

位置情報サービスの利用状況に基づく POI 推薦手法の精度比較 ーサービス間での違いー

柿原 慎太郎† 森澤 竣‡ 山名 早人§

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

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

§ 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: † shintaro.k12@fuji.waseda.jp, ‡ hiroshun@yama.info.waseda.ac.jp,
§ yamana@yama.info.waseda.ac.jp

あらまし 昨今、スマートフォン上で GPS, Wi-Fi などを用いて位置情報の取得が容易に行えるようになり、位置情報を用いた様々なサービスが登場している。こうした背景のもと、「位置情報サービスの利用状況を活用した POI 推薦手法」が落合らにより提案されている。これは、位置情報サービスのコンテンツが利用者の POI 訪問に影響を与えるという仮定に基づいている。しかし、位置情報サービスの特徴によって推薦精度に違いが出てくると考えられる。そこで、本研究では、様々な位置情報サービスに対する利用者の行動がどのように POI 推薦制度に影響を与えるのかを明らかにすることを目指した。具体的には、Pokémon Go 使用状況を用いた推薦システムと Instagram 使用状況を用いた POI 推薦システムを作成し、ユーザーベース協調フィルタリングを用いた推薦システムと適合率と再現率の比較を行い、Pokémon Go, Instagram を用いた POI 推薦がユーザーベース協調フィルタリングを用いた POI 推薦と比べ適合率と再現率を向上させるとは限らないことがわかった。

キーワード 推薦システム, 位置情報サービス

1. はじめに

POI(Point-of-interest)推薦とはユーザに新たに訪れる場所を推薦することである。昨今、スマートフォンの普及に伴い、位置情報を用いた様々なサービスが登場している。中でも、Facebook 社による Facebook¹, Instagram², Niantic 社の Pokémon Go³などが代表例として挙げられる。このような位置情報サービスの普及を背景に位置情報サービスから得ることのできる情報を推薦に活用する研究が行われている。

中でも落合ら[10]の研究では、同一の位置情報サービスを利用しているユーザは類似する場所に訪問する可能性が高いというアイデアに基づき、Pokémon Go の利用状況を考慮した POI 推薦手法を提案した。これは位置情報サービスのコンテンツが利用者の POI 訪問に影響を与えるという仮定に基づいている。Pokémon Go は、ポケストップと呼ばれる実世界と関連づけられている地点にユーザが訪れることでゲーム内アイテムを入手することができる。そのため、Pokémon Go はユーザに対して特定の地点を訪れることを強く動機づけするサービスと考えられる。一方、Instagram では特定の地点を訪れることでゲーム内のアイテムを入手することができるようなコンテンツは存在しない。しかし、Instagram ユーザの中には「インスタ映え」と言われるお洒落な写真を撮ることを動機に特定の地点を訪

れるユーザも存在する。

本研究では、落合らが明らかにした「同一の位置情報サービスを利用しているユーザは類似する場所に訪問する可能性が高く、これらのユーザの傾向を用いることで POI 推薦精度向上が可能」という点について、様々な位置情報サービスに適用可能かどうかを検証する。つまり、位置情報サービスに対する利用者の行動がどのように POI 推薦における精度に影響を与えるかを明らかにすることを旨とする。具体的には、複数の位置情報サービスに対して、各サービスを使用する利用者の行動履歴を用いた POI 推薦モデルを作成し、適合率と再現率の比較を行う。

本稿では、以下の構成を取る。第 2 節では位置情報サービスの使用履歴を活用した POI 推薦の関連研究について述べる。第 3 節で推薦手法について説明し、第 4 節で評価実験の結果、および結果の考察について述べる。最後に第 5 節でまとめを行う。

2. 関連研究

本節では、近年の推薦システムに関する位置情報サービスを活用している研究について説明する。POI 推薦システムの分類は多岐にわたるが、代表例として地理的な条件を考慮した推薦、社会的影響を考慮した推薦、位置情報サービスの利用状況を考慮した推薦について説明する。

¹ <https://www.facebook.com/>

² <https://instagram.com/>

³ <https://www.pokemongo.jp/>

2.1 地理的条件を利用した推薦

地理的条件を考慮した推薦に関する研究としては[1][2][3][4]があるが、その代表例として[1]を以下で紹介する。

ペンシルベニア州立大学の Ye ら[1]は 2011 年、Foursquare, Whrrl のユーザのチェックイン履歴を用いて地理的条件が POI 推薦に影響を及ぼすことを示した。具体的には、それぞれのユーザがチェックインしたすべての POI の 2 つの組み合わせにおいて、2 つの POI 間の距離を計算し、POI の距離に関する確率密度関数を作成したところ、以下の 2 つの事象が明らかになった。

1. ユーザはユーザの自宅やオフィスの近くにある POI に訪れやすい。
2. ユーザはユーザが訪れた POI の近くにある POI に興味を持ちやすい。(その POI がユーザの自宅またはオフィスから遠い箇所にあっても)

2.2 社会的影響を考慮した推薦

社会的影響を考慮した推薦とは一般的に友人同士は共通の好みを持つという仮定のもとに行われる、ユーザ間の社会的な関係を利用した推薦のことである。

香港中文大学の Ma ら[5]は 2009 年、消費者レビューサイト、Epinions における「信頼できるユーザー一覧」を用いて推薦システムを作成し、信頼されているユーザは信頼しているユーザのふるまいを変えることを示した。

一方ペンシルベニア州立大学の Ye ら[6]は 2010 年、アリゾナ州立大学の Gao ら[7]は 2012 年、香港城市大学の Zhang ら[8]は 2014 年、Foursquare のデータセットを使用し、POI におけるフレンドを用いた推薦を行っており、Foursquare 上のフレンドがユーザの好みに影響を与えていることが示されている。

ノースカロライナ大学の Li ら[9]は 2016 年、Gowalla と Foursquare のデータセットを使用し、フレンドを SNS 上でつながりのあるフレンド、同じ POI にチェックインしているフレンド、自宅が物理的に近いフレンドの 3 つに分類し、それぞれの分類においてユーザの好みは共通する傾向があることを示した。

2.3 位置情報サービスの利用状況を活用した POI 推薦

落合ら[10]は昨今の位置情報サービスがユーザの訪問場所に影響を与えていると考え、Pokémon Go ユーザの行動に偏りがあることを示した。また、Pokémon Go ユーザと全ユーザを対象に位置情報サービスの利用状況を考慮したユーザベース協調フィルタリングが位置

情報サービスの利用状況を考慮していない従来の協調フィルタリングと比較し、Precision@N, Recall@N ともに精度が向上していることを示した。

2.4 まとめ

本節では位置情報サービスを利用した既存研究を紹介した。落合ら[10]が提案している推薦手法は、ユーザのチェックインデータに加え、特定の位置情報サービスを使用しているかどうかについてのデータのみを推薦に使用する。また、位置情報サービスの使用状況は、簡単な質問やアプリ連携機能を用いるだけでデータが取得できる。そのため、落合ら[10]が提案している手法は地理的状况を考慮した推薦、社会的影響を考慮した推薦と比較してユーザの自宅の位置やフレンド機能などを取得することができない位置情報サービスにも適用できるという利点がある。一方、ユーザの訪問場所に影響を与える度合いは位置情報サービスの内容に依存する可能性がある。つまり、さらに多くの位置情報サービスを用いて有用性を確認する必要がある。

3. 推薦手法

本節では、実験に使用した推薦の手法について述べる。本研究では落合ら[10]が提案している手法同様、ユーザベース協調フィルタリングを用いる。以下では、まず伝統的なユーザベース協調フィルタリングについて説明し、次に落合ら[10]が提案している位置情報サービスの利用状況をもとに、ユーザベース協調フィルタリングを拡張した手法について述べる。

3.1 ユーザベース協調フィルタリング

ユーザベース協調フィルタリングとは推薦対象のユーザと他のユーザの類似度を計算し、他ユーザの履歴をユーザ間の類似度で重みづけすることで推薦対象のアイテムの推薦スコアを計算する。[11]によると、[12][13]の研究を皮切りに高い精度と実装の容易さから使われ続けてきたと述べられている。各ユーザの訪問場所を示すユーザ-POI 行列 C の各要素 c_{ij} は、ユーザ $u_i \in U$ が POI $l_j \in L$ にチェックインしているときに $c_{ij} = 1$ 、チェックインしていないときに $c_{ij} = 0$ とする。ユーザ u_i に対する POI の推薦スコア $\hat{c}_{i,j}$ は以下の式で計算する。なお、表記は Ye ら[1]と落合ら[10]のものに従っている。

$$\hat{c}_{i,j} = \frac{\sum_{u_k \in U, k \neq i} w_{i,k} c_{k,j}}{\sum_{u_k \in U, k \neq i} w_{i,k}} \quad (1)$$

$w_{i,k}$ はユーザ u_i と u_k の類似度を示し、従来研究と同様に次式で表されるコサイン類似度により計算される。

$$w_{i,k} = \frac{\sum_{l_j \in L} c_{i,j} c_{k,j}}{\sqrt{\sum_{l_j \in L} c_{i,j}^2} \sqrt{\sum_{l_j \in L} c_{k,j}^2}} \quad (2)$$

3.2 位置情報サービスの利用状況を用いた協調フィルタリング

本項では落合ら[10]が提案している位置情報サービスの利用状況を用いた協調フィルタリングについて説明する。

落合ら[10]は、対象となるユーザを、当該位置情報サービスを利用しているユーザのみに限定することでユーザ-POI 行列のデータ密度が高くなり、精度を向上できるとしている。つまり、同一の位置情報サービスを利用しているユーザは類似する場所に訪問する可能性が高くなることを期待している。

具体的には、ユーザ u_i に対する各 POI の推薦スコア $\hat{c}_{i,j}$ は以下の式で計算する。

$$\hat{c}_{i,j}^{(s)} = \frac{\sum_{u_k \in U_s} w_{i,k} c_{k,j}}{\sum_{u_k \in U_s} w_{i,k}} \quad (3)$$

U_s は特定のサービス利用者の集合を示す。 $w_{i,k}$ は式(2)により計算する。

3.3 統合モデル

本項ではここまで述べた 2 つの協調フィルタリングの推薦スコアを統合し、最終的な推薦スコアを計算する方法について述べる。落合ら[10]の研究では、ユーザベース協調フィルタリングによる推薦スコアと利用サービスに基づくユーザベース協調フィルタリングの推薦スコアの線形結合により最終的なスコアを計算する。そのため、まず各推薦スコアを次式により正規化する。

$$\tilde{c}_{i,j} = \frac{\hat{c}_{i,j}}{\max_{l_j \in L-L_i}(\hat{c}_{i,j})} \quad (4)$$

$$\hat{c}_{i,j}^{(s)} = \frac{\tilde{c}_{i,j}^{(s)}}{\max_{l_j \in L-L_i}(\tilde{c}_{i,j}^{(s)})} \quad (5)$$

ここで L_i はユーザ u_i がチェックインしたことがある POI の集合を示す。そして、未訪問の POI に対する推薦スコアは以下の式で計算する。

$$c_{i,j} = (1 - \alpha) \times \tilde{c}_{i,j} + \alpha \times \hat{c}_{i,j}^{(s)} \quad (6)$$

2 節で述べた通り、地理的条件等が推薦精度に影響を与えるため、Ye ら[1]のように地理的条件も考慮することでより高精度の推薦が可能であると考えられる。しかし、本研究では位置情報サービスの内容が利用サービスに基づくユーザベース協調フィルタリングに与える影響を明らかにすることが目的のため、式(6)の通りユーザベース協調フィルタリングのスコアとサービス利用者のみでの推薦スコアの線形結合としている。

4. 評価実験

位置情報サービスの利用状況に基づく POI 推薦手法において位置情報サービスの内容が推薦精度に及ぼす影響を明らかにするため、Pokémon Go と Instagram の 2 つのサービス各々の使用状況を用いた推薦システム（ユーザベース協調フィルタリングを利用）を作成し、同システムと適合率と再現率の比較を行った。

4.1 データセットおよび実験設定

チェックインデータとして、2019 年 8 月 1 日～8 月 29 日の Foursquare のデータを利用した。データは Foursquare を通じて Twitter に投稿されたツイートから取得した。Foursquare を投稿元とするツイートは本文が「I'm at ~」からはじまり、かつ日本語が含まれているツイートを取得した。

一日あたりユーザによらず 10,000 件のチェックインデータを収集し、合計 290,000 件、25,972 ユーザのチェックインデータを収集した。落合ら[10]の研究にない、2019 年 1 月 1 日～9 月 31 日までの期間で「ポケモン GO」「ポケ GO」「ポケストップ」のうちいずれかのキーワードを含むツイートを 3 件以上投稿しているユーザを Pokémon Go サービス利用者、同様の期間で「Instagram」「インスタ」のうちいずれかのキーワードを含むツイートを 3 件以上投稿しているユーザを Instagram サービス利用者とした。Pokémon Go の利用者は 1,687 ユーザ Instagram の利用者は 10,061 ユーザであった。

3 節で述べた POI 推薦を行うためのデータは先行研究の落合ら[10]のものに従い、前述のデータに対して、5 人以上がチェックインしている POI かつ 5 人以上がチェックインしている POI に 5 回以上チェックインしたユーザに限定して実験を行った。この条件でのユーザ数は全ユーザが 7,879 ユーザ、Pokémon Go 利用者が 367 ユーザ、Instagram ユーザが 2,262 ユーザであった。

POI 推薦の評価実験では 5 分割交差検証を行った。この一連の捜査を 5 分割されたデータすべてにおいて行い、平均値を求めて評価精度とした。推薦は推薦スコアが高い上位 N 件を利用する。実験では N=1, 5, 10, 20 とした。図 1, 2 に 5 回以上チェックインしている Pokémon Go, Instagram ユーザにおける異なるチェックイン回数の分布を示す。また、図 3, 4 に 5 回以上チェックインしている Pokémon Go, Instagram ユーザにおける重複をチェックイン回数の分布を示す。また、表 2 に 5 回以上チェックインしている Pokémon Go, Instagram ユーザにおけるチェックイン POI ランキングを示す。

表 1 データセットの概要

	全ユーザ	Instagramユーザ	Pokemon Go ユーザ
キーワード		「Instagram」 「インスタ」	「ポケモンGO」 「ポケGO」 「ポケストップ」
平均チェックイン回数(回/人)	11.17	7.54	9.95
ユーザ数(人)	42,304	10,061	1,687
5回以上チェックインしているユーザ数(人)	7,879	2,262	367
5回以上チェックインしているユーザの平均チェックイン回数 (POIの重複を含む) (回/人)	16.15	15.34	19.4
5回以上チェックインしているユーザの平均チェックイン回数 (POIの重複を含まない) (回/人)	8.17	8.57	8.71

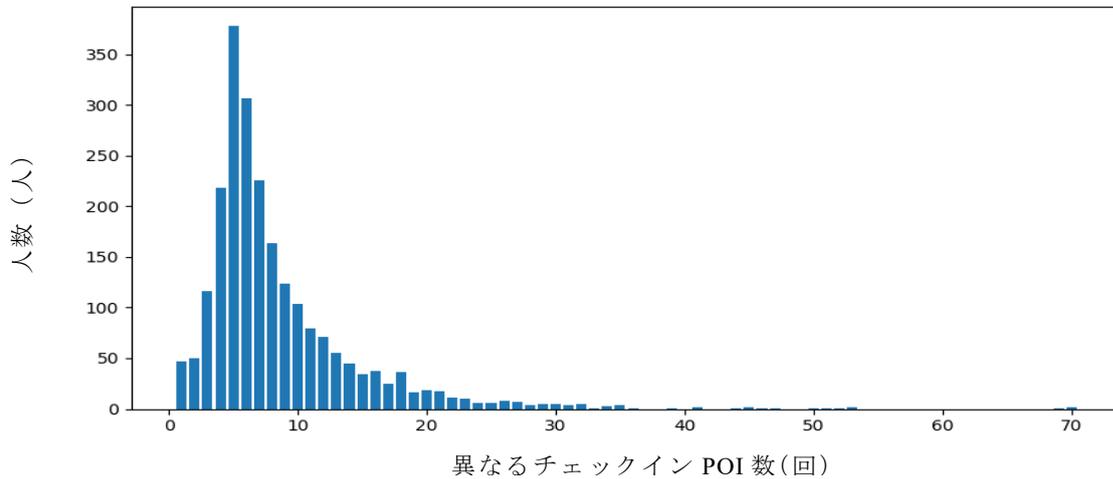


図 1 5回以上チェックインしている Instagram ユーザにおける異なるチェックイン POI 数の分布

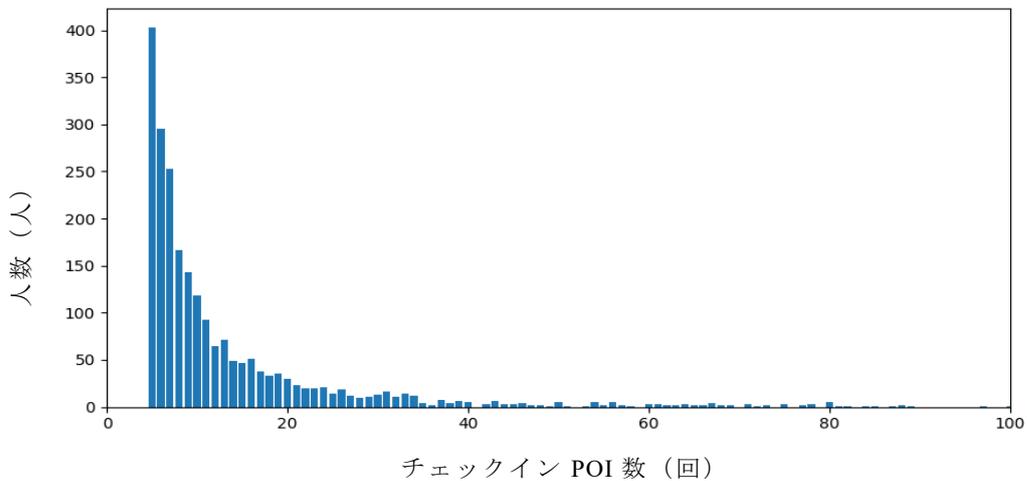


図 2 5回以上チェックインしている Instagram ユーザにおける重複を含むチェックイン POI 数の分布

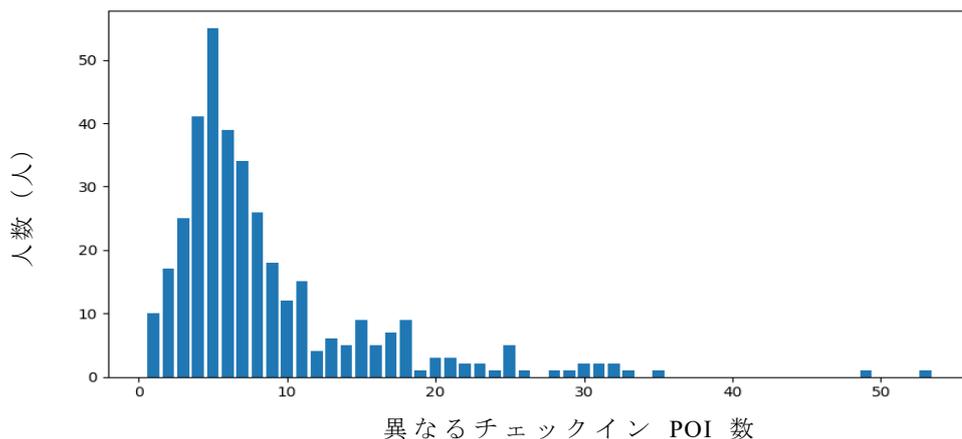


図3 5回以上チェックインしている Pokémon Go ユーザにおける異なるチェックイン POI 数の分布

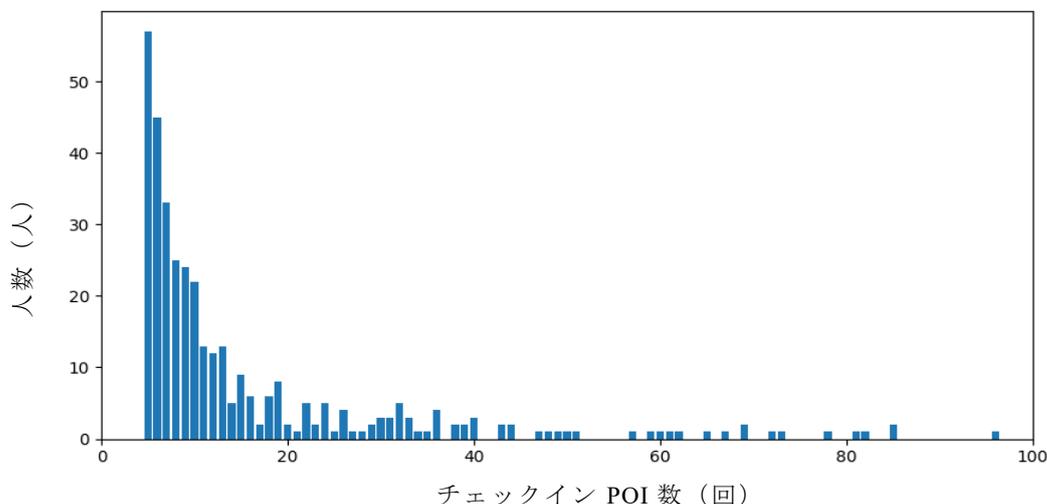


図4 5回以上チェックインしている Pokémon Go ユーザにおける重複を含むチェックイン POI 数の分布

表2 5回以上チェックインしているユーザにおけるチェックイン POI ランキング

Instagram ユーザ	相対頻度	Poke'mon Go ユーザ	相対頻度	全ユーザ	相対頻度
東京駅 in 千代田区	0.01205	東京駅 in 千代田区	0.01700	東京駅 in 千代田区	0.01017
新宿駅 in 新宿区	0.007551	名古屋駅 in 名古屋市	0.01054	秋葉原駅 in 千代田区	0.006223
横浜駅 in 横浜市	0.006946	南浦和駅 in さいたま市	0.007165	新宿駅 in 新宿区	0.005791
秋葉原駅 in 千代田区	0.006571	秋葉原駅 in 千代田区	0.007024	横浜駅 in 横浜市	0.005406
名古屋駅 in 名古屋市	0.005591	大宮駅 in さいたま市	0.005620	大阪駅 in 大阪市	0.005201
大阪駅 in 大阪市	0.005476	横浜駅 in 横浜市	0.005620	名古屋駅 in 名古屋市	0.005013
池袋駅 in 豊島区	0.005332	JR 名古屋駅 in 名古屋市	0.005479	東京国際空港 / 羽田空港 in 大田区	0.004125
JR 新宿駅 in 新宿区	0.004698	東海道新幹線 名古屋駅 in 名古屋市	0.005339	国際展示場駅 - in 江東区	0.004054
東京国際空港 / 羽田空港 in 大田区	0.004381	蕨駅 in 蕨市	0.004777	JR 新宿駅 - in 新宿区	0.003999
渋谷駅 in 渋谷区	0.004208	国際展示場駅 - in 江東区	0.004355	池袋駅 in 豊島区	0.003999
東海道新幹線 名古屋駅 in 名古屋市	0.004121	新宿駅 in 新宿区	0.004215	東京ビッグサイト - in 江東区	0.003866
上野駅 in 台東区	0.004035	学園前駅 - in 千葉市	0.004215	品川駅 in 港区	0.003316
品川駅 in 港区	0.003631	青砥駅 - in 葛飾区	0.004074	上野駅 in 台東区	0.003284
国際展示場駅 in 江東区	0.003458	JR 千葉駅 - in 千葉市	0.003934	大宮駅 in さいたま市	0.003159
東京ビッグサイト in 江東区	0.003228	桑名駅 in 桑名市	0.003793	東海道新幹線 名古屋駅 in 名古屋市	0.002844
阪急 梅田駅 in 大阪市	0.003170	京成千葉駅 - in 千葉市	0.003793	大黒PA in 横浜市	0.002569
JR 東京駅 - @jreast_official in 千代田区	0.003055	鶯谷駅 in 台東区	0.003653	コミックマーケット96 in 江東区	0.002530
東京レポート駅 - @twr_official in 江東区	0.003026	上野駅 in 台東区	0.003512	渋谷駅 in 渋谷区	0.002420
大黒PA in 横浜市	0.002767	越谷駅 in 越谷市	0.003512	JR 東京駅 - in 千代田区	0.002357

表 3 α を変化させた際の F 値@10

α	Pokémon Go 利用状況を用いた推薦	Instagram 利用状況を用いた推薦
0.1	0.02850	0.02854
0.2	0.02848	0.02862
0.3	0.02845	0.02860
0.4	0.02839	0.02847
0.5	0.02832	0.02837
0.6	0.02827	0.02830
0.7	0.02823	0.02821
0.8	0.02817	0.02813
0.9	0.02816	0.02812
1.0	0.001050	0.008442

4.2 評価指標

評価指標には落合ら[10]の研究で用いられている Precision@N, Recall@N を用いる. Precision@N は推薦された上位 N 件の POI のうち正解データが含まれる POI の割合, Recall@N は正解データのうち推薦された上位 N 件の POI に含まれる割合である.

4.3 評価結果

3.1 項で述べたユーザベース協調フィルタリングをベースラインとして, Pokémon Go 利用状況を用いた推薦と Instagram 利用状況を用いた推薦について評価した. 5 分割交差検証し, 平均値の評価結果を表 3~表 5 に示す. 3 章で述べた通り, ユーザベース協調フィルタリングと利用サービスに基づく協調フィルタリングの統合モデルは推薦スコアを統合するためのパラメータ α が必要となる. α を 0.1 から 1.0 まで 0.1 刻みで変化し, 5 分割交差検証を行ったときの F 値@10 の平均値を表 2 に示す. Pokémon Go 利用状況を用いた推薦では $\alpha=0.1$, Instagram 利用状況を用いた推薦を比較する際には $\alpha=0.2$ の際の F 値が最大だったため評価検定の際は, Pokémon Go 利用状況を用いた推薦では $\alpha=0.1$, Instagram 利用状況を用いた推薦を比較する際には $\alpha=0.2$ における推薦結果を用いた. 表 4, 5, 6 にそれぞれ推薦結果の Precision@N, Recall@N, F 値@N を示す. ユーザベース協調フィルタリングでの推薦と Pokémon Go の利用状況を用いた推薦における F 値@N とユーザベース協調フィルタリングでの推薦と Instagram の利用状況を用いた推薦における F 値@N ウィルコクソンの符号順位検定を用いて検定した結果を表 8 に示す. N=5, 10, 20 において $p>0.05$ であり, 非有意であった.

今回使用したデータと落合ら[10]のデータにおけるチェックイン POI ランキングを表 8 に示す. 落合ら[10]のデータでは錦糸町駅を代表とする Pokémon Go において希少なキャラクターを入手できるニュース⁴が出ていた POI が散見される. そのため, 落合ら[10]の研究では Pokémon Go の利用状況を用いた推薦を行い, 適合率と再現率が高くなったことが考えられる. 一方, 今回の実験で使用したデータは, Pokémon Go リリースから期間が空いており, チェックイン POI の偏りの差が小さくなり, 落合ら[10]の結果と比較し, 推薦の F 値が上がらなかったのではないかと考えられる.

表 4 各サービスに基づいた推薦の Precision@N

N	ベースライン	Pokémon Go 利用状況を用いた推薦	Instagram 利用状況を用いた推薦
1	0.000654	0.000654	0.000681
5	0.0171	0.0171	0.017
10	0.0167	0.0167	0.0168
20	0.0134	0.0134	0.0134

表 5 各サービスに基づいた推薦の Recall@N

N	ベースライン	Pokémon Go 利用状況を用いた推薦	Instagram 利用状況を用いた推薦
1	0.000386	0.000386	0.000401
5	0.0493	0.0493	0.0492
10	0.0966	0.0966	0.0970
20	0.154	0.155	0.154

⁴ <https://rocketnews24.com/2019/09/10/1260518/>

表 6 各サービスに基づいた推薦の F 値@N

N	ベースライン	Pokémon Go 利用状況 を用いた推薦	Instagram 利用状況 を用いた推薦
1	0.0005	0.0005	0.0005
5	0.0254	0.0254	0.0253
10	0.0285	0.0285	0.0286
20	0.0246	0.0246	0.0246

表 7 ベースラインと各サービスの利用状況を用いた推薦における F 値@N の差をウィルコクソンの符号順位検定を用いて検定した際の p 値

N	Pokémon Go 利用状況 を用いた推薦	Instagram 利用状況 を用いた推薦
5	0.285	0.465
10	0.655	0.144
20	0.465	0.655

5. おわりに

本稿では、位置情報サービスの内容によってユーザの行動に与える影響は異なると考え、Twitter から取得した Foursquare のチェックインデータを用いて Pokémon Go, Instagram の利用状況を用いた推薦を行い、ユーザベース協調フィルタリングによる推薦と比較することで位置情報サービスの利用状況が推薦の性能に与える影響について分析した。結果、Pokémon Go, Instagram の利用状況を用いた推薦が適合率と再現率を向上させるとは限らないことがわかった。

今後の課題として、適合率と再現率の向上が確認されている落合ら[10]とのデータの違いとして、サービスがリリースされてからの期間が挙げられるため、サービスがリリースされてからの期間が推薦にどのように影響を与えるかを分析することを検討している。

謝辞

本研究を進めるにあたり、研究の相談や助言をしていただいた山名研究室の方々に厚く御礼を申し上げます。

参考文献

- [1] Mao Ye, Peifeng Yin, Wang-Chien Lee, and Dik-Lun Lee, “Exploiting Geographical Influence for Collaborative Point-of-interest Recommendation”, in Proceedings of the 34th SIGIR ’11, pp. 325–334, 2011.
- [2] Defu Lian, Cong Zhao, Xing Xie, Guangzhong Sun, Enhong Chen, and Yong Rui, “GeoMF: Joint geographical modeling and matrix factorization for point-of-interest recommendation”, in Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 831–840, 2014.
- [3] Yong Liu, Wei Wei, Aixin Sun, and Chunyan Miao, “Exploiting geographical neighborhood characteristics for location recommendation,” in Proceedings of the ACM International Conference on Information and Knowledge Management, pp. 739–748, 2014.
- [4] Shenglin Zhao, Irwin King, and Michael R Lyu, “Capturing geographical influence in poi recommendations”, in Proceedings of the International Conference on Neural Information Processing, pp. 530–537, 2013.
- [5] Hao Ma, Irwin King and Michael R. Lyu, “Learning to Recommend with Social Trust Ensemble”, in Proceedings of the 32nd SIGIR ’09, pp. 203–210, 2009.
- [6] Mao Ye, Peifeng Yin, and Wang-Chien Lee, “Location recommendation for location-based social networks”, in Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems, pp. 458– 461, 2010.
- [7] Huiji Gao, Jiliang Tang, and Huan Liu, “Exploring social-historical ties on location-based social networks, in Proceedings of the Sixth International AAAI Conference on Weblogs and Social Media, pp. 114-121, 2012.
- [8] Yong Ge, Huayu Li, and Hengshu Zhu, “Point-of-interest recommendations: Learning potential check-ins from friends”, in Proceedings of the 22nd KDD’16, pp. 975-984, 2016.
- [9] Jia-Dong Zhang, Chi-Yin Chow, and Yanhua Li, “Lore: exploiting sequential influence for location recommendations”, in Proceedings of the 22nd ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, pp 103–112, 2014.
- [10] 落合 桂一, 深澤 佑介, 山田 渉, 松尾 豊, “位置情報サービスの利用状況を活用した POI 推薦手法”, in The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017.
- [11] Matthew R. McLaughlin, and Jonathan L. Herlocker, “A Collaborative Filtering Algorithm and Evaluation Metric that Accurately Model the User Experience”, in Proceedings of the 27th SIGIR ’04, pp. 329-336, 2004.

- [12] Paul Resnick, Neophytos Iacovou, Mitesh Suchak, Peter Bergstrom, and John Riedl, "GroupLens: An open architecture for collaborative filtering of netnews", in Proceedings of the 1994 Conference on Computer Supported Collaborative Work, pp. 175-186, 1994.
- [13] Upendra Shardanand, Pattie Maes, "Social Information Filtering: Algorithms for Automating"Word of Mouth"", in Proceedings of ACM CHI'95 Conference on Human Factors in Computing Systems, pp. 210-217, 1995.