

LBSNにおけるユーザアクティビティのトピック分析

森田紗椰^{†,a} 熊野雅仁^{†,b} 小堀聡^{†,c} 木村昌弘^{†,d}

† 龍谷大学大学院理工学研究科電子情報学専攻 †† 龍谷大学理工学部電子情報学科

a) *t18m022@mail.ryukoku.ac.jp* b) *kumano@rins.ryukoku.ac.jp*c) *kobori@rins.ryukoku.ac.jp* d) *kimura@rins.ryukoku.ac.jp*

概要 位置情報ベースのソーシャルネットワークサービス (LBSN) の普及に伴い、都市観光における人々のアクティビティについての大量の観測データを有効活用することが期待されている。本研究では、観光マーケティングへの活用基盤とするために、トピックモデル LDA (Latent Dirichlet Allocation) による分析法を LBSN でのユーザアクティビティ分析に拡張し、観光都市における人々の POI (point-of-interest) 群への訪問行動に対して、時間情報に依存しないそのトピック構造を行動の指向性の観点から分析する枠組みを与える。そして、Foursquare データを用いて観光マーケティングの視点から、東京およびニューヨークにおけるユーザアクティビティのトピック構造を分析する。

キーワード ソーシャルメディアマイニング, 位置情報サービス, トピック分析, 観光マーケティング

1 はじめに

ソーシャルメディアや位置情報サービスの発達と普及によって、都市観光における人々のアクティビティについての大量の観測データが得られるようになり、人々が観光スポットなどを訪問する際の特徴的行動パターンをそのようなビッグデータに基づいて理解し、その都市の観光マーケティングへ活用することが期待されるようになってきた [1,2]。Foursquare Swarm や Facebook Places などの位置情報ベースのソーシャルネットワークサービス (LBSN) では、その都市の観光スポットや有名店舗などが POI (point-of-interest) として登録されており、それら POI 群へのユーザ達のチェックイン情報が観測可能である。したがって、近年、LBSN におけるユーザ達の過去のチェックイン情報に基づき、近い将来の POI 訪問イベントを予測する問題についての研究が注目されている。

Chen ら [3], Feng ら [4] および Zhang ら [5] は、離散的な時間軸の上でこの予測問題を研究した。また Liu ら [6] は、この問題を連続的な時間軸上に拡張して論じた。人々の行動は時間帯で変化しうるので、Gao ら [7] や Yuan ら [8] は時間帯を考慮することにより予測性能の改善を試みた。Yang ら [9] は、LBSN でのユーザの POI 訪問行動における時空間的嗜好を抽出することについて研究している。一方、Hu と Ester [10] は、Twitter データに対し時間情報を考慮せずにユーザ達の空間的トピックを抽出することについて論じた。上記のように、LBSN におけるユーザ達の POI 群への訪問行動データに関しては、すでに多様な時空間的分析が試みられているが、本研究では、実際の観光マーケティングへの活用

基盤とするために、その第一歩として、与えられた観光都市に対して時間情報を考慮しないトピック群を抽出し、それらの特徴を詳細に分析することを考える。

ところで、文書コーパスのトピック分析に関して、Griffiths と Steyvers [11] は、トピックモデル LDA (Latent Dirichlet Allocation) [12] を効果的に推論する Markov chain Monte Carlo アルゴリズムを与え、それを用いて論文誌 PNAS のアブストラクト文書群のトピック構造を論文カテゴリーの観点も含めて分析した。本研究では、彼らの研究を LBSN でのユーザアクティビティ分析に拡張し、観光都市における人々の POI 群への訪問行動に対して、時間情報に依存しないそのトピック構造を行動の指向性の観点から分析する枠組みを与える。そして、Foursquare データ [9] を用いて観光マーケティングの視点から、東京およびニューヨークにおけるユーザアクティビティのトピック構造を詳細に分析する。

2 トピックモデル

指定された観光都市における LBSN でのユーザアクティビティを、トピックモデル LDA [12] に基づいて分析することを考える。ユーザ全体の集合を \mathcal{U} とし、POI 全体の集合を \mathcal{W} とする。ここに、 \mathcal{W} の要素数は、 $|\mathcal{W}| = W$ である。各ユーザ $u \in \mathcal{U}$ のアクティビティを、 $N(u)$ 個の POI の列、

$$\mathbf{w} = (w_1, \dots, w_{N(u)})$$

と同一視する。ただし、 $w_n \in \mathcal{W}$ は u が第 n 番目に訪問した POI を表しており、 $N(u)$ は u が訪問した POI の総数である。また、ユーザアクティビティの観測データ全体を、

$$D = \{\mathbf{w}(u) | u \in \mathcal{U}\}$$

とする．ここに、 $\mathbf{w}(u)$ は、ユーザ u のアクティビティを表している．

LDA では、ユーザアクティビティの観測データ D に対して、潜在トピック総数 K を固定し、以下の様な生成過程を仮定する．最初に、すべての $k = 1, \dots, K$ に対して、次の様に Dirichlet 分布から W 次元多項分布 $\phi^{(k)}$ を生成する．

$$\phi^{(k)} \sim \text{Dirichlet}(\beta)$$

そして、各ユーザ $u \in \mathcal{U}$ のアクティビティ \mathbf{w} を以下の様に生成する．まず、次の様に Dirichlet 分布から K 次元多項分布 $\theta^{(u)}$ を生成する．

$$\theta^{(u)} \sim \text{Dirichlet}(\alpha)$$

次に、すべての $n = 1, \dots, N(u)$ に対して、トピック z_n と POI w_n を次の様に多項分布から生成する．

$$\begin{aligned} z_n | \theta^{(u)} &\sim \text{Multinomial}(\theta^{(u)}) \\ w_n | z_n, \phi^{(z_n)} &\sim \text{Multinomial}(\phi^{(z_n)}) \end{aligned}$$

ただし、 α と β はハイパーパラメータである．

3 ユーザアクティビティのトピック分析

3.1 トピックモデルの推定

本研究では、Griffiths と Steyvers [11] によって与えられた、Gibbs サンプリングを用いて各 POI w にトピック $z(w)$ を割り当てていく Markov chain Monte Carlo アルゴリズムに基づいて、ユーザアクティビティの観測データ D から LDA を学習する．各 $u \in \mathcal{U}$ に対して、 $\mathbf{w}(u) \in D$ のトピック列を $\mathbf{z}(\mathbf{w}(u))$ とし、 $Z = \{\mathbf{z}(\mathbf{w}(u)) | u \in \mathcal{U}\}$ とする．

まず、潜在トピック数 K を指定し、LDA のパラメータ ϕ と θ の値を、 $k = 1, \dots, K$ に対して次の様に推定する．

$$\begin{aligned} \hat{\phi}_w^{(k)} &= \frac{n_w^{(k)} + \beta}{n^{(k)} + W\beta} \quad (w \in \mathcal{W}) \\ \hat{\theta}_k^{(u)} &= \frac{m_k^{(u)} + \alpha}{m^{(u)} + K\alpha} \quad (u \in \mathcal{U}) \end{aligned}$$

ここに、事後確率 $P(Z | D)$ からのサンプリングに対して、 $n_w^{(k)}$ は POI w がトピック k に割り当てられた回数を表し、 $n^{(k)}$ はトピック k に割り当てられた総回数を表し、 $m_k^{(u)}$ はユーザ u のアクティビティの中でトピック k に割り当てられた回数を表し、 $m^{(u)}$ はユーザ u のアクティビティの中で割り当てられたトピックの総数を表している．

潜在トピック数 K の推定については、ホールドアウト法または交差検定により行う．テストデータにおける

性能評価については、ユーザ u が POI w を訪問する確率 $P(u \rightarrow w)$ を、

$$P(u \rightarrow w) = \sum_{k=1}^K \hat{\theta}_k^{(u)} \hat{\phi}_w^{(k)}$$

で予測し、ランキング上位での精度 (P@5 および P@10) またはテストデータの予測尤度により評価する．

3.2 ユーザ行動の指向性とトピックの関係分析

まず、推定したパラメータ $\{\hat{\phi}_w^{(k)}\}$ を用いて、各トピック k を関連する POI 群 $\{w\}$ により説明する．また、推定したパラメータ $\{\hat{\theta}_k^{(u)}\}$ を用いて、各ユーザ u のトピック嗜好性を調べる．本研究では、特に、ユーザ行動の指向性の指標を導入し、 $\{\hat{\theta}_k^{(u)}\}$ を用いてそれとトピックとの関係性を分析する．

ユーザ行動の指向性の指標として、行動する時間帯、行動する曜日および、訪問する POI のカテゴリーの 3 つの観点考えた．特に、行動する時間帯の観点では、「午前 6 時から午前 11 時まで」「午前 11 時から午後 4 時まで」「午後 4 時から午後 9 時まで」「午後 9 時から翌朝の午前 6 時まで」の 4 つの時間帯への分割に焦点をあてた．さて、上記のような指標を一つ導入して、ユーザ行動の指向性を A_1, \dots, A_L の L 個のクラスに分割したとする．このとき、各ユーザ $u \in \mathcal{U}$ の行動指向性のクラスを次の様に定義する．まず、 u の POI への訪問回数の平均値と標準偏差を、それぞれ $\mu(u)$ と $\sigma(u)$ とする．そして、各クラス A_ℓ に対して、 u が A_ℓ に属する POI 訪問アクティビティを $(\mu(u) + \sigma(u))$ 回以上行っているならば、 u は A_ℓ に属すると定義する．もし u が属するクラスが存在しないならば、 u はその観点での「行動指向性なし」というクラス A_{L+1} に属すると定義する．

各トピック k に対するユーザ行動指向性のクラス A_ℓ の関係度 $R_{\ell,k}$ ($\ell = 1, \dots, L+1$; $k = 1, \dots, K$) を次の様に定義する．

$$R_{\ell,k} \propto \sum_{u \in A_\ell} \hat{\theta}_k^{(u)}$$

ただし、 $\sum_{\ell=1}^{L+1} R_{\ell,k} = 1$ である．本研究では、 $\{R_{\ell,k}\}$ を用いて、LDA に基づいたユーザ達の POI 訪問行動におけるトピック構造と、ユーザ行動の指向性の関係を分析する．

4 実験

4.1 実験データ

Foursquare の check-in データセット [9] に含まれる、2012 年 4 月 3 日から 2013 年 2 月 16 日までのニューヨークと東京に関するデータのうち、東京データを用いた結果を報告する．東京データは POI 数 7,873、ユーザ

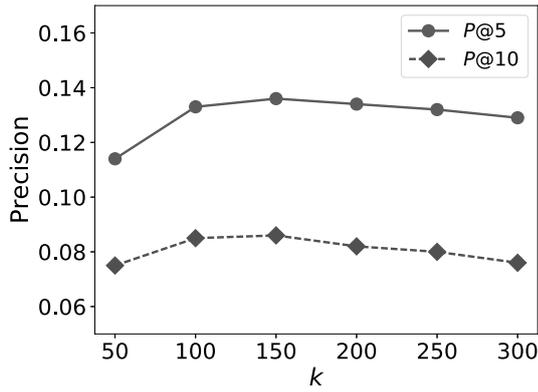


図 1: トピック数 K に対する POI 訪問行動の予測精度

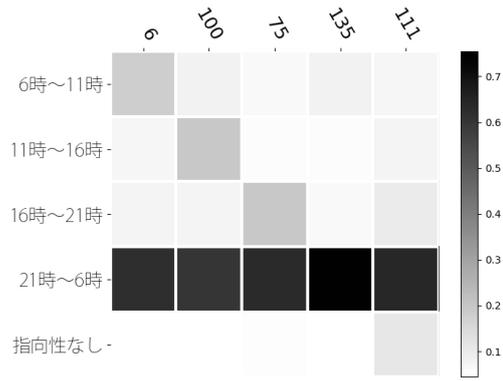
数 2,293 人, check-in 総数 575,703 であった. ここでは, 頁数の関係から, 2012 年の 5 月 1 日から 6 月 30 日までの 2 か月を学習期間, 2012 年の 7 月 1 日から 7 月 31 日までの 1 か月を予測期間とした場合の結果を報告する. それらの期間における check-in 数は 5 月が 73,643, 6 月が 50,000, 7 月が 50,634, ユーザ総数は 1,926 人であった. トピック構造の分析では, 5 月と 6 月における 2 か月のデータで LDA を学習した結果を報告する.

4.2 予測性能の評価

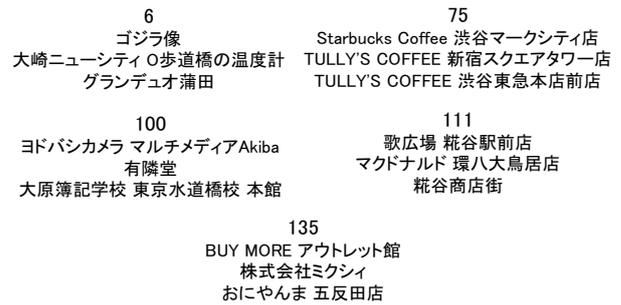
LDA の学習では, 事前に潜在トピック数に関するパラメータ K を与える必要がある. ここでは, 各ユーザの POI 訪問行動に関して予測性能の高い K を用いてトピック構造の分析を行うことを考える. そこで, 潜在トピック数 K を変化させたとき, 2 か月のデータを用いて LDA の学習を行い, 予測期間において尤度の高い上位 n 箇所の POI を各ユーザが実際に訪問しているかについて予測性能の評価を行った. 予測期間において, ランキング上位 n 箇所の POI ごとに 1 度でも訪問が行われていれば正解であるとみなした. 図 1 に, $n=5$ と $n=10$ と設定した場合における予測精度をユーザ数で平均した比較結果を示す. POI 訪問先の上位 $n=5$ ($P@5$) と上位 $n=10$ ($P@10$) のいずれにおいても $K=150$ のときに予測性能が高いことがわかる. そこで, 潜在トピック数 $K=150$ としたときのトピック構造の分析を行う.

4.3 トピック構造の分析結果

図 2 は, ユーザ行動の指向性の指標の観点 A_ℓ として, ユーザが行動する 4 つの時間帯 (A_1, A_2, A_3, A_4) = (6 時から 11 時, 11 時から 16 時, 16 時から 21 時, 21 時から 6 時), および A_5 = 指向性なしとしたときのトピック k との関係を示したものである. 図 2a は関係度 $\{R_{\ell,k}\}$ の可視化結果であり, その対角要素は, 各時間帯 (行) において, すべてのトピックを調べたとき, 最も $\{R_{\ell,k}\}$ が高いトピック (列) が配置されるように表示している. 例えば, 時間帯 6 時から 11 時において最も $\{R_{\ell,k}\}$ が高



(a) 関係度 $\{R_{\ell,k}\}$ の可視化

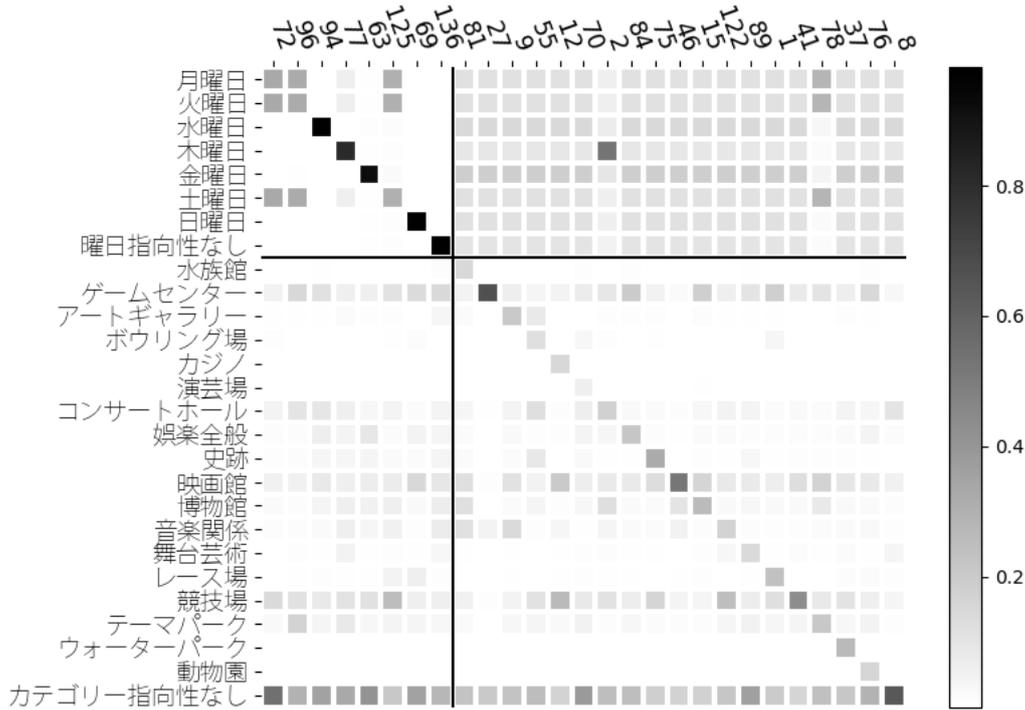


(b) 各トピックの訪問 POI トップ 3

図 2: 時間帯 (ユーザ行動の指向性) とトピックの関係

かったトピックは $k=6$ であり, 時間帯 11 時から 16 時において最も $\{R_{\ell,k}\}$ が高かったトピックは $k=100$ である. いずれのトピックにおいても, 時間帯との関係においては, 21 時から 6 時までの深夜から朝にかけての時間帯と関係度が最も高いものの, 1 つのトピックが複数の時間帯との関係度が高くなる場合があることもわかる. また, 図 2b は, 図 2a に登場した各トピックにおいて尤度の高い訪問 POI トップ 3 を示している. なお, POI のうち, 交通機関の駅や停留所などは check-in 数が常に多い傾向があることから, 図 2b では交通機関に関連する POI を除いたうえでのトップ 3 を示している. ここで, トピック $k=75$ に着目すると, ユーザの POI 訪問行動として coffee ショップを訪れる傾向があり, 21 時から 6 時までの時間帯とも関係度は高いが, 16 時から 21 時までの夕方から夜にかけての時間帯とも関係度が高いことがわかる.

ユーザ行動の指向性の指標については, 異なる指標を一緒に比較することも可能である. まず, 曜日と POI のカテゴリ (Foursquare のベニューカテゴリトップ階層「芸術&娯楽」) を一緒にしたものと, トピックとの関係を図 3 に示す. 図 3a は, 関係度の可視化結果であるが, 「水族館」から「動物園」までの 18 カテゴリは, トップ階層「芸術&娯楽」のサブカテゴリである.



(a) 関係度 $\{R_{\ell,k}\}$ の可視化

- | | | | |
|---|--|--|--|
| <p>81
JAMアキハバラ ラタンコナス部
シーフォートスクエア
スーパカレー カムイ</p> <p>27
松屋 三鷹店
ヨドバシカメラ マルチメディア吉祥寺
アトレ吉祥寺</p> <p>9
大島防災公園
ファミリーマート 西大島店
東京工業大学附属科学技術高等学校</p> <p>55
中落合公園
下落合駅前交差点
落合橋</p> <p>12
TOWER RECORDS 新宿店
TOWER RECORDS 渋谷店
新宿ピカデリー</p> <p>70
ビックカメラ 池袋本店
西武池袋本店
ビックカメラ 池袋本店 パソコン館</p> <p>2
SL広場
玉川上水第二緑道
青山学院大学 青山キャンパス</p> | <p>84
明治神宮
代々木公園
ロンドンパブ レイルウェイ タバーン</p> <p>75
Starbucks Coffee 渋谷マークシティ店
TULLY'S COFFEE 新宿スクエアタワー店
TULLY'S COFFEE 渋谷東急本店前店</p> <p>46
笹塚エレン屋敷
ファミリーマート 南台四丁目店
ライフ 笹塚店</p> <p>15
スーパー銭湯 湯処葛西
WINE & DINE 上野店
ヨドバシカメラ マルチメディアAkiba</p> <p>122
TSUTAYA 大崎駅前店
二子玉川ライズ ショッピングセンター
渋谷駅ハチ公前喫煙所</p> <p>89
AKIHABARAゲーマーズ
ヨドバシカメラ マルチメディアAkiba
ソフマップAKIBA 4号店 アミューズメント館</p> <p>1
勝間橋
株式会社ティーネットワーク 本社
アフィリア・シェリーズ</p> | <p>41
NHKホール
Beatdown
ヤマダ電機 テックランドNew港北センター本店</p> <p>78
多摩川
日本橋口
東海道本線 六郷川橋梁</p> <p>37
セブンイレブン 南浦和西口店
デイリーケアセイジヨー 南浦和西口店
HUB 秋葉原店</p> <p>76
東京汐留ビルディング
汐留シオサイト 地下歩行者道
鹿島田跨線橋</p> <p>8
男の娘BAR シービーズ
osteria PERNO
スリーエフ 北池袋店</p> <p>72
文京グリーンコート
セブンイレブン 荒川西日暮里五丁目店
NTT東日本 本社</p> <p>96
レーザーナ川崎プラザ
ヨドバシカメラ マルチメディア川崎ルフロ
川崎市立川崎総合科学高等学校</p> | <p>94
セブンイレブン 豊洲3丁目店
ららぽーと豊洲
コネスール 赤坂店</p> <p>77
世田谷区立南桜丘保育園
Starbucks Coffee 秋葉原駅前店
アドアーズ サンシャイン店</p> <p>63
東京競馬場
東京オリンピック(1964) 50km競歩折り返し点
ラウンドワン 府中本町駅前店</p> <p>125
セブンイレブン 東池袋2丁目店
大倉山公園梅林
都筑PA</p> <p>69
電気通信大学 西3号館
住吉稲荷
セブンイレブン 上北沢5丁目店</p> <p>136
東宝日比谷ビル
スーパーサカガミ 清瀬店
西友 清瀬店</p> |
|---|--|--|--|

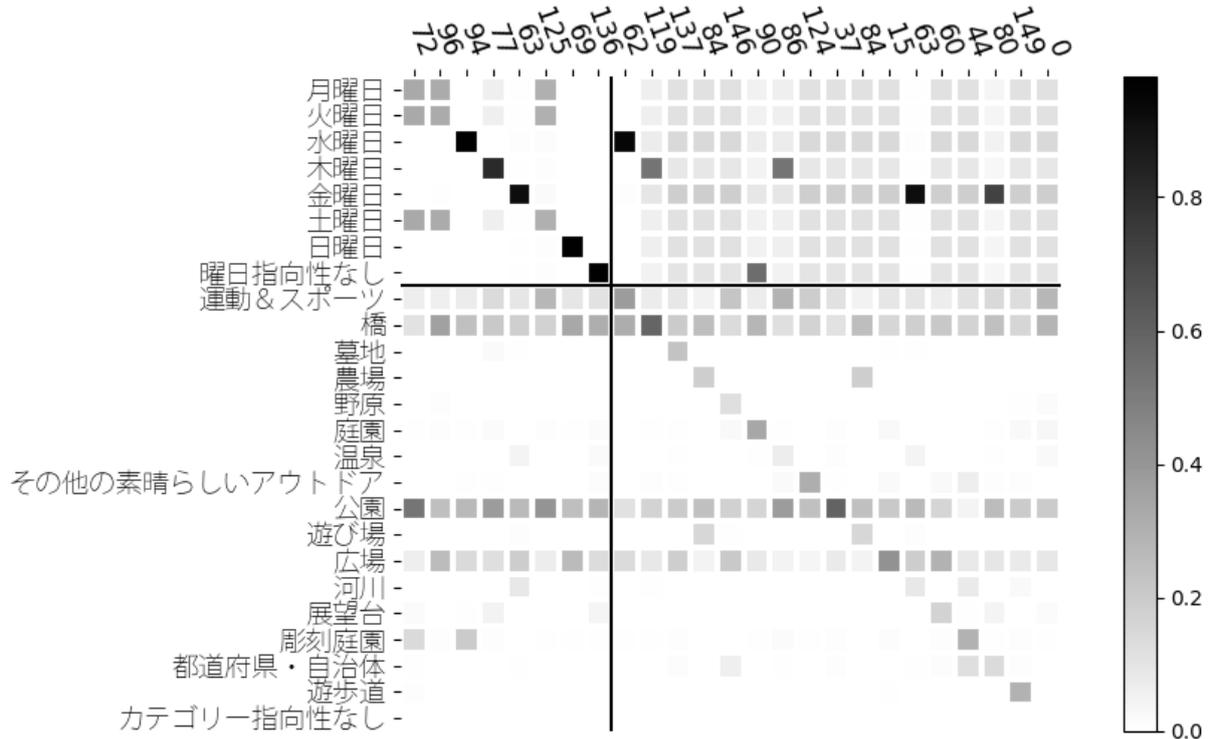
(b) 各トピックの訪問 POI トップ 3

図 3: 曜日および芸術&娯楽カテゴリー (ユーザ行動の指向性) とトピックとの関係

なお、これらの 18 サブカテゴリーは、学習期間において POI 訪問がなかったサブカテゴリーを省いた結果である。上記で着目したトピック $k=75$ は、図 3a において、曜日との関係を確認すると、どの曜日にも関係していることがわかる。また、芸術&娯楽カテゴリーのサブ

カテゴリーとの関係度を確認すると、「史跡」「映画館」「競技場」との関係度が高い傾向があることがわかる。

図 4 は、曜日と POI のカテゴリーを一緒にしてトピックとの関係を示したものであるが、カテゴリーを「アウトドア&レクリエーション」に変更したものである。図 4a



(a) 関係度 $\{R_{\ell,k}\}$ の可視化

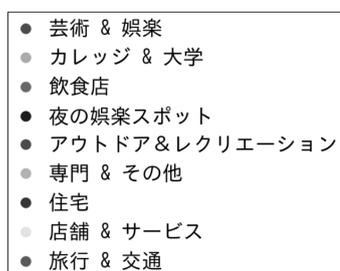
- | | | | |
|--|---|--|---|
| <p>62
ThinkPark Tower
エレクトロニック・アーツ株式会社
セブンイレブン 港区溜池山王店</p> <p>119
デジタル・ナレッジクリエイティブOne秋葉原ビル
セブンイレブン 西大井店
やまや 道玄坂店</p> <p>137
国立霞ヶ丘陸上競技場
まいばすけっと 中丸子店
味の素スタジアム</p> <p>84
明治神宮
代々木公園
ロンドンパブ レイルウェイ タバーン</p> <p>146
国立霞ヶ丘陸上競技場
まいばすけっと 中丸子店
味の素スタジアム</p> <p>90
明治神宮
代々木公園
ロンドンパブ レイルウェイ タバーン</p> | <p>86
早稲田大学 55号館
ゲームコーナー 牙銀
早稲田大学 学生会館</p> <p>124
バルタン星人型街灯
ウルトラマン シンボル像
登戸駅 ドラえもん像</p> <p>37
セブンイレブン 南浦和西口店
デイリーケアセイジヨー 南浦和西口店
HUB 秋葉原店</p> <p>15
スーパー銭湯 湯処葛西
WINE & DINE 上野店
ヨドバシカメラ マルチメディアAkiba</p> <p>63
東京競馬場
東京オリンピック(1964) 50km競歩折り返し点
ラウンドワン 府中本町駅前店</p> <p>60
BARウラメン(裏面)
ドールコーヒーショップ 東横渋谷店
クロスガーデン川崎</p> | <p>44
小川町交差点
西海商店
柘榴坂</p> <p>80
studio yoggy 新宿EASTスタジオ
HOT HOUSE
用賀PA</p> <p>149
UDXビジョン
札の辻橋
浅草駅前 スモーキングエリア</p> <p>0
新宿スクエアタワー
浦和PARCO
TULLY'S COFFEE 新宿スクエアタワー店</p> <p>72
文京グリーンコート
セブンイレブン 荒川西日暮里五丁目店
NTT東日本 本社</p> <p>96
レーザーナ川崎プラザ
ヨドバシカメラ マルチメディア川崎ルフロ
川崎市立川崎総合科学高等学校</p> | <p>94
セブンイレブン 豊洲3丁目店
ららぽーと豊洲
コネスール 赤坂店</p> <p>77
世田谷区立南桜丘保育園
Starbucks Coffee 秋葉原駅前店
アドアーズ サンシャイン店</p> <p>125
セブンイレブン 東池袋2丁目店
大倉山公園梅林
都筑PA</p> <p>69
電気通信大学 西3号館
住吉稲荷
セブンイレブン 上北沢5丁目店</p> <p>136
東宝日比谷ビル
スーパーサカガミ 清瀬店
西友 清瀬店</p> |
|--|---|--|---|

(b) 各トピックの訪問 POI トップ 3

図 4: 曜日およびアウトドア&レクリエーションカテゴリー (ユーザ行動の指向性) とトピックとの関係

は、関係度の可視化結果であり、「運動&スポーツ」から「遊歩道」までの16カテゴリーは、トップ階層「アウトドア&レクリエーション」のサブカテゴリーである。図 3a と同様に、学習期間において POI 訪問がなかったサブカテゴリーを省いている。ここで、図 4b のうち、トピック $k=124$ に着目すると、子供向け番組で有名な人気キャラクターに関連して街中に設置されたオブジェ

などの POI への訪問行動との関係があることが示唆される。また、トピック $k=124$ は、「アウトドア&レクリエーション」のサブカテゴリーとの関係を確認すると、「運動&スポーツ」「橋」「その他の素晴らしいアウトドア」「公園」「広場」などのサブカテゴリーとの関係度が高いことがわかる。このトピック $k=124$ について、より詳しく調べるために、駅や停留所を含めた上位 20 位ま

(a) トピック $k=124$ と関係度が高い POI の位置

(b) Foursquare トップカテゴリー

図 5: POI 訪問トピックの地図上での行動分析

での POI を地図上に可視化した例が図 5 である。図 5a の地図上に描画した色付きの円が POI の位置を示しており、円の色は、図 5b の Foursquare トップカテゴリーと対応づけている。人気キャラクターに関連したオブジェは、図 5a において、赤い楕円で示した比較的近い地域に存在し、ドラえもん像とバルタン星人やウルトラマンのオブジェの中間に飲食店、茶々への訪問行動があることもわかる。また、それらの POI が図 5a の水色の線で描画した小田急小田原線に沿っていることもわかった。なお、ユーザ行動の指向性の指標は 3 つ以上の場合でも組み合わせることが可能であり、より多くの指標を組み合わせることで、より詳しいトピック分析が可能であることに注意しておく。すなわち、本研究のようにユーザの POI 訪問行動の指向性の指標や地図システムを組合せてトピック構造分析を行うことで、観光マーケティングへ活用できる可能性が示唆された。

5 まとめ

Foursquare を対象として、ユーザ行動の指向性に基づいて POI 訪問行動に関するトピック構造を分析した。近年、人々のリアル行動データを観光地創生に生かす手

法が注目されている。本研究では、複数のユーザ行動の指向性を組み合わせることで人々の行動データ分析を行える可能性を示した。これらの結果は観光マーケティングにつながると考えている。

参考文献

- [1] Chen, S., Yuan, X., Wang, Z., Guo, C., Liang, J., Wang, Z., Zhang, X.L., and Zhang, J., “Interactive visual discovering of movement patterns from sparsely sampled geo-tagged social media data,” *IEEE Transactions on Visualization and Computer Graphics*, vol. 22, no. 1, pp. 270–279, 2016.
- [2] 相原健郎, “ビッグデータを用いた観光動態把握とその活用: 動体データで訪日外客の動きをとらえる,” *情報管理*, vol. 59, no. 11, pp. 743–754, 2017.
- [3] Chen, C., Yang, H., Lyu, M., and King, I., “Where you like to go next: Successive point-of-interest recommendation,” in *Proceedings of IJCAI’13*, 2013, pp. 2605–2611.
- [4] Feng, S., Li, X., Zeng, Y., Cong, G., Chee, Y.M., and Yuan, Q., “Personalized ranking metric embedding for next new poi recommendation,” in *Proceedings of IJCAI’15*, 2015, pp. 2069–2075.
- [5] Zhang, J. and Chow, C., “Spatiotemporal sequential influence modeling for location recommendations: a gravity-based approach,” *ACM Transactions on Intelligent Systems and Technology*, vol. 7, no. 1, pp. 11:1–11:25, 2015.
- [6] Liu, Y., Liu, C., Liu, B., Qu, M., and Xiong, H., “Unified point-of-interest recommendation with temporal interval assessment,” in *Proceedings of KDD’16*, 2016, pp. 1015–1024.
- [7] Gao, H., Tang, J., Hu, X., and Liu, H., “Exploring temporal effects for location recommendation on location-based social networks,” in *Proceedings of RecSys’13*, 2013, pp. 93–100.
- [8] Yuan, Q., Cong, G., Ma, Z., Sun, A., and Magnenat-Thalmann, N., “Time-aware point-of-interest recommendation,” in *Proceedings of SIGIR’13*, 2013, pp. 363–372.
- [9] Yang, D., Zhang, D., Zheng, V.W., and Yu, Z., “Modeling user activity preference by leveraging user temporal characteristics in LBSNs,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 45, no. 1, pp. 129–142, 2015.
- [10] Hu, B. and Ester, M., “Spatial topic modeling in online social media for location recommendation,” in *Proceedings of RecSys’13*, 2013, pp. 25–32.
- [11] Griffiths, T. and Steyvers, M., “Finding scientific topics,” *Proceedings of the National Academy of Sciences of the United States of America (PNAS)*, vol. 101, suppl. 1, pp. 5228–5235, 2004.
- [12] Blei, D., Ng, A., and Jordan, M., “Latent Dirichlet allocation,” *Journal of Machine Learning Research*, vol. 3, pp. 993–1022, 2003.