

目的地候補周辺のPOIを用いた移動先予測の高精度化

松下 拓海¹ 坪内 孝太² 下坂 正倫¹

概要：過去の移動軌跡から次の移動先を予測する移動先予測は、都市計画や交通最適化への応用が期待されている。近年では、出発地周辺のPOI（Point of Interest）や土地利用といった時空間文脈を軌跡情報に加えることで予測精度を向上させる手法が提案されているが、いずれも出発地側の文脈のみを用いており、移動先周辺の文脈は活用されていない。都市部のように多様な施設が密集する地域では、近接する候補地の文脈の違いが移動先の区別に寄与すると考えられる。本研究では、移動距離・方向の補助タスクにより目的地候補を推定し、候補周辺のPOIを移動先予測モデルに統合する枠組みを提案する。HuMob Challenge 2024 データセットを用いた実験により、提案手法は都市B, C, DにおけるGeoBLEUの平均値0.324を達成し、同コンペティション1位手法の0.319を上回った。さらに、目的地候補と正解の位置関係に基づくケース分析により、候補周辺のPOI文脈が特に候補近傍に正解が存在する場合の予測誤りの修正に寄与することを示した。

1. 序論

1.1 背景

過去の移動軌跡をもとに次の移動先を予測する移動先予測は、都市計画や交通最適化、災害時の避難誘導など多岐にわたる応用が期待されている基礎的な研究課題である [1], [2]。近年ではGPS搭載端末やスマートフォンの普及により大規模な移動軌跡データの収集が容易となり、機械学習モデルによる高精度な移動先予測が盛んに研究されている。特に、自然言語処理分野で発展したTransformerを移動軌跡に応用したLP-BERT [2] はHuMob Challenge 2023で1位を獲得するなど、移動先予測におけるデファクトスタンダードとなっている。

しかし、単純な軌跡情報のみでは、通勤・通学のような日常的な規則性の外にある移動や、近接する複数の候補地のうちどこが選ばれるかを十分に区別することは難しい。そのため近年では、出発地周辺のPOIや土地利用 [3], [4], [5], リモートセンシング画像 [6], [7] など、軌跡の各地点に紐付く時空間文脈を追加情報として軌跡と統合することで予測精度を向上させる手法が提案されている。また、移動距離や方向といった軌跡から計算可能な情報を補助タスクとして学習させ、移動先の空間的位置を直接的に推定する枠組み [8] も提案されている。

しかし、既存手法が扱う文脈はいずれも出発地側に留まっており、移動先側の文脈は活用されていない。都市部




図 1: 近接する目的地候補の区別における移動先側 POI 文脈の役割

では多様な施設が数百メートル四方に密集しており、似た位置関係にある近接した候補地であっても施設構成や土地利用は大きく異なりうる。こうした候補地周辺の文脈の違いは、「ある軌跡パターンの直後にはオフィス街ではなく商業地が選ばれやすい」といった推論に直結するため、近接する移動先候補を区別する上で本質的な手がかりとなる。図 1 に、近接候補地の区別における移動先側 POI 文脈の有効性を概念的に示す。

移動先周辺のPOIは、移動者がその地点を選んだ動機を強く反映する。降車地点や到着地点周辺のPOIから移動目的を推定する研究 [9], [10], [11] では、移動先のPOI分布が訪問目的と強く対応することが示されている。このことから、移動先周辺の文脈を予測モデルに組み込むことは近接候補の区別に有効と考えられる。しかし、移動先は予

¹ 東京科学大学 情報理工学院 情報工学系

² LINE ヤフー株式会社

測対象そのものであり事前には与えられないため、移動先の推定と文脈の取得を統合的に扱うフレームワークが必要となる。

そこで本研究では、移動距離・方向の予測を補助タスクとして導入し、推定された目的地候補の周辺 POI を軌跡の潜在表現と統合することで、移動先予測の精度を向上させる枠組みを提案する。提案手法は、LP-BERT [2] をベースに移動距離・方向の補助タスクを追加して目的地候補を推定し、候補を中心とした 3×3 グリッドの POI をモデルが学習した位置埋め込み空間上で取得し、再び軌跡の潜在表現に加算することで最終的な移動先を予測する。HuMob Challenge 2024 データセット [12] を用いた実験により、提案手法は同コンペティション 1 位手法 [13] を上回る GeoBLEU スコア（都市 B, C, D の平均 0.324）を達成した。さらに、目的地候補と正解の位置関係に基づくケース分析により、提案手法が候補近傍に正解が存在する場合の予測誤りを効果的に修正していることを示した。

本研究の貢献は以下のようにまとめられる。

- 目的地候補を推定しその周辺の POI 文脈を軌跡に統合することで移動先を区別する、移動先予測のフレームワークを提案する。
- HuMob Challenge 2024 データセットにおける実験で、同コンペティション 1 位手法を上回る GeoBLEU スコアを達成する。
- 目的地候補と正解の位置関係に基づくケース分析により、目的地候補周辺の POI 文脈が移動先予測の精度向上に寄与する条件を明らかにする。

1.2 関連手法

移動先予測の既存手法は、本研究の立場から見ると「目的地候補をどのように推定するか」「推定された移動先の文脈をどう活用するか」の 2 軸で整理できる。以下ではこの 2 軸に沿って関連研究を整理し、本研究の位置付けを明確にする。

1.2.1 目的地候補の推定

移動先予測の既存手法の多くは単段の予測器として設計されているが、その出力を目的地候補とみなすことで本研究における候補推定の要素技術として利用可能である。活用する文脈の観点から、目的地候補の推定に資する手法は、時間文脈を主とする手法、出発地周辺の空間文脈を活用する手法、および移動距離・方向を直接推定する手法に大別される。

時間文脈のみを用いる手法は、訪問系列から逐次遷移パターンや周期性を捉えることで移動先を推定する。DeepMove [1] は、時刻・曜日などの時間文脈と履歴アテンションを用いた RNN により軌跡の逐次遷移パターンと周期性を捉え、チェックインデータにおいて RNN に対し Acc@1 を平均 31.63% 向上させた。LP-BERT [2] は、BERT を移

動軌跡に適用し、日付・時刻・座標・前回移動からの時間差を入力として移動先を予測する枠組みを提案し、HuMob Challenge 2023 において GeoBLEU 0.344 で優勝した。これらの手法は軌跡の順序性を精緻にモデル化する一方、地点周辺の空間文脈は扱わないため、近接する候補地の区別は訪問系列の文脈のみに依存する。

出発地周辺の空間文脈を活用する手法は、各訪問位置周辺の POI・土地利用・リモートセンシング画像などの意味情報を軌跡に組み込むことで予測精度を向上させる。POI や土地利用を用いる手法として、Yao ら [3] は各位置周辺の POI の TF-IDF から土地利用の意味ベクトルを構築し Bi-LSTM に統合することで、基地局データにおいて Acc@1 87.63% を達成した。Hong ら [4] は各訪問位置周辺の POI から LDA により土地利用を表現し、滞在時間や時間帯とともに Multi-Head Self-Attention に統合することで、GC データセットにおいて Acc@1 45.6% を達成している。STaBERT [5] は LP-BERT に各位置の POI 情報（85 次元）と時間記述子（曜日・休日・活動期間）を追加することで、HuMob Challenge 2023 のデータにおいて GeoBLEU を 0.34 から 0.75 へ大幅に向上させている。リモートセンシング画像を用いる手法として、Xu ら [6] は GPS 軌跡データに対して高解像度マルチスペクトル画像から土地利用を推定し軌跡と融合することで、F-score を 8.69% 向上させた。Jiang ら [7] はリモートセンシング画像・POI 分布・道路ネットワークを統合したグラフ表現により訪問位置の空間的・意味的文脈を表現し、東京データセットにおいて Recall@5 0.348, NDCG@5 0.257 を達成している。これらの手法は出発地側の文脈により近接候補の識別性を高めるが、活用する文脈はいずれも軌跡上で観測済みの地点に限られる。

移動距離や移動方向を直接推定する手法は、目的地の空間的位置を出発地からの変位として直接的に捉える。MoBERT [8] は、移動距離と移動方向の予測を補助タスクとして Transformer に導入することで、HuMob Challenge 2023 のデータにおいて GeoBLEU 0.354 を達成した。距離・方向は軌跡のみから算出可能であり、POI 情報などの外部資源を必要としないため、データセットに付随する POI の粒度や品質に依存せず目的地候補を推定できる。

1.2.2 移動先の文脈を用いた予測

前節で述べたように、既存の移動先予測手法が活用する文脈はいずれも出発地側に留まっており、移動先側の文脈は活用されていない。軌跡情報と出発地周辺の文脈だけでは、近接する複数の候補地のうちどこが選ばれるかを区別する手がかりが乏しい。

一方、移動先周辺の POI が移動目的を強く示唆することは、移動目的推定の研究において示されてきた。Gong ら [9] は、タクシーの降車地点周辺の POI からベイズ推定により移動目的を 9 種に分類し、推定結果が上海市の住

民旅行調査データとよく一致することを示した。Krause and Zhang [10] は、目的地の土地利用・POI から移動目的を推定し、目的に合致する場所に候補を絞ることで目的地予測精度を Acc@1 45.7% から 52.7% へ向上させた。Meng ら [11] は、軌跡・POI 分布・ソーシャルメディアから取得した POI 人気度を組み合わせた Dynamic Bayesian Network により移動目的を推定し、POI の機能と人気度の双方が移動目的の推定に寄与することを示した。これらの研究は、到着地周辺の POI が移動者の選択動機を強く反映していることを共通して示しており、近接する複数の候補地を区別する際に有効な文脈となりうることを示唆する。

しかし、これらの研究はいずれも移動目的の推定に主眼を置くものであり、移動先予測そのものに移動先側の POI 文脈をフィードバックする枠組みは提案されていない。本研究では、移動先予測モデルに目的地候補の推定を明示的に組み込み、その候補周辺の POI を取得して軌跡の潜在表現に統合することで、このギャップを埋めることを目指す。

2. 準備

2.1 問題設定

移動先予測とは、ユーザの過去の移動軌跡から将来の移動先を予測するタスクである。本研究では、HuMob Challenge 2024 [12] の問題設定に従い、離散化されたグリッド上の位置を予測対象とする。

具体的には、ユーザ u の 60 日分の過去軌跡 $\mathcal{T}_u = \{(d_i, t_i, x_i, y_i)\}_{i=1}^{N_u}$ が与えられたとき、予測対象となる 61 日目から 75 日目の時刻 (d, t) における位置 (x, y) を予測する。ここで $d \in \{0, \dots, 74\}$ は日付インデックス、 $t \in \{0, \dots, 47\}$ は 30 分刻みの時刻インデックス、 $(x, y) \in \{1, \dots, 200\}^2$ は都市を 500m 間隔に離散化したグリッド座標である。都市 A, B, C, D の 4 都市のうち、都市 B, C, D の予測対象ユーザ各 3,000 人が予測対象となる。さらに本研究では都市 A の 3,000 人 (uid = 97000–99999) も同様にマスクして評価対象とする。

2.2 前提手法：LP-BERT

LP-BERT [2] は、自然言語処理で広く用いられる BERT アーキテクチャを移動軌跡に適用した手法である。LP-BERT は HuMob Challenge 2023 で 1 位を獲得し、HuMob Challenge 2024 の 1 位 [13]・3 位 [14] 手法の部品としても採用されるなど、大規模匿名化 GPS データセットにおける標準的な基盤手法となっている。図 2 に LP-BERT のモデル構造を示す。

LP-BERT は日付 d 、時刻 t 、位置 (x, y) 、および前回観測からの時間差 Δt をそれぞれ埋め込み層で D 次元のベクトルに変換し、それらの和を Transformer エンコーダに入力する。学習時は連続する 15 日間の位置を一定割合でマスクし、エンコーダ出力に対して位置分類ヘッド (Softmax)




図 2: 前提手法 LP-BERT のモデル構造

によりマスクされた位置を並列に予測する。LSTM のような逐次予測モデルと異なり、マスクされた全ての位置を並列に予測することで学習・推論時間を大幅に削減できる点が大きな利点である。損失関数には Cross-entropy 損失を用い、最適化には AdamW を用いる。

本研究が LP-BERT をベースとするのは、(i) 位置・時間の情報を埋め込みとして扱う単純な構造のため、新たな文脈情報（距離・方向・POI 埋め込みなど）の追加が容易であること、(ii) 並列予測により長い軌跡の処理が高速であること、(iii) HuMob Challenge 2023, 2024 の上位手法で採用されており再現性が確認されていること、の 3 点の理由による。

3. 提案手法

本研究では、移動先周辺の POI 文脈を予測モデルに組み込むために、LP-BERT を拡張した 2 段階予測フレームワークを提案する。本章では提案手法の全体像、目的地候補の推定方法、および候補周辺の文脈を軌跡表現に統合する方法を述べる。

3.1 概要

提案手法は、目的地候補の推定と候補周辺 POI 文脈を用いた最終予測の 2 段階からなる移動先予測フレームワークである。全体像を図 3 に示す。LP-BERT と同様の入力（位置 ID r 、日付 d 、時刻 t 、時間差 Δt ）に加え、各位置での事前学習済み POI 埋め込みおよび直前位置からの移動距離を入力とする Transformer エンコーダを共通の基盤とする。第 1 段階では、エンコーダ出力から直前位置の候補予測と予測位置への移動距離・方向を推定し、候補予測に移動ベクトルを加えて目的地候補グリッドを得る。ここで移動距離・方向は補助タスクとして学習させ、候補推定に必要な空間的手がかりをモデルから引き出す。第 2 段階では、推定された候補を中心とする近傍グリッドの POI 埋め込みを取得し、エンコーダ出力と結合して最終的な移動先を予測する。候補推定を経由することで、予測対象である移動先が事前に与えられないという問題を回避しつつ、移動先側の POI 文脈を予測に活用できる。




図 3: 提案手法の概要

3.2 エンコーダ入力と POI 埋め込み

提案手法のエンコーダ入力は、LP-BERT の入力に各位置の事前学習済み POI 埋め込みと前位置からの移動距離埋め込みを加えたものである。

以下ではグリッド座標 $(x, y) \in \{1, \dots, 200\}^2$ を 1 次元の位置 ID に変換する関数を次式で定義する。

$$\text{idx}(x, y) = (x - 1) \cdot 200 + (y - 1) \quad (1)$$

入力位置 $r_i = \text{idx}(x_i, y_i)$ に対する POI 埋め込みは、事前に都市ごとに学習した Space2Vec [15] 型のテーブル $E_{\text{POI}} \in \mathbb{R}^{C \times R \times D_{\text{POI}}}$ (C : 都市数, $R = 40000$: グリッド数, D_{POI} : 埋め込み次元) を用いる。POI 埋め込みは学習中は凍結し、予測位置では 0 ベクトルで置換することで真の位置情報の漏洩を防ぐ。

各時刻の入力ベクトル h_i は、位置・日付・時刻・時間差・POI・移動距離の各埋め込みを連結して次式で構成する。

$$h_i = [e_i^r; e_i^d; e_i^t; e_i^{\Delta t}; e_i^{\text{POI}}; e_i^{\rho}] \quad (2)$$

ここで、 $e^r, e^d, e^t, e^{\Delta t}$ はそれぞれ位置・日付・時刻・時間差の学習可能な埋め込みであり、 e_i^{ρ} は前回位置からの移動距離 $\rho_i = \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} / 2 \text{ km}$ を 2 層 MLP で埋め込んだものである。予測位置では $e^r, e^{\text{POI}}, e^{\rho}$ を学習可能なマスク埋め込みで置換する。これらに正弦波位置エンコーディングを加算した後、 L 層の Transformer エンコーダに通し、隠れ表現 $z_i \in \mathbb{R}^D$ を次式で得る。

$$z_i = \text{TransformerEncoder}(h_i) \quad (3)$$

3.3 目的地候補の推定

移動距離・方向は、移動先の空間的位置を出発地からの変位として直接的に与える手がかりである。MoBERT [8] が示したように、これらを補助タスクとして学習させるこ

とで、モデルは軌跡の順序性のみに頼らず空間的な移動パターンを内部表現に取り込む。

具体的には、エンコーダ出力 z_i から 2 つの MLP ヘッドを分岐させる。距離ヘッドは正規化された対数移動距離 $\tilde{\rho}_i \in \mathbb{R}$ を次式で回帰し、正規化済み対数距離 $(\log(1 + \rho_i) - \mu) / \sigma$ を目標とした SmoothL1 損失で学習する。

$$\tilde{\rho}_i = \text{MLP}_{\rho}(z_i) \quad (4)$$

ここで、 μ, σ は学習データ全体での対数距離の平均・標準偏差を表す。方向ヘッドは移動方向を 9 クラス（停止、東、北東、北、北西、西、南西、南、南東）として分類し、Cross-entropy 損失で学習する。9 クラス分類を採用するのは、グリッド座標への離散的な変位とよく整合するためである。各クラス $c \in \{0, \dots, 8\}$ には単位変位ベクトル $\theta_c \in \mathbb{R}^2$ を対応付け、 $c = 0$ は停止 $\mathbf{0}$ とし、 $c = 1, \dots, 8$ は東から反時計回りに 45° ずつ回転させた単位ベクトル（斜め方向は $(\pm\sqrt{2}/2, \pm\sqrt{2}/2)$ ）とする。方向ヘッドの出力 $\hat{p}_i \in \mathbb{R}^9$ 、予測クラス $\hat{c}_i$ 、および対応する予測方向ベクトル $\hat{\theta}_i \in \mathbb{R}^2$ は次式で与えられる。

$$\hat{p}_i = \text{MLP}_{\theta}(z_i), \quad (5)$$

$$\hat{c}_i = \arg \max_{c \in \{0, \dots, 8\}} \hat{p}_{i,c}, \quad (6)$$

$$\hat{\theta}_i = \theta_{\hat{c}_i} \quad (7)$$

連続表現による回帰との比較は 4.2 節で述べる。

推論時には、予測位置 i に対して次のように目的地候補グリッド r_i^{cand} を構成する。まず直前位置のエンコーダ出力 z_{i-1} から位置分類ヘッド W_r (POI 文脈を使わない素の分類器) により直前位置の候補予測 $\hat{r}_{i-1}^{\text{int}} = \arg \max_r W_r(z_{i-1}, \mathbf{0})$ を得る。次に距離ヘッド出力 $\tilde{\rho}_i$ を正規化対数変換の逆変換により物理距離 $\hat{\rho}_i$ へ戻す。

$$\hat{\rho}_i = \exp(\tilde{\rho}_i \sigma + \mu) - 1 \quad (8)$$

続いて予測方向ベクトル $\hat{\theta}_i$ を用いて、候補予測のグリッド座標 $(x_{i-1}^{\text{int}}, y_{i-1}^{\text{int}}) = \text{idx}^{-1}(\hat{r}_{i-1}^{\text{int}})$ に移動ベクトルを加算し、目的地候補の座標を次式で計算する。

$$x_i^{\text{cand}} = x_{i-1}^{\text{int}} + \hat{\theta}_i^x \cdot 2\hat{\rho}_i, \quad (9)$$

$$y_i^{\text{cand}} = y_{i-1}^{\text{int}} + \hat{\theta}_i^y \cdot 2\hat{\rho}_i, \quad (10)$$

$$r_i^{\text{cand}} = \text{idx}(x_i^{\text{cand}}, y_i^{\text{cand}}) \quad (11)$$

ここで、係数 2 は距離の単位 (km) をグリッド幅 (0.5 km) に戻すための変換である。

このように直前位置の候補予測に移動距離・方向を加えることで、学習された順序的遷移パターンだけでは曖昧になる近接した候補地を、空間的変位の観点から再サンプリングできる。

3.4 目的地候補周辺の POI 文脈の統合

第 2 段階では、推定された目的地候補の周辺 POI 埋め込みを平均プーリングし、エンコーダ出力に結合することで最終的な移動先を予測する。

具体的には、第 1 段階で推定された目的地候補 r_i^{cand} について、候補自身を除いた K 近傍グリッド（本研究では $K = 8$ ）の POI 埋め込みを取得し、平均プーリングにより候補周辺の文脈ベクトル $\bar{e}_i^{\text{POI}} \in \mathbb{R}^{D_{\text{POI}}}$ を次式で得る。

$$\bar{e}_i^{\text{POI}} = \frac{1}{K} \sum_{r \in \mathcal{N}_K(r_i^{\text{cand}})} E_{\text{POI}}[k_i, r] \quad (12)$$

ここで、 $\mathcal{N}_K(\cdot)$ は事前計算した近傍テーブル、 k_i はユーザが属する都市 ID を表す。観測位置では $\bar{e}_i^{\text{POI}} = \mathbf{0}$ とする。

最終的な位置予測 $\hat{r}_i$ は、エンコーダ出力と候補周辺 POI 文脈を連結した特徴量を位置分類ヘッド W_r に通し、次式で得る。

$$\hat{r}_i = \arg \max_r W_r([z_i; \bar{e}_i^{\text{POI}}]) \quad (13)$$

学習時は最終予測 $\hat{r}_i$ の Cross-entropy 損失と、距離・方向の補助損失を合わせた重み付き和

$$\mathcal{L} = \mathcal{L}^r + \lambda_\rho \mathcal{L}^\rho + \lambda_\theta \mathcal{L}^\theta \quad (14)$$

を目的関数とする。

4. 実験

本章では、提案手法の有効性を検証するため、HuMob Challenge 2024 データセット [12] を用いた比較実験と、候補推定の正誤に基づくケース分析を行う。

4.1 実験設定

4.1.1 データセット

本実験では、LY Corporation のスマートフォンアプリ




図 4: HuMob Challenge 2024 データセットの概要

の GPS ログから生成された匿名化大規模 GPS データセットである HuMob Challenge 2024（以下 HuMob'24）データセット [12] を用いる。HuMob'24 は、日本国内の 4 都市（都市 A, B, C, D）の計約 15 万人・75 日間の移動軌跡から成り、各都市のユーザ数は都市 A が 10 万人、都市 B が 2.5 万人、都市 C が 2 万人、都市 D が 6 千人である。位置情報は 500m 四方のグリッドに離散化され、時刻は 30 分刻みで集約されている（図 4）。

HuMob Challenge 2024 の問題設定に従い、都市 B, C, D それぞれ 3,000 人の予測対象ユーザについて、61-75 日目の位置をマスクし予測する。本研究では加えて都市 A の 3,000 人 (uid = 97000-99999) も予測対象として扱い、モデルの学習には都市 A, B, C, D の全ての訓練区間の軌跡を用いるクロスシティ学習を採用する。

POI 埋め込みは、HuMob Challenge 2024 データセットに付随する各都市のグリッド単位 POI カテゴリカウント（86 カテゴリ）を入力として、Space2Vec [15] により $D_{\text{POI}} = 64$ 次元で都市ごとに事前学習したものをを用いる。学習済み POI 埋め込みは以降の予測モデル学習中は凍結する。

4.1.2 評価指標

HuMob Challenge の公式評価指標である GeoBLEU [16] を用いる。GeoBLEU は自然言語処理で用いられる BLEU を移動軌跡に拡張した指標で、予測軌跡と正解軌跡の n -gram に対して地理的近さを考慮した類似度を計算する。コンペティションと同じく $N = 3$ 、距離減衰パラメータ $\beta = 0.5$ を用い、値が高いほど予測精度が高いことを示す。

4.1.3 比較手法

提案手法の構成要素ごとの寄与を確認するため、距離ヘッド単独の基礎構成に、方向ヘッド（分類/回帰の 2 種）と POI 文脈の有無を組み合わせ以下の 5 モデルを比較する。

- 距離
- 距離 + 方向（分類）
- 距離 + 方向（回帰）

表 1: HuMob'24 における GeoBLEU スコア

モデル	A	B	C	D	平均 (B-D)
距離	0.3445	0.3235	0.3270	0.3072	0.3192
距離+方向 (回帰)	0.3453	0.3247	0.3284	0.3059	0.3197
距離+方向 (分類)	0.3461	0.3254	0.3287	0.3106	0.3216
距離+方向 (回帰)+POI	0.3469	0.3267	0.3300	0.3123	0.3230
距離+方向 (分類)+POI	0.3486	0.3280	0.3295	0.3146	0.3241
LP-BERT	0.3376	0.3191	0.3202	0.3076	0.3156
HuMob'24 1 位 [13]	—	—	—	—	0.319
HuMob'24 2 位 [17]	—	—	—	—	0.3093
HuMob'24 3 位 [14]	—	—	—	—	0.3050

- 距離 + 方向 (分類) + POI
- 距離 + 方向 (回帰) + POI

方向 (回帰) では, 3.3 節の 9 クラス分類ヘッドを連続角度 ϕ_i に対する $(\sin \phi_i, \cos \phi_i)$ の 2 次元ベクトルを出力する回帰ヘッドに置き換え, SmoothL1 損失で学習する. 推論時の候補グリッド構成式における $\hat{\theta}_i$ には, 回帰ヘッドが直接予測した $(\cos \hat{\phi}_i, \sin \hat{\phi}_i)$ をそのまま用いる (ここで $\hat{\phi}_i$ は予測された連続角度).

ベースラインとして, LP-BERT [2] を再現したモデルおよび HuMob Challenge 2024 公式リーダーボードの上位 3 手法 [13], [14], [17] を用いる.

4.1.4 学習設定

全モデル共通で, Transformer エンコーダは層数 $L = 4$, ヘッド数 8, 隠れ次元 2048, 位置埋め込み次元 128 とする. 最適化は AdamW, 実効バッチサイズ 64 (4GPU), エポック数は都市 A, B, C, D のクロスシティ学習で最大 50 エポックとする. 学習率と補助タスクの損失重み $\lambda_\rho, \lambda_\theta$ は, 検証データ上の GeoBLEU を目的関数として, 比較モデルごとに独立に Optuna によるベイズ最適化 (各 20 試行, 10 エポック) を行い, 各モデルで得られた最良値を採用した. 候補推定における近傍数は $K = 8$ を既定値とする.

4.2 比較実験結果

各モデルの GeoBLEU スコアを表 1 に示す. 提案手法は, 都市 B, C, D の平均 GeoBLEU で 0.3241 を達成し, LP-BERT ベースラインの 0.3156 から +2.69% の向上, HuMob Challenge 2024 の 1 位手法 [13] の 0.319 をも +1.60% 上回った. また, 都市別に見ても, 提案手法は 4 都市全てで比較モデル中の最良値またはそれに準ずる性能を示し, 最小ユーザ数の都市 D でも LP-BERT に対して +2.28% の改善を達成している.

補助タスクの有無で見ると, 移動距離のみの追加で +1.14%, 移動距離+方向 (分類) の追加で +1.90% の改善が得られ, 空間的変位を捉える補助タスクが有効であることが確認できる. その上に目的地候補周辺の POI 文脈を加えると追加で +0.77% の改善が得られ, 目的地候補周辺の POI 文脈が補助タスクとは独立に寄与していることが確認

表 2: 提案手法のケース分析 (全予測位置に対する割合 [%])

	A	B	C	D
Case 1 (候補正解)	32.32	31.59	32.39	28.56
1a (最終正解)	30.90	30.06	30.79	26.54
1b (最終誤答)	1.42	1.53	1.60	2.02
Case 2 (誤答, K 近傍内)	22.68	22.52	23.04	23.96
2a (訂正成功)	1.00	0.97	1.13	1.22
2b (別誤答)	1.03	1.14	1.22	1.53
2c (同誤答)	20.66	20.41	20.70	21.21
Case 3 (誤答, K 近傍外)	44.99	45.89	44.57	47.48
3a (訂正成功)	0.38	0.48	0.39	0.70
3b (別誤答)	4.31	5.28	5.31	5.81
3c (同誤答)	40.31	40.13	38.86	40.96
訂正率 (2a の 2 内割合)	4.41	4.31	4.89	5.10
訂正率 (3a の 3 内割合)	0.85	1.04	0.88	1.47

できる. 方向の表現形式については, 9 クラス分類の方が回帰よりもわずかに高い性能を示した. これは, 候補推定時にはどちらの表現も離散的な座標に丸められるため, 離散方向の分類として扱う方がノイズの少ない候補グリッドが得られたためと考えられる.

4.3 ケース分析

提案手法において, 候補予測 $\hat{r}^{\text{int}}$ と最終予測 $\hat{r}$ の正誤, および候補予測の近傍 $K = 8$ グリッド内に正解が含まれるか否かで予測事例を以下の 3 ケースに分類する.

Case 1 候補予測が正解.

Case 2 候補予測は不正解だが, 正解が候補予測の $K = 8$ 近傍に存在.

Case 3 候補予測が不正解で, 正解も $K = 8$ 近傍にない. さらに各ケースを最終予測の正誤に応じて, 正解 (a) / 候補と別の誤答 (b) / 候補と同じ誤答 (c) に細分する.

各都市のケース別割合を表 2 に示す. Case 2 (誤答だが正解が候補近傍に存在) における訂正率 (Case 2a / Case 2) は 4.3–5.1% であり, Case 3 の訂正率 0.85–1.47% と比べて約 4–6 倍高い. これは, 候補近傍に正解が存在する場合に候補周辺 POI 文脈が予測の訂正に明確に寄与していることを示している. 一方, 全ての予測位置の 31–32% (都市 D では 28.6%) は Case 1 (候補予測が既に正解) であり, このうち大部分 (各都市 30% 前後) は POI 文脈導入後も正解が維持されている (Case 1a). Case 2 は 22–24% を占めており, POI 文脈による訂正が期待される領域である.

一方で, Case 2c すなわち候補予測と同じ誤答が最終段で維持されるケースは, 全体の約 20% と最も大きい割合を占める. これは, 候補近傍の POI 平均は近接グリッド間で類似しやすく, 候補予測と正解が近傍 $K = 8$ 内にあっても常に十分な識別情報を与えるわけではないことを示す. また, Case 3 (候補近傍外に正解) は全体の 45–47% を占

めており、候補推定そのものが大きく外れた場合には POI 文脈の効果は限定的である。これは、Case 3 で正解が候補近傍外にある場合、POI プーリングの空間範囲 ($K = 8$ 近傍) を超えるため POI 文脈が正解に関する情報を持ち得ないためと考えられる。

以上より、候補周辺 POI 文脈は候補推定が正解の近傍に収まる場合に特に有効であり、候補推定の誤差が大きい場合には効果が限定的となる。都市 D において訂正率が最も高い (5.10%) のは、ユーザ数が最も少なく軌跡情報が疎なため、周辺文脈による補完の寄与が相対的に大きくなるためと考えられる。

5. 結論

本研究では、移動先側の文脈が活用されてこなかったという既存研究の課題に対し、移動距離・方向の補助タスクで目的地候補を明示的に推定し、その周辺の POI 文脈を予測モデルに統合する 2 段階予測フレームワークを提案した。HuMob Challenge 2024 データセットを用いた実験では、提案手法は都市 B, C, D における GeoBLEU 平均 0.3241 を達成し、LP-BERT ベースラインから +2.69% の改善、HuMob Challenge 2024 の 1 位手法 [13] の 0.319 を +1.60% 上回った。また、目的地候補と正解の位置関係に基づくケース分析により、候補近傍に正解が存在する場合の訂正率はそれ以外と比べて約 4–6 倍高く、候補周辺の POI 文脈が近接候補の区別に寄与していることを定量的に示した。

本研究の課題は以下の 3 つが挙げられる。

異なる候補予測手法と複数候補の活用

本研究では移動距離・方向の補助タスクによる単一の候補予測を用いたが、候補予測の精度は最終予測性能に直結する。より高精度な候補予測手法の検討や、距離・方向の予測信頼度に応じた複数候補の生成とそれらを統合して活用する枠組みの検証が考えられる。

より意味的情報を含む POI 文脈の活用

本研究ではグリッド単位の POI カテゴリカウントから学習した Space2Vec 埋め込みを用いたが、POI は単なるカテゴリ分布以上の意味情報 (営業時間・混雑度・相互の機能的関係など) を持つ。これら意味的文脈を取り込んだ POI 表現への拡張と、それが近接候補の区別にもたらす効果の検証が求められる。

他データセットを用いた汎化性の検証

本研究の実験は HuMob Challenge 2024 データセットのみを対象としており、地域・観測粒度・ユーザ母集団の異なる条件下での一般性は未検証である。HuMob Challenge 2025 データセットをはじめとする他データセットへの適用を通じ、提案枠組みの汎化性を検証することが必要である。

参考文献

- [1] 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 on World Wide Web (WWW '18)*, ACM Press, pp. 1459–1468 (online), DOI: 10.1145/3178876.3186058 (2018).
- [2] 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, *Proceedings of the 1st International Workshop on the Human Mobility Prediction Challenge (HuMob-Challenge '23)*, ACM, pp. 1–6 (online), DOI: 10.1145/3615894.3628498 (2023).
- [3] Yao, Y., Guo, Z., Dou, C., Jia, M., Hong, Y., Guan, Q. and Luo, P.: Predicting mobile users' next location using the semantically enriched geo-embedding model and the multilayer attention mechanism, *Computers, Environment and Urban Systems*, Vol. 104, p. 102009 (online), DOI: 10.1016/j.compenvurbsys.2023.102009 (2023).
- [4] Hong, Y., Zhang, Y., Schindler, K. and Raubal, M.: Context-aware multi-head self-attentional neural network model for next location prediction, *Transportation Research Part C: Emerging Technologies*, Vol. 156, p. 104315 (online), DOI: 10.1016/j.trc.2023.104315 (2023).
- [5] Liu, Y., Tan, H., Kanjaria, R., Li, L. and Salim, F. D.: Classical Feature Embeddings Help in BERT-Based Human Mobility Prediction, *Proceedings of the 33rd ACM International Conference on Advances in Geographic Information Systems (SIGSPATIAL '25)*, ACM, pp. 1134–1137 (online), DOI: 10.1145/3748636.3763212 (2025).
- [6] Xu, C., Li, F. and Xia, J.: Fusing high-resolution multi-spectral image with trajectory for user next travel location prediction, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 116, p. 103135 (online), DOI: 10.1016/j.jag.2022.103135 (2023).
- [7] Jiang, N., Yuan, H., Si, J., Chen, M. and Wang, S.: Towards Effective Next POI Prediction: Spatial and Semantic Augmentation with Remote Sensing Data, *2024 IEEE 40th International Conference on Data Engineering (ICDE)*, IEEE, pp. 5061–5074 (online), DOI: 10.1109/ICDE60146.2024.00104 (2024).
- [8] Fang, T., Luo, X., Walther, P. and Werner, M.: Human Mobility Prediction with Multi-Task Curriculum Training, *Proceedings of the 33rd ACM International Conference on Advances in Geographic Information Systems (SIGSPATIAL '25)*, ACM, pp. 1238–1241 (online), DOI: 10.1145/3748636.3771316 (2025).
- [9] Gong, L., Liu, X., Wu, L. and Liu, Y.: Inferring trip purposes and uncovering travel patterns from taxi trajectory data, *Cartography and Geographic Information Science*, Vol. 43, No. 2, pp. 103–114 (online), DOI: 10.1080/15230406.2015.1014424 (2016).
- [10] Krause, C. M. and Zhang, L.: Short-term travel behavior prediction with GPS, land use, and point of interest data, *Transportation Research Part B: Methodological*, Vol. 123, pp. 349–361 (online), DOI: 10.1016/j.trb.2018.06.012 (2019).
- [11] Meng, C., Cui, Y., He, Q., Su, L. and Gao, J.: Towards the Inference of Travel Purpose with Heterogeneous Urban Data, *IEEE Transactions on Big Data*, Vol. 8, No. 1, pp. 166–177 (online), DOI: 10.1109/TB-DATA.2019.2921823 (2022).
- [12] Yabe, T., Tsubouchi, K., Shimizu, T., Sekimoto, Y.,

- Sezaki, K., Moro, E. and Pentland, A.: YJMobi100K: City-scale and longitudinal dataset of anonymized human mobility trajectories, *Scientific Data*, Vol. 11, No. 1, p. 397 (online), DOI: 10.1038/s41597-024-03237-9 (2024).
- [13] Terashima, H., Takagi, S., Tamura, N., Shoji, K., Hos-sain, T., Katayama, S., Urano, K., Yonezawa, T. and Kawaguchi, N.: Time-series Stay Frequency for Multi-City Next Location Prediction using Multiple BERTs, *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on the Human Mobility Prediction Challenge (HuMob '24)*, ACM, pp. 5–9 (online), DOI: 10.1145/3681771.3699909 (2024).
- [14] Suzuki, M., Fukushima, Y., Koyama, R., Kumagai, H., Mimura, T. and Ochiai, K.: Cross-city-aware Spatiotem-poral BERT, *Proceedings of the 2nd ACM SIGSPA-TIAL International Workshop on the Human Mobil-ity Prediction Challenge (HuMob '24)*, ACM, pp. 33–36 (online), DOI: 10.1145/3681771.3699915 (2024).
- [15] Mai, G., Janowicz, K., Yan, B., Zhu, R., Cai, L. and Lao, N.: Multi-Scale Representation Learning for Spa-tial Feature Distributions using Grid Cells, *International Conference on Learning Representations (ICLR)* (2020).
- [16] Shimizu, T., Tsubouchi, K. and Yabe, T.: GEO-BLEU: Similarity Measure for Geospatial Sequences, *Proceedings of the 30th International Conference on Advances in Geographic Information Systems (SIGSPATIAL '22)*, ACM, pp. 1–4 (online), DOI: 10.1145/3557915.3560951 (2022).
- [17] Tang, P., Yang, C., Xing, T., Xu, X., Xu, J., Jiang, R. and Sezaki, K.: Llama-Mob: Instruction-Tuning Llama3-8B Excels in City-Scale Mobility Prediction, *Proceedings of the 2nd ACM SIGSPATIAL Interna-tional Workshop on the Human Mobility Prediction Challenge (HuMob '24)*, ACM, pp. 1–4 (online), DOI: 10.1145/3681771.3699908 (2024).