

# 位置ベース SNS を通した群衆の移動経験に基づく 都市空間の近接性分析

若宮 翔子<sup>1,a)</sup> 李 龍<sup>1,2,b)</sup> 角谷 和俊<sup>1,c)</sup>

受付日 2012年12月20日, 採録日 2013年4月5日

**概要:** 今日の都市における交通ネットワークの複雑化や人々の活動領域の拡大などにより, 都市空間での近接性は単に地理的な距離だけでなく移動時間や訪れる頻度によって歪んでおり, あらゆる場所間の近接関係を直感的に測ることが困難である. そのため, ユーザの目的ごとに距離や時間などの観点から都市空間での近接性の歪みを考慮して近接したところを容易に探せるようにする必要がある. 本研究では, 経験的・社会的な観点から生じる空間の歪みによる都市地域の複雑な近接関係を抽出するために, 位置ベース SNS を通した群衆の移動経験に基づく地域間の近接性分析手法を提案する. 具体的には, 都市空間での膨大な群衆のライフログが簡単に得られる Twitter を用いて実空間における群衆の移動経験を観察し, 市区町村を単位とした地域間の近接性を測定し, 都市空間における地域クラスタ間の空間的な歪みを分析する. 実験では, Twitter における群衆のライフログと社会調査の一環として地域間の移動量を集計したパーソントリップ OD 量データを用いて群衆の移動経験を抽出し, 移動距離, 移動時間, 移動量の観点で測定した地域クラスタ間の近接性を比較する. また, 日常生活における規則的な移動に関する調査結果であるパーソントリップ OD 量データと比べ, Twitter のデータを用いた群衆の移動経験では, より多様な目的の移動経験を中心とした地域クラスタ間の近接性を観察することが可能であることを示す.

キーワード: 都市分析, 近接地域, 群衆ライフログ, Twitter

## Urban Proximity Analysis with Crowd Movements Based on Location-based Social Networks

SHOKO WAKAMIYA<sup>1,a)</sup> RYONG LEE<sup>1,2,b)</sup> KAZUTOSHI SUMIYA<sup>1,c)</sup>

Received: December 20, 2012, Accepted: April 5, 2013

**Abstract:** Due to the growing complexity of urban areas by sophisticated transportation network and dramatically expanding area of human activities, urban areas are conceptually distorted in terms of moving time and familiarity, consequently making it difficult to intuitively comprehend the overall distortion of urban areas. Hence, it is critical to support user's urban exploration considering the dynamic nature of the urban areas. In this work, in order to figure out and utilize the distortion of urban space, we propose a method to analyze urban proximity based on location-based social networks. In particular, we observe crowd movements through Twitter, which can provide lots of crowd's daily moving activity logs, for the purpose of deriving the distorted urban image as an index map. In the experiment, we examine the availability of Twitter as a source to observe crowd movements to analyze distortion of urban space, in comparison to person trip OD (Origin-Destination) data, which is a social survey to investigate people's movements between urban areas. Finally, we will show the significant benefit of Twitter utilization for crowd movement observation, particularly reflecting on a variety of human activities which cannot be easily acquired with the conventional social investigations.

**Keywords:** urban analysis, vicinity areas, crowd lifelogs, Twitter

## 1. はじめに

近年、都市における交通ネットワークの複雑化や人々の活動領域の拡大などにより、都市空間における近接性は、単に地理的な距離だけでなく移動時間や訪れる頻度によって歪んでおり、あらゆる場所間の近接関係を直感的に測ることは困難である。実際に、遠隔地であるにもかかわらず、高速鉄道を利用して短い時間で移動することができるため近く感じたり、多くの人々が訪れているために近く感じたりすることや、あるいは近隣であるにもかかわらず、交通が不便で移動時間がかかるために遠く感じたりするといった都市空間の歪みが生じており、簡単に把握することは難しい。このような場所間の近接性は、都市空間における人々のさまざまな活動における重要な判断の基準となる。そのため、ユーザの目的ごとに距離や時間などの観点から都市空間での近接性の歪みを考慮して近接したところを容易に探せるようにする必要がある。特に、なじみのない都市における近接性を把握することができれば、旅行計画を立てるときや引っ越し先を決めるときなどの個人の地理的な意思決定の場面で有用とされるだけでなく、都市計画やマーケティングなどの場面においても有益な情報になると思われる。

一般的に、空間的な歪みは、その都市で生活したり、その都市を訪れたりすることによって把握することができる。また、ウェブ上のオンラインマップや電車移動時間情報などを参照することによってある程度は間接的に調べることができる。しかしながら、個人がすべての都市を訪れることは困難である。一方、その都市で実際に生活したり、活動したりしたことがある人々の経験を借りることができれば有用であると考えられる。従来、都市地域における社会調査の1つとして、人々の移動や都市交通の実態を調べることを目的としたパーソントリップ調査<sup>\*1</sup> (PT調査)が行政主導のもと実施されてきた。このPT調査では、ある都市地域で生活している人々の交通行動の起点(出発地)、終点(到着地)、目的、利用手段、行動時間帯などを含む1日の詳細なトリップデータを調査し、その結果を用いて、地域間の移動量や利便性などを分析している。パーソントリップOD量データは、日常生活における規則的な移動に関する調査結果であるため、通勤・通学のような目的を中心とした移動でしか地域クラスター間の近接性を把握することができない。さらに、PT調査には、多大な時間とコストがかかり、調査者だけでなく、自分の1日の行動

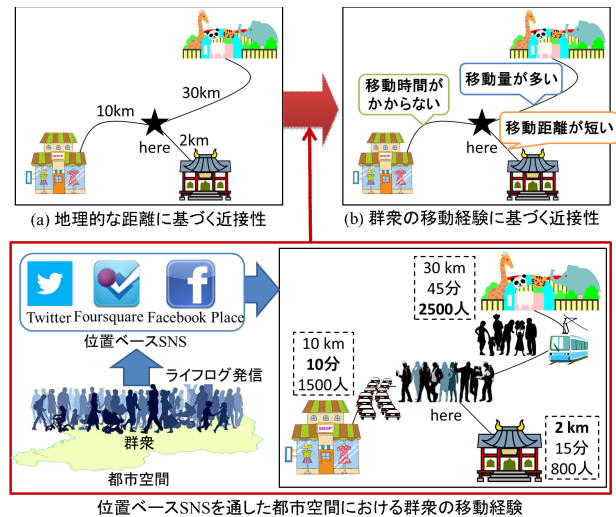


図 1 群衆の移動経験を用いた都市空間の近接性分析  
 Fig. 1 Proximity analysis between urban areas using crowd experience on movements.

を振り返りながら質問票を埋めていく回答者にとっての負担も大きい。さらに10年に1度といった頻度でしか実施されておらず、現在提供されている最新のデータは平成12年度のものである。

都市空間における歪みを動的に把握するためには、多様な人々の実際の場所間の移動距離、移動時間や移動量を知る必要がある。そのために、近年普及しているソーシャルネットワークにおいて共有されている群衆のライフログを活用することができると考えられる。特に、モバイル端末を通して実空間における場所に関連した位置情報付きのライフログを取得することが可能であるため、都市空間で活動している人々の移動経験を容易にモニタリングすることができる。実際に、Twitter<sup>\*2</sup>やFoursquare<sup>\*3</sup>のような位置ベースSNSでは、これまでにない規模の人々の実空間での経験を含む大量のライフログが共有されており、ユーザID、時間情報、位置情報などのメタデータを分析することによって、移動を含むさまざまな群衆の経験を抽出することが可能である。

本研究では、都市空間における地域間の複雑な近接関係を抽出して空間的な歪みを把握するために、位置ベースSNSを通した群衆の移動経験に基づく地域間の近接性測定手法を提案する。これにより、たとえば、図1(a)のように特定の場所からの地理的な距離を示している従来の周辺地域ガイドに対し、ソーシャルネットワークから取得した群衆の移動経験を通して、図1(b)のように地理的な近接地域だけでなく、移動時間がかからずアクセスしやすいという点で近接している地域や、多くの人々が訪れるという点で近接している地域を発見することが可能になる。具体

<sup>1</sup> 兵庫県立大学  
 University of Hyogo, Himeji, Hyogo 670-0092, Japan  
<sup>2</sup> 情報通信研究機構  
 National Institute of Information and Communications  
 Technology, Soraku, Kyoto 619-0289, Japan  
 a) ne11n002@stshse.u-hyogo.ac.jp  
 b) lee.ryong@gmail.com  
 c) sumiya@shse.u-hyogo.ac.jp

<sup>\*1</sup> パーソントリップ調査：  
<http://www.mlit.go.jp/crd/tosiko/pt.html>  
<sup>\*2</sup> Twitter: <http://twitter.com/>  
<sup>\*3</sup> Foursquare: <https://foursquare.com/>

的には、Twitterにおける群衆のライフログを用いて抽出した群衆の移動経験とパーソントリップOD量データを用いて抽出した群衆の移動経験に基づく地域クラスタ間の近接性をそれぞれ測定して比較する。また、日常生活における規則的な移動に関する調査結果であるパーソントリップOD量データに比べ、Twitterの群衆ライフログを用いた場合には、より多様な目的の移動経験に基づく地域クラスタ間の近接性を観察可能であることを示す。

本稿の構成は次のとおりである。まず、2章において、本研究のアプローチと関連研究について述べ、3章では、Twitterを通した群衆の移動経験と比較対象として用意したパーソントリップOD量データに基づく群衆の移動経験に基づく地域間の近接性測定手法について具体的に説明する。4章では、2種類のデータセットを用いて近接性を測定し、それぞれの近接性に基づき生成した近接地域マップを比較した結果についてまとめる。5章で今後の課題について議論し、最後に、6章でまとめと今後の展開について述べる。

## 2. Twitterを通した群衆の移動モニタリングによる都市空間の近接性分析

本章では、Twitterに代表されるソーシャルネットワークから取得可能な大量の群衆のライフログデータの活用可能性を確認するために、都市空間における群衆の移動経験に基づく地域間の近接性分析のアプローチを2.1節で述べ、2.2節で関連研究をまとめる。

### 2.1 本研究のアプローチ

本稿では、ソーシャルネットワークにおけるデータの新しい価値を示すために、人々のライフログから得られる移動データを用いて測定される地域間の近接性とパーソントリップOD量データを用いて測定される地域間の近接性を比較する。ここで、Twitterの位置情報付きツイートと比較対象とするパーソントリップOD量データの特徴を表1にまとめる。Twitterのジオタグ付きツイートは、実際に人々の活動を通して得られるものであるため、時間の遅れなどといったデータの正確性の問題や多くのノイズが含まれているという欠点が存在する。その反面、多様な人々の経験を大規模に（いつでも、どこでも）取得することができるため、たとえば、去年の今ごろ、大阪で雨が降った平日の人々の経験を借りたいというように、ユーザの要求に応じたコンテキストで人々の経験を再利用することが可能であるという利点がある。このようなデータを経験としてまとめることで、場所間の関係を知るために利用することができ、本研究で着目している空間の歪みを把握することも可能になる。また、パーソントリップOD量データのみでは量的にカバーできない部分をカバーすることができるという点でも優れている。

表1 パーソントリップOD量データとTwitterのジオタグ付きツイートによる群衆移動モニタリングの特徴比較

Table 1 Crowd movements using person trip OD data vs. crowd movements using geo-tagged Tweets over Twitter.

	従来の社会調査 パーソントリップOD量調査による 群衆移動モニタリング	本研究 Twitterのジオタグ付きツイートによる 群衆移動モニタリング
対象者	無作為に抽出した調査対象地域 居住世帯の構成員 (5歳以上)の全員	京阪神都市圏でTwitterに位置情報 付きツイートを発信しているユーザ
調査方法	調査票	Twitterに共有されているライフログ
コスト	高コスト	低コスト
分析期間	1~3年	数時間
調査期間	約1ヶ月	自由に設定可能
調査頻度	10年に一度	いつでも
調査範囲	任意の都市圏単位	どこでも
調査範囲の ゾーニング	市区町村単位	自由に設定可能
対象データ	交通行動の起点 (Origin), 終点 (Destination), 目的, 利用手段, 行動時間帯など 1日の詳細な交通データ (トリップデータ)	移動経験 (移動空間距離, 移動時間, 移動量)
ノイズ	相対的に少ない	多い
リアルタイム性	なし	高い
データの正確性	高い	低い



図2 位置ベース SNS を通した群衆の移動経験を活用した都市空間での近接性分析のための研究モデル

Fig. 2 Research model for urban proximity analysis using crowd movements through location-based social networks.

本研究では、位置ベース SNS を通してモニタリングすることができる実空間での群衆の移動経験を活用し、都市における地域間の近接性を分析する。本稿での具体的な取り組みは以下のとおりである。

a) 群衆の移動経験モニタリング：実空間における人々の経験を反映したライフログが大量に蓄積されており、それを簡単に取得して利用することができるソーシャルネットワークに着目する。具体的には、図2(a)のようにソーシャルネットワーク上で共有されている大量の位置情報付きの群衆のライフログを用いて、都市空間における市区町村を単位とした地域クラスタ間の群衆の移動経験を移動距離、移動時間、移動量の観点でモニタリングする。

b) 地域クラスタ間の近接性測定：次に、図2(b)のように、地域クラスタ間の移動データを用いた近接性に基づ

き、対象都市における地域クラスタの相対的な近接性を測定し、人々の都市での移動経験を反映した地域間の近接関係を表現したインデスマップを作成する。

c) 近接地域マップの生成：上記 b) で作成したインデスマップ上での地域クラスタ間の近接関係をより理解しやすい形で表現するために、図 2(c) のように、ある地域を基準として近接性が高い地域クラスタを地図上に示した近接地域マップを作成する。本稿では、Twitter のデータと従来のパーソントリップ OD 量データに基づき生成される各近接地域マップの差異を比較する。

## 2.2 関連研究

本節では、距離認知や空間認知の調査・分析と人々の経験を用いた場所間の関連性抽出という 2 つの観点で関連研究をまとめ、本研究の特徴を明らかにする。

### a) 距離認知や空間認知の調査・分析

認知距離研究分野では、実距離と個人の認知距離との差を分析することを目的として [25]、距離認知に関わる要因についての考察 [7] や距離認知の傾向についての議論 [2] などさまざまな観点での分析が行われてきた。一般的に、個人の認知距離は、被験者へのアンケートを通して調査される。太田 [23] は、東京から地方都市への認知距離の歪みについてアンケート調査を行い、その結果を分析した。このような認知研究に対し、本研究では、地理的なまとまりとしての人々の都市空間での距離感を推定し、それを地理的な意思決定を支援するための地域情報検索や地域情報推薦に活用するシステムの開発を目指しているという点で発展的である。

人々の空間認知や距離認知は、地理的な距離だけでなく、移動時間やその場所に対する親近感に影響を受ける。そのため、都市空間は地理的に連続した領域であるにもかかわらず、非連続的な領域と見なされる。Lightfoot ら [14] は、特定の地域から公共交通機関を使って他の地域へ移動するときに要する時間や家賃に基づき、地図インタフェース上でインタラクティブに地域を検索することができるシステムを開発した。この研究は、人々の地理的な意思決定に影響を与える移動時間と場所特性を考慮した地域情報検索システムであり、本研究で目指すシステムと関連しているといえるが、我々は人々の生活を通して形成される経験的な近接性を判定し、それを活用することを目的としている点が特徴的である。

### b) 人々の経験を用いた場所間の関連性抽出

モバイル端末や GPS の発達により、実空間での人々の経験を簡単に共有したり利用したりすることができるようになってきた。このような人々の経験を活用することで、実空間の場所間の関連性を把握することが可能である。Zheng ら [22] は、GPS 端末を通して取得した人々の移動軌跡とメッセージから予測される行動を分析し、実空間に

存在する POI と人々の活動を関連付けることにより、ある場所に適した行動の推薦やある行動に適した場所の推薦を行うための手法を提案した。Yuan ら [18] は、タクシーに設置した GPS を用いて取得した人々の移動パターンと地域に存在する施設のカテゴリ情報を用いて、地域の機能を分析するための手法を提案した。Leung ら [13] は、ユーザ、行動、場所からなる三部グラフを構築し、GPS 端末のデータから取得した移動軌跡を用いて協調的に位置推薦を行う手法を提案した。

また、写真共有サイト Flickr に投稿されている時空間タグ付き写真からの人々の経験を活用した研究として、Choudhury ら [4], [5] や Kurashima ら [10] は群衆のランドマークを中心とした移動履歴を分析し、旅行ルートを自動的に生成したり、推薦したりするための手法を提案した。Ahern ら [1] は、ジオタグ付き写真から抽出した代表的なタグを地域と関連付け、地図インタフェース上で写真とともに提示するシステムを開発した。Pang ら [16] は、ウェブ上のトラベログと写真を活用し、トラベログから場所に関する代表的なタグを見つけ出し、写真を対応付けることによってそれらのタグを視覚的に表現する手法を提案している。

Twitter を通じて抽出した人々の経験を活用した研究として、Hasegawa ら [8] は、旅行者の行動の時空間連続性を考慮して旅行ツイートを組織化することにより、旅行体験をまとめて検索するための手法を提案した。岡ら [24] は、ツイートの発信密度が多い地域を地図変形により強調することで、イベントやホットスポットを時系列的に可視化する手法を提案した。Mislove ら [15] は、Twitter のメッセージから人々の感情を抽出し、時間的・空間的な感情の変化を地図変形によって可視化するシステムを開発した。我々の過去の研究 [12], [26] では、Twitter で共有されている群衆ライフログを用いて、地域クラスタごとに人々の潜在的な行動パターンを分析することにより、地域特徴を抽出するための手法を提案した。

これらの研究は、都市空間における人々の経験に基づき複数の場所間の関係性を抽出したり視覚化したりしているという点で本研究と関連している。しかし、本研究では、都市空間において人々が認知している場所間の「近さ」を人々の移動経験を用いて大規模に分析し、それを周辺地域検索などへと応用するために「近接感」に関する新たな尺度を検討している点で特徴的であるといえる。

我々は、過去の研究 [19], [20], [21] において、Twitter から取り出した群衆ライフログを用いて地域間の関係と各地域の影響力を直感的に表現するための認知地図を生成した。具体的には、群衆の移動経験を用いて、移動距離と移動量の観点で近接している地域をより近くに配置し、多くの人々が集まる地域をより強調して表現した。これらの論文と本稿との差異は大きく分けて、目的の違い、提案指標の

違い、対象地域クラスタの違いの3点である。まず、目的の違いについて、本稿では Twitter から取り出した人々の移動経験に基づく地域クラスタ間の近接性を測定し、特定の地域クラスタを中心とした近接地域マップを生成することを目的としている。また、従来のパーソントリップ OD 量データから取得可能な人々の移動経験に基づき生成した近接地域マップと比較することで、ソーシャルネットワークのデータの利用可能性について分析することを目指している。次に、群衆の移動経験から抽出可能な移動距離と移動量を指標として用いたのに対し、本稿では、移動距離、移動量と移動時間からなる指標を提案している点で異なる。さらに、我々の過去の研究では、ジオタグ付きツイートの地理的な分布を考慮して地域クラスタを決めたが、今回はパーソントリップ OD 量データと Twitter のジオタグ付きツイートという2つの異なるデータセットを用いた結果の比較のために、市区町村を単位とした地域クラスタを用いたという点でも異なる。

### 3. 群衆の移動経験を用いた地域クラスタ間の近接性測定手法

本章では、都市空間での人々の移動経験に基づき、地域間の近接性を分析する手法について述べる。地域間の群衆の移動経験は、移動距離、移動時間、移動量（人々による移動の総数）の3つの観点で数値行列としてまとめて表現する。そして、この3つの移動行列を用いて、インデクスマップを生成し、地図上の地域間の地理的な近接性の歪みを表現するために、近接地域マップを作成する。このマップでは、ユーザが指定した地域と3つの観点で近接している地域を容易に検索することが可能となる。今回は、都市空間の歪みを調べるために、Twitter のジオタグ付きツイートとパーソントリップ OD 量データという異なる性質のデータセットを対象にしているため、それぞれのデータから移動行列を生成する方法について詳しく述べる。

#### 3.1 群衆の移動モニタリングによる都市空間での近接性測定プロセス

都市空間での地域間の近接性を測定するための主な処理の流れを図3に示す。群衆の移動データの収集（図3(a)）、移動行列の生成（図3(b)）、近接性の算出・インデクスマップの生成（図3(c)）、および近接地域マップの作成（図3(d)）について述べる。

##### a) 移動データの収集

本研究では、都市空間における距離の歪みは実際の群衆の移動経験に依存するところが大いと考え、群衆の移動データに注目している。群衆の移動経験を収集するためのデータセットとして、パーソントリップ OD 量データと Twitter で共有されている群衆ライフログを利用する。特に、Twitter を用いる理由としては、都市空間を中心に膨大

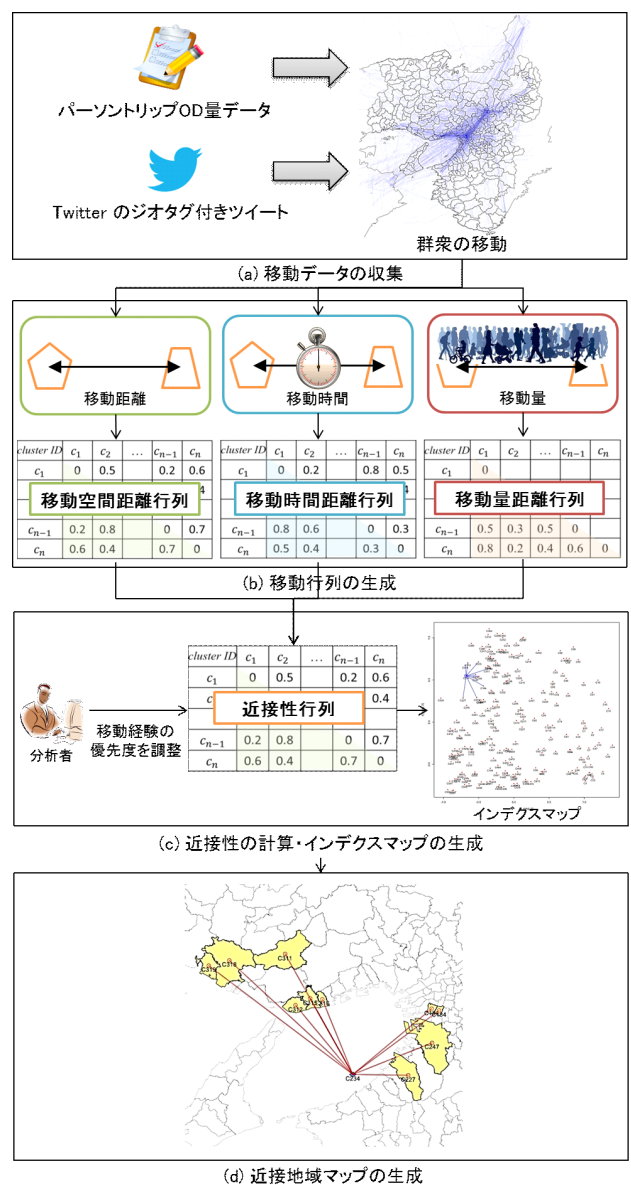


図3 群衆の移動を用いた都市空間の近接性測定プロセス  
 Fig. 3 Process of geo-social proximity estimation between urban clusters using crowd moving experiences.

な量の移動の記録がつねに発信されており、API を用いて移動データを容易に収集することができるからである。具体的には、個々のユーザからの連続的な位置情報付きメッセージ（ツイート）を取得し、2つの地点間の移動を1つの移動セグメントと見なすことで移動データを抽出する。そのため、移動セグメントからは、2つの地点間の移動距離を得ることができ、各地点でのツイートの時刻の差分から移動時間を得ることができる。もちろん、ツイートの発信はユーザらの自由意思によるものであるため、正確な移動時間を表すというよりも、移動時間だけでなく他の活動のために要した時間も含んだ時間として解析すべきである。また、ユーザの移動セグメントを集めて、任意の2つの地点間の移動を集計し、群衆単位の移動を計測することができる。このように、Twitter を用いることにより、多数の




図 4 京阪神都市圏における行政区域に基づく地域クラスタ (グレーの領域)

Fig. 4 Urban clusters based on administrative districts.

人々の自由な情報発信をもとに、群衆全体の移動経験をマクロスケールで観察することが可能であると期待される。

#### b) 移動行列の生成

移動データを集計するために、地域を任意の領域単位に分割する必要がある。本稿では、近接性を分析する対象都市内の地域クラスタ ( $c_i \in R_{zone}, 1 \leq i \leq \# zones$ ) を決める。今回は、パーソントリップ OD 量データとの比較を行うために、パーソントリップ調査結果の分析に用いられている行政区域に基づく地域単位を地域クラスタとする。実際に、図 4 の地図のように、京阪神都市圏 (色付けされている領域) の 234 個の市区町村をクラスタ領域として扱う。このとき地図データとして、国土交通省が公開している Shapefile 形式の国土数値情報・行政区域データ<sup>\*4</sup>を用いた。そして、各地域クラスタ間の移動経験を  $234 \times 234$  の行列として集計する。特に、移動距離、移動時間、移動量の 3 つの移動行列を生成する。

#### c) 近接性計算・インデクスマップ生成

地理的な近接関係がどのように歪んでいくのかを測定するために、2次元のユークリッド空間に対して変形を行う必要がある。本研究では、人々の移動という観点から地域クラスタ間の距離を計測した移動行列を用いて、地域を2次元上に配置する。これにより、たとえば、移動時間が短い地域クラスタを近くに配置することができ、移動時間を基準とした新しいマップを生成することが可能となる。このマップは、ユーザの関心地域を中心に近接地域を探索するためのインデクスとして用いることができるため、イン

デクスマップと呼ぶ。

#### d) 近接地域マップ生成

上記の手法で生成した 3 つの移動行列は、ユーザの意図に応じて合成することができる。たとえば、地理的に近く、移動量も多い地域クラスタを探すような検索が可能となる。より近接している地域クラスタを発見するために、検索結果数を決めて k 最近傍検索 (k-NN; k-Nearest Neighbor Search) をインデクスマップ上で行う。その結果、2次元のユークリッド空間上での近接関係だけでなく、移動時間や移動量の観点から近接している地域クラスタをより直感的に検索することが可能となる。

### 3.2 群衆の移動モニタリングと近接性の測定

地域クラスタ間の近接性を分析するために、Twitter に投稿されているジオタグ付きツイートとパーソントリップ OD 量データをそれぞれ用いて、群衆の移動経験に関する情報として移動距離、移動時間、移動量を抽出する方法について述べる。

#### 3.2.1 Twitter を通した群衆の移動経験モニタリング

位置ベース SNS である Twitter で共有されているジオタグ付きツイートをを用いて、都市における地域クラスタ間の群衆の移動経験を移動距離、移動時間、移動量の観点で抽出する。まず、Twitter からジオタグ付きツイートを収集するために、Twitter が提供している Streaming API<sup>\*5</sup>を用いてデータを収集するだけでなく、我々の過去の研究で開発した地理的ツイート収集システム [11] を用いることにより、大量のジオタグ付きツイートを収集する。図 5 に近畿地方を対象として収集することができたジオタグ付きツイートの地理的な密度に基づく分布を示す。次に、収集したジオタグ付きツイートからユーザ ID、発信日時、位置情報、テキストメッセージなどのメタデータを抽出し、データベースへ格納する。今回は、ユーザ ID、発信日時、位置情報を用いて、都市における群衆の移動経験を抽出する。

群衆の移動経験をモニタリングするために、個々のユーザの移動を抽出して集約する必要がある。地域クラスタ間の個人ユーザの移動は、同一ユーザが時間  $t_i$  にある地点  $p_i$  でツイートを発信し、時間  $t_{i+1}$  に地点  $p_j$  でツイートを発信したとき、地点  $p_i$  と地点  $p_j$  が異なり、かつ同一地域クラスタに存在しないという条件を満たす場合 ( $t_i < t_{i+1}$ ,  $p_i \neq p_j$ ,  $p_i \in c_s.region$ ,  $p_j \in c_e.region$ ,  $c_s \neq c_e$ ) に抽出して移動リストに追加する。このとき、ユーザ ID に基づきソートしておくことで、個人ユーザの移動を効率的に抽出することができる。2 つの地域クラスタ間の移動時間  $movetime_{c_s,c_e}$  は、式 (1) の関数  $MoveTimeSec(.,.)$  によって、地点  $p_j$  での発信時間  $t_{i+1}$  と地点  $p_i$  での発信時間  $t_i$  の差によって求める。このとき、時間の単位はすべて秒

<sup>\*4</sup> 国土数値情報・行政区域データ：  
<http://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-N03.html>

<sup>\*5</sup> Twitter Streaming API:  
<https://dev.twitter.com/docs/streaming-apis>

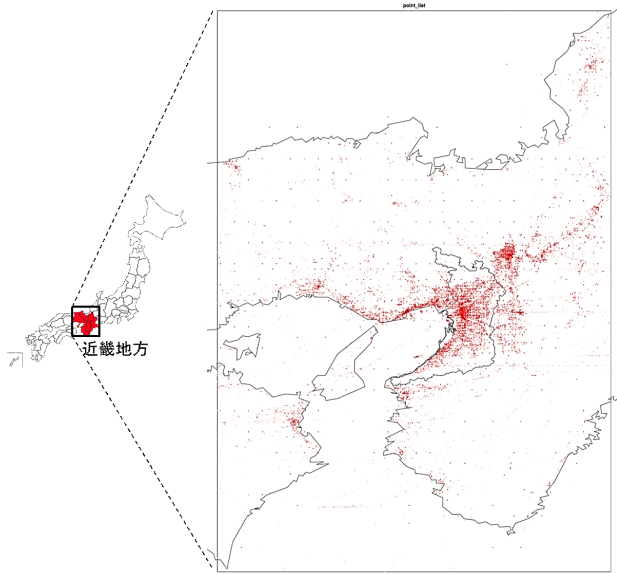


図 5 Twitter から取得したジオタグ付きツイートの地理的分布 (近畿地方)

Fig. 5 Geographical distribution of geo-tagged Tweets from Twitter.




図 6 Twitter のジオタグ付きツイートを用いて抽出した群衆の移動経験

Fig. 6 Crowd moving experiences observed using geo-tagged Tweets over Twitter.

に置き換えて計算した.

$$movetime_{c_s, c_e} = MoveTimeSec(c_s, c_e) \quad (1)$$

$$MoveTimeSec(c_s, c_e) = t_{i+1} - t_i$$

図 6 に, Twitter から抽出した群衆の移動セグメントを示す. この図は, 任意の 300 の移動セグメントをランダムに抽出して示したものである. 今回は, 単純に 2 地点間の移動経験 (以降, 移動セグメントと呼ぶ) に焦点をあてたアプローチをとっている. 3 地点以上の移動経験 (すなわ

ち, 移動軌跡) の活用に関しては, 今後の課題として検討する予定である.

Twitter データから抽出した地域クラスタ間の個人ユーザの移動を移動距離, 移動時間, 移動量の観点で集約し, 地域クラスタ間の群衆の移動経験を数値としてまとめるために, 移動空間距離行列  $M_S$ , 移動時間距離行列  $M_T$ , 移動量距離行列  $M_F$  の 3 つの距離行列を作成する. それぞれの行列成分となる 2 つの地域クラスタ  $c_s, c_e$  間の移動空間距離  $M_S[c_s, c_e]$ , 移動時間距離  $M_T[c_s, c_e]$ , 移動量距離  $M_F[c_s, c_e]$  は以下のように定義する.

#### 移動空間距離の計算

式 (2) を用いて地域クラスタ間の移動空間距離  $M_S[c_s, c_e]$  を計算する. 地域クラスタ間の群衆の移動経験は複数の移動セグメントからなっているため, 1 つの数値として表現する必要がある. 今回は, 2 つの地域クラスタ  $c_s$  と  $c_e$  の群衆の平均移動距離を移動空間距離とするために, 地域クラスタの中心点間の距離を計算している.

$$M_S[c_s, c_e] = ts_{c_s, c_e} \quad (2)$$

$$ts_{c_s, c_e} = |c_s.center - c_e.center|$$

#### 移動時間距離の計算

地域クラスタ間の群衆の移動時間に基づき, 式 (3) を用いて地域クラスタ間の移動時間距離  $M_T[c_s, c_e]$  を計算する.  $tt_{c_s, c_e}$  は 2 つの地域クラスタ  $c_s$  から  $c_e$  への平均移動時間を意味する変数であり,  $Mean(\cdot)$  は平均を計算するための関数である. 移動時間距離  $M_T[c_s, c_e]$  の値は, 移動時間のばらつきをおさえるため  $tt_{c_s, c_e}$  に対数  $\log$  をかけた値とする.

$$M_T[c_s, c_e] = \log(tt_{c_s, c_e} + 1.0) \quad (3)$$

$$tt_{c_s, c_e} = Mean(MovTime(c_s, c_e))$$

4 章の実験では, 京阪神都市圏の市区町村を単位とした地域クラスタを用いているため, 最も遠い地域クラスタ間を移動する場合でも 1 日あれば十分に移動可能である. そのため, 移動時間として長すぎるものはノイズと見なして扱わないものとする. また, 一般的に考えて移動時間が短すぎるものもノイズである可能性が高い. そのため今回は, 最長移動時間を 24 時間, 最短移動時間を 15 分とし, 最短移動時間以上かつ最長移動時間未満の移動セグメントのみを扱う.

#### 移動量距離の計算

地域クラスタ間の群衆の移動量に基づき, 式 (4) を用いて地域クラスタ間の移動量距離  $M_F[c_s, c_e]$  を計算する.  $tf_{c_s, c_e}$  は 2 つの地域クラスタ  $c_s$  から  $c_e$  への個人ユーザの移動の総数を表す変数であり,  $MoveSeg(c_s, c_e)$  は移動の総数を計算するための関数である. 移動量距離  $M_F[c_s, c_e]$  の値は, 移動量が多いほど出発地域クラスタから到着地域クラスタに対する親近感が強くなるという仮定に基づき,

$tf_{c_s, c_e}$  の逆数をとることで算出する. なお, これは, 一般的に親近感の高い地点間の距離は, 相対的に短く, あるいはより正確に認知されるという報酬仮説 [17] に基づく.

$$M_F[c_s, c_e] = \frac{1}{tf_{c_s, c_e} + 1.0} \quad (4)$$

$$tf_{c_s, c_e} = MoveSeg(c_s, c_e)$$

### 3.2.2 パーソントリップ OD 量データを通じた群衆の移動経験モニタリング

実際の移動調査データとして, パーソントリップ調査結果を分析して得られるパーソントリップ OD (Origin-Destination) 量データを用いて群衆の移動距離, 移動時間および移動量を算出し, 移動空間距離行列  $M_S$ , 移動時間距離行列  $M_T$ , 移動量距離行列  $M_F$  の3つの距離行列を作成する. それぞれの行列成分となる2つの地域  $c_s, c_e$  ( $c_i \in R_{zone}$ ,  $1 \leq i \leq \#zones$ ) 間の移動空間距離  $M_S[c_s, c_e]$ , 移動時間距離  $M_T[c_s, c_e]$ , 移動量距離  $M_F[c_s, c_e]$  を以下のように定義する.

#### 移動空間距離の計算

地域クラスタ間の距離に基づき, 式 (5) を用いて地域クラスタ間の移動空間距離  $M_S[c_s, c_e]$  を計算する.  $gs_{c_s, c_e}$  は地域クラスタ  $c_s$  と  $c_e$  の中心点間の距離によって求められる群衆の平均移動距離を表す変数である. 空間的距離  $M_S[c_s, c_e]$  の値は群衆の平均移動距離と等しいものとする. なお, 3.2.1 項で説明した Twitter のジオタグ付きツイートをを用いたときと同様の計算方法を適用した.

$$M_S[c_s, c_e] = gs_{c_s, c_e} \quad (5)$$

$$gs_{c_s, c_e} = |c_s.center - c_e.center|$$

#### 移動時間距離の計算

地域クラスタ間の群衆の移動時間に基づき, 式 (6) を用いて地域クラスタ間の移動時間距離  $M_T[c_s, c_e]$  を計算する.  $gt_{c_s, c_e}$  は地域クラスタ  $c_s$  から  $c_e$  への経路移動時間を示す変数であり,  $GDirection(.)$  は Google 社が提供している経路探索サービスである Google Driving Directions \*6 の API \*7 は, 地域クラスタ  $c_s$  と  $c_e$  の中心点とその間を移動するときのモード (徒歩, 車, 公共交通機関) を引数として検索すると, 経路情報を返す関数である. 今回は, 地域クラスタとして市区町村を単位としているため, 徒歩での移動は現実的ではないと考え, 徒歩による移動時間は考慮していない. また, 公共交通機関に関しても, 路線に影響を受けるため, 駅を中心に地域クラスタを設定した場合には適しているかもしれないが, 今回の場合には, 車での移動が最も適していると考え, 車で移動した場合の予想時間

を用いた. この群衆の移動時間データ  $M_T[c_s, c_e]$  の値は, 移動時間のばらつきをおさえるため,  $gt_{c_s, c_e}$  に  $\log$  をかけた値とする.

$$M_T[c_s, c_e] = \log(gt_{c_s, c_e} + 1.0) \quad (6)$$

$$gt_{c_s, c_e} = GDirection(c_s.center, c_e.center, mode = 'drive')$$

#### 移動量距離の計算

地域クラスタ間の群衆の移動量に基づき, 式 (7) を用いて地域クラスタ間の移動量距離  $M_F[c_s, c_e]$  を計算する.  $gf_{c_s, c_e}$  は地域クラスタ  $c_s$  から  $c_e$  への個人ユーザの移動の総数を表す変数であり,  $MoveSeg(c_s, c_e)$  はパーソントリップ OD 量データから移動の総数を抽出するための関数である. この移動量距離  $M_F[c_s, c_e]$  の値は, 移動量が多いほど地域クラスタ間の近接関係は強くなるという仮定に基づき,  $gf_{c_s, c_e}$  の逆数をとって計算する.

$$M_F[c_s, c_e] = \frac{1}{gf_{c_s, c_e} + 1.0} \quad (7)$$

$$gf_{c_s, c_e} = MoveSeg(c_s, c_e)$$

### 3.2.3 移動行列に基づく近接性行列の作成

すべての地域クラスタのペアに対して群衆の移動からの移動空間距離, 移動時間距離, 移動量距離をそれぞれ求め, 移動空間距離行列  $M_S$ , 移動時間距離行列  $M_T$ , 移動量距離行列  $M_F$  の3つの距離行列を完成させ, これらの移動に基づく距離を統合して近接性行列を生成する. しかし, 元となる3つの距離行列成分の単位はそれぞれ異なるため, 式 (8) の関数  $nr(.)$  を用いて行列成分を正規化する.

$$nr(M) = \frac{M[c_s, c_e]}{\max(M)} \quad (8)$$

正規化した3つの距離行列の値に基づき, 2つの地域クラスタ  $c_s, c_e$  間の近接性  $M_R$  を算出して近接性行列を生成する. 本稿では, 群衆の移動経験に関わる3つの指標 (移動距離, 移動時間, 移動量) をそれぞれ優先した場合に, 地域クラスタ間の近接性にどのような差異が現れるのかについて, 正確性よりもむしろさまざまな場合について詳細に分析して知見を得ることを目的としているため, 地域クラスタ間の近接性  $M_R$  を式 (9) により計算する.

$$M_R = w_S \cdot M_S + w_T \cdot M_T + w_F \cdot M_F \quad (9)$$

$$(0 \leq w_S, w_T, w_F \leq 1)$$

式 (9) において,  $w_S, w_T, w_F$  は, 地域クラスタ間の近接性を移動距離, 移動時間, 移動量に対する優先度を指定して分析するために定義した重み変数である. それぞれ0から1.0までの値を選択することが可能である.

### 3.3 地域クラスタ間の相対的な近接性表現

対象都市内に設定した地域クラスタ間の近接性を表現す

\*6 Google Directions:

<https://maps.google.com/maps?hl=en&tab=ll>

\*7 Google Directions API:

<https://developers.google.com/maps/documentation/directions/>



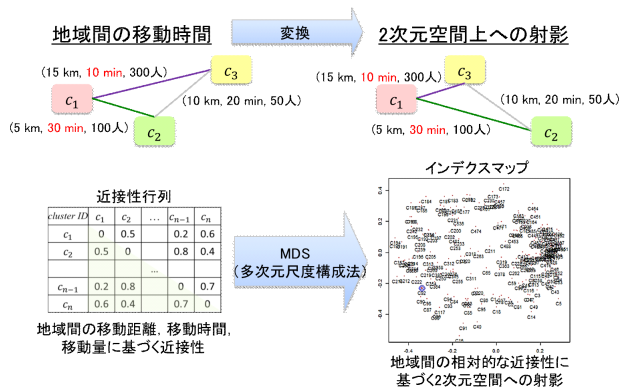


図 7 多次元尺度構成法による地域クラスタ間の相対関係を反映したインデクスマップの作成

Fig. 7 Generation of index map reflecting relative relations among urban clusters by MDS.

るために、相対的な近接性に基づき地域クラスタを配置したインデクスマップを作成する。このとき、より直感的な表現のために、近接関係が強い地域クラスタは近くに、逆に近接関係が弱い地域クラスタは遠くに配置すべきであると考え、多次元尺度構成法 (Multi-Dimensional Scaling; MDS) [9] を用いた。この手法は、図 7 に示すように、対象間の距離に基づき多次元空間上の各対象の座標値を求め、点間の距離が観測されたもとの距離と最も一致する点の布置を決める方法である。たとえば、図 7 の左上のように 3 つの地域クラスタ  $c_1$ ,  $c_2$ ,  $c_3$  があるとき、地理的には  $c_1$  と  $c_2$  が近く、 $c_1$  と  $c_3$  が遠い。しかしながら、移動時間の観点では、 $c_1$  と  $c_2$  が遠く、 $c_1$  と  $c_3$  が近くなる。このような距離関係を表現するために、MDS を用いて 2 次元空間上の距離に変換してマッピングする。

実際に、図 7 のように、作成した近接性行列に対して MDS を適用し、各地域クラスタの 2 次元空間上での座標値を算出し、インデクスマップを作成する。このインデクスマップは、人々が空間をどのように移動しているか、そしてその結果として生じる空間的な歪みを表現しているといえる。ここで、入力となる近接性行列において、地域クラスタ  $c_s$  から地域クラスタ  $c_e$  への近接性と地域クラスタ  $c_e$  から地域クラスタ  $c_s$  への近接性が必ずしも等しくなるとは限らない ( $M[c_s, c_e] \neq M[c_e, c_s]$ )。しかしながら、今回用いた MDS では 2 対象間の距離について、距離の公理の対称性を前提としている。そのため、作成した近接性行列をそのまま MDS で処理することが難しい。そこで、今回は地域クラスタ間の平均近接性に置き換え、近接性行列を対称な行列に変換して処理した。

$$M'[c_s, c_e] = M'[c_e, c_s] = \frac{M[c_s, c_e] + M[c_e, c_s]}{2}$$

### 3.4 近接地域マップの生成

3.3 節の手法で生成したインデクスマップでは、新たに定義した距離尺度を用いて地域クラスタ 2 次元上に再配置

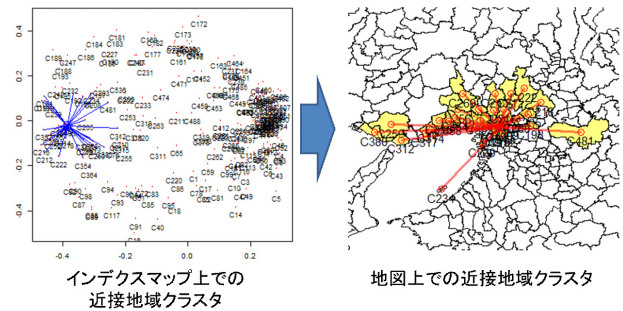


図 8 近接地域マップ：地図上での近接地域クラスタの表現  
Fig. 8 Representation of geo-social vicinity areas on a map.

した。しかし、ユーザが直接このインデクスマップを見ながら自分の居場所や関心地域を中心として近接地域を把握することが難しい。そのため、インデクスマップ上で近接と判定された地域を従来の地図上で分かりやすく表現する。具体的には、MDS の結果として生成されたインデクスマップ上でユーザが指定した地域クラスタを中心に上位  $k$  件の近接地域クラスタを抽出する。このとき、 $k$ -NN ( $k$ -Nearest Neighbor) アルゴリズム [6] を適用する。そして、図 8 のように、従来の地図上の対応する近接地域クラスタ間を線でつないで強調することにより、近接地域マップを生成する。

## 4. 実験

本章では、3 章で説明した提案手法に基づき、従来の社会調査手法の 1 つであるパーソントリップ調査から得られるパーソントリップ OD 量データとソーシャルネットワークから取得可能な群衆のライフログの 2 種類のデータセットを用いて実験を行った。具体的には、群衆の移動経験を移動空間距離、移動時間、移動量の観点でそれぞれ抽出して 3 つの移動行列を作成し、それらに基づき近接性行列を生成した。そして、近接性行列に対して MDS を適用してインデクスマップを作成し、このインデクスマップ上である地域クラスタの近接性を地図上で強調した近接地域マップを作成した。4.1 節では実験に用いた 2 種類のデータセットの詳細について説明し、4.2 節では実験結果を比較して示し、得られた知見について 4.3 節で考察する。

### 4.1 データセット

Twitter を通してモニタリングした群衆の移動経験とパーソントリップ OD 量データからの群衆の移動経験に基づく近接性を分析した結果を比較する。そのために、ジオタグ付きツイートとパーソントリップ OD 量データを取得し、234 の共通の地域クラスタを設定した。それぞれの詳細は以下のとおりである。

#### ジオタグ付きツイート

Twitter が提供している Streaming API と我々の過去の研究で開発した地理的ツイート収集システム [11] を用い

てジオタグ付きツイートの収集を行った。このとき、日本の近畿地方を含む領域（経度 = [134.122433, 136.337186], 緯度 = [33.210804, 36.385050]）をモニタリング対象地域に設定した。これにより、2012年9月16日から同年10月7日の約3週間のうち253,793人のユーザが発信した3,417,737件のツイートを図5のように収集することができた。そして、このデータから計154,366の地域クラスタ間の群衆の移動セグメントを抽出した。図6にその結果を示す。それぞれの線分が移動セグメントを表している。なお、今回は同一地域クラスタ内での移動は対象としておらず、この総数にもその数は含まれていない。

#### パーソントリップ OD 量データ

京阪神都市圏交通計画協議会\*8が平成12年に実施した第4回京阪神都市圏中間年次調査の京阪神都市圏パーソントリップ調査集計結果\*9を用いて、出発地域と到着地域とその間の移動量からなるパーソントリップ OD 量データを取得した。ここで、京阪神都市圏とは滋賀県、京都府、大阪府、兵庫県、奈良県、和歌山県を含む地域である。この調査は10年に1度の頻度で実施されており、平成22年にも実施された。しかしながら、平成25年4月時点でその調査の速報集計結果（平成24年12月公開）\*10のみしか公開されておらず、現況集計値を得ることができなかった。そのため、今回は平成12年の調査結果を用いて3章で説明した手法により地域クラスタ間の移動空間距離と移動量を抽出した。また、パーソントリップ調査では、地域間の移動手段や目的は調査しているが、移動時間については調査していないため抽出することができない。そのため、Google Driving Directions により求めた地域クラスタ間の最短経路移動時間を仮想的なデータとして用いた。

#### 地域クラスタ

今回の実験では、滋賀県、京都府、大阪府、兵庫県、奈良県、和歌山県を含む京阪神都市圏を対象都市として、地域クラスタ間の近接性を分析する。そのために、京阪神都市圏のパーソントリップ OD 量データを分析する際のゾーニング\*11により設定されている小ゾーン\*12に基づき、図4に示すように234の市区町村を単位とした地域クラスタを用いた。一般的に、小ゾーンは、都市計画区域や市区町村における交通流動を把握するために定められた地理的な単

位であり、原則として市区町村を単位としている。ただし、大都市については、市区町村を分割したゾーンが定義されている。なお、平成12年に実施された調査では723のゾーンが用いられていたが、今回は、市区町村が分割されているゾーンはまとめて、当時の市区町村を単位とした行政区域を地域クラスタと見なし、京阪神都市圏内の234の地域クラスタを対象とした。

#### 4.2 実験結果

上記の2種類のデータセットを用いてそれぞれ抽出した群衆の移動経験から移動距離、移動時間、移動量をそれぞれ優先した場合に、地域クラスタ間の近接性がどのように変化するかについて分析し比較した結果を示す。本稿では、以下のように3つの基点となる地域クラスタを決め、それらを中心とした近接性について分析した。

- Case 1: C196, 大阪府大阪市北区（大阪駅）
- Case 2: C89, 京都府京都市下京区（京都駅）
- Case 3: C234, 大阪府泉南郡田尻町（関西国際空港）

図12, 図13, 図14に大阪府大阪市北区（C196）、京都府京都市下京区（C89）、大阪府泉南郡田尻町（C234）をそれぞれ基点としたときの結果を示す。これらの図において、(A)はパーソントリップ OD 量データに基づく結果、(B)はTwitterのジオタグ付きツイートに基づく結果である。また、(a)は移動空間距離、(b)は移動時間、そして(c)は移動量をそれぞれ優先したときの結果である。

##### 4.2.1 Case 1: 大阪府大阪市北区（C196）

この基点地域クラスタには、京阪神都市圏内で最大のJR大阪駅が存在しており、会社や商業施設が立ち並ぶ都市である。図12を用いて、この基点地域クラスタを中心とした近接性について分析、比較した結果を説明する。

##### i) パersonトリップ OD 量データを用いた場合

図12(A)はパーソントリップ OD 量データを用いて抽出した移動経験の中で、優先する指標を変えたときにそれぞれ抽出される上位30件の近接地域クラスタを示している。パーソントリップ OD 量データは、通勤・通学や買い物といった人々の日常生活に関わる規則的な移動をまとめたものであるといえる。図9に、パーソントリップ OD 量データから抽出したこの基点地域クラスタに関わる移動セグメントを示す。図12の(A)(a)と(b)は、それぞれ移動空間距離と移動時間を優先した場合の地域クラスタ間の近接性に基づく結果である。この結果から、移動空間距離を考慮した場合は当然であるが、移動時間を考慮した場合にも、地理的に近接した地域クラスタが基点地域クラスタの近接地域クラスタとして抽出されていることが分かる。次に、図12(A)(c)は、移動量を優先した場合の地域クラスタ間の近接性に基づく結果である。先ほどの結果と比べると、近接地域クラスタが地理的に広い範囲に存在することが分かる。実際に、共通の地域クラスタは大阪府大

\*8 京阪神都市圏交通計画協議会：

<http://www.kkr.mlit.go.jp/plan/pt/index.html>

\*9 平成12年京阪神都市圏パーソントリップ調査集計結果：

<http://www.kkr.mlit.go.jp/plan/pt/data/pt/index.html>

\*10 第5回近畿圏パーソントリップ調査速報集計結果：

[http://www.kkr.mlit.go.jp/plan/pt/research\\_pt/h22/pt\\_h22.pdf](http://www.kkr.mlit.go.jp/plan/pt/research_pt/h22/pt_h22.pdf)

\*11 ゾーニング：

[http://www.city.sakai.lg.jp/city/info/\\_tetuki/img/09zone\\_h.pdf](http://www.city.sakai.lg.jp/city/info/_tetuki/img/09zone_h.pdf)

\*12 国土交通省 京阪神都市圏ゾーンコード：

<http://nlftp.mlit.go.jp/ksj/jpgis/datalist/KsjTmpl-S05-b.html>




図 9 パーソントリップ OD 量データを通して観測される大阪府大阪市北区 (C196) に関わる群衆移動

Fig. 9 Crowd moving segments centering Kita ward, Osaka city (C196) observed using person trip OD data.





図 10 Twitter を通して観測される大阪府大阪市北区 (C196) に関わる群衆移動

Fig. 10 Crowd moving segments centering Kita ward, Osaka city (C196) observed using geo-tagged Tweets over Twitter.


阪市西区 (C191) と大阪府大阪市中央区 (C192) の 2 個のみであった。このことから、移動空間距離が短い地域クラスタや移動時間がかからない地域クラスタであっても近接地域クラスタとして抽出されることが分かる。また、この 2 個以外の地域クラスタには、鉄道の主要な駅が存在する郊外地域が多いため、公共交通機関を利用して通勤や通学をしている人々の移動による空間的な歪みを観察することができたといえる。

ii) Twitter のジオタグ付きツイートを用いた場合

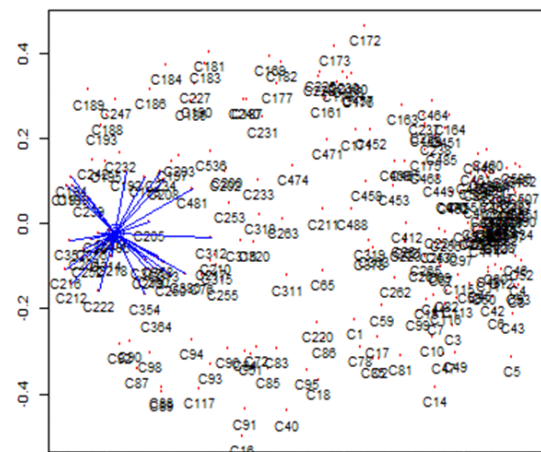
図 12(B) は Twitter のジオタグ付きツイートを用いて抽出した移動経験の中で、優先する指標を変えてそれぞれ抽出される上位 30 件の近接地域クラスタを示している。図 10 はこの基点地域クラスタに関わる移動セグメントで



(a) 移動空間距離を優先した場合



(b) 移動時間を優先した場合



(c) 移動量を優先した場合

図 11 インデスマップを用いた大阪府大阪市北区 (C196) の近接地域クラスタの抽出

Fig. 11 Extraction of vicinity areas centering Kita ward, Osaka city (C196) on each indexing map.

あり、図 11 は近接地域を求めるために用いたインデスマップである。ジオタグ付きツイートを用いて抽出される群衆の移動経験は、パーソントリップ OD 量データからの群衆の移動経験に比べると、もっと一般的で多様性があ

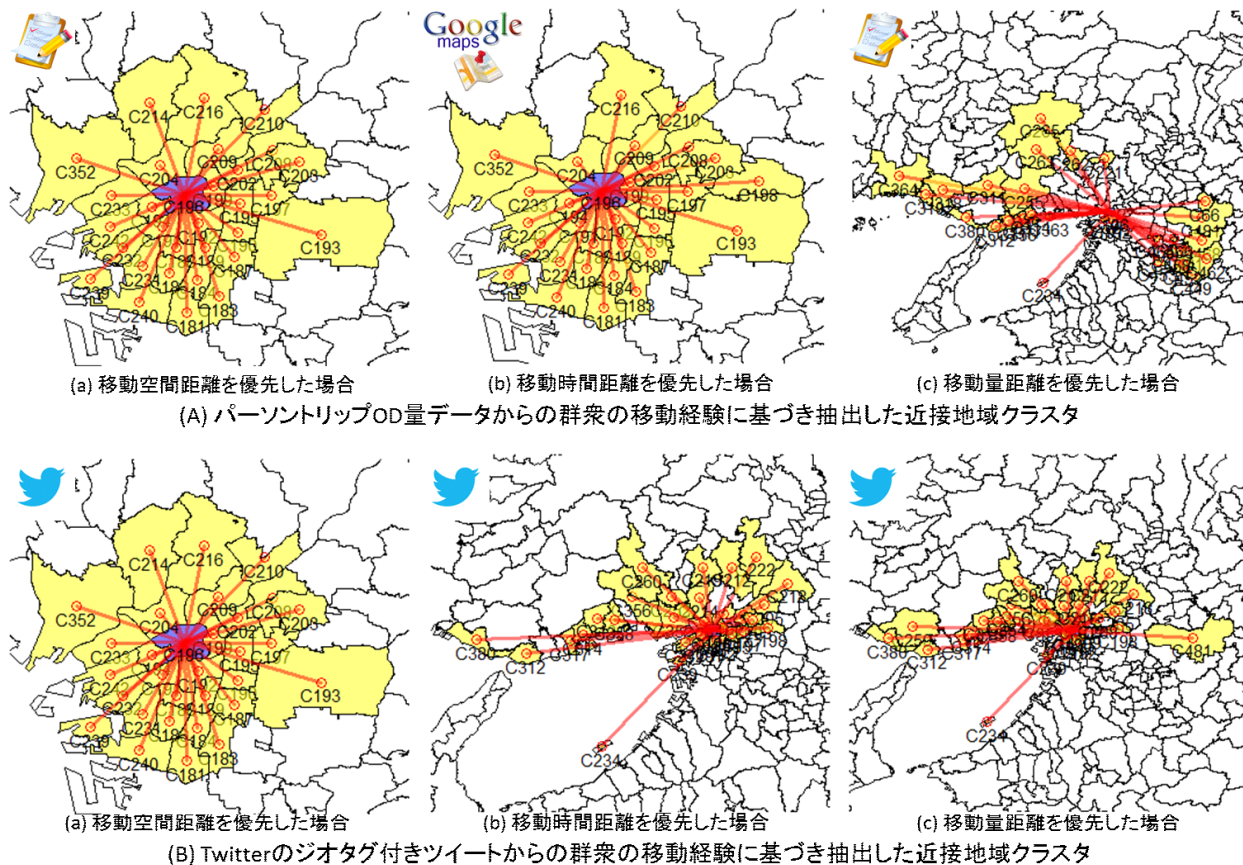


図 12 群衆の移動経験に基づく近接性 (大阪府大阪市北区 (C196) を中心とした場合)

Fig. 12 Geo-social proximity based on crowd moving experiences (Kita ward, Osaka city (C196)).

る. 具体的には, パーソントリップ調査の場合, 対象者は対象地域の居住者のみであるが, Twitter のジオタグ付きツイートの場合は, 対象期間中に対象地域内でツイートを公開発信した全ユーザであるため, 居住者だけでなく観光客なども含まれる. さらに, 規則的な移動という制限もないため, 平日だけでなく, 休日の移動や, ソーシャルイベントが発生した際の移動なども含めた多様性のあるダイナミックな移動経験を扱うことが可能である.

図 12 (B) (a) と (b) より, 移動時間を優先した場合には, 移動空間距離を優先した場合には抽出されなかった地理的に広範囲に存在する 16 個の地域クラスタとの近接関係を判定しており, 地理的には遠いけれども移動時間を重視すると近くなるという歪みを確認することができた. さらに, 図 12 (B) (c) は移動量を優先したときの結果であり, 30 個の地域クラスタのうち 26 個の地域クラスタが図 12 (B) (b) の結果と共通していることが分かった. この中でも, 関西国際空港が含まれる地域クラスタ (C234) との近接関係を判定しており, これは多様な人々の移動経験を用いているからこそ抽出される結果であるといえる. また, 残り 4 個の地域クラスタのうちの 1 個の地域クラスタに関しては, 移動空間距離を重視した場合には近接しているが, 移動時間を重視した場合には近接ではない地域クラスタであっ

た. さらに, 兵庫県神戸市西区 (C250) や奈良県奈良市 (C481) などの 3 個の地域クラスタに関しては, 移動空間距離を重視した場合にも移動時間を重視した場合にも近接として抽出されなかった地域クラスタであり, 両地域への多様な人々の移動に基づく空間的な歪みを確認することができた.

### iii) 比較結果

図 12 (A) のパーソントリップ OD 量データを用いた場合の結果と図 12 (B) の Twitter のジオタグ付きツイートをを用いた場合の結果を比較し, その差異について考察した結果を説明する. まず, 移動空間距離に関しては, どちらのデータセットを用いた場合にも, 移動が観測された地域クラスタ間の中心点間の距離として算出したため, 図 12 (A) (a) と図 12 (B) (a) のように抽出される結果は同じであった. 移動時間に関しては, パーソントリップ OD 量データから取得可能なデータが存在していないため, Google Driving Directions を用いて地域クラスタ間の中心点間を車で移動するときの最短経路を取得し, その経路の移動時間を仮想的な移動時間として用いた. その結果, 図 12 (A) (b) のように地理的に近い地域クラスタが近接地域クラスタとして抽出された. これに対し, Twitter のジオタグ付きツイートをを用いた場合には, 人々の実空間における振舞

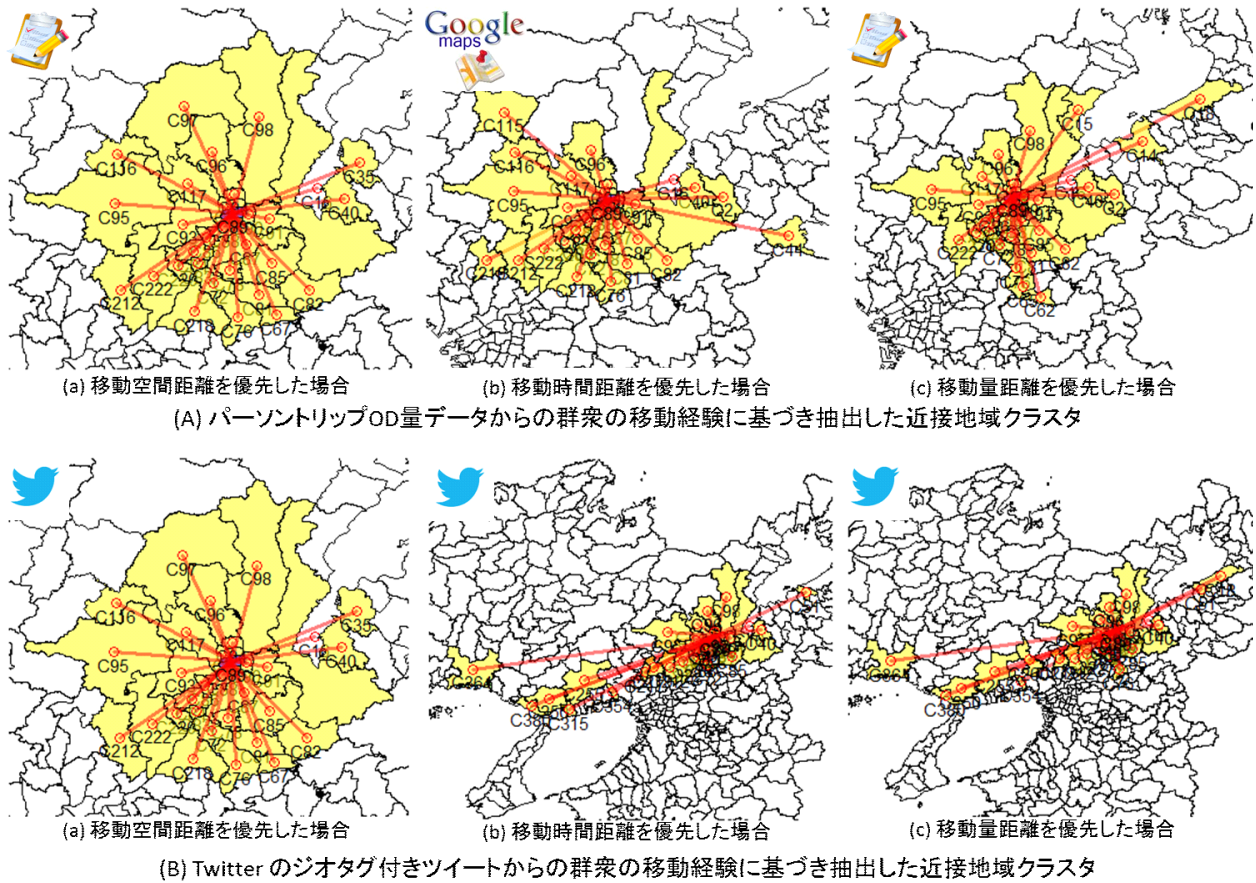


図 13 群衆の移動経験に基づく近接性 (京都府京都市下京区 (C89) を中心とした場合)  
 Fig. 13 Geo-social proximity based on crowd moving experiences (Shimogyo ward, Kyoto city (C89)).

いも含んだ移動時間が抽出されており、時間的な範囲が仮想的な移動時間と比べて大きくなるとともに地理的な範囲も相対的に大きくなったため、図 12(B) (b) のように地理的に離れた地域クラスタとの近接関係を判定したと考えられる。移動量に関しては、パーソントリップ OD 量データに基づき抽出された上位 30 件の近接地域クラスタを具体的に調べると、基点地域クラスタと地理的に近い大阪府内の地域クラスタが 4 個、大阪府の東側に隣接している兵庫県内の地域クラスタが 15 個、大阪府の西側に隣接している奈良県内の地域クラスタが 11 個であった。

これらの結果から、大阪府大阪市北区 (C196) を基点とした場合、通勤や通学などの日常生活における規則的な移動は地理的に近接した場所ではなく、地理的に離れた地域クラスタとつながって頻繁に起こっていることが分かる。これは、都市における中心市街地の人口が減少して郊外の人口が増加する人口移動現象であり、人口分布図で見ると中心部が空洞化するドーナツ化現象の影響を反映した結果であると考えられる。実際に、基点地域クラスタは京阪神都市圏内最大の JR 大阪駅があるだけでなく、他の公共交通機関の駅が集中しておりハブ的な役割を担っている地域であるため、郊外にある自宅から都心にある会社や学校へ通うという移動傾向を反映した地域クラスタ間の近接関係

が表現されているといえる。また、Twitter のジオタグ付きツイートに基づく移動経験は比較的ローカルなエリアで観察されており、一般的な移動経験による地域クラスタ間の近接関係は相対的に地理的に狭い領域内で強いという傾向があることが確認された。たとえば、大阪に観光などのために訪れる人々は、さらに地理的に離れた地域も訪れるというよりも、基点地域クラスタ周辺にとどまるという傾向が見て取れる。実際に、基点地域クラスタの周辺地域には、心斎橋、難波、天王寺などの繁華街が多数存在しており、周辺地域をめぐるだけでも 1 日中楽しむことができるという地域特徴を反映した結果であるともいえる。

#### 4.2.2 Case 2: 京都府京都市下京区 (C89)

この基点地域クラスタは、歴史的建造物が立ち並び、新幹線や新快速が停車する JR 京都駅を利用して多くの観光客が訪れる観光都市である。図 13 を用いて、この基点地域クラスタを中心とした近接性について分析、比較した結果を説明する。

##### i) パーソントリップ OD 量データを用いた場合

図 13(A) はパーソントリップ OD 量データを用いて抽出した移動経験の中で、優先する指標を変えたときにそれぞれ抽出される上位 30 件の近接地域クラスタを示している。図 13(A) の (a) と (b) は、移動空間距離と移動時間を

それぞれ優先したときの地域クラスタ間の近接性に基づく結果を示している。移動空間距離を優先した場合に抽出される30個の近接地域クラスタと移動時間を優先したときに抽出される30個の近接地域クラスタのうち、共通しているのは26個であった。それ以外の4個の地域クラスタの中には滋賀県甲賀郡甲南町(C44)のように、地理的に離れている地域クラスタも含まれており、部分的な空間の歪みを観察することができた。実際に、滋賀県甲賀郡甲南町(当時、現在は合併により滋賀県甲賀市)は滋賀県東南部に位置しており、大阪、名古屋から100km圏内にあるため、近畿圏と中部圏を結ぶ広域交通拠点となっている。また、図13(A)(c)は、移動量を優先した場合の地域クラスタ間の近接性に基づく結果である。大阪府大阪市北区(C196)の場合とは異なり、図13(A)の(a)および(b)と共通している地域クラスタは23個であった。また、残り7個の近接地域クラスタのうち、移動空間距離を重視した場合にも移動時間を重視した場合にも抽出されなかった滋賀県内の地域クラスタ(C14, C15, C18)や京都府内の地域クラスタ(C62, C65)が近接地域クラスタとして抽出されており、これらの近接性には空間的な歪みが生じていることが分かる。

#### ii) Twitter のジオタグ付きツイートを用いた場合

図13(B)はTwitterのジオタグ付きツイートを用いて抽出した移動経験の中で、優先する指標を変えたときにそれぞれ抽出される上位30件の近接地域クラスタを示している。図13(B)の(a)と(b)は移動空間距離と移動時間をそれぞれ優先した場合の地域クラスタ間の近接性に基づく結果である。これらを比べると、移動空間距離を優先した場合には抽出されなかった地理的により広範囲に存在する10個の地域クラスタとの近接関係を判定しており、地理的には遠いけれども移動時間を重視すると近接関係にあるという歪みを確認することができた。さらに、図13(B)(c)は移動量を優先した場合の地域クラスタ間の近接性に基づく結果であるが、30個中27個の地域クラスタが図13(B)(b)の結果と共通していることが分かった。また、残り3つの地域クラスタに関して、京都府京田辺市(C76)に関しては、移動空間距離を重視した場合には近接しているが、移動時間を重視した場合には近接ではない地域クラスタであった。さらに、滋賀県彦根市(C18)や兵庫県宝塚市(C260)に関しては、移動空間距離を重視した場合にも移動時間を重視した場合にも近接ではない地域クラスタを抽出することができ、群衆の移動経験に基づく空間的な歪みを確認することができた。

#### iii) 比較結果

図13(A)のパーソントリップOD量データを用いた場合の結果と図13(B)のTwitterのジオタグ付きツイートを用いた場合の結果を比較し、その差異について考察した結果を説明する。まず、移動空間距離に関しては、どちらの

データセットを用いた場合でも、移動が観測された地域クラスタ間の中心点間の距離として算出したため、図13(A)(a)と図13(B)(a)のように近接地域クラスタとして抽出される結果は同じであった。移動時間に関しては、仮想的な移動時間を用いた場合には、図13(A)(b)のように比較的地理的に近接している地域クラスタが抽出されたのに対し、Twitterのジオタグ付きツイートを用いた場合には、図13(B)(b)のように地理的に離れている地域クラスタを近接地域クラスタとして抽出した。移動量に関しては、パーソントリップOD量データを用いた場合に実際に抽出された上位30件の近接地域クラスタについて調べると、基点地域クラスタと地理的に近接している京都府内の地域クラスタが22個、京都府の西側に位置する滋賀県内の地域クラスタが6個、京都府の東側に位置する大阪府内の地域クラスタが2個であった。このことから、Case2で基点とした京都府京都市下京区(C89)を中心とした場合、通勤や通学などの日常生活における規則的な移動は基点地域クラスタの周辺地域で頻繁に起こっていることが分かる。これに対し、Twitterのジオタグ付きツイートを用いた場合には、京都府内の地域クラスタが17個、滋賀県内の地域クラスタが4個、大阪府内の地域クラスタが3個、兵庫県内の地域クラスタが6個であり、パーソントリップOD量データを用いた場合に比べて、広域的な領域から近接地域クラスタが抽出されたことが分かる。

#### 4.2.3 Case 3: 大阪府泉南郡田尻町 (C234)

この基点地域クラスタは、京阪神都市圏最大の国際空港である関西国際空港が存在する人口島である。図14を用いて、この基点地域クラスタを中心とした近接性について分析、比較した結果を説明する。

##### i) パーソントリップOD量データを用いた場合

図14(A)はパーソントリップOD量データを用いて抽出した移動経験の中で、優先する指標を変えたときにそれぞれ抽出される上位30件の近接地域クラスタを示している。図14(A)の(a)と(b)は、それぞれ移動空間距離と移動時間を優先したときの結果である。関西国際空港は人口島内にあるため地理的に独立しており、そこへアクセスする方法も限られている。実際に、空港島への鉄道や車でアクセスするために利用される関西国際空港連絡橋は唯一の陸上アクセスを担っている。移動空間距離を考慮した場合は、アクセス経路にかかわらず、移動が観測された地域クラスタ間の中心点間の距離を計算したため、基点地域クラスタを中心として同心円状に存在する地域クラスタとの近接関係を判定した。しかし、移動時間を考慮した場合には、大阪湾沿岸の地域クラスタやそれよりも西向きの内陸部に存在する地域クラスタが抽出された。このことから、移動空間距離を重視した場合に比べ、移動経路を考慮した近接地域クラスタを抽出することができたといえる。次に、図14(A)(c)は、移動量を優先したときの結果であ

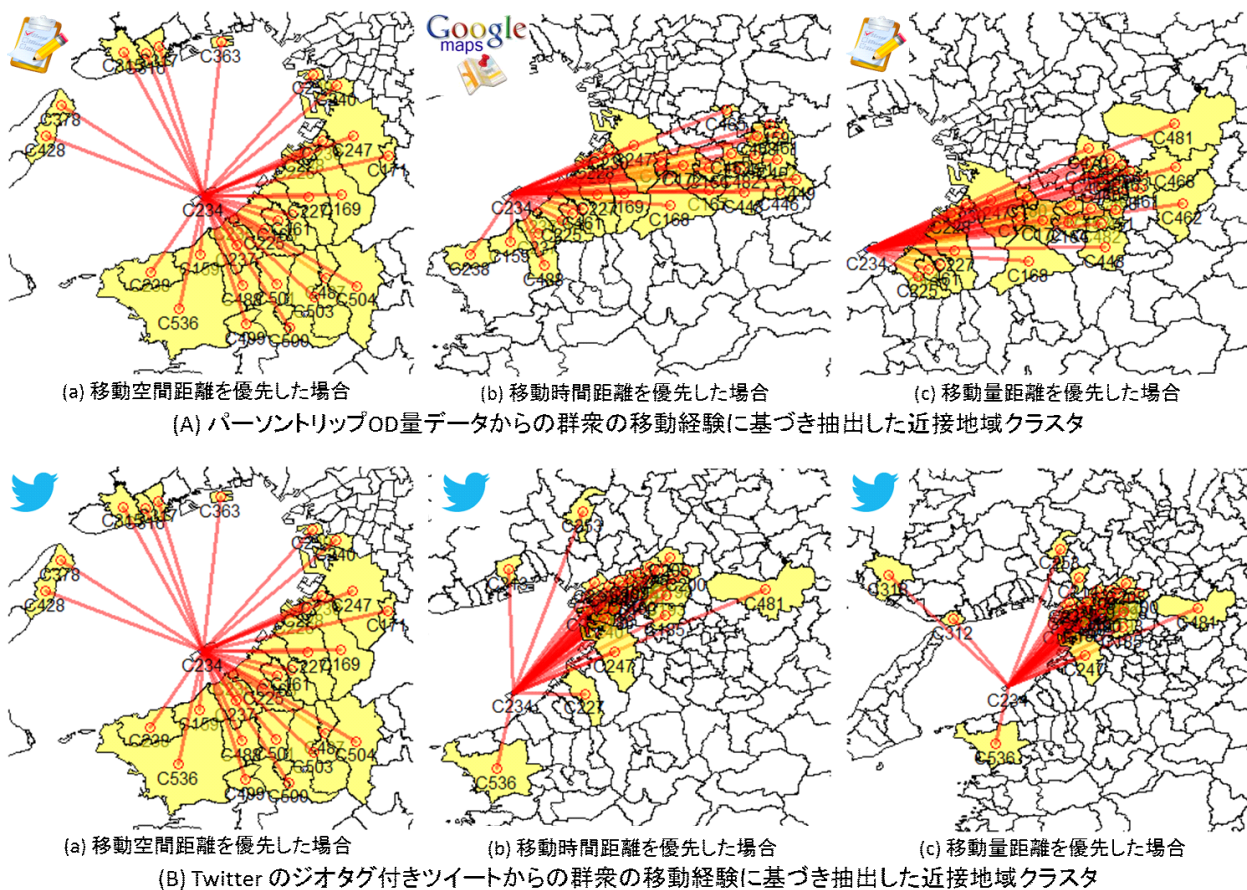


図 14 群衆の移動経験に基づく近接性 (大阪府泉南郡田尻町 (C234) を中心とした場合)

Fig. 14 Geo-social proximity based on crowd moving experiences (Kansai International Airport (C234)).

る. 図 14(A) の (a) および (b) と共通している地域クラスタは大阪府内の 8 個の地域クラスタのみで, 残り 22 個の地域クラスタに関しては, 移動空間距離が短く移動時間がかからない地域クラスタであるが抽出されていない. そのため, これらの近接性には空間的な歪みが生じていることが分かる.

### ii) Twitter のジオタグ付きツイートをを用いた場合

図 14(B) は Twitter のジオタグ付きツイートをを用いて抽出した移動経験の中で, 優先する指標を変えたときにそれぞれ抽出される上位 30 件の近接地域クラスタを示している. 図 14(B) の (a) と (b) はそれぞれ移動空間距離と移動時間を優先したときの結果である. これらを比べると, 移動空間距離を優先した場合には抽出されなかった地理的により広範囲に存在する 25 個の地域クラスタとの近接関係を判定し, 空間の歪みを確認することができた. さらに, 図 14(B) (c) は移動量を優先したときの結果であり, 30 個の地域クラスタのうち 26 個の地域クラスタが図 14(B) (b) の結果と共通していることが分かった. また, 異なる 4 個の地域クラスタとして, 大阪府大阪市東淀川区 (C209), 大阪府豊中市 (C214), 兵庫県神戸市垂水区 (C312), 兵庫県加古川市 (C318) のような移動空間距離を重視した場

合にも移動時間を重視した場合にも近接地域クラスタとして抽出されなかった地域クラスタとの近接関係を判定し, 群衆の移動経験に基づく空間的な歪みを確認することができた.

### iii) 比較結果

図 14(A) のパーソントリップ OD 量データを用いたときの結果と図 14(B) の Twitter のジオタグ付きツイートをを用いたときの結果を比較し, その差異について考察した結果を説明する. まず, 移動空間距離に関しては, どちらのデータセットを用いた場合でも, 移動が観測された地域クラスタ間の中心点間の距離として算出したため, 図 14(A) (a) と図 14(B) (a) のように近接地域クラスタとして抽出される結果は同じであった. 移動時間に関しては, 図 14(A) (b) のように地理的に近接した地域クラスタが抽出された. これに対し, Twitter のジオタグ付きツイートをを用いた場合には, 人々の実空間における振舞いも含んだ移動時間を扱ったため, 時間的な範囲が仮想的な移動時間と比べて大きくなっており, それにともない地理的な範囲も相対的に大きくなっており, 図 14(B) (b) のように地理的に離れていても近接地域クラスタとして抽出されたと考えられる. 移動量に関しては, パーソントリップ OD 量データを

用いて実際に抽出された上位 30 件の近接地域クラスタを具体的に調べると、基点地域クラスタと地理的に近接している大阪府内の地域クラスタが 13 個、大阪府の西側に隣接している奈良県内の地域クラスタが 17 個であった。このことから、この基点地域クラスタにおいて、通勤や通学などの日常生活における規則的な移動はアクセスが便利な地域クラスタとの間で頻繁に起こっているといえる。これに対し、Twitter のジオタグ付きツイートをを用いた場合には、大阪府内の地域クラスタが 25 個、兵庫県内の地域クラスタが 3 個であり、奈良県内の地域クラスタが 1 個、和歌山県内の地域クラスタが 1 個であった。この結果から、多様な目的を持った人々による一般的な移動は、大阪湾沿岸の地域クラスタだけでなく、より広域的な領域内の近接地域クラスタとの間で頻繁に起こっていることが分かる。

### 4.3 実験の考察

パーソントリップ OD 量データを用いた近接性と Twitter のデータを用いた近接性を、3 つの地域クラスタを中心として比較した。その結果、パーソントリップ OD 量データを用いた場合には、通勤や通学などの日常的で規則的な移動に関わる地域クラスタとの近接関係を判定することができた。一方、Twitter のデータを用いた場合には、通勤や通学だけに限定した移動だけでなく、多様な人々の実際の移動に関わるような地域クラスタとの近接関係を判定することができた。また、中心とする地域クラスタの特徴は人々の移動に影響しているため、Case 1 の大阪駅の地域クラスタのような都心では、規則的な移動が郊外の地域クラスタとの強くつながっていることから、パーソントリップ OD 量データに基づく近接地域クラスタは、Twitter のデータに基づき抽出された近接地域クラスタよりも、地理的により広い範囲から抽出されていた。Case 2 の京都駅の地域クラスタや Case 3 の関西国際空港の地域クラスタでは、日常的な移動がローカルエリアを中心に起こっているため、パーソントリップ OD 量データに基づく近接地域クラスタよりも、Twitter のデータに基づき抽出された近接地域クラスタの方が、地理的に広域範囲に及んでいた。このように、これらのデータセットから観察可能な人々の移動経験は性質が異なるため、抽出される近接地域クラスタにもその違いが明確に表れていた。そのため、これらをユーザの目的に応じて補完的に用いることで、より効果的に都市における近接性を把握することが可能になると期待できる。

## 5. 議論：群衆の経験に基づく近接性を活用するためのシステムに向けて

本章では、位置ベース SNS に基づく群衆の距離感の探求と活用のための本研究の貢献について簡単にまとめる。

- **位置ベース SNS を通じた群衆の移動モニタリング** 本稿では、Twitter から取得される群衆のライフログのユー

ザ ID、発信時間、位置情報を用いてモニタリングすることができる最もメタなレベルでの群衆の移動経験を扱った。しかしながら、ライフログにはテキストメッセージも含まれており、それを分析することにより、人々の移動の目的やそのときの感情やトピックだけでなく、ユーザの属性を把握することも可能である。今後の課題として、このような群衆の移動を意味的に分析し、それに基づきクラスタリングした結果に対して、今回提案した近接性の分析を行うことも可能であると考えている。また、今回は、パーソントリップ OD 量データから取得した群衆の移動に基づく近接性との比較を行ったが、群衆の移動パターンは、平日・休日や季節などによって変化するため、さまざまな時間の粒度でモニタリングした結果の分析についても行う予定である。

- **都市空間での近接感を表す尺度の定義および表現** 本稿で述べた都市空間の近接性は、人々の「近い」という感覚に焦点を当てた認知距離である。認知距離は地理的空間内で認知される距離であるが、『見えない距離』とも呼ばれている [3]。それゆえに、都市空間での近接性を直感的に把握可能な尺度として定義することが重要である。さらに、地域案内や地域推薦に活用するために、都市空間の近接性の効果的な視覚化手法について検討することが必要である。

- **ユーザの目的に応じた近接地域検索** 本稿では、群衆移動に関わる 3 つの指標（移動空間距離、移動時間、移動量）をそれぞれ優先した場合の地域クラスタ間の近接性がどのように異なるのかについて分析した。特に、今回は正確かつ詳細に分析を行うというよりも、できるだけシンプルな算出式を用いた。しかしながら、3 つの指標の積による算出式などを用いることによっても近接性を測定することが可能であると考えられる。これについては、ユーザの目的に合わせて、地域クラスタ間の近接性をどのように応用するかによって適切な式を定義する必要があると考えられるため、今後の課題として検討する予定である。

## 6. まとめ

本稿では、都市空間で移動する群衆にとって重要な空間認知の 1 つである近接感に着目し、都市空間における群衆の移動経験を簡単かつ大規模に扱うことができる位置ベース SNS を通じてモニタリングし、地域クラスタ間の近接性を分析するための手法を提案した。特に、空間的、時間的、親近的という 3 つの観点から地域クラスタ間の近接関係を分析するために、群衆の移動から移動距離、移動時間、移動量を抽出し、都市空間における群衆の経験的・社会的な近接性を分析した。実験では、Twitter から取得したデータを用いて抽出した群衆の移動経験に基づき都市空間の近接性と社会調査の一環として行われているパーソントリップ OD 量データによって得られた群衆の移動に基づく都市空間の近接性を示して比較した。その結果、パーソント



リップ OD 量データを用いた場合には、通勤や通学などの日常的な生活における規則的な移動に基づく近接地域クラスタを抽出することができた。これに対して、Twitter のデータを用いた場合には、パーソントリップ OD 量データを用いた場合よりも多様な人々の移動経験に基づく近接地域クラスタを抽出することができた。このことから、これらのデータセットに基づく結果をそれぞれ補完的に用いることができると期待される。

今後の展開として、提案手法により分析した地域クラスタ間の近接性を活用した地理的な意思決定支援のためのシステムを開発することを計画している。具体的には、ある地域にいるユーザに対して、今回提案した空間的、時間的、親近的な近接性に対する重みをユーザが調整し、周辺地域を検索することができるインタフェースの開発や、近接関係の地域クラスタを視覚的に強調して表現するためのインタフェースの開発を行うことを考えている。さらに、群衆のライフログに含まれているテキストメッセージを分析して群衆の移動を分類することによって、ユーザの属性や移動の意図を考慮した都市空間の近接性を分析することを計画している。

**謝辞** 本研究の一部は、平成 24 年度特別研究員奨励費 (24.9154) によるものである。ここに記して謹んで感謝の意を表する。

## 参考文献

- [1] Ahern, S., Naaman, M., Nair, R. and Yang, J.H.-I.: World Explorer: Visualizing Aggregate Data from Unstructured Text in Geo-referenced Collections, *Proc. 7th ACM/IEEE-CS joint conference on Digital libraries (JCDL'07)*, pp.1-10 (2007).
- [2] Briggs, R.: Methodologies for the measurement of cognitive distance, *Environmental Knowing, Theories, Research and Methods*, Moore, G.T. and Golledge, R.G. (Eds.), pp.325-334, Dowden, Hutchinson & Ross (1976).
- [3] Cadwallader, M.: Cognitive distance in intraurban space, *Environmental Knowing, Theories, Research and Methods*, Moore, G.T. and Golledge, R.G. (Eds.), pp.316-324, Dowden, Hutchinson & Ross (1976).
- [4] Choudhury, M.D., Feldman, M., Amer-Yahia, S., Golbandi, N., Lempel, R. and Yu, C.: Constructing Travel Itineraries from Tagged Geo-Temporal Breadcrumbs, *Proc. International Conference on World Wide Web (WWW)*, pp.1083-1084 (2010).
- [5] Choudhury, M.D., Feldman, M., Amer-Yahia, S., Golbandi, N., Lempel, R. and Yu, C.: Automatic Construction of Travel Itineraries Using Social Breadcrumbs, *Proc. ACM Conference on Hypertext and Hypermedia (HT)*, pp.35-44 (2010).
- [6] Cover, T. and Hart, P.: Nearest neighbor pattern classification, *IEEE Trans. Information Theory*, Vol.13, Issue: 1, pp.21-27 (1967).
- [7] Day, R.A.: Urban distance cognition: Review and contribution, *Australian Geographer*, 13-3, pp.193-200 (1976).
- [8] Hasegawa, K., Ma, Q. and Yoshikawa, M.: Trip Tweets Search by Considering Spatio-temporal Continuity of User Behavior, *Proc. 23rd International Conference on Database and Expert Systems Applications (DEXA 2012)*, LNCS 7447, pp.141-155 (2012).
- [9] Kruskal, J. and Wish, M.: Multidimensional scaling, *Sage University Papers on Quantitative Applications in the Social Sciences*, pp.07-011 (1978).
- [10] Kurashima, T., Iwata, T., Irie, G. and Fujimura, K.: Travel Route Recommendation Using Geotags in Photo Sharing Sites, *Proc. ACM Conference on Information and Knowledge Management (CIKM)*, pp.579-588 (2010).
- [11] Lee, R., Wakamiya, S. and Sumiya, K.: Discovery of unusual regional social activities using geo-tagged microblogs, *World Wide Web Special Issue on Mobile Services on the Web*, Vol.14, No.4, pp.321-349 (2011).
- [12] Lee, R., Wakamiya, S. and Sumiya, K.: Urban Area Characterization based on Crowd Behavioral Lifelogs over Twitter, *Personal and Ubiquitous Computing*, Vol.17, Issue 4, pp.605-620 (2013).
- [13] Leung, K.W.-T., Lee, D.L. and Lee, W.-C.: CLR: A Collaborative Location Recommendation Framework based on Co-Clustering, *Proc. ACM SIGIR Conf. on Research and Development in Information Retrieval (SIGIR)*, pp.305-314 (2011).
- [14] Lightfoot, C. and Steinberg, T.: Travel-time Maps and their Uses (2006), available from <http://www.mysociety.org/2006/travel-time-maps/>.
- [15] Mislove, A., Lehmann, S., Ahn, Y.Y., Onnela, J.P. and Rosenquist, J.N.: Understanding the Demographics of Twitter Users, *Proc. 5th International AAAI Conference on Weblogs and Social Media (ICWSM'11)*, pp.133-140 (2011).
- [16] Pang, Y., Hao, Q., Yuan, Y., Hu, T., Cai, R. and Zhang, L.: Summarizing Tourist Destinations by Mining User-generated travelogues and photos, *Comput. Vis. Image Underst.*, Vol.115, No.3, pp.352-363 (2011).
- [17] Pocock, D.: The cognition of intra-urban distance, a summary of Scottish, *Geographical Magazine*, Vol.94, No.1, pp.31-35 (1978).
- [18] Yuan, J., Zheng, Y. and Xie, X.: Discovering Regions of Different Functions in a City Using Human Mobility and POIs, *Proc. 18th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, KDD'12*, pp.133-140 (2012).
- [19] Wakamiya, S., Lee, R. and Sumiya, K.: Crowd-sourced Cartography: Measuring Socio-cognitive Distance for Urban Areas based on Crowd's Movement, *Proc. 4th International Workshop on Location-Based Social Networks, LBSN'12*, pp.935-942 (2012).
- [20] Wakamiya, S., Lee, R. and Sumiya, K.: Measuring Crowd-sourced Cognitive Distance between Urban Clusters with Twitter for Socio-cognitive Map Generation, *Proc. 4th International Conference on Emerging Databases-Technologies, Applications, and Theory, EDB'12*, pp.181-192 (2012).
- [21] Wakamiya, S., Lee, R. and Sumiya, K.: Looking into Socio-cognitive Relations between Urban Areas based on Crowd Movements Monitoring with Twitter, *DBSJ Journal*, Vol.11, No.2, pp.19-24 (2012).
- [22] Zheng, V.W., Zheng, Y., Xie, X. and Yang, Q.: Collaborative Location and Activity Recommendations with GPS History Data, *Proc. International Conference on World Wide Web (WWW)*, pp.1029-1038 (2010).
- [23] 太田宏佑: 東京から地方都市への認知距離の歪みについての研究, 入手先 (<http://jre.sfc.keio.ac.jp/review12/ronbun/oota.pdf>).

- [24] 岡 瑞起, 橋本康弘, 笹原和俊, 池上高志: カートグラムを用いた空間のアフォーダンスの可視化, インタラクシオン 2011 (2011).
- [25] 岡本耕平: 認知距離研究の展望, 人文地理, Vol.34, No.5(1), pp.45-64 (1980).
- [26] 李 龍, 若宮翔子, 角谷和俊: Tweet 分析による群衆行動を用いた地域特徴抽出, 情報処理学会論文誌データベース (TOD54), Vol.5, No.2, pp.36-52 (2012).



若宮 翔子 (学生会員)

2011年兵庫県立大学大学院環境人間学研究科博士前期課程修了。現在、兵庫県立大学大学院環境人間学研究科博士後期課程在学中。日本学術振興会特別研究員 (DC2)。ソーシャルメディア・マイニング, 群衆マイニング, マルチメディア・データベースに関する研究に従事。日本データベース学会学生会員。



李 龍 (正会員)

2001年京都大学大学院情報学研究科社会情報学専攻修士課程修了。2003年京都大学大学院情報学研究科社会情報学専攻博士課程修了。同年韓国 SAMSUNG 総合技術院入社。2008年兵庫県立大学環境人間学部環境人間学科特任講師。2009年兵庫県立大学環境人間学部環境人間学科特任准教授。2011年情報通信研究機構研究員。同年兵庫県立大学環境人間学部環境人間学科客員研究員。現在に至る。ソーシャルネットワーク, 群衆マイニング, ウェブ情報検索, 地理情報処理に関する研究に従事。博士 (情報学)。電子情報通信学会, 日本データベース学会等各会員。



角谷 和俊 (正会員)

1988年神戸大学大学院工学研究科修士課程修了。同年松下電器産業 (株) 入社。ソフトウェア開発環境, マルチメディアデータベース, データ放送の研究開発に従事。1998年神戸大学大学院自然科学研究科博士後期課程情報メディア科学専攻修了。1999年神戸大学都市安全研究センター都市情報システム研究分野講師, 2000年同助教授。2001年京都大学大学院情報学研究科社会情報学専攻助教授。2004年兵庫県立大学環境人間学部環境人間学科教授。現在に至る。博士 (工学)。IEEE Computer Society, ACM, 電子情報通信学会, 日本データベース学会等各会員。

(担当編集委員 鎌原 淳三)