到着時間割合(${}_j r_k^t$) : 〃　特定の到着時間 t (30分毎)のデータ数の割合
性別/年齢割合(${}_j r_k^t$) : 〃　特定の年齢性別 t (10歳毎)のデータ数の割合
トリップ順序割合(${}_j r_k^t$) : 〃　特定のトリップ番号 t※※のデータ数の割合
※※1日のうち1番最初のトリップ（ある地点からある地点への移動）を1、その次のトリップを2,...,1日の最後のトリップを n とする

＜算出方法例＞

滞留目的 k ,滞在時間 t におけるデータ数を ${}_t N_k^t$ とする．
滞留目的ごとの割合 ${}_t r_k^t$ は，右の式で求める．
他の説明変数も同様の方法で滞留目的ごとの割合を算出する．

$${}_t r_k^t = \frac{{}_t N_k^t}{\sum_t {}_t N_k^t}$$

図 3 目的変数と説明変数の概要

4. 滞留施設・目的の推定結果および分析事例

4.1 使用データの概要

石川県白山市および小松市を分析対象地域に設定し，対象地域内の居住者の滞留行動を分析した（表 1）．移動軌跡データは，株式会社 Agoop 社が提供するポイント移

動軌跡データを使用した．居住地域コードが石川県白山市および小松市であり，分析対象地域内で移動が観測されたユーザを分析対象とした．滞留施設の推定時に用いる建物データは，石川県都市計画基礎調査（2021 年度時点）を用いた（表 2）．建物データの建物用途は，滞留目的推定モデルの目的変数（7 区分）に合わせて再分類した（表 3）．

滞留目的推定モデルの構築で用いる都市交通調査データは，2018 年度の東京都市圏パーソントリップ調査データ（PT データ）を用いた．本稿では，分析対象地域である石川県白山市および小松市と地域特性が類似する地域の PT データのみを使用した．具体的には，①人口密度が 80 人/㎢以上 500 人/㎢以下，かつ，②昼夜間人口比率が 85%以上 115%以下である 89 市区町村のデータを分析対象とした（データ数 32,098 件）．

4.2 滞留施設推定手法の推定結果

本稿では滞留時間の閾値 τ は 10 分に設定し，滞留施設を推定した（図 4）．10 代男性と 40 代女性の同定結果を図 5 に示してある．両者とも病院を訪れた後に商業施設へ立ち寄る様子が確認できる．ただし，移動軌跡のみでは病院や商業施設における滞留目的が通院か勤務か，あるいは買い物かといった詳細までは知ることができない．

4.3 滞留目的推定モデルの推定結果

図 6 にパラメータ推定の際に用いたデータ数，設定した条件を示す．なお，パラメータ推定に用いる学習率 η および正則化強度 λ は，グリッドサーチに基づき決定した（η=0.00005，λ=0.0001）．

滞留目的推定モデルのパラメータの推定結果を図 7(a)(b)に示す．「勤務」や「通学」では，性別/年齢割合の影響が大きい．特に，「通学」は，概ね学齢期（20 歳以下）に集中する活動であることが強く反映されている．また，「買物等」は商業施設，「帰宅」は住宅に関する値が大きく，建物用途が目的推定に強く寄与していることが確認できる．学習・検証データの平均対数尤度の推移を図 7(c)に示してある．

表 1 対象地域の概要

	石川県白山市/小松市
人口	計215,000人
人口密度（人/km²）	146.25/286.26
昼夜間人口比率	97.95/101.12
都市区分	地方中核都市圏周辺都市（中心都市40万人以上）
GPSデータ固有ID数	37,157人
使用データ取得日	2023年 8月5,6日,11月18,19日,12月23,24,30,31日, 2024年 1月1日,2月4,6～8,10日,5月3~6日,8月 17,18,20~22,24,25,28,31日,9月1,3～5日

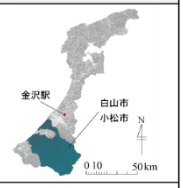
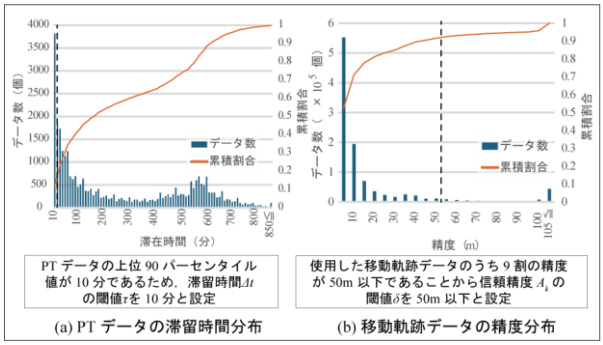


表 2 石川県都市計画基礎調査の概要

調査頻度	数年~10年ごとの行政単位での調査（自治体により異なる）
調査項目	建物ID，所在地，建物用途，構造，延床面積など
調査地域	日本全国（本稿では石川県19市町村）
調査方法	主に現地踏査（目視調査）
実施	国土交通省，地方公共団体

表 3 建物用途の読み替え

建物利用現況調査	用途読み替え
商業施設，商業系用途複合施設，娯楽施設，遊戯施設	商業系施設
住宅，共同住宅，店舗等併用住宅，店舗等併用共同住宅，作業所併用住宅	住宅
業務施設	事務所系
官公庁施設，文教厚生施設	文教厚生施設
運輸倉庫施設，重工業施設，軽工業施設，サービス工業施設，家内工業施設，農林漁業用施設，危険物貯蔵・処理施設	工業系施設
宿泊施設	宿泊施設
その他，不明	その他



(a) PT データの滞留時間分布　(b) 移動軌跡データの精度分布

図 4 滞留場所の抽出条件設定



(a) 10 代男性（平日）

(b) 40 代女性（平日）

※移動軌跡データではプライバシー保護のため，居住地付近の位置情報は秘匿される．そのため，ユーザの居住地は滞留施設として抽出されない．

図 5 滞留施設の抽出例

(a) 使用データ数

データセット名	データ数
学習データ	22,468
検証データ	6,419
テストデータ	3,211
合計	32,098

(b) 学習終了条件とグリッドサーチの導入

学習終了条件：一つ前の学習から平均対数尤度の変化が 0.0001 以下になった場合に学習を終了

※学習率と正則化強度の決定にはグリッドサーチを導入
候補値
(0.01,0.005,0.001,0.0005,0.0001,0.00005,0.00001,0.000005)
から全ての組み合わせを試して学習が安定して収束し，最も平均対数尤度が大きくなる組み合わせを採用．

図 6 使用データ数と学習終了条件



実際の目的＼予測結果	勤務	通学	買物等	通院	送迎	帰宅	その他
勤務	928	6	40	2	5	7	81
通学	10	263	0	0	3	0	17
買物等	3	0	536	7	4	6	14
通院	11	1	0	46	4	0	41
送迎	5	0	3	4	141	5	20
帰宅	1	0	0	0	2	253	8
その他	107	15	100	69	60	51	332

図 7 滞留目的推定モデルの推定結果

テストデータに対する滞留目的の推定精度（再現率・適合率）を図 7(d)に，混合行列を図 7(e)に示す．「通院」と「その他」は誤分類されやすい傾向が確認された．これは「通院」が他の滞留目的と比較してデータ数が少ないことや，「その他」には複数の滞留目的が含まれるため，行動の特徴が捉えにくいことが原因と考えられる．一方，「勤務」や「通学」は再現率と適合率が共に 80%を超えており，推定精度は高く良好である．

4.4 移動軌跡データでの分析事例

4.2 節で抽出した滞留施設に対して滞留目的推定モデルを適用し，滞留目的を推定した．10 代男性の例（図 4(a)）では，病院での滞在時間が短いため「通院」，商業施設での滞在時間が長いため「勤務」と同定された．すなわち，この男性は患者であり，商業施設の従業員と推察される．一方，40 代女性の例（図 4(b)）では病院での滞在時間が長いことから「勤務」，商業施設での滞在時間が短いため「買い物」であると同定された．すなわち，この女性は病院スタッフであり，商業施設の訪問客であると推察される．以上のように，同一建物用途における滞留であっても，滞留時間などの情報から異なる滞留目的が同定されており，一定の解釈が可能な結果を与えている．

5. おわりに

本稿では，移動軌跡データを用いて個人単位で滞留施設・滞留目的を推定する方法を提案した．具体的には，まず，移動軌跡データから滞留地点を抽出し，滞留施設を推定した．次に，パーソントリップ調査データを用いて，ロジスティック回帰による滞留目的推定モデルを構築した．このモデルを石川県白山市・小松市の移動軌跡データに適用することで，移動軌跡データから滞留施設・滞留目的の推定が可能であることを確認した．移動軌跡データのノイズ処理や滞留目的「その他」における推定精度の向上，利用圏分析などへの提案手法の適用は今後の課題である．

参考文献

小沢 啓次郎・田中 貴宏 (2023) 地方都市都心部の利便施設特性指標に基づくエリア区分と滞留の分布傾向に関する研究.「日本都市計画学会都市計画論文集」, **58**(3) , 1600 - 1607.

藤田 将成・伊藤 浩二・小林 稔・南 弘征・水田 正弘 (2012) GPS 移動履歴とスポット情報閲覧履歴の統合解析に基づいたスポット推薦手法の提案.「データ分析の理論と応用」, **2**(1), 53-68.

移動履歴データから順伝播型ニューラルネットワークで抽出した地域のベクトル表現の意味解釈
―ロジットモデルとの対応関係を通した検討―

白勢拓*・井上亮**

Interpretation of regional embeddings extracted from travel history data using a feedforward neural network
- Examination Through Correspondence with Logit Models -

Taku Shirose* and Ryo Inoue**

Abstract: Previous studies have explored applying Word2Vec, a natural language processing technique, to people flow data to extract embeddings representing regional characteristics. One study has demonstrated that these embeddings reflect inter-regional accessibility. However, analyses considering features of the input data, such as individual attributes and sequence relationships, have not been performed. This study aims to interpret the characteristics of embeddings extracted from stay location sequence data using a feed-forward neural network model that learns embeddings considering individual attributes and sequence relationships. Experimental results suggest that the embeddings extracted by the examined model represent accessibility between regions.

Keywords: 近接性（Accessibility），人流データ（people flow data），ベクトル表現（embeddings）

１．はじめに

近年，情報通信技術や測位技術の発展により，人々の移動の実態を詳細に記録した，人流データの蓄積が進んでいるが，その活用は，地域の滞在人口や地域間の移動量などの把握にとどまっている．人流データを人の移動履歴データとして扱う分析には，移動先の予測を目指したものは数多くみられるが，往復や周遊などの，地域間の人の移動パターンに着目して，地域間の関係性を捉えようとする分析は少ない．

人の移動履歴データの分析アプローチの一つは，各個人の滞在地の順序を表す滞在地系列に対して，深層学習に基づく自然言語処理手法を適用した地域の特徴を表す「ベクトル表現」の抽出である．Crivellari and Beinat (2019) は，自然言語の文章から単語のベクトル表現を抽出する Word2Vec (Mikolov et al., 2013) を滞在地系列に適用し，地域の特徴を表すベクトル表現を抽出できることを示した．さらに，Murray et al. (2023) は，Word2Vec による滞在地系列の分析は，特定条件下にて重力モデルと数学的に等価で，学習されたベクトル表現の内積が地域間の近接性を表すことを理論的に示し，実証的にも検証した．

しかし，Word2Vec が集計モデルである重力モデルと等価であるとの関係は，Word2Vec の入力データが個人単位の滞在地系列であるのに，分析にその「個人単位」「系列」という情報を反映できていないことを意味する．

人流データが有する情報を活かして地域間の近接関係を抽出するには，個人属性を考慮すること，および，滞在地が系列で記録されていることを考慮した分析が必要である．本稿はこの検討の第一段階として，特定の属性を有する個人が，ある滞在地から次の滞在地への１回の移動を１レコードとした移動データから，深層学習モデルによる分析を通して地域間の関係を抽出する分析を検討する．まず，得られるベクトル表現の解釈可能性を担保するため，Word2Vec と同様に，単純な Feed-Forward 型ニューラルネットワーク (FNN) のモデルを前提とする．個人属性と現在の滞在地の入力に対して，次の滞在地を予測するタスクの学習で得られる地域のベクトル表現が獲得する性質を，目的地選択行動に従来から用いられるロジットモデルとの比較を通して解釈し，人流データの深層学習モデルによる地域間関係分析への応用可能性を検討することを目的とする．

２．既往研究

Word2Vec のモデルのうち，Skip-gram モデルは，文章中の一単語を入力し，その前後に表れる単語を予測するタスクを通じて，モデルを学習する．全文章データ中の全単語の数をm，埋め込み次元をnとする．ある単語が入力されると，その単語に対応する行にのみ 1 を与え，それ以外に 0 を与えた $1\times m$の One-Hot ベクトルを入力層

* 学生会員 東北大学 大学院情報科学研究科（Tohoku University）
〒980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-06 E-mail: shirose.taku.r6@dc.tohoku.ac.jp
** 正会員 東北大学 大学院情報科学研究科（Tohoku University）

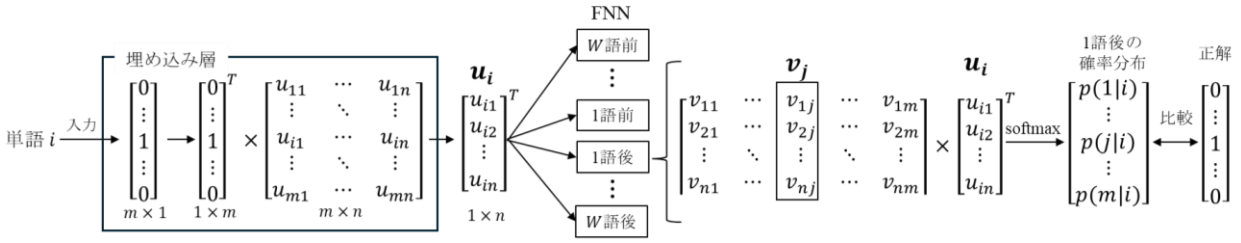


図 1　Skip-gram の概要

に入力する．対応する 1 行にのみ 1 が入ったベクトルのため，$m\times n$の埋め込み層のうち入力語に対応する行のみが演算され，中間層には入力単語に固有の $1\times n$の特徴量ベクトルが伝えられる．

Skip-gram の全結合層は，一般的な FNN である．前後単語の範囲であるウィンドウサイズWについて，$n\times m$の行列が前後それぞれ 2 つずつ，計 $2W$個存在する．出力層では，文章中で入力語の前後W語を予測する確率分布を softmax 関数でモデル化する．

$$p(j|i)=\frac{\exp(\boldsymbol{v_j}\cdot\boldsymbol{u_i})}{\sum_{j'=1}^{m}\exp(\boldsymbol{v_{j'}}\cdot\boldsymbol{u_i})} \tag{1}$$

ここで$p(j|i)$は，単語iが与えられたときに，任意の前後位置において単語jが現れる確率である．また，$\boldsymbol{v_j}$は，全結合層の中で単語jに対応する列ベクトルであり，$\boldsymbol{u_i}$は単語iの特徴量ベクトルである．

Murray et al., (2023) は，滞在系列データに Skip-gram を適用する手法が，モデルの学習時間を短縮する手法である Negative Sampling (NS) (Mikolov et al., 2013) を使用し，ウィンドウサイズ$W=1$の場合にのみ，重力モデルと等価の式で地域間流動を予測すると明らかにした．モデルの学習の際，通常の Skip-gram は学習対象地域全てについてベクトルの積を計算し，softmax 関数でモデル化するが，NS は正例(正解)に対して複数の負例(間違い)をランダムにサンプリングし，その負例を正解もしくは間違いに分類する 2 値分類問題に置き換えることで，モデルの学習時間を短縮する手法である．負例のサンプリングの際には，学習データ中で登場頻度の高い地域が高確率で抽出される．NS の目的関数は，正例のペアの予測確率を 1 に近づけ，且つ負例のペアの予測確率を 0 に近づけることであるため，以下の損失関数の最小化である．

$$\begin{aligned}L^{NS}&=\sum_i\left[\ln\frac{1}{1+\exp\{-\ln f(\boldsymbol{v_j}\cdot\boldsymbol{u_i})+\ln p_0(j)+c\}}\right.\\&\left.+\sum_{k\in V}\ln\frac{1}{1+\exp[-\{-\ln f(\boldsymbol{v_k}\cdot\boldsymbol{u_i})+\ln p_0(k)+c\}]}\right]\\f(\boldsymbol{v_j}\cdot\boldsymbol{u_i})&=(\boldsymbol{v_j}\cdot\boldsymbol{u_i}+\ln p_0(j)+c)\end{aligned} \tag{2}$$

ここで，jは正例，Vは負例の集合，$p_o(j)$は学習データ中でのjの登場割合，cは定数項である．$W=1$で，Skip-gram に NS を使用した場合，学習された埋め込み層の重みと全結合層の重みが一致する (Levy and Goldberg. 2014)．そのため，Skip-gram Negative Sampling (SGNS) を用いて予測する確率分布は，以下の式で計算される．

$$\begin{aligned}P^{NS}(j|i)&=\frac{f(\boldsymbol{u_j}\cdot\boldsymbol{u_i})}{\sum_{j'\in V}f(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i})}\\&=\frac{\exp(\boldsymbol{u_j}\cdot\boldsymbol{u_i}+\ln p_0(j)+c)}{\sum_{j'\in V}\exp(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i}+\ln p_0(j')+c)}\\&=\frac{p(j)\exp(\boldsymbol{u_j}\cdot\boldsymbol{u_i})}{\sum_{j'\in V}p\,(j')\exp(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i})}\end{aligned} \tag{3}$$

したがって，SGNS によって予測される，地域iと地域j間の流動量$\widehat{T_{ij}}$は以下の通りである．

$$\widehat{T_{ij}}\propto p(i)P^{NS}(j|i)\propto\frac{p(i)\,p(j)\exp(\boldsymbol{u_j}\cdot\boldsymbol{u_i})}{\sum_{j'}p(j')\exp(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i})} \tag{4}$$

また，Skip-gram は，滞在地系列の中での滞在地iとjの隣接関係は考慮するが，その前後関係は考慮できないため，地域i, jを発着する相互の流動量が等しいと仮定してモデルを学習することになる．

$$\begin{aligned}&\widehat{T_{ij}}=\widehat{T_{ji}}\Leftrightarrow\frac{p(i)\,p(j)\exp(\boldsymbol{u_j}\cdot\boldsymbol{u_i})}{\sum_{j'\in V}p(j')\exp(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i})}=\frac{p(j)\,p(i)\exp(\boldsymbol{u_i}\cdot\boldsymbol{u_j})}{\sum_{i'\in V}p(i')\exp(\boldsymbol{u_{i'}}\cdot\boldsymbol{u_j})}\Leftrightarrow\\&\sum_{j'\in V}p(j')\exp(\boldsymbol{u_{j'}}\cdot\boldsymbol{u_i})=\sum_{i'\in V}p(i')\exp(\boldsymbol{u_{i'}}\cdot\boldsymbol{u_j})\\&\Rightarrow\widehat{T_{ij}}=Cp(i)p(j)\exp(\boldsymbol{u_j}\cdot\boldsymbol{u_i})\end{aligned} \tag{5}$$

(5)式より，$W=1$の設定の SGNS は，重力モデル$\widehat{T_{ij}}=Cm_im_jf(r_{ij})$ と等価な方程式で移動を予測すると解釈できる．つまり，学習されたベクトル表現 $\widehat{\boldsymbol{u_i}},\widehat{\boldsymbol{u_j}}$のベクトル空間上での距離が，地域$i,j$間の近接性に対応する．

３．FNN とロジットモデル

ある時点の滞在地を入力し，次の移動後の滞在地を予測して，ベクトル表現を学習する FNN と，ロジットモデルそれぞれが予測する確率分布は，いずれも softmax 関数の形をしており，FNN の全結合層の出力と，ロジットモデルの確定効用は対応関係にある．いずれのモデルも，個人単位の移動行動を扱うため，ある時点の滞在地の入力から次の滞在地を予測する FNN の学習により得られるベクトル表現について，その意味をロジットモデルとの比較を通して明らかにする．

３．１ 検討する FNN モデル

本研究では，以下の式で次の滞在地を予測して，ベクトル表現を学習するモデルを検討する．

$$p^k(j|i) = \frac{\exp\left(\boldsymbol{v_j}\cdot\boldsymbol{u_i} + \boldsymbol{w^a}\cdot\boldsymbol{a_j} + \boldsymbol{w_j^h}\cdot\boldsymbol{h_k}\right)}{\sum_{j'=1}^{m}\exp\left(\boldsymbol{v_{j'}}\cdot\boldsymbol{u_i} + \boldsymbol{w^a}\cdot\boldsymbol{a_{j'}} + \boldsymbol{w_{j'}^h}\cdot\boldsymbol{h_k}\right)} \quad (6)$$

ここで，$\boldsymbol{u_i}$はある時点の滞在地iの特徴量ベクトル，$\boldsymbol{v_j}$は次の移動後の滞在地jに対応する全結合層の列ベクトル，$\boldsymbol{a_j}$は着地の魅力度，$\boldsymbol{h_k}$は移動者kの個人属性，wは重みパラメータである．このモデルは， Word2Vec と同様の，1 層の Feed-Forward 型の全結合層での出力に，着地の魅力度と個人属性の線形結合を加算して，softmax 関数で確率化する．全結合層の数は，ベクトル表現の解釈可能性の担保のために，本研究では 1 層のモデルを考える．

３．２ ロジットモデル

ロジットモデルは，ランダム効用理論に基づく離散選択モデルである．個人は選択肢の望ましさを意味する効用が最も大きい選択肢を選ぶ．ランダム効用理論において，選択肢の効用は確率的に表され，選択肢jの効用U_jは以下の式により計算される．

$$U_j = V_j + \varepsilon_j \quad (7)$$

ここで，V_jは観測可能な説明変数によって表される確定効用，ε_jは観測不能な要因を説明する確率的な誤差項である．ある個人が選択肢jを選択する確率p_jは，

$$p_j = Pr\left[U_j > \max_{j'(\neq j)}\left(U_{j'}\right)\right] \quad (8)$$

ある．ここで，$Pr[*]$は*の生起する確率である．誤差項が独立なガンベル分布に従う場合の，ランダム効用理論に基づく離散選択モデルがロジットモデルと呼ばれ，p_jは以下のように表される．

$$p_j = \int Pr\left[U_j = x\right]Pr[U_1 < x]\cdots Pr[U_m < x]dx$$

$$= \exp\left(V_j\right)\int_{-\infty}^{\infty}\exp(-x)\exp\left[-\left(\sum_{j'=1}^{m}\exp\left(V_{j'}\right)\right)\exp(-x)\right]dx$$

$$= \frac{\exp\left(V_j\right)}{\sum_{j'=1}^{m}\exp\left(V_{j'}\right)} \quad (9)$$

目的地選択問題において，確定効用の説明変数には発地i着地j間の距離d_{ij}，着地の魅力度$\boldsymbol{a_j}$，移動者kの個人属性$\boldsymbol{h_k}$などが一般に用いられ，確定効用項はそれらの線形結合によって表される．地域iにいる個人kにとって，次の滞在地の地域jの確定効用は以下の通りである．

$$V_j^k = w^d\cdot d_{ij} + \boldsymbol{w^a}\cdot\boldsymbol{a_j} + \boldsymbol{w_j^h}\cdot\boldsymbol{h_k} \quad (10)$$

ここでwは重みパラメータである．2 地域間距離，着地の魅力度などの選択肢に固有の変数には，全地域に共通の重みパラメータを用いる．一方，個人属性などの選択肢に固有でない変数は，その線形結合を選択肢固有にするために，選択肢ごとに異なる重みパラメータ$\boldsymbol{w_j^h}$を設定することが一般的である．なお，全ての選択肢に固有の重みパラメータを設定すると多重共線性が生じるために，一つの基準選択肢はその重みパラメータを 0 に固定する．

３．３ 検討モデルとロジットモデルの対応関係

検討モデルは，全結合層での出力に，(10)式のうち，距離以外の説明変数にあたる項を加算して，softmax 関数で確率化する．つまり，ロジットモデルで地域間距離にあたる項を$\boldsymbol{v_j}\cdot\boldsymbol{u_i}$で置き換えた式で次の滞在地を予測するため，$\boldsymbol{v_j}\cdot\boldsymbol{u_i}$は$w^d\cdot d_{ij}$と対応する．したがって，検討モデルにより学習されたベクトル表現と全結合層の重みの内積 $\widehat{\boldsymbol{v_j}}\cdot\widehat{\boldsymbol{u_i}}$は，移動データに潜む地域間の近接性を表す．

４．東京都を対象とした分析

本研究では，実データに検討モデルを適用し，得られた地域のベクトル表現が獲得した性質を考察する．

４．１ 使用データとモデルの設定

東京大学空間情報科学研究センター「人の流れプロジェクト」提供の「擬似人流データ」から，東京都内で移動が完結した約 870 万人の移動を対象とする．東京都市圏パーソントリップ調査の計画基本ゾーン 164 地域で個人の滞在地を表した系列を作成した．移動者の個人属性は年齢，性別，職業の 3 種類を使用し，年齢は 0~19 歳，20~39 歳，40~59 歳，60~89 歳の 4 区分，性別は男性，女性の 2 区分，職業は就業者，無職，学生の 3 区分に分類した．「0~19 歳」「女性」「学生」を基準のカテゴリーとし，ダミー変数を設定した．着地の魅力度を表す指標として，平成 28 年経済センサス-活動調査 従業者数，平成 27 年度国勢調査 人口総数を用いる．従業者数は繁華街やオフィス街などの性質による魅力度を説明し，人口総数は住宅街の性質による魅力度を説明する変数として用いる．

検討モデルは埋め込み次元を 25 次元とし，滞在地系列データを学習用と検証用に 8:2 の割合で分割し，Early stopping を用いて，validation loss の改善が見られなくなってから 2 回まで学習を行い，最良のモデルを選択した．

検討モデルの比較対象として，SGNS の学習とロジットモデルの推定を行う．SGNS は，Murray et al. (2023)と同じ設定のモデルを用いて，埋め込み次元を検討モデルと同じ 25 次元と設定する．ロジットモデルの説明変数は，着地の魅力度と個人属性は検討モデルと同じ変数，地域間距離は計画基本ゾーンの重心間距離(km)を用い，(10)式で確定効用を計算する．なお，この推定では，全データを用いた推定は計算量の観点から困難なため，対象データから 3%をサンプリングして使用した．

４．２ ベクトル表現の特徴

検討モデルにより学習されたベクトル表現と全結合層の重みの内積 $\widehat{\boldsymbol{v_j}}\cdot\widehat{\boldsymbol{u_i}}$を縦軸，推定されたロジットモデルでの距離の重みパラメータと距離の積 $\widehat{w^d}\cdot d_{ij}$を横軸とした散布図を**図 2** に示す．推定された距離の重みの値は，-0.368 であった．対応する両者の間には，比例に近い関係性が見てとれ，類似した性質を持つと考えられる．

図 2 の中で，都心 5 区(千代田，中央，港，新宿，渋谷)

を発地とする移動に注目したものを**図 3**(a)に，都心 5 区を着地とする移動に注目したものを**図 3**(b)に示す．**図 3**(a)は，**図 3**(b)と比較して，$\widehat{w^a} \cdot d_{ij}$の値が小さい範囲に，$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$の値が特に小さい点が多く見られる．これは，距離が離れた地域間の移動において，都心を発地とする場合と，都心を着地とする場合では，ベクトル表現が表す近接性に大きな違いがあることを示している．オフィス街や繁華街が集中する都心の人を集める範囲の広さに起因して，都心を着地とする方向の近接性が高くなったと考えられ，ベクトル表現は移動の向きを区別した近接性を表すと解釈できる．

次に，$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$について，新宿駅西口地域，八王子駅地域を発地とする移動に注目した分布を**図 4** に，新宿駅西口地域，八王子駅地域を着地とする移動に注目した分布を**図 5** に示す．八王子駅地域は両図の間に違いがみられない一方，新宿駅西口地域は，**図 4** と比較して，**図 5** では地理的距離が近い地域だけでなく，距離の離れた地域にも，その値の大きい地域が確かに多く分布している．比較対象の SGNS によるベクトル表現の内積について，新宿駅西口地域，八王子駅地域に注目した分布を**図 6** に示す．移動の向きを区別できない SGNS の分布は，**図 4**, **図 5** と異なる傾向の分布をしている．

５．おわりに

本研究は，個人属性と現在の滞在地の入力に対して，次の滞在地を予測する FNN で得られる地域のベクトル表現の性質を，ロジットモデルとの比較を通して解釈を行った．実データを用いた分析により，そのベクトル表現は，移動の向きを区別した地域間の近接関係を表すと評価でき，人流データの深層学習モデルによる地域間関係分析への応用可能性が示唆された．今後，過去の滞在地と現在の滞在地の関連性を学習し次の滞在地を予測する，LSTM や Transformer などの深層学習モデルによるベクトル表現について，同様の議論へと発展させたい．

謝辞

本研究は，東京大学 CSIS 共同研究（No. 1184）による成果である（利用データ：擬似人流・トリップデータ 東京都データセット CSIS 人の流れプロジェクト事務局提供）．

参考文献

Crivellari, A. and Beinat, E. (2019) From motion activity to geo-embeddings: Generating and exploring vector representations of locations, traces and visitors through large-scale mobility data. *ISPRS International Journal of Geo-Information*, **8**(3), 134.

Levy, O., & Goldberg, Y. (2014). Neural word embedding as implicit matrix factorization. *Advances in neural information processing systems*, 27.

Mikolov, T., Chen, K., Corrado, G., and Dean, J. (2013) Efficient estimation of word representations in vector space. arXiv:1301.3781.

Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. *Advances in neural information processing systems*, 26.

Murray, D., Yoon, J., Kojaku, S., Costas, R., Jung, W. S., Milojević, S., & Ahn, Y. Y. (2023). Unsupervised embedding of trajectories captures the latent structure of scientific migration. *Proceedings of the National Academy of Sciences*, 120(52), e2305414120.

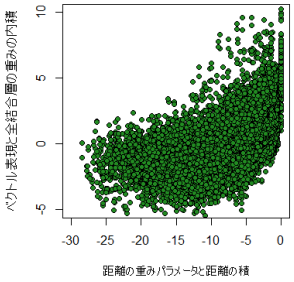
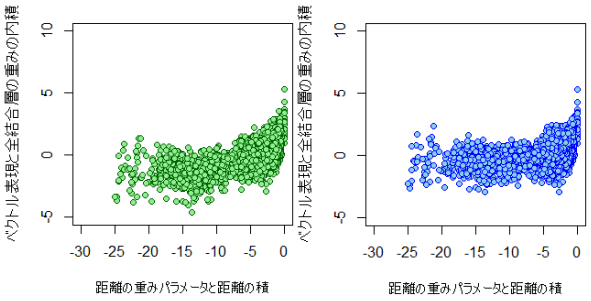


図 2　$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$と$\widehat{w^a} \cdot d_{ij}$の散布図



(a) 発地　　(b) 着地

図 3　都心 5 区に着目した$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$と$\widehat{w^a} \cdot d_{ij}$の散布図

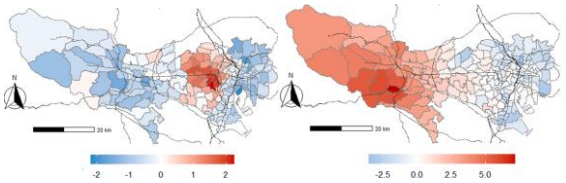


図 4　注目地域を発地とする移動の$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$の分布

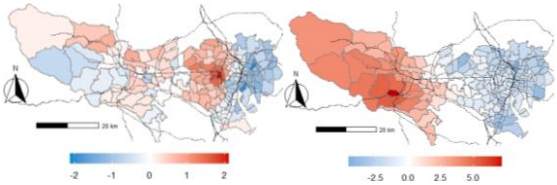


図 5　注目地域を着地とする移動の$\hat{\boldsymbol{v}}_j \cdot \hat{\boldsymbol{u}}_i$の分布

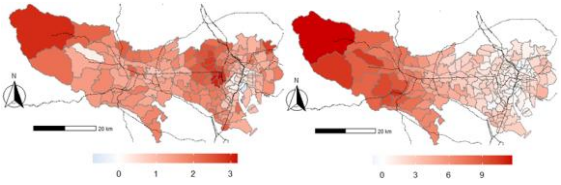


図 6　SGNS の$\hat{\boldsymbol{u}}_j \cdot \hat{\boldsymbol{u}}_i$の分布

エージェントワークフローを活用した大規模言語モデルによる擬似人流データの生成と精度向上

瀬貫雄介*・龐岩博・関本義秀****

An Agentic Workflow Approach for Pseudo People Flow Data Generation with Large Language Models

Yusuke Senuki*, Yanbo Pang**, Yoshihide Sekimoto**

Abstract: This study explored a method for generating high-precision pseudo people flow data by leveraging Large Language Models (LLMs) and introducing an agent-based workflow. Specifically, it employed an iterative feedback process involving an AI agent that generates synthetic people flow by few-shot, and a separate AI agent that evaluates the generated people flow. This approach resulted in a stepwise improvement in the quality of simulated people flow data. The proportion of flows meeting the criteria increased by 11.8 percentage points compared to conventional methods during the first generation and by 30.0 percentage points during the tenth generation. Furthermore, the frequency of activity appearances in the flows increased by 41.6%, confirming that the generated data includes diverse cases not sufficiently represented by single-generation models. Such data is expected to be utilized in urban planning and commercial analysis scenarios as a method to simulate people flow.

Keywords: 擬似人流データ（pseudo people flow data），大規模言語モデル（large language models），エージェントワークフロー（agentic workflow）

１．はじめに

民間による商業分析や自治体における都市計画・災害対策など，様々な場面で GIS を用いた人流（人の移動）のデータの応用が広まっている．一方で，それらの目的でスマートフォンから得られた位置情報などのデータを直接使用することは，個人のプライバシーを侵害するため許可を得ることが非常に難しい．この問題を解決する手法として，少量の実データや統計的知見を基に，人々の移動パターンをアルゴリズムで生成する「擬似人流データ」の開発が注目されており（Kashiyama et al.,2024），大規模言語モデル（LLM）を基に移動モデルを構築する研究も行われている（Wang et al.，2023）．

その一方で，生成系モデルで大量に活動スケジュールを作ると，イベント回数や時間配分などの外形的な定量指標が許容範囲でも「人間らしくない」「単純すぎる」「現実では起きにくい」サンプルが残るという問題が避けがたい．これは人間行動の複雑さに対して，「人間らしさ」「現実らしさ」の判定を定量化しにくいことに起因する．人間の専門家による定性的評価は可能だが，大量・自動化が難しく，モデル改良の反復に耐える評価基盤になりにくい．

本研究の核心は、このギャップを LLM を評価者（Evaluator）として用いるエージェントフレームワークで埋める点にある．すなわち，生成→評価→再生成の反復ループを導入し，評価エージェントが「矛盾の有無」と「多様性（人間らしい広がり）」の双方をもとに 5 段階で採点し，閾値に満たない場合は改善コメントをもとに再生成する．これにより，これまで人手に頼ってきた曖昧かつ文脈依存の判断を自動かつ大規模に実施できる．実装では生成エージェント・評価エージェントの双方に GPT-4 を用い，15 分スロットの 1 日スケジュール，23 語彙の制約，最大 10 回の反復，5 段階の評価指標を採用した．GPT-4 は文脈理解や推論能力が高く，複雑な人間行動や社会的文脈を考慮した擬似人流の生成が可能である一方で，高い推論能力を持つため，生成された人流データの一貫性や妥当性を評価し，数値スコア（GPTScore）を算出する役割も担うことができる．

本稿では，2 章でエージェントワークフローの詳細やデータの具体的な内容について紹介した上で，3 章で評価エージェント・生成エージェントを稼働させた結果を示した．さらに 4 章でそれらの結果を踏まえ考察した上で，5 章では今後の研究の可能性について記した．

２．提案手法

２.１　全体の構成

本研究では，人流を生成するエージェントと生成され

*　学生会員　東京大学 空間情報科学研究センター（Center for Spatial Information Science at the University of Tokyo）
〒277-8568　千葉県柏市柏の葉 5-1-5，　E-mail：senuki@csis.u-tokyo.ac.jp
**　正会員　　東京大学 空間情報科学研究センター（Center for Spatial Information Science at the University of Tokyo）

表 1　人間による点数ラベルの付与方針

5 点…矛盾点がない上で，買い物や余暇などの多様な行動が含まれる人流．
4 点…矛盾点はないが，やや多様性に欠ける人流．会社員の「家→通勤→会社→帰宅→家」など．
3 点…矛盾点はないが，非常に多様性に欠ける人流．会社員の「家→会社→家」や一日中「家」のみなど．
以下のような矛盾点がある場合は，矛盾の程度に合わせて元の点数から 1 個につき 1~2 点減点．（下限は 1 点）
・通勤や通学が 2 時間以上．あるいは通勤と帰宅・通学と帰宅の時間差が 45 分以上．
・途中に挟まれる不自然な移動．例えば「会社→通勤→会社」など．
・年齢や職業にそぐわない行動．例えば 10 歳の会社など．今回は性別は点数判定の要素としては用いなかった．

表 2　生成エージェントに与えた個人属性・生成エージェントの出力・評価エージェントの出力の例

【与えた個人属性】What is the daily schedule of a female aged 35-39 who works as a Professional/engineering_workers?
【生成エージェント出力】00:00-07:00 House, 07:00-07:30 Commute, 07:30-17:30 Office, 17:30-18:15 Private_Space, 18:15-18:30 Back_Home, 18:30-22:00 House, 22:00-22:30 Go_Eat, 22:30-24:00 House
【評価エージェント出力】スコア: 5　　改善点: 特に改善点なし。属性と行動が一致し、多様な行動が含まれている。

た人流を評価するエージェントのフィードバックの繰り返しによって人流の精度を向上させる．人流を 1 件生成する実行過程は以下①から④であり，これを生成する件数分繰り返す．多様な生成と一貫した評価のため，温度（temperature）は生成時は 0.7, 評価時は 0.0 とした．

① 生成エージェントが，生成する人流の個人属性（性別・職業・年齢層）を決定する．これは訓練データからランダムに選ばれる．
② 生成エージェントが，15 件の few-shot を含む生成用プロンプトに基づいて人流を 1 件生成する．
③ 評価エージェントが，15 件の few-shot を含む評価用プロンプトに基づいて人流を 5 段階で評価する．この際，点数だけではなく何故そのような評価結果になったか説明した短文も 50 文字以内で出力する．
④ 評価が 3 点以下で，なおかつ現在のループ回数が 9 回目以下の場合は，生成エージェントに評価結果の短文を見せ，再生成の指示を送る．逆に，評価が 4 点以上か，あるいは現在のループ回数が 10 回目の場合は，生成された人流を生成結果として書き加える．

2.2　データの内容

本研究で用いられる人流のデータは，0 時から 8 時 45 分が活動 X，8 時 45 分から 9 時 15 分が活動 Y……のように，活動の区切れ目が 15 分ごとに置かれ，個人属性は性別（男性・女性），職業（営業職・技術職・学生など），年齢層（20~25 歳など基本的に 5 歳区切り）の 3 要素から成り立つ．人流において活動を表す語彙は，家・通勤・会社・ショッピングなど全 23 種類が使われている．

本研究では，訓練データとして few-shot 等に用いる人流データとして，Zhang et al.（2024）が LLaMA3 をファインチューニングし，few-shot を組み合わせることで一括生成した人流データを用いた．この一括生成モデルでは元データとして，2008 年に東京都市圏（東京都・神奈川県・埼玉県・千葉県・茨城県南部）を対象に行われた第 5 回東京都市圏パーソントリップ調査の結果が用いられている．この研究では基礎的な人流の大量生成に成功した一方で，多様性にやや欠けるという欠点が見られた．

2.3　スコアリング手法

Zhang の一括生成モデルで生成された人流 1000 件に対して，手動で 5 から 1 の点数ラベルを付与する．5 が最高点，1 が最低点であり，具体的な点数の基準は表 1 に記した．但し，1 点の人流は数が少なかったため，訓練の精度向上のためにデータの一部を表 1 の基準で 1 点になるよう改悪し，1 点が全体の 1 割を超えるようにした．

2.4　擬似人流データの生成・評価

生成エージェントには，以下の 5 種類のプロンプトを与えて擬似人流データを生成させた．

① 基本のプロンプト（「あなたは人流データを生成するエージェントです」で始まる簡単な文章）
② 制約ルールの明文化（「属性と行動の整合性を保ってください」「多様な行動を含めてください」など好ましい生成方法のルールを簡単に書いた文章）
③ 5 点から 1 点の簡単な採点基準
④ スコア例の few-shot（点数ラベル付きの人流について，生成する人物の属性と近いものを，5 点〜1 点のものをそれぞれ 3 個ずつ，計 15 個与える）
⑤ 生成時に使える語彙の種類（全 23 種）

評価エージェントには上記の①に相当する基本のプロンプトのほか．上記の②③④と同じプロンプトを与えた．

出力結果は，表 2 のように個人属性・生成結果・評価結果の 3 要素を含む行が，生成された人流の個数分の行数で結果として保存される．

表 3　一括生成モデルと今回のモデルでの生成された人流の頻出シーケンスの各上位 3 件

【Zhang et al. (2024) の一括生成モデルで生成された人流の頻出シーケンス上位 3 件】
House→Commute→Office→Back_Home→House　157/500 (31.4%)
House→Shopping_Daily→Store Daily→Back_Home→House　30/500 (6.0%)
House→Go_Scholl→School→Back_Home→House　27/500 (5.4%)
【今回の実験で生成された人流の頻出シーケンス上位 3 件】
House→Commute→Office→Go_Eat→Socializing→Back_Home→House　30/500 (6.0%)
House→Commute→Office→Shopping_Daily→Store_Daily→Back_Home→House　18/500 (3.6%)
House→Commute→Office→Go_Eat→Office→Shopping_Daily→Store_Daily→Back_Home→House　17/500 (3.4%)

3．実験と結果

3.1　評価エージェントによる評価結果

まず，評価エージェントの適切な人流評価を確認するための実験を行った．人間が点数ラベルをつけた 1000 件の人流のうち，半分の 500 件を人流と点数がセットになった訓練データとしたうえで，残りの半分をテストデータとした．プロンプトや few-shot の個数を評価エージェントと同じ要領で設定して点数をつけさせ，GPT-4 が適切に点数をつけられているかを確認した．

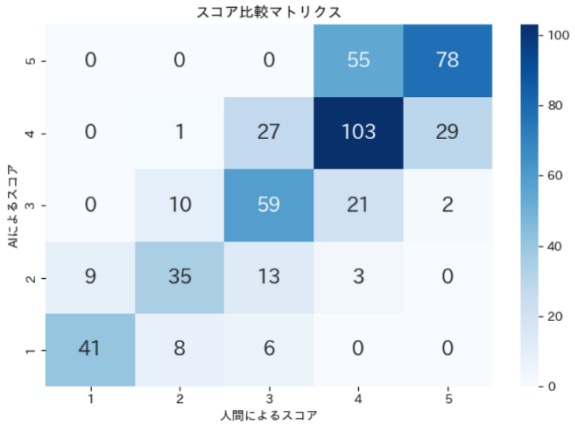


図 1　人間の点数ラベルと評価エージェントによる点数付けの比較マトリクス

図 1 のマトリクスを確認すると，対角線上のセルの値がそれぞれ最も大きく，その次に対角線の一つ隣のセルの値が大きくなっていることから，AI エージェントによる点数の付け方が人間の点数の付け方の傾向とある程度一致していることが読み取れる．

3.2　生成エージェントによる生成結果

次に，エージェントワークフローに基づいて実際に人流を 500 件生成し，生成結果を Zhang による LLaMA3 を用いた一括生成モデル（訓練データ）と比較した．

表 3 からは，本研究による生成では単純な人流の数が減っていることがわかった．Zhang の一括生成モデルでは 30%以上で「家→通勤→職場→帰宅→家」という単純な人流が生成されていたのに比べ，本研究では一番多い種類のものであっても全体の 6%であるように，多様な人流のシーケンスが生成されていることが確認された．

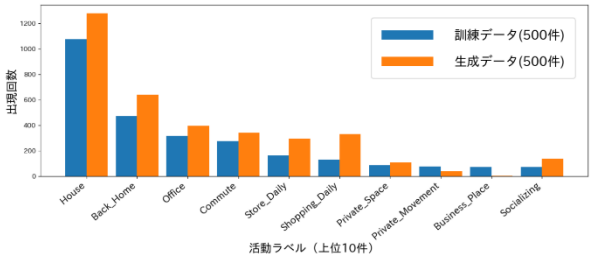


図 2　Zhang の結果(青)と今回の結果(橙)による活動内容の語彙の合計生成回数の比較グラフ

図 2 で示した語彙の出現回数の上位 10 件を見ると，本研究で生成された人流は，Zhang の一括生成モデルと比較して全体的な傾向を保ちつつも人流内の活動の回数を全体的に増やしていることがわかる．今回生成された人流 500 件のうちに語彙は合計 4280 回含まれており，Zhang の一括生成モデルである 3023 回に比べて 41.6%，人流 1 件あたりでは 2.095 回増加していた．特にショッピングが 186.7%増加するなどしており，余暇の活動を中心に従来より多様な人流が生成されていることが確認できる．

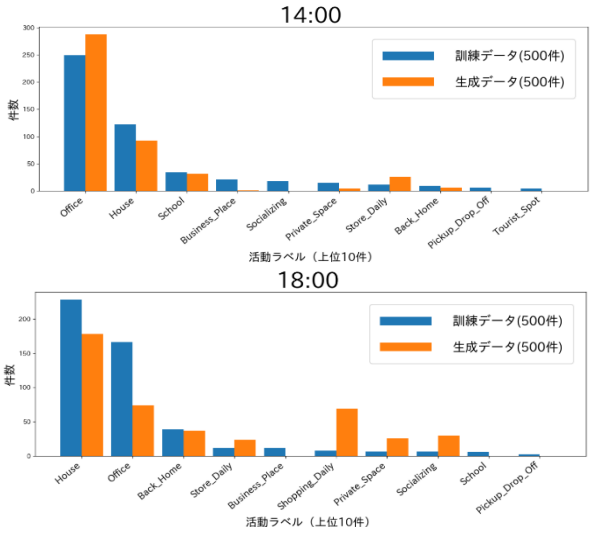


図 3　Zhang の結果(青)と今回の結果(橙)による活動内容の特定の時間(14 時と 18 時)での数の比較グラフ

さらに，図 3 で昼 14 時と夕方 18 時時点に限定した語彙の出現回数を比較すると，18 時には家や職場が減った代わりにショッピングなどが多く生成されている一方で，14 時にはそれらはあまり生成されていないことがわかり，生成エージェントが多様性のある行動をどの時間帯に多く出現させるべきかを考慮できていることが読み取れる．

3.3　再生成による精度向上の結果

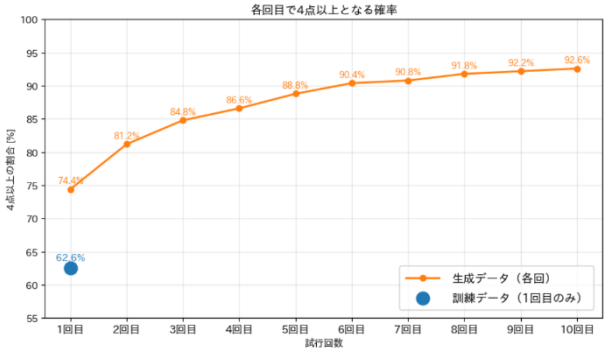


図 4　再生成回数ごとの 4 点以上の割合のグラフ

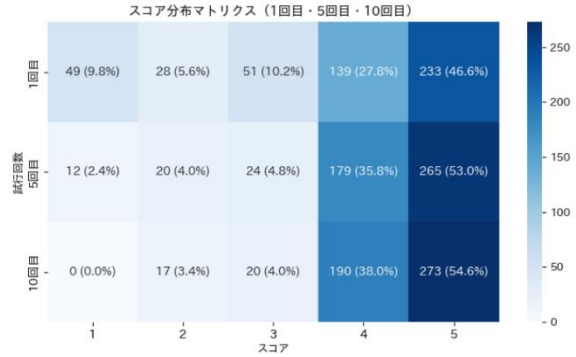


図 5　生成 1，5，10 回目における点数のマトリクス

再生成を繰り返すことでどのように生成結果が向上するかを調べた．図 4 からは，4 点以上の割合が Zhang の一括生成モデル比べて生成 1 回目で 11.8 ポイント増加，生成 10 回目で 30.0 ポイント増加していること，再生成を繰り返すほど 4 点以上の割合が伸びるものの上昇率は逓減してゆくことが示された．また図 5 からは，再生成を繰り返すことで 1 点の生成結果が無くなったものの，2, 3 点はいくつか修正されずに残っていることが見られ，完全に問題がある生成結果よりも僅かに問題がある生成結果を修正する方が相対的に難しいことが示された．

3.4　再生成の閾値変更による効果

4 点となっている閾値を 5 点，3 点に変更した場合の実験も行った．図 6 からは閾値が 5 点の場合は 1~2 回の再生成による効果が大きいこと，閾値が 3 点の場合でも完全に質の低い人流を除去するのは難しいことが示された．また，閾値 5 点の場合の語彙の出現回数は Zhang の一括生成モデルの 3023 回に比べて 47.7%多い 4465 回であり，これは閾値 4 点のときを 6.1 ポイント上回った．

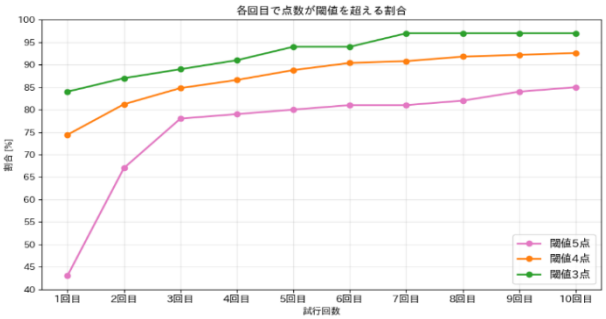


図 6　再生成回数ごとの閾値以上の点の割合のグラフ

4．考察

3 章の結果から，GPT-4 による GPTScore が人流の評価としても適切に作動すること，従来よりも正確かつ多様性のある人流が生成されていること，再生成システムによってワークフロー内で適切に修正が行われていることが示された．その一方で，訓練データでは存在した一部の語彙が極端に生成されなかったことも確認され，多様性をより確保するための他の必要性も見受けられた．

今後は閾値を状況に応じて変化させることで「単純な人流」と「多様な人流」を適切な割合で生成させ現実の人流に近づけることや，一部の語彙を積極的に生成結果に含めるようなプロンプトを状況に応じて用いることでより多様性を確保することが展望として挙げられる．

5．結論と今後

本研究では，生成エージェントと評価エージェントを動かすエージェントワークフローによって擬似人流データを高精度に生成する方法を探求し，従来の一括生成型のモデルに比べてより正確で多様な疑似人流が生成されたことを確認した．今回は人流を行動内容に限定して言語で処理したが，今後の研究では，今回の結果を実際の地図上での人流生成の補助に活用させ，GIS 上で商業分析や都市計画などの研究に役立てることを目指している．

参考文献

Kashiyama, T., Pang, Y., Shibuya, Y., Yabe, T., and Sekimoto, Y.(2024) Nationwide synthetic human mobility dataset construction from limited travel surveys and open data. *Computer-Aided Civil and Infrastructure Engineering,* **39**, 3337–3353.

Wang, Xinglei, Meng Fang, Zichao Zeng, and Tao Cheng (2023) Where Would I Go Next? Large Language Models as Human Mobility Predictors, arXiv:2308.15197.

Zhang, Y., Zhang, K., Pang, Y., and Sekimoto, Y.(2024) Agentic Large Language Models for Generating Large-Scale Urban Daily Activity Patterns. *2024 IEEE International Conference on Big Data (BigData)*, Washington, DC, USA, pp. 6815-6822.

パーソントリップデータを用いた通院行動負担の空間分析

吾妻勇太*・山本佳世子**

Quantitative Spatial Assessment of Outpatient Access Burden Based on Person Trip Data

Yuta Azuma*, Kayoko Yamamoto**

Abstract: Japan's aging population and uneven distribution of general hospitals have increased outpatient travel burden, especially in suburban areas. This study quantifies the burden using person trip data from the Tokyo Metropolitan Area, focusing on six municipalities in the Kitatama Nanbu region. Patient origins are approximated by population-weighted centroids, and destinations by physician-weighted hospital centroids, enabling realistic distance estimation without precise coordinates. Travel burden is calculated by combining trip distance with transportation mode-specific weights and aggregated at the small zone level. Zones with multiple hospitals, such as Chofu City, show lower burdens due to localized access. In contrast, southeastern Komae City exhibits high burden values due to the absence of nearby hospitals and cross-boundary travel. This study presents a replicable framework for evaluating healthcare accessibility by integrating spatial analysis with mobility data. It underscores the role of hospital location in shaping outpatient behavior and offers insights for regional healthcare planning. Future work will refine origin-destination modeling and incorporate route-level data for improved accuracy.

Keywords: 通院行動（Outpatient Travel），医療アクセス（healthcare accessibility），空間分析(Spatial Assessment)，
パーソントリップデータ（Person Trip Data），総合病院の配置（Distribution of general hospitals）

１．序論

１.１　研究の背景と目的

近年，日本では超高齢化が急速に進行しており，今後も高齢者人口の増加が継続すると予測されている．これに伴い，医療資源の逼迫が懸念され，効率的かつ公平な医療施設の利用・配置が求められている．医療施設が不足する地域では，希望する医療サービスを受けるために長時間・長距離の移動を強いられ，通院やリハビリにかかる移動負担（通院行動負担）は深刻な課題となっている．こうした課題に対して有効な施策を導入するには，まず通院行動の負担がどの地域でどの程度深刻かを定量的に把握する必要がある．

本研究は，現実の移動状況を反映するためにパーソントリップデータを活用し，通院行動負担の定量化することを目的とする．また，負担を増加させる要因を分析し，今後の施策立案に資する知見を提供することで，地域ごとの医療アクセス改善に貢献することを目指す．

１.２　関連分野における先行研究と本研究の位置付け

関連分野の先行研究として，鈴木（2011）による既存施設を活用した都市施設の再配置モデルに関する研究，竹内ら（2017）による公共施設の利用者数予測に関する研究，相馬ら（2019）による都市特性に着目した通院行動分析の研究，坂田ら（2023）による居住地・勤務地に関する空間分析の研究，服部ら（2023）による私事交通に着目した交通利便性の定量化に関する研究，Satoh et al. (2018) による送迎行動に注目した保育施設の適正配置評価の研究がある．

これらの先行研究は，施設配置や空間的行動，交通利便性などに関する重要な知見を提供しているが，本研究はそれらと比較して，以下の 3 点において独自性を有する．

(1) 各利用者が選択する医療施設の実態を考慮し，通院行動を個別に把握する
(2) 医療施設の空間的配置を基に，移動に伴う負担を定量的に評価する
(3) パーソントリップデータにおける始点地域・終点地域に中心点を設定し，実際の移動距離を精度高く算出する

これら 3 点の特徴により，本研究は通院行動の空間的負担をより現実的かつ政策的に活用可能な形で明らかにすることを可能とする．

*　学生会員 電気通信大学大学院情報理工学研究科（The University of Electro-Communications）
〒182-8585 東京都調布市調布ヶ丘 1-5-1　E-mail：a2530002@gl.cc.uec.ac.jp
**　正会員 電気通信大学大学院情報理工学研究科（The University of Electro-Communications）
〒182-8585 東京都調布市調布ヶ丘 1-5-1　E-mail：kayoko.yamamoto@uec.ac.jp

２．研究の枠組みと方法

本研究では，まず，医療施設の配置計画が策定される単位である第二次医療圏から，分析対象となる研究地域を選定する．次に，選定した地域における通院行動データを取得し，統計処理や空間分析に適した形式へ加工する．その後，通院行動の発生量と移動距離に基づいて，通院行動に伴う負担を定量化し，負担値が極端に高い地域を抽出する．抽出された地域については，地理的条件や医療施設の配置状況，交通アクセスなどの要因を多角的に分析し，通院負担の背景にある構造的課題を明らかにする．

３．対象地域の選定

本研究では，地域医療計画の基本単位である第二次医療圏のうち，東京都の北多摩南部地域（武蔵野市，三鷹市，調布市，狛江市，小金井市，府中市の 6 市）を対象として評価を行う．図 1 に北多摩南部地域における小ゾーン分けと総合病院の配置状況を示す．総合病院は第二次医療圏内の中核を担う施設で，診療科の多様性や高度な医療機能を備えており，医療施設配置計画において重点的に扱われる施設であるため，本研究で対象とする．図 1 から明らかなように，北多摩南部地域では総合病院の配置に偏りが見られ，これにより通院の容易さに小ゾーン間で顕著な差が生じていると考えられる．特に医療施設が集中している地域と施設が少ない周辺部との間で，通院行動にかかる負担の格差が生じている可能性がある．このような地域内格差の実態を定量的に把握することは，今後の医療施設配置の見直しや，高齢者の通院支援施策の検討において重要であると考えられるため，本研究では北多摩南部地域を対象地域として選定した．

４．利用データの収集

本研究では，東京都市圏パーソントリップ調査結果から，通院行動に関する以下の 4 項目のデータを抽出し，分析に利用する．

(1) 始点地域：通院行動の開始地点となる地域
(2) 終点地域：通院行動の到着地点となる地域
(3) 交通手段:通院に用いられた交通手段(徒歩, 自転車, 自動車，電車の 4 種類)
(4) 発生量：項目(3)の 4 種類の交通手段ごとの通院行動の発生件数

始点地域および終点地域には，調査で提供されている最も細かい地域区分である「小ゾーン」を用いる．小ゾーンとは，夜間人口約 15,000 人を目安に行政区分に基づいて地域を細分化した単位であり，都市圏内の通院行動の空間的傾向を把握する上で有効である．また，町丁目レベルの境界情報については，2015 年国勢調査で用いられている境界データを参照し，空間的な整合性を確保する．これにより，通院行動の空間的分布と医療施設の配置との関係を高精度に分析することが可能となる．

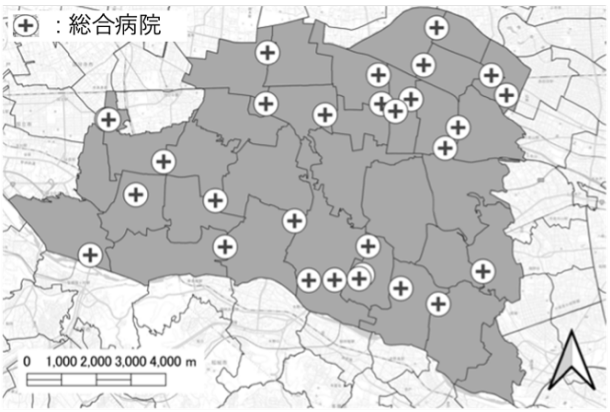


図 1 北多摩南部地域における小ゾーンと総合病院配置

５．利用データの加工

本研究で利用するパーソントリップデータでは，通院行動の始点地域および終点地域について，それぞれ具体的な座標情報を直接取得することができない．そこで，区間の移動距離を算出するための代替手法として，始点地域には人口分布に基づいて重み付けした中心点，終点地域には医師数に基づいて重み付けした医療施設の中心点を設定する．これらの中心点は，それぞれ式(1)により算出し，各地域の空間的特性を反映した座標として用いる．このように人口や医師数といった実態に基づく重み付けを行うことで，通院行動の空間的負担をより現実的かつ精度高く評価することが可能となる．

$$y = \frac{\sum_{i\in\Omega} w_i y_i}{\sum_{i\in\Omega} w_i} \quad x = \frac{\sum_{i\in\Omega} w_i x_i \cos y_i}{\sum_{i\in\Omega} w_i \cos y_i} \qquad (1)$$

Ω: 小ゾーン内の基本単位区集合
x , y: 人口で重み付けした中心点の経度，緯度
x_i , y_i : 基本単位区 $i \in \Omega$の面積の中心点の経度，緯度
w_i: 基本単位区 $i \in \Omega$の人口

例として，本研究の研究対象地域に含まれる狛江市において，式(1)を適用し，人口分布で重み付けした各小ゾーンの中心点を算出した結果を図 2 に示す．図 2 では，狛江市の各小ゾーンの人口を考慮した中心点が地図上に可視化されており，地域内の人口重心を反映した座標設定が行われている．このような中心点の設定により，通院行動における始点地域の空間的な実態をより精度高く捉えることが可能となり，現実的な移動距離の算出が期待される．

人口データについては，国勢調査の結果をもとに，各町丁目単位での人口情報を取得し，分析に利用した．各

小ゾーンにおいては，単純な図形の幾何学的中心点ではなく，人口分布に基づいて重み付けされた位置を中心点として設定していることが確認された．このような人口バランスを考慮した中心点の設定により，地域内の人口密度や居住分布を反映した空間分析が可能となり，通院行動にかかる移動負担の評価においても，より現実的かつ精度の高い結果が得られると期待される．

６．通院行動にかかる負担の定量化

通院行動の移動距離は，始点地域および終点地域の中心点として設定した中心点座標を用いて式(2)により算出する．さらに，交通手段ごとの移動時間の違いを考慮し，距離に対して重み付けを行うことで，通院行動にかかる実質的な負担を評価する．各交通手段の重みの値は，瀬川ら（1996），鈴木ら（2015），矢部ら（2016）の先行研究の成果をもとに設定しており，各交通手段に応じた移動効率の違いを反映している．具体的な 4 種類の交通手段ごとの通院行動の重みづけの値を表 1 に整理して示す．このような重み付けの導入により，単なる距離評価では捉えきれない交通手段の選択による通院負担の差異を，より現実的かつ定量的に把握することが可能となる．

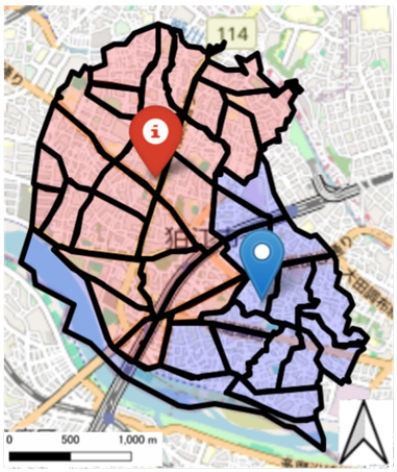


図 2 狛江市の人口分布で重み付けした各小ゾーンの中心点

表 1 交通手段ごとの重み付けの値

交通手段	w_i
徒歩	1.000
自転車	3.710
自動車	7.900
電車	5.805
バス	6.000

$$d = r\,\frac{\arccos(\sin y_1 \sin y_2 + \cos y_1 \cos y_2 \cos(x_1 - x_2))}{w_i} \qquad (2)$$

d: 交通手段を考慮した通院行動の移動距離
r: 地球の半径 $(6.378*10^6\text{m})$
x,y: 通院行動始点，終点地域の中心点座標
w_i: 交通手段ごとに設定した重みの値

さらに，求めた通院行動の移動距離とその区間における通院行動の発生量を用いて，小ゾーンごとに通院行動にかかる負担を式(3)により定量化する．ここで算出される負担値は，通院に伴う移動の物理的・時間的コストを反映した指標であり，地域ごとの医療アクセスの実態を把握する上で有効である．この定量化により，通院負担が特に大きい地域を客観的に抽出することが可能となり，今後の医療施設配置や交通支援施策の検討に資する基礎的な情報を提供する．

$$\sum_{q \in Q'} \frac{f_q}{\sum_{q \in Q'} f_q} d_q \qquad (3)$$

Q': ある小ゾーンでの通院行動の集合
f_q: ある通院行動 q∈Q’ の交通量
d_q: ある通院行動 q∈Q’ の移動距離

７．実験結果

研究対象地域のうち，調布市の小ゾーンごとに通院行動の負担を定量化した結果を表 2 に示す．通院行動の発生量の大小に左右されないように，各小ゾーンの通院行動の発生量で正規化した値をもとに評価する．表 2 から，各小ゾーンによって負担の大きさが異なることが確認できる．特に負担が少ない小ゾーン 5 ではこのゾーン内での通院行動が多く，移動距離が短く抑えられていた．この小ゾーンの総合病院配置を図 3 に示す．図 3 から明らかなように，当該地域には複数の病院が立地し，住民が近隣で医療サービスを受けやすい環境が整っている．これが通院行動負担の軽減につながっていると考えられる．

一方，狛江市の小ゾーンごとに通院行動の負担を定量化した結果を表 3（表 2 と同様な正規化），各小ゾーンと総合病院配置を図 4 に示す．図 4 の南東部に位置する小ゾーン 1 では負担値が約 1.75 と高く，他地域よりも負担が大きいことが明らかとなった．狛江市では総合病院が 1 か所のみで北西部に偏在しており，南東部では周辺に病院がなく，自動車や電車で遠方の医療施設へ通院する必要がある．これが負担増加の要因であると推察される．

以上の実験結果から，調布市では小ゾーン内に複数の総合病院が分散して立地し，住民は居住地から近距離で医療サービスを受けることが可能である．その結果，同一ゾーン内で通院が完結するケースが多く，移動距離が短く抑えられ，通院負担が軽減されている．一方，狛江市では総合病院が市内に 1 か所しか存在せず，しかも北西部に偏在しているため，南東部の住民は近隣に医療機関がなく，遠方の医療施設へ移動する必要がある．これらの結果は，医療施設の立地密度と空間分布が通院負担に与える影響の大きさを示しており，今後の地域医療計画において重要な検討要素となる．

８．結論と今後との研究課題

本研究では，東京都市圏パーソントリップ調査結果から通院行動に関わるデータを抽出し，人口データと組み合わせることで，始点地域および終点地域に中心点を設定し，通院行動にかかる負担の定量化を行った．この分析の結果，付近に総合病院が立地していない地域では，通院行動にかかる負担が相対的に大きくなる傾向が明らかとなった．このことから，各小ゾーンにおける中心点として，始点には人口分布に基づいて重み付けした中心点を，終点には目的地となる総合病院の中心点を設定することで，通院に伴う移動負担を定量的かつ現実的に評価することが可能であるといえる．

一方で，本研究では小ゾーン単位の中心点を用いたため，交通手段による移動経路の相違や実際の道路網の影響を通院行動の負担に十分に反映することができなかった．このため，より細かい空間区分で通院行動の始点を定めるとともに，交通手段別の経路選択を考慮した分析手法の導入が今後の研究課題としてあげられる．これにより，通院支援施策や医療施設配置計画においてより精緻で実態に即した判断材料を提供することが期待される．

表 2 調布市の小ゾーンごとの通院行動にかかる負担の定量化

小ゾーン	総人口	通院行動の総発生量	通院行動にかかる負担合計	通院行動の発生量で正規化した値
1	36,415	2,456	2,231.68897	0.908668
2	33,665	1,054	463.23096	0.439498
3	35,472	902	605.13594	0.670882
4	46,452	1,752	1,779.35311	1.015613
5	36,172	830	175.18939	0.211072
6	54,438	1,108	1,129.66121	1.019550



図 3 調布市の特に負担が少ない小ゾーン 5 の総合病院配置

参考文献

坂田幸繁・栗原由紀子（2023）パーソントリップ調査からみた属性別の職住分布特性の分析．「中央大学経済研究所年報」，**55**，415-435.

鈴木温・鈴木和佳奈・栗田歩（2015）アクセシビリティ指標に基づく保育所待機児童の発生評価に関する研究．「土木学会論文集 D3（土木計画学）」，**71**(5)，I_375-I_385.

鈴木勉（2011）既存施設を活用した都市施設の再配置モデルメディアン型およびカバリング型条件付き施設配置モデルの一般化と統廃合への応用．「都市計画論文集」，**46**(3)，421-426.

瀬川洋子・貞廣幸雄（1996）GIS を利用した保育施設計画立案支援システムの開発．「GIS-理論と応用」，**4**(1)，11-18.

相馬佑成・笹林徹・谷口守(2019)都市特性に着目した通院行動分析．「都市計画報告集」，**18**(3)，234-239.

総務省統計局（2015）平成 27 年国勢調査結果. <https://www.stat.go.jp/data/kokusei/2015/kekka.html>

竹内翔平・恒川和久（2017）パーソントリップ調査を用いた公共施設の立地評価に関する考察：名古屋市を対象として．「建築計画」，**2017**，949-950.

東京都市圏交通計画協議会(2021)第 6 回東京都市圏パーソントリップ調査．<https://www.tokyo-pt.jp/special_6th>

服部晃依・吉川徹・讃岐亮（2023）地方都市と大都市の生活利便性の比較．「都市計画報告集」，**22**(1)，96-102.

矢部努（2016）道路ネットワークの現状 多様なモビリティとそれを支える交通網．48-49.

Satoh, K., Tsukahara, K., Yamamoto, K. (2018) Location evaluation of childcare facilities focusing on transportation in Japanese urban areas. *Journal of Geographic Information System*, **10**(6), 521-538.

表 3 狛江市の小ゾーンごとの通院行動にかかる負担の定量化

小ゾーン	総人口	通院行動の総発生量	通院行動にかかる負担合計	通院行動の発生量で正規化した値
1	30,339	783	1,370.83955	1.750753
2	54,433	3,312	1,748.48496	0.527924

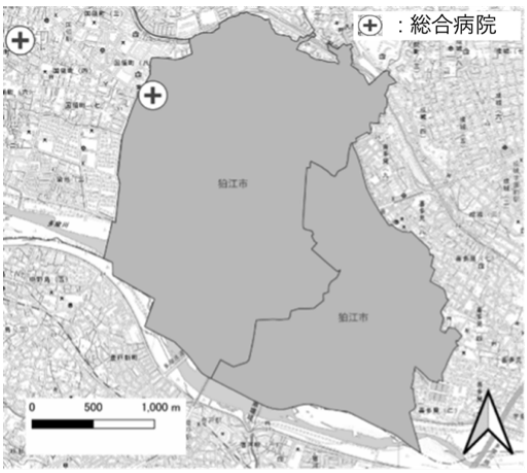


図 4 狛江市における各小ゾーンと総合病院配置