

ソーシャルメディア上のアイテム共起を用いたサービス横断推薦

堤田 恭太[†] 中辻 真[†] 内山 俊郎[†] 藤村 考[†]

[†] 日本電信電話株式会社 NTT サイバーソリューション研究所
〒 239-0847 神奈川県横須賀市光の丘 1-1

E-mail: †{tsutsumida.kyota,nakatsuji.makoto,uchiyama.toshio,fujimura.ko}@lab.ntt.co.jp

あらまし 本研究は、ユーザが興味を持つ別サービス中のアイテムを予測して推薦する手法を提案する。これにより、ユーザは普段訪れないサービスからも興味のあるアイテムを発見できるというメリットが生まれる。しかし、自サービスにないアイテムの推薦は、そのアイテムに利用履歴がないことや、自サービスと共通のメタデータが付与されていないため難しい。そこで本研究は、自他サービスのアイテムの情報を含む blog などのソーシャルメディアのデータを用いて推薦を行う。具体的には、自他サービスのアイテムの blog データ上での共起情報と、自サービスのユーザの利用履歴、自他サービスのアイテムとメタデータの間を用いてグラフを構築し、そのグラフ上を Random Walk して被推薦ユーザに推薦する他サービスのアイテムを順位付ける。評価実験は、洋楽と邦楽を別サービスと見なして一方のアイテムの履歴のみから隠された側の履歴を予測し、比較手法と比べて高精度な推薦が可能であることを示す。

キーワード 推薦システム, ソーシャルメディア, Random Walk with Restart

Cross-Service Recommendation Using Item Relations in Social Media

Kyota TSUTSUMIDA[†], Makoto NAKATSUJI[†], Toshio UCHIYAMA[†], and Ko FUJIMURA[†]

[†] NTT Cyber Solutions Laboratories, NTT Corporation
1-1 Hikari-no-oka Yokosuka-Shi Kanagawa, 239-0847 Japan

E-mail: †{tsutsumida.kyota,nakatsuji.makoto,uchiyama.toshio,fujimura.ko}@lab.ntt.co.jp

1. はじめに

推薦システムの登場により、ユーザは膨大な量のアイテムから興味に合ったものをより簡単に発見できるようになった。一方で、ユーザが普段訪れないサービスのアイテムは、ユーザが興味を持つものであってもなかなか見つけられないという問題がある。そこで本研究は、ユーザの自サービスの利用履歴と、ソーシャルメディア上のデータを用いて、ユーザが興味を持つ他サービスのアイテムを予測して推薦する手法を提案する。

しかし、このような推薦は単一のサービスにおける推薦と異なり、複数のサービス間で共通のユーザや共通のメタデータが存在しないことが問題となる。例えば、アイテムとユーザの二部グラフ構造を用いた協調フィルタリングの様な、従来の推薦方式 [1] ~ [4] は、複数のサービスに共通して存在するユーザがいなければ、自サービスのユーザには自サービスのアイテムしか推薦することができない。また、利用履歴の少ない状況でのアイテムの推薦自体、Cold-Start 問題とよばれる推薦の難しい状況であることは広く知られている [5], [6]。

そのため本研究は、blog などのソーシャルメディア上でのア

アイテム間の共起情報を、共通するユーザや共通するメタデータの代わりに用いることで、これらがない条件での推薦を実現する。具体的には、Konstas らが単一のサービス内の推薦のために用いたユーザ、アイテム、タグからなるグラフ [7] を拡張し、blog 上での各サービスのアイテムの共起情報を用いて、複数のサービスを一つのグラフに結合する。次に、そのグラフを用い、グラフ上の様々な関係やグラフの構造を考慮して被推薦ユーザから他サービスのアイテムへの関連度を計算するアルゴリズムである Random Walk with Restart (RWR) によって、被推薦ユーザへのから他サービスのアイテムへの関連度を計算し、その値の高いアイテムから順に推薦を行う。

評価実験では、洋楽と邦楽を別サービスと見なして、ユーザの自サービスの履歴から、隠された他サービスの履歴を予測する実験を行った。提案法に対する比較手法として、(1)blog 上でのアイテムの記述数順による方法、(2)blog 記事を用いたコンテンツフィルタリングによる方法、の 2 つを用意し、提案法は高精度に他サービスのアイテムを推薦可能であることを示した。

本研究が示す成果は以下の 2 点である。

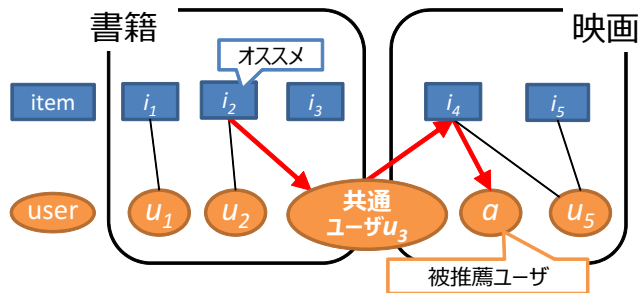


図 1 共通するユーザを用いるサービス横断の概念図

(1) 単一のサービス上でユーザ、アイテム、メタデータの関係性をグラフ化して推薦を行う Konstas らの手法 [7] を、複数サービスのアイテムについての情報を持つ blog データを用いて拡張し、共通するユーザや共通のメタデータのない、他サービスのアイテムを推薦可能なグラフを提案した。

(2) 提案したグラフに RWR を適用した提案法が、比較手法と比べて優れた推薦精度であることを示し、通常は推薦が行えない他サービスのアイテムの推薦が実現可能であることを示した。

本稿の構成は以下の通りである。2 章では、関連研究およびサービス横断推薦に応用する場合の問題点、背景技術となる Random Walk with Restart (RWR) による推薦について述べる。3 章では、問題の定義、提案するグラフの構築手法と RWR によるグラフのマイニング手法など、提案手法について述べる。4 章では、検証用データセット、定量的な評価に用いた評価指標、比較手法、実験結果といった評価実験について述べる。5 章では、本研究のまとめを述べる。

2. 関連研究

本章では、従来の推薦システムの紹介と、サービス横断推薦に適用する場合の問題点、提案法の背景技術となる RWR を用いた推薦について述べる。

2.1 従来の推薦システムのアルゴリズムとその問題点

推薦システムのアルゴリズムには、協調フィルタリング (CF) による方法 [1] ~ [4] が広く用いられている。図 1 は、二部グラフを用いた CF の様に、複数のサービスに共通するユーザを用いて他サービスのアイテムを推薦する場合の概念図である。ここでは例示のため、自サービスを映画サービス、他サービスを書籍サービスとする。この図では、映画サービスに属する被推薦ユーザ a が、利用履歴として i_4 を持つ時、両サービスにアイテムを持つ「共通ユーザ u_3 」を経由して、書籍サービスのアイテム i_2 を a に推薦することができる。しかし、自サービスと他サービスに共通するユーザがない場合や、実際に存在しても、それぞれのユーザ ID の対応がとれない場合には、CF のみでは推薦を行うことができない。

こうした CF のみでは推薦が行えないアイテムは、コンテンツのメタデータなどの様々な属性を用いたコンテンツフィルタリング [8], [9] による推薦を組み合わせるハイブリッド方

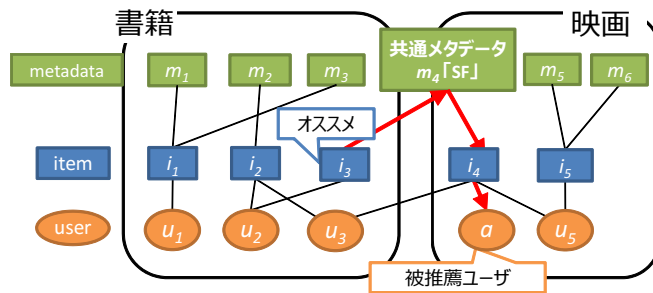


図 2 共通のメタデータを用いるサービス横断の概念図

式による推薦が行われることがある [10]。図 2 は、共通ユーザではなくメタデータを用いて他サービスのアイテムが推薦される例の概念図であり、映画サービスで「SF」を好むユーザ a は、書籍サービスにおける「SF」のアイテムが推薦可能となっている。しかし、こうした組合せによって推薦できるアイテムは、各サービスが扱っているアイテムのごくわずかしかないため、推薦システムが特定のアイテムしか推薦できないという問題がある。また、「SF」のようなメタデータがそれぞれに存在したとしても、異なるサービス間で全く同じ表記のメタデータを用いて管理していることは考えにくい。両サービスのメタデータのマッチングや、整合性のとれた新しいメタデータの体系を用意するコストが掛かってしまう。こうしたサービス間でメタデータやクラスタリング結果の対応をとることが難しい問題に対しては、共通するユーザを用いて関連付ける方法 [11] が提案されているが、この場合は複数のサービスに利用履歴を持つユーザが必要である。

複数のサービスで共通するユーザが存在しない条件での推薦システムの研究は、Li らの異なるサービスの Rating データであっても、その Rating の分布は変わらないと仮定して他サービスのデータを欠損値の補完に用いることで、sparsity の問題に対処して推薦精度を向上させる試み [12], [13] がある。しかし、Li らの実験データにおいては、ユーザの Rating 傾向の分布は同じものを想定できたが、サービスの組合せによってはユーザによって傾向や評点の分布が大きく異なる場合があることや、そもそも Rating データが存在しない場合には適用できないという問題がある。また、あくまでもそれぞれのサービス内における推薦精度の改善を目指した研究であるため、自サービスのユーザに他サービスのアイテムを推薦する目的には利用できない。

2.2 Random Walk with Restart (RWR)

本研究で用いるグラフマイニングの手法である RWR [14] について説明する。

RWR は、ユーザやアイテムをノードとし、ノード間の関係をエッジ、関係の強さをエッジの重みとしたグラフ上の、起点となるノードからの各ノードの関連度 (近接性スコア) を計算するアルゴリズムである。RWR は Random Walk と異なり、各ステップにおいて一定の確率 α に従って起点ノード a に値が付与される点に特徴がある。

被推薦ユーザを表す起点ノードを a 、RWR の繰り返しを表

すステップ数を t , ステップ t における起点ノード a から各ノードの到達確率を表すベクトルを $p^{(t)}$, 前述のグラフを隣接行列として表したものを A , a に対応する要素を 1, それ以外を 0 とするベクトルを q , RWR のハイパーパラメータである定数 $\alpha (0 < \alpha < 1)$ として, 以下の式 (1) を繰り返し更新することにより, 起点ノードから全てのノードへの近接性スコアを計算する. 最終的に, 他サービスのアイテムを表すノードの中で, a からの近接性スコアの高いものから順に推薦すべきアイテムとする.

$$p^{(t+1)} = (1 - \alpha)Ap^{(t)} + \alpha q \quad (1)$$

Random Walk または, RWR を用いる推薦システムの研究がいくつか行われている [7], [15], [16]. 例えば Yildirim らは, アイテムをノードとし, アイテムの類似度をエッジの重みとして持つグラフ上で被推薦ユーザが持つアイテムを起点として Random Walk し, 被推薦ユーザへの推薦の予測値を計算することで, グラフの sparsity に起因する推薦精度の低下を抑え, 従来のメモリベースの推薦システムよりも推薦精度を改善した. また, Konstas らは, 音楽のソーシャルネットワーキングサービス (SNS) である last.fm^(注1) において, サービス上での, ユーザ, アイテム, タグの関係からなるグラフを構築し, そのグラフに RWR を適用して, 被推薦ユーザとアイテム間の結びつきの強さを表す近接性スコアを計算し, そのスコアの高いアイテムから順に推薦する手法を提案した. 推薦精度を比較する評価実験において, タグや SNS 特有のユーザ間の友人関係が, アイテム推薦の精度向上に寄与することを示した.

3. 提案手法

本章では, まず本研究で取り扱う問題を定義し, 次に, 提案するグラフの概要と, その構築方法について述べる.

3.1 問題の定義

表 1 は, 本稿で用いられる主な記号をまとめたものである.

本研究では, 自サービス X の被推薦ユーザ $a \in U^X$ に対して, 他サービス Y のアイテム $i \in I^Y$ についての関連度を表す近接性スコア $s_{a,i}$ を求め, そのスコア順に推薦を行う. 以下の通り, 本研究で取扱う問題を形式化する.

問題: 他サービスに存在するが, a が興味を持ちうるアイテムを予測して推薦

入力: 被推薦ユーザ a と a の自サービスの利用履歴, 自サービスのユーザ履歴, 自他サービスのアイテムの blog 上での出現頻度と共起回数, アイテムのメタデータ

出力: 他サービスに存在するアイテムの近接性スコア

以下, 3.2 節の手順で自サービスの情報を含んだ隣接行列 A を構築する. 推薦にあたっては, 構築された A に対し, 被推薦ユーザ a とアイテム i の近接性スコア $s_{a,i}$ を RWR(式 1) を用いて計算し, その近接性スコア $s_{a,i}$ の高い順にユーザ a にアイテム i を推薦する.

表 1 本研究で用いる変数の一覧

変数	説明
X	履歴のある自サービスを表す記号
Y	履歴ない他サービスを表す記号
U^X	X のユーザ集合を表すベクトル
$I^{X(Y)}$	$X(Y)$ のアイテム集合を表すベクトル
$M^{X(Y)}$	$X(Y)$ のメタデータ集合を表すベクトル
$r_{u,i}$	ユーザ u からみたアイテム i の重み
$r_{i,m}$	アイテム i からみたメタデータ m の重み
$r_{i,j}$	アイテム i からみたアイテム j の重み
I_u	ユーザ u がもつアイテム集合を表すベクトル
M_i	アイテム i がもつメタデータ集合を表すベクトル
a	被推薦ユーザ (推薦を受けるユーザ)
$s_{a,i}$	被推薦ユーザとアイテムの近接性スコア

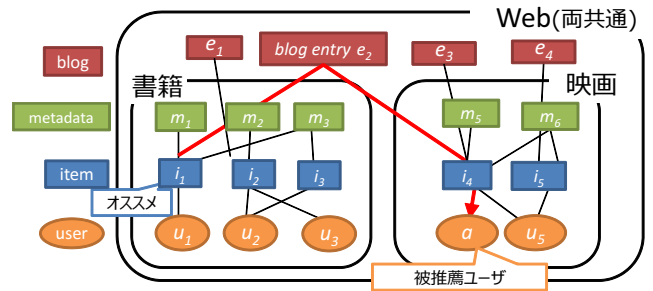


図 3 提案するサービス横断のためのグラフの概念図

3.2 提案するグラフの構築手順

本節では, 提案するサービス横断のためのグラフの構築手順について述べる.

図 3 は提案法の概念図である. 共通するユーザや, 共通メタデータがない場合にも, 両サービスのアイテムの blog 上の関連の強さを表す e_2 があることで, 被推薦ユーザ a に, 他サービスのアイテム i_1 を推薦することができる.

また, Algorithm 1 は, グラフにおける隣接行列を構築する手順であり, 次の 6 つの処理と対応している.

(1) ユーザ-アイテム行列の構築 (1 - 6 行目)

自サービス X におけるユーザ-アイテム関係を表す行列 $U^X I^X$ を, サービス X のデータベースを参照して構築する. 具体的には, あるユーザ u がアイテム i を持っていれば, 行列の要素として定義される $r_{u,i}$ に 1 を代入し, なければ 0 が代入される. 同様に他サービス内におけるユーザ-アイテム関係の関連度の行列を表す $U^Y I^Y$ を構築する.

(2) アイテム-メタデータ行列の構築 (7 - 12 行目)

自サービス X のアイテム-メタデータ関係を表す行列 $I^X M^X$ を, サービス X のデータベースをそれぞれ参照して構築する. 具体的には, あるアイテム i がメタデータ m を持っていれば, 行列の要素である $r_{i,m}$ に 1 を代入し, なければ 0 が代入される. 同様に $I^Y M^Y$ を構築する.

(3) アイテム-アイテム行列の構築 (13 - 18 行目)

アイテム-アイテム関係を表す行列 $I^X I^Y$ を, サービス X のアイテム i とサービス Y のアイテム j との重み $r_{i,j}$ を要素とし

(注1): <http://www.lastfm.com/>

て構築する．この重みには，文書データ上での i と j の出現頻度を用いて，独立性の検定に用いられる χ^2 値 [17] を求めて $\chi_{i,j}^2$ とし，16 行目の通りに最大値で除して用いることで 0 から 1 の間の値に収めて用いた．同様にして，他サービス内におけるアイテム-アイテム関係の関連度の行列を表す $I^Y I^Y$ の行列も構築する．自サービス内のアイテム-アイテム関係の関連度を表す $I^X I^X$ の行列は，自サービス内ではユーザのサービス利用履歴によって二部グラフによる協調フィルタリングと同様にして関連するアイテムをたどることが可能なため，今回は用いなかったためゼロ行列となる．

ここで， χ^2 を用いる代わりに，jaccard 係数 [18] など他の尺度を用いる方法も考えられるが，他の手法は χ^2 値に比べて二つのアイテムの要素間で出現数に差が大きい組合せにおいてうまくいかないことや， χ^2 値は検索エンジンを用いて値を計算するコストが小さいことを鑑みて今回は χ^2 値を用いた．また，今回の検証には blog データをコーパスとして用いているため，blog の記事単位の共起ではなく，blog の同一アカウントの記事全てを一つの記事と見なして重みを計算することもできるが，ニュース記事などのデータにおいても利用可能な方法として，記事単位の共起を採用した．

(4) サービスの組合せ毎に行列を結合 (19 - 20 行目)

サービスの組合せ毎に，上記の手順で構築された行列を結合して A の部分行列として $S^{(X,X)}$ を Algorithm 1 の 20 行目の式の通り構築する．その際，定義されていない $U^X U^X$ ， $M^X M^X$ ， $U^X M^X$ はゼロ行列とする．同様に， $S^{(X,Y)}$ ， $S^{(Y,X)}$ ， $S^{(Y,Y)}$ を構築する．特に，サービスの横断部分を表す $S^{(X,Y)}$ は，アイテム-アイテム行列 $I^X I^Y$ 以外はゼロ行列となる．

(5) 隣接行列 A の構築 (21 - 21 行目)

提案するグラフである隣接行列 A を，サービスの組合せ毎の行列 $S^{(X,X)}$ ， $S^{(X,Y)}$ ， $S^{(Y,X)}$ ， $S^{(Y,Y)}$ を結合して構築する．グラフ上で自サービス内のグラフ $S^{(X,X)}$ と他サービス内のグラフ $S^{(Y,Y)}$ の行き来には， $S^{(X,Y)}$ と $S^{(Y,X)}$ のアイテム-アイテム行列 $I^X I^Y$ を必ず経由する必要があるため，つまり，ソーシャルメディア上でのアイテム間の関連度を用いて，自サービスのみを利用しているユーザに他サービス内のアイテムを推薦可能になる．

(6) 隣接行列 A の正規化処理 (23 - 29 行目)

隣接行列 A について，列の和が 1 なるように正規化処理を行い，提案法の用いる最終的な行列 A を得る．

3.3 RWR によるグラフのマイニング

前節で構築手順を述べたグラフを表す隣接行列 A を用い，被推薦ユーザ a を起点ノードとした RWR (式 1) を収束するまで繰り返し， a から各ノードへの近接性スコアを計算する．被推薦ユーザ a とアイテム i の近接性スコア $s_{a,i}$ が計算され，このスコアの高いものから順に提示することで，ユーザ a へ推薦が行われる．また，収束時の t 時点での $p^{(t)}$ は，アイテムだけでなくメタデータやユーザなどの全ノードについての近接性スコアが格納されているため，他サービスのアイテムを示す領域だけ取り出す必要がある．Algorithm 1 の通りに隣接行列を構築した場合，

Algorithm 1 隣接行列 A の構築手順

Input: ユーザ集合 U^X ，アイテム集合 $I^{X(Y)}$ ，メタデータ集合 $M^{X(Y)}$ ，ユーザ u の持つアイテム集合 I_u ，アイテム i の持つメタデータ集合 M_i

Output: 複数サービスの要素からなる隣接行列 A .

```

1: //  $U^X I^X$  の構築
2: for each user  $u \in U^X$  do
3:   for each item  $i \in I^X$  do
4:      $r_{u,i} = \begin{cases} 1 & i \in I_u \\ 0 & otherwise \end{cases}$ 
5:   end for
6: end for
7: //  $I^X M^X (I^Y M^Y)$  の構築
8: for each item  $i \in I^X$  do
9:   for each metadata  $m \in M^X$  do
10:     $r_{i,m} = \begin{cases} 1 & m \in M_i \\ 0 & otherwise \end{cases}$ 
11:   end for
12: end for
13: //  $I^X I^Y$  の構築
14: for each item  $i \in I^X$  do
15:   for each item  $j \in I^Y$  do
16:     $r_{i,j} = \chi_{i,j}^2 / \max_j \chi_{i,j}^2$ 
17:   end for
18: end for
19: // サービスの組合せ毎に部分行列を結合
20:  $S^{(X,X)} = \begin{pmatrix} U^X U^X & U^X I^X & U^X M^X \\ U^X I^X & I^X I^X & I^X M^X \\ U^X M^X & I^X M^X & M^X M^X \end{pmatrix}$ 
21: // 部分行列を結合して  $A$  を構築
22:  $A = \begin{pmatrix} S^{(X,X)} & S^{(X,Y)} \\ S^{(X,Y)^T} & S^{(Y,Y)} \end{pmatrix}$ 
23: // 隣接行列  $A$  正規化処理
24:  $N = |U^X| + |I^X| + |M^X| + |I^Y| + |M^Y|$ 
25: for  $g = 0$  to  $N$  do
26:   for  $h = 0$  to  $N$  do
27:     $A(g,h) = A(g,h) / \sum_{g=0}^N A(g,h)$ 
28:   end for
29: end for

```

他サービスのアイテム集合への近接性スコアを格納した領域は， $p_i^{(t)} (|U^X| + |I^X| + |M^X| + 1 \leq i \leq |U^X| + |I^X| + |M^X| + |I^Y|)$ となる．

4. 評価実験

本節では，検証に用いたデータセット，定量的な評価を行うための指標，提案法に対して有効性を検証するための比較手法について述べる．最後に，提案法と比較手法について行った評価実験の結果をまとめる．

4.1 検証用データセット

本研究の検証には，doblog^(注2)において，プログラマー (ユーザ) が洋楽と邦楽のアーティスト (アイテム) に関して記述したら，

(注2): <http://www.doblog.com/>

表 2 実験で用いたデータセットの概要

ユーザ数	3800
アイテム数 (アーティスト数)	1800
アイテム数 (洋楽アーティスト)	1078
アイテム数 (邦楽アーティスト)	722
メタデータ数	320
テストセットのユーザ数	284
テストセットの 1 ユーザの平均邦楽アイテム数	10.95
テストセットの 1 ユーザの平均洋楽アイテム数	14.58
blog データ記事数	約 4000 万

ユーザのアイテムの履歴に含まれるとするデータセット [19] を用いた。アイテムには、カテゴリに相当するメタデータが 1 つもしくは複数付与されている。

システムの評価実験を行うにあたり、洋楽の記録と邦楽の記録を別サービスとみなすため、それぞれの記録においてユーザが重ならないようにデータを分割し、双方に共通するユーザが存在しない状態にした。また、洋楽のアイテムと邦楽のアイテムでは、両方に共通して付与されたメタデータは存在しないため、メタデータのみを介しての推薦は行うことができないデータとなっており、複数のサービスでそれぞれにメタデータ表記が異なる状況を想定している。なお、アイテム間の関連度を計算するための blog データには、正解となる履歴データの構築に用いられた doblog のデータは含まれていない。

テストセットのユーザは、洋楽と邦楽の両方のアイテムをそれぞれ 3 つ以上履歴に持つユーザとし、284 ユーザを用いた。

用いたデータセットの規模などの詳細は表 2 の通りである。

4.2 評価指標

推薦システムの評価には、そのシステムの利用目的に応じて様々な指標が用いられる [6], [20]。今回の実験には、評価値のないデータセットにおいて推薦精度を測るために用いられる、MAP (Mean Average Precision) と $P@k$ (Precision@k) を用いた。 $P@k$ の k の値は 1, 10, 100 とした。

$P@k$ は、推薦システムが出力したトップ k 件の結果の中で正解となるアイテム (正解アイテム) の含まれる割合を表す。システムが提示する全件を対象とする Precision と比べて、ランキング上位の精度が比較可能であるため推薦システムの評価によく用いられる。

また、MAP は、まず、ユーザの正解アイテムの出現順位時点における Precision の値を求め、それらを平均した値である平均適合率 (Average Precision, AP) を、テストデータセットの全ユーザについて求めて平均した値を表す。AP や MAP は、特にテストユーザ毎に、含まれる正解アイテム数が異なる場合の推薦精度を比較するのに役立つ。例えば、 $P@k$ は正解アイテムを 100 件持つユーザのトップ 1 を正解する場合と、正解アイテムを 3 件しか持たないユーザのトップ 1 を正解する場合の予測の難しさを区別しないが、MAP の場合は前者が 0.01、後者が 0.33 と扱われるため、予測の難しさが考慮されていることになる。

ここで、ユーザ u の持つ正解アイテムの数を $|I_u|$ 、上位 i 件

目のアイテムが正解なら $r_i = 1$ 、不正解なら $r_i = 0$ と表す時、それぞれの指標は次の通りに定義される。

u の Recall(k) は、式 (2) で与えられる。

$$\text{Recall}(k) = \frac{|\text{システムが提示できた正解アイテム}|}{|I_u|} \quad (2)$$

u の $P@k$ は、式 (3) で表される。

$$P@k = \frac{|\text{システムが提示できた正解アイテム}|}{k} \quad (3)$$

また、 u それぞれの平均適合率 AP_u は、 $P@k$ と r_i を用いて次式 (4) で表される。

$$AP_u = \frac{1}{|I_u|} \sum_{i \in I_u} r_i \times P@k \quad (4)$$

MAP は、平均適合率 AP_u とテストユーザ集合を表すベクトル U_{test} を用いて、式 (5) で表される。

$$MAP = \frac{1}{|U_{test}|} \sum_{u \in U_{test}} AP_u \quad (5)$$

4.3 比較手法

評価実験のため、比較手法として以下を用意した。

(1) blog 記述人気順:

推薦システムを評価するにあたって、アイテムをそのサービスにおける人気ランキング順に並べたものを提示し、定量的な評価の比較手法とする方法が用いられることがある。本実験では、他サービス中の履歴は存在しない状態、もしくは利用できない状態を想定しているが、blog 上でのアイテムの記述順は確認できると考えて、他サービスのアイテムの人気ランキングを blog の記述数をカウントすることで擬似的な人気順として用意した。また、この方法は、全てのユーザに同じ推薦結果が提示される。

(2) blog コンテンツフィルタリング:

被推薦ユーザ a の持つ自サービスのアイテム集合 I_a と、blog データ上で共起する頻度の多い、他サービスのアイテムを順に提示して推薦する方法。

(3) 提案法:

3.2 節で述べた隣接行列に対して RWR を適用し、被推薦ユーザ a との近接性スコア $s_{a,i}$ の高い順にアイテムの推薦を行う方法。RWR のハイパーパラメータ α は 0.9 と 0.1 について検証を行った。

(4) (参考値) 正解データの人気順:

他サービスのアイテムの人気ランキング順に提示する方法を、参考値として用意した。本実験の提案法は、他サービスの人気順や利用履歴に関する情報は用いずに推薦を行っているため、この方法との比較は必ずしも必要ではないと考えられるが、実験データの性質の確認や、推薦精度の目安として用いるために用意した。(1) の blog 記述人気順と同様にこの方法は、全てのユーザに同じ推薦結果が提示される。

表 3 比較手法と提案法の MAP, P@k(洋楽 邦楽)

methods	MAP	P@1	P@10	P@100
blog 記述人気順	0.031	0.032	0.014	0.025
blog コンテンツフィルタリング	0.011	0.014	0.005	0.017
提案法 ($\alpha=0.9$)	0.260	0.306	0.061	0.030
提案法 ($\alpha=0.1$)	0.035	0.038	0.048	0.027
(参考値) 正解データ人気順	0.132	0.302	0.101	0.057

表 4 比較手法と提案法の MAP, P@k(邦楽 洋楽)

methods	MAP	P@1	P@10	P@100
blog 記述人気順	0.031	0.004	0.030	0.019
blog コンテンツフィルタリング	0.017	0.000	0.014	0.019
提案法 ($\alpha=0.9$)	0.067	0.039	0.036	0.030
提案法 ($\alpha=0.1$)	0.031	0.021	0.039	0.027
(参考値) 正解データ人気順	0.071	0.014	0.108	0.048

4.4 実験結果

実験は、全ユーザについて邦楽の履歴を隠して、テストユーザである被推薦ユーザの洋楽の履歴のみから、隠された邦楽の履歴の予測を行った実験と、その逆の、洋楽の履歴を隠して邦楽の履歴のみから、隠された履歴を予測する実験を行った。

表 3 と表 4 にそれぞれの実験における、MAP と $P@k$ の値をまとめた。2 つの比較手法と比べ、提案法は高い推薦精度であることが分かる。

また、参考値として用意した正解データにおける人気順に対しても、 $P@10$ や $P@100$ では劣るが、MAP と $P@1$ において匹敵する精度となっている。特に、提案法の MAP が優れていることは、提案法が少量の履歴しか持たないユーザへの推薦を、他の手法と比べて得意としていることを表していると考えられる。複数人で簡単に推薦結果を比較したところ、人気順には現れないが一部にファンの多いメタル系などのジャンルにおいて、提案法がより適切に推薦ができていたことを確認した。

RWR の α については、今回の実験では 0.9 と 0.1 という極端な 2 例で実験を行ったが、 $\alpha = 0.9$ の方が MAP と $P@k$ は高い傾向となり、起点ノード a をより重視する方が高い推薦精度となった。

5. まとめ

本研究は、複数のサービスを横断して、自サービスのユーザに、共通ユーザや共通のメタデータがない条件下でも、ユーザがまだ利用していない他サービスのアイテムを推薦可能にするためのグラフの構築方法と、そのグラフを RWR によってマイニングして推薦を行う手法を提案した。

また、定量的なシステムの評価にあたり、洋楽と邦楽を別サービスと見なしたデータセットを用いて、自サービスの履歴のみを用いて、隠されたもう一方の他サービスのアイテムを予測する実験を行い、考えられる比較手法と比べて高精度に推薦が可能であることを示した。これにより、ユーザやジャンルなどのメタデータが共通でない異なるサービスを横断してアイテムの推薦を行うために、ソーシャルメディア上のアイテムの共起関

係が利用可能なことを示した。

文 献

- [1] Sarwar, B., Karypis, G., Konstan, J. and Reidl, J.: Item-based collaborative filtering recommendation algorithms, in *Proc. WWW '01*, pp. 285–295 (2001).
- [2] Resnick, P., Iacovou, N., Suchak, M., Bergstorm, P. and Riedl, J.: GroupLens: An Open Architecture for Collaborative Filtering of Netnews, in *Proc. CSCW '94*, pp. 175–186 (1994).
- [3] Sarwar, B. M., Konstan, J. A., Borchers, A., Herlocker, J. L., Miller, B. N. and Riedl, J.: Using Filtering Agents to Improve Prediction Quality in the GroupLens Research Collaborative Filtering System, in *Proc. CSCW '98*, pp. 345–354 (1998).
- [4] Hofmann, T.: Probabilistic latent semantic analysis, in *Proc. UAI '99*, pp. 289–296 (1999).
- [5] Schein, A. I., Popescul, A., Ungar, L. H. and Pienkock, D. M.: Generate models for coldstart recommendations, in *ACM SIGIR 2001 Workshop on Recommender Systems* (2001).
- [6] Herlocker, J. L., Konstan, J. A., Terveen, L. G. and Riedl, J. T.: Evaluating collaborative filtering recommender systems, *ACM Trans. Inf. Syst.*, Vol. 22, No. 1, pp. 5–53 (2004).
- [7] Konstas, I., Stathopoulos, V. and Jose, J. M.: On social networks and collaborative recommendation, in *Proc. SIGIR '09*, pp. 195–202 (2009).
- [8] Balabanović, M. and Shoham, Y.: Fab: content-based, collaborative recommendation, *Communications of the ACM*, Vol. 40, No. 3, pp. 66–72 (1997).
- [9] Mooney, R. J. and Roy, L.: Content-based book recommending using learning for text categorization, in *Proceedings of the fifth ACM conference on Digital libraries*, DL '00, pp. 195–204, New York, NY, USA (2000), ACM.
- [10] 神鷹敏弘: 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).
- [11] Yanagihara, T., Hoashi, K., Ono, C., Matsumoto, K. and Takishima, Y.: Proposal and Evaluation of Cross Media Recommendation, *DBSJ Journal*, Vol. 8, No. 2, pp. 13–18 (2009).
- [12] Li, B., Yang, Q. and Xue, X.: Can movies and books collaborate?: cross-domain collaborative filtering for sparsity reduction, in *Proc. IJCAI '09*, pp. 2052–2057 (2009).
- [13] Li, B., Yang, Q. and Xue, X.: Transfer learning for collaborative filtering via a rating-matrix generative model, in *Proc. ICML '09*, pp. 617–624 (2009).
- [14] Tong, H., Faloutsos, C. and Pan, J.-Y.: Fast random walk with restart and its applications, in *Proc. ICDM '06*, pp. 613–622 (2006).
- [15] Yildirim, H. and Krishnamoorthy, M. S.: A random walk method for alleviating the sparsity problem in collaborative filtering, in *Proc. RecSys '08*, pp. 131–138 (2008).
- [16] Gori, M. and Pucci, A.: ItemRank: A Random-Walk Based Scoring Algorithm for Recommender Engines, in *Proc. IJCAI '07*, pp. 2766–2771 (2007).
- [17] Manning, C. D. and Schütze, H.: *Foundations of Statistical Natural Language Processing*, MIT Press, Cambridge, MA (1999).
- [18] Anderberg, M. R.: Cluster Analysis for Applications, Monographs and Textbooks on Probability and Mathematical Statistics, in *Academic Press, Inc., New York* (1973).
- [19] Nakatsuji, M., Yoshida, M. and Ishida, T.: Detecting innovative topics based on user-interest ontology, *Web Semantics*, Vol. 7, No. 2, pp. 107–120 (2009).
- [20] 神鷹敏弘: 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).