

# BERT を用いたスマートフォン位置情報による 移動状態推定技術

上坂 大輔<sup>1</sup>・小林 亮博<sup>1</sup>・武田 直人<sup>1</sup>・南川 敦宣<sup>2</sup>・森本 章倫<sup>3</sup>

<sup>1</sup> 非会員 株式会社 KDDI 総合研究所 (〒356-8502 埼玉県ふじみ野市大原 2-1-15)

E-mail: {da-kamisaka, ak-kobayashi, no-takeda}@kddi-research.jp

<sup>2</sup> 非会員 KDDI 株式会社 (〒102-8460 東京都千代田区飯田橋 3-10-10)

E-mail: at-minamikawa@kddi.com

<sup>3</sup> 正会員 早稲田大学教授 理工学術院 (〒169-8555 東京都新宿区大久保三丁目 4 番 1 号)

E-mail : akinori@waseda.jp

近年、スマートプランニング等に必要な移動需要のモデル化の手段として、Activity-Based Model (ABM) が実用化されつつある。また、そのデータソースとして、従来のパーソントリップ調査のみでは困難であった、近距離トリップや滞在パターンの観測、季節性の反映や鮮度の確保に利点のある、スマートフォン位置情報の活用が注目されている。スマートフォン位置情報は、大規模かつ継続的にデータを蓄積することが可能である一方、移動状態（手段）や移動目的などのセマンティクスを直接的には観測できない課題があった。そこで本論では、自然言語処理において文脈理解に用いられる BERT を応用して、ラベルなしのスマートフォン位置情報の系列データから場所や行動の特徴表現をデータドリブンに獲得し、さらに、少量の正解ラベルを用いて移動状態を推定する手法を提案、その有効性と課題について検証する。

**Key Words:** location data, smart city, smart planning, smartphone, Activity-Based Modeling, location embeddings, BERT, transportation mode detection

## 1. はじめに

都市の現在あるいは将来の人流・交通流を推定する交通需要予測は、街づくり（スマートプランニング）や都市交通施策の検討（渋滞回避、回遊促進、賑わい醸成等）、MaaS や自動運転等の交通システムの設計や効率的運用等において、重要かつ基本となる技術の一つである。交通需要予測を行うための大きな2つの考え方としては、従来の四段階推定法<sup>1)2)</sup>の他に、個人の一日の活動・移動をモデル化する Activity-Based Model (ABM)<sup>3)</sup>の活用が進められている<sup>4)</sup>。例えば東京都市圏交通計画協議会は、ABM によるアクティビティシミュレータを構築している<sup>5)</sup>。交通需要予測のデータソースにはパーソントリップ調査 (PT 調査)<sup>6)</sup>を用いるのが一般的だが、近年では、①短距離移動や複雑な移動パターン、移動以外の観測、②データの鮮度、③長期観測の観点で優れている、スマートフォン位置情報の活用が注目されている<sup>7)8)9)10)11)</sup>。さいたま市は、ビッグデータを活用したスマートプランニングによる交通基盤整備の実証実験として、スマートフォン位置情報を利用した駅周辺における回遊

実態の分析やシミュレーションを行っている<sup>12)</sup>。一方で、スマートフォン位置情報自体には移動目的や移動状態（移動手段）といった意味情報が付加されていないことが大きな課題である。

そこで本研究では、位置情報ビッグデータを用いた ABM による交通需要予測の実現を目的とし、その基盤技術として、位置情報の意味や文脈の表現（埋め込み表現）をデータドリブンに獲得し、移動目的や移動手段などといった重要変数を推定・付加できるモデルを構築することを目指す。本論では、その最初のステップとして、スマートフォン位置情報を用いた移動状態推定技術を提案・検証する。

スマートフォン位置情報から移動状態を推定する方法は数多く提案されているが、位置情報に加えて、路線情報などの GIS データと組み合わせたり<sup>13)14)</sup>、内蔵された加速度センサ等を用いたり<sup>15)</sup>、複数のデータソースを組み合わせるのが一般的である。いずれの場合も一定の精度は得られているものの、あくまでも移動状態推定に特化したものに過ぎない。本研究では、高精度な移動状態推定の実現それ自体を目的とするのではなく、その評価

を通じた、場所や移動の意味に相当する表現の学習と ABM への活用可能性の検証、課題発見を目的とする。

ABM では、人の行動 (Activity) は自宅⇒職場⇒店⇒…といった一連のトリップやツアーで表現される。これは一般化すれば、意味をもった個々の位置情報 (例えば滞在場所や経由地) を、意味をもった順序で次元に並べた系列 (シーケンス) データとみることができる。この点に着目し、位置情報やモビリティのモデリングに、近年発展の著しい自然言語処理 (NLP) のアプローチを適用する試みがある<sup>16)17)18)</sup>。NLP で扱う言語データは、「単語」の系列である「文章」が単位であり、これは行動系列と類似した構造を持つ。また、意味が文脈によって変化する「単語」は、移動目的によって意味の異なる場所と似ていると言える (例えばショッピングモールは、食事や買い物、映画鑑賞など様々な用途で利用される)。NLP の技術の一つである BERT (Bidirectional Encoder Representations from Transformers)<sup>19)</sup> は、文脈理解や、教師なしでの事前学習による言語モデル獲得を特徴としており、場所の意味の理解や、ラベルの無いスマートフォン位置情報による学習との親和性が高い。Lin らは、移動先の予測を行うための BERT を用いた埋め込み表現獲得手法を提案している<sup>18)</sup>。しかし、①ABM にとって重要なトリップやツアーといった活動単位の概念が無く一日の行動全てを単一の系列として扱っている、②位置と時間以外の特徴量が表現できず、交通需要予測に重要な交通条件などと移動の関係性を学習できない、③次位置の予測での検証に留まっている、という点が大きな課題である。

この課題を踏まえ、BERT を用いた移動状態推定技術を提案する。提案手法では、トリップ単位での地域メッシュコードの系列データに、移動速度や進行方向といったアノテーション不要の (純粹に位置情報のみから算出できる) 特徴量を加えたものを入力とした事前学習を行った後に、少量の教師ありデータによって、移動状態推定モデルを訓練 (ファインチューニング) する。地域メッシュのコード体系や、場所の意味、地図情報などを一

切与えることなく、ラベルの無い位置情報のみから、場所やトリップの意味を学習 (例えば、ある地点やトリップと別の地点やトリップが意味的に「似ている」ことを理解) させることで、精度の良い移動状態推定が期待できる。また、この事前学習モデルは、移動状態推定だけでなく、移動目的の推定や移動先の予測、新しい交通手段や施設、政策に対する将来の行動のシミュレーションなどにも幅広く適用でき、スマートフォン位置情報を活かした ABM にとっての基盤技術となると考えている。

本論では、提案手法の詳細と、ケーススタディとして宇都宮市の 5 か月間のスマートフォン位置情報を用いた評価について、以降の章にて説明する。

## 2. 提案手法

提案するアーキテクチャの全体像を図-1 に示す。提案手法は、①前処理、②トリップエンコーダ、③事前学習と、④移動状態推定から構成される。

### ① 前処理

前処理では、観測された生データである位置情報の点群から、トリップ単位の移動データを生成する。具体的には、最初にノイズとなる誤差の大きな観測点の除去を行った後、小林らの手法<sup>20)</sup>をベースに、連続する2つの測位点間の距離と時間差から移動と滞在の判別を行い、最後に、滞在から次の滞在までの移動軌跡を1トリップとして、出力する。

### ② トリップエンコーダ

トリップエンコーダは、特徴量抽出とトークナイズを行い、後続の事前学習が行える系列データ、すなわち NLP における単語と文章データを生成する。

緯度・経度は連続値であり、そのままでは単語として扱えないため、地域メッシュコードに変換 (離散化) する。さらに、位置以外の情報として時間や速度といった特徴量を加えるため、サブワード<sup>21)</sup>を定義し、トリップ中の各メッシュコードの末尾に付与する。例えば、自然

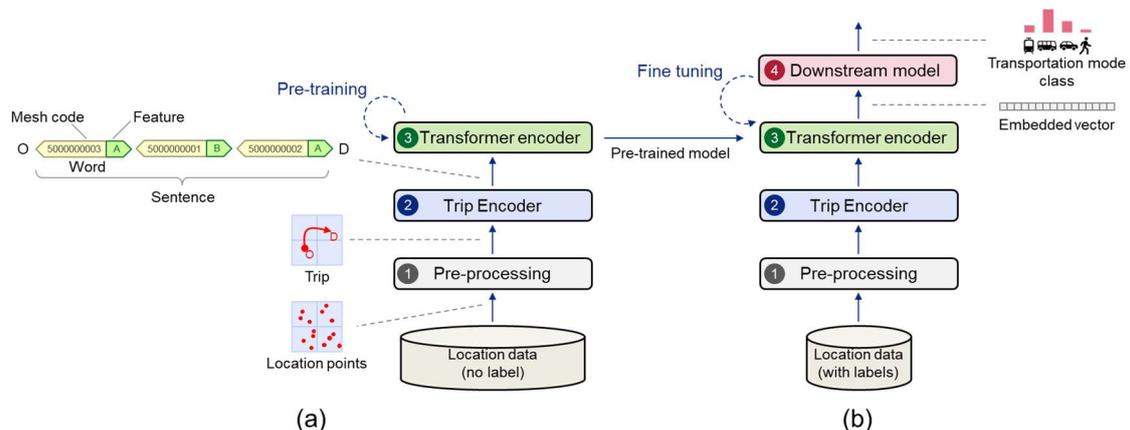


図-1 提案手法概要

言語では“play”と“#ing”というサブワードから“playing”という単語が成り立つように、提案手法では、“500000012”というメッシュコードと、“##WN”という特徴量（平日・夜間を指す）から、“500000012WN”という単語を構成する。単語間はスペースで区切られ、トリップの終端で改行される。なお、GPSの測位周期が一定でないことを踏まえ、連続して出現した同一メッシュコード群は、1つに集約する。例えば、メッシュコード系列A, A, A, B, C, Cは、A, B, Cのようにエンコードする。

### ③ 事前学習

事前学習時の疑似タスクには、一般的なBERT同様、MLM (Masked Language Model) を用いる。これは、文章中の一部の単語をマスクし、それを予測できるようモデルを訓練する教師なし（自己教師あり）学習であり、トリップの途中のメッシュコードをマスク・予測することに相当する。このとき、正解メッシュは前後のマスクされていないメッシュの間に存在することが想定され、一見すると容易なタスクにも思えるが、メッシュコードのルールや空間的な位置関係の情報は明示的には一切与えていない点に注意されたい。

### ④ 移動状態推定

移動状態推定では、事前学習済みのモデルから出力されたトリップのEmbedding（埋め込み表現、文脈）を説明変数として、目的変数である移動状態クラスの分類を行う。モデルとしては3層のMLP (Multi-Layer Perceptron)<sup>2)</sup>を用いた。訓練には、事前学習とは別の、移動状態の正解ラベルを付与したデータを用い、移動状態が精度良く予測できるよう、予測誤差を事前学習済みモデルにフィードバックして、モデルパラメータを微調整（ファインチューニング）する。

## 3. 対象都市における評価

### (1) データセット

事前学習には、2019/3/1～7/31の5カ月間の宇都宮市内の位置情報データを利用した。これは、KDDI 株式会社からauスマートフォン利用者より許諾を得て取得したGPSデータである。特徴量の効果を検証するために、付与した特徴量の異なる次の4通りのデータセットを用意し、移動状態推定の精度比較を行った。

- O：メッシュコードのみ（特徴量を付与しない）。
- T：メッシュコードに、時間に関する特徴量として、平日/休日種別と、昼/夜を示すフラグを付与。昼は6-19時台、夜は20-翌5時台と定義した。
- P：メッシュコードに、ユーザ属性を示す特徴量として、そのユーザの推定自宅メッシュ、職場

メッシュのメッシュコードを付与する。自宅と職場はそれぞれ、夜と昼に最も滞在頻度の高いメッシュとした。

- B：メッシュコードに、行動に関する特徴量として、当該メッシュの滞在時間（15分未満、15～60分、60分～の3状態）、メッシュ間の移動速度（5km/h未満、5～20km/h、20km/h～の3状態）と進行方向（東西南北と滞留の5状態）の情報を示すカテゴリ値を付与。

いずれの特徴量も、スマートフォン位置情報のみから得ることのできるものであり、調査データやアノテーションは必要としない。地域メッシュには4分の1地域メッシュ<sup>2)</sup>（一辺約250m）を採用した。

移動状態推定には、2019/8/21～10/20の約2か月間実施された、「宇都宮 MaaS 社会実験」<sup>2)</sup>において実験用アプリを用いてスマートフォンで収集されたGPSデータを用いた。実験用データにつき、通信キャリアが保有する位置情報よりも高頻度（およそ30秒周期）で測位されており、移動状態の正解ラベル付与に適しているためである。ユーザ数は216名である。移動状態として、徒歩、自家用車、バス、鉄道の4状態を定義し、目的トリップ単位で1つの正解データを付与した。例えば、自宅から職場への移動に徒歩とバスを利用した場合、移動状態の正解ラベルはバスとなる。正解データの算出には、GPSデータとバス停・鉄道駅の座標、および、バス位置情報データ（GTFS-Realtime<sup>2)</sup>）を併用して機械的に判定処理を行った後、目視にて補正を加えたものを利用した。

### (2) 評価条件

BERTは、Hugging Face Open-Source Libraries<sup>2)</sup>のTransformersライブラリを利用して実装した。モデルサイズは、報告<sup>1)</sup>のBERT<sub>BASE</sub>（レイヤ数：12、隠れ層：768次元、自己注目ヘッド数：12）と同様である。データセットO、T、P、Bの事前学習済みモデル単体での性能については、MLMのTop-100 accuracy（マスクされた正解メッシュが推定結果上位100件中に含まれる割合）でそれぞれ、91.4%、85.8%、95.0%、93.6%であることを確認した。事前学習の評価の詳細については、小林らの関連研究<sup>2)</sup>を参照されたい。移動状態推定用のMLPの中間層のノード数は50、損失関数は交差エントロピー誤差（Cross Entropy Loss）とした。

ユーザベースでの5分割の交差検定（5-fold CV）を行い、F値（F1スコア）を分類性能の指標として、以下の3種のベースライン手法と性能を比較した。

- NB（ナイーブベイズ<sup>2)</sup>）：ベイズの定理にもとづく単純な確率的分類器
- RF（ランダムフォレスト<sup>2)</sup>）：決定木による複数の弱学習器を統合（バギング）し汎化能力を

向上させるアンサンブルモデル

- **LGBM (Light GBM<sup>30)</sup>** : 逐次的に弱学習器を構築していく勾配ブースティングの一つ

なお、ベースライン向けの入力データについては、トリップ中の各メッシュの出現 (通過) 回数を特徴量としたテーブルデータ形式を用いた。

**(3) 評価結果**

提案手法とベースラインの評価結果 (F 値) を表-1 に示す。全体的な傾向としては、NBが0.4~0.5程度と最も低く、他の3手法は0.7~0.8程度でその差は比較的接近していた。特徴量Pを除いた数値では提案手法が最も高く、次いでLGBMという結果であった。特徴量Pのみ傾向がやや異なり、RFが最も高い性能を示した。

特徴量付与による精度向上効果を見ると、NB以外の3手法のいずれについても、特徴量TとPの効果は殆ど確認できず、特徴量なし(O)と概ね同程度の精度であった。特徴量Tは平日/休日と昼/夜の4状態のみのごく単純なものであるため、移動状態を推定するにあたって十分な予測力が無かったものと思われる。また、特徴量P(自宅と職場メッシュ情報)は、ユーザ属性の表現を意図したものであったが、今回のユーザ規模(N=216)程度では実質的にはユーザ個人を識別するIDに近い。そのため、評価対象ユーザ本人のデータが学習データに含まれないユーザベースでの交差検定では、効果が無かったものと思われる。この点は、例えば性年代情報など、同じ属性をもつユーザが複数存在するような特徴量を用いることで、効果が表れる可能性がある。一方、特徴量Bについては、特徴量なし(O)と比べた際に顕著な(0.05~0.1pt)精度の向上が確認できた。移動速度等の特徴量が、場所や距離だけでは判断が難しいようなケースでの識別に寄与したものと考えられる。

次に、移動状態別の判定精度を検証する。図-2に、ベースライン中で最も性能の良かったLGBMと提案手法についての、特徴量OとBにおける混同行列を示す。最も精度良く識別できていたのは鉄道であった。鉄道は、全データ中1%前後しか含まれていないにも関わらず、特徴量なし(O)でもF値0.9前後を示していた。他の移動手段と異なり走行する場所や移動距離が決まっているため、メッシュコードのみでも容易に識別可能であったものと考えられる。自家用車と徒歩は相互に間違えやすい傾向にあったが、特徴量B付与による精度向上が著し

表-1 評価結果 (F 値)

Method	O	T	P	B
NB	0.483	0.494	0.425	0.401
RF	0.691	0.690	<b>0.694</b>	0.777
LGBM	0.699	0.703	0.682	0.790
Ours	<b>0.735</b>	<b>0.717</b>	0.690	<b>0.798</b>

く、2つの手法のいずれもBはOに対し0.1~0.2ptの向上が確認された。一方、最も識別困難であったのはバスで、速度や場所の性質が似た自家用車だけでなく徒歩とも間違える傾向が強く、また、特徴量Bの付与によっても改善が見られなかった。今回、正解ラベルは目的トリップ単位で付与しており、例えば「バス停まで徒歩で行き、そこからバスを利用する」場合でも正解ラベルは「バス」となるため、識別が難しかったものと思われる(自家用車についても「駐車場まで徒歩で行き、そこから自家用車を利用する」ケースが当然あるが、自宅を出発地と考えた場合、バスに比べ徒歩の移動距離は短く、間違えにくいと想像される)。

最後に、トリップ長ごとの判定精度を評価する。図-3に、特徴量OとBにおける提案手法とLGBMの識別精度(トリップ長2~50メッシュまで)を示す。(a)は全移動手段、(b)~(d)はそれぞれ、自家用車、徒歩、バスの結果である。なお、鉄道はトリップの絶対数が少なすぎ、トリップ長別に細分化すると乱高下するため、省略する。図-3(a)によれば、全体傾向としてはトリップ長による精度の違いは大きくない(全領域で0.7~0.8前後)が、特に長さが20メッシュ(最大約7km)以下の短距離トリップにおいて、特徴量Bの付与による精度向上が確認できる。この傾向は自家用車において特に顕著であった。図-3(b)を見ると、特徴量なし(O)の精度は両方式ともトリップ長が短いほど悪く、トリップ長3メッシュ以下では0.5を下回る水準であったが、特徴量Bでは大幅に向上し、トリップ長によらず0.8前後を示した。自家用車とは対照的に、徒歩(図-3(c))については、長距離ほど精度が低下する傾向が見られた。注目すべき点として、特徴量なし(O)の場合、提案手法はLGBMより精度が高く、自家用車のトリップ長10メッシュ以下と徒歩の



(a) LGBM



(b) Ours

図-2 混同行列 (左: O, 右: B)

トリップ長 20 メッシュ以上では、両方式に約 0.2pt の差があることが確認された。短距離では徒歩・自家用車のいずれも利用される割合が高く、速度等の特徴量が無いと判別が難しいところ、トリップ中のメッシュ系列に何らかの順序性があり、これが提案手法の推定精度に寄与したと考えられる（例えばメッシュ系列  $A \Rightarrow B \Rightarrow C$  と  $A \Rightarrow C \Rightarrow B$  は LGBM では区別がないが、BERT では異なる系列として認識される）。図-3(d)に示すバスについては、提案手法と LGBM、特徴量なし (O) と特徴量 B で殆ど傾向に違いが見られなかった。前述の通り、徒歩とバスを併用したトリップの影響である可能性がある。

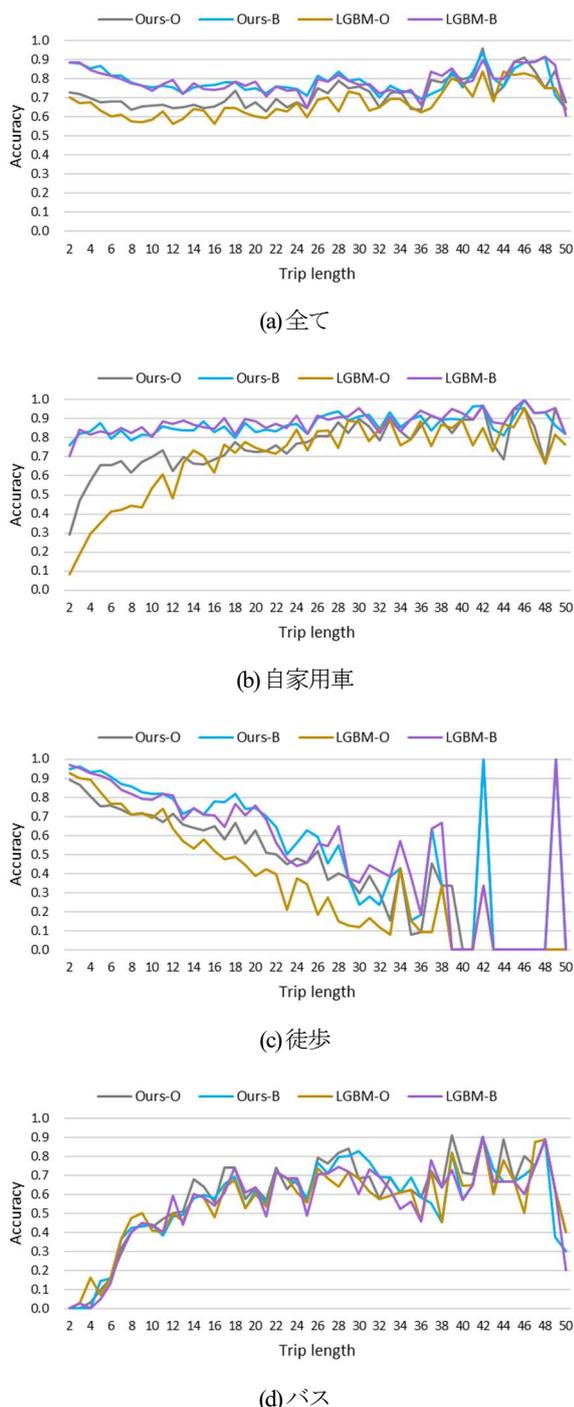


図-3 トリップ長別推定精度

## 4. おわりに

本論文では、位置情報を文章のような系列データとして扱い、BERT を用いて正解ラベルの無いスマートフォン位置情報から移動の意味や文脈に関するモデルを事前学習し、少量のラベル有りデータで移動状態推定を行う手法を提案した。実際のスマートフォン位置情報を用いた評価で、4 種の移動状態を識別するタスクにおいて、特徴量を付与しない場合と、速度等の特徴量を付与した場合について、全ベースラインを上回る精度（それぞれ F 値 0.735, 0.798）を確認した。提案手法はとりわけ短距離の自家用車や徒歩に強く、BERT による行動系列の順序性を考慮したモデル化が奏功したと考えられる。

今回の検証結果は、意味情報を持たないスマートフォン位置情報から事前学習した行動モデルが、適切に文脈表現を獲得（場所やトリップ同士が本質的に似たものであるかどうかを学習）できている可能性を示している。これによって、例えば、PT 調査から得た少量のラベルデータで事前学習済みモデルをファインチューニングすることで、大規模なスマートフォン位置情報に、移動手段だけでなく移動目的など交通行動のモデリングにとって重要なセマンティクスを推定・付与できる可能性がある。このことは、短距離トリップや滞在、季節性の反映といった、スマートフォン位置情報をもつ継続観測による強みを活かした ABM の実現に繋がる、重要な一歩であると考えている。今後の課題としては、より予測力に寄与する特徴量やトリップのエンコード方式、事前学習の疑似タスク等の検討・定量評価などがあげられる。

## 参考文献

- 1) 米谷栄二, 渡辺新三, 毛利正光: 交通工学, 国民科学社, pp. 169-196, 1971.
- 2) 佐々木綱: 都市交通計画, 国民科学社, pp. 75-322, 1974.
- 3) 澤田茜, 小原拓也, 佐々木邦明: アクティビティモデルとモバイル空間統計を用いた都市圏 OD 推計の可能性, 土木計画学研究・講演集 55, 2017.
- 4) 国土交通省都市局: スマート・プランニング実践の手引き【第二版】, 2018.
- 5) 東京都市圏交通計画協議会: 東京都市圏 ACT, [https://www.tokyo-pt.jp/special\\_6th](https://www.tokyo-pt.jp/special_6th), 2021.
- 6) 国土交通省: パーソントリップ調査, [https://www.mlit.go.jp/toshi/tosiko/toshi\\_tosiko\\_tk\\_000031.html](https://www.mlit.go.jp/toshi/tosiko/toshi_tosiko_tk_000031.html)
- 7) 国土交通省都市局: 総合都市交通体系調査におけるビッグデータ活用の手引き, 2018.
- 8) 石井良治: 都市交通計画におけるビッグデータ等の活用, 第 16 回総合都市交通計画研修, 2019.
- 9) 越智健吾, 関信郎, 岩館慶多, 石神孝裕, 若井太亮, 石井良治, 杉田溪: PT 調査データとビッグデータを用いた実務的な詳細スケール目的別手段別 OD 表の作成手法, 土木学会論文集 D3 (土木計画学), 2019,

- 75 巻, 5 号, p. I\_709-I\_717, 2019.
- 10) 吉羽崇, 小林亮博, 中管章浩, 南川敦宣, 富岡秀虎, 森本章倫: スマートフォン位置情報データを活用したバス需要予測に関する研究, 土木学会論文集 D3, 2020, 76 巻, 5 号, p. I\_767-I\_775, 2021.
  - 11) S. Jiang, J. Ferreira and M. C. Gonzalez: Activity-Based Human Mobility Patterns Inferred from Mobile Phone Data: A Case Study of Singapore, in IEEE Transactions on Big Data, vol. 3, no. 2, pp. 208-219, doi: 10.1109/TBDDATA.2016.2631141, 2017.
  - 12) 国土交通省: データ駆動型社会に対応したまちづくりに関する勉強会・データを活用したまちづくり取組のヒントと事例, 2021.
  - 13) Stenneth, L., Wolfson, O., Yu, P. S., and Xu, B.: Transportation mode detection using mobile phones and GIS information, In Proceedings of the 19th ACM SIGSPATIAL international conference on advances in geographic information systems, pp. 54-63, 2011.
  - 14) 石塚宏紀, 小林直, 村松茂樹, 小野智弘: 携帯電話通信履歴による位置情報を用いた鉄道利用者推定の提案, 第 77 回全国大会講演論文集, pp.9-10, 2015.
  - 15) Widhalm, Peter, Philippe Nitsche, and Norbert Brändie: Transport mode detection with realistic smartphone sensor data, Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012), pp.573-576, 2012.
  - 16) Y. Zhou and Y. Huang: DeepMove: Learning Place Representations through Large Scale Movement Data, 2018 IEEE International Conference on Big Data (Big Data), pp. 2403-2412, 2018.
  - 17) Yao, Z., Fu, Y., Liu, B., Hu, W., and Xiong, H.: Representing urban functions through zone embedding with human mobility patterns, In Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence (IJCAI-18), 2018.
  - 18) Lin, Y., Wan, H., Guo, S., & Lin, Y.: Pre-training Context and Time Aware Location Embeddings from Spatial-Temporal Trajectories for User Next Location Prediction, Proceedings of the AAAI Conference on Artificial Intelligence, 35(5), pp.4241-4248, 2021.
  - 19) Devlin, J., Chang, M., Lee, K., and Toutanova, K: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp.4171-4186, 2019.
  - 20) 小林直, 石塚宏紀, 南川敦宣, 村松茂樹, 小野智弘: 携帯電話通信履歴に適した移動滞在状態推定手法の提案, 情報処理学会論文誌データベース (TOD), Vol.10, No.1, pp.13-23, 2017.
  - 21) Sennrich, R., Haddow, B. and Birch, A. 2016. Neural Machine Translation of Rare Words with Subword Units. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers) (Berlin, Germany, Aug. 2016), 1715-1725.
  - 22) Fionn Murtagh: Multilayer perceptrons for classification and regression, Neurocomputing 2, 5, pp.183-197. [https://doi.org/10.1016/0925-2312\(91\)90023-5](https://doi.org/10.1016/0925-2312(91)90023-5), 1991.
  - 23) 総務省統計局: 地域メッシュ統計について, [https://www.stat.go.jp/data/mesh/m\\_tuite.html](https://www.stat.go.jp/data/mesh/m_tuite.html)
  - 24) 宇都宮 MaaS 社会実験実行委員会: 宇都宮 MaaS 社会実験, <https://www.machidukuri.org/news/272>.
  - 25) GTFS-JP: 標準的なバス情報フォーマット, <https://www.gtfs.jp/>
  - 26) Hugging Face: Hugging Face Open-Source Libraries: <https://huggingface.co/>
  - 27) 小林亮博, 上坂大輔, 武田直人, 南川敦宣: 位置情報ビッグデータを用いた交通需要予測のための表現学習技術, 第 64 回土木計画学研究発表会・秋大会, 2021 (掲載予定) .
  - 28) Rish, Irina: An empirical study of the naive Bayes classifier, IJCAI 2001 workshop on empirical methods in artificial intelligence, Vol. 3, No. 22, 2001.
  - 29) Breiman, L.: Random Forests, Machine Learning 45, 5-32, <https://doi.org/10.1023/A:1010933404324>, 2001.
  - 30) Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu: LightGBM: a highly efficient gradient boosting decision tree, In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17), Curran Associates Inc., Red Hook, NY, USA, 3149-3157, 2017.

(Received September 30, 2021)

## BERT-based Transportation Mode Prediction using Smartphone Data

Daisuke KAMISAKA, Akihiro KOBAYASHI, Naoto TAKEDA, Atsunori MINAMIKAWA and Akinori MORIMOTO

In recent years, Activity Based Model (ABM) has become a practical approach to model and understand human mobility patterns throughout a city for smart planning. Location data collected by smartphones is attracting attention as a data source for ABM because it has the advantage of capturing short trips, stay patterns, seasonal trends in real time. On the other hand, smartphone data has difficulties to observe semantics such as transportation mode and purpose of trips. In this paper, we propose an approach using BERT, which is used for natural language processing, to obtain location embeddings from a large amount of location data without annotations, and to classify transportation mode with a small amount of labeled data. We evaluated accuracy and feasibility of our approach using real-world location data.