

時系列分散表現に基づく 東京都の人流クラスタリング

田中 宏季, 久保 基, 中村 哲

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 / 奈良先端科学技術大学院大学

hiroki.tanaka.ks@riken.jp

概要: 本研究では、人流解析法の構築を目指し、時系列の分散表現を使用して、東京都の 2020 年 2~5 月におけるスマートフォンユーザの行動系列 (100m 四方もしくは 50m 四方メッシュ ID) からユーザをクラスタ化することを試みた。先行研究では、再帰型ニューラルネットワーク (LSTM: Long Short Term Memory) を使用して、これまでの経路からユーザの次の訪問場所を予測するモデルを学習している。本研究では、それを注意機構付き双方向 LSTM (Bi-LSTM) に拡張し、LSTM との比較を試みた (テストの正解率で 0.5 を達成)。さらに、特に東京都新宿歌舞伎町地域における、LSTM および Bi-LSTM から導出された分散表現ベクトルの距離に基づいてユーザのウォードクラスタリングを試みた。本研究では Bi-LSTM にすることによるメッシュ予測の精度変化、階層的クラスタリングの結果について議論する。

Keyword: 人流解析, 双方向 LSTM, 階層的クラスタリング, 分散表現

1. はじめに

携帯型機器の普及と位置情報取得の精度向上により、人の移動が容易に追跡可能となった。このような端末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行動ルート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 [1]。これまでの位置情報の解析 [2,3,4] では、場所間の距離など地理的な近さに着目する研究中心であったが、Crivellari らの研究 [1] 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ことに焦点を当てている。

人流は時系列データとして扱うことができる。何時どのような場所に行ったかということを理解することは、人の行動パターンを理解するためには必要不可欠である。これまで、時系列モデルを用いた移動履歴における次の行き先を予測する研究 [5] がある。この Crivellari らの研究では、過去から未来への一方再帰型ニューラルネットワークモデル (LSTM: Long Short Term Memory) による手法が、移動履歴系列以外に特別な情報なしで行動パターンの予測を行えるとして、その有用性を報告している。

我々のグループでは観光情報に関する種々の解析を進めている。 [9]。人流解析については、Crivellari [5] の研究に対し、行動データから得られる移動履歴系列に対して、現在から未来に亘る行動系列に加えて現在から過去に亘る行動系列を考慮した行動近接性をもつ位置埋め込み表現を獲得し得られた位置埋め込み表現から移動履歴系列をベクトル化し、さらに、新たにベクトル化された移動履歴系列をクラスタリングすることにより、任意のユーザの移動履歴系列を解析し、その行動パターンを抽出することを試みた [8]。本研究では、この人流解析法の応用として、東京都における 2020 年 2~5 月のデータを解析することを試みた。100m 四方メッシュおよび、より詳細な 50m 四方メッシュによる次メッシュ予測精度、得られた分散表現からの人流経路のクラスタリングを実施した。

2. 関連研究

Word2Vec [6] による分散表現では、単語の分散表現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。この考えを利用して、移動履歴パターン

解析においても用いられている。Crivellari らの研究 [1]では、Word2Vec をベースとした手法である Mot2Vec を提案した。移動履歴系列を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、訪問地間の意味の近さについて議論した。また、得られた分散表現から移動履歴系列をベクトル化し、得られたベクトル間でのコサイン類似度を計算することで、その行動系列間の類似度についても議論した。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されている研究 [6]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。このため、時系列の情報を用いたモデルとして、LSTM に基づく手法 [5]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と述べられている。LSTM を用いた人流予測では、あるいくつかの訪問地に対して、次の訪問地を予測することによって移動履歴パターンを学習する。実験では、7ヶ月に亘るイタリア（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、他時系列モデルとの比較を精度により、人流パターンの予測において有効であるということが示された。

3. 提案手法

本節では、(1) 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タスク及び未来の訪問地からある過去の訪問地を予測するタスクを解くことによって各訪問地の分散表現を獲得し、(2) 獲得された分散表現から移動履歴系列をベクトル化して、(3) その得られた行動系列のベクトルのクラスタリングを行うことによって移動履歴の理解につなげる手法を提案する。

3.1 移動履歴データ¹

今回解析に使用す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。今回用いるデータは時間情報及び位置情報（緯度・経度、メッシュ ID）、ユーザ属性に大別される。我々は、位置情報として 100m 四方メッシュおよび 50m 四方メッシュを算出した。

3.1 Bi-LSTM を用いた移動履歴予測による分散

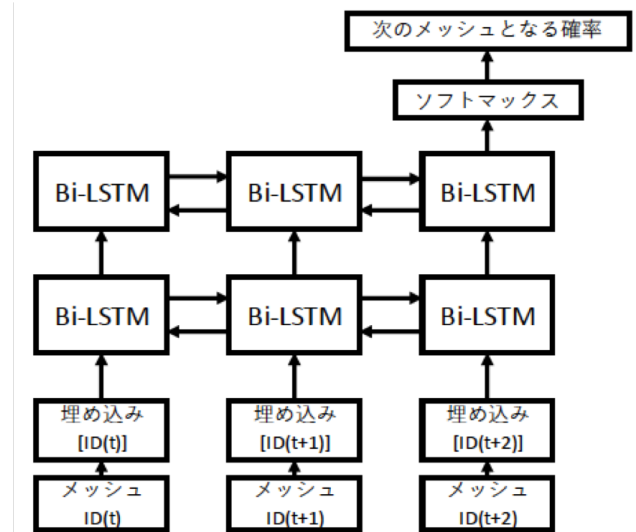


図1 Bi-LSTM による次のメッシュ予測 [8]

表現の獲得

今回解析に使用するデータは既にユーザが訪問した行動系列は全て揃っているということを利用して、Bi-LSTM を用いることによって、双方向の予測を行う。このようにすることで、予測精度を向上させるだけでなく、獲得する分散表現についても、よりメッシュ間の内部表現において移動履歴系列の行動の意味が考慮された強固な分散表現が得られるのではないかと考えられる。今回提案する手法の特徴としては、従来の手法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に同時に行うことによる精度向上を図る点である。図1に提案手法の概略図を示す。

提案手法は、先行研究 [5]の LSTM 層を Bi-LSTM 層に置き換えた形になっている。それ以外は先行研究と同じモデルの構造である。図1における右方向の LSTM が順方向 LSTM で、左方向の LSTM は逆方向 LSTM である。Bi-LSTM の出力はそれぞれの LSTM の層から出力されるベクトルが結合されたものであり、2層目の Bi-LSTM の出力は順方向 LSTM 及び逆方向 LSTM の最終隠れ層のベクトルを結合したものである。表1に提案する Bi-LSTM によるメッシュ予測のパラメータを示す。最大系列長はメッシュ予測の際、どの長さまでのメッシュ経路から次のメッシュを予測するかというパラメータである。Embedding 層のユニット数及び LSTM ユニット数は 300 とした。バッチサイズとエポック数は今回の実験では 1024 と 50 とした。最適化手法は Adam を用いた。

¹ データ提供元: 株式会社 Agoop

表 1 Bi-LSTM のパラメータ

最大系列長	100
モデル構造	(Input, Embedding, Bi-LSTM, Bi-LSTM, Dense)
Embedding 層ユニット数	300
隠れ層の数	300
バッチサイズ	1024
最大エポック数	50
最適化手法	Adam
Early stopping のモニタ値	検証データの損失値

Early stopping では、検証データによる損失値をモニタリングし、その損失値の向上が見られなくなってから 3 回までは学習をするように設定した。今回のメッシュ予測では、訓練データと検証データ及びテストデータを 8:1:1 で分割し、そのデータを用いて学習を行った。テストデータはモデルの精度から各モデルの評価を行うために用いた。

3.2 行動ベクトルのクラスタリング

ここで、求めた移動履歴ベクトルのクラスタリングについて述べる。今回用いるクラスタリング手法は階層的クラスタリング（クラスタ数: 8）である。本研究では、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比較的分類感度が高いとされるウォード法を用いる。評価指標はコーフェン相関係数を用いる。コーフェン相関係数を用いることで、得られたクラスタリング結果と元の非類似度の一致度を測ることでクラスタ階層の妥当性を検証する一手法とする。また、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。

4. 解析に使用した人流データ

2020年2~5月におけるデータを利用した。行動系列総数は 30 経路以上訪問記録がある全ユーザを対象としており、35767 ユーザ分である。LSTM 及び Bi-LSTM の時系列モデルの学習データとした。また、本研究におけるクラスタリングの対象とした移動履歴系列は、訪問したメッシュが 30 以上である 20:00-4:00 に新宿歌舞伎町を訪問した 877 ユーザ分である。

5. 実験結果

本節では、提案手法を人流データに適用した実

験の結果について、メッシュ予測精度および階層的クラスタリングに分けて報告する。

5.1 メッシュ予測

本節では、LSTM のモデル及び Bi-LSTM モデルを用いた次メッシュ予測における学習結果につ

表 2 テストのメッシュ予測精度

いて、100m 四方メッシュと 50m 四方メッシュでの結果を述べる。学習結果として、テスト時の精度を、表 2 にまとめる。

提案手法である Bi-LSTM モデルを用いた手法

100m 四方メッシュ	
LSTM	0.44
Bi-LSTM	0.50
50m 四方メッシュ	
LSTM	0.37
Bi-LSTM	0.37

が 100m 四方メッシュで、より良い予測精度であるということがわかる。この精度の向上は、Bi-LSTM モデル双方向の系列を学習していることによると考えられる。また、100m 四方メッシュの方が 50m 四方メッシュに比較して高い予測精度であることが確認できる。これは 50m 四方メッシュの方が詳細な場所を獲得できるが、その分訪問のクラス数が増え、誤差が増えるためだと考えられる。

5.2 階層的クラスタリング

本節では、得られたクラスタリングの階層構造及び、得られたクラスタについて報告し、どのような人流クラスタに分けられたかについてその理由と共に考察する。図 2 に Bi-LSTM (100m 四方メッシュ) の分散表現獲得法に基づいて獲得した分散表現による階層的クラスタリングの結果を示す。各グラフの縦軸はクラスタ間距離を、横軸はユーザ ID を示しており、グラフタイトルにある数値はコーフェン相関係数を示している。本研究では、クラスタ数 8 個に上位からクラスタ化した。クラスタ 5 及びクラスタ 6 の重心に最近傍のユーザ 1 名分についての経路を図 3 にまとめる。両者とも新宿歌舞伎町を經由しているが、クラスタ 6 では、よりその近郊に滞在していることがわ

かる。




図2 ウォード法によるクラスタリング結果 (100m 四方メッシュ, Bi-LSTM). グラフタイトルに示す値はコーフェン相関係数である.

7. おわりに

本研究の目的は、時系列を考慮した移動履歴系列を解析することで、その行動パターンを抽出することである。双方向時系列を学習する Bi-LSTM を用いて系列表現を学習し、その表現ベクトルを階層的クラスタリングを行うことにより、同じ場所を訪問するルートではあるものの、その訪問順が異なる経路を近いルートとして抽出することができた。今後は、Bi-LSTM に自己注意機構の導入、学習時間の短縮や訪問ルートにおける滞在時間などを考慮して、より明確なユーザクラスタリングを行うことが考えられる。

参考文献

[1] Crivellari, A, and Euro B.: From Motion Activity to Geo-Embeddings: Generating and Exploring Vector Representations of Locations, Traces and Visitors through Large-Scale Mobility Data. ISPRS International Journal of Geo-Information 8.3: 134 (2019)
[2] Feng, Z, and Yanmin Z.: A survey on trajectory data mining: Techniques and applications, IEEE Access 4: 2056-2067 (2016)
[3] Lee, S, Lim, J, Park, J and Kim, K.: Next place prediction based on spatiotemporal pattern mining of mobile device logs, Sensors 16.2: 145 (2016)
[4] Zhang, W, Wang, X and Huang, Z.: A System of Mining Semantic Trajectory Patterns from GPS Data of Real Users, Symmetry, 11. 889. 10.3390/sym11070889 (2019)



2020年2月8日 15:25~22:51

クラスター5



2020年3月3日 11:35~23:53

クラスター6

図3 行動経路の可視化 (100m 四方メッシュ, Bi-LSTM による階層的クラスタリング) .

[5] Crivellari, A, and Euro B.: LSTM-Based Deep Learning Model for Predicting Individual Mobility Traces of Short-Term Foreign Tourists. Sustainability 12.1: 349 (2020)
[6] Mikolov, T and Sutskever, I and Chen, K and Corrado, G.S and Dean, J.: Distributed representations of words and phrases and their compositionality, Advances in neural information processing systems (2013)
[7] Hirota, M, Oda, Tetsuya, Endo, Masaki, Ishikawa, Hiroshi.: Generating Distributed Representation of User Movement for Extracting Detour Spots, Proceedings of the 11th International Conference on Management of Digital EcoSystems (2019)
[8] 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 (2019)
[9] 中村 哲, 諏訪 博彦, 須藤 克仁, Sakti Sakriani, 田中 宏季, 吉野 幸一郎, 藤本 まなと, 松田 裕貴, 安本 慶一: 理研 AIP における人流データ解析と行動変容, 観光情報学会 第 21 回研究発表会 (2020)