口頭発表

2025年11月1日(土) 11:00 ~ 12:20 | E会場(共通教育棟 A23番教室)

[E2] 移動・交通１

司会：中山 俊

11:00 ~ 11:20

[E2-01] 断面交通量調査に基づく乗客流動推定モデルへの昇降施設における混雑度の組み込み

*福富 洋太[1]、大佛 俊泰[1]、村木 正幸[2]、坂本 千洋[2] (1. 東京科学大学、2. 株式会社日建設計)

11:20 ~ 11:40

[E2-02] 松江市中心市街地におけるコロナ禍前後の人流データ解析

*宮本 彩加[1]、角田 明宝[1]、宮本 藍介[1] (1. アジア航測株式会社)

11:40 ~ 12:00

[E2-03] Classifying Bicycle Sharing Service Stations in Tokyo by Temporal Patterns

*M SANAULLAH KHAN[1], Fumiko ITO[1] (1. Tokyo Metropolitan University)

12:00 ~ 12:20

[E2-04] 動物の移動行動クラスタリングとセンサーネットワークシミュレーション

*川瀬 純也[1] (1. 東京大学情報基盤センター)

©一般社団法人地理情報システム学会

断面交通量調査に基づく乗客流動推定モデルへの昇降施設における混雑度の組み込み

福富洋太*・大佛俊泰・村木正幸***・坂本千洋*****

Incorporating Pedestrian Density at Vertical Transport Facilities into Passenger Flow Estimation Model Based on Detailed Cross-Sectional Traffic Volume Surveys

Yota FUKUTOMI*, Toshihiro OSARAGI**, Masayuki MURAKI***, Chihiro SAKAMOTO***

Abstract: Predicting passenger flow is crucial for mitigating congestion and improving safety when planning railway station upgrades. However, essential data such as origin-destination flows and sectional volumes are typically unavailable during the planning stage. To address this limitation, we developed a passenger flow model calibrated using detailed cross-sectional traffic volume data observed at a railway station in the previous paper. While the model effectively captured macroscopic route choices, it exhibited limited accuracy in estimating microscopic route behaviors. This study enhances the model by incorporating pedestrian density at vertical transport facilities such as stairs, escalators, and elevators, which dynamically affects passenger movement and significantly improves the accuracy of microscopic route choice estimations.

Keywords: 断面交通量調査（cross-sectional traffic volume survey），大規模鉄道駅（large railway station），乗客流動（passenger flow），乗客流動モデル（passenger flow model），改修計画（renovation plan）

１．はじめに

近年，鉄道会社による新線・延伸計画に伴い，大規模な鉄道駅の改修工事が数多く計画されている．鉄道駅の改修計画を策定する際には，混雑緩和や安全性向上の観点から，改修後の乗客流動を事前に予測し，改修案を定量的に評価する技術が不可欠である．しかし，計画段階では，評価に不可欠な改修後の OD 交通量（出発地－目的地間交通量）や断面交通量などのデータが未知であるという根本的な課題が存在する．

筆者らはこれまで，乗客の乗車位置は降車駅の構内プランに強く依存する傾向があることに着目し，各車両扉における乗車人数は改修後も変化しないと仮定することで，各車両扉における降車人数を逆推定する手法を提案した（福富ほか，2024）．この乗車量制約型モデルによれば，駅構内における乗客のマクロな経路選択（ホーム間を結ぶ地下通路と跨線橋の選択など）については高い精度で記述できることが確認された．しかし，ミクロな経路選択（隣接する階段とエスカレータの選択など）については，その予測精度は不十分であった．

本モデルの課題は，昇降施設周辺における混雑状況を考慮していないことにある．加瀬ら(2021)は，階段やエスカレータの混雑度をモデルに組み込むことで，乗客の経路選択行動をより高精度に再現している．このモデルは OD 交通量を制約条件としていることから，筆者らのモデルの制約条件とは大きく異なるもののモデル改良の参考となる．

本研究では，乗車量制約型モデルに昇降施設における歩行者密度を組み込み，ミクロな経路選択の推定精度の向上を図り，その改善の程度を定量的に検証する．

２．分析対象駅と断面交通量調査データの概要

本研究では，都心と郊外を結び，3 路線が乗り入れ，改札内乗り換えが頻繁に行われている，4 面 6 線の A 駅を分析対象とする．A 駅の略図を図 1 に示してある．

A 駅では，図 2 に示す通り，断面交通量調査により，主要な地点（改札機・通路・階段・エスカレータ・エレベータなど）における 1 分単位の方向別の交通量，ならびに全ての車両扉における 1 分単位の乗車人数・降車人

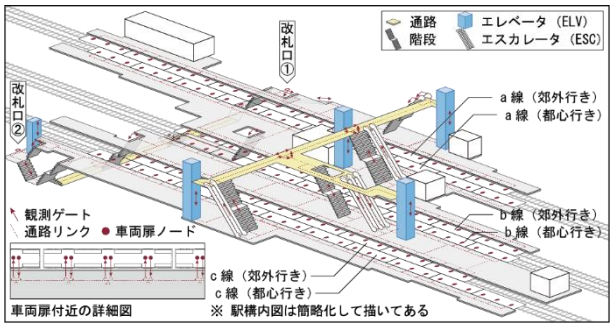


図 1　分析対象とする A 駅の平面概略図

*　学生会員　東京科学大学　環境・社会理工学院　建築学系（Institute of Science Tokyo）
〒152-8550　東京都目黒区大岡山 2-12-1　E-mail：fukutomi.y.786f@m.isct.ac.jp
**　正会員　東京科学大学　環境・社会理工学院　建築学系（Institute of Science Tokyo）
***　非会員　株式会社日建設計　都市社会基盤部門　シビルグループ（Nikken Sekkei L.T.D）

調査日	2022 年 10 月 24 ～ 28 日 ※本稿では 27 日（木）を分析	調査項目 （観測点）	①車両扉の乗降客数　（30×6 箇所） ②昇降設備の断面交通量　（19 箇所） ③通路の断面交通量　（12 箇所） ④改札の断面交通量　（2 箇所） 計 213 箇所
時間帯	7:00 ～ 9:00, 17:30 ～ 18:30（1 分毎）		
調査方法	カメラで録画した映像を後日確認し，目視および数取器を用いた手作業で，各観測点における断面交通量をカウントした	カメラ台数	計 113 台

図 2　断面交通量調査の概要

数が観測データとして得られている．また，すべての観測地点を含む駅構内の移動経路を有向ネットワークで表現し，空間データを構成している．本稿では，これらを原データとした．

3．既存の乗客流動推定モデルの概要

これまでに開発した乗客流動推定モデルは，断面交通量調査データに基づき，車両扉や改札などの出発地－目的地間における移動経路ごとの乗客流動量を推定するモデルである（図 3）．本モデルは主に以下のステップから構成されている．

まず，出発地－目的地間の移動で想定されるすべての移動経路を抽出する．次に，通過するリンクの空間特性に応じて設定した歩行抵抗をリンク長に乗じ，移動経路全体で合計することで移動コストを算出する（図 3(b)）．この時，出発地点が車両扉である場合は，車両内の混雑の影響も考慮する．具体的には，降車人数が一定の閾値を超える場合には，その超過量に比例して移動コストを増加させることで混雑回避行動を疑似的にモデルに組み込んだ．

次に，乗客の経路選択行動を，移動コストを負の効用とみなした多項ロジットモデルで表現する．これにより，各目的地点（改札・車両扉）への移動者の経路選択確率を算出する（図 3(c)）．この経路選択確率を吸収量（目的地点への移動人数）に乗じることで，経路ごとの移動者数を確率的に推定する（図 3(d)）．

最後に，推定した経路ごとの移動者数を集計することで，各出発地点の発生量（出発地点からの移動人数）および各リンクの交通量を推定する（図 3(e)）．

なお，図 3(a)に示す各パラメータは，断面交通量調査から得られた，断面交通量や各出発地点の発生量を正解データとして，誤差関数が最小となるように勾配法を用いて推定する（図 3(f)）．

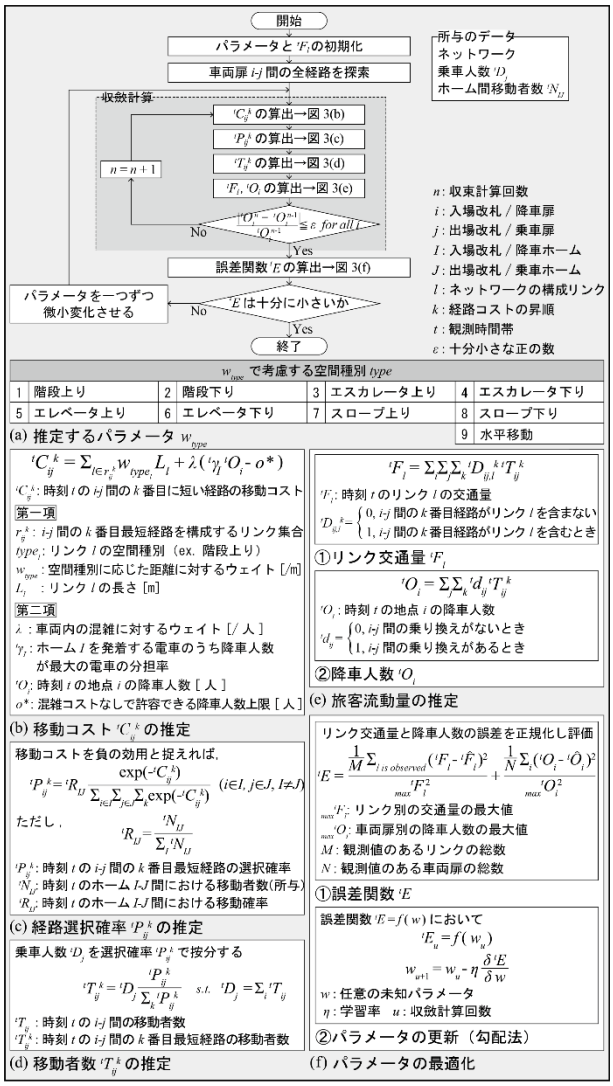


図 3　既存の乗客流動推定モデルの概要

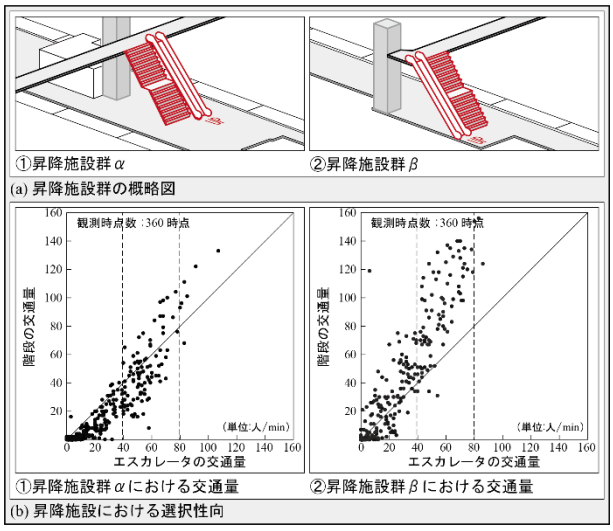


図 4　昇降施設周辺における乗客流動特性

4．昇降施設周辺における乗客流動特性

本章では，A 駅における昇降施設周辺の断面交通量調査データに基づき，ミクロな経路選択の行動特性を明らかにする．図 4 に，A 駅構内において，階段とエスカレータが隣接している 2 箇所（昇降施設群 α, β）の略図と，それぞれの単位時間あたりの断面交通量の観測結果を示してある．

図 4(b)①の昇降施設群 α を見ると，エスカレータの交通量が 40[人/min]以下の時点では，エスカレータが優先的に選択されていることが分かる．一方，エスカレータの交通量が増加するにつれてその選択割合は減少し，80[人/min]以上では階段を選択する割合が増加する傾向が見られる．これらの値は，それぞれエスカレータの片側または両側がほぼ満員となる状態に相当する．すなわ

ち，エスカレータの利用人数が最大輸送人数を超えると，乗客の選択傾向が変化することを示唆している．

一方，図 4(b)②の昇降施設群 β では，エスカレータの交通量に限らず，階段が優先的に選択されている．これは，階段とエスカレータの配置や周辺の動線といった物理的なレイアウトの違いが，混雑に対する乗客の選択性向に影響を与えている可能性を示唆している．

これらの現象は，乗客のミクロな経路選択が，距離や配置といった静的な因子だけでなく，刻々と動的に変化する混雑状況に大きく依存していることを示している．さらに，混雑状況下での選択性向は昇降施設のレイアウトによっても異なる可能性が示唆されたため，移動距離に基づく静的なパラメータのみでは，動的に変化する選択行動を十分に表現することは困難であると考えられる．そこで，本稿では，昇降施設周辺における歩行者密度の影響を乗車量制約型モデルに組み込み，ミクロな経路選択の記述精度の向上を試みる．

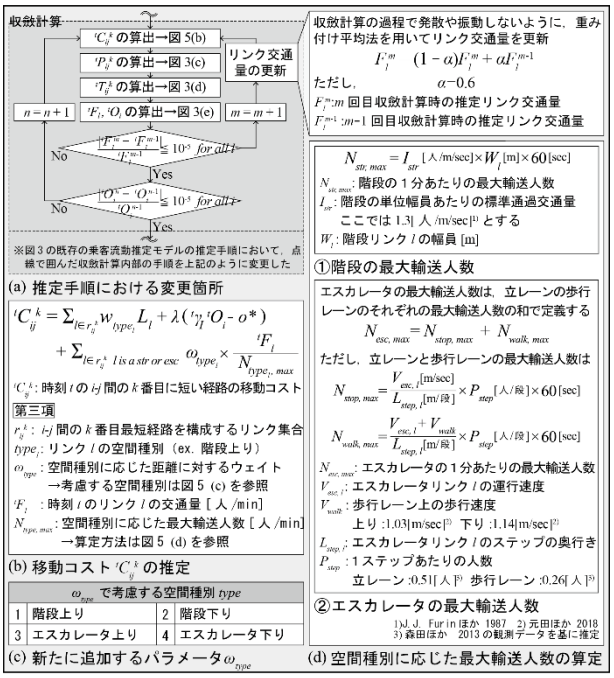


図 5　乗客流動推定モデルの改良の概要

５．乗客流動推定モデルの改良

５.１　改良モデルの概要

鉄道駅を利用する人々は，日常的な移動を通じて得られる総移動距離や総移動時間などの体験に基づき，マクロな経路選択を行っていると考えられる．一方で，「隣接する階段とエスカレータのどちらを選択するか」というミクロな経路選択については，その時々の混雑状況に応じて臨機応変に決定していると考えられる．すなわち，昇降施設周辺における歩行者密度の動的変化を考慮することで，ミクロな経路選択の記述精度を高められる可能性がある．そこで本章では，昇降施設周辺で発生する歩行者密度の動的な変化を移動コストに組み込み，パラメータ値を収斂計算によって推定する方法について検討する．

５.２　歩行者密度を考慮した移動コストの定式化

昇降施設内の歩行者密度の動的変化を考慮したモデルの推定手順を図 5 に示してある．具体的には，移動コストの推定において，既存モデルで用いていた，リンクの空間種ごとの距離に基づく移動コスト（第一項）と車両内の混雑状況に基づくコスト（第二項）に加えて，昇降施設リンクの混雑状況に応じて動的に変化する移動コスト（第三項）を新たに導入する（図 5(b)）．

ここで，混雑度の指標として，リンク交通量を昇降施設の種類に応じた単位時間あたりの最大輸送人数[人/min]で正規化したものを用いる．なお，昇降施設別の最大輸送人数は図 5(d)に示す式で定義される．

本モデルでは，リンク交通量は移動コストに依存して決まるが，図 5(b)に示す式のとおり，移動コストもまたリンク交通量の関数となっている．そのため，あるリンクの交通量が増加し混雑すると移動コストが上昇し，結果としてそのリンクを避けて他の経路が選択されやすくなる仕組みとなっている．

すなわち，リンク交通量と移動コストは相互依存の関係にあるため，推定の際には収斂計算が必要となる．そこで，全てのリンクにおけるリンク交通量の変化量が一定の閾値内（本稿では10^{-5}）に収まるまで収斂計算を行い，平衡状態を与える収束値を求める．さらに，収斂計算プロセスにおける計算値の発散や振動を回避するため，重み付け平均法を用いてリンク交通量を更新する．

５.３　Ａ駅におけるパラメータ最適化と精度評価

図 6(a)に示された発生量の推定結果を見ると，既存モデルと改良モデルのどちらも良好な推定精度を示している．また，表 6(d)の評価指標を見ると，平均二乗誤差は約 21%減少しているものの，他の精度指標は両者の値は大きく異ならない．すなわち，発生量というマクロな乗客流動量を記述する上では，両モデルとも十分な記述能力を有していると言える．

一方で，図 6(b)のリンク交通量では推定結果に改善が見られる．従来モデルのグラフでは過大・過小推計が散見されるが，改良モデルでは全体的にばらつきが小さくなっている．また，図 6(d)の評価指標を見ると，平均二乗誤差は約 34%，平均絶対誤差は約 16%減少しており，補正済み決定係数も 0.031 向上している．さらに，図 6(c)の推定誤差の分布を見ると，階段とエスカレータが隣接している地点における推定誤差は概ね解消されていることが分かる．これらの結果は，昇降施設における歩行者密度という乗客のミクロな経路選択に影響を与える因子を考慮したことで，個々の昇降施設のリンク交通量をより正確に推定できるようになったことを示している．

図 6(e)には，朝のピーク時間帯（7:40～8:40）におけるパラメータの推定値を示してある．階段とエスカレータにおける混雑に対するパラメータ値を比較すると，上りも下りも共通してエスカレータの方が大きい．すなわち，階段とエスカレータが併設されている場合，混雑が激しくなるにつれてエスカレータの移動コストの増加幅が階段のそれよりも大きくなり，その結果，選択性向はエスカレータから階段に推移することを示している．これは，エスカレータの最大輸送人数が階段のそれよりも小さいため，混雑時には利用までの長い待ち時間を避けて階段を選択しようとする人が増えることを意味している．

また，両パラメータの値の「差」を上りと下りで比較すると，「下りの差」の方が「上りの差」よりも大きいことがわかる．すなわち，歩行者密度が増加するにつれて，エスカレータから階段に推移する選択性向は，下りの方が一層顕著に現れることを示している．上り階段よりも下り階段の方が労力的な負荷が小さいため，エスカレータからの遷移が多くなるものと推察される．

６．おわりに

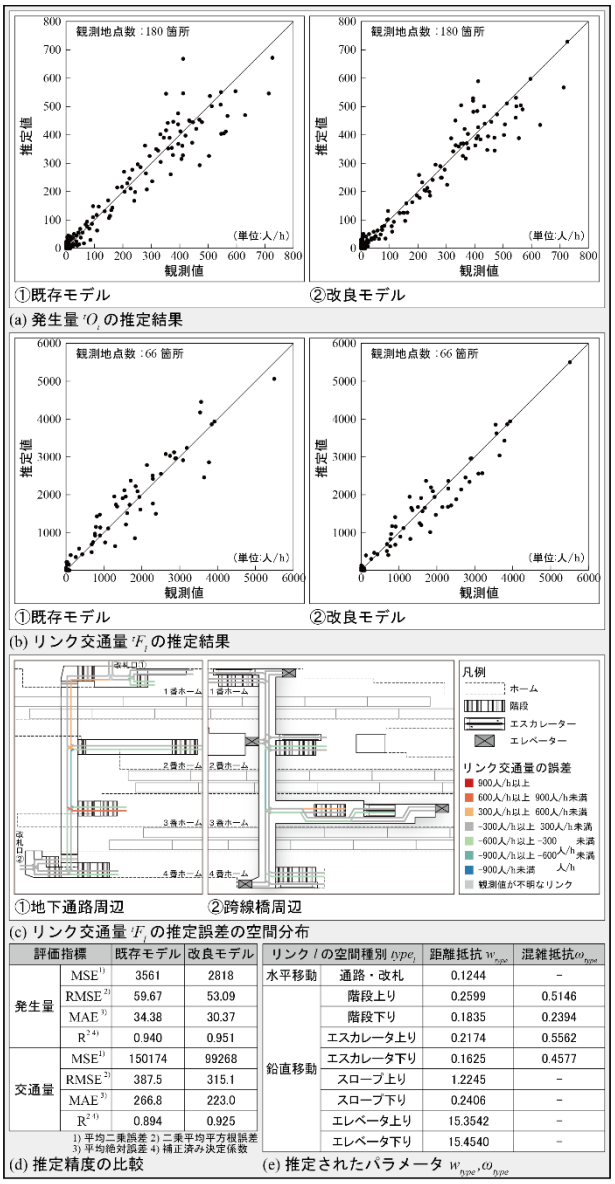
本稿では，これまでに構築した乗車量制約型モデルを改良し，推定精度の向上を定量的に確認した．

まず，昇降施設周辺の断面交通量調査データを分析することで，エスカレータの交通量が増加するにつれて，階段の利用割合が増加するという乗客のミクロな経路選択行動が，その時々の混雑状況に大きく影響されていることを示した．すなわち，移動距離といった静的なパラメータのみでは，動的に変化する選択行動を表現することが困難であることが判明した．

この課題を解決するため，昇降施設周辺の混雑度を移動コストに動的に組み込むことでモデルを改良し，A 駅の断面交通量調査データを用いてパラメータを再推定した．その結果，改良モデルは従来モデルよりも高い決定係数を示し，モデルの推定精度が向上したことが確認された．また，改良モデルによって得られたパラメータから，上り・下りいずれの方向についても，混雑度が増すにつれてエスカレータから階段に利用者が推移する傾向が強く現れることが判明した．

以上より，本研究で提案した改良モデルによれば，駅構内の混雑状況を考慮することが可能となり，個々の昇降施設のリンク交通量を従来よりも正確に推定できることが示された．

ただし，図 4(b)①②を見て分かるとおり，階段とエレベータの位置関係によっても選択性向が異なる可能性がある．今後は，この点に関しても改良を加え，改良したモデルが，構内の空間構造や乗り換え特性の異なる他の鉄道駅においても有効に機能するか否かについて検証する予定である．



評価指標		既存モデル	改良モデル
発生量	MSE[1]	3561	2818
	RMSE[2]	59.67	53.09
	MAE[3]	34.38	30.37
	R^2[4]	0.940	0.951
交通量	MSE[1]	150174	99268
	RMSE[2]	387.5	315.1
	MAE[3]	266.8	223.0
	R^2[4]	0.894	0.925

1) 平均二乗誤差 2) 二乗平均平方根誤差
3) 平均絶対誤差 4) 補正済み決定係数

(d) 推定精度の比較

リンク l の空間種別 $type_l$		距離抵抗 w_{type}	混雑抵抗 ω_{type}
水平移動	通路・改札	0.1244	-
鉛直移動	階段上り	0.2599	0.5146
	階段下り	0.1835	0.2394
	エスカレータ上り	0.2174	0.5562
	エスカレータ下り	0.1625	0.4577
	スロープ上り	1.2245	-
	スロープ下り	0.2406	-
	エレベータ上り	15.3542	-
	エレベータ下り	15.4540	-

(e) 推定されたパラメータ w_{type}, ω_{type}

図 6　A 駅における精度評価

本研究は，東京科学大学研究倫理審査会の承認を受けて実施したものである(承認番号:第 2025116 号).

参考文献

加瀬史朗・佐藤敏彦・坂本圭司 (2021) ホーム上旅客流動の変化を予測できるシミュレーションシステムの開発．「JR EAST Technical Review」，**41**，49-54.

福富洋太・大佛俊泰・岸本まき・村木正幸・坂本千洋 (2024) 断面通行量調査に基づく鉄道駅構内の旅客流動推定モデル．「日本建築学会学術講演梗概集」，**6**，647-648.

元田良孝・宇佐美誠史 (2018) エスカレーター内の歩行に関する基礎研究.「交通工学研究発表会論文集」，**38**，221-225

森田泰智・森地茂・伊東誠 (2013) 駅昇降施設の最大捌け人数に関する研究 －都心駅周辺の急速な都市開発による鉄道駅の激しい混雑への対応に向けて－．「土木学会論文集 D3」，**69**(5)，595-611.

Fruin and John. J. (1987) Pedestrian Planning and Design (rev. ed.). Mobile, Ala.: Elevator World Magazine, Inc.

松江市中心市街地におけるコロナ禍前後の人流データ解析

宮本彩加*・角田明宝・宮本藍介*****

Analysis of People Flow Data in the Central Urban Area of Matsue City Before and After the COVID-19 Pandemic

Ayaka MIYAMOTO*, Meiho TSUNODA**, Aisuke MIYAMOTO***

Abstract: In recent years, human mobility data has become a valuable tool for addressing regional challenges, enabled by the spread of smartphones and digital technologies. In Matsue City, despite efforts to revitalize the central urban area, a major challenge remains the recovery of tourist numbers, which declined during the COVID-19 pandemic. This study analyzes the area by visualizing estimated stay population before and after the pandemic, using mobility data and conversion coefficients. The data is broken down by time, gender, and age group, and presented through graphs and maps to reveal changes and potential contributing factors. The effectiveness of revitalization efforts is also evaluated. Findings indicate signs of recovery in the number of people staying and demonstrate the impact of revitalization efforts. These results may inform traffic planning, tourist hub development, and broader applications including evidence-based policymaking (EBPM) for urban improvement.

Keywords: 人流データ（People Flow Data），GPS データ（GPS Data），可視化分析（Visual Analytics），都市解析（Urban Analysis），施策検証（Policy Evaluation），

１．はじめに

松江市観光白書によれば，観光入込客数は 2019 年に最大値を記録したものの，新型コロナウイルスの影響により急激に減少した．その後，2022 年は回復傾向が見られるものの，コロナ禍以前の状態には届いていない状況である．一方，松江市では中心市街地エリアビジョンを策定し，JR 松江駅から国宝松江城に至るエリアについて，中心市街地の活性化対策を進めているが，コロナ禍による観光客減少の回復が進まないことと，活性化対策の効果を検証する仕組みが整っていないという課題がある．

近年，センサ，カメラ及びスマートフォン等の機器の普及・発展により，様々な場面で人・モノの位置情報が取得しやすくなり，人の移動や滞在に関するデータ（以下「人流データ」）が詳細かつ迅速に取得できるようになった．人流データは交通機関や商業施設における混雑回避などの身近な情報提供サービスや，行政機関における防災・交通・観光といった地域課題への利用など，官民問わず多様な分野で活用されている．

そこで，松江市中心市街地を対象にコロナ禍前後の人流解析を実施し，現状を把握するとともに活性化対策の効果を検証した．

２．人流データの取得

人流データは，計測・集計加工方法によって，カウントデータ，滞留データ，OD データ，移動軌跡データの 4 種類に分けられる．また，データの取得・計測方法には，センサ・カメラにより人を計測する方法，スマートフォンや GPS 端末などのデバイスを使用する方法の 2 通りがある．さらに，デバイスを使用する方法には，位置情報を GPS で取得するものと Wi-Fi アクセスポイントから取得するものの 2 通りがある．

本研究では，道路上や細分メッシュでの滞在人口集計及び，後述する換算係数算出のため，以下に示す 3 種類のデータを取得した．

２.１　流動人口データ

株式会社 Agoop の保有する『ポイント型流動人口データ』（以降，流動人口データ）は，複数のスマートフォンアプリから収集した位置情報のデータである．各ポイントに ID，年月日，時間，緯度経度，GPS 精度（accuracy），移動速度，性別，年代など．28 種類の属性情報が含まれている．

データの取得範囲は図 1 に示す青枠の範囲内とし，取得期間は 2019 年 8 月・9 月・10 月および 2023 年 8 月・9 月・10 月とした．

*　正会員　　アジア航測株式会社（ASIA AIR SURVEY CO LTD.．）
〒215-0004　神奈川県川崎市麻生区万福寺 1-2-2　E-mail：ayk.miyamoto@ajiko.co.jp
**　非会員　　アジア航測株式会社（ASIA AIR SURVEY CO LTD.．）
***　非会員　　アジア航測株式会社（ASIA AIR SURVEY CO LTD.．）

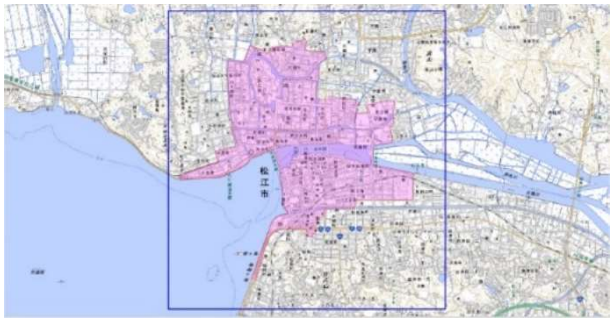


図 1　解析範囲（地理院地図を用いて作成）

2.2　全国人流データ

国土交通省がG空間情報センターに公開している『全国の人流オープンデータ（1km メッシュ）』（以降，全国人流データ）は，株式会社 Agoop の保有する GPS データをもとに，1km メッシュごとに 1 ヶ月間における 1 日当たりの平均を各年月別に集計したデータである．2019 年から 2021 年までの期間のみが公開されているため，2019 年のデータを取得した．

2.3　センサデータ

一般社団法人社会基盤情報流通推進協議会の人流解析専門チームが公開している『松江駅構内人流センサデータ』（以降，センサデータ）は，松江駅構内 17 箇所に設置された人流センサによって，分単位で通過した人数を集計したデータである．17 箇所のセンサのうち改札口のデータを使用した．改札口のデータを使用した理由は，他の箇所のデータは機器の故障によるデータの取得漏れがあったためである．

3．換算係数の算出

流動人口データはスマートフォンの位置情報をアプリから取得するため，スマートフォンを所有していない人や，アプリをインストールしていない人の位置情報を取得できない．そこで，全国人流データを真値とし，流動人口データの各ポイントが何人分に相当するかを計算する換算係数を算出した．なお，全国人流データは 2019 年から 2021 年までしか公開されていないため，2019 年の全国人流データとセンサデータから 2023 年の全国人流データを推計した．

換算係数の算出フローを，図 2 に示す．

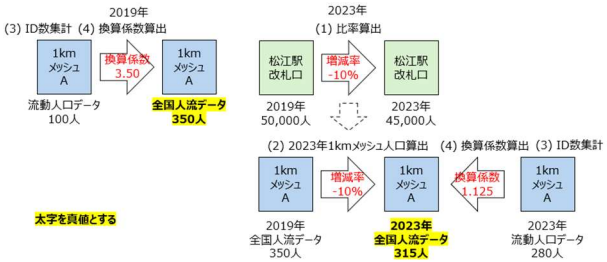


図 2　換算係数算出の概念フロー

換算係数の算出は，1km メッシュごとに解析期間の年月別及び平日／休日別に行った．

まず，センサデータを用いて改札を通過した人数の日平均を求め，図 2 (1) で 2019 年と 2023 年の値を比較し，増減率を求めた．結果を表 3 の赤枠内に示す．

表 3　センサデータ増減率算出結果

平日／休日	年月	センサデータ（人）	年月	センサデータ（人）	(1) 比率（%）
平日	2019年8月	7,162	2023年8月	5,734	0.801
	2019年9月	7,520	2023年9月	5,883	0.782
	2019年10月	7,656	2023年10月	6,491	0.848
休日	2019年8月	7,533	2023年8月	6,810	0.904
	2019年9月	5,513	2023年9月	4,362	0.791
	2019年10月	5,462	2023年10月	5,102	0.934

続いて，(2) で (1) で求めたセンサデータの増減率と 2019 年の全国人流データを用い，2023 年の全国人流データの推定値を算出した．結果を表 5 の緑枠内に示す．

さらに，(3) で流動人口データを用いて 1km メッシュ内の ID 数を集計した．結果を表 4・5 の黄枠内に示す．

最後に，(4) で「全国人流データの月間推定滞在者数／流動人口データ ID 数」を計算し換算係数を算出した．結果を，表 4・5 の赤枠内に示す．

表 4　換算係数算出結果の例（2019 年 8 月）

メッシュコード	平日／休日	月間推定滞在人口（人）	(3) ID数	(4) 換算係数
53331043	平日	14,007	3,098	4.521304
	休日	5,400	1,475	3.661017
53331044	平日	99,666	5,039	19.778924
	休日	42,830	2,304	18.589410

表 5　換算係数算出結果の例（2023 年 8 月）

メッシュコード	平日／休日	日平均滞在人口（人）	暦日	(1) 比率（%）	(2) 月間推定滞在人口（人）	(3) ID数	(4) 換算係数
53331043	平日	667	22	0.801	11,754	11,742	1.001022
	休日	540	9	0.904	4,393	6,286	0.698855
53331044	平日	4,746	22	0.801	83,634	15,456	5.411102
	休日	4,283	9	0.904	34,846	7,386	4.717845

4．データの可視化と解析

流動人口データの各ポイントに換算係数を掛け合わせた値を用いて，データの可視化と解析を行った．

4.1　コロナ禍前後のゾーン別滞在人口の比較

中心市街地エリアビジョンによって設定された 6 つのゾーンを対象に，各ゾーンにおける滞在人口をコロナ禍前後で比較した結果を図 6・7 に示す．

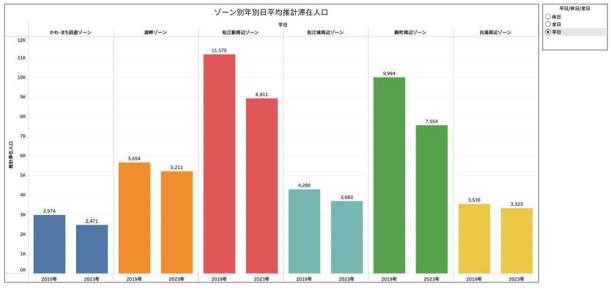


図 6　日平均推計滞在人口（平日）



図 7　日平均推計滞在人口（休日）

平日においては，「松江駅周辺ゾーン」と「殿町周辺ゾーン」はコロナ禍前に比べて 2 割程度減少している．このゾーンには事務所が多く，コロナ禍でのテレワークの普及による労働形態の変化が一部影響しているものと考えられる．一方，「湖畔ゾーン」と「白潟周辺ゾーン」はコロナ禍前の 9 割程度まで回復しており，中でも「白潟周辺ゾーン」の 10 月の推計滞在人口はコロナ禍前を上回っている．また，「かわ・まち回遊ゾーン」や「松江城周辺ゾーン」もコロナ禍前の 8 割強まで回復している．

休日においては，全体的にコロナ禍前の 8 割以上にまで回復しており，中でも「湖畔ゾーン」と「白潟周辺ゾーン」はほぼコロナ禍前の状況となっている．「殿町周辺ゾーン」を除く他のゾーンもコロナ禍前の 9 割弱の状況となっている．

以上から，各ゾーンにおける滞在人口は，平日および休日ともにコロナ禍前の状態に回復しつつあると考えられる．

4.2　活性化対策の効果検証

老舗和菓子屋の彩雲堂では，2023 年に職人商店街創出支援事業の補助金を受けて天神町の店舗を改装した．この効果検証のため，図 8 に示す彩雲堂を中心とした 25m メッシュ 4 メッシュを対象に，滞在人口をコロナ禍前後で比較した．結果を表 9 に示す．

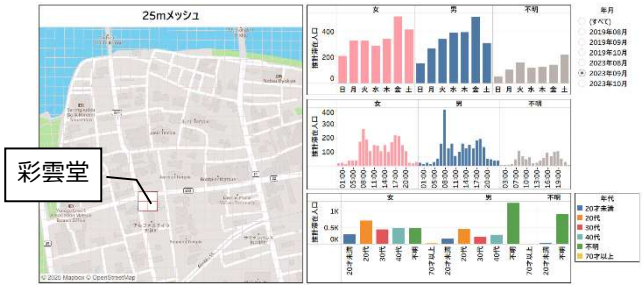


図 8　彩雲堂を中心とした 4 メッシュの滞在人口
（2023 年 9 月）

表 9　彩雲堂を中心とした 4 メッシュの滞在人口
（2023 年 9 月）

年月	9時台	10時台	11時台	12時台	13時台	14時台	15時台	16時台	17時台	総計（人）
2019年8月	218	406	339	198	238	148	298	351	316	2,512
2019年9月	219	253	299	202	261	218	335	319	233	2,339
2019年10月	180	164	253	108	217	217	344	181	362	2,026
2023年8月	381	364	461	347	351	383	679	720	1,169	4,855
2023年9月	375	308	276	257	283	308	304	382	466	2,959
2023年10月	336	283	481	418	345	449	495	514	869	4,190

彩雲堂の開店時間である 9 時から 18 時までの時間において，コロナ禍前後の滞在人口を比較すると，8 月と 10 月のコロナ禍後の滞在人口は，コロナ禍前の滞在人口の約 2 倍となっている．

松江市では，8 月に花火大会である「水郷祭」，10 月には松江神社の例大祭である「松江祭鼕行列」などが開催されるため，これらのイベントが滞在人口の増加に影響したと考えられる．一方で，9 月においても約 1.3 倍の滞在人口の増加が見られることから，活性化対策による効果が見受けられる．

4.3　新たな観光拠点の検討

2023 年 9 月 9 日から 11 月 30 日にかけて，松江市市街地を流れる京橋川沿いに期間限定で「松江ウォーターテラス」がオープンした．松江ウォーターテラスは川沿いに設けられた屋外のテラス席であり，近隣飲食店でテイクアウトした飲食物を食べることができるほか，夜にはライトアップされる．テラスが新たな観光拠点として設定できるかを検討するため，図 10 に示す範囲を対象に，居住地別の推計訪問者数を曜日ごとに比較した．結果を図 11 に示す．



図 10　松江ウォーターテラスの位置
（地理院地図を用いて作成）

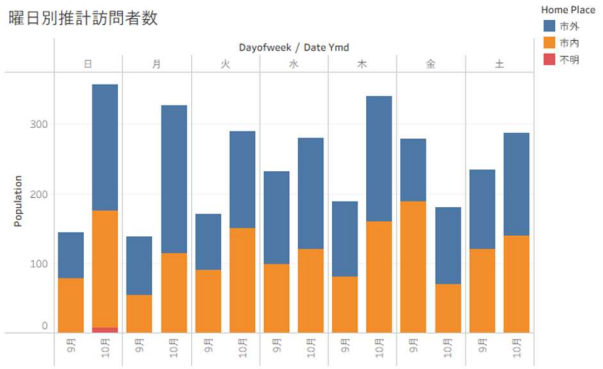


図 11　曜日別推計訪問者数

曜日別の傾向としては，日曜日・月曜日における 10 月の訪問者数は 9 月の 2 倍以上，火曜日・木曜日は 1.5 倍以上となっている．日曜日・月曜日においては，10 月は 3 連休があることから，市外から訪れた観光客が多いためと考えられる．また，火曜日・水曜日においては，ランチ等の利用があったためと考えられる．

以上から，松江ウォーターテラスには市内居住者のみならず，市外の観光客を含めた集客効果があったと考えられる．また，テラスの周辺は空き店舗があるため，空き店舗に出店する事業者に対する補助であるチャレンジショップ支援事業を活用して，特に飲食店の誘致を行い店舗の充実を図ることで，テラス周辺を新たな観光拠点として設定できる可能性がある．

4.4　更なる活用

2023 年 8 月から 10 月までの道路上の推計滞在人口を，交差点で分割した単位で，性別・年代別，性別・時間帯別にグラフで可視化した結果を図 12・表 13 に示す．



図 12　道路上の滞在人口
（2023 年 8 月 5 日）

表 13　道路上の滞在人口割合
（2023 年 8 月 5 日 19 時）

年代	男性（%）	女性（%）	不明（%）
20歳未満	9.80	12.75	0.10
20代	11.00	21.10	0.03
30代	3.94	9.46	0.01
40代	4.31	6.53	0.00
70才以上	0.22	0.00	0.00
不明	4.02	4.36	12.36

水郷祭開催日時である 2023 年 8 月 5 日 19 時において，滞在人口の年齢・性別の傾向は，20 代女性が約 21%と最も高く，20 代未満女性が約 13%，年齢・性別ともに不明が約 12%，20 代男性が約 11%と続く．

これにより，例えば店舗のオーナーが水郷祭の日にどの年代・性別の人が何時ごろ何人くらい店舗の前を行き来するかを把握でき，開店閉店の時間や販売商品の検討が可能になる．また，5 月から 9 月にかけて月 1 度開催される「土曜夜市」やプロバスケットボールチーム「島根スサノオマジック」のホームゲーム等のイベント開催日の前後の人の移動状況から，歩行者誘導に伴う新たな施策の実施に向けた検討のエビデンスとしての活用できる．

5．考察及びまとめ

コロナ禍前後の人流解析を実施した結果，滞在人口がコロナ禍前の状態に回復しつつある現状の把握や，イベント開催時における来訪者の属性・移動傾向の分析，中心市街地活性化対策の効果検証が可能となった．分析結果は Tableau Public 上で一般公開されており，自治体職員のみならず市民や事業者と連携した活用が期待される．

今後，イベント開催時の交通誘導計画や新たな観光拠点開発等のエビデンスはもとより，よりよいまちづくりのための EBPM（Evidence-based Policy Making）での活用にも期待が持てる．また，分析結果を用いて検討した施策を実施した場合の効果検証には，継続的にデータを蓄積し，可視化を続けることが必要と考える．

謝辞

本研究は「松江市 3D 都市モデル整備業務委託」の業務成果の一部である．ここに記して関係者各位に謝意を表す．

参考文献

国土交通省不動産・建設経済局（2021）．オープンデータ（人流データ）定義書．＜https://www.geospatial.jp/ckan/dataset/mlit-1km-fromto/resource/e2083495-8095-4119-a865-e5c22e6a7eee＞．

国土交通省不動産・建設経済局情報活用推進課（2024）．地域課題解決のための人流データ利活用の手引き（Ver1.2 版）．＞ https://www.mlit.go.jp/tochi_fudousan_kensetsugyo/chirikukannjoho/content/001733098.pdf＞．

松江市（2022）．令和 4 年版松江市観光白書（本編）．＜https://www.city.matsue.lg.jp/material/files/group/27/R4_honpen.pdf＞．

松江市（2025）．松江市 中心市街地活性化基本計画．＜https://www.city.matsue.lg.jp/material/files/group/21/4kikeikaku.pdf＞．

東京における自転車シェアサービスポートの時系列パターンによる分類

カーンサナウラ*・伊藤史子**

Classifying Bicycle Sharing Service Stations in Tokyo by Temporal Patterns

M Sana Ullah Khan1, Fumiko ITO2

Abstract: This research examines the spatial and temporal usage patterns of Bicycle Sharing Services, including Docomo Bike Share and Hello Cycling, in Tokyo using high-resolution station-level data collected over one week at 15-minute intervals. The study employed Principal Component Analysis and identified four dominant temporal patterns, such as commuting peaks on weekdays and leisure flows on weekends. Three distinct clusters were identified using PCA scores for each BSS station: (i) central city residential–industrial commuter origins, (ii) downtown commercial and transit-oriented destinations, and (iii) peripheral residential and suburban local-use stations. The study found a significant association between cluster membership, land use districts, and proximity to a train station using cross-tabulation and the Chi-square test. The spatial distribution of BSS station with cluster membership was examined by mapping. This research, by linking BSS temporal demand characteristics with urban fabric, provides new insights into the integration of BSS within multimodal transport planning.

Keywords: Bicycle Sharing Service (BSS)（自転車シェアリングサービス）, Micromobility Services（マイクロモビリティサービス), Clustering Analysis（クラスタリング分析）, Spatial Analysis（空間分析）

1. Introduction

The rising population densities and rapid urbanization have exacerbated different challenges for different global megacities, such as air pollution (Deshpande & Mishra, 2007) and traffic congestion ((Busari et al., 2021). Bicycle Sharing Services (BSS), in response to these challenges, emerge as an essential component of a multimodal transportation network. This micromobility service, BSS, mitigates the “last mile” and “first mile” issue (Kealy & Wu, 2021) and promoting active transportation to reduce the dependence on private vehicles. BSS has rapidly spread worldwide and become a popular mode of micromobility services (Todd et al., 2021).

However, the efficiency and sustainability of BSS depend on understanding the spatiotemporal usage pattern (Song et al., 2024) which are dynamic and shaped by numerous urban elements. Especially investigating how demand varies temporally and distinguishing between weekday commuting peaks and weekend leisure usage is vital for optimizing BSS operations and infrastructure planning (Xu et al., 2018). The recent BSS system produce location and time specific data, which enables research on each station and the mobility behavior (Beecham & Wood, 2014).

Different studies in the past have investigated the usage pattern and demand (Kim, 2024; Toro et al., 2020; Xie & Wang, 2018) and a few of the studies used clustering to understand the type of BSS stations based on their usage on weekdays and weekends. In particular, the link between temporal demand patterns and their surrounding urban context, such as proximity to a train station and land use, remains unexplored. To address this research gap, the study is required to integrate temporal demand analysis, statistical clustering, and spatial interpretation, an approach this research adopts.

Despite the increase in the popularity of BSS, various studies have examined the temporal demand patterns of spatial station distributions. This research aims to explore the temporal pattern of individual stations on weekdays and weekends. Using 15-minute, individual BSS station data to identify distinct temporal patterns in the case of Tokyo by using two most popular BSS in Japan, Docomo Bike Share and Hello Cycling. This study also examines the statistical relationship between these clusters, proximity to train station and land use districts. Later, this research maps the BSS stations and analyzes the spatial distribution of BSS, revealing the broader urban structure of BSS usage.

2. Temporal Variation of BSS

This research utilizes open data from the bike share map website regarding BSS (Bicycle Sharing Services). For this research, data from both popular BSS Hello Cycling and Docomo Bike Share were used, comprising one week of data in

*学生会員　東京都立大学都市環境科学研究科（Tokyo Metropolitan University）
〒192-0397　東京都八王子市南大沢 1-1
Tel. 080-9001-0888　E-mail: [plnrsanaullahkhan@gmail.com]
**正会員　東京都立大学都市環境科学研究科（(Tokyo Metropolitan University）

October 2023, collected at 15-minute intervals from 7:00 AM to 11:00 PM. The data was filtered to retain valid records, and the data from both BSS services (Hello Cycling and Docomo Bike Share) were merged. Subsequently, the net bike change was calculated. The Net bike change was calculated by subtracting the number of available bikes from the previous interval using a Python Script. The Net bike change is defined as the difference in the number of available bikes at the docking station between two consecutive time intervals. If the value of the Net bike change is positive, it means more bikes were returned to the docking station than were taken. However, if the net bike change is negative, it indicates more bikes were taken from the docking station than returned.

3. Classification of BSS by Temporal Patterns (Weekdays vs. Weekends)

3.1. Methodology

This study employed Principal Component Analysis (PCA). Before running PCA, a scree plot was constructed to show eigenvalues, guiding the selection of the number of PC components. The PCA was conducted with four components to generate eigenvalues, cumulative variance, explained variance ratios, and scores for all BSS stations (IDs). The extracted PCA loadings were used in identifying peak time slots across weekdays and weekends for each PC component. Using these loadings, a loading-time plot was created for each PC component (07:15–23:00), which helped in naming them based on their behavior across time on weekdays and weekends. This research aims to determine the type of BSS stations used by Ward's hierarchical clustering based on PCA scores. A dendrogram was created, and based on linkage distance, the number for k was selected. After confirming the k value, ward clustering with a k value of 3 was employed, and a t-SNE visualization of the BSS stations in a 2-dimensional space was generated. To understand the behavioral pattern of each cluster across time on weekdays and weekends, a figure was created showing the mean net bike change of each cluster over time on weekdays and weekends (7:00 to 23:00).

3.2. Results

3.2.1. Principal Component Analysis (PCA)

Figure 1 shows the scree plot indicating a sharp decline in eigenvalue from the first to the fourth component. The scree flattening technique, also known as the elbow test, was used to select the number of components to minimize noise.

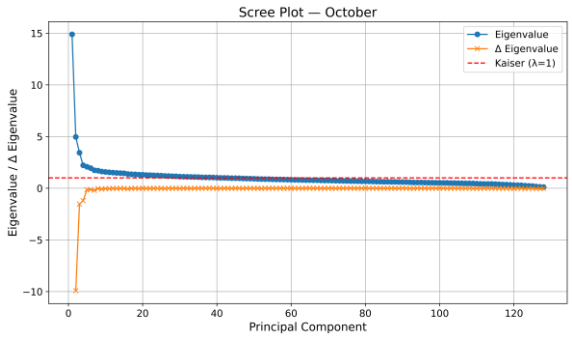


Figure 1: Scree plot for determining the number of principal components

Table 1 below shows the eigenvalues, explained variance ratios, and cumulative explained variance. Components were assigned after analyzing Figure 2, which shows the loading across time on weekdays and weekends for each component.

Table 1: PCA eigenvalues, explained variance ratios

PC	Eigen value	Explained Variance Ratio	Component Name
PC1	14.878	0.1162	Commuting Flow (AM Outflow - Inflow)
PC2	4.9589	0.0387	Morning Activity Peak and Evening Peak
PC3	3.4289	0.0268	Evening inflows and Midday outflow
PC4	2.2209	0.0173	Midday Utilization

As shown in Figure 2a, PC1 on weekdays exhibits significant negative loadings (morning peak, 7:15-9:00), indicating the start of the commute trip, and significant positive loadings (evening peak, 18:00-21:00), indicating the end of the commute trip. The pattern remains almost the same on weekends; the morning shows the start of the trip (outflow), while the afternoon and evening reflect inflows. Similarly, Figure 2b, PC2 on weekdays, captures positive loadings in the early morning (08:00 to 10:00) and late evening (20:00 to 23:00), indicating bike returns during the start and end of the day. While (17:00 to 20:00) shows a significant outflow of bikes, it shows the beginning of the last trip of the commute. On the weekend, the early morning (7:15 to 11:00) shows the outflow of trips, while the afternoon and evening trip shows the trips for leisure activities. Figure 2c shows a similar trend on both weekdays and weekends for PC3. Early morning and evening time (20:00 to 23:00) shows inflow, while negative loadings throughout the day indicate trips for daily activities. Figure 2d, PC4 on weekdays between 11:00 and 14:00 shows significant positive loading, indicating bike use for short trips during lunch

breaks or errands. On weekends, it shows a mixture of positive and negative loadings from afternoon to evening.

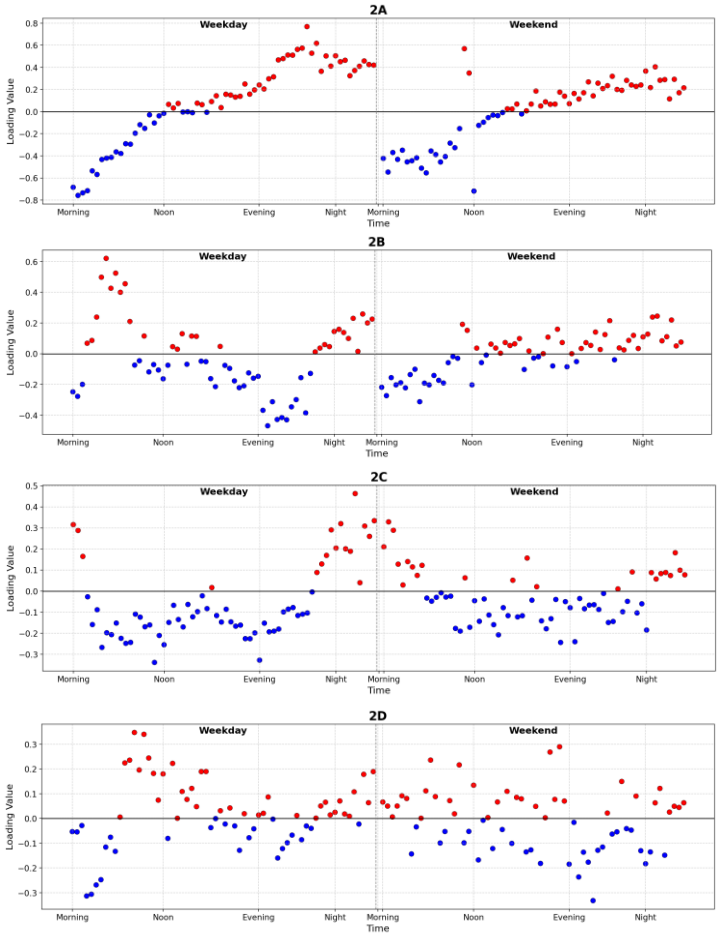


Figure 2: PCA loadings versus time on weekdays and weekends

3.2.2. Clustering Analysis

Later, Ward's hierarchical clustering method was employed using PCA scores. Based on which three distinct clusters at a meaningful linkage distance were selected. The majority of BSS stations (n = 2,750) are in Cluster 2, while Clusters 0 (n = 209) and 1 (n = 248) represent smaller but behaviorally distinct groups.

3.2.3. Cluster Visualization and Temporal Profile

Figure 3 below was created using the mean net bike change of each cluster across time intervals on weekdays and weekends. Cluster 0 on weekdays shows a significant negative mean net bike change in the morning (7:15 to 9:00) and a significant positive mean net bike change in the evening (18:00 to 21:00), confirming the commute start and end trip. Cluster 1 exhibits an opposite trend to Cluster 0, characterized by significant inflow in the early morning (7:15 to 9:00) and significant outflow in the evening (18:00 to 21:00) on weekdays and weekends. This indicates that the user commutes to work by bike, using those in cluster 0, and parks them in the station located in cluster 1. On weekends, Clusters 0 and 1 both show peaks indicating the start and end of the first trip to leisure or daily activities. While Cluster 2 indicates only slight fluctuation throughout the day or balanced inflow and outflow trips.

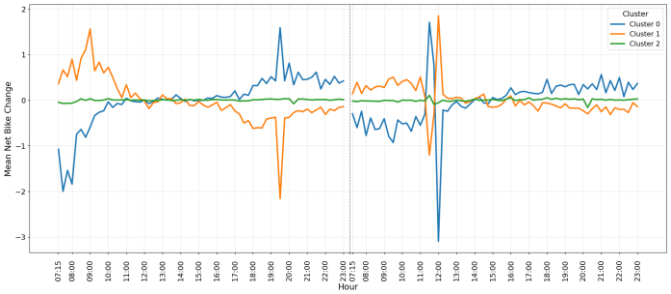


Figure 3: Mean net bike change profiles of clusters

4. Urban Spatial Characteristics of BSS Clusters

4.1. Methodology

Once assigning cluster numbers to each BSS station, cross-tabulations and Chi-Square Tests of Independence (performed in SPSS) were employed to investigate the association between cluster membership and two factors: (i) land-use district category (residential, commercial, industrial), and (ii) train station proximity (≤800 m vs. >800 m). To understand the spatial distribution of BSS across Tokyo, the final clusters with station ID were mapped using GIS as shown in Figure 5.

4.2. Results

4.3. Association of Cluster with Land Use District and Train Station Proximity

After cluster analysis, cross-tabulation, and a chi-square test were employed to confirm the statistical association between clusters and land use district categories and proximity to train stations. Figure 4 below shows the cluster membership with land-use categories and train station proximity, revealing that both factors have statistically significant associations with cluster membership (land use: $\chi^2 = 175.056$, df = 4, $p < .001$, Cramer's V = 0.165; station proximity: $\chi^2 = 25.446$, df = 2, $p < .001$, Cramer's V = 0.089). As shown in Figure 4, most stations in this cluster 0 are in Tokyo's downtown area, which explains the significant morning outflow and evening inflow on both weekdays and weekends (as shown in Figure 3). These BSS stations serve the residents of the inner city, especially those living in mixed-use areas and in proximity to a train station (as shown in Figure 4, where 82.3% of stations are within an 800m distance). Therefore, Cluster 0 is serving as the *Central City Residential-Industrial Commuter Stations*.

Cluster 1 is also situated mainly in the downtown area of Tokyo. However, it exhibits an opposite temporal trend to Cluster 0 (as shown in Figure 3), with a significant inflow in the morning (at the end of the first trip) and outflow in the evening

(at the start of the last commute trip). The analysis also revealed that 62.1% of the stations are in commercial land use districts and 89.9% within 800m proximity of the train station. This cluster serves as a *Downtown Commercial and Transit-Oriented Destination*. However, Cluster 2 is spread across Tokyo, dominating the outer edges of the Tokyo Metropolitan Area. As shown in Figure 4, most stations (52.7%) are in residential land use districts. The use of BSS stations or the inflow and outflow of Cluster 2 is lower than that of Clusters 0 and 1. This might be due to short or local trips. Cluster 2 serves as *Peripheral Residential and Suburban Local Use*.

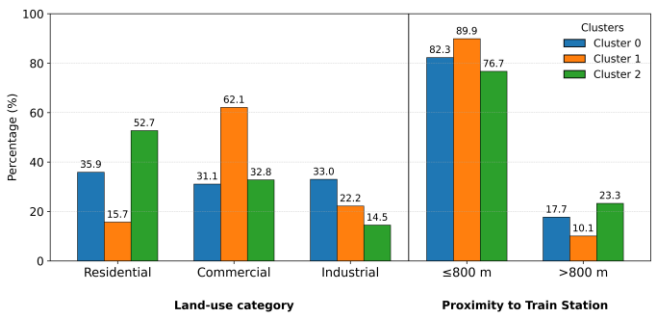


Figure 4: Cross-tabulation of clusters with land-use category and train station proximity

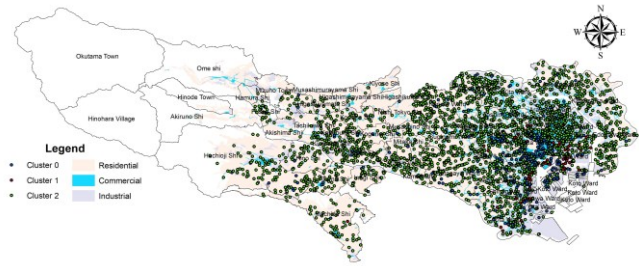


Figure 5: Spatial distribution map of BSS station across Tokyo

5. Conclusion

This research employed Principal Component Analysis (PCA), Clustering Analysis, and Chi-square test on Bicycle Sharing Service (BSS) data. PCA and clustering revealed three distinct BSS station types in Tokyo. Cluster 0 serves as a central city residential, industrial, and commuter origin. Cluster 1 serves as downtown commercial and transit-oriented destinations. Cluster 2 serves as peripheral residential and suburban local-use stations with stable, short trips.

Chi-square tests confirmed a significant relationship between clusters, land use district (residential, commercial, and industrial), and train station proximity (≤800m and >800m), while spatial mapping reinforced these patterns. These findings address a significant research gap by taking each BSS station into account and explicitly linking the temporal demand patterns of BSS stations with their urban context, including land use and proximity to transit. The data used in this research is at 15-minute intervals, meaning that some short inflow/outflow events may not be fully captured; however, the extensive coverage ensures robust and reliable results. In addition, this research utilizes data from the Autumn (October) season only; future research can compare different seasons to determine whether the BSS stations exhibit a similar pattern across different seasons on weekdays and weekends, and whether their cluster membership remains the same or changes.

References

Beecham, R., & Wood, J. (2014). Exploring gendered cycling behaviours within a large-scale behavioural data-set. *Transportation Planning and Technology*, *37*(1), 83-97.

Busari, A., Loto, R., Ajayi, S., Odunlami, O., Folake, A., Kehinde, O., & Olawuyi, O. (2021). Ameliorating urban traffic congestion for sustainable transportation. IOP Conference Series: Materials Science and Engineering,

Deshpande, A., & Mishra, P. (2007). Urbanization, air pollution and human health. *J. Environ. Res. Dev*, *1*(3).

Kealy, A., & Wu, J. (2021). Safety Challenges and Solutions in Bike-Sharing Systems. 2021 IEEE 18th International Conference on Mobile Ad Hoc and Smart Systems (MASS),

Kim, K. (2024). Discovering spatiotemporal usage patterns of a bike-sharing system by type of pass: a case study from Seoul. *Transportation*, *51*(4), 1373-1407.

Song, R., Jiang, J., & Guo, X. (2024). Analysis of Behaviour Pattern of Bicycle-sharing Users Based on Complex Network: a Case Study of Beijing Downtown Area. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *48*, 437-444.

Todd, J., O'Brien, O., & Cheshire, J. (2021). A global comparison of bicycle sharing systems. *Journal of Transport Geography*, *94*, 103119.

Toro, J. F., Carrion, D., Brovelli, M., & Percoco, M. (2020). Bikemi bike-sharing service exploratory analysis on mobility patterns. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *43*, 197-203.

Xie, X.-F., & Wang, Z. J. (2018). Examining travel patterns and characteristics in a bikesharing network and implications for data-driven decision supports: Case study in the Washington DC area. *Journal of Transport Geography*, *71*, 84-102.

Xu, X., Ye, Z., Li, J., & Xu, M. (2018). Understanding the Usage Patterns of Bicycle‐Sharing Systems to Predict Users' Demand: A Case Study in Wenzhou, China. *Computational intelligence and neuroscience*, *2018*(1), 9892134.

動物の移動行動クラスタリングとセンサーネットワークシミュレーション

川瀬純也*

Spatiotemporal Movement Clustering and Sensor Network Simulation of Animals

Junya Kawase*

Abstract: This study demonstrates the potential of animal wearable sensor networks and aims to efficiently expand their coverage area by evaluating the data collection performance of delay-tolerant networking (DTN) through simulations based on actual animal movement data. GPS trajectories of dairy cows were collected over 111 consecutive days and analyzed using spatiotemporal movement clustering. Based on the clustering results, simulations were conducted assuming data delivery and collection via DTN, and the coverage area and coverage ratio of the sensor network were compared. In scenarios where individuals were selected across clusters, the results were largely consistent with those of biased selection scenarios, but the risk of complete data collection failure was reduced.

Keywords: 移動行動クラスタリング（spatiotemporal movement clustering），カバー面積（coverage area），動物装着型センサー（animal wearable sensor）

１．はじめに

野生動物に様々なセンサーデバイスを携行してもらうことで，人間では容易に侵入することができない自然環境の情報や，野生動物同士の接触履歴を知ることができ，社会の様々な場面での活用が期待できる．森林や山地に富んだ日本の自然環境下では，記録したデータを動物自らが運搬し，他のデバイス装着個体と遭遇した際にそのデータを共有し，これを繰り返すことで数珠つなぎにデータを伝播・回収する“遅延耐性ネットワーク”（DTN）という技術の利用が想定されている（Kobayashi et al., 2018）（図 1）．

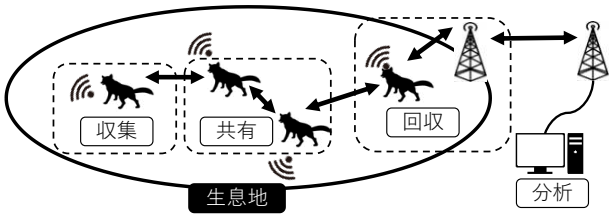


図 1　野生動物 DTN のコンセプト

限られたデバイス装着個体数で，効率的にセンサーネットワークがカバーする面積を広くするためには，異なる群れの間を行き来するような個体や，他の個体に接触する機会が多いような個体にセンサーデバイスを携行してもらうことが理想的だと考えられる．しかし，デバイス装着個体の選択やそれによって変化するセンサーネットワークのカバー面積について，実際の動物の移動行動データを用いた実験や評価を行った先行研究はない．

そこで本研究では，自由に昼夜放牧されている家畜の GPS データを用いて，その移動行動をクラスタリングするとともに，各クラスター間を行き来するような個体を効率的に選択する手法について検討を行い，実際に DTN が構築されていた場合を想定してセンサーネットワークがカバーする面積について評価を行った．

２．使用した GPS データ

本研究では，北海道のある牧場において，夏季期間，自由に昼夜放牧されている雌の乳牛の GPS データを用いた．放牧地の概略図を図 2 に示す．放牧地の広さは約 40 ha，高低差は最大で約 150 m．東側の低い場所に牛舎が置かれている．

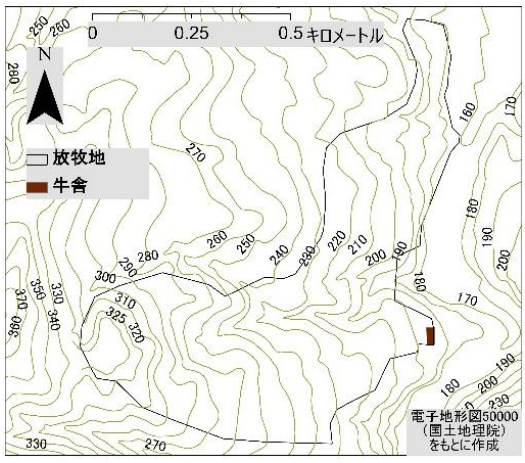


図 2　放牧地の概略図

GPS ログは牛の首に装着したロガーにより 20 分ごとに記録され，無線通信で収集される．牛の体勢や樹木等

*　正会員　　東京大学情報基盤センター（Information Technology Center, the University of Tokyo）
〒277-0882　千葉県柏市柏の葉 6-2-3　E-mail：j.kawase@ds.itc.u-tokyo.ac.jp

の影響により GPS ログが記録・収集できなかった場合は，そのまま欠損として扱った．使用したロガーは GlobalSat 社の LT-520 で，牛用の首輪を用いて装着した．GPS の測位タイミングは，ロガーの設定や首輪の取り付けとメンテナンスの影響を受け，全てのロガーで一致させることはできなかった．本研究では，2023 年 6 月 16 日から 10 月 4 日の連続した 111 日間において，データを十分に回収できた 21 頭の雌の乳牛を対象とした．

牛たちは午前 6 時ごろと午後 3 時ごろの 1 日 2 回，搾乳や管理のため，放牧地から牛舎に自ら戻るように馴致されており，まれに戻らない個体がいる場合は，農家の人によって誘導される場合もある．また放牧地には雄の乳牛が 2 頭放牧されており，行動を共にしている．

3．移動行動クラスタリング手法の概要

3.1　配列アライメントを用いた移動行動クラスタリング手法の関連研究

本研究では，移動行動のクラスタリングには配列アライメント手法を用いた．もともとはバイオインフォマティクスにおいて，DNA などの配列の類似した領域を特定する際などに用いられる手法であるが，時空間行動分析と近い分野での例として，日常行動を対象とした日記調査の分析への援用が挙げられる（Wilson, 1998; Wilson et al., 1999）．観光者の GPS データを対象とした例（Shoval and Isaacson, 2007），動物園などの限られた空間での観覧者を対象とした例（矢部, 2010; 川瀬・伊藤, 2016）などがある．動物の移動行動に同様の手法を使用した例は見られないが，類似した手法として，野生動物の移動行動データを文字列化して最長共通部分列（LCSS）を用いてクラスタリングを行い，動物種間の違いを明らかにした研究などがある（Gao et al., 2016）．いずれにしても，毎日繰り返され，しかし同じではない移動行動を，一定期間ごとに区切ってクラスタリングを行い，さらに期間全体でのクラスタリングを行い，活用しようというような例はみられない．

3.2　移動行動の文字列化

午前 6 時からの 24 時間を 1 日のサイクルと捉え，20 分ごとに滞在したエリアを表す文字を並べて，1 日の移動行動を文字列として表す．ある 20 分間の GPS ログが欠損している場合は空白（indel）として扱った．

人間の移動行動を対象とした分析の場合は，対象エリアの形状や機能をもとにエリア分けがなされるが，放牧地では同様の手法をとることができない．そこで，多くの GPS ログが記録された各々の地点が，その日の乳牛の行動の特徴を表していると仮定し，その日の全ての GPS ログをプロットしてカーネル密度推定を行い，密度の頂点から作成したボロノイ図を文字列化のためのエリア分けとした（図 3）．エリア分けは 111 日間それぞれで作成した．20 分ごとに各 GPS ログが位置するエリアを表す文字あるいは空白を表す indel を順番に並べてゆき，24 時間当たり 72 文字の文字列でもって 1 日の移動行動を表した．36 文字以上が indel となる場合は，その個体の 1 日全体を欠損として扱った．

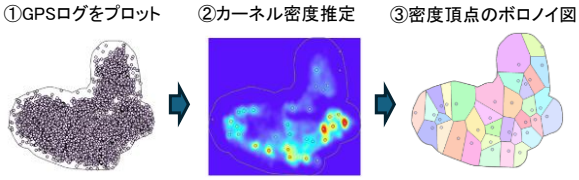


図 3　エリア分けの作成手順イメージ

3.3　配列アライメントの実行

配列アライメントの計算には R パッケージ TraMineR（Gabadinho et al., 2011）を用いた．ある文字列を別の文字列に変換する際の編集操作のコストを計算する Levenshtein 距離の概念をもとにした Optimal matching のアルゴリズムを用いた．エリア分けをもとに，同じ文字の場合は「2」，隣接するエリア同士の置換の場合は「1」，indel との置換の場合は「1」，それ以外の置換の場合を「0」とし，文字列間の類似度を計算した．最後に階層的クラスタリングを行い，樹状図を得た．

1 日ごとにクラスタリングを行い，さらにそのクラスタリング結果 111 日分を並べて文字列とし，111 日分の期間全体でのクラスタリングを行った．1 日全体が欠損となった個体は，当該日の 1 日ごとのクラスタリングの対象からは除外し，期間全体でのクラスタリングでは当該日のクラスタリング結果を indel として扱った．

4．クラスタリング結果

4.1　1 日ごとのクラスタリング結果の例

ある 1 日のクラスタリング結果によって得られた樹状図を図 4 に，クラスターごとに分けて描画した時空間パスを図 5 に示す．この時空間パスでは，地表面を午前 6 時とし，1 分ごとに 1 m の高さを取るように移動軌跡を描画している．この例では，特に 1 日の前半と後半の違いに着目することで，クラスターごとに移動行動の特徴の違いを見て取ることができる．

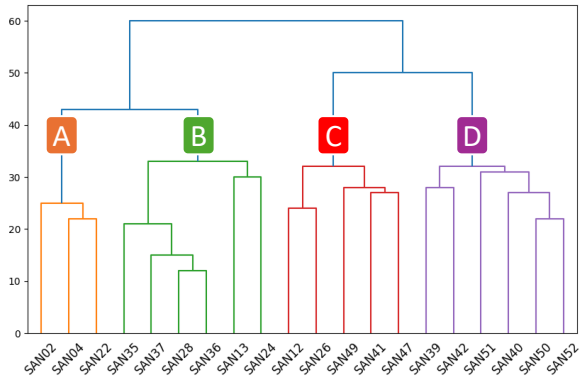


図 4　クラスタリング結果の樹状図の例

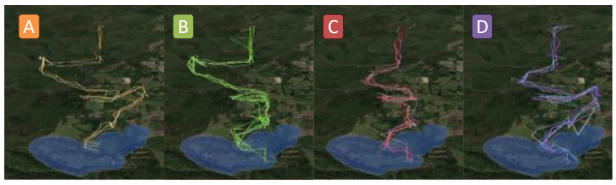


図 5　クラスタリング結果ごとの時空間パスの例

4.2　期間全体でのクラスタリング結果

111 日間の期間全体でのクラスタリング結果の樹状図を図 6 に示す．図中，左端の 2 個体は 1 日全体での欠損が多く含まれていることがわかった．図 7 に 111 日間全体での文字列の一部を示す．1 行ごとが各個体を表し，1 日ごとのクラスタリング結果が左から右に順に並んでいる．1 列が 1 日ごとの結果を表しており，期間全体での結果を参考に，その日のクラスターごとに彩色している．この結果から，多くの日で移動行動を共にしているクラスターを得ることができたことが示唆された．

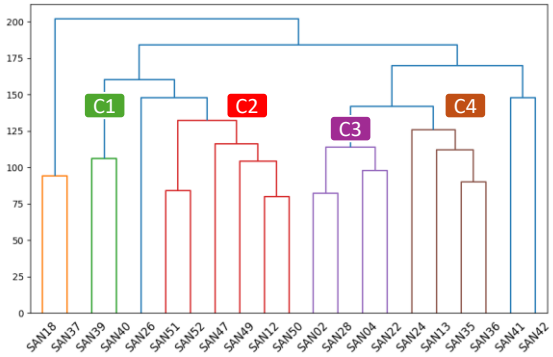


図 6　期間全体でのクラスタリング結果の樹状図

ID	全体	6/16	6/17	6/18	6/19	6/20	6/21	6/22	6/23	6/24	6/25	6/26	6/27	6/28	6/29	6/30	7/1
SAN18																	
SAN37		c1	c1	c2	c1	c3	c3	c3	c2	c1	c2	c2	c1	c1	c2	c2	c2
SAN39	C1	c3	c2	c1	c2	c3	c3	c3	c1	c3	c2	c2	c2	c1	c2	c1	c4
SAN40	C1	c1	c2	c2	c2	c3	c5	c2	c1	c2	c2	c2	c2	c1	c3	c1	c4
SAN26		c2	c1	c1	c1	c2	c0	c3	c2	c0	c1	c2	c2	c1	c2	c2	c3
SAN51	C2	c1	c3	c2	c1	c3	c0	c3	c1	c3	c2	c2	c1	c1	c4	c2	c4
SAN52	C2	c3	c3	c1		c3	c1	c3	c1	c1	c1	c2	c1	c1	c4	c2	c4
SAN47	C2	c3	c1	c2	c2	c3	c5	c3	c2	c1	c2	c1	c2	c1	c2	c1	c3
SAN49	C2	c3	c1	c2	c2	c2	c5	c2	c2	c1	c1	c2	c2	c0	c4	c2	c3
SAN12	C2	c3	c3	c1	c2	c3	c2	c3	c2	c1	c2	c2	c2	c1	c4	c2	c3
SAN50	C2	c3	c3	c1	c2	c2	c5	c3	c2	c1	c1	c2	c1	c1	c1	c2	c4
SAN02	C3	c1	c2	c2	c1	c1	c3	c1	c2	c3	c2	c3	c1	c1	c2	c1	c1
SAN28	C3	c1	c2	c2	c1	c1	c4	c3	c2	c3	c2	c3	c1	c1	c2	c1	c2
SAN04	C3	c1	c2	c2	c1	c1	c4	c1	c2	c3	c2	c3	c1	c1	c4	c1	c1
SAN22	C3	c1	c2	c2	c1	c1	c4	c1	c2	c3	c2	c1	c2	c1	c1	c1	c1
SAN24	C4	c1	c2	c2	c1	c1	c2	c1	c2	c2	c2	c3	c1	c1	c2	c1	c2
SAN13	C4	c1	c3	c2	c1	c1	c3	c1	c2	c1	c2	c3	c2	c1	c2	c2	c2
SAN35	C4	c1	c1	c2	c1	c1	c1	c1	c2	c1	c2	c3	c2	c1	c4	c1	c2
SAN36	C4	c1	c1	c2	c1	c1	c3	c1	c2	c3	c2	c3	c2	c1	c2	c1	c2
SAN41		c1	c1	c2	c2	c1	c0	c3	c2	c1	c2	c1	c1	c1	c2	c1	c3
SAN42		c2	c3	c1	c2	c3	c5	c2	c0	c1	c2	c2	c2	c1	c3	c2	c4

図 7　111 日間のクラスタリング結果を並べた文字列の一部

5．DTN がカバーする面積のシミュレーション

実際の GPS データをもとに，乳牛たちに装着したデバイスによって DTN 型のネットワークが構成されている場合を想定し，センシング，データの伝播・回収のシミュレーションを行い，センサーネットワークがカバーする面積を推定する．一部の個体のみで DTN が構成される場合を想定し，個体の組み合わせによってセンサーネットワークがカバーする面積がどのように変化するかを評価する．4 章の移動行動クラスタリングにより得られた各クラスターを参考に，DTN を構成する個体を選択した場合と，それと反するように個体を選択した場合との結果を比較した．

5.1　シミュレーションの設定

本研究では，シミュレーションは 1 分単位で進行し，1 日単位（午前 6 時から翌朝午前 5 時 59 分）で評価するものとした．GPS ログの欠損部分は，存在する GPS ログ間を直線でつなぎ，ログ間の時間差で直線を等分することで，1 分単位で補間した．これは，収集された GPS ログの測位タイミングが必ずしも一致しないことへの対応も含んでいる．

各デバイスは平面距離で 30 m 以内に 1 分以上継続して位置する場合に通信が可能であるとした．なお，データ量にかかわらず通信が可能であればデータの送受信が完了するものとした．1 日に 2 度，基本的に全ての個体が牛舎に集まることを考慮し，牛舎があるエリアから平面距離で 100 m の範囲では通信が行えないものと設定した．

5.2　シミュレーションの進行

①シミュレーションは 1 分 1 ターンごとに進行し，通信範囲内に位置する個体を抽出する．②1 つ前のターンから継続して通信範囲内に位置した個体同士は通信が成功したとみなし，それまでに収集した観測データを共有する．③次のターンに遷移する前に，フィールドでの観測が行われ，観測データ（本研究では，デバイスの ID，時刻，座標のみ）が追加される．④これを繰り返し，最終ターンまでに固定ノードに到達した観測データを「回収したデータ」とする．なお，固定ノードは実際にロガー回収用のゲートウェイが設置されている位置とし，通信可能範囲は 30 m に設定した．

5.3　「回収したデータ」の評価

放牧地全体を 25 m × 25 m のグリッド（図 8）でわけ，「回収したデータ」が位置するグリッドを「回収できたグリッド」とみなす．このグリッドを集計し，各シナリオを以下の項目で評価する．なお，GPS ログがひとつも記録されていないグリッドは評価対象の全体数から除外した．

1. 回収できたグリッドの数
2. 全個体を対象とした DTN によって回収できたグリッド数を 100 とした場合のカバー率

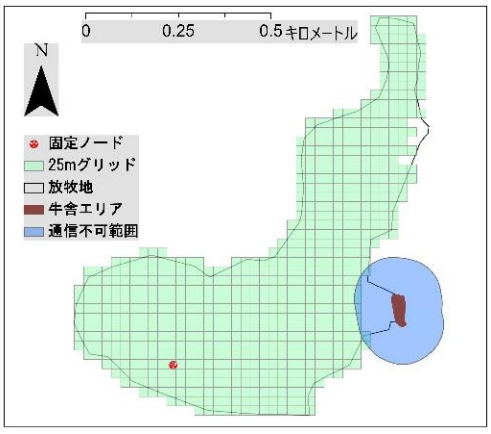


図 8　評価用 25 m × 25 m グリッド

5.4　DTN 構成個体選択シナリオの設定

21 個体のうち，欠損の多い 2 個体を除いた 19 個体を対象とすることとした．なお，19 個体のみで 4 章と同様のクラスタリングを再度行ったが，得られる結果は変わらなかった．次に，111 日間のうち，19 個体のいずれかでも 1 日全体の欠損が含まれる日は評価の対象外とした．そして，19 個体のいずれもが固定ノードの 30 m 以内に接近せずに，データを回収できなかった日も評価の対象外とし，111 日間のうち 62 日分を評価の対象とした．

クラスタリング結果から，C1（2 個体），C2（6 個体），C3（4 個体），C4（4 個体）からそれぞれ 1 個体ずつ選び，残る 3 個体を加えた全 7 個体で構成する DTN を想定し，192 パターンでシミュレーションを行った（シナリオ A）．比較対象として，似通った移動行動の個体たちに偏ってしまった場合を想定し，C2・C3・C4 のうち 2 つのクラスターから 7 個体を選択した 248 パターンのシミュレーションを行った（シナリオ B）．

5.5　シミュレーション結果

シミュレーション結果の集計結果を箱ひげ図で図 9 に示す．回収できたグリッド数およびカバー率のどちらについても，最大値，平均値，中央値，四分位範囲などでシナリオ A が上回ってはいるがその差はわずかであった．

各シナリオにおいて，回収できたグリッドが 0 だったパターンの数を表 1 に示す．シナリオ B の方が，回収できたグリッド数が 0 であったパターンが含まれる日数が明らかに多い．各クラスターから個体を選択したシナリオ A の方が，固定ノードまでデータを運んでくれる個体が含まれる確率が高くなり，データ回収が失敗するリスクを低減できる可能性が示された．

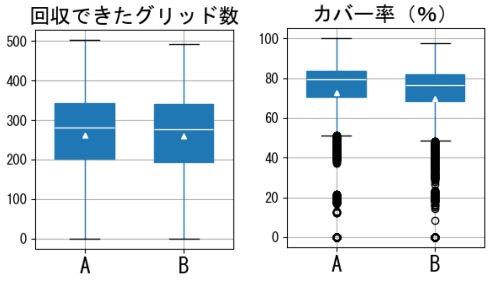


図 9　シナリオ A および B の結果比較

表 1　回収できたグリッドが 0 だったパターンの数

	6月				7月							
	18日	24日	29日	30日	5日	10日	13日	16日	17日	22日	23日	31日
シナリオA		6		16	160		144		24			160
シナリオB	1		1		80	1	157	1	9	248	248	80

	8月							9月				計
	1日	2日	17日	20日	26日	29日	31日	12日	17日	18日	20日	
シナリオA					144			32			45	731
シナリオB	1	8	8	16	157	9	1	8	1	8	16	1059

おわりに

本研究では，野生動物装着型 DTN がカバーする面積を効率的に広くすることを目的に，自由に昼夜放牧されている家畜の GPS データを用いて，その移動行動をクラスタリングし，DTN を構成する個体の選び方でカバーする面積がどのように変化するのかをシミュレーションして評価を行った．

提案手法において各クラスターから個体を選択するだけでは，カバーする面積を効率的に広くできるとは言えなかった．しかし，データ回収が失敗するリスクを低減できる可能性が示された．

今後は，期間全体でのクラスタリング方法の再検討やシミュレーションの評価方法の再検討を行っていくとともに，現実的な野生動物 DTN の運用方法に沿ったセンサーデバイス装着個体選択方法を検討していく．

謝辞

本研究は，JSPS 科研費 JP23K12323 の助成を受けたものです．また本研究成果の一部は，データ活用社会創成プラットフォーム mdx を利用して得られたものです．

参考文献

川瀬純也・伊藤史子（2016）対象者の状態を加味した配列アライメントによる時空間行動分析手法の提案と分析 - 歩行速度と観覧対象との距離を活用した観覧行動類型化手法の提案 - .「地理情報システム学会講演論文集」，**25**，E-6-1.

矢部直人（2010）GPS データに対する配列解析の援用.「地理情報システム学会講演論文集」，**19**，181-190.

Gabadinho, A., Ritschard, G., Müller, N.S. & Studer, M. (2011) Analyzing and visualizing state sequences in R with TraMineR. *Journal of Statistical Software*, **40**(4), 1-37.

Gao, P., Kupfer, J. A., Zhu, X., & Guo, D. (2016) Quantifying animal trajectories using spatial aggregation and sequence analysis: a case study of differentiating trajectories of multiple species. *Geographical Analysis*, **48**(3), 275-291.

Kobayashi, H. H., Nakagawa, K., Makiyama, K., Sasaki, Y., Kudo, H., Niraula, B., & Sezaki, K. (2018) Animal-to-animal data sharing mechanism for wildlife monitoring in Fukushima exclusion zone. *Multimodal Technologies and Interaction*, **2**(3), 40.

Shoval, N., & Isaacson, M. (2007) Sequence alignment as a method for human activity analysis in space and time. *Annals of the Association of American geographers*, **97**(2), 282-297.

Wilson, W. C. (1998) Activity pattern analysis by means of sequence-alignment methods. *Environment and Planning A*, **30**(6), 1017-1038.

Wilson, C., Harvey, A., & Thompson, J. (1999) ClustalG: Software for analysis of activities and sequential events. *IATUR conference proceedings*.