

メタデータ付き推薦のためのグラフマイニング

A Graph Mining Method for Recommending Items with Personalized Metadata

堤田 恭太

Kyota TSUTSUMIDA

中辻 真

Makoto NAKATSUJI

内山 俊郎

Toshio UCHIYAMA

藤村 考

Ko FUJIMURA

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

NTT Cyber Solutions Laboratories, NTT Corporation

In this paper, we propose a graph-based recommender systems which shows recommend items with a selected metadata from a hierarchical metadata tree, such as genres. The item's metadata suitably chosen for users may explain the item well to them or even improve the user's impression of the results. Especially, in case that recommended items have many metadata, system must make a reasonable selection of the metadata considering user's familiarity. The basic idea is that the system calculates the proximity score from active user to items and metadata by using Random Walk with Restarts(RWR) and PageRank. Although RWR can predict items to be recommended, it tends to rate higher the metadata in the higher hierarchical metadata. In order to choose the metadata of the item, our proposed method uses a score obtained by dividing RWR score by PageRank score.

1. はじめに

情報推薦において、提示するアイテムがどういったものであるかをユーザに簡潔に伝えるため、「SF 小説」が好きなあなたには同じ「SF 小説」のこれがお勧めです、というように、アイテムのジャンル等のメタデータを同時に提示されることがある。このとき、提示されるアイテムが複数の異なるメタデータを持っていたり、メタデータが階層的な構造を持って付与されている場合は、システムが何らかの基準でメタデータを選択する必要がある。

そこで本研究は、ユーザ、アイテム、メタデータをノードとするグラフをマイニングして推薦を行う方法 [Konstas 09] に加えて、アイテムを提示する際に、推薦するアイテムへの影響と、ユーザにとっての親密度を考慮して、同時に提示すべきメタデータを選択する手法を提案する。推薦を受けるユーザがより興味を持ちそうなメタデータや、そのメタデータの粒度を予測して提示することで、推薦されたアイテムの内容をより容易に把握できたり、推薦結果そのものの印象を改善できる可能性がある。

本稿の構成は以下の通りである。2 章は、関連研究、背景技術となる Random Walk with Restart(RWR) による推薦、及び PageRank について簡単に述べる。3 章では、提案手法について述べる。特に、RWR による推薦に加えてユーザに適したメタデータを抽出する手法について述べる。4 章では、実験とその結果について述べる。5 章では、まとめと今後の課題を示す。

2. 関連研究

推薦システムの導入においては、推薦精度が高いだけでなく、その推薦システム自体がユーザから信頼を得るような工夫を施さなければならないと言われている [Swearingen 01, Sinha 02, Herlocker 04, McNee 06]。そのための方法もいくつか提案されており、例えば、同時に推薦の根拠を様々な形で提示する研究 [Herlocker 00] や、推薦そのもののシステムが推定した確信

度合いを提示する [McNee 06] などがあり、ユーザの推薦結果に対する納得感を向上することが示されている。

また、最近の推薦結果をより受け入れやすくする工夫の例として、ソーシャルメディアの性格を強めた QA コミュニティであるソーシャルサーチエンジン Aardvark^{*1} に関する研究 [Horowitz 10] が挙げられる。ユーザにマッチする質問をシステムが提示する際に、推薦を受けるユーザは、質問のどのような属性によって、提示されたのかが確認できるようになっており、質問が提示された理由を確認しやすくすることで透明性や納得感の向上に寄与していると考えられる。

2.1 Random Walk with Restart(RWR)

本節では、グラフマイニングの手法である RWR[Tong 06] と、RWR を用いた推薦の関連研究について簡単に説明する。

RWR はグラフ上の起点ノードと他のノードとの近接性を計算するアルゴリズムであり、情報推薦に適用する場合は、ユーザやアイテムをノード、ノード間の関係 (購買関係、メタデータが付与されているかなど) をエッジ、ノード間の関係の強さをエッジの重みとして表現したグラフ上で、推薦を受けるユーザ a を起点ノードとして、起点ノードからアイテムを表すノードへの近接性を計算するために用いられる。アイテムノードの近接性スコアの高いアイテムを、推薦すべきアイテムとして提示する。

より詳細には、式 1 を定常状態となるまで繰り返す事によって計算される。

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

ここで、 $p^{(t)}$ は、 t ステップ後の起点ノード a から各ノードへの到達確率が保存されるベクトル、 q は、起点ノード a を表す値のみを 1、他の値を 0 とするベクトル、 A を、各列の和が 1 になるように正規化されたノード間の隣接行列、 α は、Random walk が起点ノードに戻る確率、 t は繰り返しのステップ数、とする。また、 α の値は 0.9 を用いた。

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 [Konstas 09, Yildirim 08, Gori 07]。例えば Yildirim らは、アイテムをノードとし、アイテムの類

連絡先: 連絡先: 堤田 恭太, 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, 神奈川県横須賀市光の丘 1-1, tsutsumida.kyota@lab.ntt.co.jp

*1 <http://vark.com/>

似度をエッジの重みとして持つネットワーク上で推薦を受けるユーザが持つアイテムを起点として Random Walk し、推薦を受けるユーザへの推薦の予測値を計算することで、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クサービス (SNS) である last.fm^{*2} のデータセットを用い、ユーザとアイテム (楽曲) の関係のみならず、SNS であることを利用して、サービス上で、ユーザ、アイテム、タグの関係をグラフとして表現して RWR を適用し、最終的に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するモデルを提案した。その結果として、タグやユーザ間の友人関係が、アイテム推薦の精度向上に寄与し、ユーザベースの協調フィルタリングより優れた推薦精度となることを定量的に確認している。

2.2 PageRank

本研究で用いる PageRank について述べる。

PageRank は隣接行列 A の最大固有値に対する固有ベクトルを求めることで得られる。一般には、隣接行列 A を n 次の正方行列とし、 β は $0 < \beta < 1$ を満たす定数とすると、式のようなグーグル行列と呼ばれる行列 G を導入して、その行列 G に対する固有方程式 3 を解くことで求めることができる。 β の値は、通例用いられる 0.85 を用いた。また、求められたメタデータ m の PageRank のスコアは、 PR_m と表す。

$$G = \beta A + (1 - \beta) \begin{pmatrix} 1/n & \cdots & 1/n \\ \vdots & \ddots & \vdots \\ 1/n & \cdots & 1/n \end{pmatrix} \quad (2)$$

$$Gr = r \quad (3)$$

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、グラフを表す隣接行列の構築方法、RWR によるアイテムの推薦方法、検討した提示メタデータの選択手法について述べる。

3.1 問題の定義

表 1 に、本研究で用いる主な記号をまとめる。

以下、3.2 節の手順で他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、推薦を受けるユーザ a とアイテム i の近接性スコア $s_{a,i}$ を RWR (式 1 参照) 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 を提示して推薦を行う。提示メタデータの選択にあたっては、3.4 節で提示する手法を用いる。

3.2 隣接行列の構築手順

本節では、グラフを表す隣接行列 A の構築手順について述べる。

まず、ユーザ-アイテム関係を表す行列 UI , IU について、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 を代入する。また、アイテム-メタデータ関係を表す行列 IM , MI について、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 を代入する。 MM については、メタデータ間の上位-下位関係のある組み合わせには 1 を代入し、ない場合は 0 を代入する。その他の、 UU , II , UM , MU はゼロ行列とする。

表 1: 本研究で用いる変数の一覧

変数	説明
U	ユーザ集合を表すベクトル
I	アイテム集合を表すベクトル
M	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	推薦を受けるユーザ (被推薦ユーザ)
$s_{a,i}$	被推薦ユーザとアイテムの近接性スコア
$s_{a,m}$	被推薦ユーザとメタデータの近接性スコア
PR_m	メタデータの PageRank のスコア

構築された 9 つの行列を、次式のように結合して A を構築する。

$$A = \begin{pmatrix} UU & UI & UM \\ IU & II & IM \\ MU & MI & MM \end{pmatrix}$$

最後に、隣接行列 A について、行と列をそれぞれ和が 1 になるように正規化処理を行って、最終的な隣接行列 A を得る。

3.3 RWR によるアイテムの推薦

前節で述べた隣接行列 A を用いて、被推薦ユーザ a を起点ノードとした RWR (式 1) を、定常状態となるまで有限回繰り返す。最終的な p の値として、被推薦ユーザ a とアイテム i の近接性スコア $s_{(a,i)}$ 、および、被推薦ユーザ a とメタデータ m の近接性スコア $s_{(a,m)}$ が計算され、 $s_{(a,i)}$ の高いものから順に推薦アイテムとして a に提示することで、 a へのアイテムの推薦が可能となる。

また、同時に得られる $s_{(a,m)}$ は、提案する提示メタデータの選択手法で用いる。

3.4 提示メタデータの選択手法

本研究では特に、メタデータ付きでアイテムを提示する際に、提示するメタデータを選択する手法について検討した。検討した手法は次の 3 つである。

1. 最下層 (リーフ)

RWR によって求められる近接性スコア $s_{a,i}$ が高いアイテム i が持つメタデータ集合 $m \in M_i$ の中から、階層的なメタデータの中で最もアイテムに近い最下層のもの (リーフ) を、常に出る手法である。リーフが複数ある場合は、より出現回数の多い方が一般的なものである場合が多いため、それを選ぶこととする。

2. RWR の近接性スコア

推薦アイテム i が持つメタデータ集合 $m \in M_i$ の中から、被推薦ユーザ a からのメタデータへの近接性スコア $s_{a,m}$ の最も高いものを提示する手法である。RWR の近接性スコア $s_{a,m}$ が高いものは、アイテムを推薦する場合と同様に、ユーザにとって有意義なものであると考えられる。また、近接性スコア $s_{a,m}$ の高いメタデータは、 i の近接性スコア $s_{a,i}$ に大きく影響しているため、これを選

*2 <http://www.lastfm.com/>

Algorithm 1 提示メタデータの選択手法 (手法 3)

Input: ユーザ a , a に推薦するアイテム i ,
 i のメタデータ集合 M_i , RWR の近接性スコア $s_{a,m}$,
 m の PageRank のスコア PR_m

Output: i と同時に提示するメタデータ $m \in M_i$

- 1: RWR の計算により a に提示するアイテム i を選ぶ
- 2: 同時にメタデータへの近接性スコア $s_{a,m}$ を得る
- 3: i のメタデータの内, RWR の近接性スコアと PageRank の値の比が最も大きいものを選ぶ
- 4: **for** each metadata $m \in M_i$ **do**
- 5: $m = \operatorname{argmax}_m s_{a,m} / PR_m$
- 6: **end for**

ぶのは、推薦アイテムの選択に大きく影響したメタデータを選んでいくことになる。RWR を用いた推薦システムでは、 p に $s_{a,i}$ だけでなく、 $s_{a,m}$ も値が含まれるため、 $s_{a,m}$ を別途計算する必要はない。

3. RWR と PageRank の比

RWR によって求められる近接性スコア $s_{a,i}$ から、グラフの構造上スコアを得やすい分を割り引く手法。具体的には、Algorithm1 に概要を示すように、PageRank の値で RWR による近接性スコアを割った値が高いメタデータを提示する。PageRank の値で割ることによって、メタデータが階層的な構造を持っている場合に、RWR がよりリンクを多くもつ上位階層のノードに高い近接性スコアを付けやすい傾向があるのを抑える目的がある。

4. 実験と結果

本節では、実験とその結果について述べる。実験に用いたデータセットの概要および、アイテムの推薦精度を比較する実験の結果と、同時提示するメタデータを選択する実験の結果について述べる。

4.1 検証用データセット

システムの評価実験を行うにあたり、過去の *doblog*^{*3} のデータから、ブロガーが洋楽と邦楽のアーティストについての記述回数を元にしてユーザのアーティストへの興味を収集したデータセット [Nakatsuji 09] を用いた。メタデータは、アイテムを管理するためのカテゴリに相当するものが 1 つ以上付与されており、メタデータの最下層 (リーフ) が複数付与されているものがあることや、メタデータ間で階層構造を持つという特徴がある。

例えば、ある邦楽のグループのアーティストには、[(ルート)]-[邦楽]-[J ポップ]-[グループ]-[(邦楽のアイテム)]、といったメタデータが全て付与されており、同時に、[(ルート)]-[邦楽]-[ロック]-[ギターロック]-[(邦楽のアイテム)]、というメタデータが付与されている。

4.2 アイテムの推薦精度評価

推薦システムの定量的な評価には様々な指標が用いられる [Herlocker 04, 神島 07] が、今回は評価値のないデータで推薦精度を測るために用いられる、 $P@k$ と MAP (Mean Average Precision) を用いた [Manning 08]。 $P@k$ は、推薦システムが出力したトップ k 件の結果の内、正解アイテムの含まれる割

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)	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

表 3: 人気順と RWR の MAP, $P@k$ (洋楽 邦楽)

methods	MAP	$P@1$	$P@10$	$P@100$
正解データ人気順	0.132	0.302	0.101	0.057
RWR($\alpha=0.9$)	0.367	0.289	0.062	0.030

合を表す。Precision による評価と比べて、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。本研究の k は 1, 10, 100 の値を用いた。

MAP は、ユーザのもつ各アイテムの出現順位時点における Precision の平均である平均適合率 (AP) を、テストセットの全ユーザについて求めて平均した値を表し、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に、手法間での推薦精度を比較するのに役立つ。

また、RWR によるアイテムの推薦精度を簡単に検討するため、比較する手法としてアイテムのデータセット内での人気順に提示する方法 (正解データ人気順) を用意した。

4.3 実験結果と考察

本節では、アイテムの推薦精度評価実験の結果と、同時に提示するメタデータの各手法での選択した結果について述べる。

まず、アイテムを提示する実験では、ユーザのアイテムの中から洋楽のアイテムのみを用いて、隠した邦楽のアイテムを予測する実験を行って定量的な評価を行った。

表 3 は MAP と $P@k$ の値をまとめた表である。正解データ中の出現数順に提示する手法 (正解データ人気順) と比べて、提案法の RWR による手法は高い精度であることが分かる。特に、RWR による推薦精度は、MAP の値が高いことから少量の履歴しか持たないユーザへの推薦を適切に行えていると考えられる。

また、表 4 は、各手法のメタデータの提示結果の典型的な例として、あるユーザに対して RWR で推薦を行った上位 5 件のアイテムについて、まとめたものである。INPUT の行は、ユーザの邦楽のアイテムを予測するために用いられた洋楽のアイテムのリストであり、OUTPUT の行は、推薦アイテムの順位とアイテム名のリストである。太字はシステムが正しく予測できたアイテムを表す。また、各手法毎に、各推薦アイテムに対して同時に提示するメタデータをまとめている。

表の通り、(1) 最下層 (リーフ) は、アイテムの内容に近いものが提示されているが、最頻出のメタデータを用いてもユーザにとって聞き慣れないものが含まれやすい傾向があり、ユーザはある程度そのジャンル (メタデータ) について知っている必要がある。一方で、(2) RWR の近接性スコアの高いメタデータを提示する手法は、ユーザにとってより親しみのあるものになりやすいはずであるが、階層的に付与されたメタデータの場合は、邦楽 (最上位層) に集中してしまう傾向が見られ、そ

*3 <http://www.doblog.com/>

表 4: 推薦アイテムのリストと、手法毎の提示メタデータの比較

INPUT(洋楽アイテム)	ストラトヴァリウス, ロブ・ゾンビ, アイアン・メイデン				
OUTPUT(邦楽アイテム)	ORANGE RANGE	hide	ELLEGARDEN	X JAPAN	キャラル
(1) 最下層 (リーフ)	オルタナティブ	ギターロック	ハードロック	ギターロック	ルーツロック
(2) RWR の近接性スコア	邦楽	邦楽	邦楽	邦楽	邦楽
(3) RWR と PageRank の比	オルタナティブノパンク	ロック	ロック	ロック	ロック

のままでは利用できないことが分かった。最後の (3)RWR と PageRank の比を用いる手法は、ある程度アイテム毎に異なるメタデータを提示できていることが分かるが、上位のメタデータを提示する傾向がある。

5. まとめと今後の予定

本研究は、ユーザ、アイテム、メタデータからなるグラフをマイニングし、RWR によってアイテムを推薦する際に、推薦結果の印象を改善することを目的としてユーザに合ったメタデータを選ぶ手法を提案した。RWR によってユーザと関連の強いメタデータを選択しながら、メタデータが階層的に付与されている場合の問題を PageRank の値を用いて解消することで回避することができた。今後は、被験者を募って実際にアイテムの印象がどのように変わるかを評価し、有効性を検討していきたいと考えている。

参考文献

- [Gori 07] Gori, M. and Pucci, A.: ItemRank: A Random-Walk Based Scoring Algorithm for Recommender Engines, in *Proc. IJCAI '07*, pp. 2766–2771 (2007)
- [Herlocker 00] Herlocker, J., Konstan, J., and Riedl, J.: Explaining collaborative filtering recommendations, in *Proc. CSCW '00*, p. 250ACM (2000)
- [Herlocker 04] 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)
- [Horowitz 10] Horowitz, D. and Kamvar, S. D.: The anatomy of a large-scale social search engine, in *Proc. WWW '10*, WWW '10, pp. 431–440, New York, NY, USA (2010), ACM
- [Konstas 09] Konstas, I., Stathopoulos, V., and Jose, J. M.: On social networks and collaborative recommendation, in *Proc. SIGIR '09*, pp. 195–202 (2009)
- [Manning 08] Manning, C. D., Raghavan, P., and Schütze, H.: *Introduction to Information Retrieval*, Cambridge University Press (2008)
- [McNee 06] McNee, S. M., Riedl, J., and Konstan, J. A.: Being accurate is not enough: how accuracy metrics have hurt recommender systems, in *Proc. CHI '06*, pp. 1097–1101 (2006)
- [Nakatsuji 09] 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)
- [Sinha 02] Sinha, R. and Swearingen, K.: The role of transparency in recommender systems, in *CHI '02 extended abstracts on Human factors in computing systems*, CHI '02, pp. 830–831, New York, NY, USA (2002), ACM
- [Swearingen 01] Swearingen, K. and Sinha, R.: Beyond algorithms: An HCI perspective on recommender systems, in *ACM SIGIR 2001 Workshop on Recommender Systems* (2001)
- [Tong 06] Tong, H., Faloutsos, C., and Pan, J.-Y.: Fast random walk with restart and its applications, in *Proc. ICDM '06*, pp. 613–622 (2006)
- [Yildirim 08] 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)
- [神鷹 07] 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)