

仮想空間環境におけるコンテキスト情報を活用した 協調フィルタリング手法の提案と評価

川瀬 寛太^{1,†1} レ ハイ バン¹ ターウォンマツ ラック^{2,a)}

受付日 2015年1月9日, 採録日 2015年7月1日

概要: 本稿では, 近年様々な用途で注目を集めている仮想空間環境においてユーザにエリア推薦を行う手法を提案し, その有用性を評価した. 仮想空間環境は非常に多様なエリアによって構成され, ユーザらはそれらのエリアを訪問することによって, 他ユーザとのコミュニケーションや観光などを行うことができる. しかし, この多様なエリアの存在によってユーザが興味を持つエリアを見つけることを困難にしているという問題がある. 我々はこの問題解決に向けてエリア推薦システムの開発を目指す. 仮想空間のエリアはカテゴリや説明文などのメタ特徴を持っており, これらの特徴をコンテキストと呼ぶ. コンテキストを考慮した既存の推薦手法を改良し, 仮想空間のこのような特性を活かした推薦手法を提案し, 仮想空間 Second Life から収集したデータを用いた評価実験によって提案手法の有用性を確認することができた.

キーワード: 推薦システム, 強調フィルタリング, コンテキスト情報, 仮想空間環境, Second Life

Proposal and Evaluation of Collaborative Filtering Methodology Using Context Information in Virtual World

KANTA KAWASE^{1,†1} BANG HAI LE¹ RUCK THAWONMAS^{2,a)}

Received: January 9, 2015, Accepted: July 1, 2015

Abstract: In this paper, we propose an area recommendation method in a virtual space environment, which has attracted attention for various applications in recent years, and evaluate our method's effectiveness. Virtual space environment is composed of a large number of areas where users can perform such activities as communication and tourism with other users. However, an issue exists that it is difficult for such users to find areas that they are interested in. We aim to develop an area recommendation system for solving this issue. Areas in virtual space have meta features such as categories and descriptions, and they are called contexts. We propose a method that improves an existing recommendation method that considers contexts. The proposed method makes recommendations by taking advantage of the aforementioned characteristics in virtual space. We confirm the effectiveness of the proposed method by experiments using data collected from the virtual space called Second Life.

Keywords: recommendation systems, collaborative filtering, context information, virtual space environment, Second Life

1. はじめに

近年, ユーザにとって有用な情報や商品を選び出し, 提示する推薦システムの普及が進んでいる. 推薦システムは, これまで主に通販サイトや動画サイトなどの2次元 Web コンテンツで使用されてきたが, 仮想空間のような3次元 Web コンテンツへの応用は少なかった. 仮想空間は, 現実世界を模倣して構築され, 様々なアプリケーションの

¹ 立命館大学大学院情報理工学研究科
Graduate School of Information Science & Engineering,
Ritsumeikan University, Kusatsu, Shiga 525–8577, Japan

² 立命館大学情報理工学部
College of Information Science & Engineering, Ritsumeikan
University, Kusatsu, Shiga 525–8577, Japan

^{†1} 現在, セイコーエプソン株式会社
Presently with Seiko Epson Corporation

^{a)} ruck@is.ritsume.ac.jp

ためのプラットフォームを提供していることなどから娯楽目的以外にも研究対象として注目を集めている。しかし、この仮想空間の利用において、ユーザらが豊富なコンテンツの中から自分に合ったコンテンツを見つけることが困難になっているという問題が存在する。本研究では、仮想空間を構成しその豊富なコンテンツを担うエリアに焦点を当て、推薦システムの適用による前述の問題の解決を目指す。

既存の推薦領域では、主に推薦対象ユーザと他のユーザ群の嗜好情報を活用して推薦を行う協調フィルタリング手法 Matrix Factorization (MF) が予測精度や拡張性の高さから用いられることが多い。本研究では、この MF に仮想空間が持つ特徴情報（以降、コンテキスト情報と呼ぶ）をユーザまたはユーザが訪問したエリアと推薦候補エリアとのつながりとして取り入れることで精度向上を狙った協調フィルタリング手法を提案する。提案手法の性能を検証するため、仮想空間 Second Life (SL) から収集したデータを使用しユーザの興味のあるエリアの推薦実験を行った。この実験で、提案手法が従来の推薦領域において用いられてきた MF 関連の既存手法を上回る性能を示し、その有用性を確認することができた。

2. 関連研究

2.1 仮想空間 Second Life

ここでは、研究対象とする SL について説明する。SL はユーザ数 100 万人、構成エリア 25,000 の最も広大な仮想空間の 1 つである。SL ユーザは仮想空間で自分の分身としてのアバターを操作し、様々なエリアへの訪問や他ユーザとのインタラクションなど様々な体験をすることにより現実世界とは異なる第 2 の人生を楽しむことが可能である。

SL は、娯楽目的だけでなく現実世界との多くの類似点から教育 [1] や、研究対象 [2], [3], [4] としても注目を集めている。Callaghan ら [1] は仮想空間環境を利用して工学教育における没入感や魅力をどれだけ生みだすことができるかを検証した。McDonough ら [2] は、SL 内で行われる活動やエリアの保存・記録方法について調査を行った。Steuere ら [3] は、位置情報付きデータとソーシャルネットワークの関係に着目し、SL におけるアバターの位置情報とオンラインソーシャルネットワーク My Second Life を利用したユーザ間のインタラクション予測手法を提案した。

また、SL の利用において、1 ユーザに対し膨大な数のエリアが存在することから、ユーザの行きたい・興味のあるエリアを見つけ出すことが困難になっているという問題がある。この問題に対して Eno ら [4] は仮想空間環境におけるエリア推薦について研究を行った。同研究では SL からデータ収集を行い、コンテンツベースフィルタリングによる実験を行っている。我々は、2.2 節で述べる理由により、コンテンツベースフィルタリングではなく、協調フィルタリングによるエリア推薦手法を提案し、この問題の解決を

目指す。

2.2 推薦システム

推薦システム [5], [6], [7] とは、ユーザにとって有用な情報や商品などを選出し、それらをユーザの目的に合った形で提示するシステムを指す。推薦システムが普及した背景には、大量の情報が情報技術の発展によって発信され、それらの情報の蓄積や流通が容易になり、誰もが多くの情報を得ることができるようになったことがあげられる。この状況が情報過多問題を引き起こした。ここで情報過多問題とは専門性のないユーザが欲しい対象を特定する方法が分からない、探している対象を特定できないといった理由から、情報を参照できる状態にあるにもかかわらず、それを識別できないという問題を指す。この状況に対処するため、ユーザにとって有用な、嗜好に合った対象を予測する推薦システムが考案された。

推薦システムにおける、ユーザの嗜好を予測するためのアルゴリズムは、コンテンツベースフィルタリングと協調フィルタリングに大別される。コンテンツベースフィルタリングはユーザが評価（本研究では訪問）したアイテム群（本研究ではエリア群）と推薦候補アイテム群の特徴を比較して推薦を行う手法である。協調フィルタリングは、推薦対象ユーザと他のユーザ群の嗜好情報（本研究では訪問履歴）を比較して嗜好を推測する手法である。SL における推薦の既存研究 [4] ではコンテンツベースフィルタリングが用いられているが、本研究では、SL ユーザの平均訪問エリア数が全エリア数に対して非常に少なくコンテンツベースで必要とされるユーザプロファイルの作成が難しいという理由から、協調フィルタリングに着目した。

3. 提案手法

3.1 数式記法

文章中でも再度述べるが、既存手法および提案手法で用いる変数を表 1 に示す。

3.2 Matrix Factorization

推薦システムはユーザのコンテンツに対する評価を活用して推薦を行う場合が多い。この評価は、ユーザ $\times$ コンテンツの行列 R で表現されることが一般的である。本研究では、このユーザ評価をエリアに訪問したかどうかのバイナリによって表現する。MF [8] は、この評価値行列 R をユーザ数 $N \times$ 潜在特徴数 K のユーザ特徴行列 P と潜在特徴数 $K \times$ コンテンツ数 M のコンテンツ特徴行列 Q に分解し、分解後の行列 P, Q の内積から未知の評価値を予測するという手法である（図 1）。

ユーザに着目すると他のユーザに比べて多くのエリアを訪問するユーザもいれば少ないエリアしか訪問しないユーザもいる。またエリアに着目すると、人気のエリアもあれ

表 1 変数のまとめ

Table 1 Summary of variables.

Notations	Meaning
N	ユーザ数
M	エリア数
K	潜在特徴数
$R \in \{0,1\}^{N \times M}$	評価値行列
$P \in \mathbb{R}^{N \times K}$	ユーザ特徴行列
$Q \in \mathbb{R}^{K \times M}$	エリア特徴行列
u	対象ユーザ
i	対象エリア
r_{ui}	ユーザ u のエリア i に対する既知評価値
$\hat{r}_{ui}$	ユーザ u のエリア i に対する予測評価値
e_{ui}	既知評価値と予測評価値の差
S	既知の評価値集合
$p_u^T \in \mathbb{R}^{1 \times K}$	ユーザ u の特徴ベクトル (行列 P の第 u 行目)
$q_i \in \mathbb{R}^{K \times 1}$	エリア i の特徴ベクトル (行列 Q の第 i 列目)
b_u	ユーザ u のバイアス
b_i	エリア i のバイアス
$contexts$	コンテキスト集合
$contexts(i)$	エリア i が保持するコンテキスト集合
c_{il}	エリア i が保持するコンテキスト l
b_{uc}	ユーザ u のコンテキスト c へのバイアス
$areas(u)$	ユーザ u が訪問したエリア集合
$sim(i, j)$	エリア i とエリア j の類似度




図 1 Matrix Factorization のイメージ図

Fig. 1 Conceptual diagram of Matrix Factorization.

ば、不人気のエリアも存在する。このようなユーザ，エリアそれぞれが持つ傾向を考慮するため，行列 P ， Q の内積にユーザとコンテンツの評価バイアス b_u ， b_i を加え式 (1) の形でユーザ u のエリア i に対する予測評価値が定義される。

$$\hat{r}_{ui} = b_u + b_i + p_u^T q_i \quad (1)$$

この予測評価値と観測値間の誤差を次の式 (2) として定義する。

$$e_{ui} = r_{ui} - \hat{r}_{ui} \quad (2)$$

そして式 (3) のように二乗誤差に過学習を防ぐための各変数の L2 ノルムをパラメータ λ でコントロールした正則化項を加え，目的関数 (3) を定義する。

$$\min_{b_*, p, q} \sum_{(u,i) \in S} (r_{ui} - \hat{r}_{ui})^2 + \lambda \left(\sum b_*^2 + \|p_u\|^2 + \|q_i\|^2 \right) \quad (3)$$

上記の目的関数を勾配降下法や確率的勾配降下法 (Stochastic Gradient Descent; 以下 SGD) などの最適化手法を用いて最小化を行う。各パラメータの更新式は以下のように表される。

$$p_u \leftarrow p_u + \gamma(e_{ui} \cdot q_i - \lambda \cdot p_u) \quad (4)$$

$$q_i \leftarrow q_i + \gamma(e_{ui} \cdot p_u - \lambda \cdot q_i) \quad (5)$$

$$b_u \leftarrow b_u + \gamma(e_{ui} - \lambda \cdot b_u) \quad (6)$$

$$b_i \leftarrow b_i + \gamma(e_{ui} - \lambda \cdot b_i) \quad (7)$$

ここでパラメータ γ によって勾配をコントロールしている。更新式を用いて導出された結果を用いて評価値を計算し，その値が高いエリアを推薦する。

3.3 Context-Aware Factorization

仮想空間にはコンテンツが持つコンテキスト情報を容易に取得できるという特徴がある。著者らは，SL で取得可能な次の 2 種類のコンテキストに着目し，これらのコンテキストをユーザのエリア訪問に影響を与える要素と仮定し，推薦に活用する。

• カテゴリ

エリアが特定のカテゴリを持つかどうかをバイナリ (0/1) 表現したベクトルで定義される。

• 説明文

エリアを説明する文章中の単語を $tf-idf$ による重みで表現したベクトルによって定義される。 tf (Term Frequency) は単語の出現頻度を， idf (Inverse Document Frequency) は逆文書頻度を表し，2つの積が $tf-idf$ である。エリア i の説明文に含まれる単語 w の出現頻度 tf_{wi} と逆文書頻度 idf_w は式 (8)，(9) で表される。

$$tf_{wi} = \frac{\text{単語 } w \text{ のエリア } i \text{ 説明文中の出現回数}}{\text{エリア } i \text{ 説明文の総単語数}} \quad (8)$$

$$idf_w = \log \frac{\text{総エリア説明文数}}{\text{単語 } w \text{ を含むエリア説明文数}} \quad (9)$$

ここでカテゴリと説明文はエリア作者によって規定されたテキスト情報を指す。

これらのコンテンツが持つようなコンテキスト情報を前述の MF で使用される予測評価値式に組み込んだ手法である Context-Aware Factorization (CAF) [9] が既存手法として存在する。CAF の予測評価値は以下に定義される。




図 2 Context-Aware Factorization のイメージ図

Fig. 2 Conceptual diagram of Context-Aware Factorization.

$$\hat{r}_{ui} = b_u + b_i + \frac{1}{|context(i)|} \sum_{c_{il} \in context(i)} b_{uc_{il}} + p_u^T q_i \quad (10)$$

ここで通常の MF の予測評価値式からの変更点は第 3 項である．第 3 項の $context(i)$ はエリア i が持つコンテキスト集合を， c_{il} は集合 $context(i)$ 内のコンテキスト l を， $b_{uc_{il}}$ はユーザ u のコンテキスト c_{il} に対するバイアスを表す．つまり第 3 項はエリア i が持つコンテキストに対するユーザ u のバイアス（図 2）の平均を意味する．この予測評価値式を前述の目的関数に組み込み，SGD を用いて最適化することで各パラメータを導出することができる． $b_{uc_{il}}$ の更新式は以下のように表される．

$$b_{uc_{il}} \leftarrow b_{uc_{il}} + \gamma(e_{ui} - \lambda \cdot b_{uc_{il}}) \quad (11)$$

3.4 Context-Aware Factorization + Context Similarity Term

CAF は MF にコンテキスト情報を組み込むことで予測精度の改善に成功した．これは，予測評価値式によってユーザと推薦候補エリアが持つコンテキストの直接的な関係を反映させることができたためである．しかし，ユーザのコンテキストに対する嗜好は，訪問エリアが持つコンテキストで表現できると我々は考える．このように訪問エリアと推薦候補エリアのコンテキストを比較することで，ユーザとコンテキストの直接的なつながりだけでなく，訪問エリアを通じた間接的なつながりも考慮する（図 3）ことにより CAF の性能をさらに向上させるため新たな予測評価値式 (12) を提案する．

$$\hat{r}_{ui} = b_u + b_i + \frac{1}{|context(i)|} \sum_{c_{il} \in context(i)} b_{uc_{il}} + p_u^T q_i + \frac{1}{|areas(u)|} \sum_{j \in areas(u)} sim(i, j) \quad (12)$$

ここで $areas(u)$ はユーザ u が訪問したエリア集合を表す．これに対して $sim(i, j)$ はエリア i とエリア j の類似度を表し，コンテキストがカテゴリの場合は以下のジャカード係数 (13) によって類似度を計算する．

$$sim_{jaccard}(i, j) = \frac{|context(i) \cap context(j)|}{|context(i) \cup context(j)|} \quad (13)$$

コンテキストが説明文にある単語の $tf-idf$ 値で表現され



図 3 提案手法のイメージ図

Fig. 3 Conceptual diagram of the proposed methodology.

る場合は，以下のコサイン類似度式 (14) によって計算される．

$$sim_{cos}(i, j) = \frac{\sum_{l \in context(i)} tfidf_{c_{il}} \cdot tfidf_{c_{jl}}}{\sqrt{\sum_{l \in context(i)} tfidf_{c_{il}}^2} \sqrt{\sum_{l \in context(j)} tfidf_{c_{jl}}^2}} \quad (14)$$

提案した予測評価値式の第 5 項は，ユーザ u が評価したエリア群とエリア i が持つコンテキストが類似するほど高評価になる効果がある．また，このユーザのコンテキストに対する訪問エリアを用いた嗜好表現は，コンテンツベースフィルタリングにおけるユーザプロファイルとも解釈できる．このように提案手法は，協調フィルタリングとコンテンツベースフィルタリングの両手法を意識したハイブリッドな手法となっている．この予測評価値式を目的関数式 (3) に代入し，既存手法 CAF のように SGD によってパラメータを導出し，推薦を行う．

4. 評価実験

提案手法である Context-Aware Factorization + Context Similarity Term (CAF+SIM) の有用性を検証するための評価実験を行った．

4.1 データセット

本検証に用いるデータセットには，SL のクロールデータを用いる．既存研究 [4] で使用された SL 用のクロールデータを参考に作成し，データ収集を行った．このデータ収集には，Second Life Destination Guide と呼ばれる Linden 社が SL にある約 25,000 エリアの中からベストなエリアと認定したエリアを紹介するサイトに掲載されているエリア群（データ収集時点で 1,925 エリア）を複数のボットに巡回させ，ユーザがアバタを使ってどのようなエリアを訪問したか，またエリアが持つコンテキスト情報（カテゴリ，説明文）の収集を行った．

データ収集のためには Linden 社に提供されるスクリプト言語を用いている．前記のエリア群には関係者以外によるスクリプトの使用禁止のエリアが含まれているため，データ収集ができたのは 1,308 エリアとなる．また，ボットがあるエリアに入り，スクリプトを実行してデータ収集

表 2 Second Life のユーザ・エリア訪問データ

Table 2 Second Life visiting data.

Data	Second Life Log
Num.non-zeros	25486
Num.users	804
Num.areas	1308
Sparseness	97.58 (%)
AVG.areas per user	31.7

を行った直後、次の巡回先のエリアに移る設定にしたため、収集したデータからはユーザのエリア滞在時間が特定できないが、1 周ごとのデータからユーザのエリア訪問回数が特定できる。本研究ではこの訪問回数をユーザにとって有用なエリアであることを示す指標として採用した。

具体的には、あるユーザに着目した場合、同ユーザのすべての未訪問エリアに対する評価値を 0 とする。訪問エリアに対しては、同ユーザが訪問した回数のパーセンタイルに基づいて以下のアルゴリズムにより評価値を決める。

1. $r = 5$, $i = 5$ とする。
2. IF 評価値が未決定である全エリアのパーセンタイルが同じである OR $i = 1$ THEN

評価値が未決定である全エリアの評価値を r とした後、終了。

ELSE IF 評価値が未決定であるエリアのうち、パーセンタイルが $((i - 1) \cdot 20, i \cdot 20]$ の範囲内にあるエリアが存在する THEN

評価値が未決定であるエリアのうち、パーセンタイルが $((i - 1) \cdot 20, i \cdot 20]$ の範囲内にある全エリアの評価値を r とした後、 $r = r - 1$ とする。

3. IF 評価値が未決定であるエリアが存在する THEN
 $i = i - 1$ とした後、ステップ 2 に戻る。

ELSE

終了

訪問したエリア数が 25 以上かつそれらのエリアの中に自分の平均評価値以上のエリア数（4.2 節に述べる正解エリアの候補数）が 5 以上のユーザのみ実験用データとして使用する。この前処理後のデータを表 2 に示す。Num.non-zeros はユーザ × エリアの訪問行列の非ゼロ要素数を、Num.users はユーザ数、Num.areas はエリア数、Sparseness はユーザ × エリア行列中のゼロ要素の割合を、AVG.areas per user は 1 ユーザあたりの平均エリア訪問数を表す。表 3 にはエリアが持つコンテキスト情報について示す。Num.non-zeros はエリアとコンテキストの組合せ数、Num.contexts はコンテキスト数、Sparseness はエリア × コンテキスト行列中のゼロ要素の割合を、AVG.contexts per area は 1 エリアあたりの平均コンテキスト保有数を表す。

表 3 Second Life エリアコンテキストデータ

Table 3 Second Life area context data.

Context Type	Category (0/1)	Description (tf-idf)
Num.non-zeros	2145	12706
Num.contexts	94	3801
Sparseness	98.26	99.74
AVG.contexts per area	1.64	9.71

4.2 実験プロトコル

実験は既存推薦研究 [10], [11] を参考に行う。まず、データセットをトレーニングセットとテストセットに分割する [10]。トレーニングセットにおけるエリア数を “Given N” と表現する。テストセットには後述する正解エリアをある程度含めること [11] が推奨されているから、各ユーザの訪問エリアの中から正解エリアを推薦リストのサイズ (L) と同じ数でテストセットのデータとして選択しておく。次に、たとえば “Given 5” の場合はランダムに各ユーザの残りの訪問エリアから 5 つの訪問エリアをトレーニングセットのデータとして選択し、最後に残ったすべての訪問エリアをすべての未訪問エリアとともにテストセットに追加するという形で分割が行われる。

各ユーザの正解エリアは、文献 [11] で述べられた決定法に従って、当該ユーザの評価値の平均と標準偏差の合計以上の評価値を持つエリアとする。ただし、同条件を満たすエリア数が L 未満の場合は標準偏差に 1 以下の正の係数を掛け、 L 個のエリアが確保されるまで、徐々に条件を緩めていく。

分割後のトレーニングセットを用いて学習し、テストセットを用いて手法の評価を行う。分割は 5, 10, 15 の 3 段階行う。このようにデータセットの分割を複数パターン実施することによりトレーニングセット数に応じた実験結果を検証する。

4.3 評価尺度

本実験用のデータにはユーザがエリアを訪問したかどうかという情報しか含まれていない。そこでユーザが訪問したエリアを正解エリアとする Top-N 推薦によって推薦手法の評価を行う。Top-N 推薦とは各ユーザに N エリアからなる推薦リストを提示し、そのリストを評価するタスクである。本研究では、Top-N 推薦の場合において価値ある推薦結果は上位 3 件から 5 件であるという “Less-is-More” の考え方に基いて推薦リストの Top-5 エリアのみを評価する。提案手法の性能評価には Top-5 Precision, 1-call at Top-5, Mean Reciprocal Rank の 3 尺度を用いる。

• Top-5 Precision (P@5)

Top-5 Precision は、推薦リストにおける正解比である。各ユーザに対し式 (15) のように計算する。

$$P@5 = \frac{\text{正答数}}{\text{推薦アイテム数}} \quad (15)$$

ここで Top-5 を採用しているため推薦アイテム数が 5 となっている。全ユーザで平均をとったものが Top-5 Precision である。この評価尺度によって推薦リスト全体を評価する。

- 1-call at Top-5 (1-call@5)

推薦リスト内に 1 つでも正解エリアが含まれていれば 1, 1 つも含まれていなければ 0 として各ユーザのスコアとし、ユーザ全体の平均をとったものが 1-call@5 である。1-call@5 によって最低 1 エリアは推薦リストに含めることができたかどうか評価され、Less-is-More が満たされているかが分かる。

- Mean Reciprocal Rank (MRR)

Reciprocal Rank (RR) は、推薦エリアの順位を評価する指標で、式 (16) のように定義される。

$$RR = \frac{1}{n} \quad (16)$$

ここで n はユーザに与えた推薦リストの中でその上から 1 番最初に正解したエリアの順位である。もし推薦リスト中に正解がなければ 0 となる。この RR の全ユーザ平均をとったものが MRR である。

4.4 比較手法

提案手法の有用性を検証するため以下の手法と性能比較を行う。

- PureSVD

PureSVD [12] とは特異値分解 (Singular Value Decomposition, SVD) を用いて評価値行列 R を式 (17) のように $N \times K$ の正規直交行列 U , $K \times K$ の対角行列 Σ , $M \times K$ の正規直交行列 Q の 3 つに分解することで推定する手法である。単純な特異値分解のみを用いた手法でありながら高精度な手法として前記の文献 [12] など推薦関連の多数の論文で比較手法として使用されている。

$$\hat{R} = U \cdot \Sigma \cdot Q^T \quad (17)$$

前述のユーザ特徴行列は式 (18)

$$P = U \cdot \Sigma = R \cdot Q \quad (18)$$

によって定義される。そしてユーザ u のエリア i に対する予測評価値は

$$\hat{r}_{ui} = r_u \cdot Q \cdot q_i^T \quad (19)$$

で定義される。

- Probabilistic Matrix Factorization (PMF)

PMF [8] は 3.1 節の MF のパラメータ更新を SGD によって行う手法である。SGD とは、ランダムにデータを選択

表 4 Given 5 での実験結果

Table 4 Experimental results at Given 5.

Given 5	P@5	1-call@5	MRR
PureSVD	0.067	0.287	0.140
PMF	0.080	0.341	0.163
CAF (Category 0/1)	0.082	0.347	0.168
CAF+SIM (Category 0/1)	0.088	0.363	0.179
CAF (Description tf-idf)	0.079	0.338	0.164
CAF+SIM (Description tf-idf)	0.089	0.370	0.182

表 5 Given 10 での実験結果

Table 5 Experimental results at Given 10.

Given 10	P@5	1-call@5	MRR
PureSVD	0.082	0.340	0.167
PMF	0.089	0.372	0.172
CAF (Category 0/1)	0.096	0.396	0.188
CAF+SIM (Category 0/1)	0.104	0.415	0.210
CAF (Description tf-idf)	0.089	0.374	0.173
CAF+SIM (Description tf-idf)	0.102	0.414	0.209

表 6 Given 15 での実験結果

Table 6 Experimental results at Given 15.

Given 15	P@5	1-call@5	MRR
PureSVD	0.103	0.407	0.207
PMF	0.093	0.385	0.189
CAF (Category 0/1)	0.105	0.423	0.223
CAF+SIM (Category 0/1)	0.118	0.454	0.248
CAF (Description tf-idf)	0.094	0.387	0.192
CAF+SIM (Description tf-idf)	0.115	0.449	0.242

し、選択したデータに対応する勾配によってパラメータを更新する手法である。コンテキスト情報を活用しない手法として、活用する手法との性能差を検証するために比較対象とした。

- Context-Aware Factorization

CAF は 3.3 節で述べたように MF にコンテキスト情報を組み込んだ手法である。PMF と同様に SGD を用いてパラメータ更新を行う。MF よりも精度が高いことが報告されている。コンテキスト情報を組み込んだ MF の改良手法であるこの CAF との比較を行い、提案手法の有用性を検証する。

4.5 パラメータ

各手法に用いるパラメータの決定方法について本節で述べる。提案手法の有用性を示すため、比較手法が高い精度を出すことのできるパラメータを使用する。以下の流れで決定する。実験コンディションを Given 5 に固定し、以下の流れでパラメータを決定する。Given 5 で行う理由は、




図 4 各コンディションにおける P@5 の結果

Fig. 4 P@5 results for each condition.




図 5 各コンディションにおける 1-call@5 の結果

Fig. 5 1-call@5 results for each condition.




図 6 各コンディションにおける MRR の結果

Fig. 6 MRR results for each condition.

トレーニングデータの最も少ないコンディションであり推薦システムの実利用に近い条件であるためである。

(1) 潜在特徴数 K の決定

比較手法の PureSVD で $K = 10, 50, 100$ の 3 パターンで検証し、最も高精度の K を使用する。

(2) γ と λ の決定

PureSVD で最も高精度な結果を出した K を使用し、比較手法 PMF を用いる。 γ を 0.001, 0.005, 0.01 の 3 パターンと λ を 0.01, 0.05, 0.1 の 3 パターンという 3×3 の 9 パターンで検証を行い、最も精度の高い γ と λ の組合せを CAF と提案手法にも使用することで評価実験を行う。

最終的に各手法のパラメータには $K = 10$, $\gamma = 0.001$, $\lambda = 0.1$ を用いる。

4.6 実験結果

表 4, 表 5, 表 6 に各コンディションの実験結果を示す。図 4, 図 5, 図 6 に各評価尺度における実験結果を示す。

5. 考察

表 4～表 6 の結果を見ると、P@5 では提案手法 CAF+SIM が最も優れていた。P@5 は推薦リスト全体を評価する指標である。このことからユーザの嗜好を複数カバーした推薦ができていることが分かる。1-call@5 においても P@5 と同様に提案手法が最も優れた結果を示した。推薦リスト内のエリア順位を評価する MRR も、前記の 2 尺度と同様に提案手法が最も優れていた。このことから推薦リスト内のエリア順位を評価した場合においても提案手法が優れていることが分かる。

図 4～図 6 を見ると、トレーニングセットのサイズが大きくなるにつれて性能に増加傾向が見られる。これは、テストセットに含まれる正解エリアが一定以上存在することを保証するプロトコルを採用しているため、トレーニングセットのサイズに比例して 3 章に述べたパラメータの最適化が機能していると推測できる。

各ユーザのエリア訪問情報を補助するコンテキスト情報について考察する。CAF を用いた場合、カテゴリ、説明文の順に性能が高かった。しかし提案手法においては、Given 5 で説明文、Given 10・15 でカテゴリの方が高かった。このことから性能は予測評価値のモデルおよびトレーニングセットのサイズにも依存するため、カテゴリと説明文の間には優劣はつけられないと考えられる。

CAF に焦点を当てると、全コンディションにおいて提案手法が優れていることが確認された。これは予測評価値式に加えた類似度項が、ユーザの訪問してきたエリアのコンテキストと未訪問のエリアとのコンテキストのつながりをとらえることで、既存手法よりもユーザの嗜好を反映させることに成功したためであると考えられる。

6. まとめ

本稿では、仮想空間環境が持つ様々なコンテキストを組み込んだ協調フィルタリング手法を提案した。既存手法ではユーザとアイテムが持つコンテキストとの関連のみを考慮していた。これに対して、著者らはユーザが訪問したエリア群と予測エリアの間でコンテキストのつながりをも考慮することで精度向上を図り、仮想空間 Second Life から収集したデータを用いて評価実験を行い、その有用性を検証することができた。

今後は、エリアのコンテキストだけでなくユーザが持つコンテキストをも活用した手法や複数あるコンテキストからユーザの嗜好と関連のある有用なコンテキストを自動抽出し、それらのコンテキストを活用して推薦を行う手法の提案を考えている。また、ユーザの訪問エリアについて順

序関係を求め、ある評価値の高いエリアから次の評価値の高いエリアを発見するまでの時間の削減量を新たな評価指標としたい。

謝辞 本研究の一部は文部科学省科学研究費補助金（基盤研究（C）, 課題番号：26330421, 課題名：メタバースとそのソーシャルネットワークのための体験支援）による助成による援助を得て実施された。また、査読者の先生方から有益なご教示、ご助言をいただいた。ここに記して謝意を表する。

参考文献


- [1] Callaghan, J.M., McCusker, K., Losada, L.L., Harkin, J. and Wilson, S.: Using Game-Based Learning in Virtual Worlds to Teach Electronic and Electrical Engineering, *IEEE Trans. Industrial Informatics*, Vol.9, No.1, pp.575–584 (2013).
- [2] McDonough, J., Olendorf, R., Kirschenbaum, M., Kraus, K., Reside, D., Donahue, R., Phelps, A., Egert, C., Lowood, H. and Rojo, S.: PRESERVING VIRTUAL WORLDS FINAL REPORT (2010), available from <http://hdl.handle.net/2142/17097> (accessed 2015-01-04).
- [3] Steurer, M. and Trattner, C.: Predicting interactions in online social networks: an experiment in second life, *Proc. 4th International Workshop on Modeling Social Media*, pp.5:1–5:8 (2013).
- [4] Eno, J., Stafford, G., Gauch, S. and Thompson, W.C.: Hybrid User Preference Models for Second Life and Open-Simulator Virtual Worlds, *Adaption and Personalization Lecture Notes in Computer Science*, Vol.6787, pp.87–98 (2011).
- [5] 神嶋敏弘：推薦システムのアルゴリズム（1），人工知能学会誌，Vol.22, No.6, pp.826–837 (2007).
- [6] 神嶋敏弘：推薦システムのアルゴリズム（2），人工知能学会誌，Vol.23, No.1, pp.89–103 (2008).
- [7] 神嶋敏弘：推薦システムのアルゴリズム（3），人工知能学会誌，Vol.23, No.2, pp.248–263 (2008).
- [8] Koren, Y., Bell, R. and Volinsky, C.: Matrix factorization techniques for recommender systems, *IEEE Computer*, Vol.42, No.8, pp.30–37 (2009).
- [9] Zhang, M., Tang, J., Zhang, X. and Xue, X.: Addressing cold start in recommender systems: A semi-supervised co-training algorithm, *Proc. 37th International ACM SIGIR Conference on Research & Development in Information Retrieval*, pp.73–82 (2014).
- [10] Shi, Y., Karatzoglou, A., Baltrunas, L.B., Larthon, M., Oliver, N. and Hanjalic, A.: CLiMF: Learning to maximize reciprocal rank with collaborative less-is-more filtering, *Proc. 6th ACM Conference on Recommender Systems*, pp.139–146 (2012).
- [11] Said, A., Bellogín, A. and Vries A.: A Top-N Recommender System Evaluation Protocol Inspired by Deployed Systems, *Proc. Large-Scale Recommender Systems 2013, at the 7th ACM Conference on Recommender Systems* (2013).
- [12] Paolo, C., Koren, Y. and Roberto, T.: Performance of Recommender Algorithms on Top-N Recommendation Tasks, *Proc. 4th ACM Conference on Recommender Systems*, pp.39–46 (2010).



川瀬 寛太

報推薦システムの研究に従事。

2013年3月立命館大学情報理工学部知能情報学科卒業。2015年3月同大学大学院情報理工学研究科情報理工学専攻博士課程前期課程人間情報科学コース修了。同年の4月よりセイコーエプソン株式会社に勤務。在学中、情



レ ハイ バン

報推薦システムの研究に従事。

2013年3月立命館大学情報理工学部知能情報学科卒業。ベトナムでの勤務経験を経て国費留学生として同年の9月に同大学大学院情報理工学研究科情報理工学専攻博士課程前期課程人間情報科学コースに入学。2015年9月同



ターウォンマット ラック
(正会員)

究に従事。

1994年東北大学大学院工学研究科情報理工学専攻博士課程修了。博士（工学）。2004年4月より立命館大学情報理工学部知能情報学科教授。計算知能、人工知能、およびゲーム AI の研