

MAP 推定を用いた歩行者の位置情報予測

—POI 推薦を目的として—

田中 博己†¹ 高須 淳宏†² 山名 早人†^{2,3}

†¹ 早稲田大学基幹理工学研究科 〒169-8555 東京都新宿区大久保 3-4-1

†² 国立情報学研究所 〒101-8430 東京都千代田区一ツ橋 2-1-2

†³ 早稲田大学理工学術院 〒169-8555 東京都新宿区大久保 3-4-1

E-mail: †^{1,3}{mizurin, yamana}@yama.info.waseda.ac.jp, †²takasu@nii.ac.jp

あらまし スマートフォンに代表される GPS 搭載機器が広く普及したことに伴い、位置情報サービス(LBS)の重要性が向上している。位置情報を予測することによって、観光地の推薦や目的地をベースとした広告の推薦、自動的に目的地を設定するナビゲーションシステム提供が可能になる。従来研究では、位置情報の予測手法として主に隠れマルコフモデルが用いられている。隠れマルコフモデルの構築には道路ネットワークの構築が必要であるため、道路上を走行することがほぼ保証されている自動車に対する位置情報の予測に限られる。一方、歩行者は必ずしも道路上を通らない場合があり、道路ネットワークを利用した隠れマルコフモデルの適用ができない。これに対して本研究では、道路ネットワークを用いず、100m 四方のメッシュに分割した上で MAP 推定を用いて予測を行う手法を提案する。現在地から 10 分後に歩行者が位置するメッシュを予測する場合、予測精度は 3.23%、2 分後の予測精度は 20%となった。

キーワード LBS, MAP 推定

1. はじめに

スマートフォンを始めとした Global Positioning System(GPS)を搭載した機器の普及に伴い、大量の位置情報の取得が容易になった。位置情報サービス(LBS)とは、取得した位置情報を利用して提供するサービスのことをいう。LBS を用いたアプリケーションには、カーナビゲーションシステムを代表として、様々なアプリケーションが存在し、日々の生活に浸透している。

とりわけ近年では、多くの位置情報を用いたアプリケーションの要素技術として、位置情報予測の研究が必要とされている[1]。例えば、観光地の推薦や目的地をベースとした広告の配信、自動的に目的地を設定するナビゲーションシステムがある。位置情報の予測により、LBS の提供者は現在位置から目的地や未来の位置に基づく広告の配信が可能になり、位置情報ベースの広告配信の効果がより向上すると考えられる。

従来、位置情報の予測に関する研究は、隠れマルコフモデルが用いられていた[2][3]。隠れマルコフモデルによる予測では、道路ネットワークが用いられている。つまり、位置情報の予測対象(自動車など)が、常に道路上に存在することを前提としており、歩行者などの道路ネットワーク以外に位置する可能性がある対象物に対する予測に適用することができない。歩行者は、道路だけでなく、公園や広場、大学などを移動する可能性がある点に注意しなければならない。

本研究では、従来手法が対象としなかった歩行者に対する、現在地から 10 分以内の位置情報の予測を行うことを目的とする。具体的には、既存研究で多く用いられている道路ネットワークを用いずに予測を行う。

はじめに、近似した位置を同一として扱うために予測対象地域を 100m 四方のメッシュに分割する。次に、MAP 推定を行い位置情報の予測を行う。

本稿では以下の構成を取る。2 節で関連研究を説明し、位置情報の予測の研究に対する本研究の立ち位置を明確にする。3 節で提案手法の説明を行い、4 節で評価実験を説明する。5 節で本研究をまとめる。

2. 関連研究

位置情報予測に関する研究は、2012 年以前に行われていた「Trajectory の頻出パターンマイニング」、2010 年以降に行われている「Trajectory モデルの構築による手法」、2016 年以降に研究されている「深層学習を用いた手法」の 3 種類に分類できる。

2.1. 頻出パターンマイニングを利用した位置予測

Trajectory の頻出パターンマイニングを利用した手法では、主に決定木を構築し、位置情報の予測している。ピサ大学の Monreale ら[4]は、2009 年に目的地をベースに決定木の構築を行い、その後、国立成功大学の Ying ら[5]が 2011 年に目的地だけではなく、個人の移動履歴を利用した決定木の構築を行っている。

Trajectory の頻出パターンマイニングを用いた手法では決定木構築の計算コストが高くなるという問題点がある。また、決定木を構築する手法であるため、予測対象が目的地に限られる問題がある。そのため、2012 年以降はほぼ行われていない手法である。

2.2. Trajectory モデル構築による位置予測

Trajectory モデルを構築する手法は、2010 年以降に研究が開始された。Trajectory モデルの構築には、主に隠れマルコフモデルが用いられている。Trajectory モデルの構築した手法に対する予測対象は、ルート予測と目的地予測の 2 種類である。ルート予測と目的地予測それぞれの予測方法の概略を以下に示す。

ルート予測

1. Trajectory を地図上の道路にマッピング。
2. 道路を Road Segment に分割し、それぞれ番号を付与。
3. Road Segment を用いて道路ネットワークを構築。
4. 3 を用いて隠れマルコフモデルを構築。

目的地予測

1. 目的地の集合を用いて目的地ネットワークを構築。
2. 1 を用いてマルコフモデルを構築。

Trajectory モデル構築の方法には、第三者の Trajectory を利用した手法と、個人の移動履歴を利用した手法の 2 種類ある。

2.2.1. 第三者の Trajectory を利用した手法

第三者のデータを利用した手法について表 1 にまとめる。他人の Trajectory を利用した手法には、多数の自動車の位置情報が含まれているデータセットを用いた研究が一般的である。これは、自動車の位置情報データセットの T-Drive[6][7]のように、14,000 台を超えるタクシーの位置情報を用いることができるためと考えられる。また、予測対象は目的地とする研究が多い。

表 1. 第三者の Trajectory を利用した方法

著者	提案年	手法	データセット
Gambs ら [8]	2012	MC	Pheonetic, GeoLife, Synthetic
Asahara ら [9]	2011	Mixed MC	Simulation, Original
Xue ら [1]	2013	MC	T-Drive
Huang ら [10]	2015	MC	GeoLife
Ye ら [2]	2016	HMM	Taxis' Data

MC: Markov Chain

HMM: Hidden Markov Model

2.2.2. 個人の移動履歴を利用した手法

個人の移動履歴を利用した手法を表 2 にまとめる。個人の移動履歴を利用した手法では、予測対象の人数が少人数であるものについて、長期間の位置情報を対象にしている。これは、位置情報のデータセットが個人のプライバシーと大きく関係することから、大人数の個人から許諾を得ることが難しいことに起因してい

ると考えられる。実際、実験協力者を募って独自にデータセットを作成したものが多く、利用したデータセットも公開されていない場合が多い[3]。予測対象は、目的地、ルート予測とも存在する。

表 2. 個人の移動履歴を利用した手法

著者	提案年	手法	データセット
Alvarez-Garcia ら [3]	2010	HMM	Original (6 people)
Yuan ら [11]	2013	MC	CD dataset

HMM: Hidden Markov Model

2.3. 深層学習を利用した手法

深層学習を利用した手法は 2016 年頃から研究が開始された。画像を利用し、群衆における数秒後の位置情報の予測を行うもの[12]、群衆移動予測を行うもの[13]がある。しかし、プライバシー問題やデータ収集の難易度から、個人のデータの予測を行うほどのデータセットが揃っていない。そのため、個々の対象者に対する位置情報の予測が困難になっていると考えられる。

2.4. 関連研究のまとめ

位置情報の予測に用いられている手法について代表的なものを時系列順に表 3 に示す。位置情報の予測に用いられている手法は、隠れマルコフモデルを利用した手法が多く、位置情報の予測に道路情報が必要になる。したがって、歩行者のように必ずしも道路上を移動しない対象に対する位置情報の予測には適用ができない。また、深層学習を利用した予測手法では、大量のデータが必要となるため、目的地やルート予測を対象にするに必要な位置情報の収集が困難とあり、研究事例が限定されていると考えられる。

表 3. 既存研究のまとめ

著者	提案年	手法			予測対象
		FPM	ETH	DL	
Monreale ら [4]	2009	✓			People's destination
Ying ら [5]	2011	✓			People's destination
Gambs ら [8]	2012		✓		People's / vehicles' destination
Huang ら [10]	2015		✓		People's / vehicle's destination
Ye ら [2]	2016		✓		Vehicles' route
Zhang ら [13]	2017			✓	Crowd flows

FPM: Frequent Pattern Mining, ETM: Establish Trajectory Methods, DL: Deep Learning,

3. メッシュを用いた歩行者の位置情報予測手法の提案

3.1. 概要

本稿では、「必ずしも道路上を通過するとは限らない歩行者に対する位置情報予測」を目的とした手法を提案する。具体的には以下の手順で行う。

1. メッシュを用いた Trajectory の表現
2. 移動時間の分布の計算
3. メッシュ間遷移確率の推定
4. EM アルゴリズムによるパラメータ推定
5. 単純マルコフ連鎖を用いたメッシュ間移動予測

3.2. メッシュを用いた Trajectory の表現

本研究では、図 1 で示すように地図上の平面を格子状に分割する。観光地の推薦や目的地をベースとした広告の推薦用途を想定した場合、数 cm や数 m 単位での予測は不要であるため、本研究では、100m 四方のメッシュに分割し、n 分後の利用者の位置について、メッシュを単位として予測することとした。つまり、100m 四方の領域内を「同一の位置」と考える。

100m のメッシュサイズは、POI 推薦目的において十分に小さいサイズである。また、GPS で取得した位置情報自体も誤差を含んでいるため、極端にメッシュサイズを小さくした場合、Ground Truth が正しいメッシュに含まれない可能性が増大することからも適切な大きさであると判断した。

メッシュの集合を G と表す。また、Trajectory に含まれる個々の位置情報を表す点を含むメッシュを g で表し、 $g \in G$ と定義する。



図 1 地図をメッシュ分割したイメージ (map tiles ©OpenStreetMap, CC BY-SA 2.0).

メッシュを用いて Trajectory をメッシュ位置およびメッシュの移動に必要なとした時間の組 (g, t) で表す。ここで、 $g = \langle g_1, g_2, \dots, g_n \rangle$ は Trajectory に含まれる個々の位置情報に対応するメッシュを表し、 $t = \langle t_1, t_2, \dots, t_n \rangle$ における各時間 t_i はある Trajectory がメッシュ g_i に入って

から g_i を出るまでの経過時間を示す。以下では、メッシュ内の移動時間と表現する。

3.3. メッシュ内滞在時間分布

メッシュ内の移動時間 t_i は、移動手段や移動目的によって異なる。本研究においては、歩行者のみを対象としているため、目的地に向かって歩いている場合と、観光をしているような場合とでは移動速度が異なる。そのため、歩行者は各々移動モード m を持つとする。ここで、移動モードとは、「歩く」「走る」等を想定する。

本研究では、各メッシュ g を時間 t で移動する確率を式(1)の混合ガウス分布で表す。

$$p(t|g) = \sum_{m \in M} \theta_{gm} \mathcal{N}(t; \mu_{gm}, v_{gm}^2) \quad (1)$$

ここで、 M は混合ガウス分布の成分集合を、 θ_{gm} は、メッシュ g の成分のうち、移動モード $m \in M$ の混合比を表す。 μ_{gm} および v_{gm}^2 は式(2)に示すように、メッシュ g のモード m のガウス分布の平均と分散を表す。

$$\begin{aligned} & \mathcal{N}(t; \mu_{gm}, v_{gm}^2) \\ &= \frac{1}{\sqrt{2\pi v_{gm}^2}} \exp\left(-\frac{(t - \mu_{gm})^2}{2v_{gm}^2}\right) \end{aligned} \quad (2)$$

3.4. メッシュ間遷移確率

Trajectory があるメッシュ g からモード m で隣接するメッシュへの遷移確率を ϕ_{gma} と表す。ここで d は隣接するメッシュ 4 方向を表し、 $d = \{\text{north, east, south, west}\}$ のいずれかを表す。なお、本モデル化では簡単のため、対角線方向へのメッシュには移動せず、対角線方向のメッシュへの移動では 2 ステップ (例: 東 → 北) の移動を行うものとしている。

メッシュ間の遷移確率を用いることによって、Trajectory を

$$c_i = (g_i, t_i, d_i) \quad (3)$$

の 3 項の組で表すこととする。ここで d_i は g_i からの移動方向を表しており、 $\mathbf{d} = \langle d_1, d_2, \dots, d_n \rangle$ は、メッシュ間の遷移方向の列を表している。移動方向 d_i は、 g_i と g_{i+1} より求めることができる。

3.5. Trajectory の尤度

本節では、本研究で用いるパラメータの集合を

$$\begin{aligned} \Theta = & \{ \theta_g \}_{g \in G} \cup \{ \phi_{gm} \}_{g \in G, m \in M} \\ & \cup \{ \mu_{gm} \}_{g \in G, m \in M} \\ & \cup \{ v_{gm} \}_{g \in G, m \in M} \end{aligned} \quad (4)$$

と表す. Trajectory $\mathbf{x} = \langle c_1, c_2, \dots, c_n \rangle$ について, それぞれのメッシュ g_i の移動モード m_i とし, また, Trajectory \mathbf{x} の移動モード列を $\mathbf{z} = \langle m_1, m_2, \dots, m_n \rangle$ として表す. \mathbf{z} は直接観測することができないことに注意する必要がある. Trajectory の移動モード列 \mathbf{z} に対する尤度は以下のように表される.

$$p(\mathbf{x}, \mathbf{z} | \boldsymbol{\theta}) = \prod_{i=1}^l \mathcal{N}(t_i; \mu_{g_i m_i}, \nu_{g_i m_i}) \theta_{g_i m_i} \phi_{g_i m_i d_i} \quad (5)$$

また, 移動モードに関する周辺尤度は以下の式(6)で表される.

$$p(\mathbf{x} | \boldsymbol{\theta}) = \prod_{i=1}^l \sum_{m \in M} \mathcal{N}(t_i; \mu_{g_i m}, \nu_{g_i m}) \theta_{g_i m} \phi_{g_i m d_i} \quad (6)$$

3.6. EM アルゴリズムによるパラメータ推定

3.6.1. 最尤推定

学習データとして Trajectory の集合 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ が与えられたとき, パラメータ $\boldsymbol{\theta}$ の最尤推定

$$\operatorname{argmax}_{\boldsymbol{\theta}} [\ln p(\mathbf{X} | \boldsymbol{\theta})] \quad (7)$$

を求める.

本モデルの最尤推定値は EM アルゴリズムを用いて求めることができる. 学習データに含まれるそれぞれの Trajectory \mathbf{x}_i に対する移動モード列 \mathbf{z}_i と表す. また, 学習データに対する移動モード列を $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_n\}$ と表すことにする. \mathbf{z}_i は学習データ中の Trajectory に対するモード列を表す. ここで, 訓練データ \mathbf{X} と移動モード列 \mathbf{Z} に対する変分事後分布 $q(\mathbf{Z} | \mathbf{X})$ を導入する.

Jensen の不等式を用いると, 尤度 $p(\mathbf{X} | \boldsymbol{\theta})$ の下界 $L(q(\mathbf{Z} | \mathbf{X}), \boldsymbol{\theta})$ は以下ようになる.

$$\ln p(\mathbf{X} | \boldsymbol{\theta}) \geq L(q(\mathbf{Z} | \mathbf{X}), \boldsymbol{\theta}) \quad (8)$$

以下では変分事後分布 $q(\mathbf{Z} | \mathbf{X})$ を q と略記する.

EM アルゴリズムは, 対数尤度 $\ln p(\mathbf{X} | \boldsymbol{\theta})$ を最大化する代わりに上記の下界 $L(q(\mathbf{Z} | \mathbf{X}), \boldsymbol{\theta})$ を最大化する変分事後分布 q とパラメータ $\boldsymbol{\theta}$ を求める. アルゴリズムは, 尤度 $p(\mathbf{X} | \boldsymbol{\theta})$ が収束するまで, q と $\boldsymbol{\theta}$ を交互に更新する. t 回目に求められた変分事後分布とパラメータをそれぞれ q^t および $\boldsymbol{\theta}^t$ とする.

E ステップ

E ステップではパラメータを $\boldsymbol{\theta}^{t-1}$ に固定し, 対数尤度の下界 $L(q, \boldsymbol{\theta}^{t-1})$ を最大化する. これを満たす変分事後分布は以下の式(9)で与えられる.

$$q^t = \operatorname{argmax}_q [L(q, \boldsymbol{\theta}^{t-1})] = p(\mathbf{Z} | \mathbf{X}, \boldsymbol{\theta}^{t-1}) \quad (9)$$

EM アルゴリズムにおいて $t-1$ 回目に求められたパラメータを $\boldsymbol{\theta}^{t-1}$ と表す. また, t 回目の最適変分事後分布を $q^t(\mathbf{Z} | \mathbf{X})$ と表すことにする. 式(9)より, E ステップでは, Trajectory に含まれる個々の位置情報における点 $\mathbf{c} = (g, t, d)$ に対する移動モードの事後確率は以下の式(10)で与えられる.

$$\begin{aligned} q^t(m | \mathbf{c}) &= p(m | \mathbf{c}, \boldsymbol{\theta}^{t-1}) \\ &\propto p(\mathbf{c}, m | \boldsymbol{\theta}^{t-1}) \\ &= \theta_{gm}^{t-1} \phi_{gmd}^{t-1} \mathcal{N}(t; \mu_{gm}^{t-1}, \nu_{gm}^{t-1}) \end{aligned} \quad (10)$$

M ステップ

M ステップでは, 変分事後分布を q^t に固定して, 対数尤度の下界 $L(q, \boldsymbol{\theta}^t)$ を最大化するパラメータ $\boldsymbol{\theta}$ を求める.

$$L(q, \boldsymbol{\theta}^t) = \sum_{\mathbf{z}} q^t \ln p(\mathbf{X}, \mathbf{Z} | \boldsymbol{\theta}) - q^t \ln q^t \quad (11)$$

ここで, 変分事後分布 q^t は固定されているため, 式(12)の第2項は定数となる, したがって, 第1項を最大化するパラメータ $\boldsymbol{\theta}$ を求めれば十分である. 以下では, 式(12)の第1項を $Q(\mathbf{X}, \boldsymbol{\theta})$ と表す.

$$Q(\mathbf{X}, \boldsymbol{\theta}) = \sum_{\mathbf{x} \in \mathbf{X}} \sum_{i=1}^{|\mathbf{x}|} \sum_{m \in M} q^t(m | \mathbf{c}_i) \cdot \ln[\theta_{gm} \phi_{gmd} \mathcal{N}(t; \mu_{gm}, \nu_{gm})] \quad (12)$$

加えて, パラメータ $\boldsymbol{\theta}$ を求めるためには, 移動時間とメッシュ間遷移確率の制約を満たす必要がある.

1) 移動時間

各メッシュ $g \in G$ において移動モードの分布 θ_{gm} は以下の式(13)の制約を満たす必要がある.

$$\sum_{m \in M} \theta_{gm} = 1 \quad (13)$$

Lagrange の未定乗数法を用いて式(14)の制約のもと, 式(14)の $Q(\mathbf{X}, \boldsymbol{\theta})$ を最大にする移動モード分布 θ_{gm} を求めると以下の更新式が得られる

$$\theta_{gm}^t \propto \sum_{\mathbf{x} \in \mathbf{X}} \sum_{i=1}^{|\mathbf{x}|} q^t(m | \mathbf{c}_i) \cdot \delta(g, g_i) \quad (14)$$

となる．同様に，

$$\mu_{gm}^t = \frac{\sum_{x \in X} \sum_{i=1}^{|x|} q^t(m|\mathbf{c}_i) \cdot t_i \cdot \delta(g, g_i)}{\sum_{x \in X} \sum_{i=1}^{|x|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i)} \quad (15)$$

となり，

$$v_{gm}^t = \frac{\sum_{x \in X} \sum_{i=1}^{|x|} q^t(m|\mathbf{c}_i) (t_i - \mu_{gm}^t)^2 \delta(g, g_i)}{\sum_{x \in X} \sum_{i=1}^{|x|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i)} \quad (16)$$

となる．

2) メッシュ間遷移確率

各メッシュ $g \in G$ の各移動モード $m \in M$ において，方向 $d \in D$ に移動する確率は，以下の制約を満たす必要がある．

$$\sum_{d \in D} \phi_{gmd} = 1 \quad (17)$$

式(17)の制約のもと式(12)の $Q(X, \Theta)$ を最大にする遷移確率は以下のとおり求まる．

$$\phi_{gmd}^t \propto \sum_{x \in X} \sum_{i=1}^{|x|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i) \cdot \delta(d, d_i) \quad (18)$$

3.6.2. MAP 推定

最尤推定を用いると，データ量が少ない場合に推定確率が低下するという問題が発生する．そこでメッシュ間の遷移確率を向上させるために，MAP 推定を利用する．

まず，各パラメータについて以下の共役事前分布を仮定する．

- 各メッシュ $g \in G$ において $\theta_g \sim \text{Dir}(\alpha)$
- 各メッシュ $g \in G$ と各移動モード $m \in M$ において $\phi_{gm} \sim \text{Dir}(\beta)$
- 各メッシュ $g \in G$ と各移動モード $m \in M$ において $\mu_{gm} \sim \mathcal{N}(\xi, \eta)$

ここで， $\text{Dir}(\alpha), \text{Dir}(\beta)$ は以下の対象ディクレ分布を表している．

$$\begin{aligned} \text{Dir}(\theta_g; \alpha) &= \frac{\Gamma(\alpha \cdot C_m)}{\Gamma(\alpha)^{C_m}} \prod_{m \in M} \theta_{gm}^{\alpha-1} \\ \text{Dir}(\phi_{gm}; \beta) &= \frac{\Gamma(\beta \cdot C_d)}{\Gamma(\beta)^{C_d}} \prod_{d \in D} \phi_{gmd}^{\beta-1} \end{aligned} \quad (19)$$

式(19)において， C_m は移動モードの総数を表し， C_d は移動方向の総数を表す．本研究では 4 である．

以下では，上記の事前分布のハイパーパラメーターをまとめて， Λ と表すことにする．

$$\Lambda = \{\alpha, \beta, \xi, \eta\} \quad (20)$$

ここで，事前分布に基づいてパラメータ Θ が求められる確率を以下の式(21)に示す．

$$\begin{aligned} p(\Theta|\Lambda) &= \prod_{g \in G} [\text{Dir}(\theta_g; \alpha)] \\ &\cdot \prod_{g \in G, m \in M} [\mathcal{N}(\mu_{gm}; \xi, \eta)] \\ &\cdot \prod_{g \in G, m \in M} [\text{Dir}(\phi_{gm}; \beta)] \end{aligned} \quad (21)$$

次に，学習データとして Trajectory の集合 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ が与えられたとき，パラメータの MAP 推定値 Θ^*

$$\begin{aligned} \Theta^* &= \underset{\Theta}{\text{argmax}} [\ln p(\mathbf{X}|\Theta) \cdot p(\Theta|\Lambda)] \\ &= \underset{\Theta}{\text{argmax}} [\ln p(\mathbf{X}|\Theta) + \ln p(\Theta|\Lambda)] \end{aligned} \quad (22)$$

を求める．式(22)の第 1 項は最尤推定の目的関数と同じであり，その下界は，式(11)の $L(q, \Theta)$ となる．そこで，MAP 推定の目的関数である式(23)の下界

$$LM(q, \Theta, \Lambda) = L(q, \Theta) + \ln p(\Theta|\Lambda) \quad (23)$$

を EM アルゴリズムを用いて最大化するパラメータを求める．最尤推定の場合と同じように，アルゴリズムは，尤度 $p(\mathbf{X}|\Theta)$ が収束するまで q と Θ を交互に更新する． t 回目に求められた変分事後分布とパラメータをそれぞれ q^t および Θ^t と表す．

E ステップ

E ステップではパラメータを Θ^{t-1} に固定し， $LM(q, \Theta, \Lambda)$ を最大化する．ここで，下界 $LM(q, \Theta, \Lambda)$ を最大とする変分事後分布は，最尤推定のとくと同じく，以下の式(24)で与えられる．

$$\begin{aligned} q^t &= \underset{q}{\text{argmax}} [LM(q, \Theta^{t-1}, \Lambda)] \\ &= p(\mathbf{Z}|\mathbf{X}, \Theta^{t-1}) \end{aligned} \quad (24)$$

また，Trajectory に含まれる個々の位置情報における点 $\mathbf{c} = (g, t, d)$ に対する移動モードの事後確率も最尤推定と同じく式(25)として与えられる．

$$\begin{aligned}
q^t(m|\mathbf{c}) &= p(m|\mathbf{c}, \boldsymbol{\theta}^{t-1}) \\
&\propto p(\mathbf{c}, m|\boldsymbol{\theta}^{t-1}) \\
&= \theta_{gm}^{t-1} \phi_{gmd}^{t-1} \mathcal{N}(t; \mu_{gm}^{t-1}, \nu_{gm}^{t-1})
\end{aligned} \quad (25)$$

M ステップ

M ステップでは、変分事後分布を q^t に固定して、対数尤度の下界 $LM(q, \boldsymbol{\theta}, \boldsymbol{\Lambda})$ を最大化するパラメータ $\boldsymbol{\theta}$ を求める。

$$\begin{aligned}
LM(q, \boldsymbol{\theta}^t, \boldsymbol{\Lambda}) &= \sum_{\mathbf{Z}} q^t \ln p(\mathbf{X}, \mathbf{Z}|\boldsymbol{\theta}) \\
&\quad - q^t \ln q^t \\
&\quad + \ln p(\boldsymbol{\theta}|\boldsymbol{\Lambda})
\end{aligned} \quad (26)$$

ここで、変分事後分布 q^t は固定されているため、式(26)の第2項は定数となる、したがって、第1項と第3項を最大化するパラメータ $\boldsymbol{\theta}$ を求めれば十分である。また、第1項は最尤推定と同じであるため、式(25)の $Q(\mathbf{X}, \boldsymbol{\theta})$ を用いることができる。式(27)では、MAP 推定の M ステップで最大化する関数を表す

$$Q(\mathbf{X}, \boldsymbol{\theta}, \boldsymbol{\Lambda}) = Q(\mathbf{X}, \boldsymbol{\theta}) + \ln p(\boldsymbol{\theta}|\boldsymbol{\Lambda}) \quad (27)$$

加えて、パラメータ $\boldsymbol{\theta}$ を求めるためには、移動時間とメッシュ間遷移確率の制約を満たす必要がある。

1) 移動時間

各メッシュ $g \in G$ において移動モードの分布 θ_{gm} は以下の式(28)の制約を満たす必要がある。

$$\sum_{m \in M} \theta_{gm} = 1 \quad (28)$$

この時、移動モード分布 θ_{gm} の更新式は

$$\begin{aligned}
\theta_{gm}^t &\propto \sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} [q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i)] + \alpha \\
&\quad - 1
\end{aligned} \quad (29)$$

となる。同様に、

$$\begin{aligned}
\mu_{gm}^t &\propto \\
&\frac{\eta \sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} q^t(m|\mathbf{c}_i) \cdot t_i \cdot \delta(g, g_i) + \xi \nu_{gm}^{t-1}}{\eta \sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i) + \nu_{gm}^{t-1}}
\end{aligned} \quad (30)$$

となる。

分散については、事前分布を導入していないため、最尤推定と同じ更新式になる。

$$\begin{aligned}
\nu_{gm}^t &\propto \\
&\frac{\sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} q^t(m|\mathbf{c}_i) (t_i - \mu_{gm}^t)^2 \delta(g, g_i)}{\sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i)}
\end{aligned} \quad (31)$$

となる。

2) メッシュ間遷移確率

各メッシュ $g \in G$ の各移動モード $m \in M$ において、方向 $d \in D$ に移動する確率は、以下の制約を満たす必要がある。

$$\sum_{d \in D} \phi_{gmd} = 1 \quad (32)$$

したがって、以下の更新式が求められる。

$$\begin{aligned}
\phi_{gmd}^t &\propto \sum_{\mathbf{x} \in X} \sum_{i=1}^{|\mathbf{x}|} q^t(m|\mathbf{c}_i) \cdot \delta(g, g_i) \\
&\quad \cdot \delta(d, d_i) + \beta - 1
\end{aligned} \quad (33)$$

3.7. 移動予測

3.7.1. 移動モード推定

3.6 項で求めたパラメータを用いて移動モード m の事後確率を求める。その際、テストデータとして、自分の過去の Trajectory を用いる。自分の Trajectory とは、現在取得した点を含む Trajectory を指す。自分の過去の Trajectory とは、現在取得した点を含む Trajectory における、現在取得した点までの Trajectory を示す。確率が最も高いモードが自分の Trajectory における移動モードとする。すなわち、Trajectory の最中に移動モードが変わることはないと仮定する。

モード m が決定された場合、そのモードにおけるメッシュ内平均滞在時間が定義可能である。本研究では、予測するすべての Trajectory に対するメッシュ内滞在時間は、各モード m におけるメッシュ内平均滞在時間であると仮定し、メッシュ内滞在時間まではメッシュの移動は行われぬものとする。

3.7.2. 移動先メッシュの予測

各モード m に対する遷移確率を元に、単純マルコフ連鎖を用いて推定を行う。

4. 評価実験

4.1. データセット

本研究で使用するデータセットは Microsoft Research の GeoLife GPS Trajectories[14][15][16] (以下 GeoLife) である。GeoLife とは最大で 2007 年 4 月から 2012 年 8 月までの期間 182 人に対して位置情報を収集したものである。GeoLife の特徴として、移動モードが付与されていることにある。移動モードとは、どのような手段によって移動したかを表すもので、

全 11 種類存在する。そのモード名は、「walk」, 「subway」, 「car」, 「bike」, 「motorcycle」, 「airplane」, 「taxi」, 「train」, 「boat」, 「run」, 「bus」であり、モードが一部の Trajectory に対して付与されている。182 人のうち 64 人の Trajectory には、少なくとも 1 点以上の位置情報に対して移動モードが付与されたデータが存在する。なお、GeoLife の移動モードは、GPS Point に直接ラベル付けされているのではなく、ある Trajectory のある時間からある時間まで、どの移動モードであったかを示すファイルが別途存在する。

1 つの .plt ファイルには、ユーザ 1 人の 1 日分のデータが含まれている。また、移動モードは全 11 種類存在し、そのモード名は、「walk」, 「subway」, 「car」, 「bike」, 「motorcycle」, 「airplane」, 「taxi」, 「train」, 「boat」, 「run」, 「bus」である。なお、GeoLife の移動モードは、GPS Point に直接ラベル付けされているのではなく、ある Trajectory のある時間からある時間まで、どの移動モードであったかを示すファイルが別途存在する。

4.2. 前処理

4.2.1. Trajectory の分割

GeoLife の .plt ファイルには、ユーザ 1 人の 1 日分のデータが含まれている。つまり、1 つのファイル内に複数の Trajectory が含まれる。そこで、前処理として、Trajectory のデータにおいて GPS の取得間隔が 300 秒以上あいている場合は、前後の Trajectory を異なる Trajectory として分割する。

4.2.2. 移動モードの推定

移動モードは一部の GPS Point にのみ付与されているため、GeoLife の「walk」「run」ラベルが付与されている Trajectory のみを使用するとデータ量が不足する。そのため、研究に利用可能なデータ量を増加させる目的で移動モードを推定する。移動モードを推定する研究はこれまでも行われてきた[17]が、本研究においては、簡単のため、Trajectory の移動速度をもとに移動モードを擬似的に付与する。各移動モードに移動速度の差があるため、本研究では平均 5km/h 以下で移動している Trajectory を歩行者とみなした。結果、本研究で利用可能な Trajectory の数は 2,597 である。

4.3. 評価手法

MAP 推定や最尤推定を用いた位置情報予測を行うため、評価手法はメッシュに対する確率を用いる。具体的には、ある観測点 p_k の n 分後 ($0 < n \leq 10$) に Ground Truth が属しているメッシュと同じメッシュを予測した確率を用いる。各々の Trajectory に対して予測を行い、その平均を求める。2,597 の Trajectory のうち、90%

を学習データ、10%をテストデータとし、10-cross-validation を行う。評価する際は、過去の Trajectory を使用する時間の長さを m 分間 ($0 \leq m \leq 10$) と可変させて評価を行う。

4.4. 実験結果

4.4.1. EM アルゴリズムを用いた MAP 推定によるパラメータ推定

EM アルゴリズムを用いた MAP 推定を行う。本研究ではメッシュ間の遷移確率を求めるために、それぞれのメッシュに対して 15 個以上の Trajectory を通過したのに対してパラメータ推定を行った。Trajectory の通過個数が 0 個を含む 15 個未満の Trajectory に関しては、 d の遷移確率をすべて 0.25 であるとみなした。本研究では移動モードの総数 C_m は 2 と決定した。

4.5. メッシュの移動予測

EM アルゴリズムと単純マルコフ連鎖を組合せて実験を行った。実験結果を図 2 に示す。本研究の結果は予測開始から 2 分後の精度が 20.2%、10 分後の精度が 3.23% となった。




図 2 時間経過と精度の関係

5. おわりに

本研究では、POI 推薦に利用することを目的として、歩行者に対する位置情報の予測を行う手法を提案した。既存研究では、主に自動車を対象としたルート予測、また歩行者を対象とした研究であっても、目的地の予測のみであった。これら既存研究の問題点を解決することを目的として、100m メッシュを用いて遷移確率を MAP 推定で予測し、単純マルコフ連鎖を用いることで、歩行者に対する位置情報予測を行った。10-cross-validation の結果、10 分後の予測精度は、3.23%、2 分後の予測精度は 20% であった。

本研究においては、単純マルコフ連鎖を用いていること、個人の履歴を用いていないことから十分な精度を得ることができていない。今後の課題としては、N 重マルコフ連鎖を用いることで、複数前の状態を予測

に取り入れることにより精度向上を行っていきたい。
さらにメッシュ構築においては、より精度を高めるため4方向ではなく6方向（六角形を用いた分割）を採用することを検討したい。

参 考 文 献

- [1] A. Y. Xue, R. Zhang, Y. Zheng, X. Xie, J. Huang and Z. Xu: "Destination Prediction by Sub-trajectory Synthesis and Privacy Protection against such Prediction", *Proc. of International Conference on Data Engineering*, pp. 254-265, 2013.
- [2] N. Ye, Y. Zhang, R. Wang and R. Malekian: "Vehicle trajectory prediction based on Hidden Markov Model", *KSII Trans. on Internet and Information Systems*, vol. 10, no. 7, pp. 3150-3170, 2016.
- [3] J. A. Alvarez-Garcia, J. A. Ortega, L. Gonzalez-Abril and F. Velasco: "Trip destination prediction based on past GPS log using a Hidden Markov Model," *Expert Systems with Applications* vol.37, no.12, pp.8166-8171, 2010.
- [4] A. Monreale, F. Pinelli, R. Trasarti and F. Giannotti, WhereNext: "A Location Predictor on Trajectory Pattern Mining", *Proc. of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 637-646, 2009.
- [5] J. J. C. Ying, W. C. Lee, T. C. Weng and V. S. Tseng, "Semantic Trajectory Mining for Location Prediction," *Proc. of the 19th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 34-43, 2011.
- [6] J. Yuan, Y. Zheng, X. Xie and G. Sun: "Driving with knowledge from the physical world", *Proc. of the 17th ACM SIGKDD International Conference on Knowledge discovery and data mining*, pp. 316-324, 2011.
- [7] J. Yuan, Y. Zheng, C. Zhang, W. Xie, X. Xie, G. Sun and Y. Huang: "T-drive: driving directions based on taxi trajectories", *Proc. of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 99-108, 2010.
- [8] S. Gambs, K. Marc-Olivier and N. Miguel: "Next Place Prediction using Mobility Markov Chains", *Proc of the First Workshop on Measurement, Privacy, and Mobility*, pp.1-6, ACM, 2012.
- [9] A. Asahara, K. Maruyama, A. Sato and K. Seto: "Pedestrian-movement Prediction based on Mixed Markov-chain Model," *Proc. of the 19th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 25-33, 2011.
- [10] W. Huang, S. Li, X Liu and Y. Ban: "Predicting human mobility with activity change", *International Journal of Geographical Information Science*, vol.29, no.9, pp. 1569-1587, 2015.
- [11] H. Yuan, Y. Qian, R. Yang and M. Ren: "Human Mobility Discovering and Movement Intention Detection with GPS Trajectories," *Decision Support Systems*, Vol.63, pp.39-45, 2013.
- [12] A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei and S. Savarese: "Social LSTM: Human Trajectory Prediction in Crowded Spaces," *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 961-971, 2016.
- [13] J. Zhang, Y. Zheng and D. Qi: "Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction," *Proc. of the 31st AAAI Conference on Artificial Intelligence*, pp.1302-1308, 2017.
- [14] Y. Zheng, L. Zhang, X. Xie and W. Y. Ma, "Mining interesting locations and travel sequences from GPS trajectories", *Proc. of International conference on World Wide Web*, pp.791-800, 2009.
- [15] Y. Zheng, Q. Li, Y. Chen, X. Xie and W. Y. Ma: "Understanding Mobility Based on GPS Data", *Proc. of ACM conference on Ubiquitous Computing*, pp.312-321, ACM, 2008.
- [16] Y. Zheng, X. Xie, W. Y. Ma: "GeoLife: A Collaborative Social Networking Service among User, location and trajectory", *IEEE Data Engineering Bulletin*. Vol.33, No.2, pp. 32-40. 2010.
- [17] A. Kinoshita, A. Takasu, K. Aihara, J. Ishii, H. Kurawasa, H. Sato, M. Nakamura and J. Adachi: "GPS Trajectory Data Enrichment based on a Latent Statistical Model," *Proc. of The International Conference on Pattern Recognition Applications and Methods*, pp.255-262, 2016.