

時系列滞在頻度傾向と移動傾向を組み合わせた 移動先予測手法

寺島 青^{1,a)} 高木 峻¹ 田村 直樹¹ 庄子 和之¹ Tahera Hossain¹ 片山 晋¹ 浦野 健太¹
米澤 拓郎¹ 河口 信夫^{1,2}

概要：モバイル端末の普及に伴い、都市における大規模な位置情報データの収集が容易となり、位置情報データに基づく移動履歴を活用した研究が盛んに行われている。移動履歴から捉えられる移動傾向は、ユーザの将来の移動を予測する手掛かりとなり、予測結果はマーケティング戦略等での活用が期待できる。移動予測の分野においては、都市における大規模なユーザの移動履歴を用いて深層学習モデルを訓練し、予測を行う研究が多くなされている。しかし、ユーザが多い大規模な都市では学習可能な移動履歴が豊富にある一方で、ユーザが少ない小規模な都市では不十分で、予測精度が低くなる懸念がある。また、異なる都市間で移動履歴の共有を試みた場合、都市空間の構造が異なるため、移動履歴中の滞在エリア同士の対応付けが必要となる。そこで本研究では、異なる都市間で共通する時系列滞在頻度傾向と、各都市で固有の移動傾向を組み合わせた移動先予測手法を提案する。時系列滞在頻度とは、ユーザの移動履歴中の各滞在所に、時間帯毎の滞在頻度を与えたもので、都市の機能的な特徴を用いずに異なる都市間で共通に扱える特徴量である。これにより、異なる都市のユーザの移動履歴を同様に扱うことが可能になる。評価実験では、都市間で共通する時系列滞在頻度傾向を学習させたモデル (SFT-BERT) および各都市で固有の移動傾向を学習させたモデル (CMT-BERT) をエンコーダとして用い、下流モデルにより移動予測を行った。その結果、単一の都市の移動履歴のみで学習および予測を行った場合に対する優位性を示した。

Next Location Prediction Method Combining Time-Series Stay Frequency Tendency and Movement Tendency

HARU TERASHIMA^{1,a)} SHUN TAKAGI¹ NAOKI TAMURA¹ KAZUYUKI SHOJI¹ TAHERA HOSSAIN¹
SHIN KATAYAMA¹ KENTA URANO¹ TAKURO YONEZAWA¹ NOBUO KAWAGUCHI^{1,2}

1. はじめに

モバイル端末の普及に伴い、都市における大規模な位置情報データの収集が容易となった。位置情報データに基づく移動履歴を分析し、都市計画・交通計画・災害対策等に活用する試みが盛んに行われている [1][2][3]。

日常生活での移動には、平日の日中に会社に行く、月に一度病院に行くといった周期的な部分があり、移動履歴から

捉えられる移動傾向は、ユーザの将来の移動を予測する手掛かりとなる [4][5]。大規模なユーザの移動予測の結果は、ライドシェアのモビリティ配置計画や、需要に適合した移動販売車の出店など様々な面での活用が期待できる。

移動傾向は個人に依存する部分が多いが、会社員や学生といった属性毎に共通する部分もあると考えられる。例えば、図1のように、多くの会社員は平日の日中オフィスエリアに滞在し、夜間は自宅に帰り、移動のため駅を使うと考えられる。移動予測では、移動傾向が類似する他者の移動傾向の考慮により、ユーザ毎では不足する情報を補え、予測精度の向上が見込まれる。そのため、都市の大規模なユーザの移動履歴を用いて深層学習モデルを訓練し、予測を行

¹ 名古屋大学大学院 工学研究科
Graduate School of Engineering, Nagoya University

² 名古屋大学 未来社会創造機構
Institutes of Innovation for Future Society, Nagoya University

^{a)} haru@ucl.nuee.nagoya-u.ac.jp




図 1 属性毎の移動パターン

う研究が多くなされている [6][7][8].

ユーザが多い大規模な都市では、学習に利用可能な移動履歴が豊富にある一方で、小規模な都市では学習に利用できる移動履歴が少なく、その都市の移動履歴のみでは予測精度が低くなる懸念がある。そこで、都市間で移動履歴の共有を考えた時、都市間では都市空間の構造が異なるため、移動履歴中の各滞在エリア同士の対応付けが必要となる。

異なる都市間で、エリア同士を対応付けるための特徴量として、各建物のカテゴリを表す POI(Point of Interest) の活用が挙げられる。エリア毎の POI の集約により、オフィスエリア、駅エリア、住宅エリア、ショッピングエリアのように、エリアを機能毎に分類でき、これにより都市間でエリア同士の対応付けが可能となる。しかし、都市の POI 情報を最新の状態にするためには店舗情報等の調査が必要であり、更新コストが大きいという課題がある。また、都市の中心部では情報が集まりやすい傾向にあるが、郊外においては情報が不足するといった課題も挙げられる。加えて、ショッピングモールなどの複合施設の場合はエリア内で POI が混在し、一意な対応付けが困難な場合もある。

これらの課題を解決するため、本研究では都市間で共通する時系列滞在頻度傾向と、各都市で固有の移動傾向を組み合わせた移動先予測手法を提案する。時系列滞在頻度とは、ユーザの移動履歴中の各滞在エリアに、時間帯毎の滞在頻度を与えたもので、都市の機能的な特徴を用いずに、異なる都市間で共通に扱える特徴量である。これにより、POI など都市空間に紐づく他のデータを必要とせず、異なる都市のユーザの移動履歴を同様に扱うことが可能になる。本手法では図 2 のように、二つの BERT(Bidirectional Encoder Representations from Transformers)[9] ベースのモデル (SFT-BERT, CMT-BERT) を作成し、これらをエンコーダとして用い、下流モデルにより移動予測を行う。BERT は Transformer Encoder を用いたエンコーダモデルであり、自然言語処理分野において、下流タスクと組み合わせられて用いられることが多い。SFT-BERT(Time-series Stay Frequency Tendency BERT) では異なる都市間で共通する時系列滞在頻度傾向を学習させ、CMT-BERT(City Movement Tendency BERT) では各都市で固有の移動傾向を学習させる。本手法によって、ユーザが少ない都市での移動予測において、都市間で共通する時系列滞在頻度傾向

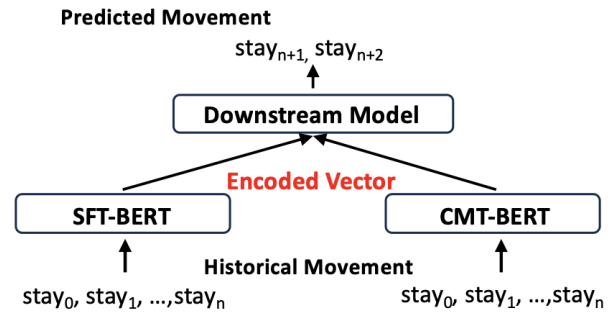


図 2 提案手法概要

を考慮した予測が可能となる。

評価実験では、日本の 4 都市の移動履歴データが含まれる公開データセットを用いた [10]. データセットには、各都市のユーザの 75 日間の 30 分刻みの移動履歴が含まれる。4 都市のうちユーザが少ない 3 都市 (都市 B, 都市 C, 都市 D) の、予測対象ユーザの最後の 15 日間の移動を予測した。下流モデルへの入力に SFT-BERT および CMT-BERT の出力を用いた場合と、そうでない場合の予測精度を比較し、提案手法の優位性を確認した。

本研究の貢献は以下のようにまとめられる。

- 異なる都市のユーザの移動履歴を同様に扱うための特徴量として時系列滞在頻度を提案
- 異なる都市間で共通する時系列滞在頻度傾向と各都市で固有の移動傾向を組み合わせた移動先予測手法を提案
- 単一都市の移動履歴のみで学習および予測を行った場合に対して提案手法により予測精度の向上を実現

本論文の構成は次に示すとおりである。まず第 2 章で移動先予測および都市間での転移学習に関する研究課題を整理する。3 章で提案手法の説明をし、4 章で提案手法の評価を行う。最後に 5 章でまとめと今後の展望について述べる。

2. 関連研究

2.1 移動先予測

移動傾向は会社員や学生といった属性毎に共通する部分もあるが、個々のユーザに依存する部分も大きいと考えられる。そのため、ユーザ毎に移動予測モデルを作成する研究がなされている [11][12]. しかし、これらの手法ではユーザ毎の移動履歴のみを用いるため、データ量やデータ密度に予測精度が影響を受けやすいという課題がある。

そこで、ユーザ毎の移動傾向のみでは不足する情報を補うため、他者の移動傾向を考慮した予測が行われている [6][7][8]. これらの研究では、大規模なユーザの移動履歴と深層学習モデルを用いて移動傾向を学習させ、最終的に各ユーザの移動を予測している。また、Transformer[13] の



図 3 都市間での時系列滞在頻度傾向の類似性

出現以降は、Attention ベースの移動予測モデルも出現し、深層学習モデル出現以前に比べ予測精度は大幅に向上した [14][15]。しかし、ユーザが多く移動履歴が豊富な都市では、深層学習モデルの訓練に十分な移動履歴がある一方で、小規模な都市においては訓練に十分な移動履歴がなく、予測精度が低くなる懸念がある。そこで、都市間で移動履歴の共有を考えた時、都市空間の構造の違いから、移動履歴中の滞在エリア同士の対応付けが困難であるという課題が残る。そのため、多くの既存研究では都市毎に予測モデルを作成するものにとどまっている。

2.2 都市間での転移学習

各都市でのデータ量不足を補うため、都市間での転移学習に関する研究が行われている [16][17]。これらの研究では、ソースとなる都市のデータでモデルを訓練し、ターゲット都市のデータでモデルをチューニングする。これにより、異なる都市間で特徴の転移を可能としている。しかし、転移学習の研究の多くは、タクシーやバイクなどの移動履歴データを用いて、各メッシュにおける単位時間のモビリティの流入量を予測しており、個々のモビリティの軌跡単位での移動予測は行っていない。本研究では、都市間で軌跡単位での特徴の伝搬を可能としている。

3. 提案手法

3.1 時系列滞在頻度

時系列滞在頻度とは、各ユーザの移動履歴中の各滞在エリアを、時間帯毎の滞在頻度を元にランク付けしたものである。表 1 のように、移動履歴を平日と休日に分け、1 日を 4 つの時間帯に分割し、各時間区分に訪れていたエリアを滞在頻度毎に 0-10%、10-20%、20-40%、40%-の 4 つに分類する。時間帯の幅は、多くの移動が想定される時間帯では短く、夜間など移動が少ないと想定される時間帯では長く設定している。各滞在エリアは曜日 2 区分、時間帯 4 区分、滞在頻度 4 区分にそれぞれ分類され、最終的にこれらを組み合わせて 32 クラスの時系列滞在頻度に分類される。

時系列滞在頻度はユーザ毎に算出しており、図 3 のように異なる都市間でも、属性毎に同様の傾向が現れると期待

| 表 1 時系列滞在頻度 | |
|------------------------|--|
| Day of Week | weekday weekend |
| Time Segment (0.5h) | 0 - 11 or 42 - 47 12 - 17 18 - 35 36 - 41 |
| Visit Frequency | 40% - 100% 20% - 40% 10% - 20% 0% - 10% |

できる。例えば、会社員であれば日中に高頻度で滞在するエリアはオフィスであると考えられ、夜間に高頻度で滞在するエリアは自宅であると考えられる。このように、都市の機能的な特徴を用いずに異なる都市において共通する滞在傾向を表現できる。異なる都市間でエリア同士を対応付ける特徴量は複数存在するが、時系列滞在頻度はユーザ毎の移動履歴のみから算出できる。これにより、都市のエリア毎のデータ量の差を考慮する必要がなく、都市規模の影響を受けにくいと考えられる。

3.2 時系列滞在頻度傾向学習モデル

時系列滞在頻度傾向を学習させるモデルとして BERT ベースのモデル SFT-BERT(Time-series Stay Frequency Tendency BERT) を提案する。モデルの概要を図 4 の左側に示す。SFT-BERT は、Embedding 層、Transformer Encoder で構成される。モデルへの入力には軌跡単位の時系列移動履歴である。移動履歴中の各滞在には時系列滞在頻度 (f)、日付 (d)、時間 (t)、曜日 (w)、滞在間の時間差 (Δt) が含まれる。これらの特徴量は Embedding 層でベクトル化されたのち、加算され Transformer Encoder に入力される。ベクトル同士を足し合わせることで次元数の増加に伴う計算量の増加を防ぐ。

SFT-BERT の訓練時には、移動履歴中の一部の滞在の時系列滞在頻度 (f) をマスクし、マスク部分の時系列滞在頻度 (f) を予測させる。SFT-BERT は、移動履歴を双方向から見て学習を行うため、予測箇所を移動履歴の最後尾に限定する必要がなく、マスクの位置は移動履歴中で任意に決

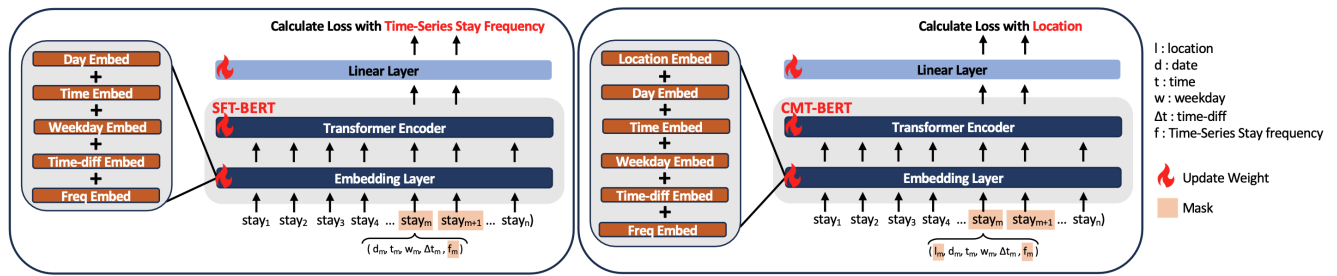


図 4 事前学習モデル (SFT-BERT, CMT-BERT)

められる。訓練時のみ Transformer Encoder の出力のうち、マスク部分のベクトルを全結合層に入力し、時系列滞在頻度 (f) の確率分布に変換する。その後、確率分布とマスク部分の正解時系列滞在頻度 (f) 間で訓練損失を計算する。損失関数にはクロスエントロピーを用いる。ここでは、異なる都市間で共通する滞在傾向を学習させるため、様々な都市のユーザの移動履歴を区別せずに用いる。

3.3 各都市の移動傾向学習モデル

各都市における移動傾向を学習させるモデルとして BERT ベースのモデル CMT-BERT (City Movement Tendency BERT) を提案する。モデルの概要を図 4 の右側に示す。CMT-BERT も同様に Embedding 層、Transformer Encoder で構成される。モデルへの入力軌跡単位の時系列移動履歴である。移動履歴中の各滞在には場所 (l)、時系列滞在頻度 (f)、日付 (d)、時間 (t)、曜日 (w)、滞在間の時間差 (Δt) が含まれる。これらの特徴量は Embedding 層でベクトル化されたのち、加算され Transformer Encoder に入力される。

CMT-BERT の訓練時には、移動履歴中の一部の滞在所 (l) と時系列滞在頻度 (f) をマスクし、マスク部分の滞在所 (l) を予測させる。訓練時のみ Transformer Encoder の出力のうち、マスク部分のベクトルを全結合層に入力し、各滞在所 (l) の確率分布に変換する。その後、各滞在所 (l) の確率分布のベクトルとマスク部分の正解滞在所 (l) 間で訓練損失を計算する。損失関数にはクロスエントロピーを用いる。ここでは、各都市のユーザの滞在所に基づく移動傾向を学習させるため、マスク部分の各滞在所 (l) のみを予測する。各都市での一般的な移動傾向を学習させるため、各都市内のユーザを区別せずに学習を行う。CMT-BERT は都市毎にモデルを訓練させる。

3.4 移動予測下流モデル

下流モデルでは各都市のユーザの将来の移動予測を行う。図 5 のように、移動履歴中の各滞在 (場所 (l)・日付 (d)・時間 (t)・曜日 (w)・滞在間の時間差 (Δt)・時系列滞在頻度 (f)) を SFT-BERT, CMT-BERT それぞれでエンコードしたベクトルに各滞在所 (l) の Embedding を足し合わせ

表 2 データセット概要

| | City A | City B | City C | City D |
|--------------|---------|--------|--------|--------|
| Individuals | 100,000 | 25,000 | 20,000 | 6,000 |
| Valid mesh | 34,032 | 26,523 | 9,208 | 21,113 |
| Target Users | 0 | 3,000 | 2,000 | 1,000 |

たものを入力とし、将来の移動予測を行う。下流モデルの訓練時には、SFT-BERT, CMT-BERT のパラメータの更新は行わない。損失関数にはクロスエントロピーを用いる。

下流モデルでは、都市間で共通する時系列滞在頻度傾向と、各都市で固有の移動傾向を合わせた傾向が学習される。これにより、単一都市のユーザの移動傾向のみで不足する情報を補うことが可能となる。下流モデルの学習においても、各都市の一般的な移動傾向を学習させるため、入力にユーザ情報は加えない。

4. 評価実験

4.1 データセットおよび課題設定

本実験では、オープンソースの移動履歴データセットを使用する [10]。データセットには、日本における 4 都市 (都市 A, 都市 B, 都市 C, 都市 D) のユーザの移動履歴が含まれる。各ユーザの移動履歴は 75 日間の 30 分刻みの移動である。各都市のデータセットの詳細を表 2 に示す。データが取得された都市の場所は非公開であり、データの取得期間も公表されていない。位置情報が観測されていない時間帯はレコードなしとなっている。移動履歴中の各滞在所は 500m のメッシュでの滞在で、各都市それぞれ 40,000 メッシュずつ存在する。

本実験では、ユーザ数の少ない 3 都市 (都市 B, 都市 C, 都市 D) のユーザを予測対象とする。予測対象ユーザの 61 日目から 75 日目までの 15 日間の 30 分刻みの滞在所を予測する。予測対象のユーザ数は表 2 のとおりである。モデルの訓練には、予測対象でないユーザの全移動履歴と予測対象ユーザの 1 日目から 60 日目までの移動履歴を用いる。

4.2 評価指標

本実験では GEOBLEU, DTW, Accuracy の 3 つの評価指標を用いる。以下に各評価指標の詳細を示す。GEOBLEU と DTW には予測エリアと正解エリアの空間的距離も考慮

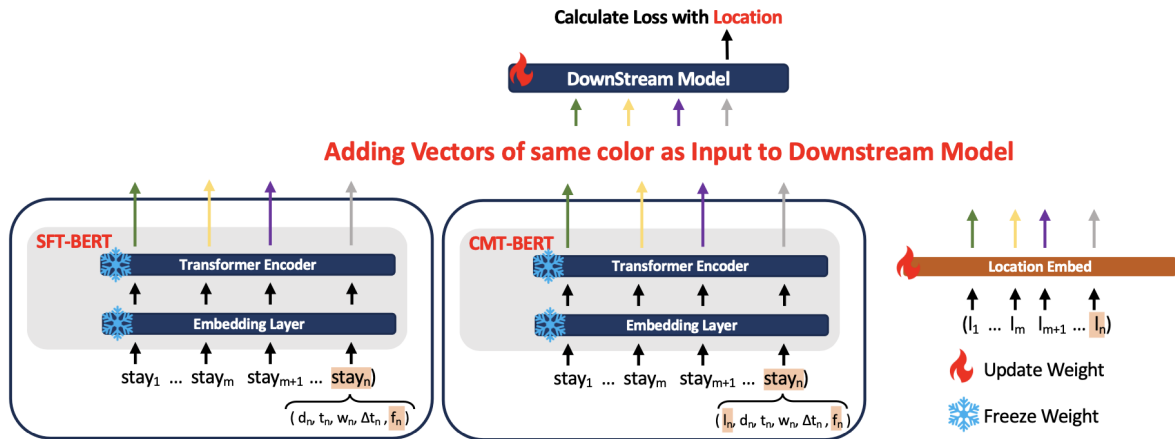


図 5 SFT-BERT および CMT-BERT と下流モデルを用いた移動予測

されている。

– Accuracy

予測エリアと正解エリアの一致率を百分率で計算。

– GEOBLEU[18]

自然言語処理の分野で用いられる BLEU を参考にした評価指標。局所的な予測精度を評価するためのもので、値が大きい方がスコアは良く、予測結果と正解が完全に一致すると値は 1 になる。

– DTW[19]

予測軌跡と正解軌跡の時系列間の類似度を評価する指標。値が小さい方がスコアは良く、予測軌跡と正解軌跡が完全に一致すると値は 0 になる。




図 6 事前学習データセット作成方法

表 3 SFT-BERT, CMT-BERT パラメータ

| model | epoch | batch | layer | head |
|----------|-------|-------|-------|------|
| SFT-BERT | 250 | 128 | 4 | 8 |
| CMT-BERT | 500 | 8 | 3 | 8 |

は表 3 の通りである。事前学習モデルの訓練時には、過学習を防ぐようパラメータを調整した。

4.3 事前学習

SFT-BERT では、4 都市の各ユーザの移動履歴から、図 6 のように連続する 1024 回の移動と時系列順にランダムに抽出した 1024 回の移動を学習データとして用いる。連続する移動からは短期的な滞在周期、ランダムに抽出した移動からは長期的な滞在周期が学習されると期待できる。ユーザ毎に移動履歴の密度が異なり、データ長に差があるため、学習に用いる移動履歴の最大長を 1024 に定めた。これにより、計算機のメモリの節約につながる。訓練時には、バッチ毎にランダムな位置から始まる連続する 100 回の移動の時系列滞在頻度 (f) をマスクする。下流タスクにおいて、連続する複数日の移動を予測するため、事前学習モデルの訓練時にも連続する移動をマスクし学習させている。

CMT-BERT では、都市毎の各ユーザの移動履歴から、連続する 1024 回の移動と時系列順にランダムに抽出した 1024 回の移動軌跡を学習データとして用いる。訓練時には、バッチ毎にランダムな位置から始まる連続する 100 回の移動の場所 (l) と時系列滞在頻度 (f) をマスクする。

SFT-BERT および CMT-BERT の訓練時のパラメータ

4.4 移動予測

本実験では、下流モデルとして RNN[20], LSTM[21], GPT[15], LP-BERT[14] を採用した。既存研究のモデル構造を参考に、本実験用に合わせてモデルを作成した。

移動予測の際は、長短期的移動傾向を捉えることが有効であると考えられる。そのため、下流モデルによる予測時には各ユーザの全移動履歴を入力とした。ユーザ毎にデータ長が異なるため、バッチ内で最大長のものに合わせパディングを行いモデルに入力した。

都市間で共通する時系列滞在頻度傾向と、各都市で固有の移動傾向を組み合わせた予測手法の有効性を示すため、下流モデルへの入力として以下の 4 種類を試した。Embed は移動履歴中の各滞在 (場所 (l)・日付 (d)・時間 (t)・曜日 (w)・滞在間の時間差 (Δt)・時系列滞在頻度 (f)) を Embedding 層でベクトル化し、足し合わせたものである。入力を Embed のみとした時は、学習から予測まで単一都市のデータのみで完結している。

- Embed
- SFT-BERT + Embed

表 4 移動予測結果

| | | RNN[20] | | | LSTM[21] | | | GPT[15] | | | LP-BERT[14] | | |
|--------|-----------------|---------|-------|--------|----------|-------|-------|---------|-------|-------|-------------|-------|-------|
| | Input | GEO | DTW | Acc | GEO | DTW | Acc | GEO | DTW | Acc | GEO | DTW | Acc |
| city B | Embed | 0.0223 | 194.8 | 1.101 | 0.2497 | 36.56 | 20.06 | 0.2445 | 23.33 | 23.19 | 0.3201 | 24.11 | 29.67 |
| | SFT + Embed | 0.0228 | 231.8 | 1.112 | 0.2119 | 27.58 | 17.91 | 0.2601 | 23.06 | 24.35 | 0.3156 | 22.31 | 28.30 |
| | SFT + CMT | 0.0604 | 61.58 | 3.385 | 0.2485 | 26.56 | 23.42 | 0.2483 | 27.30 | 23.57 | 0.3354 | 23.83 | 31.08 |
| | SFT + CMT + Loc | 0.0673 | 62.22 | 3.750 | 0.2484 | 26.13 | 23.47 | 0.2500 | 26.04 | 23.47 | 0.3357 | 23.64 | 31.07 |
| city C | Embed | 0.0281 | 122.3 | 1.565 | 0.2433 | 25.62 | 19.88 | 0.2433 | 18.12 | 24.03 | 0.3176 | 16.83 | 30.01 |
| | SFT + Embed | 0.0282 | 122.2 | 1.607 | 0.2142 | 21.63 | 18.29 | 0.2576 | 16.98 | 25.27 | 0.3101 | 16.44 | 28.78 |
| | SFT + CMT | 0.0668 | 43.05 | 3.659 | 0.2495 | 19.74 | 24.03 | 0.2541 | 18.26 | 24.73 | 0.3310 | 16.40 | 31.29 |
| | SFT + CMT + Loc | 0.0689 | 45.42 | 3.868 | 0.2473 | 19.22 | 24.02 | 0.2546 | 18.52 | 24.70 | 0.3307 | 16.30 | 31.40 |
| city D | Embed | 0.027 | 688.2 | 0.1131 | 0.2498 | 53.60 | 18.72 | 0.2251 | 34.36 | 21.01 | 0.3060 | 43.61 | 24.64 |
| | SFT + Embed | 0.0062 | 633.6 | 0.2845 | 0.0601 | 224.8 | 4.624 | 0.2295 | 37.51 | 21.21 | 0.3093 | 39.41 | 23.45 |
| | SFT + CMT | 0.0081 | 385.4 | 0.3412 | 0.2315 | 86.89 | 21.78 | 0.2716 | 35.38 | 23.41 | 0.3212 | 41.13 | 24.90 |
| | SFT + CMT + Loc | 0.0078 | 399.2 | 0.3270 | 0.2204 | 37.75 | 20.67 | 0.2685 | 35.60 | 23.31 | 0.3255 | 40.44 | 25.69 |

- SFT-BERT + CMT-BERT

- SFT-BERT + CMT-BERT + Location.Embed

下流モデルの訓練時において、RNN、LSTM、GPT は seq2seq で予測を行うモデルであるため、移動履歴の最後尾から適当な回数の移動を予測するように訓練させた。LP-BERT では移動履歴中のランダムな位置から始まる連続する 15 日分の移動をマスクして訓練させた。

下流モデルによる移動予測の結果を表 4 に示す。表 4 では、各都市の予測結果において、評価指標毎に最もスコアが高いものを赤色、2 番目にスコアが良いものを青色で示している。全体的な予測結果の傾向として、下流モデルへの入力に SFT-BERT および CMT-BERT のエンコード結果を用いた場合のスコアが良いことが分かった。この結果より、都市毎の移動履歴のみで学習および予測を行う場合に対して、提案手法の優位性を示した。また、下流モデルとして LP-BERT を採用した場合がスコアが良いことも分かった。

4.5 考察

4.5.1 下流モデルの比較

下流モデルによる予測精度では、LP-BERT が 3 つの評価指標における全体的なスコアとして最も良い結果となった。本実験の予測タスクでは、60 日の移動履歴から 15 日分の移動を予測するもので、移動履歴の長期の依存関係の理解が必要であった。そのため、RNN、LSTM といった構造が簡素なモデルでは、系列の前半の傾向が薄れてしまい、長期の移動傾向を捉えきれなかったと考えられる。一方で、GPT、LP-BERT といった Attention ベースのモデルでは、移動履歴全体から傾向を捉えることが可能で、長期の依存関係をより詳細に捉えられたと考えられる。

LP-BERT の予測精度が同じ Attention ベースの GPT を上回った要因として、GPT は予測を seq2seq で行い長期の予測では累積誤差の影響を受けるためと考えられる。LP-BERT では、複数の移動を並列に予測するため累積予

測誤差の影響は受けにくい。また、訓練時のマスクを移動履歴中の任意の位置にできるため、多様な移動傾向を学習できたと考えられる。

4.5.2 LP-BERT 予測結果分析

下流モデルとして LP-BERT を採用した場合が最も良いスコアとなったため、LP-BERT による移動予測結果の分析を行った。図 7 に各都市における時間区分毎・滞在頻度区分毎の Accuracy を示す。図の上段が時間区分毎、下段が滞在頻度毎の結果である。

時間区分毎では、夜間の予測精度は高い一方で日中の精度が低くなっている。夜間は自宅など特定のエリアに滞在する可能性が高いが、日中は移動などで滞在エリアの細かい変化が多いと考えられる。深層学習モデルによる移動予測では、過去の移動傾向の特徴を学習し将来の移動を予測するため、周期性の少ない非定常的な移動の予測精度が低くなる傾向がある。

滞在頻度毎に見ても、高頻度で滞在するエリアの予測精度が高く、低頻度で滞在するエリアの精度が低くなっている。これも同様に、高頻度の滞在エリアには滞在の周期性がある一方で低頻度で滞在するエリアには周期性が少ないと考えられる。

また、図 8 は、各都市（都市 B、都市 C、都市 D）の予測対象ユーザの訓練データおよび、入力を SFT-BERT + CMT-BERT + Location.Embed とした時の予測結果における、エリア毎の出現割合をヒートマップで可視化したものである。各都市のデータセット全体で、滞在が多い区域を拡大して示している。日中と夜間それぞれ 3 時間ずつの移動を抽出し、訓練データと予測結果で時間帯毎のエリア使用率の傾向を確認した。日中は、使用されるエリアの種類が多く、またエリア毎の使用率にも大きな差がある一方で、夜間は使用されるエリアが日中に比べ限定的である。訓練データと予測結果で、時間帯毎に類似した傾向があることから、予測の妥当性を確認した。




図 7 時間区分毎・滞在頻度毎の予測精度

5. まとめと今後の展望

本研究では、都市間で共通する時系列滞在頻度傾向と、各都市で固有の移動傾向を組み合わせた移動先予測手法を提案した。異なる都市間では、都市空間の構造が異なることから、移動履歴の共有が困難であったが、時系列滞在頻度の導入で可能とした。提案手法では、複数都市のユーザの移動履歴で時系列滞在頻度傾向を学習した SFT-BERT と、各都市のユーザの移動履歴で各都市固有の移動傾向を学習した CMT-BERT をエンコーダとして用い、複数の下流モデルにより予測精度の比較をした。評価実験の結果、単一都市の移動履歴のみで学習および予測を行った場合に対して提案手法の優位性を示した。

今後は、より多くの都市の移動履歴データを用い、多様な移動傾向を学習した移動予測モデルの作成を行いたいと考えている。

謝辞 本研究の一部は NICT 委託研究 (22609), JST CREST(JPMJCR22M4), JST RISTEX(JPMJRS23K), 科学研究費補助金 (22H03580, 22H03696) に支援いただいています。

参考文献

- [1] Ratti, C., Frenchman, D., Pulselli, R. M. and Williams, S.: Mobile landscapes: using location data from cell phones for urban analysis, *Environment and planning B: Planning and design*, Vol. 33, No. 5, pp. 727–748 (2006).
- [2] Jiang, S., Ferreira, J. and Gonzalez, M. C.: Activity-based human mobility patterns inferred from mobile phone data: A case study of Singapore, *IEEE Transactions on Big Data*, Vol. 3, No. 2, pp. 208–219 (2017).

- [3] Yabe, T., Jones, N. K., Rao, P. S. C., Gonzalez, M. C. and Ukkusuri, S. V.: Mobile phone location data for disasters: A review from natural hazards and epidemics, *Computers, Environment and Urban Systems* (2022).
- [4] Zhang, Y., Li, Y. and Ji, W.: A Trajectory-Based User Movement Pattern Similarity Measure for User Identification, *IEEE Transactions on Network Science and Engineering*, Vol. 10, No. 6, pp. 3834–3845 (2023).
- [5] Han, Q., Yoshikawa, A. and Yamamura, M.: Mining User Similarity from GPS Trajectory Based on Spatial-temporal and Semantic Information, *2022 3rd International Conference on Information Science, Parallel and Distributed Systems (ISPDS)*, pp. 174–180 (2022).
- [6] Feng, J., Li, Y., Zhang, C., Sun, F., Meng, F., Guo, A. and Jin, D.: Deepmove: Predicting human mobility with attentional recurrent networks, *Proceedings of the 2018 World Wide Web conference*, pp. 1459–1468 (2018).
- [7] Ke, S., Xie, M., Zhu, H. and Cao, Z.: Group-based recurrent neural network for human mobility prediction, *Neural Computing and Applications*, Vol. 34, No. 12, pp. 9863–9883 (2022).
- [8] Jianwei Chen, Jianbo Li, Y. L.: Predicting Human Mobility via Long Short-Term Patterns, *Computer Modeling in Engineering Sciences*, Vol. 124, No. 3, pp. 847–864 (2020).
- [9] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: Bert: Pre-training of deep bidirectional transformers for language understanding, *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL HLT 2018*, pp. 4171–4186 (2018).
- [10] Yabe, T., Tsubouchi, K., Shimizu, T., Sekimoto, Y., Sezaki, K., Moro, E. and Pentland, A.: YJMob100K: City-scale and longitudinal dataset of anonymized human mobility trajectories, *Scientific Data*, Vol. 11, No. 1, p. 397 (2024).
- [11] Gambs, S., Killijian, M.-O. and del Prado Cortez, M. N.: Next place prediction using mobility markov chains, *Proceedings of the first workshop on measurement, privacy, and mobility*, pp. 1–6 (2012).

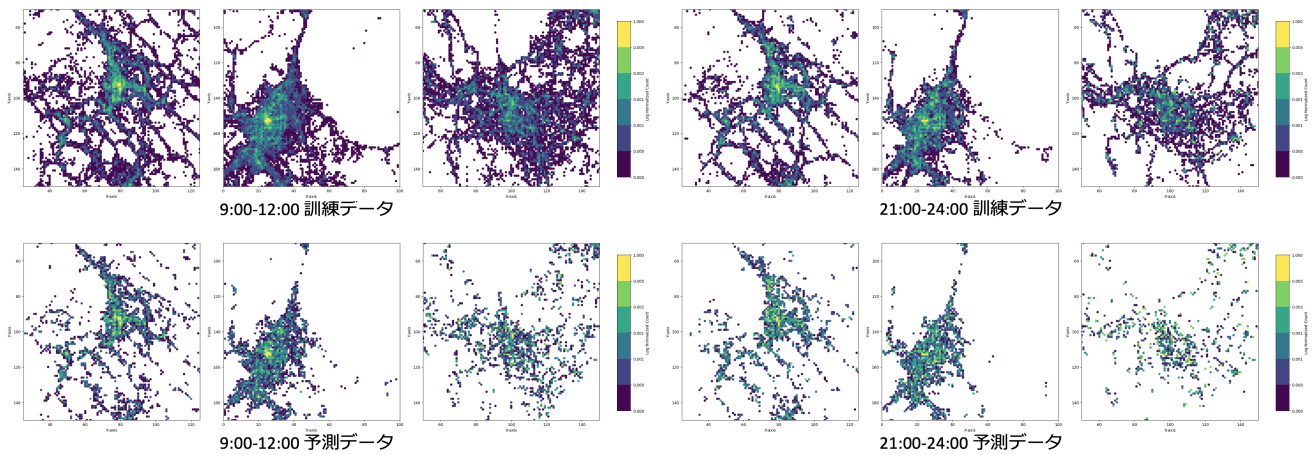


図 8 訓練データおよび予測データのメッシュ毎のレコード数

- [12] Suzuki, M., Furuta, S. and Fukazawa, Y.: Personalized human mobility prediction for HuMob challenge, *Proceedings of the 1st International Workshop on the Human Mobility Prediction Challenge*, pp. 22–25 (2023).
- [13] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I.: Attention is all you need, *Advances in neural information processing systems*, Vol. 30, pp. 5998–6008 (2017).
- [14] 寺島 青, 田村直樹, 庄子和之, 片山 晋, 浦野健太, 米澤拓郎, 河口信夫: BERT に基づく都市における移動エリア予測手法の提案, 研究報告モバイルコンピューティングと新社会システム (MBL), Vol. 2024-MBL-111, No. 8, pp. 1–7 (2024).
- [15] Solatorio, A. V.: GeoFormer: Predicting Human Mobility using Generative Pre-trained Transformer (GPT), *Proceedings of the 1st International Workshop on the Human Mobility Prediction Challenge*, pp. 11–15 (2023).
- [16] Yao, H., Liu, Y., Wei, Y., Tang, X. and Li, Z.: Learning from multiple cities: A meta-learning approach for spatial-temporal prediction, *The world wide web conference*, pp. 2181–2191 (2019).
- [17] Jin, Y., Chen, K. and Yang, Q.: Selective cross-city transfer learning for traffic prediction via source city region re-weighting, *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 731–741 (2022).
- [18] Shimizu, T., Tsubouchi, K. and Yabe, T.: GEO-BLEU: Similarity Measure for Geospatial Sequences (2022).
- [19] Senin, P.: Dynamic time warping algorithm review, *Information and Computer Science Department University of Hawaii at Manoa Honolulu, USA*, Vol. 855, No. 1-23, p. 40 (2008).
- [20] Al-Molegi, A., Jabreel, M. and Ghaleb, B.: STF-RNN: Space time features-based recurrent neural network for predicting people next location, *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 1–7 (2016).
- [21] Kong, D. and Wu, F.: HST-LSTM: A hierarchical spatial-temporal long-short term memory network for location prediction., *IJCAI*, Vol. 18, No. 7, pp. 2341–2347 (2018).