

推薦論文

NSP-BERT：滞在履歴の長期的依存関係を考慮した
効率的な滞在予測手法寺島 青^{1,a)} 田村 直樹¹ 庄子 和之¹ 片山 晋¹ 浦野 健太¹ 米澤 拓郎¹ 河口 信夫^{1,2}

受付日 2025年5月7日, 採録日 2025年12月9日

概要：都市における人々の将来の滞り場所の予測は、シェアモビリティの配置計画、イベント時の混雑緩和、マーケティング戦略など、様々な都市課題の解決において重要な役割を果たす。人々の滞在履歴には、曜日や時間帯ごとに特定の場所への周期的な滞在傾向があり、これらは将来の滞り先を予測するうえで有用な手がかりとなる。こうした滞在傾向をより詳細にとらえるためには、滞在履歴における長期的な依存関係を考慮した特徴抽出が有効であり、さらに最新の滞在傾向を予測に反映させるためには、日々蓄積される滞在履歴の活用が必要である。そこで、滞在履歴の長期的な依存関係を考慮しつつ、最新の傾向を活用するために、効率的な学習および予測が可能な手法の構築が求められる。本研究では、これらの課題を解決する滞在予測モデル NSP-BERT (Next Stay Prediction BERT) を提案する。NSP-BERT は、Transformer における Attention 機構により滞在履歴の長期的な依存関係を考慮しつつ、逐次的な処理を必要としない効率的な予測を実現する。また、滞在単位（滞在エリア + 滞在時間）でデータを扱うことにより、従来の時間刻みで滞在エリアを予測する手法と比較してデータ長を削減でき、さらなる効率化が実現可能となる。実世界の人流データセットを用いた実験により、NSP-BERT と他の深層学習モデル間で予測精度および効率性を比較し、滞在予測タスクにおける NSP-BERT の優位性を実証した。

キーワード：滞在予測, 都市人流データ, アーバンコンピューティング, BERT, 機械学習

NSP-BERT: An Efficient Next Stay Prediction Method Considering
Long-term Dependencies in Stay HistoryHARU TERASHIMA^{1,a)} NAOKI TAMURA¹ KAZUYUKI SHOJI¹ SHIN KATAYAMA¹ KENTA URANO¹
TAKURO YONEZAWA¹ NOBUO KAWAGUCHI^{1,2}

Received: May 7, 2025, Accepted: December 9, 2025

Abstract: Predicting future human mobility in urban environments is crucial for tackling a range of urban challenges, such as planning shared-mobility deployments, managing event-related congestion, and designing effective marketing strategies. Historical human stay records exhibit strong periodic patterns across days of the week and times of day, and these recurring visits to specific locations provide valuable insights for predicting future stays. Capturing these patterns in greater detail enables the model to learn features that reflect long-term dependencies in stay records. Moreover, incorporating the most recent stay behavior—summarized by daily aggregates of stay records—is essential for accurate prediction. Therefore, it is imperative to develop an efficient learning and prediction framework that accounts for long-term dependencies while leveraging up-to-date trends. To address these challenges, we propose NSP-BERT (Next Stay Prediction BERT), a model for future stay prediction. NSP-BERT leverages the Transformer’s attention mechanism to capture long-term dependencies in stay records, enabling efficient prediction without sequential processing. In addition, we represent mobility data at the level of stay units which shortens the input sequence relative to conventional time-step-based stay-area prediction and further improves computational efficiency. Experiments on real-world human mobility datasets demonstrate that NSP-BERT achieves superior prediction accuracy and efficiency compared with existing deep learning baselines for stay prediction.

Keywords: next stay prediction, human mobility, urban computing, BERT, machine learning

1. はじめに

モバイル端末の普及により、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滞在履歴は、人々の行動特性を理解するための重要な手がかりとなり、都市計画、交通計画、災害対策など多様な分野での活用が進められている [1], [2], [3]。特に、都市における人々の将来の滞り場所の予測は、シェアモビリティの効率的な配置計画、大規模イベント時の混雑予測、ターゲティング広告戦略の高度化など、都市が直面する諸課題の解決で重要な役割を担う。

人々の日常生活には、曜日や時間帯ごとに特定のエリアへの周期的な滞在傾向が存在する [4], [5], [6]。このような滞在傾向には個人差があるものの、会社員や学生といった属性ごとに類似する傾向が現れる場合も少なくない [7], [8], [9]。たとえば、多くの会社員は朝に自宅を出発し、公共交通機関などを用いて通勤し、勤務先周辺で昼食をとり、夕方に帰宅する。このような行動パターンは、会社員に共通する代表的な傾向である。こうした背景から、移動予測においては、予測対象ユーザ自身の傾向に加え、似た傾向を持つ他のユーザの情報を活用する予測手法が広く採用されている。このアプローチにより、予測対象ユーザ単独では不十分な情報を補完し、より高精度な予測が可能となる。

将来の滞りを予測するうえで、過去の滞在傾向は重要な手がかりとなる。滞在傾向には、週単位や月単位といった多様な周期性が存在し [10]、これらの傾向をより詳細かつ正確にとらえるためには、滞在履歴における長期的な依存関係を考慮した特徴抽出が有効である。また、最新の滞在傾向を予測に反映させるためには、日々蓄積される最新の滞在データの活用が求められる。そこで、滞在履歴の長期的な依存関係を考慮しつつ、最新の傾向を反映するため効率的な学習および予測が可能となる手法が必要となる。既存の移動予測に関する研究では、RNN や LSTM といった深層学習モデルを用いる手法が数多く提案されている [11], [12]。深層学習モデルの活用により、都市における一般的な滞在傾向の抽出が可能となり、活用以前と比べ予測精度は大幅に向上した。しかし、これらのモデルは系列が長くなるにつれ、前方の情報が徐々に失われるという構造的な制約があり、滞在履歴の長期的な依存関係を考慮した予測が得意である。加えて、将来の滞り場所を逐次的に予測するため効率面においても課題が残る。

本研究では、これらの課題を解決する滞り予測モデル Next Stay Prediction BERT (NSP-BERT) を提案する。NSP-BERT は、自然言語処理分野で広く用いられる深層学習モデル BERT (Bidirectional Encoder Representations from Transformers) [13] を基盤とした滞り予測モデルである。NSP-BERT は Embedding 層、Transformer Encoder、および全結合層により構成される。Transformer [14] における Attention 機構により、滞在履歴の長期的な依存関係を詳細にとらえられ、BERT のマスク学習を参考にし、図 1 のように、逐次的な処理を必要としない効率的な予測（並列予測）を実現する。また、学習時においては、将来の予測期間に応じた連続的な滞りをマスクする“滞り予測タスクに特化したマスク手法”を導入し、モデルの予測性能の向上を実現している。さらに、多くの移動予測の既存モデルが、時間刻みでデータを扱うのに対し、NSP-BERT は滞り単位（滞りエリア + 滞り時間）でデータを扱う。これにより、同一エリアにおける連続した滞りをまとめて処理できるため、入力系列長の削減が可能で、さらなる効率化が実現される。

本研究では、以前に我々が発表した内容 [15] に加え、実世界の人流データセットを用いて追加の実験および考察を行い、提案手法である NSP-BERT の有効性を明らかにした。実験には、株式会社プログウォッチャー [16] が許諾を得たユーザから取得した GPS データに基づく人流データを使用した。対象とするデータは、名古屋市近郊および大阪市近郊におけるユーザの 90 日間の滞在履歴であり、このうち予測対象ユーザの最後の 15 日間の全滞りを予測した。滞りエリアの予測精度を測る指標として、Top-k Accuracy, GEOBLEU [17], DTW (Dynamic Time Warping) [18] を用いた。GEOBLEU は、自然言語処理分野で用いられる評価指標 BLEU [19] を参考に作られた、移動予測の評価指標である。また、滞り時間の予測精度は、予測滞り時間と正解滞り時間の誤差で評価した。NSP-BERT と他の深層学習モデル間で予測精度および学習効率の比較を行った結果、滞り予測タスクで、NSP-BERT は多くの評価指標において他モデルを上回る予測精度を達成した。さらに、他モデルが Top-1 Accuracy の最高値を達成するのに要した学習時間においても、NSP-BERT は他のモデルを上回るスコアを達成しており、このことから学習効率の面においても優位性を有することが実証された。

本研究の貢献は以下のようにまとめられる。

- 滞在履歴の長期的な依存関係を考慮しつつ、効率的な予測を実現する滞り予測モデル NSP-BERT を提案した。

本論文の内容は 2024 年 6 月のマルチメディア、分散、協調とモバイル (DICOMO2024) シンポジウムにて報告され、同プログラム委員長により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

¹ 名古屋大学大学院工学研究科
Graduate School of Engineering, Nagoya University, Nagoya,
Aichi 464-8603, Japan

² 名古屋大学未来社会創造機構
Institutes of Innovation for Future Society, Nagoya University,
Nagoya, Aichi 464-8601, Japan

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




図 1 NSP-BERT と逐次的予測を行うモデルの予測方法比較
 Fig. 1 Comparison between sequential prediction models and NSP-BERT.

- 実世界の人流データセットを用いた実験により、滞在予測タスクにおいて NSP-BERT と他の深層学習モデル間で予測精度および効率性を比較し、滞在予測タスクにおける NSP-BERT の優位性を実証した。
- NSP-BERT と他の深層学習モデルの予測特性の分析を行い、現状のモデルにおける最終的な課題点を整理した。

本論文の構成は次に示すとおりである。まず 2 章で既存の移動予測に関する研究の課題を整理する。3 章では、提案手法 NSP-BERT について説明し、4 章で評価実験を行う。5 章では、実験結果に対する考察を行う。最後に、6 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 個々の移動傾向に基づく移動予測

日常生活の人々の移動傾向には、ユーザごとに固有の傾向も多く存在する。そのため、移動予測において、予測対象ユーザ自身の移動履歴のみから移動傾向を抽出し予測を行う手法も数多く提案されている [20], [21]。これらの手法は、予測対象ユーザのデータのみに基づくため、他のユーザの傾向を考慮するために必要な計算コストが不要であるという利点がある。しかし、予測対象ユーザの移動履歴のデータ量に予測精度が影響を受けやすく、データ量が少ないユーザの予測精度が大きく低下する懸念がある。そこで、会社員や学生といった、属性ごとに類似した移動傾向が見られることに着目し、傾向が類似する他者の情報を考慮した予測手法が提案されている [22], [23], [24]。しかし、これらの手法は、統計情報や確率遷移モデルなどに基づいており、時系列性の考慮が不十分である。また、予測において、直前数回の移動に依存する傾向があり、長期的な周期性や時間的文脈が重要となる移動予測タスクにおいては課題が残る。

2.2 深層学習による移動予測

傾向が類似する他のユーザを考慮しつつ、時系列性を考慮した予測を行うために、移動予測において深層学習モデルの活用が進んでいる。これらの手法の多くは、RNN や LSTM といったモデルを活用しており、移動履歴中の時系列的な依存関係をとらえることを目的としている [11], [12]。

また、これらの時系列予測モデルを基盤とした手法として、移動履歴に含まれる長期的・短期的な周期性に着目した手法や、類似した傾向を持つユーザをグループ化して学習する手法など様々なものが提案されている [25], [26], [27], [28]。しかし、RNN や LSTM は系列が長くなるにつれ、前方の情報が徐々に失われるという構造的な制約があり、長期的な依存関係の考慮が不可欠な移動予測タスクにおいては性能が十分でないという課題がある。さらに、将来の複数回の移動を予測する際に、予測結果を次の予測に順次反映させる逐次的な予測手法のため、計算効率の低下や累積誤差の影響といった問題も生じる。

そこで、移動履歴の長期的な依存関係を考慮するためのアプローチとして、Transformer の活用が進んでいる。Transformer における Attention 機構により、移動履歴内のすべての移動間の関係を考慮した、詳細な特徴抽出が可能となる。Transformer を活用した手法として CTLE (Context and Time Aware Location Embedding) [29] があげられる。CTLE は、移動履歴を Transformer Encoder によりエンコーディングする事前学習モデルであり、別の下流予測モデルにより将来の移動を予測する。この手法により、移動履歴の長期的な依存関係の考慮が可能となった一方で、LSTM などの逐次的な予測を行う下流モデルを併用するため効率面において課題が残る。また、Transformer を用いた他の多くの手法も同様に、将来の複数回の移動予測には逐次的な処理が必要であり効率面において課題がある [30], [31]。加えて、近年は大規模言語モデルの急速な発展にともない、移動予測においても大規模言語モデルの活用が進んでいる [32], [33]。しかし、大規模言語モデルは、系列データ処理にかかる計算コストが大きいため、長期の移動履歴を扱う移動予測では効率面において同様に課題がある。

こうした課題に対して、我々はこれまでに LP-BERT (Location Prediction BERT) [34] を提案してきた。LP-BERT は自然言語処理分野で広く用いられる深層学習モデルである BERT を基盤とした移動予測モデルであり、Transformer Encoder と全結合層により移動予測を行う。これにより、移動履歴の長期的な依存関係を考慮しつつ、逐次的な処理を必要としない効率的な予測を実現した。しかし、Transformer はパラメータ数も多く、入力系列が長

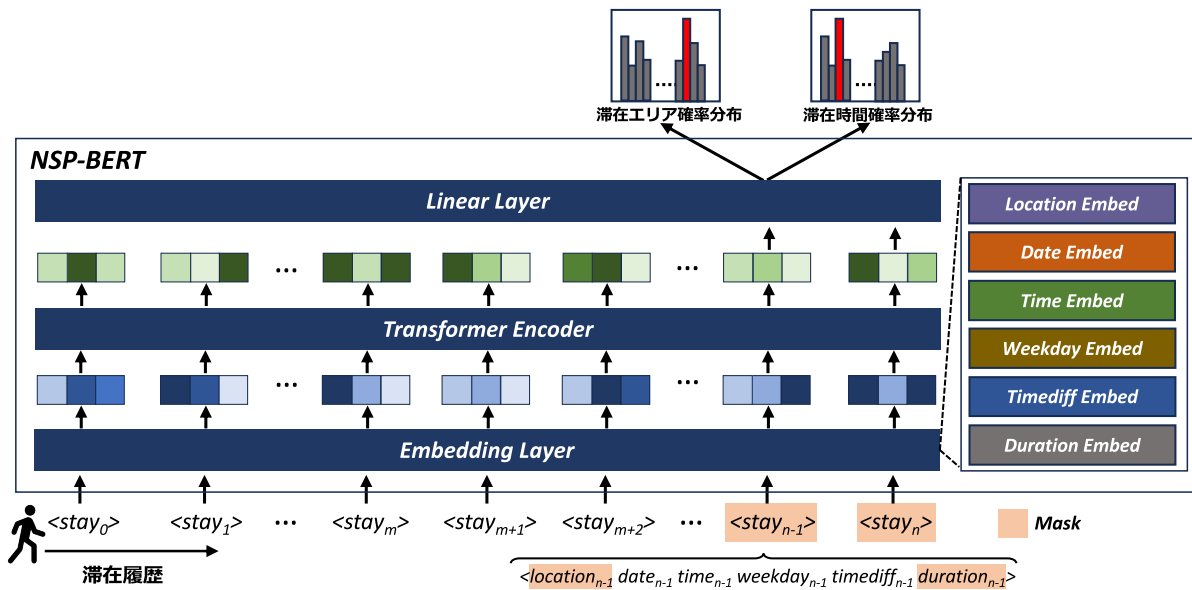


図 2 NSP-BERT アーキテクチャ
Fig. 2 Architecture of NSP-BERT.

くなるほど、計算コストが大幅に増加するため、さらなる効率化が求められる。

そこで本研究では、これまでの LP-BERT を発展させ、滞在単位（滞在エリア + 滞在時間）でデータを扱い、滞在単位での予測を可能にする NSP-BERT を提案する。NSP-BERT は、従来の時間刻みで滞在履歴を処理する手法と比較して、滞在単位でデータを扱うことで入力系列の長さを大幅に削減できる。さらに、同一エリアにおける連続した滞在を 1 つの滞在和としてまとめて予測し、計算コストの削減を可能とする。

3. 提案手法

本章では、提案する滞在和予測モデル NSP-BERT (Next Stay Prediction BERT) のモデル構成、学習方法、予測方法について説明する。

3.1 NSP-BERT アーキテクチャ

NSP-BERT の概要を図 2 に示す。NSP-BERT は、自然言語処理分野で広く用いられる深層学習モデル BERT (Bidirectional Encoder Representations from Transformers) のアーキテクチャを基盤とした滞在和予測モデルであり、Embedding 層、Transformer Encoder、全結合層の 3 つの要素から構成される。NSP-BERT への入力はいずれもユーザの時系列の滞在和履歴である。このとき、BERT のマスク学習に倣い、予測期間の滞在和も“マスク”という状態で滞在和履歴に含まれる。滞在和履歴中の各滞在和は、滞在エリア (l)、日付 (d)、滞在開始時間 (t)、曜日 (w)、滞在和間の時間差 (Δt)、滞在時間 (Δd) の 6 つの特徴量で構成される。滞在和履歴には滞和在が観測されない時間帯も存在するため、ある滞和在が観測されてから次の滞和在が観測されるまでの時

間（滞在和間の時間差）をモデルへの入力として用い、系列中における各滞和在の相対的な時間的位置をモデルに与える。Transformer では、一般に Positional Encoding を用いて系列中の位置情報をモデルに与えるが、滞在和履歴においては滞和在が観測されない時間帯の存在により、系列が疎になるケースがある。このような特性をふまえ、本研究では Positional Encoding の代替として、日付および時間による時系列の絶対位置、および滞在和間の時間差による相対的な位置情報をそれぞれモデルに与えている。これにより、時間情報をより柔軟かつ適切にモデルへ埋め込める。まず、ユーザの滞在和履歴に含まれる各滞和在は Embedding 層で滞和在ごとにベクトル化される。このとき、各特徴量は個別に Embedding され、最終的に以下の式のようにそれらを加算した 1 つの滞在和ベクトルが生成される。特徴量ごとのベクトルを結合するのではなく加算による統合を行い、滞和在ベクトルの次元数の増加にともなう計算コストの増加を抑制している。

$$\begin{aligned}
 stay_i &= (l_i, d_i, t_i, w_i, \Delta t_i, \Delta d_i) \\
 vec_{stay_i} &= vec_{l_i} + vec_{d_i} + vec_{t_i} \\
 &\quad + vec_{w_i} + vec_{\Delta t_i} + vec_{\Delta d_i}
 \end{aligned}$$

続いて、Embedding 層から出力された滞和在ベクトル列は、Transformer Encoder へと入力される。Transformer Encoder は、滞在和履歴中の滞和在ベクトル間の相互関係を学習し、それらの関係性を反映した新たなベクトル列を出力する。最後に、Transformer Encoder から出力されたベクトルのうち、予測対象となる部分のベクトルのみを全結合層へ入力し、最終的に滞和在ごとに滞在和エリアおよび滞在和時間の確率分布として出力される。




図 3 マスクトークン置換
Fig. 3 Masked token replacement.

3.2 学習および予測

NSP-BERT の学習時においては、各ユーザの滞在履歴中の任意の位置から始まる連続した複数回の滞在を予測対象とし、その部分の滞在エリアと滞在時間を図 3 のようにマスクトークンに置き換える。NSP-BERT は、将来の連続する複数回の滞在予測を目的としている。従来の BERT のマスク学習では、ランダムな位置のトークンをマスクしており、連続するトークンの予測に適していない。そのため、NSP-BERT では、連続する滞在をマスクし予測させる、“将来の複数回の滞在予測に特化したマスク学習”を導入した。本研究で対象とする滞在予測は、移動予測の既存研究に倣い [34]、将来的に滞在があると仮定したうえで、その滞在がどのエリアで、どの程度の時間続くかを予測することを目的としている。この前提のもと、マスク処理は滞在エリアおよび滞在時間のみ適用し、それ以外の特徴量はマスク対象としない。マスク部分を含む滞在履歴は Embedding 層でベクトル化され、その後 Transformer Encoder へ入力される。Transformer Encoder を通過した後、出力されたベクトルのうちマスクされた滞在に対応する部分のみが全結合層に入力され、滞在エリアおよび滞在時間の確率分布として変換される。最終的に、これらの確率分布と正解ラベルとの間でクロスエントロピー損失を以下の式のように計算し、モデルの学習を行う。ここで、滞在エリアと滞在時間の訓練損失の重み付けは、ラベル数を考慮した調整が必要であり、本研究では以下のように定義した。

$$\begin{aligned}
 Loss_{location} &= CrossEntropy(Prob_{location}, True_{location}) \\
 Loss_{duration} &= CrossEntropy(Prob_{duration}, True_{duration}) \\
 Loss_{Total} &= Loss_{location} * 0.8 + Loss_{duration} * 0.2
 \end{aligned}$$

予測時には、予測対象期間の滞在をマスク滞在として扱うことで、学習時と同様の形式でモデルを適用できる。学習時と同様に、Transformer Encoder から出力されたベクトルのうち、マスク部分（予測期間）に対応するベクトルのみを全結合層に入力し、滞在ごとに滞在エリアおよび滞在時間のそれぞれの確率分布へと変換する。最終的に、以下の式のように各確率分布において最も確率の高い滞在エリアおよび滞在時間を予測結果として出力する。

$$\begin{aligned}
 Predicted_{location_i} &= \operatorname{argmax}(Prob_{location_i}) \\
 Predicted_{duration_i} &= \operatorname{argmax}(Prob_{duration_i})
 \end{aligned}$$

4. 評価実験

本章では、滞在予測タスクにおける NSP-BERT の予測精度、効率性および頑健性を、他の深層学習モデル (RNN, LSTM, GPT, TrajGPT [30]) と比較し実証する。

4.1 実験設定

本研究で使用する人流データは、事前に同意を得たユーザのスマートフォンにインストールされたアプリケーションを通じて収集された位置情報データセットである。本研究では、滞在予測を行うため Iwata ら [35] の滞在推定手法を用いてデータの前処理を実施し、元データから各滞在の緯度、経度、滞在開始時刻、滞在経過時間を抽出した。さらに、プライバシー保護の観点から、各滞在を緯度経度の座標から、250 m × 250 m メッシュ単位のエリア滞在へと変換した。各滞在は、0 時から 23 時の 1 時間刻みの時間帯を滞在開始時刻としている。滞在時間については、1 時間未満の滞在は移動中の短時間の滞在と見なして除外し、1 時間以上の滞在のみを対象としている。また、24 時間以上の滞在については、すべて 24 時間に統一して処理している。対象とする都市は、図 4 のように名古屋市近郊と大阪市近郊であり、データの取得期間は 2023 年 10 月 1 日から 2023 年 12 月 29 日の 90 日間である。期間内に滞在が 100 レコード以上観測されたユーザを本実験の対象とした。レコード数、ユーザ数、エリア数などのデータセットの詳細は表 1 に示すとおりである。

滞在予測タスクでは、各都市 (名古屋、大阪) の全ユーザのうち 20% を予測対象ユーザとし、予測対象ユーザの 76 日目以降の 15 日間の全滞在を予測する。モデルの学習には、予測対象でないユーザの全期間の滞在履歴および予測対象ユーザの 75 日目までの滞在履歴を使用する。

4.2 評価指標

本研究では、滞在エリアの予測精度を評価する指標として、Top-k Accuracy, GEOBLEU, DTW (Dynamic Time Warping) を使用し、滞在時間の予測精度を測る指標として Duration Error および Duration MAE を使用する。GEOBLEU および DTW のスコアには、予測エリアと正解エリアの空間的な距離の差が考慮されている。各評価指標の詳細を以下に示す。

- **Top-k Accuracy**
予測結果の上位 k 個のエリア中に正解滞在エリアが含まれる確率。
- **GEOBLEU [17]**
自然言語処理の分野で用いられる BLEU を参考にした

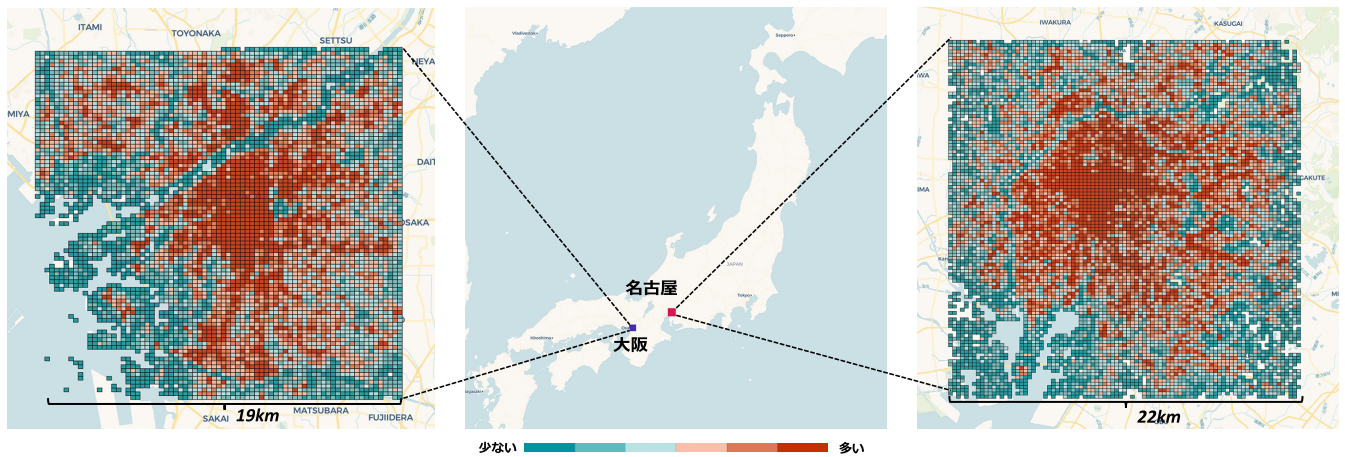


図 4 エリアごとの滞在レコード数ヒートマップ
 Fig. 4 Heatmaps of stay record volumes by area.

表 1 実験データセットの詳細

Table 1 Summary of the experimental datasets.

	レコード数	ユーザ数	エリア数	最大入力長	最小入力長
名古屋	3,599,069	19,897	9,191	487	100
大阪	5,696,549	32,353	6,150	514	100

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 [18]**

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.

– **Duration Error**

予測滞在時間と正解滞在時間の誤差の絶対値の累積和.

– **Duration MAE**

予測滞在時間と正解滞在時間の誤差の絶対値の累積和を移動回数で割ったもの (1 移動あたりの誤差).

4.3 モデルの学習

本実験では、NSP-BERT と他の深層学習モデル (RNN, LSTM, GPT, TrajGPT [30]) 間で、滞在予測タスクにおける予測精度、効率性、頑健性を比較する. RNN, LSTM は滞在履歴を先頭から順次入力し、前のステップの隠れ層の状態を用い順に滞在を予測する設計である. GPT は過去の滞在履歴を一括で初期入力とし、初期入力を元に将来の滞在を逐次的に予測する設計となっている. TrajGPT は、将来の複数回の滞在予測タスクに合うよう、一部実装を変更して実験を行った. 具体的には、推論時に Transformer Decoder による逐次予測を行っている. すべてのモデルにおいて、予測時に予測対象滞在の日付、滞を開始時間、曜日、滞在間の時間差の情報を用いている. NSP-BERT の学習時には、予測対象期間である 15 日に対応させるため、

表 2 各モデルのパラメータ

Table 2 Model hyperparameters.

	Embed	Batch	Layer	Head	Rate
RNN	128	16	2	–	1e-4
LSTM	128	16	1	–	2e-4
GPT	128	16	2	8	2e-4
TrajGPT*	128	16	1	8	2e-4
NSP-BERT	128	16	2	8	5e-4

バッチごとに滞在履歴中の任意の位置から始まる連続した 15 日間の全滞在をマスク対象とし学習を行った. 一方で、RNN, LSTM, GPT, TrajGPT は、逐次的な推論を行うモデルであるため、滞在履歴の末尾から連続する適当な回数分の滞在を予測するタスクにより学習させた. 各モデルのパラメータを表 2 に示す. 名古屋のデータを用い、各モデル様々な層数、学習率でそれぞれ 100 エポックずつ学習を行い、パラメータの探索を行った. パラメータ比較時の詳細は付録に示す. 実験には、CPU (Xeon w9-2475X), GPU (RTX 6000Ada, 48 GB) を搭載したマシンを用いた. また、各モデルの実装には PyTorch を使用した.

4.4 実験結果

本節では、予測精度、効率性、頑健性の 3 つの項目において NSP-BERT と他の深層学習モデル間で比較を行った.

4.4.1 予測精度の比較

各モデルにおいて、それぞれ 100 エポックずつ学習を

表 3 各モデルの予測結果
Table 3 Prediction results.

$Model_{epoch}$	Top-1 \uparrow (%)	Top-5 \uparrow (%)	GEOBLEU \uparrow (N=3)	DTW \downarrow	DurationError \downarrow (h)	DurationMAE \downarrow (h)
<i>RNN</i> ₁₀₀	9.16	19.97	0.0622	20.88	155	5.022
<i>LSTM</i> ₃₀	50.49	70.88	0.3418	7.290	136	4.379
名古屋 <i>GPT</i> ₉₀	57.27	72.55	0.4154	6.449	137	4.443
<i>TrajGPT</i> * ₈₀	59.37	76.43	0.4399	6.105	131	4.284
<i>NSP-BERT</i>₁₀₀	62.10	78.90	0.4746	6.663	52	1.720
<i>RNN</i> ₁₀₀	3.61	37.55	0.0381	18.57	156	5.042
<i>LSTM</i> ₃₀	50.64	71.25	0.3600	6.369	136	4.385
大阪 <i>GPT</i> ₂₀	56.71	74.80	0.4280	5.844	131	4.347
<i>TrajGPT</i> * ₉₀	58.64	77.68	0.4280	5.503	125	4.195
<i>NSP-BERT</i>₉₀	61.21	79.63	0.4846	5.926	57	1.543

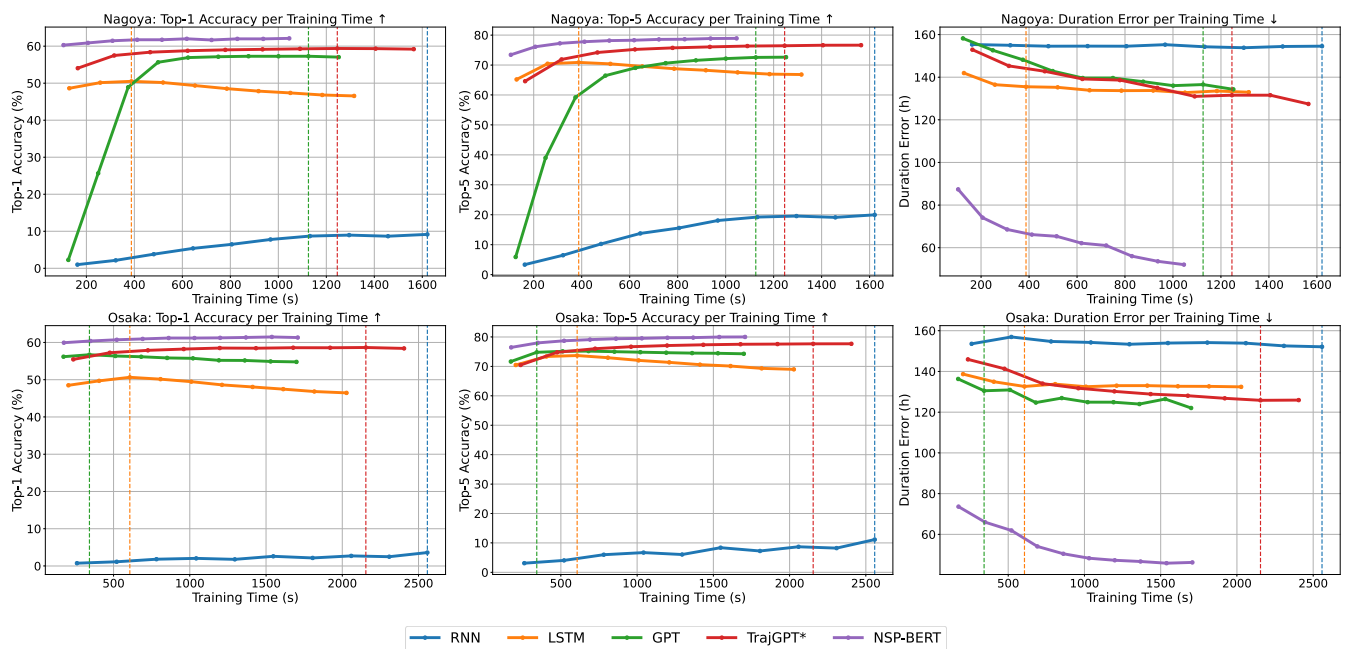


図 5 学習時間に対する予測精度 (上段：名古屋, 下段：大阪)
Fig. 5 Prediction accuracy vs Training time.

行った. 10 エポックごとの重みを用いて予測精度の評価を行い, Top-1 Accuracy が最高値を記録したエポック時点における各評価指標のスコアを表 3 に示す. 結果から, NSP-BERT はほぼすべての評価指標において他のモデルのスコアを上回っており, 予測性能における優位性が実証された.

4.4.2 効率性の比較

図 5 に, 各モデルの学習時間に対する Top-1 Accuracy, Top-5 Accuracy, Duration Error のスコアの推移を示す. RNN, LSTM, GPT, TrajGPT が Top-1 Accuracy の最高値を達成した時点の学習時間 (図 5 の破線) を基準とすると, 同学習時間において NSP-BERT はすべての評価指標で他のモデルを上回る予測精度を達成している. これらの結果より, NSP-BERT は学習の初期段階において高精度な予測を実現できるとともに, 比較した他のモデルに対す

る効率面での優位性も実証された.

4.4.3 頑健性の比較

図 6 に, 予測時に対象ユーザの入力データをランダムに一定割合で欠落させた場合の予測精度の比較結果を示す. 滞在履歴において位置情報が観測されなかった時間帯は欠損として扱われるため, 欠損に対して頑健なモデルの構築は滞在予測において重要な課題となる. 本実験では, 入力データの 10%, 30%, 50%, 70%, 80%, 90%, 95% を欠落させた 7 つの条件を設定し, 各モデルの予測精度を比較した. その結果, NSP-BERT は他のモデルと比較して, 欠損率が高い条件下においても高い予測精度を維持しており, 入力がかた状況に対する優れた頑健性を有することが確認された.

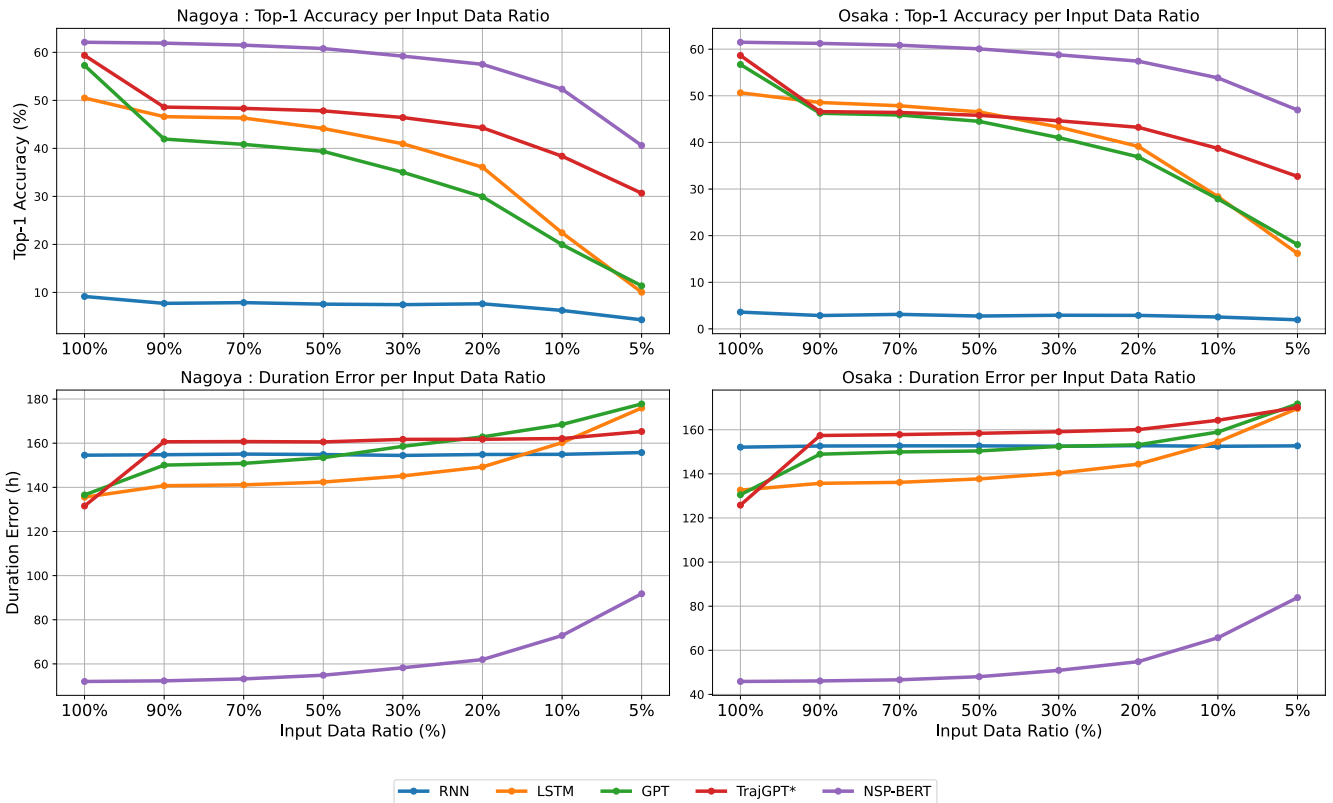


図 6 入力データを一定割合で欠落させたときの予測精度
 Fig. 6 Prediction performance under input data sparsity.

5. 考察

5.1 実験結果に関する考察

表 3 の結果から、NSP-BERT は他の深層学習モデルと比較して、滞在エリアおよび滞在時間の予測において、ほぼすべての評価指標で優位性を示した。滞在予測では、滞在履歴の長期的な依存関係をとらえた特徴抽出が有効であり、本実験においても 90 日間の滞在履歴からの特徴抽出が必要であった。RNN と LSTM は系列長が長くなると前方部分の傾向が薄れるという課題があり、この制約が NSP-BERT と比較した場合の予測精度の低下につながったと考えられる。一方で、DTW のスコアにおいては、GPT および TrajGPT が NSP-BERT を上回る結果となった。この要因としては、NSP-BERT が学習データに頻出するエリアを過度に予測し、その結果として軌跡全体の形状に基づき評価する DTW のスコアが低下した可能性が考えられる。NSP-BERT は、マスク学習時に頻出パターンを過度に学習し、局所的な予測には強みを示す反面、軌跡全体の形状予測には課題を残している。NSP-BERT が、他のスコアを維持した状態で、DTW のスコアを改善するためには、滞在履歴に稀に出現するエリアの正確な予測が必要と考える。

図 5 の結果からは、NSP-BERT が他の深層学習モデルと比較して、学習の早い段階でより高いスコアを達成したことが確認できる。また、他のモデルが Top-1 Accuracy の最高値を達成した学習時間において、NSP-BERT は他

のモデルの予測精度を上回ることが確認された。これは、NSP-BERT がより効率的な学習を実現していることを示唆しており、その効率性においても優位性を実証した。さらに、滞在時間の予測精度の推移より、NSP-BERT は学習の進行にともない精度が向上したのに対し、他のモデルでは精度の向上がほとんど見られなかった。これは、滞在エリアの周期性に比べ滞在時間の周期性が低く、他のモデルではその周期性を十分にとらえられなかった可能性がある。最終的に、NSP-BERT は滞在エリアと滞在時間という複数のラベルを同時に予測する複雑なタスクに対しても適性を持つことが確認された。

図 6 に、予測時に入力データをランダムに一定割合で欠落させた場合における、各モデルの予測精度の比較結果を示す。RNN は長い系列データを処理する際に前方の情報が失われやすいという構造的な制約があり、入力の一部が欠落している状態でも、もともと考慮可能な情報量が限定的であることから、予測精度に大きな変化が見られなかったと考えられる。一方で、LSTM、GPT、TrajGPT、NSP-BERT は欠落率が増加するにつれて予測精度が低下する傾向が確認された。特に、GPT は、初期入力に過去の移動履歴を一括で用いるため欠落による影響を大きく受けたと考えられる。その中で、NSP-BERT は入力データを欠落させた場合においても相対的に高い予測精度を維持しており、データが疎な人流データセットに対しても頑健な予測が可能であることが期待される。

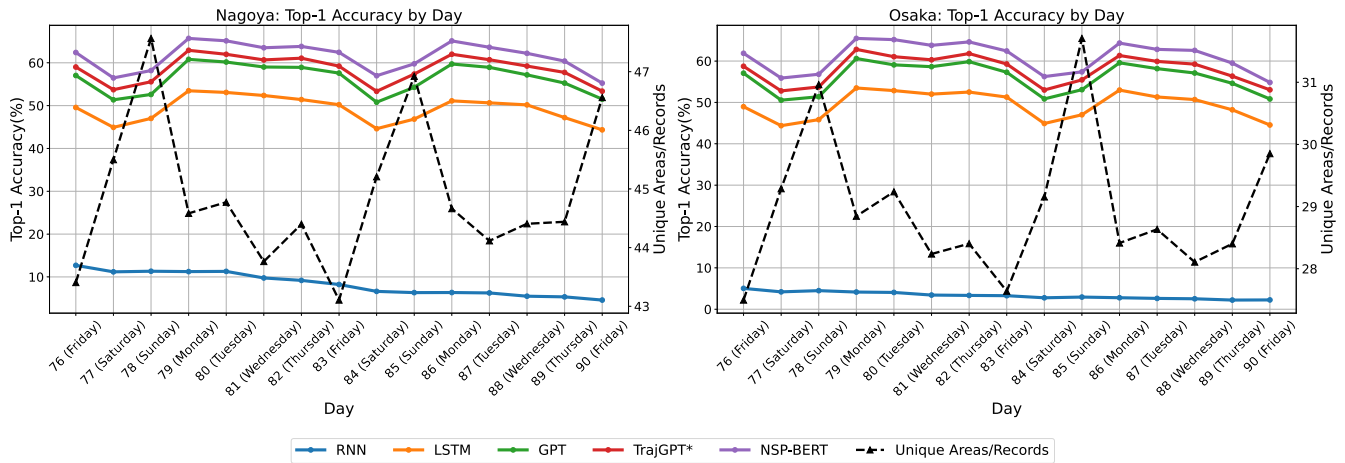


図 7 日ごとの Top-1 Accuracy のスコア
 Fig. 7 Daily Top-1 accuracy during the prediction period.

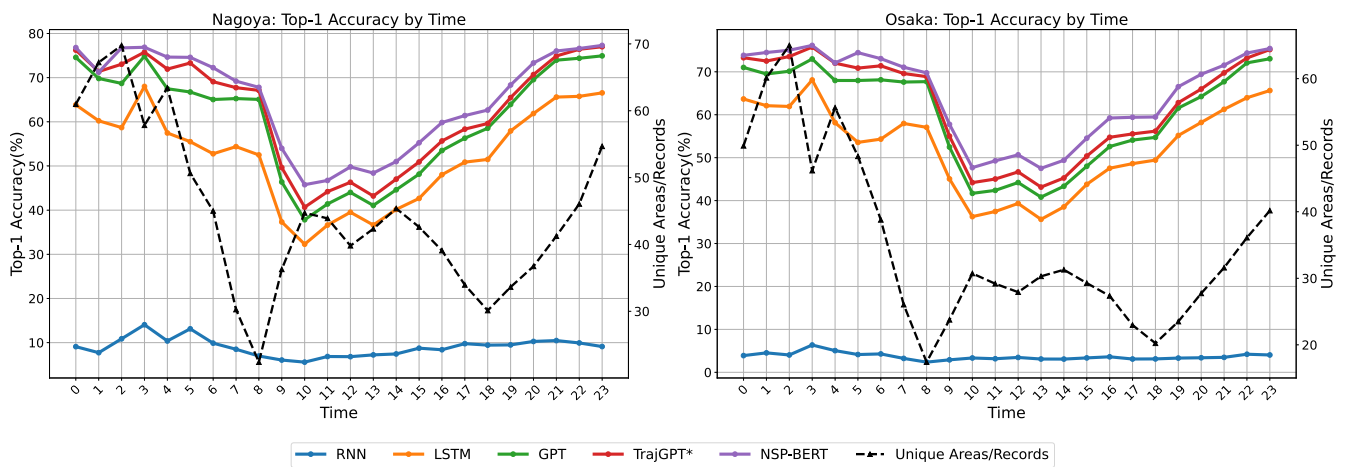


図 8 時間ごとの Top-1 Accuracy のスコア
 Fig. 8 Timely Top-1 accuracy during the prediction period.

5.2 予測結果の詳細分析

図 7 に、予測対象期間の日ごとの予測結果における Top-1 Accuracy のスコアと、その日の滞在レコード数に対する出現したユニークエリア数 (ユニークエリア数/滞在レコード数) の可視化結果を示す。LSTM, GPT, TrajGPT, NSP-BERT に共通して、平日と比較して休日の予測精度が低い傾向が確認された。これは、平日に比べ休日の方が、滞在レコード数に対するユニークエリア数が多く、滞在のパターンが多様かつ複雑であることに起因すると考えられる。この結果は、複雑な滞在パターンを含む予測における予測精度の向上が今後の課題であることを示している。一方で、RNN では日ごとの予測精度が後半にかけて徐々に低下する傾向が見られた。これは、RNN が将来の滞在を逐次的に行う構造であるため、長期間にわたる複数回の滞在を予測する場合、誤差が蓄積しやすく、後半の予測精度に悪影響を及ぼしたものと推察される。

次に、図 8 に、予測対象期間の時間ごとの予測結果における Top-1 Accuracy のスコアと、その時間の滞在レコード数に対する出現したユニークエリア数 (ユニークエリア

数/滞在レコード数) の可視化結果を示す。LSTM, GPT, TrajGPT, NSP-BERT はいずれも、夜間と比較して日中の予測精度が低いことが確認された。夜間は、滞在レコード数、ユニークエリア数ともに少なく、滞在パターンが単純であるため、予測が容易であったと考えられる。一方で、日中は滞在レコード数、ユニークエリア数ともに多く、複雑な滞在パターンの考慮が必要であり予測精度の低下につながったと考えられる。最終的に、日ごと、時間ごとの予測結果からも、他モデルと同様の傾向が見られるなかで、NSP-BERT がつねに最も良いスコアを達成していることが確認され、モデルの優位性が再実証された。

5.3 予測結果の地図上での分析

図 9 は、各都市における時間帯別に集計した、NSP-BERT による予測結果および正解データの滞在レコード数をヒートマップで可視化したものである。時間帯は、日中 (8:00-19:00) と夜間 (20:00-7:00) の 2 区分で分析を行っている。正解データに基づく観測結果からは、両都市において夜間に比べ日中の方が、滞在が観測されたエリア数が多

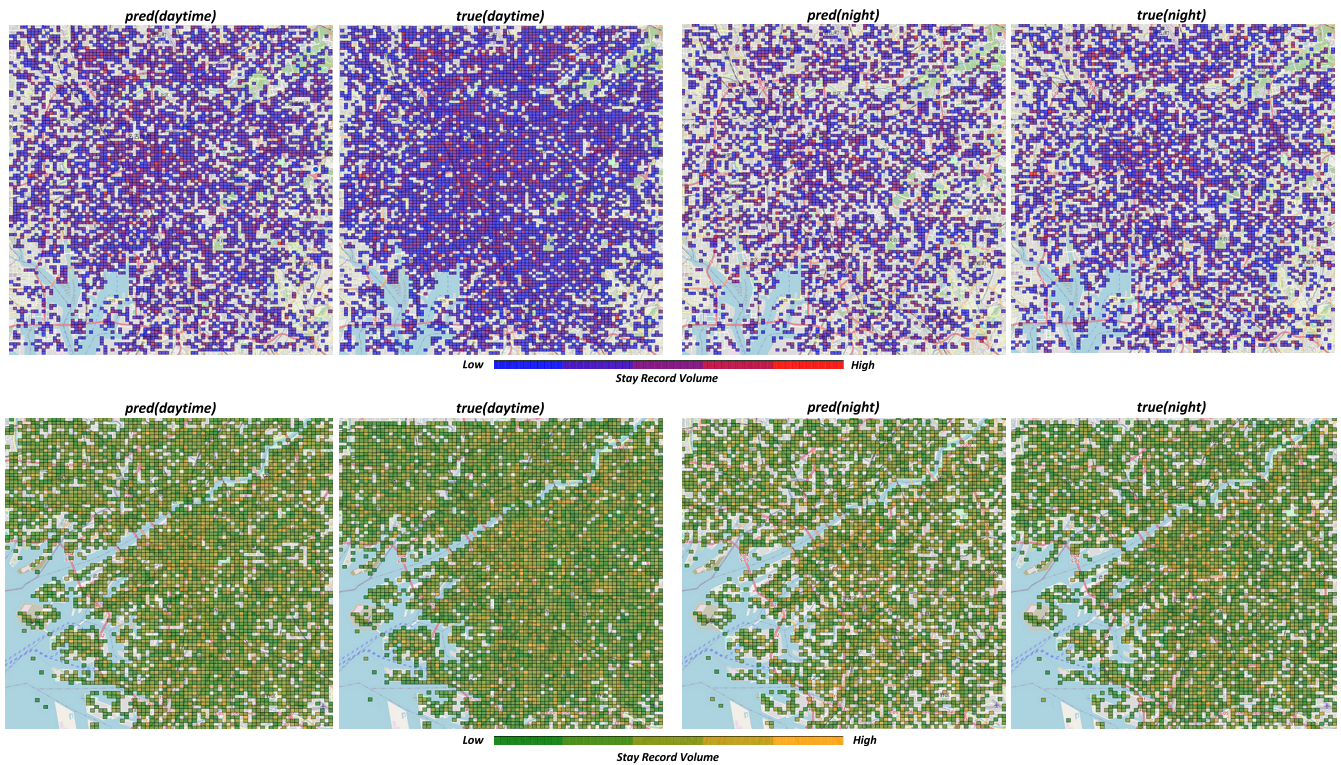


図 9 予測結果と正解データの地図上での比較 (上段：名古屋，下段：大阪)
 Fig. 9 Spatial comparison of predicted and ground-truth stay distributions.

いことが確認され、この傾向は、NSP-BERT による予測結果にも一致して現れている。また、滞在が多く観測されたエリアの地理的分布についても、正解データと予測結果間で高い類似性が確認された。これらの結果は、NSP-BERT が都市全体における滞在傾向をとらえた予測を行っていることを示している。一方で、日中・夜間いずれの時間帯においても、予測結果では正解データと比較して出現しているエリア数が少ない傾向が見られた。これは、利用頻度が低い局所的なエリアの予測が難しく、今後の課題として残ることを示唆している。さらなる予測精度の向上には、利用頻度が高いエリアを過度に予測せず、利用頻度の低い局所的なエリアも予測可能な手法の構築が求められる。

6. まとめ

本研究では、滞在履歴の長期的な依存関係を考慮しつつ、効率的な滞在予測が可能なモデル NSP-BERT (Next Stay Prediction BERT) を提案した。NSP-BERT は、Transformer における Attention 機構の活用により、滞在履歴中のすべての滞在間の関係を考慮でき、かつ逐次的な処理を必要としない効率的な予測を実現する。実世界の人流データセットを用いた実験において、NSP-BERT は、RNN, LSTM, GPT, TrajGPT といった移動予測の研究で採用される他の深層学習と比較して、予測精度および効率性の両面で優れた性能を示した。また、入力データが欠損している状態においても他のモデルと比較して相対的に高い予

測精度を維持しており、その頑健性も示された。予測結果の分析においては、滞在パターンが複雑な場合に予測精度が低下するという課題が確認された。一方で、他のモデルにおいても同様の傾向が現れるなかで、NSP-BERT は予測対象期間の日ごとおよび時間ごとの予測精度で、つねに良いスコアを示しており、その予測性能の高さが改めて確認された。

今後の展望としては、データ量に対するモデル性能や、推論時間比較による効率性評価を通してさらなる検証を行う。都市において人々の滞在傾向をとらえるのに、最少のデータ量で高性能なモデルの構築は、さらなる計算コスト削減において重要であると考えられる。また、予測対象とする地域や期間に対してより頑健に対応可能なモデルの構築を目指す。人々の滞在傾向は都市構造や季節などの空間的・時間的な要因に大きく左右される。条件に合わせてモデルをつど学習させることはコストや運用面において課題となる。そのため、今後はより汎用性が高く、低コストかつ実用性が高い予測モデルの設計と実装に取り組む予定である。

謝辞 本研究の一部は JST CREST (JPMJCR21F2, JPMJCR22M4), 内閣府 SIP3 (JPJ012495), JSPS 科学研究費補助金 (22H03580, 22K18422) に支援いただいています。また、データ提供にご協力いただきました株式会社ブログウォッチャーに感謝いたします。

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 Trans. 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*, Vol.94 (2022).
- [4] Gonzalez, M.C., Hidalgo, C.A. and Barabasi, A.-L.: Understanding Individual Human Mobility Patterns, *Nature*, Vol.453, No.7196, pp.779–782 (2008).
- [5] Shoji, K., Terashima, H., Tamura, N., Katayama, S., Urano, K., Yonezawa, T. and Kawaguchi, N.: Life Pattern-Based Human Attribute Estimation Using Only GPS Data, *IEEE Access*, Vol.13, pp.131803–131822 (2025).
- [6] Damiani, M.L., Acquaviva, A., Hachem, F. and Rossini, M.: Learning Behavioral Representations of Human Mobility, *Proc. 28th International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*, pp.367–376 (2020).
- [7] Zhang, Y., Li, Y. and Ji, W.: A Trajectory-Based User Movement Pattern Similarity Measure for User Identification, *IEEE Trans. Network Science and Engineering*, Vol.10, No.6, pp.3834–3845 (2023).
- [8] 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).
- [9] Shi, T., Ji, G., Yu, Z. and Zhao, B.: Collective Periodic Pattern Discovery for Understanding Human Mobility, *Cluster Computing*, Vol.24, No.1, pp.141–157 (2021).
- [10] Li, J., Wang, J., Zhang, J., Qin, Q., Jindal, T. and Han, J.: A Probabilistic Approach to Detect Mixed Periodic Patterns from Moving Object Data, *Geoinformatica*, Vol.20, No.4, pp.715–739 (2016).
- [11] Liu, Q., Wu, S., Wang, L. and Tan, T.: Predicting the Next Location: A Recurrent Model with Spatial and Temporal Contexts, *Proc. AAAI Conference on Artificial Intelligence*, pp.194–200 (2016).
- [12] Kong, D. and Wu, F.: HST-LSTM: A Hierarchical Spatial-temporal Long-short Term Memory Network for Location Prediction, *Proc. International Joint Conference on Artificial Intelligence (IJCAI)*, pp.2341–2347 (2018).
- [13] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: Bert: Pre-training of Deep Bidirectional Transformers for Language Understanding, *Proc. 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL HLT*, pp.4171–4186 (2018).
- [14] 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 (NeurIPS)*, pp.5998–6008 (2017).
- [15] 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: NSP-BERT: 滞在時間を考慮に入れた効率的な Next Stay 予測手法, マルチメディア, 分散, 協調とモバイルシンポジウム 2024 論文集, Vol.2024, 情報処理学会 (2024).
- [16] available from (<https://www.blogwatcher.co.jp/>).
- [17] Shimizu, T., Tsubouchi, K. and Yabe, T.: GEO-BLEU: Similarity Measure for Geospatial Sequences, *Proc. 30th International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*, pp.1–4 (2022).
- [18] Senin, P.: Dynamic Time Warping Algorithm Review, *Information and Computer Science Department University of Hawaii at Manoa Honolulu*, Vol.855, pp.1–23 (2008).
- [19] Papineni, K., Roukos, S., Ward, T. and Zhu, W.-J.: BLEU: A Method for Automatic Evaluation of Machine Translation, *Proc. 40th Annual Meeting on Association for Computational Linguistics (ACL)*, pp.311–318 (2002).
- [20] Gambs, S., Killijian, M.-O. and del Prado Cortez, M.N.: Next Place Prediction Using Mobility Markov Chains, *Proc. 1st Workshop on Measurement, Privacy, and Mobility*, pp.1–6 (2012).
- [21] Bhattacharya, A. and Das, S.K.: LeZi-update: An Information-theoretic Approach to Track Mobile Users in PCS Networks, *Proc. 5th Annual ACM/IEEE International Conference on Mobile Computing and Networking (MobiCom)*, pp.1–12 (1999).
- [22] Chen, M., Liu, Y. and Yu, X.: NLPMM: A Next Location Predictor with Markov Modeling, *Pacific-Asia Conference on Knowledge Discovery and Data Mining* (2014).
- [23] Ying, J.J.-C., Lee, W.-C., Weng, T.-C. and Tseng, V.S.: Semantic Trajectory Mining for Location Prediction, *Proc. 19th International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*, pp.34–43 (2011).
- [24] Suzuki, M., Furuta, S. and Fukazawa, Y.: Personalized Human Mobility Prediction for HuMob Challenge, *Proc. 1st ACM SIGSPATIAL International Workshop on the Human Mobility Prediction Challenge*, pp.22–25 (2023).
- [25] Chen, J., Li, J. and Li, Y.: Predicting Human Mobility via Long Short-Term Patterns, *Computer Modeling in Engineering & Sciences*, Vol.124, No.3, pp.847–864 (2020).
- [26] Feng, J., Li, Y., Zhang, C., Sun, F., Meng, F., Guo, A. and Jin, D.: Deepmove: Predicting Human Mobility with Attentional Recurrent Networks, *Proc. World Wide Web conference (WWW)*, pp.1459–1468 (2018).
- [27] 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).
- [28] Yang, D., Fankhauser, B., Rosso, P. and Cudre-Mauroux, P.: Location Prediction over Sparse User Mobility Traces Using Rnms, *Proc. International Joint Conference on Artificial Intelligence (IJCAI)*, pp.2184–2190 (2020).
- [29] Lin, Y., Wan, H., Guo, S. and Lin, Y.: Pre-training Context and Time Aware Location Embeddings from Spatial-temporal Trajectories for User Next Location Prediction, *Proc. AAAI Conference on Artificial Intelligence*, pp.4241–4248 (2021).
- [30] Hsu, S.-L., Tung, E., Krumm, J., Shahabi, C. and Shafique, K.: TrajGPT: Controlled Synthetic Trajectory Generation Using a Multitask Transformer-Based

Spatiotemporal Model, *Proc. 32nd ACM International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*, pp.362–371 (2024).

[31] Hong, Y., Martin, H. and Raubal, M.: How Do You Go Where? Improving Next Location Prediction by Learning Travel Mode Information Using Transformers, *Proc. 30th International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*, pp.1–10 (2022).

[32] Tang, P., Yang, C., Xing, T., Xu, X., Jiang, R. and Sezaki, K.: Instruction-Tuning Llama-3-8B Excels in City-Scale Mobility Prediction, *Proc. 2nd ACM SIGSPATIAL International Workshop on Human Mobility Prediction Challenge*, pp.1–4 (2024).

[33] Li, P., de Rijke, M., Xue, H., Ao, S., Song, Y. and Salim, F.D.: Large Language Models for Next Point-of-Interest Recommendation, *Proc. 47th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR)*, pp.1463–1472 (2024).

[34] Terashima, H., Tamura, N., Shoji, K., Katayama, S., Urano, K., Yonezawa, T. and Kawaguchi, N.: Human Mobility Prediction Challenge: Next Location Prediction Using Spatiotemporal BERT, *Proc. 1st ACM*

SIGSPATIAL International Workshop on the Human Mobility Prediction Challenge, pp.1–6 (2023).

[35] Iwata, S., Nitta, T., Takayama, T., Yanagisawa, M. and Togawa, N.: A Stayed Location Estimation Method for Sparse GPS Positioning Information, *2017 IEEE 6th Global Conference on Consumer Electronics (GCCE)*, pp.1–5 (2017).

付 録

A.1 パラメータ調整

図 A.1 に、各モデル (RNN, LSTM, GPT, TrajGPT, NSP-BERT) において、様々な層数、学習率で実験した際のエポックごとの Top-1 Accuracy スコアの推移を示す。各条件においてそれぞれ 100 エポックずつ学習を行い、10 エポックごとに評価を行った。また、表 A.1 に、各モデルにおいて Top-1 Accuracy が上位 3 つの条件を抽出した結果を示す。各モデルの最終的な層数および学習率を以下

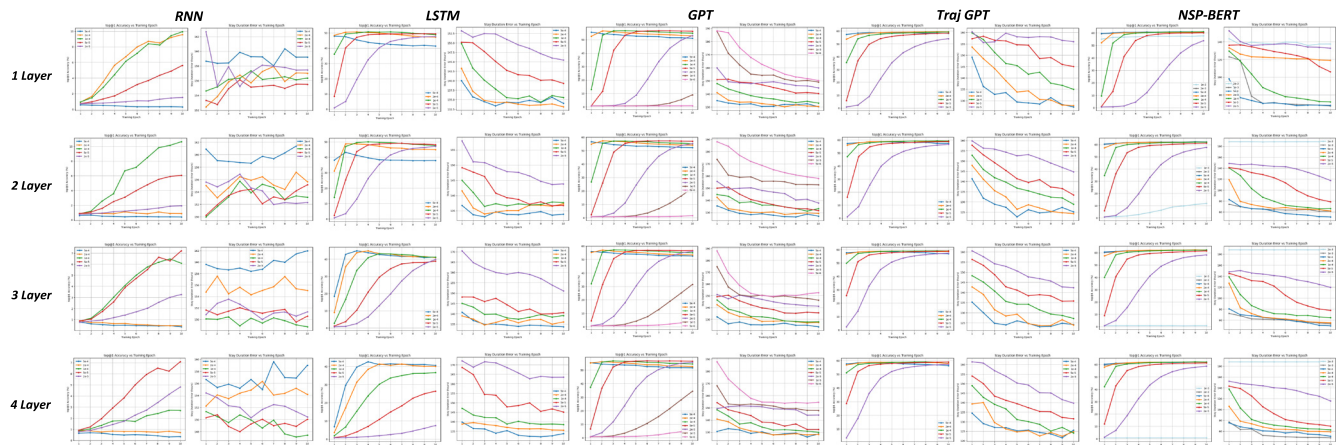


図 A.1 パラメータ比較実験

Fig. A.1 Parameter comparison experiments.

表 A.1 Top-1 Accuracy 上位 3 条件の抽出結果

Table A.1 Top three hyperparameter configurations ranked by Top-1 accuracy.

	Layer	Learning Rate	Epoch	Top-1 Accuracy	Duration Error
RNN	1	1e-4	100	9.94	156
	1	2e-4	100	9.57	157
	2	1e-4	100	10.64	153
LSTM	1	1e-4	40	50.75	138
	1	2e-4	30	50.70	135
	2	1e-4	40	50.03	137
GPT	2	2e-4	20	57.33	133
	2	5e-4	80	57.26	133
	3	1e-4	80	57.22	136
TrajGPT*	1	2e-4	90	59.45	128
	1	2e-4	100	59.37	128
	2	1e-4	90	59.37	132
NSP-BERT	2	5e-4	90	62.41	52
	3	2e-4	90	62.34	56
	4	1e-4	90	62.27	64

に示す手順で決定した。

- (1) **Top-1 Accuracy** が上位 3 つの条件を抽出。
- (2) (1)の中から **Duration Error** が最小のものを採用。
- (3) **Duration Error** が同じ値であった場合は**学習 Epoch** が小さいものを採用。

推薦文

DICOMO2024 の発表論文の中で特に評価が高かったため。

(マルチメディア, 分散, 協調とモバイルシンポジウム
プログラム委員長 越前 功)




寺島 青 (学生会員)

2024 年名古屋大学工学部電気電子・情報工学科卒業。同年より同大学大学院博士前期課程。都市における人流予測, 行動理解に関する研究に従事。



田村 直樹 (学生会員)

2021 年名古屋大学工学部電気電子・情報工学科卒業。2023 年同大学大学院修士課程修了。同年より同大学院博士後期課程。都市データモデリング, 人流分析, 行動理解に関する研究に従事。




庄子 和之 (学生会員)

2019 年名古屋大学工学部電気電子・情報工学科卒業。2021 年同大学大学院修士課程修了。2022 年より同大学院博士後期課程。データ駆動型アーバン・コンピューティング, ヒューマンモビリティのための大規模時空間データ解析に関する研究に従事。



片山 晋 (正会員)

2018 年慶應義塾大学環境情報学部卒業, 2020 年同大学大学院政策・メディア研究科修士課程修了。2023 年名古屋大学大学院工学研究科博士後期課程修了。博士 (工学)。同年より名古屋大学大学院工学研究科特任助教。主にヒューマンコンピュータインタラクション, アフェクティブコンピューティングの研究に従事。



浦野 健太 (正会員)

2016 年名古屋大学工学部電気電子・情報工学科卒業。2018 年に同大学大学院修士課程, 2021 年に博士課程を修了。同年より同大学院助教。博士 (工学)。屋内位置推定, 実世界データモデリング, 生体信号のエンターテインメント利用に関する研究に従事。



米澤 拓郎 (正会員)

2010 年慶應義塾大学大学院政策・メディア研究科後期課程博士号取得後, 同大学院特任助教, 特任講師, 特任准教授を経て, 2019 年より名古屋大学大学院工学研究科准教授。主に, ユビキタスコンピューティングシステム, ヒューマンコンピュータインタラクション, センサネットワーク等の研究に従事。ACM, 電子情報通信学会, IEEE 各会員。



河川 信夫 (正会員)

1990 年名古屋大学工学部電気電子工学科卒業。1995 年同大学大学院工学研究科情報工学専攻博士課程満了。同年同大学工学部助手, 同大学講師, 准教授を経て, 2009 年より同大学大学院工学研究科教授。NPO 位置情報サービス研究機構 Lisra 代表理事。モバイルコミュニケーション, ユビキタスコンピューティング, 行動センシングの研究に従事。博士 (工学)。ACM, IEEE, 人工知能学会, 日本ソフトウェア科学会, 電子情報通信学会, 日本音響学会各会員。本会シニア会員。