

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

小林 亮博¹・上坂 大輔¹・武田 直人¹・南川 敦宣²・森本 章倫³

¹ 非会員 KDDI 総合研究所 (〒356-8502 埼玉県ふじみ野市大原二丁目 1 番 15 号)

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

² 非会員 KDDI 株式会社 (〒102-0072 東京都千代田区飯田橋 3 丁目 10 番 10 号)

E-mail: at-minamikawa@kddi.com

³ 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

交通需要を予測する上で、スマートフォン上で取得した大規模な位置情報（ビッグデータ）が着目されつつあるが、実用化が進む ABM(Activity Based Model)にビッグデータを適用した事例は少ない。交通行動を予測する際に、移動目的などの情報は非常に重要であるが、スマートフォン位置情報ではそれらを直接観測できないため、ABM に適用する際の大きな課題となっている。一方で、テキスト解析等の分野で深層学習を用いて大量の文章から文の意味を表現するベクトル値を獲得する表現学習の技術が発達している。そこで本研究では、テキストの表現学習技術 BERT をスマートフォンの移動軌跡に適用し、移動軌跡の埋め込み表現をデータドリブンに獲得する技術を提案する。実際のスマートフォン位置情報から獲得した埋め込み表現を検証し、需要予測への適用可能性を評価した。

Key Words: Location Big Data, Traffic Demand Forecast, ABM, Representation Learning, BERT

1. はじめに

近年、人中心のモビリティネットワークを構築することが、これまで以上に都市交通施策の検討で重要となってきており、人々の活動や暮らしが表現できる ABM (Activity Based Model) を用いた交通行動のシミュレーションに注目が集まっている¹⁾。ABMは、乗り継ぎ施策など多様な施策が評価できるとともに、評価にあたっては交通量の指標だけでなく、個人の活動の変化（外出率や活動時間、アクティビティパターンの変化等）や滞留人口等の多様な切り口で影響を把握することが可能である。

一方で、交通行動のシミュレーションを利用データの面から考えた場合、スマートフォンから得られる位置情報ビッグデータの重要性が高まってきている²⁾。スマートフォンは、IC 乗車券や ETC とは異なり移動手段に関わらずユーザの移動行動を観測可能であり、PT 調査と異なり長期間に渡る観測が可能であることが特徴である。しかし、ユーザの「アクティビティ」をモデル化するためには、ユーザ個人属性や政策変数だけでなく、移動目的などユーザの移動行動の意味を示した付加情報が必須となるため、それらを直接観測できないスマートフォン

位置情報を ABM に適用する際の大きな課題となっている。

この課題に対し、特にテキスト解析の分野で発展してきた表現学習技術が有効に活用できる可能性がある。例えば、BERT は深層学習を用いて大量のラベル無しデータを事前訓練(pre-training)することで文章の意味に相当する多次元ベクトル表現（埋め込み表現）を獲得する。獲得した表現は文書分類や Q&A や翻訳など各種タスクにおいて汎用的に適用可能であり、それぞれのタスクで既存手法に対し高い精度を示すことが知られている。そこで、本研究では、BERT をスマートフォンの移動軌跡に適用し、さらに ABM で人間の行動予測に用いられているユーザ属性等の付加情報と統合することで、移動需要予測や交通手段判別などの様々な交通行動分析に適用可能な汎用的な移動行動の埋め込み表現をデータドリブンに獲得する手法を提案する。

本研究では、実際のスマートフォン位置情報から埋め込み表現獲得し、その基本的な性質や性能を評価した。さらに、獲得した位置表現を可視化することで、意味獲得の可能性について議論する。

2. 関連研究

(1) テキストの表現学習技術

表現学習とは、機械学習のタスクの実行に有用な特徴表現を獲得する手法である。画像、音、自然言語、時系列データなどの高次元なデータを、予測タスクを解くことで低次元な特徴表現に変換する技術である。かつてテキストは各単語が個別の次元で表現される非常に高次元のベクトルで表現することが一般的であり、単語空間におけるデータのスパースさが常に課題となっていた。例えば、文章判別課題などにおいて、類義語を網羅するためラベル付き訓練データを大量に用意する必用があった。この課題を解決するため Word2Vec は、新聞記事など大量のラベル無し文書から単語の共起をニューラルネットワークで予測することで、単語を低次元のベクトルに圧縮する⁵⁾。獲得したベクトルは、 $\text{King} - \text{Man} + \text{Woman} = \text{Queen}$ (図 1) のように意味をベクトル演算で取り扱うことも可能となり、単語空間におけるスパースさの課題が緩和された。そのため、少量のラベル付きデータから類義語を考慮した高精度な判別器が訓練可能となった。

BERT は、単語の意味だけでなくその前後の単語との関係を文章中の位置も含めて Attention⁶⁾ 技術を用いて訓練することで、表現学習の適用範囲を単語だけでなく文章に拡張した⁷⁾。BERT は、単語の穴埋め課題(Masked Language Model: MLM)と次文章判別課題(Next Sentence Prediction: NSP)を、大量のラベル無し文章を用いて事前学習(Pre-training)することで、文章を多次元ベクトルに変換するエンコーダを獲得する。得られたエンコーダを、文書分類や Q&A など様々なタスクに転移学習(Fine-Tuning)することで、少量のラベル付きデータから高精度の推定器を構築できることが知られている。

(2) 位置の表現学習技術

近年ではテキスト解析の分野で発達した表現学習技術を位置情報に適用する試みがある。Lin, Y.ら(2021)⁴⁾は大量の移動軌跡データから BERT を Pre-Training することで、ユーザの移動軌跡からその意味を含む多次元ベクトルを

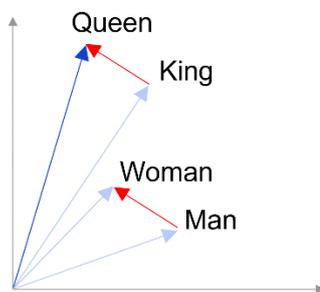


図-1 Word2Vec

抽出することで、ユーザの将来位置の予測に応用している。ここでは、単語の穴埋め問題の代わりに、ユーザの位置系列におけるマスクされた位置や時間を推定することで Pre-Training を実施している。

しかし、Lin, Y.ら(2021)の手法⁴⁾は以下 2 点の課題があり、交通施策のための交通需要の予測に用いることができない。A 地点 B 地点と移動してきたら、次は C 地点に移動しやすい、という位置 (と時間) の系列の関係性を訓練し、交通条件や施設位置などの地理的な情報との関係性は訓練しないため、交通施策のための交通需要予測に用いることができない。例えば、C 地点にあった病院を D 地点に移設した際に渋滞発生位置を予測したくとも、現在の地理的状况における A,B,C,D の関係性しかとらえることができず、地理上の変化に対する交通需要の予測ができない。また、ユーザの滞在位置の系列のみを入力としているため、次にユーザが向かう目的地は予測できるが、その目的地にどのようなルートを通して移動するかまでは予測できない。そのため、道路や鉄道の利用量といった交通施策において重要な量を予測することができない。

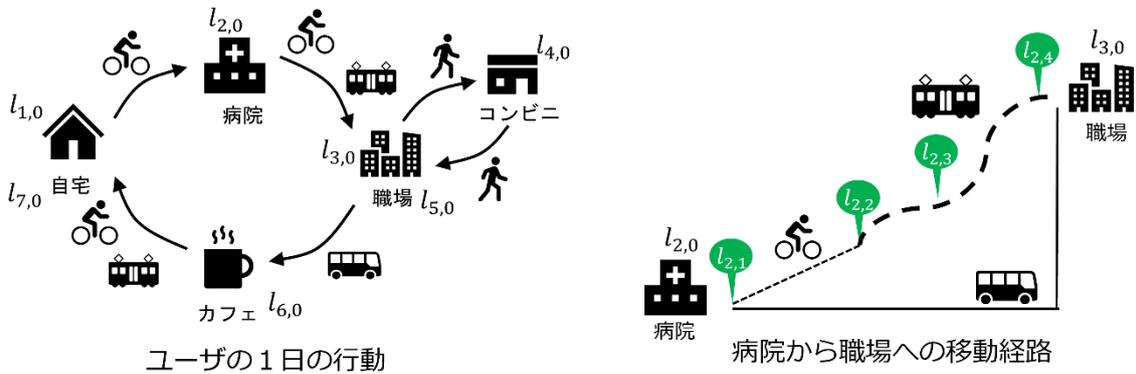
3. BERT を用いた移動軌跡の埋め込み表現

(1) 経路のエンコード

本研究では、BERT を交通需要の予測に活用するため、滞在位置の系列だけでなく、滞在地と滞在地をつなぐ経路に含まれる詳細な位置の系列をエンコードする。図 2 にその詳細を示す。オリジナルの BERT は訓練データから段落など一続きの文章を抽出し、一部の単語をマスクした上で推定する MLM タスクを事前学習で実施している。Lin らは、1 日のユーザの位置情報ログを一続きの系列と捉え、ユーザの滞在位置を抽出し位置をメッシュ等の離散表現 (図 2 中 $l_{1,0}, l_{2,0}, l_{3,0}, \dots$) に変換した上で、穴埋めタスクを実施している⁴⁾。しかし、例えば $l_{2,0}$ から $l_{3,0}$ に向かう交通機関として電車とバスのどちらを利用したかといった情報は全て失われる。それに対し提案手法は、ユーザの滞在と滞在の間で定義される移動行動 (以降 Trip と呼ぶ) を一続きの系列と定義し、その位置情報の系列に対して穴埋めタスクを実施している。以上の手続きにより、ユーザの移動手段や選択した経路も含めて訓練することが可能となる。

(2) 付加特徴のエンコード

本研究では、交通需要予測や交通手段推定など様々なタスクで応用可能な汎用的な位置表現を獲得することを目指し、位置の系列だけでなく、ユーザ属性や時刻、Trip の特徴といったユーザの交通行動の予測に有効な付



ユーザの1日の行動

病院から職場への移動経路

	X (問題)	y (正解)
[Original BERT]	The capital of France is [MASK]	BERT → Paris
[Lin 2021]	$l_{1,0}$ $l_{2,0}$ [MASK] $l_{4,0}$ $l_{5,0}$ $l_{6,0}$ $l_{7,0}$	BERT → $l_{3,0}$
[提案手法]	$l_{2,0}$ $l_{2,1}$ $l_{2,2}$ [MASK] $l_{2,4}$ $l_{3,0}$	BERT → $l_{2,3}$

図-2 提案する事前学習手法

加特徴を合わせてエンコードする。例えばユーザの移動速度などは経路や次の行動を予測する上で大きな情報であり、付加情報として有用性が高いと考えられる。

ただし、BERT は離散的な単語列しか取り扱うことができず、付加情報も離散表現する必要がある。例えば、[MESH1, MESH2, MESH3, ...] という移動経度を、[HIGH, HIGH, LOW, ...] という速度で移動した Trip が観測された場合、[MESH1_HIGH, MESH2_HIGH, MESH3_LOW, ...] のように、位置と速度で一つの意味を持つ離散表現に加工すれば、付加情報を BERT で取り扱うことが可能になる。しかし、付加情報を加えれば加えるほど、単語空間の次元数は指数的に増加し、訓練データ中に「同じ単語」が登場する頻度が極端に減少するため、位置表現の獲得が困難となる。

本研究では、単語空間の次元数を削減し、付加情報の意味を獲得しやすくするため、BERT でも用いられている Subword を用いて付加情報を表現する。BERT では WordPiece アルゴリズム⁷⁾を用いて、単語の活用形などを Subword に分割する。例えば、「doing」を「do」,

「##ing」(##は Subword を表す記号)のように1つの単語を複数の単語に分割することで、「do」と「##ing」それぞれの意味を捉えやすくするとともに、計算コストを削減できる。

図 3 は本研究で実施したエンコード手続を示す。行動予測や移動手段推定への寄与を考慮し、エンコードする付加情報は T : 時間特徴量, B : 行動特徴量, P : 個人特徴量の3つを選択した。T は、Trip 開始時刻を示す1つの Subword である。平/休日および日中 (6~19 時台) / 夜間 (20~翌5 時台) を $2 \times 2 = 4$ 種のカテゴリ値で表現した。

B はトリップに含まれる 3 種の行動特徴を示す。1つ目は、各 Trip における該当メッシュのユーザ滞在時間である。この特徴は、(-15/15-60/60)[分]の3種のカテゴリ値で表現した。2つ目の特徴は、当該メッシュ中におけるユーザの平均移動速度を示し、(-5/5-20/20)[km/h]の3種のカテゴリ値で表現した。3つ目は移動方向を示し、当該メッシュの IN-OUT を結んだ直線の向きを以下の5種のカテゴリ値(東/西/南/北/メッシュ内)で表現した。以上の通り B は、 $3 \times 3 \times 5 = 45$ 種のカテゴリ値からなる1つの Subword である。

P はユーザの自宅位置と職場位置をメッシュで表現しており、それぞれ1つの Subword で表現した。自宅と判定されたメッシュ ID 数を n 個、職場と判定されたメッシュ ID 数を m 個とすると、P は n 種のカテゴリ値からなる Subword と、 m 種のカテゴリ値からなる Subword の、合計2つの Subword で構成される。



図-3 付加特徴のエンコード手続き

4. 対象都市における実験

(1) データセット

本研究では、携帯電話の GPS データのうち、KDDI 株式会社が au スマートフォン利用者より同意を得て取得する GPS データ（以下、「スマートフォン位置情報データ」という。）を使用して検証を行った。スマートフォン位置情報は測位間隔に粗密があるが、集計した結果は各種人口統計と相関する⁸⁾だけでなく、交通需要の絶対数も精度良く推計可能なデータである⁹⁾。

本研究では、2019年3月から7月において、宇都宮市に外接する矩形上で検出された、スマートフォン位置情報データを抽出し、手法¹⁰⁾に従って滞在判定と Trip 抽出を実施した。抽出した Trip 中で観測された測位点は 250m メッシュコードで離散化し、Trip 毎のメッシュ系列として保存した。スマートフォン位置情報は測位間隔に粗密があり測位間隔が一定ではない。測位間隔が一定の場合、同一メッシュが連続して登場する場合、移動中に該当メッシュで一定期間立ち寄ったことを示し、ユーザ行動をモデル化する上で重要な情報となるが、今回は、同一メッシュが重複して登場した場合に該当メッシュでの滞在を示すとは限らず、分析時にノイズになると考えたため、同一メッシュが連続して登場する場合は重複を削除した。また、同一メッシュ内に閉じた Trip もノイズとして削除した。

上記とは別に、滞在判定結果をユーザ毎に集計し、夜間に最も多く滞在した 250m メッシュを該当ユーザの自宅位置、平日日中に最も多く滞在したメッシュを職場位置とした。滞在回数が閾値に満たない場合は、自宅/職場は未検出とした。自宅と職場の両方が検出できたユーザの Trip を抽出し、表 1 に示す 3 つのデータセット train(2w) / train(5m) / test を構築した。それぞれのデータセットに対し、O : 付加情報無し、T : 時間特徴量、B : 行動特徴量、P : 個人特徴量をそれぞれ付加したデータセットを構築した。

(2) BERT 基本性能の評価実験

BERT の基本的な性能を評価するため、train(2w) および train(5m) を用いて MLM で事前学習を行い、test セットの一部をマスクして、その推定精度を評価した。BERT では文章間の関係性を獲得するため、MLM と NSP を併用して事前学習を実施している。ただし、NSP を適用せずとも位置の表現を獲得できたとの報告もあり⁴⁾、

表-1 データセット

	train(2w)	train(5m)	test
範囲	宇都宮市に外接する矩形(長方形)		
期間	2019/03/01 - 2019/03/14	2019/03/01 - 2019/07/25	2019/07/26 - 2019/07/31

BERT の基本的な性能に絞って評価することを優先し、本研究においては事前学習を全て MLM のみで実施した。

モデルサイズは、報告³⁾の BERT_{BASE} (レイヤ数: 12, 隠れ層: 768 次元, 自己注目ヘッド数: 12) を用い、ライブラリは Hugging Face transformers¹¹⁾ を用いた。単語辞書は訓練データ毎に構築した。訓練時は、1 Trip を 1 つの系列として扱い、1 系列におけるマスクする単語の割合や、全系列における負例の割合などは全て報告³⁾と同じ設定で訓練した。

評価時は、test セット中の各 Trip に対してメッシュを 1 つマスクした課題を生成し、事前学習したモデルを用いて 1 Trip ずつマスク部を推定した。得られた各メッシュの尤度から以下の式で Top N Accuracy を算出した。

$$\text{Top N Acc} = \frac{\text{上位 N 位以内に正解を推定できた Trip 数}}{\text{全 Trip 数}}$$

本研究ではモデルの基本性能を評価するため、図 4 に示す、以下 2 つの簡易な MLM タスクの推定手法と性能を比較した。Baseline1 は前後の位置関係を用いた。もし移動軌跡が連続的に得られているのであれば、訓練データを用いずとも、マスク前後の位置関係からマスクされたメッシュを十分な精度で推定できる。具体的には、直前直後のメッシュの midpoint を算出し、その midpoint から距離が近いメッシュ上位 N 件を、推定結果とした。Trip の始点 (Origin) または終点 (Destination) がマスクされた課題に対しては、始点の次のメッシュあるいは終点の直前のメッシュからの距離が近い順に上位 N 件を抽出した。

Baseline2 は、tri-gram の頻度を用いた。train セットと test セットの間でユーザの行動や観測される測位点の傾向に大きな差が無いのであれば、訓練データ中に連続して登場する 3 メッシュの頻度を用いることで、直前直後のメッシュから容易に間のメッシュを推定できる。具体的には、訓練データ中の 3 連続するメッシュ (tri-gram) の登場頻度が高い順に上位 N 件を推定結果とした。Trip の始点

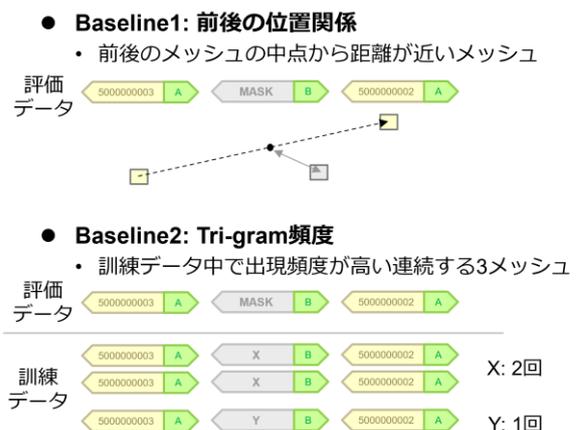


図4 MLM 推定における比較対象

(Origin)または終点(Destination) がマスクされた課題に対しては、開始記号あるいは終端記号をメッシュと数えて tri-gram を抽出した。

(3) 付加情報の効果計測実験

提案した付加情報のエンコード手法の有効性を評価するため、Oに加えて付加情報を Subword として追加したデータセット T/B/Pを用いて事前学習を実施し、test セットで MLM の Top N Accuracy を評価した。ここで評価用課題を生成する際、付加情報無しの結果と比較するため、付加情報を含む Subword 部はマスク対象には取らずに、メッシュのみを課題とした。

5. BERT による分析結果

(1) BERT 基本性能の評価結果

図 5 は BERT の基本性能の評価結果を示す。BERT は 2week に対し 5month の結果が向上しており、長期間観測による精度向上が期待できる。また、全ての Baseline に対して上回る精度が出ている。移動経路中のマスクしたメッシュは、前後の位置関係や単純な出現頻度だけで予測することは難しく、経路全体を考慮する BERT はユーザの移動行動を高精度にモデル化していると言える。

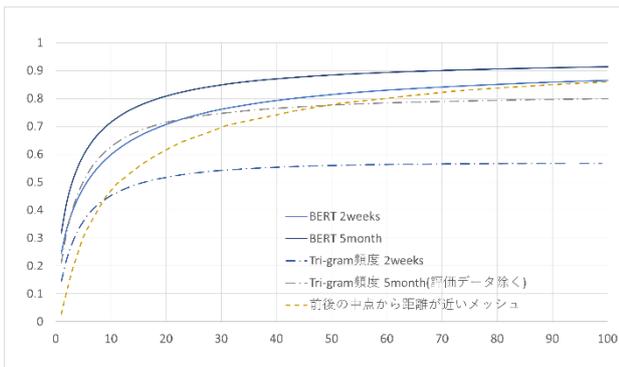


図-5 BERT 基本性能の評価結果

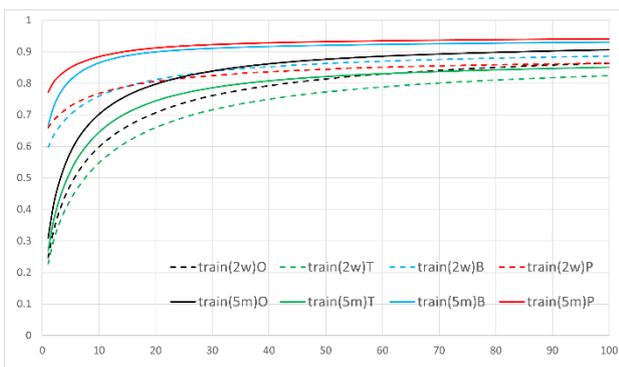


図-6 付加情報の効果

(2) 付加情報の効果計測結果

図 6 は BERT の(2) 付加情報の効果計測結果を示す。特徴量の効果を確認したところ、P および B は O より高い精度を示し、特に P は Top10 で約 90% の精度に到達した。ただし、P と B を組み合わせた場合でも P を大きく超える性能は観測されなかった。一方で、T は O を下回る精度となった。これらの傾向は 2week, 5month で一貫している。以上のことから、行動特徴、個人特徴は提案手法により効果的にモデル化されていると考えられる。

一方で時刻は、文献⁴⁾が主張するように、毎日 X 時には XX にいるといった長周期的な情報と、直前に X 時間 XX に滞在したので次は YY といった行動を取るといった短周期的な情報を併せ持つため、複数の周期性を加味したエンコードを行う必要がある可能性がある。

6. 考察

(1) BERT が得意とする課題

BERT の特徴を捉えるため、評価用の Trip をマスク位置と Trip 系列長の観点から分類し、それぞれ Top 100 Accuracy の精度を算出し Baseline と比較した。マスク位置は、始点/中間/終点の 3 種、Trip 系列長は平均の系列長に対する大小で分類し、BERT および Baseline2 に関しては train(5m) で訓練した結果を用いた。

表 2 は、その集計結果を示す。Baseline と比較すると BERT は、MASK 位置が中央でかつ、系列長が長い Trip で高精度となっている。BERT は Baseline 手法と異なり Trip 全体の情報を用いてマスクを推定している。以上の結果は、提案手法が Trip 全体の特徴を捉えてユーザの移動行動をモデル化できたことを示す。一方で、系列長が短い Trip の端点を推定する場合のみ、Tri-gram 頻度の方が BERT より高精度である。これは系列全体をモデル化したことが、系列長が短い Trip の端点を推定する場合にノイズとなった可能性がある。ただし精度差を鑑みるにその悪影響は小さいと考えられる。

(2) エンコードされた位置の意味

BERT がその Trip の意味を捉えたエンコードを実現で

表-2 BERT が得意とする課題

評価用 Trip の特徴		Trip 数	Top 100 Accuracy		
MASK 位置	Trip 系列長		BERT	位置関係	Tri-gram 頻度
中央	大	46,445	93.5%	88.8%	67.4%
	小	36,530	92.6%	86.2%	66.5%
Trip 始点 (Origin)	大	5,145	90.2%	83.2%	86.9%
	小	51,584	90.1%	86.0%	90.7%
Trip 終点 (Destination)	大	5,184	88.3%	78.7%	85.0%
	小	52,226	87.8%	84.3%	88.6%

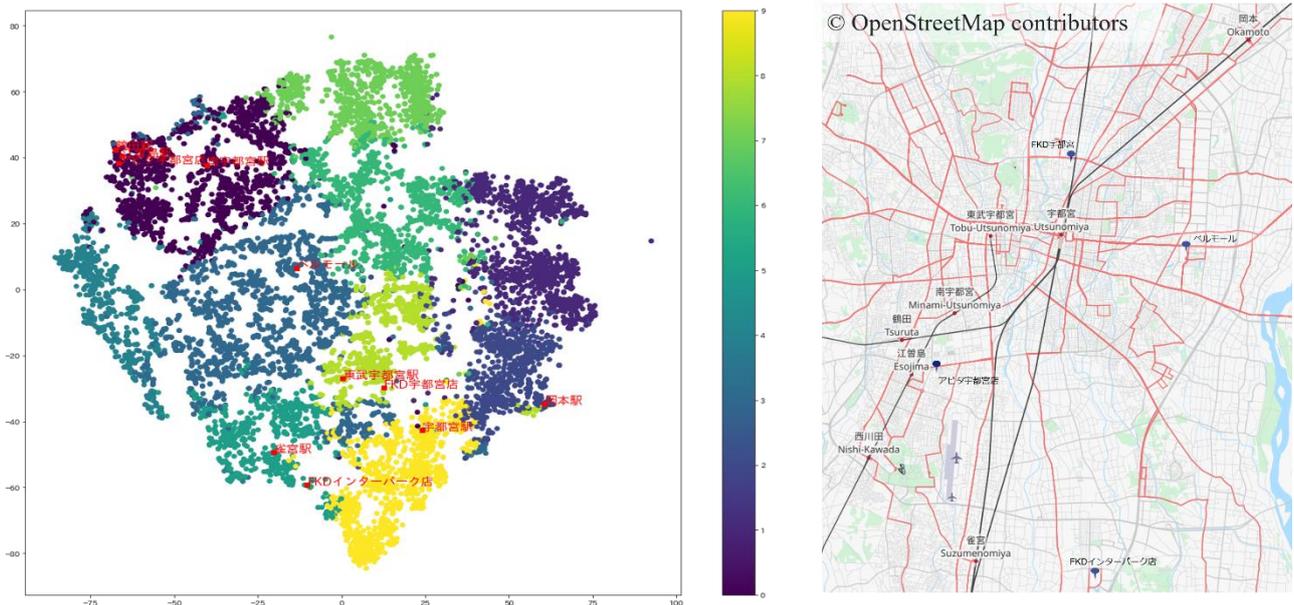


図-7 位置エンコード結果の可視化

きているか確認するため、各 Trip の位置エンコード結果を可視化した。train(2w)で訓練したモデルでtestセットをエンコードし、Trip 中の各メッシュのエンコード結果を算出した。BERT は Trip 毎にメッシュのエンコード結果が異なるため、Trip 間で集計した重心を各メッシュのエンコード結果とした。ここで test セットにおいて出現頻度が 5 回未満のメッシュはノイズとして除去した。各メッシュは 768 次元のベクトルで表現されており、k-means 法¹²⁾で 10 個のクラスタに分類した。また、t-SNE 法¹³⁾を用いて 2 次元に圧縮し図 7 (左) にプロットした。プロットした点の色は各メッシュが所属するクラスタを示す。

また図 7 (右) に示す宇都宮市で昼間人口が多いと考えられる駅や商業施設などの大規模な施設を選び、該当する施設を含むメッシュを図中に赤字で表示した。図 7 における各施設の分布を確認したところ、(鶴田駅—江曾島駅—アピタ宇都宮—南宇都宮駅) や、(雀宮駅—FKD インターパーク店) のように生活圏を同じくするメッシュが同じクラスタに分類された。一方で、同じ市中心部の駅である東武宇都宮駅と JR 宇都宮駅を別クラスタに分類されている。ただし東武宇都宮駅は、市中心部の商店街に位置し中心市街地に唯一残った百貨店が併設されており、同一クラスタに分類された FKD 宇都宮店と同じくショッピングセンターとしての機能を持つ。以上の結果は、提案手法を用いてエンコードしたベクトルが単なる地理的な距離だけでなく意味的な近さを持つ可能性を示唆する。

7. おわりに

本論文では、テキスト解析で用いられている表現学習

技術 BERT を用いて、スマートフォン位置情報からデータドリブンに移動の意味を獲得する技術を提案した。

Baseline 手法と比較した結果、提案手法は高いマスク推定精度を持ち、また長期間の観測により精度が向上することも確認できた。また、評価用 Trip を詳細に分類した結果、提案手法が Trip 全体の特徴を捉えてユーザの移動行動をモデル化した効果が観測できた。また、Subword を用いて付加情報を合わせてモデル化することを提案し、特に行動特徴や個人特徴を付加することでモデル精度が向上することを確認した。一方で、時間特徴の取り扱いに関しては課題が残った。最後にエンコードした Trip を可視化して解釈することで、提案手法がメッシュ間の位置関係や、人口動態などの情報を含む形で、都市における人間の移動をモデル化していることを示した。

本研究では、BERT の事前学習のうち MLM のみを用いて訓練しているが、将来的には NSP も同時に用いて訓練することで Trip 間の関係性もモデル化したうえで、次の Trip を予測する性能や、交通需要予測性能についても検証していく予定である。特に、スマートフォン位置情報は測位間隔に粗密を持つスパースなデータであるため、単純なメッシュ単位の予測に対し、提案手法は精度面でアドバンテージが期待できる。今後は、精度面を含め BERT を ABM に適用する際の有用性を定量的に評価する予定である。

参考文献

- 1) 東京都市圏交通計画協議会、「新たなライフスタイルを実現する人中心のモビリティネットワークと生活圏—転換点を迎えた東京都市圏の都市交通戦略—」, 2021 年 (令和 3 年 3 月)

- 2) 国土交通省都市局 都市計画課都市計画調査室, 「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 年 (平成30年6月)
- 3) Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K. 2019. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL-HLT 2019, Minneapolis, MN, USA, June 2-7, 2019, Volume 1 (Long and Short Papers) (2019), 4171–4186.
- 4) Lin, Y., Wan, H., Guo, S. and Lin, Y. 2021. Pre-training Context and Time Aware Location Embeddings from Spatial-Temporal Trajectories for User Next Location Prediction.
- 5) Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. In Advances in neural information processing systems (pp. 3111-3119).
- 6) Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł. ukasz and Polosukhin, I. 2017. Attention is All you Need. Advances in Neural Information Processing Systems (2017).
- 7) 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.
- 8) 桑原昌広, 吉岡顕, 南川敦宣, 松本浩和, 早田敏也: 「ワンウェイカーシェアリング需要推計手法検討とスマートフォン位置情報利用の妥当性検討」, 土木計画学研究・講演集 Vol.58, No.82, 2018
- 9) 吉羽崇, 小林亮博, 中管章浩, 南川敦宣, 富岡秀虎, 森本章倫. (2021). 「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 (土木計画学), 76(5)
- 10) 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.
- 11) <https://huggingface.co/transformers/>
- 12) Hartigan, John A., and Manchek A. Wong. "Algorithm AS 136: A k-means clustering algorithm." Journal of the royal statistical society. series c (applied statistics) 28.1 (1979): 100-108.
- 13) Van der Maaten, Laurens, and Geoffrey Hinton. "Visualizing data using t-SNE." Journal of machine learning research 9.11 (2008).

(XXXX.X.X 受付)

Representation Learning for Traffic Demand Forecasting Using Location-Based Big Data

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

There are few examples of applying ABM (Activity Based Model) to big data, although ABM is becoming more practical. In ABM, which takes the position that mobility is a demand derived from an individual's activity, information such as the purpose of mobility is especially important. On the other hand, in the field of text analysis, the technology of representation learning has been developed to acquire vector values representing the meaning of sentences from a large amount of text by deep learning. In this study, we propose a data-driven method for acquiring embedded representations of motion trajectories by applying BERT, a representation learning technique for text, to the motion trajectories of smartphones. We validate the embedded representations obtained from actual smartphone location data and evaluate their applicability to demand forecasting.