

個人適応型観光のためのユーザ体験推薦

山岸立¹ 馬強²

既存の観光推薦システムの多くは個人の好みに対する考慮が不十分である。特に場所の推薦に関する研究が多くは人気度や評判で場所をランキングしており、そこで何ができるかを明らかにしていないためユーザにとってわかりにくくなっている。そこで本研究では、FlickrやInstagramなどの投稿を対象にユーザの行動を分析する確率生成モデルとそれに基づくユーザの求めるユーザ体験を推薦するシステムを提案する。提案したシステムでは、ユーザ体験の4要素(Who, When, Where, What)をモデリングし、旅行者がどこで何をしたかを明らかにしながら、それに基づいてユーザのしたいことを体験できる場所を推薦する。

1 はじめに

既存の観光推薦システムやサービスは過度に有名な観光地に偏っており、誰が調べても同じ結果を示すため、人気の高い場所しか示せないことが多い。このことは観光地におけるオーバーツーリズムを誘発し、観光地にも観光客にも負の影響をもたらす。それらの観光の問題を解決するためには個人化適応型や分散指向型の観光推薦システムが必要となる。観光客の好みにあった場所を推薦しながら、色んな場所やスポットに観光客を分散させることを目指す[19][20]。

ジャンルなどの属性情報を利用して観光客の好みにあった観光地・スポットを推薦する手法が多く提案されている。しかしながら、これらの既存の推薦システムは場所のみを推薦することが多く、ユーザのその場での行動について考慮が不十分である。これに対して、観光は「光」を「観る」のであることに着目し、景色や景観物に着目した観光地評価・分析手法とそれに基づく推薦手法が提案されている[3][9]。本研究では、さらに「観る」以外の観光行動、例えば、「食べる」「遊ぶ」「ショッピング」などに着目し、観光客の「したいこと」から推薦を行うユーザ体験型推薦手法を提案する。我々は先行研究[15]と同様に、ユーザ体験は行動の主体を表すWho、時間を表すWhen、場所を表すWhere、そして行動自体をあらわすWhatである。

本研究では、この4つの要素(Who, When, Where, What)をトピックモデルを用いて分析することでその人の趣味嗜好および場所の特性を考慮して、推薦システムで複数の体験を推薦する手法を提案する。推薦システムの構成図を図1に示す。推薦システムは分析手法でデータからユーザの行動を分析し、その結果を用いて新しいユーザにそのユーザの趣味嗜好に合うようにユーザ体験




図1: 推薦システムの全体構成図

を推薦する。

本研究における貢献は以下である。

- 観光における推薦システムでありながら、場所だけでなくその場における行動まで推薦することができる。(3節)
- InstagramやFlickrに公開されている画像とそのメタデータを用いて、ユーザの体験を分析する確率生成モデルを提案する。(3節)
- ユーザや場所を「行動」に基づいて複数グループに分割し、そのグループごとにその人々の趣味嗜好との関係を確率的に分析する。これにより個々の観光客のデータが少ない、いわゆるコールドスタート問題を緩和する効果がある。(4節)

2 関連研究

Q.YuanらはTwitterを対象にユーザの行動を分析するモデルを提案している[15][16]。Yuanらはユーザの行動をWho, When, Where, Whatで表現し、Twitterのデータを利用して行動分析および予測を行っている。Yuanらの手法は、日常生活で発信される大量の位置情報付きのデータには有効とされているが、個々のユーザのデータ量が少ない観光では適用困難である。そのため、我々のモデルではユーザ体験を表現する潜在変数をモデルに導入し少ないデータでも分析可能にする。

普段の生活圏では決まった行動を取りやすいが、観光においては全く異なる行動指針によって動く。[10]では普段の行動の軌跡の情報量を測ることで最大93%の精度で行動予測できるとする一方で、旅行時の行動は大きな違いがあることも述べている。Point of Interest(POI)分析・推薦の分野でもその普段のよくある行動であるかどうかを見ることが重要となる。特に[8]では、POIの分野で普段の行動かどうか、つまりin townかout of townかによって多くの研究が整理され、まとめられている。

観光の行動予測で最も問題となるのが、同じユーザでの再現性の少なさである。観光においては同じ場所に何回も行くことが少ない。特定の観光地を転々と訪問し、その後は一度も来ないということは少なくない。つまり、ユーザと場所の関係はスパースなものとなりやすい。[2][12][13][14]ではそのような問題に取り組

¹ 学生会員 京都大学大学院情報学研究所
yamagishi@db.soc.i.kyoto-u.ac.jp

² 正会員 京都大学大学院情報学研究所
qiang@i.kyoto-u.ac.jp

み, in townとout of townどちらにも対応できるようなモデルを作っている. 特に[2]は確率モデルでの分析をするものではなく, 協調フィルタリングベースで推薦システムを構成している.

[12][18][19][20]では, データがスパースになる問題に加え, コールドスタート問題に陥ってしまうことに対してグループという概念を導入することによって対応している. それによって, 一人のユーザのデータが少なくてもグループ全体で特徴が捉えられていれば, データのスパース性を緩和した推薦をすることができる. 従来の研究ではグループはユーザまたはアイテムの特徴のみ利用することで分類しているが, 本研究ではユーザ, 時期, 場所, 行動を総合的に分析し, グループに分類している.

3 提案手法

この節ではユーザ体験の分析と推薦手法について説明する. 分析手法では確率生成モデルを用いてユーザの行動データからユーザごとの趣味嗜好を捉える. 推薦手法では分析手法で捉えたユーザの趣味嗜好を用い, その人にあった観光体験を推薦する. 以下, 3.1節で問題を定義し, 3.2節でユーザの行動をモデリングするための観測を説明し, 3.3節でモデルの定義を説明する. 3.4節ではモデルを用いた推薦手法を述べる.

3.1 問題設定

この節では本研究のシステムの入力と出力, モデリングのための背景をまとめる.

本研究におけるユーザ体験とは, 1節で述べた通り4つW(Who, When, Where, What)で構成される. 本研究では, ユーザの観光履歴データからユーザ体験をモデリングする. 画像などの入力データを分析し, そのユーザの興味嗜好を分析し, 相応しい観光体験を推薦する.

データセットはこの4要素を含むものでなくてはならない. このとき先述したFlickrやInstagramのような画像を主体とした投稿データは適している. そのような投稿データには画像と投稿に付随した文章, タグからWhatの要素を検出でき, メタデータとして位置情報と時間が含まれているためである. ここでいう時間は画像を投稿した時間ではなく画像を撮った時間すなわち行動を行ったその時刻をさす. しかし, データセットの時間は時差の影響などで正しい時間を示している場合が少なく, 時期(何月か)を使うこととする. 以上の理由で本研究もこのような画像を主体としたSNSの投稿データをデータセットとしてみなす.

また, 2節で述べたとおり, 観光における行動データの性質としてデータのスパース性が挙げられる. 本研究でもユーザ, 時期, 場所, 行動を総合的にグルーピングする. 似ている趣味嗜好のユーザや場所が同じグループに属するようにする. その結果一人あたりのデータが少なくてもよりその人や場所の趣味嗜好に合いそうなものを推薦することが可能になる.

3.2 観測

分析手法では, ユーザがどのような場所, どのような行動を好むのかをモデリングして, 過去のデータセットから発見する. 本研究では, 以下のような観測に基づいて観光地におけるユーザ体験が決定されると考える.

観測1 趣味嗜好が似ている人は複数人いる. つまり, 趣味嗜好を基準にユーザをいくつかのグループに分割できる. 逆にグループは複数のユーザを持ち, 特定の嗜好を持つことになる. 例えば, あるユーザAとあるユーザBの趣味嗜好が似ている場合, AとBは同じグループに属し, Aがある場所である行動を好むのならばそれがBにも当てはまる可能性が高い.

観測2 訪れる場所はユーザの趣味嗜好によって決定される. 趣味嗜好が似ているならば同じ場所に行く確率が高い. 例えば有名場所が好きな人たちは京都でいう金閣寺や伏見稲荷大社に行くことを好むが, 甘味が好きな人は美味しい甘味処を優先して観光の計画を立てることが多い.

観測3 ユーザの行動は趣味嗜好に依存する. ここでいう行動は, それぞれの訪問場所における, ユーザが行った具体的な動作・アクションを表す. 例えば画像撮影をしたり, 甘味を食べたり, 座禅を組むことは観光地におけるよくある行動である. 趣味嗜好が似ているユーザは同じ行動を行う確率が高い. また, 同じ場所においてユーザが複数の行動を行うこともある.

観測4 行動をする時期は趣味嗜好に影響される. これは国や文化によって異なるかもしれないが, 観光旅行をする時期はその人の行きたい季節に行くことが多い.

観測5 それぞれの場所でする行動はその場所に影響される. その場所でするよくある行動であれば, ユーザもその行動を取る可能性が高い. 有名スポットで写真をとることはその一つの例である.

観測6 それぞれの場所でする行動はその行動の時期に影響される. 例えば紅葉を見に来る人たちは秋に行動し, 海水浴をするのは日本では夏である.

3.3 User Experience Model

3.2節で説明した観測を踏まえて, ユーザ体験を分析する. 分析手法の候補として2つのモデルを構成した. 本研究では観測1, 観測2, 観測3, 観測4のみを取り入れてユーザ体験(Who, When, Where, What)を分析するBase User Experience Model(B-UEM), 全ての観測を入れたSpatiotemporal User Experience Model(ST-UEM)の2つを提案する. 説明するに当たって必要な記号を表1に示す.

3.3.1 Base User Experience Model

本研究のモデルでは, ユーザ, 場所, 時期, 行動を表す単語を観測変数として扱い, 主にグループを潜在変数とする. Base User Experience Model(B-UEM)のグラフィカルモデルを図2に示す. ただし, グラフィカルモデル上の $w_{d,i}$ というのはある投稿 $d(\in D)$ における行動を示す単語のうち i 番目の単語という意味である. グラフィカルモデル上で白丸が潜在変数を表しており, 灰色の背景色の丸が観測変数を表している.

B-UEMでは観測1, 観測2, 観測3, 観測4を下にモデリングしている. このモデルの最大の特徴は4つのWの間に依存関係がないということである. それぞれのWはグループからのみ影響を受

表1: 記号の定義

記号	定義
D	投稿の集合
G	グループの集合
U, L, T	ユーザ, 場所, 時間の集合
W	行動を示す単語の集合
$ D $	投稿(データ)数
$ G $	グループ数
$ U , L $	ユーザ数, 場所数
$ W $	行動を示す単語数
N_w	ある投稿 $d(\in D)$ での行動を示す単語数
g_d	ある投稿 $d(\in D)$ におけるグループ
u_d	ある投稿 $d(\in D)$ におけるユーザ
l_d	ある投稿 $d(\in D)$ における位置情報
w_d	ある投稿 $d(\in D)$ における行動を示す単語
t_d	ある投稿 $d(\in D)$ における時間
θ	グループを与えるカテゴリ分布
π_{g_d}	グループごとのユーザの生成確率分布
ϕ_{g_d}	グループごとの位置情報の生成確率分布
σ_{g_d}	グループごとの行動を示す単語の生成確率分布
μ_{l_d}	場所ごとの行動を示す単語の生成確率分布
τ_{g_d}	グループごとの時間の生成確率分布
ρ_{t_d}	時間ごとの行動を示す単語の生成確率分布
$\alpha, \beta, \gamma, \delta, \kappa$	ハイパーパラメータ
ϵ	

け、他の W に影響を与えることなく条件付き独立を保障している。B-UEMにおける生成過程をAlgorithm 1に示す。

ここからはある投稿データ $d(\in D)$ の元での生成を説明していく。投稿 d にはメタデータが付随しており、実際に観測したユーザ u_d 、観光した場所 l_d 、観光した時期 t_d 、そしてそこで行った行動 $w_d = \{w_{d,0}, \dots, w_{d,N_w}\}$ が観測される。これらは離散分布で表せられるため、Categorical分布からそれぞれ生成される。そのデータごとに、ユーザ、場所、単語、時期のグルーピングが行われる。グループの生成確率分布 θ からグループ g_d を生成し、

$$g_d \sim \text{Categorical}(\theta) \quad (1)$$

となる。ここでのグループは潜在変数である。

観測1より、グループの影響によりユーザは決定する。それゆえ、以下の関係が成り立つ。

$$\begin{aligned} u_d &\sim \text{Categorical}(\pi_{g_d}) \\ \pi_{g_d} &\sim \text{Dirichlet}(\gamma) \end{aligned} \quad (2)$$




図2: B-UEMのグラフィカルモデル

Algorithm 1 B-UEMの生成過程

```

1:  $\theta \sim \text{Dir}(\alpha)$   $\triangleright$  generate priors to groups
2: for  $g$  in  $|G|$  do
3:    $\pi_g \sim \text{Dir}(\gamma)$   $\triangleright$  generate priors to users
4:    $\phi_g \sim \text{Dir}(\beta)$   $\triangleright$  generate priors to locations
5:    $\sigma_g \sim \text{Dir}(\delta)$   $\triangleright$  generate priors to words
6:    $\tau_g \sim \text{Dir}(\kappa)$   $\triangleright$  generate priors to time
7: end for
8: for  $d$  in  $|D|$  do  $\triangleright$  proceed in data
9:    $g_d \sim \text{Categorical}(\theta)$   $\triangleright$  generate group
10:   $u_d \sim \text{Categorical}(\pi_{g_d})$   $\triangleright$  generate user using group
11:   $l_d \sim \text{Categorical}(\phi_{g_d})$   $\triangleright$  generate location using group
12:   $t_d \sim \text{Categorical}(\tau_{g_d})$   $\triangleright$  generate time using group
13:  for  $i$  in  $N_w$  do
14:     $w_{d,i} \sim \text{Categorical}(\sigma_{g_d})$   $\triangleright$  generate words using group
15:  end for
16: end for

```

同様に場所も観測2よりグループごとの場所の生成確率分布 ϕ_{g_d} から生成され、

$$\begin{aligned} l_d &\sim \text{Categorical}(\phi_{g_d}) \\ \phi_{g_d} &\sim \text{Dirichlet}(\beta) \end{aligned} \quad (3)$$

同様に時期も観測4よりグループごとの時期の生成確率分布 τ_{g_d} から生成され、

$$\begin{aligned} t_d &\sim \text{Categorical}(\tau_{g_d}) \\ \tau_{g_d} &\sim \text{Dirichlet}(\kappa) \end{aligned} \quad (4)$$

が成り立つ。最後に行動を示す単語は $w_{d,i}$ で表しているが、この変数が単独でプレートに載っていることから、ユーザや場所が決まる投稿に対して、行動は複数(N_w 個)存在することを示している(観測3)。各単語に対して生成を以下に行う。

$$\begin{aligned} w_{d,i} &\sim \text{Categorical}(\sigma_{g_d}) \\ \sigma_{g_d} &\sim \text{Dirichlet}(\delta) \end{aligned} \quad (5)$$




図3: ST-UEMのグラフィカルモデル

ユーザ、場所、時期、単語は離散分布でCategorical分布で表されるが、今回のモデリングではその事前分布をCategorical分布の共役事前分布であるDirichlet分布にしている。

3.3.2 Spatiotemporal User Experience Model

Spatiotemporal User Experience Model(ST-UEM)も観測変数自体はB-UEMと変わらない。ユーザ、場所、時期、行動を表す単語を観測変数として扱い、主にグループを潜在変数とする。Spatiotemporal User Experience Modelのグラフィカルモデルを図3に示す。

ST-UEMでは観測1, 観測2, 観測3, 観測4をモデリングしたB-UEMに加えて、観測5と観測6を追加してモデリングしている。このモデルでは行動を表す単語の生成には場所と時期の両方の影響を受ける。ユーザ、場所、時期に関してはB-UEMと変わらず条件付き独立を保っている。ST-UEMにおける生成過程をAlgorithm 2に示す。

ここからはある投稿データ $d \in \mathbf{D}$ の元での生成を説明していく。B-UEMと同様に、投稿 d にはメタデータが付随しており、実際に観光したユーザ u_d 、観光した場所 l_d 、観光した時期 t_d 、そしてそこで行った行動 $w_d = \{w_{d,0}, \dots, w_{d,N_w}\}$ が観測される。 u_d, l_d, t_d の生成過程に関してはB-UEMと同様に条件付き独立が保証されているので、式(2)、式(3)、式(4)がそのまま適用できる。

しかし、行動を決める際に制約が発生する。行動に関する単語 w_d の生成には、 l_d と t_d の影響を受ける。例えば、アイスを食べという行動はジェラート屋に行っていたり、7月や8月の時期であったりする確率が高い。しかし、その場所によって趣味嗜好(グループ)、場所、時期による影響の差は異なる。もしユーザがピサの斜塔に行ったら、塔の近くでピサの斜塔を支えるような画像を取る可能性は高い。これは場所による影響がその行動に強く現れている典型例である。また、時期による影響が大きい場所も存在する。本モデルではその影響の度合いに自由度を持たせるためにグループ、場所、時期のどの要素に最も影響を受けるのかというのを変数 λ を用いてモデリングした。 λ は場所によって異なるため、場所 l_d に依存する形で生成される。この変数 λ_{l_d} を用いて $w_{d,i}$ は生成される。具体的には g_d, l_d が生成された後、場所ごとに生成された変数 λ_{l_d} を重みとして扱って行動を示す単語を

Algorithm 2 ST-UEMの生成過程

```

1:  $\theta \sim \text{Dir}(\alpha)$  ▷ generate priors to groups
2: for  $g$  in  $|G|$  do
3:    $\pi_g \sim \text{Dir}(\gamma)$  ▷ generate priors to users
4:    $\phi_g \sim \text{Dir}(\beta)$  ▷ generate priors to locations
5:    $\sigma_g \sim \text{Dir}(\delta)$  ▷ generate priors to words
6:    $\tau_g \sim \text{Dir}(\kappa)$  ▷ generate priors to time
7: end for
8: for  $l$  in  $|L|$  do ▷ proceed in locations
9:    $\mu_l \sim \text{Dir}(\epsilon)$ 
10: end for
11: for  $t$  in  $|T|$  do ▷ proceed in time
12:    $\rho_t \sim \text{Dir}(\iota)$ 
13: end for
14: for  $d$  in  $|D|$  do ▷ proceed in data
15:    $g_d \sim \text{Categorical}(\theta)$  ▷ generate group
16:    $u_d \sim \text{Categorical}(\pi_{g_d})$  ▷ generate user using group
17:    $l_d \sim \text{Categorical}(\phi_{g_d})$  ▷ generate location using group
18:    $t_d \sim \text{Categorical}(\tau_{g_d})$  ▷ generate time using group
19:    $\lambda_{l_d} \sim \text{Multinomial}(1, \eta_{l_d})$  ▷ calculate weights
20:   for  $i$  in  $N_w$  do
21:      $w_{d,i} \sim \lambda_{l_d}^1 \text{Categorical}(\mu_{l_d}) + \lambda_{l_d}^2 \text{Categorical}(\rho_{t_d}) +$   

        $\lambda_{l_d}^3 \text{Categorical}(\sigma_{g_d})$  ▷ generate words using group
22:   end for
23: end for

```

生成する。式で書くと以下ようになる。

$$\lambda_{l_d} \sim \text{Multinomial}(1, \eta_{l_d}) \quad (6)$$

$$\begin{aligned}
w_{d,i} \sim & \lambda_{l_d}^1 \text{Categorical}(\mu_{l_d}) \\
& + \lambda_{l_d}^2 \text{Categorical}(\rho_{t_d}) \\
& + \lambda_{l_d}^3 \text{Categorical}(\sigma_{g_d}) \quad (7) \\
\mu_{l_d} \sim & \text{Dirichlet}(\epsilon) \\
\rho_{g_d} \sim & \text{Dirichlet}(\iota) \\
\sigma_{g_d} \sim & \text{Dirichlet}(\delta)
\end{aligned}$$

ただし、 $\lambda_{l_d} = (\lambda_{l_d}^1, \lambda_{l_d}^2, \lambda_{l_d}^3)$ とし、多項分布の1つめの引数は何回生成するかを表すものである。

3.4 モデルの応用

2つのUser Experience Modelでは場所だけでなく、行動や時期もモデリングしている。それらの要素を使って場所だけでなく他の要素の推薦も可能となる。この節ではUser Experience Modelの応用例を述べていく。

3.4.1 行動の推薦

観光において、場所と同様に最も先に決めることは何をするかということである。故に何をやりたいかを推薦することは観光の方針をおすすめることと同様である。あるユーザ u に対してどの行動 w を推薦するかは確率 $p(w|u)$ を計算し、それをスコアとしてソートすることで得られる。 $p(w|u)$ の計算の仕方はB-UEMとST-UEMで異なる。

B-UEMでは他の観測変数による影響がないため、グループによる影響しかない。

$$p(w|u) = \sum_{g \in G} p(w|g)p(g|u) = \sum_{g \in G} p(w|g) \frac{p(u|g)p(g)}{p(u)} \quad (8)$$

$$= \frac{1}{p(u)} \sum_{g \in G} p(w|g)p(u|g)p(g) \quad (9)$$

$$\propto \sum_{g \in G} p(w|g)p(u|g)p(g) = \sum_{g \in G} \sigma_g(w)\pi_g(u)\theta(g) \quad (10)$$

式(8)ではベイズの公式を用いている。

ST-UEMでは場所と時期の計算が必要である。式(9)まではB-UEMと同じである。

$$p(w|u) \propto \sum_{g \in G} p(w|g)p(u|g)p(g) \quad (11)$$

$$= \sum_{g \in G} p(u|g)p(g) \sum_{t \in T} \sum_{l \in L} p(w|g, l, t) \quad (12)$$

$$= \sum_{g \in G} \pi_g(u)\theta(g) \sum_{t \in T} \sum_{l \in L} \{\lambda_l^1 \mu_l(w) + \lambda_l^2 \rho_t(w) + \lambda_l^3 \sigma_g(g)\} \phi_g(l) \tau_g(t) \quad (13)$$

3.4.2 場所を与えたときの行動の推薦

観光において場所が先に決まったにもかかわらず、何をすれば良いかわからない時がある。この状況は特に観光場所の中で複数の行動が起こりうる場所に行くときに起こる。あるユーザー u において l が決定しているときにどの行動を推薦するかは $p(w|u, l)$ を計算し、スコアを得る。

B-UEMでは3.4.1節と同様にして以下の式を得る。

$$p(w|u, l) \propto \sum_{g \in G} \sigma_g(w)\pi_g(u)\phi_g(l)\theta(g) \quad (14)$$

ST-UEMでも次のような式となる。

$$p(w|u, l) \propto \sum_{g \in G} \pi_g(u)\phi_g(l)\theta(g) \quad (15)$$

$$\sum_{t \in T} \{\lambda_l^1 \mu_l(w) + \lambda_l^2 \rho_t(w) + \lambda_l^3 \sigma_g(g)\} \tau_g(t) \quad (16)$$

3.4.3 行動を与えたときの場所の推薦

観光の計画を決めるときにやりたいことは決まっているけど、どこに行けば良いかわからないということは多い。そのような時はこの推薦を利用することで場所を決定することができる。あるユーザー u に対して行動 w が与えられており、このときの $p(l|u, w)$ を考える。

B-UEMでは3.4.2節と同様のやり方で計算できる。

$$p(l|u, w) \propto \sum_{g \in G} \phi_g(l)\sigma_g(w)\pi_g(u)\theta(g) \quad (17)$$

ST-UEMでは次のようになる。

$$p(l|u, w) \propto \sum_{g \in G} \pi_g(u)\phi_g(l)\theta(g) \quad (18)$$

$$\sum_{t \in T} \{\lambda_l^1 \mu_l(w) + \lambda_l^2 \rho_t(w) + \lambda_l^3 \sigma_g(g)\} \tau_g(t) \quad (19)$$

表2: データセットの統計情報

City	Users	Places	Images
Kyoto	1326	1512	66865
Budapest	830	38	16997
Delhi	243	23	3361
Edinburgh	1279	28	30495
Glasgow	529	27	10289
Osaka	401	27	7028
Perth	137	22	3404
Toronto	1214	29	32351
Vienna	990	28	29614

3.4.4 ユーザ体験推薦

この推薦はこの推薦システムの主たる機能である。観光におけるシナリオで場所だけでなく行動、そして時期もセットにして推薦する。あるユーザー u に対して場所 l 、時期 t 、行動 w で推薦するため、 $p(l, t, w|u)$ を考える。

B-UEMでは次の計算でスコアを得られる。

$$p(l, t, w|u) \propto \sum_{g \in G} \phi_g(l)\tau_g(t)\sigma_g(w)\pi_g(u)\theta(g) \quad (20)$$

ST-UEMでも次のようになる。

$$p(l, t, w|u) \propto \sum_{g \in G} \pi_g(u)\phi_g(l)\tau_g(t)\theta(g) \quad (21)$$

$$\{\lambda_l^1 \mu_l(w) + \lambda_l^2 \rho_t(w) + \lambda_l^3 \sigma_g(g)\} \quad (22)$$

4 実験

本節ではモデル構成のための実験であるAblation Studyとモデルの有効性を示す比較実験の説明を行う。まず、実験に用いるデータセットについて説明し、次にそれぞれの実験について説明する。

4.1 データセット

本実験では、2つの異なるデータセットを扱う。一つはYFCC100M Kyoto[11]でもう一つは8都市を含むUser Visitsデータセット[6][7]である。両データセットともFlickrの投稿データで構成されている。YFCC100M Kyotoではクラスタリングによって場所を離散分布として扱うこととした。Kyotoデータセットに比べてUser Visitsデータセットの都市は半分以下のデータ数であり、ユーザーの訪れた都市も少ない。行動を示す単語に関しては、各画像に対してシーン検出[17]を適用して抽出した。本実験に持ちこるデータセットの統計を表2に示す。

4.2 Ablation Study

Ablation StudyではUser Experience Model構築のための実験を行う。具体的には観測5、観測6の有効性を試し、どのモデルが最も有効なのかを示す。B-UEM、ST-UEMの他、新しく2つモデルを加えて比較をする。データセットはYFCC100M Kyotoを用いて学習を行う。




図4: Ablation Study 実験結果

4.2.1 比較モデル

ST-UEMはB-UEMに観測5と観測6を加えたものである。観測5または観測6の有効性を知るためにはそれぞれの有無でモデルを構築し、比較する必要がある。B-UEMに観測5を加えたものをS-UEM、B-UEMに観測6を加えたものをT-UEMとする。

S-UEMはB-UEMに対して場所の制限が加わったものである。つまり場所が決定したことで行動の決定に影響を与える。行動は場所からの影響とグループからの影響を受けるのでそれぞれから影響を受ける度合いを λ で制御している。あるデータ $d(\in D)$ に対して行動を表す単語 w_d の生成方法は、場所 l_d が決定した状態で以下の式で導かれる。

$$\lambda_{l_d} \sim \text{Multinomial}(1, \eta_{l_d}) \quad (23)$$

$$w_{d,i} \sim \lambda_{l_d}^1 \text{Categorical}(\mu_{l_d}) + \lambda_{l_d}^2 \text{Categorical}(\sigma_{g_d}) \quad (24)$$

$$\mu_{l_d} \sim \text{Dirichlet}(\epsilon)$$

$$\sigma_{g_d} \sim \text{Dirichlet}(\delta)$$

ただし、 $\lambda_{l_d} = (\lambda_{l_d}^1, \lambda_{l_d}^2)$ であり、Multinomial分布の第1項は何回生成するかを示すものである。

T-UEMはB-UEMに対して時期の制限が加わったものである。時期が決定したことで行動の決定に影響を与える。行動は時期からの影響とグループからの影響を受けるのでそれぞれから影響を受ける度合いを λ で制御する。あるデータ $d(\in D)$ に対して行動を表す単語 w_d の生成方法は、時期 t_d が決定した状態で以下の式で

導かれる。

$$\lambda_{t_d} \sim \text{Multinomial}(1, \eta_{t_d}) \quad (25)$$

$$w_{d,i} \sim \lambda_{t_d}^1 \text{Categorical}(\rho_{t_d}) + \lambda_{t_d}^2 \text{Categorical}(\sigma_{g_d}) \quad (26)$$

$$\rho_{t_d} \sim \text{Dirichlet}(\kappa)$$

$$\sigma_{g_d} \sim \text{Dirichlet}(\delta)$$

ただし、 $\lambda_{t_d} = (\lambda_{t_d}^1, \lambda_{t_d}^2)$ であり、Multinomial分布の第1項は何回生成するかを示すものである。

4.2.2 実験設定

今回のモデルでは学習をPyroで実装されたStochastic Variational Inference[1]で行う。最適化手法としてAdam[4]を用いており、その学習率は0.001とした。データセットの90%を訓練データとして扱い、残りをテストデータとして評価した。グループの数に3~15を与えてグループの数に寄る推薦の質への影響も見ることとした。Step数は学習が収束するために $5000 + 1500 * |G|$ 回まわした。

各モデルにおける行動への影響を考慮した推薦の質を評価するため、3.4節で説明した行動の推薦と場所を与えたときの行動の推薦を行い、それぞれPrecision@10, Recall@10を考える。

4.2.3 実験結果

実験結果を図4に示す。行動推薦の結果ではS-UEMが他のモデルと比べて大幅に悪い結果を示している。この結果は場所を決定した際の行動推薦でも見られ、場所における行動への影響は




図5: 実験結果(Precision, Recall)

表3: 実験結果(Precision, Recall and F-value (k=10))

	User Visitの都市			Kyoto			Average		
model	pre@10	rec@10	F@10	pre@10	rec@10	F@10	pre@10	rec@10	F@10
B-UEM	0.147	0.489	0.226	0.050	0.070	0.058	0.099	0.279	0.142
ST-UEM	0.141	0.490	0.218	0.050	0.081	0.062	0.096	0.286	0.140




図6: Kyotoデータセットにおける訓練データの割合を変えた時のPrecision@10, Recall@10

ないことが考えられる。また、T-UEMやST-UEMがB-UEMより悪いことから時期から行動への影響も大きくあるとは言えない。ST-UEMがS-UEMより良いのは場所による悪影響が時期による影響で緩和されたことによるものと考えられる。以上より観測5に関しては否定せざるを得ない結果が得られた。また、グループの数に関してはグループの数が高いほど推薦自体はよくなる傾向にあることがわかった。

4.3 比較実験

この節では場所の推薦に着目した比較実験を2つのデータセットを使って行う。比較実験では提案した2つのモデルと協調フィルタリングベースの先行研究であるGeoMF++[5]を扱う。評価

にはPrecision, RecallとF値を扱う。

また、少ないデータの状態で推薦の質が落ちないことを示すため、20%, 50%, 80%でランダムに訓練データを選んだ時の評価もおこなった。データセットはYFCC100M KyotoとUser Visitsデータセットの両方を用いた。

4.3.1 パラメータ設定

今回のモデルでは学習をPyroで実装されたStochastic Variational Inference[1]で行う。最適化手法としてAdam[4]を用いており、その学習率は0.001とした。ここからはハイパーパラメータをどのように与えるかを述べる。 α の場合、 $|G|$ 次元となり、グループに影響される要素のハイパーパラメータ $\beta, \gamma, \delta, \kappa$ は $|G| * |L|, |G| * |U|, |G| * |W|, |G| * |T|$ 次元となる。また、ST-UEMで単語に左右する要素である μ と ρ はそれぞれ共役事前分布としてDirichlet分布 ϵ, ι を使用しており、このハイパーパラメータはそれぞれ $|L| * |W|, |T| * |W|$ となる。いずれのパラメータも1を初期値とする。また、もう一つハイパーパラメータとしてグループの数 $|G|$ を決める必要がある。今回の比較実験では $|G| = 10$ とする。Step数はデータの規模によって収束にかかる時期が依存するため、最低5000, 最大15000回で回すことにした。また、GeoMF++に関してはハイパーパラメータとして潜在空間の次元 K と α が存在するが、 K に関しては $K = 10$, α に関しては事前に $\alpha = 5, 10, 20, 30$ でグリッドサーチを行い $\alpha = 20$ を

適用する。最大イテレーション数は15にした。

4.3.2 実験結果

それぞれのモデルに対してユーザごとにトップK推薦を行った。比較実験では主にPrecisionとRecallを評価している。確率生成分布を用いていることから、計算の度に値が変わるために各モデルに対して10回学習を行い平均を計上した。

訓練データの割合が80%における結果を図5に示す。図が示す通り、我々のモデルはGeoMF++を上回っている。トップ5とトップ10に関しては全ての都市で上回ったものの、Recall@1に関してはGeoMF++がDelhi, Glasgow, Osaka, Perthの4都市で上回っている。これらの都市は他の都市に比べてデータ数が少なく、その場合はGeoMF++の方が1番目にGround Truthを推薦する能力が高いことを示している。

また、Kyotoに関してはどのモデルについても他の都市に比べてパフォーマンスが悪くなっている。これは場所の候補がまずUser Visitsデータセットより最小でも39倍以上多いことが起因する。しかし、Kyotoでは他の都市よりも2つのUser Experience ModelとGeoMF++の差が大きい。これはよりスパースなデータにも2つのUser Experience Modelの方がパフォーマンスが上回っていると言える。

次にデータの数による妥当性を判断する。訓練データの割合を変えて実験し、そのKyotoにおけるTop 10推薦の結果を図6に示す。ここでKyotoを選んだのはKyotoデータセットが規模が大きく、最もデータの割合による影響が大きいためである。この結果についてもどの訓練データの割合でも2つのUser Experience ModelはGeoMF++のパフォーマンスをPrecision, Recallで上回っている。これは我々のモデルの方がスパースなデータに対しても推薦の強靭さがあることを示している。

B-UEMとST-UEMを比較すると、表3が示す通りあまり大きな差は見られなかった。これは時期や場所の行動に対する影響が我々が予想したほどないことが理由としてあげられる。

以上、この比較実験では観光においては日常の動きをモデリングしたPOI推薦の手法とは異なる手法が必要であることを示した。また、B-UEMがそのシンプルさからST-UEMよりも有意であると考えられた。

5 まとめ

本研究では個人化した観光に対する推薦を実現するために、観光の体験を分析し趣味嗜好を推論するシステムを提案した。体験の分析ではWho, When, Where, Whatの4要素に着目し、6つの観測を考慮することでモデリングを行った。また、潜在変数をモデルに加えることでデータのスパース性に対応した。実験では最新のPOI推薦の手法と比較し、提案手法が推薦の質で上回ることを示した。

謝辞

本研究の一部は総務省SCOPE(172307001,201607008)による。

参考文献

- [1] Eli Bingham, Jonathan P. Chen, Martin Jankowiak, Fritz Obermeyer, Neeraj Pradhan, Theofanis Karaletsos, Rohit Singh, Paul A. Szerlip, Paul Horsfall, and Noah D. Goodman. Pyro: Deep universal probabilistic programming. *J. Mach. Learn. Res.*, 20:28:1–28:6, 2019.
- [2] Gregory Ferenca, Mao Ye, and Wang-Chien Lee. Location recommendation for out-of-town users in location-based social networks. In *CIKM2013*, pages 721–726, 2013.
- [3] Min Ge, Chenyi Zhuang, and Qiang Ma. Robust visual object clustering and its application to sightseeing spot assessment. *Multim. Tools Appl.*, 78(12):17135–17164, 2019.
- [4] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv:1412.6980*, 2014.
- [5] Defu Lian, Kai Zheng, Yong Ge, Longbing Cao, Enhong Chen, and Xing Xie. Geomf++ scalable location recommendation via joint geographical modeling and matrix factorization. *ACM Transactions on Information Systems*, 36(3):1–29, 2018.
- [6] Kwan Hui Lim, Jeffrey Chan, Christopher Leckie, and Shanika Karunasekera. Personalized tour recommendation based on user interests and points of interest visit durations. In *IJ-CAI2015*, pages 1778–1784, 2015.
- [7] Kwan Hui Lim, Jeffrey Chan, Christopher Leckie, and Shanika Karunasekera. Towards next generation touring: Personalized group tours. In *ICAPS2016*, pages 412–420, 2016.
- [8] Yiding Liu, Tuan-Anh Nguyen Pham, Gao Cong, and Quan Yuan. An experimental evaluation of point-of-interest recommendation in location-based social networks. *VLDB2017*, 10(10):1010–1021, 2017.
- [9] Yizhu Shen, Min Ge, Chenyi Zhuang, and Qiang Ma. Sightseeing value estimation by analysing geosocial images. *Int. J. Big Data Intell.*, 5(1/2):31–48, 2018.
- [10] Chaoming Song, Zehui Qu, Nicholas Blumm, and Albert-László Barabási. Limits of predictability in human mobility. *Science*, 327(5968):1018–1021, 2010.
- [11] Junjie Sun, Tomoki Kinoue, and Qiang Ma. A city adaptive clustering framework for discovering pois with different granularities. In Sven Hartmann, Josef Küng, Gabriele Kotsis, A. Min Tjoa, and Ismail Khalil, editors, *DEXA2021*, pages 425–434, 2020.
- [12] Weiqing Wang, Hongzhi Yin, Ling Chen, Yizhou Sun, Shazia Sadiq, and Xiaofang Zhou. Geo-sage: A geographical sparse additive generative model for spatial item recommendation. In *CIKM2015*, pages 1255–1264. ACM, 2015.
- [13] Hongzhi Yin, Bin Cui, Xiaofang Zhou, Weiqing Wang, Zi Huang, and Shazia Sadiq. Joint modeling of user check-in behaviors for real-time point-of-interest recommendation. *ACM Transactions on Information Systems*, 35(2):11, 2016.
- [14] Hongzhi Yin, Yizhou Sun, Bin Cui, Zhiting Hu, and Ling Chen. Lcars: a location-content-aware recommender system. In *KDD2013*, pages 221–229, 2013.
- [15] Quan Yuan, Gao Cong, Zongyang Ma, Aixin Sun, and Nadia Magnenat Thalmann. Who, where, when and what: discover spatio-temporal topics for twitter users. In *KDD2013*, pages 605–613, 2013.
- [16] Quan Yuan, Gao Cong, Kaiqi Zhao, Zongyang Ma, and Aixin Sun. Who, where, when, and what: A nonparametric bayesian approach to context-aware recommendation and search for twitter users. *ACM Transactions on Information Systems*, 33(1):2, 2015.
- [17] Bolei Zhou, Agata Lapedriza, Aditya Khosla, Aude Oliva, and Antonio Torralba. Places: A 10 million image database for scene recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017.
- [18] Chenyi Zhuang, Qiang Ma, and Masatoshi Yoshikawa. Sns user classification and its application to obscure poi discovery. *Multimedia Tools and Applications*, 76(4):5461–5487, 2017.
- [19] 馬強. 観光の分散化と個人化の実現に向けたユーザ生成コンテンツの分析と利活用技術について. システム/制御/情報, 63(1):32–37, 2019.
- [20] 馬強 et al. 観光情報学の最前線-観光の分散化と個人化を促進する集合知活用情報技術. 情報処理, 58(3):220–226, 2017.