特集
Special Feature

［観光情報学―スマートツーリズムに向けた研究動向―］

5 人流クラスタリング解析

応用 一般




田中宏季　中村　哲

理化学研究所革新知能統合研究センター（AIP）観光情報解析チーム／
奈良先端科学技術大学院大学

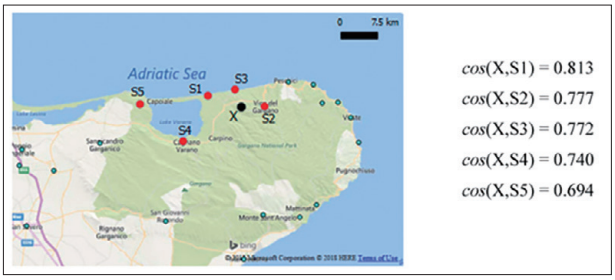
人流解析の概要

本特集の第 1 章「ポストコロナにおける観光」でも紹介した通り，観光においては，どのような旅行者が，いつ，どこに訪問するのか，旅行者にとっても，現地におけるサービス提供者にとっても，移動や宿泊を提供する業者にとっても重要である．現在は携帯型機器の普及と位置情報取得の精度向上により，人の移動を容易に追跡可能となった．我々は，理化学研究所 革新知能統合研究センター（AIP）観光情報解析チームとして，観光客をはじめとした人流の解析を行い，スマート観光へと繋げていくことを目指している．本稿では，観光における行動変容に必要な要素である人流解析技術について説明する．

携帯型機器から取得される位置情報は移動履歴を知る非常に重要な情報源となり得る．人がどのように移動をするのかを調べるためには，ただ訪問した場所の情報だけでなく移動履歴を考慮することによって，よりよく人流を解釈することができると考えられる．これまでの位置情報の解析では，場所間の距離など地理的な近さに着目する研究が中心であった．近年の深層学習の発展により，Crivellari らの研究では場所間に存在する行動近接，その行動がその周辺の場所に対してどのような意味を持つ行動なのかというところに焦点を当てている [1), 2)]．

自然言語処理における Word2Vec などの単語の分散表現とは，文章中にある単語の周辺単語を確率的に扱い，単語間の関係を分散表現として獲得する手法である．この考えは人流解析においても応用されてきている．Crivellari らの研究 [2)] では，Word2Vec を土台とした手法である Mot2Vec を提案した．移動履歴系列の位置的な距離をただ考慮するのではなく，行動近接性という行動そのものの意味的な近さを考慮することで，移動履歴から得られる訪問した場所の分散表現を獲得した．得られた分散表現により，訪問地間の関係性を議論した（図 -1 参照）．また，得られた分散表現から系列長の異なる移動履歴をベクトル化し，コサイン類似度を計算することで，その移動履歴系列間の類似度についての議論を試みている．その他の研究では，分散表現を訪問地クラスタリングに応用している研究など [3)] がある．

移動履歴は時系列データとしても扱うことが可能である．時系列の情報を用いたモデルとして，Long-Short Term Model（LSTM）に基づく手法 [1)] が提案されている． 移動履歴系列を学習する際に，LSTM は手動で特徴を抽出することなく，移動履歴系列から直接その行動パターンを捉えることが可能である．LSTM を用いた人流予測では，次の訪問地を予測することによって移動経路パターンを学習す



■図 -1　コサイン類似度に基づいた訪問地間の関係性 [2)]

© 2021 Information Processing Society of Japan

る．Crivellari ら [1]の評価では，7 カ月にわたるイタリアローマの携帯電話記録データセットを用いて行動パターンの予測を行い，LSTM が他の手法に比べ，予測において有効であるということを示した．

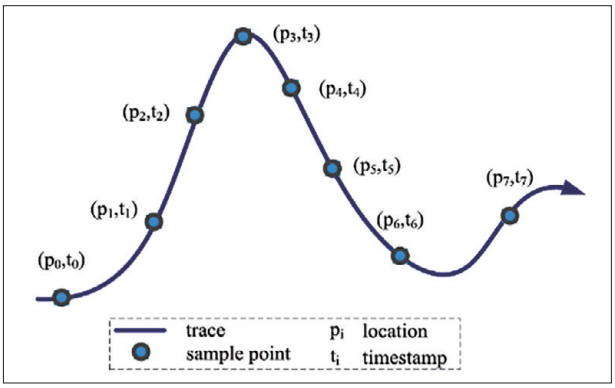
これらの研究群に関して，以下では，人流データの紹介，訪問地予測，内部分散表現ベクトルに基づいた人流クラスタリング，クラスタリングの可視化を紹介する．

人流データ

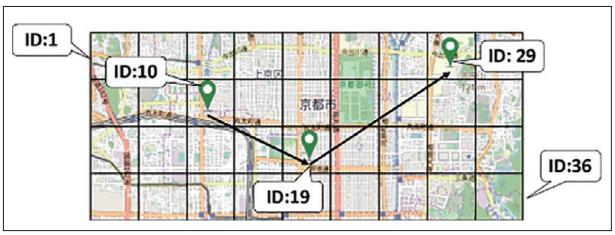
実際に人流データを解析していく上でのデータの種類，サンプリングなどを説明する．我々は（株）Agoop よりデータ提供を受け研究を行っていることから，そのデータ形式を中心に説明する．

メッシュ型流動人口データ

メッシュの範囲についてある特定時間内でどの程度の人口があるかを記録したデータである．昨今盛んに議論されている COVID-19 関連の主要駅の人流増減についてもこのデータに基づいて計算可能となる．どの観光地に人出が多いかもこのデータにより分析可能となる．



■図 -2　移動経路のサンプリング [4]



■図 -3　メッシュ ID でのサンプリング（京都市の観光地での例）[5]

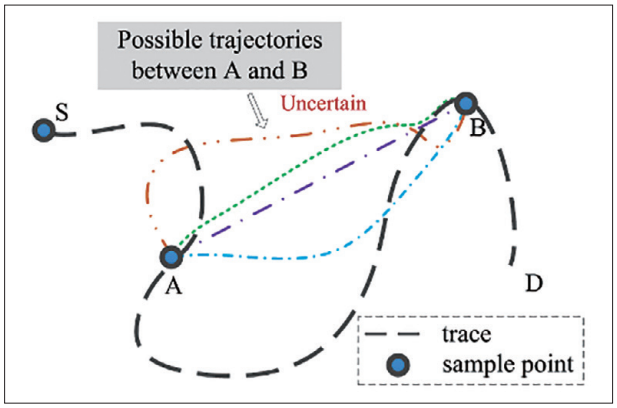
ポイント型流動人口データ

メッシュ型流動人口データよりも，詳細な人の位置情報，軌跡を得ることのできるデータである．データはスマートフォンアプリから取得された多次元のログデータである．データは時間情報および位置情報（緯度・経度），ユーザ属性（国籍，職場などを含む）である．

サンプリングとプライバシーの保護

データのサンプリングについては携帯端末の仕様によっても変わってくるが，一般的には，30 分間隔，あるいは特定のアプリが起動している時間に取得されるなどの処理がなされる（図 -2）[4]．緯度・経度，およびそれに付随したメッシュ ID が位置を表す情報である．メッシュ ID とは，緯度・経度に基づき，100m 四方などのある一定の区域に離散的に訪問場所を分類する方法である（図 -3）．またサンプリング間隔が空いてしまうと，移動方法を含めた移動履歴の不確実性の問題も残る（図 -4）[4]．

また，プライバシー保護は，人流データ解析において重大な問題である．移動履歴データの処理方法と機密情報の保護のために，いくつかの方法が提案されている．たとえば，個人に対して日ご



■図 -4　サンプリングの時間間隔によっては，移動経路の不確実性が残る [4]

© 2021 Information Processing Society of Japan

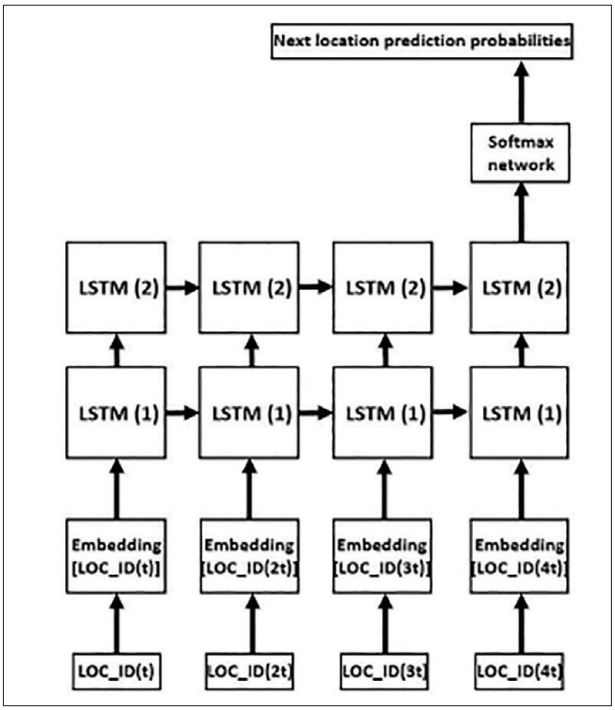
とに匿名 ID を割り当て，日ごとでその ID をリセットすることなどが挙げられる．しかしながら，この方法では同一人物を毎日追跡するような解析は困難となる．

訪問地予測モデル

訪問地予測とは，これまでの移動経路から次の訪問地を予測していく問題である[1]．これまでにも種々の取り組みがなされてきたが，近年の深層学習の発展により，再帰型ニューラルネットワークを用いたモデルが提案されてきている．ここで，モデル内部の分散表現はクラスタリングに使用することができる．

再帰型ニューラルネットワークを用いたモデル

図 -5 に Crivellari らによって提案された LSTM による次の訪問地予測のモデルを示す[1]．このモデルでは 2 層の LSTM により，これまで訪問した移動系列の情報を保持し，次に訪問する場所を予測している．図 -6 では，Global Markov model と比較した際の，テスト用データでの訪問地予測の距離毎の誤差を示している．



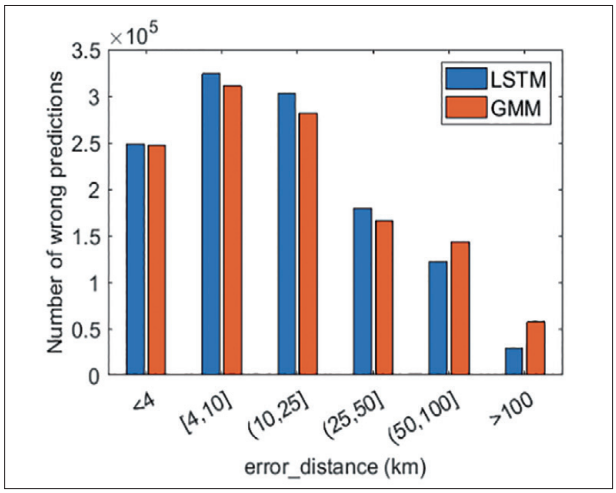
■図 -5　LSTM によるメッシュ ID 予測の概略図[1]

双方向性再帰型ニューラルネットワークを用いたモデル

久保ら[5]は，解析に使用するデータはすでに人が訪問した行動系列はすべて揃っているということを利用して双方向性 LSTM（Bi-LSTM）を用いることによって訪問地予測を行った．これにより予測精度を向上させるだけでなく，獲得する内部表現についてもより表現力が上がることを期待した．この手法の特徴としては，LSTM と比べて現在から未来の予測だけではなく，現在から過去の予測を双方向的に同時に行うことによる精度向上を図る点である．図 -7 にモデルの概略図を示す．図 -8 ではモデル学習における学習データと検証データにおける誤差を示している．

久保ら[5]は，このモデルを京都市の海外からの観光客人流データに適用し，次のメッシュ ID 予測を行ったところ，テストデータで 52.8% の精度を得ている．

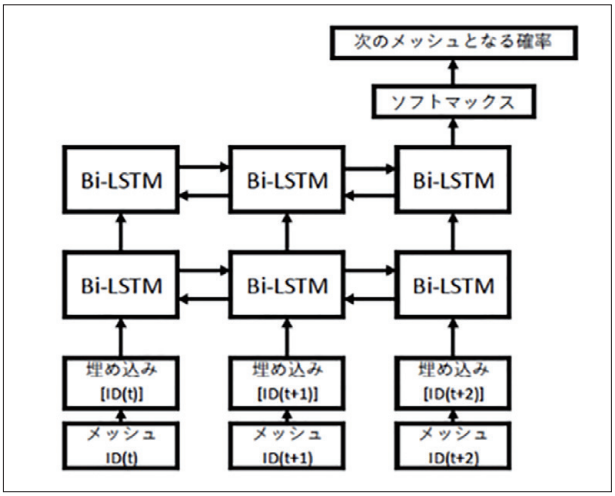
また，これまでのモデルではメッシュ ID のみを入力としていたため，その離散性から各訪問地の位置的関係や距離等をうまく学習できていない可能性



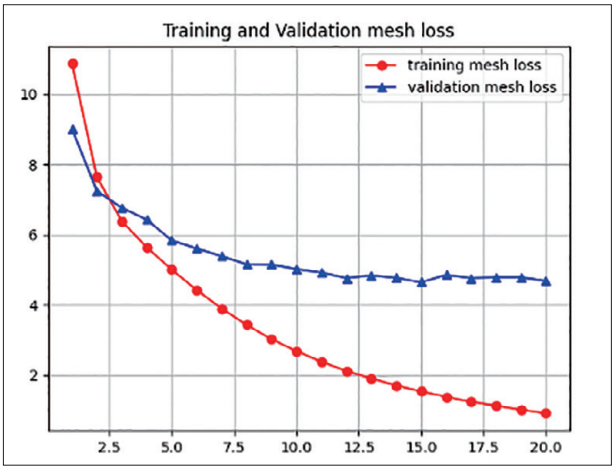
■図 -6　距離（km）ごとの予測誤差[1]

© 2021 Information Processing Society of Japan

があった．そこで，佐賀ら[6]はニューラルネットワークへの入力として，メッシュ ID だけではなく，連続的な緯度と経度の値を追加することで位置的関係性も学習させ，表現力の向上を試みた．図 -9 に手法の概略図を示す．佐賀ら[6]は，このモデルを東京都の次のメッシュ ID 予測に適用し，テストデータで 34% の精度を得ている．ここで，京都と比較した場合東京都では精度が下がっているように見えるが，京都市では全メッシュ ID 数が約 8 千（面積 827.83 平方キロメートル）であるのに対し，東京都では約 2 万（面積 2,193.96 平方キロメートル）であるため，クラスの数は異なる．



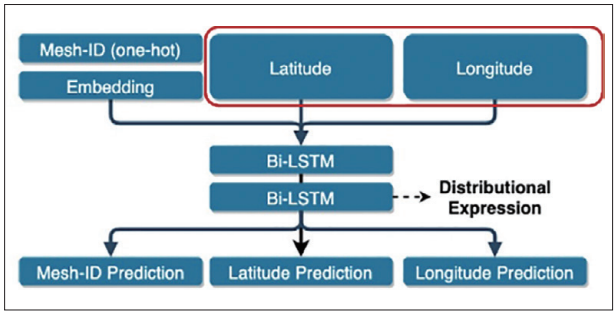
■図 -7　Bi-LSTM によるメッシュ ID 予測の概略図[5]



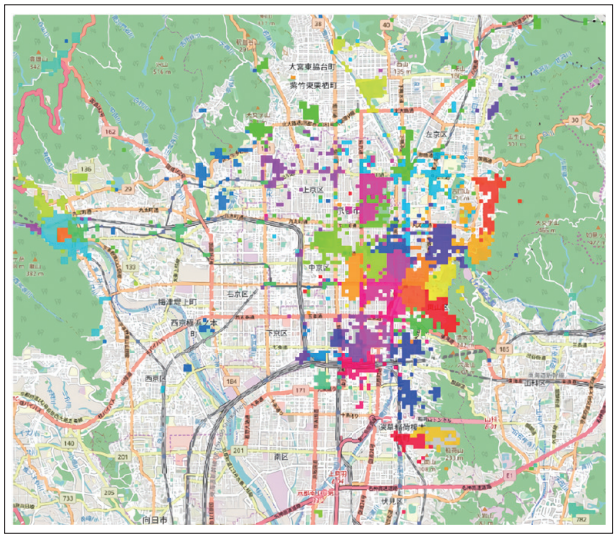
■図 -8　次のメッシュ ID 予測の誤差の学習曲線[5]

人流クラスタリング

これまでに紹介した，Bi-LSTM を用いて過去の訪問地からある未来の訪問地を予測する問題，および未来の訪問地からある過去の訪問地を予測する問題を解くことによって，各ユーザの分散表現を獲得し，クラスタリングを行うことが可能となる．これまでにも，分散表現を入力として，訪問地のクラスタリングに応用する研究[3]が存在する．Hirota ら[3]は，K-means アルゴリズムを用いて，クラスタ数 50 として京都市の訪問地をクラスタリングしている（図 -10）．移動履歴は時系列データとしても扱うことが可能であるため，久保ら[5]は，前述した双方向性再帰型ニューラルネットワークを用いて入力系列に対する分散表現として，最



■図 -9　緯度経度情報を加えた Bi-LSTM によるメッシュ ID 予測の概略図[6]



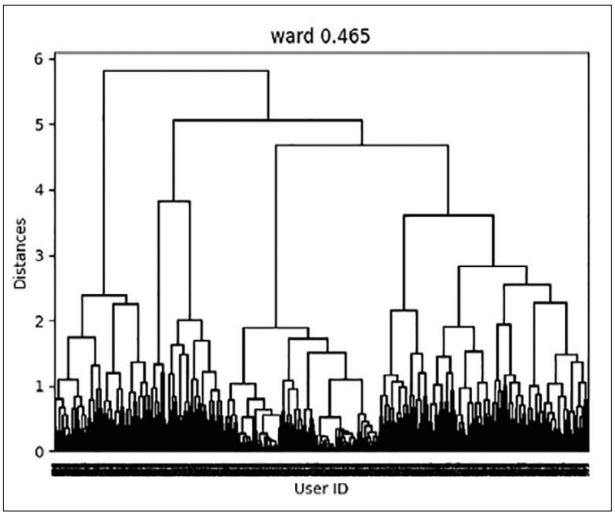
■図 -10　訪問地のクラスタリング例[3]

© 2021 Information Processing Society of Japan

特集
Special Feature

終層の Bi-LSTM の順方向と逆方向の隠れ状態を用いて，階層的クラスタリングを行った．階層的クラスタリングにおけるクラスタの併合方法の中でも分類感度が高いとされるウォード法（クラスタ数 8）を用いている．評価指標はコーフェン相関係数を用いることで，クラスタ階層の妥当性検証を試みている．図 -11 に東京都歌舞伎町（2020 年 2 ～ 5 月中）を経由したユーザに限定したクラスタリング結果を示す．

ここで，得られたクラスタの代表的な行動系列について，クラスタの近傍ユーザを分析する．人流クラスタリングでは，正解のクラスタというものが存在しないため，正解と比較した評価はできない．今回，Bi-LSTM の系列表現を階層的クラスタリングすることにより得られたクラスタ 5 および 6 について地図上に経路を描画してその傾向を分析している．ここで，東京都新宿歌舞伎町を経由したユーザのみを事前にフィルタリングし，クラスタリングの対象としたことに注意されたい．クラスタ 5 およびクラスタ 6 の重心値に最近傍のユーザ 1 名の経路を図 -12 に描画する．両者とも新宿歌舞伎町を経由しているが，クラスタ 6 では，よりその近郊に滞在していることが分かる．



■図 -11　Bi-LSTM の分散表現に基づくユーザのクラスタリング結果

人流可視化システム

我々は，クラスタとユーザがどのように移動するかを示すためのデモシステムを構築した．人流クラスタリングにより得られたクラスタに基づいて，クラスタに属する重心ユーザまたは全ユーザの実際の移動経路を描画できる（図 -13）．

まず，各クラスタの分散表現の平均を算出することにより，重心ベクトルを計算した．次に，コサイン類似度に基づいて重心ベクトルから最も近い K 人ユーザを計算する．地図上において，近傍 K ユーザ，または任意のユーザ，それに伴った職場 ID などの属性情報も確認できる仕様となっている．ユーザが異なれば，色も異なり表示される．人流可視化システムには，時間範囲，場所，および地図上に描画される最近傍ユーザの数をフィルタリングする機能が含まれている．



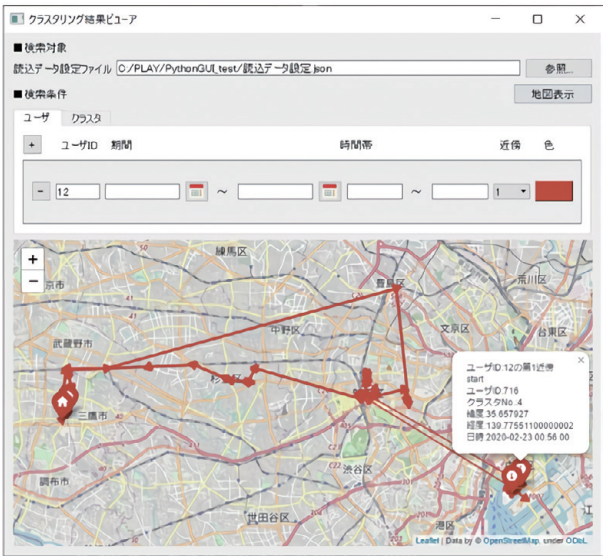
■図 -12　東京都，新宿歌舞伎町を経由するクラスタの重心ユーザの移動経路

© 2021 Information Processing Society of Japan

特集
Special Feature

今後の展望

本稿では，人流解析クラスタリングについて，その分散表現の獲得から階層的クラスタリングまでの，これまでの研究群を紹介した．今後の課題として，まずデータ処理に関しては，サンプリング間隔の一貫性や，移動経路の不確実性の問題について考慮しなくてはならない．またプライバシー保護の限界を踏まえ，どのように日ごとの変化の検出をしていくか検討が必要である．モデルに関して，Variational Auto-encoder などを利用した分散表現の高度化の検討も必要である．および，得られたクラスタに対して，クラスタ数の検討，ユーザ属性，国籍，訪問地の Point of Interest（POI）との関連を調べていき，よりクラスタの解釈性を向上させていく必要がある．今後，行動系列の精密なモデリングができれば，次行動予測，異常行動の検知にも発展できる．これらの情報を活用することで，サービス提供者や地方自治体に適切なサービスの提供が可能となる．



■図 -13　構築した人流可視化システム

参考文献

1）Crivellari, A. and Beinat, E. : LSTM-Based Deep Learning Model for Predicting Individual Mobility Traces of Short-Term Foreign Tourists, Sustainability, Vol.12(1) (2020).
2）Crivellari, A. and Beinat, E. : From Motion Activity to Geo-Embeddings: Generating and Exploring Vector Representations of Locations, Traces and Visitors through Large-Scale Mobility Data, ISPRS International Journal of Geo-Information, Vol.8 (2019).
3）Hirota, M., Oda, T., Endo, M. and Ishikawa, H. : Generating Distributed Representation of User Movement for Extracting Detour Spots, Proceedings of the 11th International Conference on Management of Digital Eco Systems (2019).
4）Feng, Z. and Zhu, Y. : A Survey on Trajectory Data Mining : Techniques and Applications, IEEE Access, Vol.4, pp.2056–2067 (2016).
5）久保　基，田中宏季，中村　哲：観光行動理解のための分散表現に基づくユーザクラスタリング，人工知能学会全国大会，pp.1-4 (June 2020).
6）佐賀健志，田中宏季，中村　哲：緯度経度情報追加による行動履歴分散表現の高精度化，人工知能学会全国大会，pp.1-4 (June 2021).

（2021 年 7 月 30 日受付）

■田中宏季　hiroki-tan@is.naist.jp

2010 年旭川工業高等専門学校生産システム工学専攻卒業．2015 年奈良先端科学技術大学院大学博士後期課程修了．現在，奈良先端大助教，および理化学研究所 革新知能統合研究センター客員研究員．

■中村　哲（正会員）　satoshi.nakamura.vr@riken.jp

ATR，情報通信研究機構などを経て，現在，理化学研究所革新知能統合研究センター観光情報解析チームリーダ，奈良先端大データ駆動型サイエンス創造センター長，教授．観光情報解析，音声言語情報処理の研究に従事．本会業績賞．本会，IEEE，ISCA フェロー．

© 2021 Information Processing Society of Japan