

観光の形態の特徴を用いた将来の訪問国の予測

柴田有基¹ 石野亜耶² 難波英嗣³ 竹澤寿幸¹

概要: 本研究では、機械学習を用い、旅行者の過去の訪問国から将来の訪問国を予測する手法を提案する。将来の訪問国を正確に予測するためには、過去の訪問国の文化や位置情報などの基本的な情報のほかに、それぞれの国の観光の特徴を考慮する必要がある。そこで、本研究では、深層学習手法の LSTM を用い、Wikipedia から獲得した国の情報に加え、観光の特徴として、手がかり語を用いた観光の形態という観点からのソーシャルメディアの解析結果を考慮することで、より正確な将来の訪問国の予測を試みる。評価実験の結果、提案手法の LSTM でベースライン手法より高い、Accuracy@1 で 26.06%、MRR で 0.403 が得られた。

キーワード: LSTM, 手がかり語, 観光の形態, 旅行ブログエントリ

Predicting the Next Country Considering Features of Tourism Types

NAOKI SHIBATA^{†1} AYA ISHINO^{†2}
HIDETSUGU NANBA^{†3} TOSHIYUKI TAKEZAWA^{†1}

Abstract: We propose a method for predicting the traveler's next country by using machine learning. To predict the next country accurately, it needs to consider the country information and features of tourism. Therefore, we propose a method considered country information using Wikipedia, and tourism types using clue words. In this paper, we conducted an experiment using LSTM with Wikipedia and tourism types of input data, and obtained the results, which is better than baseline methods, of Accuracy@1 and MRR scores of 26.06% and 0.403, respectively.

Keywords: LSTM, clue words, tourism types, travel blog entry

1. はじめに

現在、COVID-19 の影響により、海外旅行をはじめとする観光行動が縮小している。しかし、日本交通公社の海外旅行意向調査では、10~20 代の約半数の女性が、COVID-19 の収束後、海外旅行に行きたいと回答している[1]。そのため、今後、海外旅行者数が少しずつ回復していくことが期待され、こういった海外旅行を考えている旅行者へのマーケティング活動は非常に重要になると考えられる。

観光データの解析を行うためには、まず、旅行者のデータを収集する必要がある。その方法として、アンケートや観光ソーシャルメディアから収集する方法が挙げられる。アンケートでは、調べたい内容についての設問を用意することで、欲しいデータを確実に手に入れることができるメリットがあるが、大量のデータを集めるためには大きなコストがかかる。また、COVID-19 の影響により、対面式のアンケートが難しくなっている。このような現状から、本研究では、観光ソーシャルメディアからデータの収集を行い、そのデータを用いて解析を行う。

観光ソーシャルメディアの解析に関する研究として、観光スポットや観光ルートを推薦する研究は既に行われている

[2-6]。しかし、多くの研究は、ある都市やある地域などの比較的小さな範囲を対象としているため、世界中の国が対象となる海外旅行者への対応は不十分である。そこで、本研究では、世界中の国を対象とした観光ソーシャルメディアの解析を通し、旅行者の過去の訪問国履歴から将来の訪問国を予測する。これにより、世界中を対象とした観光地推薦が可能になる。

旅行者の将来の訪問国の予測を行う際には、各国の位置情報や文化などの基本的な情報に加えて、旅行者の多様な観光の特徴を考慮する必要がある。例えば、身心の健康の促進を目的としたヘルスツーリズムやスポーツの観戦や体験を目的としたスポーツツーリズムなど、旅行者の観光の形態は多様化している。そのため、このような観光の形態を考慮することで、より正確な将来の訪問国の予測が可能になると考えられる。そこで、本研究では、各国の基本的な情報に加えて、このような観光の形態を考慮し、旅行者の将来の訪問国を予測する。

2. 関連研究

2.1 将来の訪問地の予測

Su ら[2]は、ユーザの訪問履歴に加えて、フレンド関係や

¹ 広島市立大学
Hiroshima City University

² 広島経済大学
Hiroshima University of Economics

³ 中央大学
Chuo University

家が近いユーザの訪問履歴を考慮した予測手法を提案している。また、Baragliaら[3]は、ユーザの特徴とPoI(Point of Interest)の特徴を考慮した機械学習手法のRanking SVM(Support Vector Machine)によって将来訪れるPoIを予測する手法を提案している。これらの研究に対して、本研究では、深層学習手法を用いる点で異なる。

深層学習を用いた研究では、Liuら[4]は位置情報と時間情報を考慮したRNN(Recurrent Neural Network)による将来の訪問地の予測手法を提案している。また、Kongら[5]は、観光客の訪問地の周期性を考慮したLSTM(Long Short-Term Memory)[6]による予測手法を提案している。本研究では、深層学習手法のLSTMを用いている点で類似しているが、これらの研究では、ある国や地域内のデータを対象としており、本研究は世界中の国を対象としているため異なる。

国の推薦に関する研究では、Majoddiら[7]は、移民のための移住国推薦システムを提案している。また、Johnsonら[8]は、旅行者向けに国ごとの腸チフス感染症の危険性を考慮した、予防接種の推薦システムを提案している。これらの研究は世界中の国を対象としている点では類似しているものの、本研究では、観光地の観光情報を研究対象としている点で異なる。

2.2 観光の形態に関する取り組み

温泉やハイキングなど、健康維持を目的とした観光の形態であるヘルスツーリズムについての取り組みとして、河行ら[9]は、島根県大田市の自然や特産物を利用した健康促進を促すヘルスツーリズムを推進している。また、ダムや橋など、近代的な建造物を対象とした観光の形態であるインフラツーリズムについての取り組みとして、藤井ら[10]は、観光ガイドブックを通して日本のインフラツーリズムを紹介している。このような取り組みは、観光行動を通じた健康促進による医療費の削減やこれまで観光地として注目されていなかった地域での雇用の創出などの利点があり、近年、注目されている。

ソーシャルメディアの解析に関する研究について、柴田ら[11]は、世界最大級の旅行ブログサイトであるTravelBlog

(<https://www.travelblog.org/>)から大量の旅行ブログエントリを収集し、深層学習ベースの手法を用いてそれぞれの観光の形態に分類している。分類の結果から、観光の形態による世界中の観光情報の検索が可能となったほか、検索を通じた地域の魅力発見を可能にしている。本研究では、観光の形態という観点から得られるそれぞれの国の特徴を考慮することで、より正確な旅行者の将来の訪問国予測を目指す。

3. Wikipediaと観光の形態の特徴を考慮した将来の訪問国の予測

3.1 Wikipediaを用いた各国の基本的な情報の獲得

旅行者が訪問国を決定する際には、各国の位置情報や文化などの基本的な情報を考慮することが考えられる。そこで、本研究では、このような各国の基本的な情報を獲得するため、世界の国の様々な情報が掲載されているWikipediaに注目し、Wikipediaの情報を収集する方法として、Web上に公開され、かつ手軽に利用することができるWikipedia2Vec[12]の事前学習モデルを用いる。Wikipedia2Vecとは、Wikipediaのデータを用いて、単語の分散表現とエンティティの分散表現を同一空間で学習・表現する手法である。本研究では、このWikipedia2Vecの事前学習モデルから、それぞれの国名に該当するエンティティの分散表現を獲得し、これを予測の際に考慮する。

しかし、各国の基本的な情報を考慮する場合、アメリカにはハワイ州やアラスカ州、グアム島などが含まれるように、地理的に離れている地域が存在する。また、このような国では、位置情報に加え、文化や公用語も異なる場合がある。この場合、各国の基本的な情報を考慮することが難しくなるが、本研究ではこの問題に対し、離れている地域を分割することで対応する。

3.2 観光の形態を用いた各国の観光の特徴の獲得

近年の観光では、旅行者は多様な目的を持っていることが多いため、その訪問先で体験できる観光の特徴は、訪問

表 1: 観光の形態の定義と具体例

観光の形態	定義	例
インフラ、ハードツーリズム[10]	近代的な建造物や娯楽施設を対象にした観光。	橋、ダム、テーマパーク、ショッピングモール、水族館、博物館、動物園
ヘルスツーリズム[9]	心身を癒すことや散歩などの軽い運動を通して健康維持を目的とした観光。	宗教的巡礼、温泉、ハイキング、トレッキング
スポーツツーリズム[13]	スポーツを体験または観戦することを目的とした観光。	MLB、プロ野球、サッカー
グリーンツーリズム[14]	自然と触れ合うことを目的とした観光。	農業(漁業)体験、フルーツ狩り、ピクニック
ヘリテージツーリズム[14]	世界遺産や歴史的な建築物を対象にした観光。	世界遺産、国宝、寺、神社、城
カルチュラルツーリズム[15]	それぞれの地域の生活や文化、民族、伝統などを対象にした観光。	着物体験、神楽、祭り、初詣

国の決定の際の重要な判断材料になると考えられる。そこで、本研究では、観光の特徴の一つとして、先行研究の柴田らが参考文献[9-10, 13-15]を参考に定義した、表1中の6つの観光の形態を考慮し、より正確な予測を試みる。これより、3.2.1節では、Random Forestを用いた手がかり語の獲得について、3.2.2節では、観光の形態の特徴量の獲得について述べる。

3.2.1 Random Forest を用いた手がかり語の収集

柴田らの研究では、機械学習手法を用いて、収集した旅行ブログエントリをそれぞれの観光の形態に分類することで解析を行っている。分類実験に用いられたデータセットの内訳を表2に示す。このデータセットは、英語で書かれた旅行ブログエントリを対象に、英語の読み書きに不自由がない大学生と著者らで、1,909件の旅行ブログエントリを分類したものである。各観光の形態の旅行ブログエントリの件数の合計が、分類した旅行ブログエントリの総数より小さくなっているのは、一つの旅行ブログエントリに対して複数の観光の形態が付与されることや一つも付与されない旅行ブログエントリが含まれるためである。本研究では、このデータセットを用い、旅行ブログエントリの解析を行う。

表2: 人手で分類した分類結果の内訳

観光の形態	件数
インフラ, ハードツーリズム	156
ヘルスツーリズム	116
スポーツツーリズム	54
グリーンツーリズム	421
ヘリテージツーリズム	177
カルチュラルツーリズム	40
分類した旅行ブログエントリの総数	1,909

旅行ブログエントリを用いて、各国の観光の形態の特徴を獲得する方法の一つに、国ごとに集めた旅行ブログエントリを観光の形態に分類し、その結果からそれぞれの国の観光の形態の割合を求めることで、例えば、「世界遺産が有名なエジプトでは、ヘリテージツーリズムの割合が大きい」などの特徴量が得られると考えられる。しかし、小さな国や発展途上国では、投稿されている旅行ブログエントリの数が少ない場合があり、十分な特徴量を獲得することが難しくなる。そこで、本研究では、表2の観光の形態データセットに含まれる旅行ブログエントリのテキストデータから、観光の形態に関連する手がかり語を獲得し、この手がかり語を用いた国ごとの特徴量の獲得を行う。

手がかり語の獲得には、機械学習のRandom Forestを用いる。Random Forestでは、学習を通して、入力データの各要素の重要度を獲得することができる。本研究では、表2のデータセット中の各旅行ブログエントリのテキストを入力データとしたRandom Forestで分類学習を行い、各観光

の形態の重要度が高い単語を手がかり語として獲得する。Random Forestで獲得した手がかり語の例を表3に示す。学習を行う際のテキストデータは、前処理としてRNNTagger[16]による品詞タグ付けを行い、名詞のみに絞った。また、Random Forestの実装には、プログラミング言語のPython3および機械学習ライブラリであるscikit-learnのRandom Forest Classifierを用いている。表3のインフラ、ハードツーリズムでは、博物館を表す“museum”やショッピングモールを表す“mall”が含まれていることがわかる。また、そのほかの観光の形態でも、ある程度観光の形態を表す単語を獲得できていることがわかる。本研究では、この手がかり語を利用し、観光の形態の特徴量を獲得する。

3.2.2 観光の形態の特徴量の獲得

手がかり語を用いて特徴量を作成するため、本研究では、TravelBlogから各国5,500件以上の旅行ブログエントリを収集した。なお、小さな国などでは、投稿されている旅行ブログエントリの数が5,500件に満たない国もあるが、こういった国については、公開されている旅行ブログエントリのみ収集を行った。収集する旅行ブログエントリを5,500件とした理由については、十分に特徴量を獲得するため、表2のデータセットで分類対象となった1,909件の2倍より多い5,000件を目安にし、英語で書かれた旅行ブログエントリのみを対象とするため、5,000件より少し多い5,500件とした。

表3: Random Forestを用いて獲得した手がかり語の例

観光の形態	手がかり語の例
インフラ, ハードツーリズム	museum, mall, show, city, exhibit, picture, building, tower, shop
ヘルスツーリズム	hike, mountain, trail, hiker, hiking, river, rock, waterfall, valley, climb
スポーツツーリズム	game, stadium, ski, baseball, rafting, match, kayak, mountain, river
グリーンツーリズム	river, mountain, rock, park, boat, view, valley, waterfall, island
ヘリテージツーリズム	temple, site, century, emperor, statue, wall, palace, tomb, ruin, hotel
カルチュラルツーリズム	tribe, pilgrim, festival, omikoshi, brickwork, riverboat, carnival, halva

手がかり語による特徴量の作成方法については、各国の内容について投稿された旅行ブログエントリから各手がかり語が出現する割合を用いる。例えば、日本について投稿された旅行ブログエントリを100件収集し、100件中30件に“temple”が含まれる場合、日本の“temple”についての特徴量は0.3となる。このように、それぞれの手がかり語で割合を求め、その国の特徴量とし、Wikipedia2Vecから獲得した分散表現に加えて予測の際に考慮する。

4. 評価実験

4.1 実験設定

【実験に用いるデータ】

訪問履歴データの収集には、TravelBlog の 37,371 個のアカウントを対象とし、それぞれの訪問国履歴データを収集することでデータセットを構築した。なお、旅行日の判定には、旅行ブログエントリ内に記述されているブログ著者が設定した日付を用いた。また、TravelBlog では、ブログエントリを投稿する際にあらかじめ訪問国を設定する場合があります、設定した場合、その内容は URL に反映される。本実験では、この URL 内に含まれる国名を訪問国とする。

TravelBlog では、「旅行 1 日目」、「旅行 2 日目」のように、短期間で同一国についての投稿が複数存在するブログ著者が多く見られた。そのため、60 日以内に連続して同じ訪問国履歴データが存在する場合、これらの投稿をまとめる処理を行った。また、過去の訪問国履歴から将来の訪問国を予測するためには、各アカウントの訪問国の数がある程度必要となる。そのため、訪問国が 6 か国以上の訪問国履歴が存在するアカウントのみとした。これらの前処理後のデータセットの内訳を表 4 に示す。アカウント数は 9,604 個となり、訓練・検証・評価データを 8:1:1 に分割した。また、アカウントごとの訪問国数の平均は 14.1 となった。

表 4: 実験に用いるデータセットの詳細

訓練データのアカウント数	7,684	9,604
検証データのアカウント数	960	
評価データのアカウント数	960	
アカウントごとの訪問国数の平均	14.1	

【実験条件】

プログラミング言語には Python3 を用い、各実験手法の実装を行う。また、提案手法とベースライン手法の LSTM には、オープンソースの深層学習ライブラリである Keras を用いる。LSTM のパラメータについては、最適化アルゴリズムを Adam、バッチサイズを 2,048、学習率を 0.001、LSTM 層を 1 層、出力ユニット数を入力ユニット数と同じ数とし、検証データによる実験から epoch 数を決定する。

Wikipedia2Vec の事前学習モデルには、Web 上に公開されている英語のモデルで最も軽量な 100 次元のモデル (http://wikipedia2vec.s3.amazonaws.com/models/en/2018-04-20/enwiki_20180420_nolq_100d.pkl.bz2) を用いる。これは、次元数の異なるいくつかのモデルで予備実験を行ったところ、実験結果への影響がほとんど確認できなかったためである。また、各国の観光の形態の特徴量を獲得するため、TravelBlog から収集した旅行ブログエントリに含まれるテキストデータを用いて、Random Forest で収集した観光の形態の手がかり語の重要度上位 10 単語が含まれる割合を国ごとに求めた。なお、使用する手がかり語を重要度の上位 10 単語とした理由は、手がかり語上位 10、20 単語のそれ

ぞれで予備実験を行ったところ、上位 10 単語の方が良い結果が得られたためである。また、テキストの前処理には、まず、fastText[17]の言語判定モデルを用い、英語と判定されたブログエントリのみを絞り、その後、RNNTagger を用いた品詞タグ付けを行うことで、名詞のみとした。

【評価尺度】

本実験では、表 4 のデータセットを用い、予測対象から直前の 5 か国を入力データとし、次の訪問国を予測することを繰り返すことで実験の訓練・検証・評価を行う。評価尺度には、Accuracy@k ($k = 1, 3, 5, 10$) および MRR (Mean Reciprocal Rank) を用いる。Accuracy@k とは、top-k accuracy と呼ばれるものを指し、予測の確率上位 k 件に正解が含まれる場合は 1、正解が含まれない場合は 0 として評価を行う。また、MRR については、予測結果から正解が n 番目にある場合、その逆数である $1/n$ を評価値とする。

【実験手法】

本実験では、下記の 1 種類の提案手法と 8 種類のベースライン手法で実験を行った。

ベースライン手法

- Random: 無作為に選んだ国を予測結果とする。
- n-gram ($n = 4$): 訓練データを用いて n-gram モデルを構築する。
- Distance: 最後に訪れた国から距離が近い国を予測結果とする。
- Most Popular: 訓練データで最も頻出した国を予測結果とする。
- StarSpace: Facebook が公開している汎用ニューラルモデルの StarSpace[18]を用い、協調フィルタリングの問題として、学習・予測を行う。
- Wikipedia2Vec: 履歴に含まれるそれぞれの訪問国を Wikipedia2Vec の事前学習モデルを用いて分散表現に変換し、これらの分散表現の平均と cos 類似度が高い国を予測結果とする。
- LSTM(Wiki): Wikipedia2Vec の事前学習モデルからそれぞれの国や地域のエンティティの分散表現を獲得し、これを入力データとした LSTM により予測を行う。

提案手法

- LSTM(Wiki+Type): LSTM(Wiki) に対して、観光の形態の手がかり語で得られた割合、55 次元を加えることで拡張したもの。

【LSTM(Wiki+Type) について】

Wikipedia2Vec の事前学習から獲得した分散表現および各国の旅行ブログエントリから観光の形態のそれぞれの手がかり語の割合を算出することで獲得した分散表現を入力データとし、これら二つの情報を考慮した予測を行う。LSTM(Wiki+Type) の詳細として、予測の例を図 1 に示す。この例では、10 か国目を予測する様子を表しており、直前の 5 か国目から 9 か国目を入力データとしている。入力デ

一タの処理の手順については、まず、入力データとなる国を Wikipedia2Vec の事前学習モデルおよび観光の形態の手がかり語の割合を用いて、それぞれ 100 次元と 55 次元の分散表現に変換し、これら二つの分散表現を結合することで得られる新たな 155 次元の分散表現を国の分散表現とする。そして、この分散表現を LSTM の入力とし、学習・予測を行う。本実験では、この図のように、過去の五つの訪問国を入力データとし、次の訪問国を予測することを繰り返す。

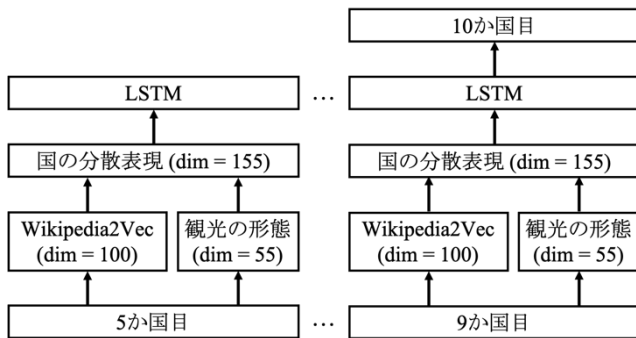


図 1: LSTM(Wiki+Type) の予測の例

4.2 実験結果と考察

評価実験の結果を表 5 に示す。これより、提案手法の LSTM(Wiki+Type) において、全ての評価指標で最も高い値が得られた。ここで、実際に、LSTM(Wiki) と統計的有意性を検証したところ、全ての評価指標で有意水準 5% において、有意性が確認された。このことから、旅行者の将来の訪問国を予測するにあたって、Wikipedia および観光の形態を考慮することが有効であると言える。また、LSTM とそのほかの手法では、LSTM の方が高い値が得られた。このことから、将来の訪問国の予測に LSTM が有効であると言える。

本実験では、過去の五つの訪問国履歴を用いて次の訪問国を予測したが、LSTM の入力データの時系列の長さは結果に影響を与える重要な要素であることが報告されている [19]。そこで、考慮する訪問国の数を 2~4 に変化させた場合でも同様に調査を行った。考慮する訪問国数の変化に伴う Accuracy@1 および MRR の変化を図 2 に示す。図中の直線は、黒色が提案手法の LSTM(Wiki+Type) を、灰色がベースライン手法の LSTM(Wiki) を表しており、横軸の α は考

慮する訪問国の数を、縦軸はその評価値の値である。図 2 より、考慮する訪問国の数を 2 から 5 へと増やしていくことで、それぞれの評価値が良くなっていることがわかる。これは、考慮する情報量が増えたことで、より正確な予測を可能にしていることが考えられる。また、2 か国を考慮した場合では、評価値の Accuracy@1 および MRR でほとんど差は確認できなかったものの、考慮する訪問国の数が 3 以上である場合、提案手法の LSTM(Wiki+Type) の方が良い値となっている。このことから、手がかり語による観光の形態を考慮することが予測に良い影響を与えていると考えられる。

表 6: Wikipedia2Vec と観光の形態の手がかり語のエジプトに対する cos 類似度の上位 5 か国

Wikipedia2Vec (100 次元)		観光の形態 (55 次元)	
国名	類似度	国名	類似度
リビア	0.874	カンボジア	0.968
チュニジア	0.870	インド	0.967
ヨルダン	0.863	インドネシア	0.963
シリア	0.860	ミャンマー	0.963
スーダン	0.837	ベトナム	0.962

ここで、実際に、観光の形態の手がかり語から獲得した分散表現がどのような特徴を獲得しているのかについて、コサイン類似度を用いて Wikipedia2Vec との比較を行う。まず、ピラミッドなどの世界遺産が有名なエジプトを例に、Wikipedia2Vec および観光の形態の手がかり語のそれぞれの分散表現におけるコサイン類似度の上位 5 か国とその類似度を表 6 に示す。Wikipedia2Vec の上位 5 か国に注目すると、中東や北アフリカなどのエジプトと比較的距離に近い国が並んでいる。この結果に対して観光の形態では、TravelBlog に世界遺産のアンコール・ワットに関する投稿が多く見られるカンボジアやタージ・マハルについての内容が多く投稿されているインドなど、ヘリテージツーリズムが有名であると思われる国が並んでいる。このように、観光の形態を考慮することで Wikipedia から獲得できなかった観光の特徴を捉えることが可能になったことで、より正確な予測が可能になったと考えられる。

表 5: 将来の訪問国予測の評価実験の結果

	手法	Acc@1	Acc@3	Acc@5	Acc@10	MRR
ベースライン手法	Random	0.44%	1.31%	2.15%	4.20%	0.026
	n-gram (n = 4)	3.75%	8.75%	12.71%	19.43%	-
	Distance	6.60%	25.78%	37.03%	50.05%	0.209
	Most Popular	7.85%	16.01%	22.24%	37.29%	0.170
	Wikipedia2Vec	12.36%	25.12%	33.83%	49.33%	0.236
	StarSpace	12.76%	25.90%	34.90%	49.72%	0.238
	LSTM(Wiki)	25.68%	46.00%	56.22%	70.24%	0.401
提案手法	LSTM(Wiki+Type)	26.06%	46.31%	56.61%	70.30%	0.403

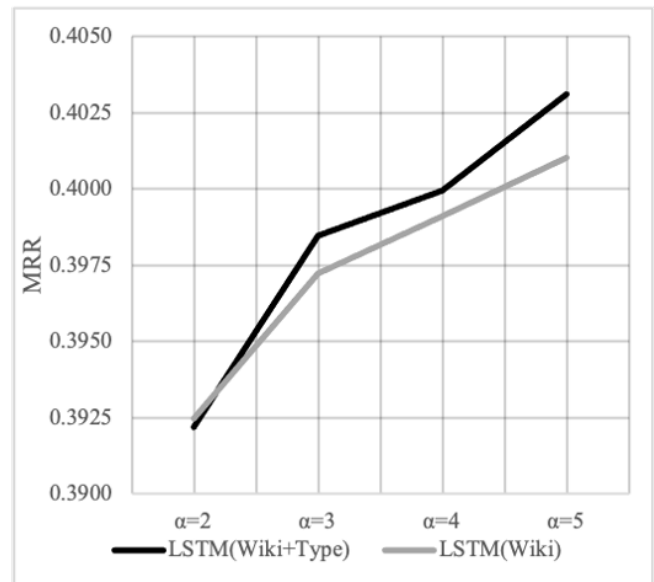



図2: 考慮する訪問国数の変化に伴う Accuracy@1 および MRR の変化

5. おわりに

本研究では、旅行ブログエントリから構築した旅行者の訪問履歴データを用い、各国の基本的な情報および観光の特徴を考慮した LSTM による将来の訪問国の予測手法を提案した。Wikipedia の情報の獲得は、Wikipedia2Vec の事前学習モデルを用いた。また、観光の形態の特徴については、Random Forest を用いて観光の形態データセット中の旅行ブログエントリのテキストデータから手がかり語を収集し、それぞれの手がかり語が国ごとに集めた旅行ブログエントリに出現する割合を調べ、これを予測に用いた。提案手法の有効性を検証するための評価実験では、評価指標の Accuracy@k (k = 1, 5, 10, 20) および MRR において、全ての評価指標で提案手法の有効性が確認された。

本研究では、各国の観光の特徴として、英語の旅行ブログエントリを観光の形態で解析を行った。今後の発展では、英語だけでなく、中国語や日本語など、そのほかの言語に拡張することで、より多角的な観光の特徴の獲得を試みることを検討している。

参考文献

[1] 公益財団法人日本交通公社, “新型コロナウイルス感染症流行下の日本人旅行者の動向 (その 4)”.
https://www.jtb.or.jp/wp-content/uploads/2020/08/covid-19-japanese-tourists-4_JTBF20200730.pdf, 2020.

[2] Su, Y. et al.. Next Check-in Location Prediction via Footprints and Friendship on Location-Based Social Networks. 19th International Conference on Mobile Data Management, MDM'18. 2018, p. 251-256.

[3] Baraglia, R. et al.. LearNext: learning to predict tourists movements. 22nd ACM international conference on Information & Knowledge Management, CIKM'13, 2013, p. 751-756.

[4] Liu, Q. et al.. Predicting the next location: A recurrent model with spatial and temporal context. 30th AAAI Conference on Artificial Intelligence, AAAI-16, 2016, p. 194-200.

[5] Kong, D. and Wu, F.. HST-LSTM: A Hierarchical Spatial-

Temporal Long-Short Term Memory Network for Location Prediction. 27th International Joint Conference on Artificial Intelligence, IJCAI-18, 2018, p. 2341-2347.

[6] Hochreiter, S. and Schmidhuber, J. LONG SHORT-TERM MEMORY. Neural computation, 1997, vol.9, No.8, p. 1735-1780.

[7] Majjodi, A. E. et al .. Towards Generating Personalized Country Recommendation. 28th ACM Conference on User Modeling, Adaptation and Personalization, ACM UMAP 2020, 2020, p. 71-76.

[8] Johnson, K. J. et al.. From the CDC: new country-specific recommendations for pre-travel typhoid vaccination. Travel Medicine, 2011, vol. 18, p. 430-433.

[9] 河行茜, 木下藤寿, 島根おだ健康ビューローの取り組み. 生涯スポーツ実践研究年報 : 鹿屋体育大学生涯スポーツ実践センター所報, 2019, vol. 17, p. 28-35.

[10] 藤井千賀子, 茂木直美, 林由利子, 柳沼しほ. インフラツーリズムガイド 2018. 芸文社. 2018.

[11] 柴田有基, 篠田広人, 難波英嗣, 石野亜耶, 竹澤寿幸. 観光の形態に基づいた旅行ブログエントリの自動分類と可視化. 観光と情報, 2020, vol. 16, no. 1, p. 49-61.

[12] Yamada, I. et al.. Wikipedia2Vec: An Efficient Toolkit for Learning and Visualizing the Embeddings of Words and Entities from Wikipedia. arXiv:1812.06280 [cs.CL], 2018.

[13] 高橋義雄, 原田宗彦, 岡星竜美, 工藤康宏, 二宮浩彰, 松岡宏高, 山下玲, 青木淑浩. スポーツツーリズム・ハンドブック. 学芸出版社, 2015.

[14] 山下晋司. 観光学キーワード. 有斐閣, 2011.

[15] 後藤和子. 観光と地域経済 -文化観光の経済分析を中心に-. 地域経済学研究, 2018, vol. 34, p. 41-47.

[16] Schmid, H. Deep Learning-Based Morphological Taggers and Lemmatizers for Annotating Historical Texts. 3rd International Conference on Digital Access to Textual Cultural Heritage, DATeCH 2019, 2019, p. 133-137.

[17] Joulin, A. et al.. Bag of Tricks for Efficient Text Classification. arXiv:1607.01759 [cs.CL], 2016.

[18] Wu, L. et al.. StarSpace: Embed All The Things!. arXiv:1709.03856 [cs.CL], 2017.

[19] Kim, S. J. et al.. State of Health Estimation of Li-Ion Batteries Using Multi-Input LSTM with Optimal Sequence Length. IEEE 29th International Symposium on Industrial Electronics (ISIE), 2020, p. 1336-1341.