

# ユーザコンテキストの同定を伴う推薦システムの提案

佐藤 宙

高木 友博

明治大学大学院理工学研究科

明治大学理工学部情報科学科

hrsatoh@cs.meiji.ac.jp

takagi@cs.meiji.ac.jp

**概要** 近年の推薦システムに関する研究では、ユーザに付帯する情報やユーザが置かれている状況、すなわちユーザコンテキストが強く注目されている。ユーザコンテキストは、商品を購入する際などのユーザの嗜好に大きく影響するため、システムがこれを考慮することでより質の高い推薦が可能となることが知られている。通常、ユーザコンテキストにはデータセット等によって明示的に与えられた情報を用いるが、一方で、明示的に取得可能な情報以外をユーザコンテキストとして用いる試みはあまり行われていない。本稿では、暗黙的に与えられたデータや外部情報などを用いてユーザの嗜好コンテキストの同定を行い、これを用いた推薦手法を提案する。実験結果から、提案手法が Top-N 推薦において、コンテキストを用いない既存手法よりも優位であることを示せた。

**キーワード** 情報推薦, コンテキスト, 協調フィルタリング, ユーザの嗜好

## 1 はじめに

近年、e-commerce や SNS などの普及によって、Web 上には膨大な情報が蓄積されている。しかし、欲しい情報が Web 上にあると分かっているにもかかわらず、欲しい情報を見つけれられないような情報過多問題が発生している。膨大な情報を収集し、ユーザが必要とする情報を選び出すシステムの一つとして推薦システムが挙げられる。

今日では、推薦システムは Web 上の様々な箇所でも用いられており、ユーザの履歴や嗜好の情報を基に推薦結果を提示している。しかし、本来システムが考慮すべき情報はこれだけでは不十分である。例えば現在の天気など、ユーザが現在おかれた状況によってユーザの必要とする情報は変化するため、これを考慮しないと推薦の質を低下させる恐れがある。この問題に対処するため、近年ユーザの状況を考慮した推薦システムに関する研究が盛んである。

ユーザコンテキストの種類は様々で、タイムスタンプや位置情報のような、暗黙的取得が比較的容易なものから、ユーザの行動目的など、アンケート等による明示的取得が必要なものまで存在する。一般的に、後者の方がよりユーザの行動に与える影響が強いため、推薦システムに用いることによる推薦の質の向上が大きいといわれている。

しかし、そのような有用なコンテキスト情報を利用することは現実的に困難である場合が多い。ユーザコンテキストを考慮した推薦を行うにあたっては、各ユーザの行動に対してその時点のコンテキスト情報を逐一取得し、データに記録しておく必要がある。しかし前述のように、有用なコンテキスト情報の取得には明示的な

手段が必要になる場合が多いため、必要なコストは高くなる傾向がある。先行研究[1][2]における実験でも、コンテキストとして用いられている情報はタイムスタンプや位置情報など、比較的取得の容易なものが大半を占めている。

そこで我々は、有用なコンテキスト情報を暗黙的に与えられた情報から同定し、これを利用することで、他のコンテキストが取得困難な環境下でも質の高い推薦を行うことを目指す。

本稿では、ユーザの履歴とアイテムのコンテンツ情報からユーザの嗜好の傾向を同定し、文献[3][4]などで提案されている手法に組み込むハイブリッド型推薦システムを提案する。なお、ユーザの嗜好の傾向とは、アイテムのコンテンツ情報に対して潜在的ディリクレ配分法(Latent Dirichlet Allocations, LDA)を適用して生成するトピックの確率分布によって表すものとする。

以下、2 章では関連研究について述べ、3 章ではコンテキスト同定の手順について述べる。4 章では評価実験とその結果の考察を述べ、5 章で本研究を結論付ける。

## 2 関連研究

### 2.1 ユーザコンテキストを考慮した推薦

ユーザコンテキストを考慮した推薦システムでは、大別すると pre-filtering 方式、post-filtering 方式、contextual modeling 方式の 3 種類のアプローチが取られている。

pre-filtering 方式とは、訓練用データから推薦を提示したいユーザと共通のコンテキスト情報をもつデータのみを選び出し、それを新たな訓練用データとして推薦を行う手法である[5]。post-filtering 方式は、一旦コンテキストを考慮せずに通常の推薦を行った後、各アイテ

ムとユーザコンテキストの適合性に基づく推薦結果の修正を経てからユーザに提示する[6]. **contextual modeling** 方式とはモデルベース推薦を拡張したもので、各ユーザ、アイテム、コンテキスト間の嗜好の規則性を分析してモデル構築を行い、それを基に推薦を行う手法である。代表的なモデルとしては、行列因子分解を拡張したテンソル因子分解が Karatzoglou, N. らによって提案され、広く知られている[3].

本稿では、主に **pre-filtering** 方式と **contextual modeling** 方式への適用を想定した手法を提案する。

## 2.2 ユーザコンテキストの同定

Hariri, N. らは、アイテムのコンテンツ情報から LDA によって生成された潜在的トピック情報をユーザがアイテムを評価した際の嗜好を表すコンテキストと定義した上で、マルコフモデルによって嗜好の推移を予測することでコンテキストの同定を行っている[7].

本稿は、LDA によって生成されたトピック情報をコンテキストとし、さらにマルコフモデルによる予測を行う点で多くの共通点をもつが、[7]では同定したコンテキストに適合する独自の推薦システムを提案しているのに対し、本稿はこれを既存の推薦システムに導入し、様々な推薦システムに対する汎用性を考慮する点で異なる。

また Said, A. は、未知のユーザコンテキストを同定し推薦に利用する研究は未だ数が少ないとしながらも、コンテキスト同定を伴うハイブリッドな推薦システムの重要性を示唆している[8].

## 2.3 ユーザの嗜好反映

本稿はユーザの嗜好をコンテキスト情報として扱っているが、以前からユーザの嗜好を推薦に反映させることを目的とした研究は数多い。そのためのアプローチとしては、ユーザが購入したアイテムのコンテンツ情報からユーザの嗜好モデルを構築し、それに合致するアイテムを優先的に推薦するといったものがある[9].

関連研究では、ユーザプロファイルの構築手法と、それに基づいた独自の推薦エンジンが提案されていることが多いが、本稿で提案するのはユーザコンテキストの同定方法と推薦エンジン中での利用方法のみとし、推薦エンジンを同定したコンテキストに特化することはない。

## 3 ユーザコンテキストの同定を伴う推薦システム

本研究の目的は、ユーザの行動に影響をもたらすコンテキストを同定し、そのコンテキストに適したアイテムの推薦を行うことである。しかし、特定のコンテキストがユーザの行動に影響をもたらすかどうかは推薦のドメインに依存することが多い。例えばユーザの位置情報は、

街中の店舗を推薦するには有用であっても、映画を推薦するにはあまり有用ではないと考えられる。そこで本稿では、幅広いドメインで有用性があると考えられるコンテキストとして、ユーザの嗜好の同定を行う。本稿では、このコンテキストを **Preference Context** と呼ぶ。**Preference Context** は後述の理由より、LDA の各トピックを属性とした確率分布で表現されるものとする。

はじめに、**Preference Context** は評価したアイテムのコンテンツ情報によって表現可能であると仮定する。一般的に、コンテンツ情報は単語の集合によって表現されるため、これを基にそれぞれの単語に対する嗜好の度合を考えることになる。つまり、**Preference Context** の属性数は単語の種類数に等しいと考えられる。しかし、コンテンツ情報のデータセットによっては極めて多数の単語を有することがあるため、このような場合に上記の考え方を適用することはあまり現実的ではない。

そこで、各アイテムのコンテンツ情報を 1 つの文書と考え、これらに対し LDA による処理を事前に行う。以後、コンテンツ情報は LDA によって生成されたトピックの確率分布に置き換えて考えることとする。したがって、**Preference Context** は LDA のトピックによって表現でき、その属性数はトピック数にまで減らすことができる。なお、コンテンツ情報のデータセット(Content Base)に LDA を適用し、トピック情報に置き換えたものを **Topic Base(TB)**と呼ぶことにする。

また、ユーザが次にどのような **Preference Context** をもつかという、未来に評価されるアイテムは知りえないため、上記の仮定を用いて **Preference Context** を与えることはできない。そこで、訓練用データにおける **Preference Context** の時系列推移の傾向からモデルを構築することで直近の **Preference Context** から直後の **Preference Context** を予測、これを基に推薦を行う。

このシステムは、モデル構築部とコンテキスト同定部に分けることができる。両者は独立しており、個々に処理することが可能である。以下に両者の詳細を述べる。

### 3.1 モデル構築部

以下にモデル構築部の処理の流れを述べる。図 1 にシステム構成を示す。また、図 1 中に付した番号は、処理の流れに付した番号と対応している。

- ① 訓練用データ中の各ユーザの評価に対する **Preference Context** を取得する。あるアイテム  $i$  を評価した際の **Preference Context** は、TB 中の同アイテムに関するトピック  $t$  の確率分布に等しいため、式(1)のように表される。

$$preferenceContext(t|i) = \Pr(t|i) \quad (1)$$

ユーザの評価履歴は時系列順に並んでいるもの

とすため、Preference Contextの時系列推移を得ることができる。

- ② ①を基に時系列予測の確率モデルを構築する。これを Context Transition Model(CTM)と呼ぶ。今回は、確率モデルにマルコフモデルを採用する。Preference Context はトピックの確率分布で表現されるが、マルコフモデルの構築にあたっては最も確率値の高いトピックのみを考慮する。このトピック  $t$  を *mainTopic* と呼び、式(2)で定義される。

$$\text{mainTopic}(i) = \arg \max_t \Pr(t | i) \quad (2)$$

また、マルコフモデルの階数を  $M$  としたとき、連続する  $M$  個の *mainTopic* からあるトピック  $t$  に推移する確率 *transPr* は式(3)で与えられる。

$$\text{transPr}(t_{M+1} | t_1, t_2, \dots, t_M) = \frac{\text{freq}(t_{M+1} | t_1, t_2, \dots, t_M)}{\text{freq}(t_1, t_2, \dots, t_M)} \quad (3)$$

$\text{freq}(t_1, t_2, \dots, t_M)$  は訓練用データで *mainTopic*  $t_1 \sim t_M$  が順番に出現した回数、 $\text{freq}(t_{M+1} | t_1, t_2, \dots, t_M)$  は  $t_1 \sim t_M$  が順に出現し、かつ次に  $t_{M+1}$  が出現した回数を表す。なお、図1は  $M=1$  の場合を表す。

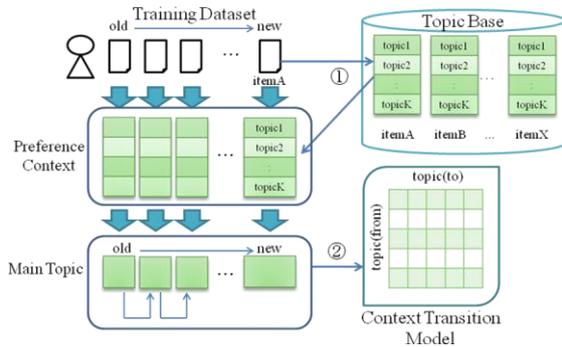


図1 モデル構築部・システム図

### 3.2 コンテキスト同定部

コンテキスト同定部では前節で述べた考えに基づき、対象ユーザの現在の Preference Context を TB と CTM を用いて同定する。これとユーザの評価履歴を推薦エンジンに入力して、同定したコンテキストに基づく推薦を行う。図2にコンテキスト同定部のシステム構成を示す。以下に処理の流れを述べる。また前節と同じく、図中の番号と処理の流れに付した番号は対応している。

- ① 対象ユーザの評価履歴において、TB から直近  $M$  回分の評価アイテムに対応する Preference Context を取得する。また、対象ユーザの直近  $M$  回分の評価アイテム列  $I$  を式(4)で表す。

$$I = (i_1, i_2, \dots, i_M) \quad (4)$$

- ② ①で得た直近の Preference Context を CTM に入力し、推薦を受ける時点での Preference Context (図2中の Identified Preference Context に相当) を求める。Preference Context は式(5)に示す確率値 *contextPr* をもとに、トピックの確率分布の形式で得られる。

$$\text{contextPr}(t | I) = \text{transPr}(t | \text{mainTopic}(i_1), \text{mainTopic}(i_2), \dots, \text{mainTopic}(i_M)) \quad (5)$$

- ③ ②で求めた Preference Context を対象ユーザの評価履歴とともに推薦エンジンへ入力し、各アイテム  $i$  に対する *score* を求める。しかし、一般の推薦エンジンは、コンテキストにはいずれか1つの属性に離散的な値を与えることのみを想定している。Preference Context の場合、属性とは各トピックを指すが、Preference Context はこれらの確率分布であるため、コンテキストの表現が一般のエンジンと合わない。そこで式(6)のように、各トピックを個別にエンジンへ入力し、*recScore* の確率値による加重平均を *score* とすることで、コンテキストの表現の差を補う。ただし、 $\text{recScore}(i, t)$  とはある推薦エンジンにトピック  $t$  をコンテキストの属性として入力した際のアイテム  $i$  の嗜好予測値を意味する。また、 $K$  は LDA のトピック数を表す。

$$\text{score}(i, I) = \sum_t^K \text{contextPr}(t | I) \text{recScore}(i, t) \quad (6)$$

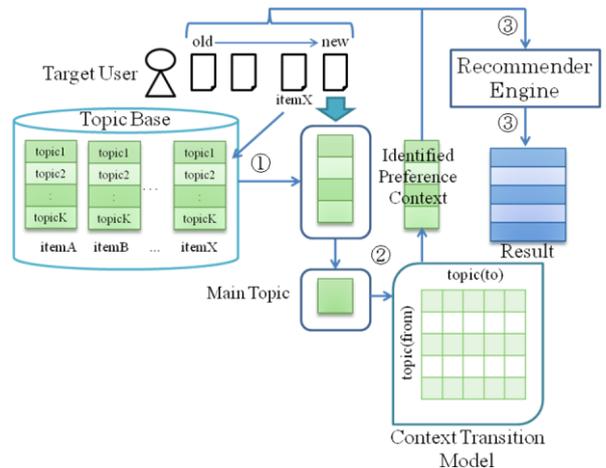


図2 コンテキスト同定部・システム図

以上の処理の多くは、文献[7]を基に考案したものであるが、本節③では独自の処理を行っている。この処理によって、ユーザコンテキストを考慮した既存の推薦エンジンに組み込んだ際に、より推薦の質が高まることを目指している。

## 4 評価実験

本章では実験により、ユーザコンテキストの同定を行うことで従来より質の高い推薦結果が得られることを示す。実験には Art of the Mix と呼ばれるデータセットに対し、後述の加工を行ったものを用いた。このデータセットには、ユーザによって評価された楽曲の履歴がプレイリストとして記録されている。規模の概要を表 1 に示す。また、提案手法にはアイテムに対しコンテンツ情報が与えられている必要がある。コンテンツ情報取得先として、Last.fm データセットを利用する。Last.fm データセットには、アイテムに対してジャンルや年代などを表すタグ情報が記述されている。

Art of the Mix の加工内容について説明する。ユーザコンテキストを考慮した推薦は従来の協調フィルタリング(CF)等と比べてデータのスパース性による cold-start 問題が起こりやすく、各アイテムに対し十分なデータ量がない場合は却って精度が低下する[11]。実験ではこの現象を避けるために閾値  $h$  を定め、被評価数が  $h$  未満のアイテムをデータセットから除外した。また、先述の通り各アイテムにはコンテンツ情報が与えられている必要があるため、Last.fm でコンテンツ情報が得られなかったアイテムも同様に除外する。また、この処理によってあるユーザが評価したアイテムが全てなくなった場合、そのユーザはデータセットから除外される。今回、閾値  $h$  を 50 として実験を行った。

表 1 Art of the Mix データセットの概要

Data Set	非加工	加工( $h=50$ )
Users	15,230	10,853
Items	134,652	1,096
Playlists	101,346	45,744
Ratings	544,615	96,471

本稿の提案手法では評価の時系列を利用し、過去の評価からその直後のユーザコンテキストを同定する。これに基づき、次の方法で推薦対象ユーザの入力データと正解データ、および訓練用データを生成する。

- ① ユーザの評価履歴を時系列順にソートする。
- ② アイテム数が  $M+5$  以上のプレイリスト  $L$  を持ち、かつそのリスト以前( $L$  含む)の総評価数が 10 以上のユーザを推薦対象ユーザとする。これ以外のユーザの履歴は訓練用データとして用いる。 $M$  はマルコフモデル(CTM)の階数である。
- ③  $L$  のうち最新 5 評価を正解データ、それ以前の評価を入力データとする。対象ユーザは最低でも 10 評価以上しているため、ユーザ毎に入力データとして 5 評価以上存在することになる。

入力データのうち、最新  $M$  個のアイテムは式(4)の  $I$

として与える。CTM に入力するアイテムと正解データのアイテムは同じプレイリストに含まれるが、同じプレイリストのアイテムは間をおかず連続して視聴されるものと考えられるため、CTM によって対象ユーザに適した Preference Context の同定を行うことが期待できる。

なお、この方法によって、表 1 の加工済データセットより計 401 人の対象ユーザを得ることができた。

### 4.1 推薦エンジン

本稿の提案手法では、同定したユーザコンテキストを既存の推薦エンジンに用いることを想定している。よって本実験では、代表的な手法として Tensor Factorization(TF)[3]、および Context-Aware Matrix Factorization(CAMF)[4]を用いる。

これらの手法は、ユーザ、アイテム、コンテキストで表現される評価値テンソル  $Y$  を複数の低ランク行列に分解するアプローチで、 $Y$  を補完したテンソル  $F$  を構築し、これを基に CF を行うものである。また、 $Y$  と  $F$  は近似の関係にあり、式(7)の関係が成り立つ。

$$\sum_{u,i,c} D_{uic} (Y_{uic} - F_{uic})^2 \approx 0 \quad (7)$$

テンソルの成分  $Y_{uic}$ ,  $F_{uic}$  は、ユーザ  $u$  がアイテム  $i$  をコンテキスト  $c$  の状態で評価した際の嗜好の度合を表す。 $D_{uic}$  は、 $Y_{uic}$  で何らかの値が観測されていれば 1、未観測であれば 0 とする。すなわち、式(7)は  $F$  の成分について、 $Y$  で観測された成分との誤差のみを考慮し、それ以外に関しては制約を設けないことを意味する。

なお本稿では評価値テンソル  $Y$  の構築にあたり、ユーザ  $u$ 、アイテム  $i$  に対応するコンテキスト  $c$  のベクトルに対し、TB 中のトピック確率分布を代入した。

CF では評価値行列  $Y$  からユーザ間の類似度を求め、最近傍ユーザの評価値を利用して対象ユーザ  $a$  の評価値を予測する。対象ユーザ  $a$  とユーザ  $u$  の類似度  $\rho_{au}$  は、2 人が評価しているアイテム集合について、Jaccard 係数を用いて計算している。 $Y$  を補完したテンソル  $F$  を用いると、コンテキスト  $c$  の下で対象ユーザ  $a$  のアイテム  $i$  に対する評価値  $score_{aic}$  は式(8)で予測される。

$$score_{aic} = \frac{\sum_u \rho_{au} F_{uic}}{\sum_u |\rho_{au}|} \quad (8)$$

なお、この例ではコンテキストは 1 種類のみとして 3 階のテンソルについて考えたが、2 種類以上のコンテキストを同時に考慮することも可能である。この場合、テンソルの階数は 4 階以上となる。

### 4.2 ハイパーパラメータの設定

提案手法では、事前に幾つかのハイパーパラメータ

の設定を行う必要がある。1つはLDAのトピック数  $K$  である。この値は、本稿と同じく Art of the Mix データセットを用いた実験を行った文献[7]を参照し、 $K=30$  とした。もう1つは、今回 CTM として用いたマルコフモデルの階数  $M$  である。ここで、マルコフモデルは連続する  $M$  個のトピック系列を入力するが、このトピック系列の種類数は  $K^M$  に相当する。訓練用データにはこの種類数を網羅することが求められるため、構築に必要なデータ量もそれに伴い増えていく。本稿では、 $M=\{1,2\}$  として実験を行った。 $M$  が3以上の場合では上記要件を満たせず、一部の対象ユーザに対しコンテキストの同定を行うことができなかったため省略した。

### 4.3 比較対象手法

本稿では、TF や CAMF からコンテキストの概念を撤廃した手法、Matrix Factorization(MF)との比較を行う。MF は、先の評価値テンソルからコンテキストに関する次元を除き、ユーザとアイテムの評価値行列を用いる点以外は、TF や CAMF とほぼ同様の手法である。

### 4.4 評価

提案手法と比較対象手法が出力した推薦リストの精度評価を行う。評価指標は、Top-N 推薦タスクにおいて用いられる Mean Average Precision(MAP)によって行った。各手法の MAP を図 3 に示す。

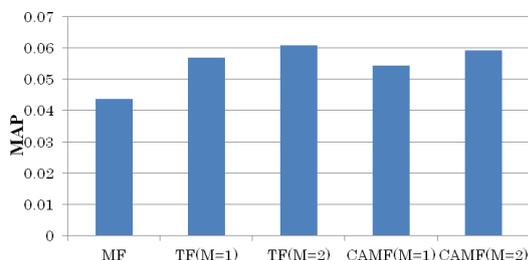


図 3 ユーザコンテキスト同定の有無による比較

### 4.5 考察

図 3 を見ると、同定したユーザコンテキストを用いた推薦は MF より優れていることがわかる。以下では、実際のあるユーザに対する推薦結果を見ていく。

表 2 は、ユーザの評価履歴を上から順に並べたものである。表 3 に直近 2 評価分のアイテムの *mainTopic* を CTM に入力した結果、同定された Preference Context を示す。表 3 から、訓練用データにおいて、*mainTopic* が 21 番にあたるアイテムを 2 回連続で評価した後は、その次も同様の *mainTopic* に対する嗜好を示すことが殆どであったことがわかる。

ここで、Preference Context の有無による推薦結果の差異を比較する。表 4 は TF( $M=2$ )の推薦結果、表 5 は MF の推薦結果を示す。表 4 では表 3 の内容に基づき、同様の *mainTopic* をもつアイテムが表 5 より多く推薦さ

れている。さらにその結果、正解データ中に存在するアイテムがより多く合致していることがわかる。このユーザも、訓練用データが示す傾向と同様の傾向をもっていたため、それを考慮することでより質の高い推薦が行えたといえる。なお、正解データに存在したアイテムはタイトルを網掛けで表記した。

表 2 ユーザの評価履歴(時系列順)

	Title	mainTopic
Input Data	My Name Is Jonas	18
	Janie Jones	23
	everlong	29
	Zombie	21
	fake_plastic_trees	21
Answer Data	Rose Parade	21
	The Blower's Daughter	21
	I Think We're Alone Now	21
	Head Like A Hole	21
	Should I Stay or Should I Go	21

表 3 同定された Preference Context のトピック確率分布

Topic	Probability
21	0.92337
29	0.01532
12	0.00958
1	0.00958
23	0.00766
18	0.00575
14	0.00575
:	:

一方で、問題点もみられた。図 4 は、データセット中の各アイテムについて(2)式の *mainTopic* を求めた結果得られた、各トピックの値に対するアイテム数の分布である。図 4 を見ると、一部のトピックにアイテム数が偏っていることがわかる。このことは、データセット中で各 *mainTopic* をもつアイテムが評価される頻度も同様に偏りがあることを意味する。ところで、今回ユーザコンテキストの同定を行うために用いたモデルは、式(3)に示したように、評価されたアイテムの *mainTopic* の時系列による推移頻度を基に構築している。このような状態でモデル構築を行うと、多くの場合で頻出トピックへの推移確率が高い値を示す。従って、コンテキスト同定により各トピックに対する嗜好の確率分布を求めた結果、頻出トピックに対し高い確率値を示すユーザが多くみられた。そしてそのコンテキストを用いて得られた推薦リストの上位には、同様のトピックを *mainTopic* にもつアイテムばかりが出現する結果となった。この現象はユーザ

の Preference Context を的確に同定できているとはいえない。

またその原因としては、アイテムの *mainTopic* のみの時系列推移を用いてモデルを構築している点にあると考えられる。*mainTopic* に基づく考え方を廃止するために、より複雑なモデルの構築が必要になるだろう。

表 4 TF による推薦結果 Top-10

Ranking	Title	mainTopic
1	Quality Control	21
2	For What It's Worth	21
3	across the sea	21
4	<b>I Think We're Alone Now</b>	21
5	<b>Head Like A Hole</b>	21
6	1979	21
7	Kung Fu	21
8	<b>Rose Parade</b>	21
9	Walk On The Wild Side	21
10	Precious Things	21

表 5 MF による推薦結果 Top-10

Ranking	Title	mainTopic
1	Janie Jones	23
2	For What It's Worth	21
3	Something I Can Never Have	29
4	Quality Control	21
5	Just Like Honey	18
6	Let's Get It On	13
7	Sliver	14
8	Red Right Ankle	29
9	say yes	13
10	Transmission	26

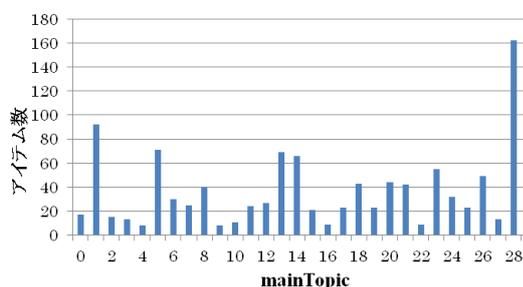


図 4 あるトピックを mainTopic にもつアイテム数の分布

## 5 結論

本稿では、ユーザコンテキストを同定することの有用性を示すため、アイテムの特徴からユーザの嗜好コンテキストを同定し、それを用いて推薦する手法の提案を行った。実験結果から、提案手法は Top-N 推薦におい

て既存手法よりも優位であることを示せた。

しかし、この手法には問題点が残っている。本稿ではユーザの嗜好コンテキストを同定するためのアプローチとして、時系列による嗜好の推移をマルコフモデルで予測していたが、モデルの都合上、嗜好データの一部しか用いなかったために的確な同定が行えなかった恐れがある。用いるモデルを変更し、嗜好データを十分に活用することでこの問題を解決できると考える。今後我々はユーザコンテキストの同定法や同定したコンテキストの扱い方について改善していく。

## 参考文献

- [1] Karatzoglou, A., Baltrunas, L., Church, K., et al.: Climbing the app wall: enabling mobile app discovery through context-aware recommendations, Proc. of CIKM'12, pp. 2527-2530, 2012.
- [2] Gantner, Z., Rendle, S., and Schmidt, T. L.: Factorization models for context-/time-aware movie recommendations, Proc. of CAMRa'10, pp.14-19, 2010.
- [3] Karatzoglou, A., Amatriain, X., Baltrunas, L., et al.: Multiverse recommendation: n-dimensional tensor factorization for context-aware collaborative filtering, Proc. of RecSys '10, pp. 79-86, 2010.
- [4] Baltrunas, L., Ludwig, B., and Ricci, F.: Matrix factorization techniques for context aware recommendation, Proc. of RecSys '11, pp. 301-304, 2011.
- [5] Adomavicius, G., Sankaranarayanan, R., Sen, S., et al.: Incorporating contextual information in recommender systems using a multidimensional approach, ACM Transactions on Information Systems, Volume 23 Issue 1, pp. 103-145, 2005.
- [6] Oku, K., Nakajima, S., Miyazaki, J., et al.: Context-aware svm for context-dependent information recommendation, Proc. of the 7th International Conference on Mobile Data Management, 2006.
- [7] Hariri, N., Mobasher, B., and Burke, R.: Context-aware music recommendation based on latent topic sequential patterns, Proc. of RecSys '12, pp. 131-138, 2012.
- [8] Said, A.: Identifying and utilizing contextual data in hybrid recommender systems, Proc. of RecSys '10, pp. 365-368, 2010.
- [9] Ren, Y., Li, G., and Zhou, W.: Learning user preference patterns for top-N recommendations, Proc. of the The 2012 IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology Volume 01, pp. 137-144, 2012.
- [10] Griffiths, T. L., and Steyvers M.: Finding scientific topics, Proc. of the National Academy of Sciences of the U.S.A, pp. 5228-5235, 2004.
- [11] Panniello, U., Tuzhilin, A., Gorgoglione, M., et al.: Experimental comparison of pre- vs. post-filtering approaches in context-aware recommender systems, Proc. of RecSys '09, pp. 265-268, 2009.