

商業施設の回遊行動データによる移動先の予測

○大井一輝 岡夏樹 荒木雅弘 (京都工芸繊維大学)
荒川邦雄 (株式会社アドインテ)

Prediction of Customers' Future Locations Based on Moving Behavior Data in a Commercial Facility

*K. Oi and N. Oka and M. Araki (Kyoto Institute of Technology)
K. Arakawa (Adinte, Inc)

Abstract— In this study, we predict customers' future locations in a commercial facility by using moving behavior data obtained in the facility. We used Markov models for the prediction. The data was pre-processed to remove data from users who had no purpose in the facility and data that could be noise for prediction. For the data sparsity problem, we applied a smoothing technique to improve the accuracy. We also tried to improve the prediction accuracy by taking into account the day of the week and the time of day. The results show that the second-order Markov model is more accurate than the first-order Markov model. Besides, the smoothing process gave better results in some cases. When taking into account the day of the week and the time of day, the accuracy of the prediction was not improved much.

Key Words: Markov model, Destination prediction, moving behavior, datasmoothing

1 はじめに

近年、ICT技術の急速な発展や、身の回りのもののIT化により、多くの人々にとってスマートフォンなど電子機器の技術は、必要不可欠なものとなっている。また、それらの機器から、人々の位置情報などの情報を測位するための技術も発展しており、比較的容易に収集することができる。それらに伴い人々が得られる情報も大変多くなっている。このような大量の情報が得られる状態において、情報を発信する側は、人々にとって正確であり、より必要とされる情報を提供することが求められている。

正確な情報とは、誤りや虚偽が含まれていないものである。また、必要とされる情報とは、人々の現在の目的に関わるものであったり、人々の意思決定に関わるようなものである。そのような情報として、個人にパーソナライズした情報が挙げられる。そのような情報を提供する方法として、人々の位置情報や移動軌跡を用いるシステムがある。しかし、位置情報などをルールベース的に用いるだけでは、適切な情報を提供するのは難しい。ルールベース的に用いるとは、人々の目的や意思に関わらず、現在位置情報から決められた情報のみを提供するようなものである。

移動軌跡データを用いて予測される情報には、未来の移動先や、その人々の属性情報が考えられる。移動先を予測することによって、そのユーザーの目的(目的地)に合った情報を提供できると考えられる。また、属性情報を推測することによって、特定の属性ごとに合った情報を提供することができる。さらに、両方の情報を組み合わせることができれば、よりパーソナライズされた情報を提供することができるだろう。

人々の位置情報を収集する方法として、ビーコンを用いる方法がある。このビーコンは、スマートフォンなどのWi-Fiに接続できる電子機器の端末情報を取得することができる。この方法では、データが取得された時刻に特定の端末がビーコンの情報取得できる距離

に存在したことがわかる。このビーコンを複数用いることによって、ある時間の位置情報を、移動軌跡として利用することができる。また、複数のビーコンを一定の範囲内に設置することによって、その範囲内で移動を目的とした移動軌跡ではなく、ユーザーの目的や意図が含まれた回遊行動のデータを取得することができる。

しかしこの方法の場合、ビーコンのデータ収集可能範囲の端末のデータを無差別に収集することとなる。つまり、データのユーザーに関係のないようなデータや、ユーザーの目的や意図を含んでいないデータが多く含まれてしまうことが考えられる。このようなデータをそのまま用いることは、パーソナライズされた情報の提供をするのにノイズとなる。

本研究では、特定範囲内で得られたユーザーの過去の回遊行動データを用いて、ユーザーの移動先を予測することを目的とする。予測精度を向上させるために、元データに対する前処理や、データスパースネス対策を検討する。また、曜日や時間帯を考慮し予測することによって精度向上を目指す。

2 関連研究

2.1 マルコフモデルをベースとした目的地予測

回遊行動データのような、移動軌跡から目的地を予測する手法として、マルコフモデルを使ったものが多くある。移動軌跡をモデル化することによって、目的地を予測するSubSynアルゴリズム^{1,2)}が提案されている。この手法では、移動軌跡をグリッド上のセルの移動として^{3,4)}、セルをマルコフモデルにおける状態としてセル間の遷移確率としている。この手法では、多数のユーザーから得られた移動軌跡を部分軌跡に分解し合成している。これにより、データスパースネス問題の解決を図っている。また特徴として、予測には移動軌跡のみを使用している。

滝本ら⁵⁾は、このSubSynアルゴリズム¹⁾²⁾に外部情報を利用したものを提案している。仮想軌跡の追加や時間帯を考慮した予測モデルによって、パーソナラ

イズされた目的地予測の精度向上がなされた。

2.2 移動軌跡と他の情報を用いた目的地予測

Imai ら⁶⁾ は、移動軌跡を用いたマルコフモデルでの目的地予測と、ユーザーの通勤や通学などの習慣的行動の情報を用いた手法を提案している。マルコフモデルはデータがスパースな場合、高い予測精度を出すことが難しい。そのため Imai らは、データがスパースな段階では、ユーザーの習慣的行動を元に予測を行い、十分なデータが集まった場合マルコフモデルを用いて予測を行った。実験では前述した SubSyn アルゴリズムよりも高い精度結果が示された。また他にも、事前の調査によって取得した車両での移動時間を分布として、それを利用するような手法^{4, 7, 8)}が提案されている。

3 回遊行動データ

3.1 データの形式

本研究では、株式会社アドインテ¹が開発した AIBeacon² を用いてデータを収集する。この AIBeacon は、Wi-Fi センサーと iBeacon³ が一体となった IOT センサーである。専用のアプリなどを必要とせず、スマートフォンなどの電子端末が Wi-Fi と接続するために発信するプローブ要求を測位することができる。つまり、Wi-Fi に接続できる端末 (以下、端末とする) を所持したユーザーがビーコンのデータ収集範囲に入ったら、その端末の MAC アドレスや、測位された時刻などが 1 つのデータとして記録される。

表 1 に、AIBeacon が収集できるデータの列の詳細を示す。それぞれの列の説明を以下に述べる。ID は測位された端末の MAC アドレスをハッシュ化したものである。Range は、端末からの受信電波強度である RSSI の数値をもとに距離レンジで区切ったものであり、1~5 と 9 であらわされる。Range, RSSI と実際の距離との対応を表 ?? に示す。この値から、AIBeacon と端末の距離を測ることができる。unit_id は、設置されているビーコンそれぞれに与えられている固有の id である。randomized は、測位した端末の MAC アドレスが固定 MAC アドレスかランダム MAC アドレスかを判別するための列である。固定であるかランダムであるかは、端末の機種や OS によって異なる。timestamp は、データが測位された時刻を UNIX 形式であらわしたものである。

Table 1: Data Format

column	Description
ID	端末のハッシュ化された MAC アドレス
Range	RSSI を距離レンジで区切ったもの
rssi	電波強度 (1~100)
unit_id	AIBeacon 固有の id
randomized	0 / 1(固定/ランダム)
timestamp	UnixTime 形式

3.2 データの特徴

このビーコンを用いて収集されるデータの特徴を述べる。

¹株式会社アドインテの HP : <https://adinte.co.jp/>

²株式会社アドインテが開発した AIBeacon : <https://adinte.co.jp/business/aibeacon/>

³iBeacon について : <https://developer.apple.com/ibeacon/>

1 つ目として、データ収集範囲内の端末すべての情報を測位してしまうため、ビーコン設置場所に目的をもって訪れていないユーザーのデータが含まれてしまうことである。そのようなユーザーとして、ビーコン設置場所付近を通っただけのユーザーや、設置場所または、設置場所付近で働いているユーザーなどが該当する。また、ビーコン設置場所に設置されていたり、使用されている端末 (以下、常駐端末とする) のデータも含まれている。

2 つ目として、端末によってはデータ収集時刻ごとに異なる MAC アドレスとしてデータが測位されてしまう。そのため、そのような端末のデータは軌跡データとすることができない。

3 つ目として、端末の機種や、状態によってプローブ要求の頻度に差があり、ユーザーが移動しているにも関わらず連続して同地点から測位してしまうことがある。以上のようなものが含まれているデータは、回遊行動データとしてはふさわしくないため、データに前処理が必要である。

3.3 データの前処理

データの前処理では、移動軌跡から移動先を予測する際に、ノイズとなりうるデータを除外することと、予測精度を向上させるための処理の 2 種類を施す。

はじめにノイズの除去について述べる。使用するデータは、3.2 節で述べたような特徴を持っており、多くのノイズを含んでいると考えられる。そのため移動先の予測を行うために、ビーコン設置場所に目的をもって訪れたユーザーのデータになるように前処理を施す。以下に挙げる処理を組み合わせることにより、ノイズとなりうるデータを除外する。

まず、施設で就業している人や常駐端末のデータを取り除くために、以下の処理を行った。

(a) 全データ収集期間において、対象施設の営業時間外に接触したことがあるユーザーのデータ

営業時間外にビーコンに測位された端末は、施設で就業している人や、常駐端末のデータである可能性が高いため。(対象施設の営業時間は、10:00~20:00 である。)

(b) 収集された軌跡の一定割合以上が同地点によるものである端末のデータ

(c) 長時間連続でデータが収集された端末のデータ

従業員や、常駐端末は、施設内の一定の場所からあまり遠くまで移動することは考えられないため、1 つの軌跡の内 8 割以上同地点のデータを除外した。また、1 つの軌跡の一番初めに測位された時刻から、最後に測位された時刻が 7 時間以上のデータを除外した。

次に、施設に目的が無いユーザーのデータを取り除くために、以下の処理を行った。

(d) 一定距離以上から収集されたデータ

ビーコンから離れたところから測位されたデータは、施設外から測位された可能性があるため。本研究では、30m 以上離れているのデータを除外した。

(e) 極端に軌跡が短いデータ

軌跡が短いデータは、ユーザーが施設内を通り抜けただけであったり、施設から離れた位置いたユーザーが偶然ビーコンに近づいた可能性が高いため。軌跡に含まれるデータが 3 つ以下のものを除外した。

4 移動先予測モデル

本モデルの作成には、主にマルコフモデルを用いる。また、予測に用いるデータは、??章で述べた、位置情報を含む回遊行動データのみとする。

4.1 マルコフモデル

はじめに、マルコフモデルについて述べる。

マルコフモデル(マルコフ過程)とは、マルコフ性を持つ確率過程のことである。ここで、マルコフ性とは、確率過程が持つ特性の一種で、その過程の将来状態の確率分布が現在の状態のみに依存する性質のことである。現在の状態のみから将来の状態が決定される場合を、特に単純マルコフモデルという。それに対して、連続した N 個の状態から将来の状態が決定される場合を、 N 次マルコフモデルという。

本研究では、ビーコン間の移動にマルコフ性を仮定する。設置されているビーコンをそれぞれを、マルコフモデルにおける一つの状態みなす。回遊行動データ中の時刻 t の時に測位したビーコン i を前状態とし、時刻 $t+1$ に測位したビーコン j を後状態とする。それぞれのビーコンにおいて訓練データを用いて、ビーコン i から j へ遷移があった回数を $C_{i \rightarrow j}$ として数え上げる。それぞれのビーコン j への遷移回数を、ビーコン i から遷移するすべてのビーコンへの遷移の合計回数で割ることによって、ビーコン i から j への遷移確率 $p_{i \rightarrow j}$ を求める(式(1))。ビーコンが L 箇所に設置されている場合、すべてのビーコン間の遷移確率を求め、状態遷移確率行列を式(2)のように示す。

$$p_{i \rightarrow j} = \frac{C_{i \rightarrow j}}{\sum_{l=1}^{L=L} C_{i \rightarrow l}} \quad (1)$$

$$M = \begin{pmatrix} p_{1 \rightarrow 1} & \cdots & p_{1 \rightarrow j} & \cdots & p_{1 \rightarrow L} \\ \vdots & \ddots & & & \vdots \\ p_{i \rightarrow 1} & & p_{i \rightarrow j} & & p_{i \rightarrow L} \\ \vdots & & & \ddots & \vdots \\ p_{L \rightarrow 1} & \cdots & p_{L \rightarrow j} & \cdots & p_{L \rightarrow L} \end{pmatrix} \quad (2)$$

遷移確率行列 M は、1次マルコフモデルにおける、1回の遷移でビーコン間を移動する確率を表している。この行列を r 乗することによって、 r 回で移動できる確率を表すことができる。

また、2次マルコフモデルにおける状態遷移確率を求める場合、時刻 t と $t+1$ の時に接触しているビーコン i, j を前状態とし、 $t+2$ に接触しているビーコン k を後状態とする。式(2)を求めた時と同様に、ビーコン i から j, j から k へ遷移があった回数を式($C_{i, j \rightarrow k}$)として数え上げる。その回数を、ビーコン i から j から遷移するすべてのビーコンへの遷移回数の合計回数で割ることによって、ビーコン i から j, j から k へ遷移確率 $p_{i, j \rightarrow k}$ を求めることができる(式(3))。式(2)の行列を L 個用意し、 M_i をビーコン i からの、ビーコン j からビーコン k への遷移確率行列とし式(4)のように示す。

$$p_{i, j \rightarrow k} = \frac{C_{i, j \rightarrow k}}{\sum_{l=1}^{L=L} C_{i, j \rightarrow l}} \quad (3)$$

$$M_i = \begin{pmatrix} p_{i, 1 \rightarrow 1} & \cdots & p_{i, 1 \rightarrow k} & \cdots & p_{i, 1 \rightarrow L} \\ \vdots & \ddots & & & \vdots \\ p_{i, j \rightarrow 1} & & p_{i, j \rightarrow k} & & p_{i, j \rightarrow L} \\ \vdots & & & \ddots & \vdots \\ p_{L \rightarrow 1} & \cdots & p_{L \rightarrow k} & \cdots & p_{L \rightarrow L} \end{pmatrix} \quad (4)$$

式(4)から、2次マルコフモデルにおける、1回の遷移でビーコン間を移動する確率がわかる。例えば、時刻 t と $t+1$ の時に、ビーコン a, b と遷移している場合、行列 M_a の b 行目、 $p_{i, j \rightarrow 1} \sim p_{i, j \rightarrow L}$ が1回の遷移後にそれぞれのビーコンに移動している確率となる。また2回の遷移した後の確率は、行列 M_b の L 行の各行における、各列の値を、重み $p_{i, j \rightarrow 1} \sim p_{i, j \rightarrow L}$ で重み付き平均した値 $q_1 \sim q_L$ となる。

2次マルコフモデルの特徴として、1次マルコフモデルと比べて、1つ長い軌跡情報を用いることができ、予測精度の向上が見込める。しかし、行列 M_i を求める際に用いるデータがスパースになりやすく、その場合うまく予測できない問題がある。

4.2 加算スムージング

スパースネス対策手法として、データスムージングがある。本研究では加算スムージングを用いる。

加算スムージングとは、確率モデルでの予測において、訓練データからは得られなかった事象に対して、僅かに確率値を付与することである。本研究の場合、1次、2次マルコフモデルともに、遷移確率行列を求める際に訓練データから数え上げた、ビーコン間の遷移回数に一定の値を加算する。これにより、一度も出現しなかった遷移のパターンも考慮することができる。加算スムージングを施した場合の $p_{i, j \rightarrow k}$ と $p_{i, j \rightarrow k}$ は、式(5)、式(6)で計算できる。この時 α は任意の実数とする。

$$p_{i \rightarrow j} = \frac{C_{i \rightarrow j} + \alpha}{\sum_{l=1}^{L=L} C_{i \rightarrow l} + \alpha L} \quad (5)$$

$$p_{i, j \rightarrow k} = \frac{C_{i, j \rightarrow k} + \alpha}{\sum_{l=1}^{L=L} C_{i, j \rightarrow l} + \alpha L} \quad (6)$$

5 実験

5.1 使用データ

特定の商業施設内に設置された AIBeacon から収集されたデータを用いる。この施設内には 51 個のビーコンが設置されている。データの収集期間は、2019 年 11 月 3 日～2019 年 11 月 30 日までの 4 週間分である。このデータの内、11 月 3 日～11 月 23 日の 3 週間分を訓練データとし、11 月 24 日～11 月 30 日までの 1 週間分をテストデータとする。

5.2 評価方法

移動先予測モデルによって移動先を予測する。予測を行うための現在位置までの軌跡を問合せ軌跡とする。また、予測は問合せ軌跡に対して m 個先の移動先を予測し、それぞれ評価する。この時長い経路は分割し短い経路とする。

移動先予測の評価指標として、各問合せ軌跡に対して予測された地点が、正しい移動先であった割合、これを正解率 $P@k$ としてあらわす。また、 m 個先の移動先予測確率に基づく確率上位 l 個の予測地点候補を対象として、正しい移動先が l 個以内に含まれているかも計算する。

5.3 実験方法

それぞれの実験の前処理やデータの設定について述べる。

5.3.1 実験 1

3.3 節で述べた、ノイズとなりうるデータを取り除く前処理を施したデータを用いて、移動先を予測する。予測は 1 次、2 次マルコフモデルを用いる。

5.3.2 実験 2

実験 1 と同様の前処理を施したデータを用いる。このデータに対して加算スムージングを施したうえで、2 次マルコフモデルを用いて 5 個先の ($m = 5$) 移動先を予測する。また、加算スムージングにおける α の値は、 $\alpha = 0.1$ から、 $\alpha = 3.0$ まで 0.5 ずつ変化させ実験する。

5.4 実験 3

実験 1 と同様の前処理を施したデータを用いる。このデータの内、商業施設の営業時間 (10:00~20:00) を、(1)10 時台~13 時台、(2)14 時台~16 時台、(3)17 時台~19 時台、の 3 つの時間帯に分割する。また分割したそれぞれのデータに対して、 $\alpha =$ で加算スムージングを施したのちに、それぞれのデータで 2 次マルコフモデルを用いて移動先を予測する。

5.5 実験 4

実験 1 と同様の前処理を施したデータを用いる。このデータの内、データを曜日ごと分割する。またそれぞれのデータに対して、実験 3 と同様に加算スムージングを施したのちに、それぞれのデータで 2 次マルコフモデルを用いて移動先を予測する。

5.6 結果

予測結果の図について説明を述べる。すべての予測結果の図は、縦軸が正解率 P 、横軸が予測確率上位 l 個を表している。例えば $l = 3$ の場合、予測確率上位 3 地点以内に、正しい移動先が含まれている割合を表している。

5.6.1 実験 1

1 次、2 次マルコフモデルでの予測の評価結果をそれぞれ Fig.1, 2 に示す。

それぞれの図より、1 次、2 次マルコフモデルの結果ともに、 $m = 1$ の正解率と、 $m = 3, 5$ の正解率と差があることがわかる。また、2 次マルコフモデルの $m = 1$ の正解率が、1 次マルコフモデルでの正解率よりも 1.5 割程度、精度が向上した。しかし、 $m = 3, 5$ の場合は $m = 1$ の場合に比べてあまり精度が向上していない。




Fig. 1: first-order Markov model




Fig. 2: second-order Markov model

5.6.2 実験 2

Fig.3 に、 α の値を変化させ、2 次マルコフモデルで 5 個先の移動先を予測した結果を示す。また、結果には予測された予測値上位 5 個以内に正解地が入っている正解率を示している。Fig.3 より、 α の値が大きくなるにつれ精度が上昇していることがわかる。しかし、 $\alpha = 0.5$ からは大きな精度向上とはなっていない。




Fig. 3: Prediction result by α

5.6.3 実験 3

それぞれの時間帯の予測結果を Fig.4, Fig.5, Fig.6 に示す。

予測結果は、3 つの時間帯それぞれわずかに予測精度が上下しているものもあるが、ほぼ同精度となっている。またデータを分割する前と比較しても、精度に変化は見られなかった。

5.6.4 実験 4

休日である日曜日、平日である水曜日、週末である金曜日の 3 つの曜日について予測結果を示す。それぞれ Fig.7, Fig.8, Fig.9 に示す。

予測結果は、実験 3 の時間帯を分割した場合と同様にデータ分割前と精度に変化は見られなかった。




Fig. 4: Results from 10:00 to 14:00




Fig. 5: Results from 14:00 to 17:00




Fig. 6: Results from 17:00 to 20:00




Fig. 7: Results of Sunday (holiday)




Fig. 8: Results of Wednesday (Weekdays)




Fig. 9: Results of Friday (Weekend)

6 考察

6.1 実験 1

5.6.1 節より, 2 次マルコフモデルでの予測結果のほうが 1 次マルコフモデルでの予測結果より全体的に良い精度が得られているのは, 2 次マルコフモデルのほうが, 1 つ前の状態を用いることができただためだと考えられる。

また, 1 次, 2 次マルコフモデルでの予測結果, とともに $m = 1$ と $m = 3, 5$ の正解率大きく差があるのは, 一部のピーコン間の遷移回数に偏りがあることで, 1 つ先以降の移動先の予測に影響を与えていると考えられる。また, 2 次マルコフモデルでの予測結果のほうが 1 次マルコフモデルでの予測結果に比べて, $m = 1$ と $m = 3, 5$ の正解率の差が大きいのは, データスパースネスによるものだと考えられる。

6.2 実験 2

実験 1 の考察から, 加算スムージングを α の値を変化させ施し, 移動先の予想を行った。

スムージングを施していない結果と $\alpha = 0.5$ の結果を比較した場合, 予測精度が 1.0 程度向上した。また, $\alpha = 0.5$ から $\alpha = 3.0$ まででも, 僅かではあるが精度が向上している。これは, スムージングを施したことによる良い効果が得られているが, α の値によるさらなる精度向上は期待できないと考えられる。

6.3 実験3

実験1, 実験2の考察より, 2次マルコフモデルに加算スムージングを $\alpha = 3.0$ で施したモデルが最も良い予測精度を得られることが分かった。よって実験3以降では, このモデルを用いて予測を行っている。

実験3では, 1時間ごとのデータ数とIDの数の推移から, 時間帯を3つに分けてモデルを作成し予測を行った。5.6.3より, 時間帯を分割しても分割しない場合と, 同じ精度しか得られなかった。また, それぞれの時間帯ごとでも精度に大きな差はみられなかった。これらの要因として, 時間帯の分け方が適切でなかった, 本データの場合時間帯と移動先の予測精度に相関がないことが考えられる。また, 実験2と同じ期間の訓練データを分割したために, 3つの時間帯それぞれのモデルを作成するための, 訓練データの絶対数が減ったことによって, 精度が向上しなかった可能性も考えられる。これらの場合, 使用するデータの期間をさらに増やすことで改善されるだろう。またデータが増えることによって, 1時間ごとのデータ数とIDの数にもより特徴が表れ, 適切な時間帯の分割が可能になると思われる。

6.4 実験4

実験4では, 各曜日ごとにデータを分割しそれぞれモデルを作成し移動先を予測した。

5.6.4より, 曜日ごとに分割しても良い予測精度は得られなかった。これは, 実験3と同じく曜日と精度に相関がない, 実験3の場合よりもさらに訓練データ数が少なくなっているため, データがスパースになりうまく予測ができなかったと考えられる。

しかし, 大幅に少ないデータ量で, ほぼ同精度が得られていることは注目すべきである。この要因として考えられるのは, データがスパースになりつつも曜日ごとの特徴をうまくとらえることができている。または, 2次マルコフモデルと加算スムージングの手法で得られる予測精度の限界であることが考えられる。これらの場合, まず訓練データを増やして移動先を予測, 加算スムージング以外のデータスパースネス対策手法を検証しなければならない。

7 結言

本研究では, 商業施設内に設置された複数のビーコンから収集された位置情報データから移動先を予測した。収集された元データには, 予測するのにノイズとなりうるデータが多数含まれており, それらを適切に前処理し, 商業施設内に目的をもって訪れたユーザーのみのデータを回遊行動データとして抽出した。

移動先の予測手法として, 1次, 2次マルコフモデルを用いた。また, データスパースネス問題に対しては, 加算スムージングを適用し予測精度を向上させた。2次マルコフモデルと加算スムージングによるデータスパースネス対策により, さらに高い予測精度を得ることができた。また, 時間帯や曜日ごとにデータを分割してそれぞれモデルを作成し, 特定期間のデータの特徴を得ることによって精度の向上を図った。しかし, データ量の問題や, データ分割の方法などの問題によって, 期待した結果を得ることはできなかった。

これらから, 使用データ量やスムージング手法, マルコフモデルとは違う他の手法を検討することが必

要である。さらに高い精度でユーザーの移動先を予測することができれば, そのユーザーに対して有益な情報や広告の提供へと応用することができるだろう。

参考文献

- 1) Xue, A. Y., Zhang, R., Zheng, Y., Xie, X., Huang, J., and Xu, Z.: Destination prediction by sub-trajectory synthesis and privacy protection against such prediction. , 2013 IEEE 29th international conference on data engineering (ICDE). , IEEE, p. 254/265. (2013)
- 2) Xue, A. Y., Qi, J., Xie, X., Zhang, R., Huang, J., and Li, : Y. Solving the data sparsity problem in destination prediction. , The VLDB Journal, 24.2: p. 219/243. (2015)
- 3) Wei, L. Y., Zheng, Y., and Peng, W. C. : Constructing popular routes from uncertain trajectories., Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining., p. 195/203. (2012)
- 4) Krumm, J., and Horvitz, E. Eric.: Predestination: Inferring destinations from partial trajectories., International Conference on Ubiquitous Computing., p. 243-260. (2016)
- 5) 瀧本祥章, 西田京介, 遠藤結城, 戸田浩之, 澤田宏, and 石川佳治.; 時間帯を考慮したパーソナライズ目的地予測., 電子情報通信学会論文誌 D, 100.4: p. 472/484. (2017)
- 6) Imai, R., Tsubouchi, K., Konishi, T., and Shimomura, M.: Early destination prediction with spatio-temporal user behavior patterns., Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 1(4), p. 1/19. (2018) krumm2007predestination,horvitz2012some
- 7) Krumm, J., and Horvitz, E.: Predestination: Where do you want to go today?., Computer, 40(4), p. 105/107. (2007)
- 8) Horvitz, E., and Krumm, J.: Some help on the way: Opportunistic routing under uncertainty., In Proceedings of the 2012 ACM conference on Ubiquitous Computing, pp. 371-380. (2012)