

ユーザモデル・アイテムモデルの統合に基づく Context-Aware 推薦システムの実験的評価

関 匠吾[†] 奥 健太^{††} 中島 伸介^{†††}

[†] 京都産業大学大学院先端情報学研究科 〒603-8555 京都府京都市北区上賀茂本山

^{††} 立命館大学情報理工学部 〒525-8577 滋賀県草津市野路東1丁目1-1

^{†††} 京都産業大学コンピュータ理工学部 〒603-8555 京都府京都市北区上賀茂本山

E-mail: [†]i1258087@cse.kyoto-su.ac.jp, ^{††}oku@fc.ritsumeit.ac.jp, ^{†††}nakajima@cse.kyoto-su.ac.jp

あらまし 近年、ユーザに適切な情報の提供を可能にする情報推薦技術が注目されている。その技術として、ユーザモデルに基づく情報推薦とアイテムモデルに基づく情報推薦の2つの手法がある。前者では新規ユーザに対してコールドスタート問題が起こり、後者では新規アイテムに対してコールドスタート問題が起こる。そこで我々はそれぞれの問題を解決するため、この2つの手法をハイブリッド的に統合する手法の提案を行なっている。本稿ではシステム構築に向けた検討を行い、プロトタイプシステムを開発した。さらに、プロトタイプシステムを用いて新規ユーザ及び新規アイテムのコールドスタート問題に対する有効性を確認する。

キーワード 情報推薦, コンテキストウェア情報推薦, ユーザコンテキスト, ハイブリッド型推薦, コールドスタート問題

1. はじめに

インターネット上には、膨大な量の情報が溢れており、この膨大な量の中から特定の情報を見つけるのは安易なことではない。このような背景から、ユーザに適切な情報の提供を可能にする情報推薦技術が注目されている。Amazon.com [1] では、ユーザに商品の推薦を行っており、Facebook [2] や Twitter [3] では、ユーザにユーザの推薦を行うなどあらゆるサービスでアイテムやユーザ問わず推薦されている。

一方で、スマートフォンの普及に伴い、ユーザがいつでも、どこでもインターネットを利用することができるようになった。また、簡単に音楽や映画、アプリケーションを購入・ダウンロードすることができるようになった。このような中、ユーザはその時の状況（コンテキスト）に合ったコンテンツが欲しい場合がある。例えば、「朝、通勤中に元気になる曲が欲しい」、「新幹線に長時間乗るときに、彼女と映画が見たい」、「旅行で遊びに来たので、観光客向けの飲食店が知りたい」などといった状況が考えられる。参加人数や所在地などを用いて飲食店を予約するアプリケーション [4] の開発も進められており、ユーザコンテキストを考慮した研究及び開発は意義があると言える。

研究として最近では、情報処理技術に対してユーザコンテキストを考慮することで、推薦精度の向上を目指した取り組みがなされ、注目を集めている。従来の情報推薦に関する研究で扱われるコンテキストの多くは、時間や場所など単純なコンテキストを扱うものであるが、我々の研究 [5] では、24次元のコンテキストを考慮したユーザの嗜好データと28次元のアイテムパラメータにSVMを用いて、コンテキスト依存型ユーザ嗜好モデルを作成し推薦対象アイテムの推測を行なっている。また、コンテキスト依存型のランキングを作成することにより成果を

挙げている。しかし、この研究ではユーザ毎に嗜好学習を行うため、新規ユーザ及び利用経験の浅いユーザに対して十分な推薦が行えないコールドスタート問題が起こる。この手法を本稿ではユーザベース手法と呼ぶ。

そこで、それぞれのユーザがどのような状況でどのようなアイテムを好むのかを学習するのではなく、アイテム側の特性として、どのような状況のユーザから支持を受けているかということを表すデータを蓄積することで、新規ユーザに対してもその時のコンテキストに応じて適切なアイテムを推薦することが可能な、アイテム利用時のユーザコンテキストを考慮した情報推薦システムの提案 [6] を我々は行なっている。しかし、これは新規アイテムが推薦対象とならないコールドスタート問題が起こる。この手法を本稿ではアイテムベース手法と呼ぶ。

これはユーザベース手法の問題をアイテムベース手法、アイテムベース手法の問題をユーザベース手法で補えば解決することができるのでは無いかと考え、この2つの手法をハイブリッド的に統合した情報推薦システムの提案を行った [7]。しかし、この提案ではシステムを構築することができておらず、推薦精度についての評価も行なっていない。

本稿では、システム構築に向けた具体的な検討を行い、プロトタイプシステムの開発を行う。さらに、プロトタイプシステムを用いて新規ユーザ及び新規アイテムのコールドスタート問題に対する有効性を確認する。

2. 関連研究と関連技術

ユーザコンテキストを考慮した研究として、Setten ら [8] は、携帯観光アプリケーション COMPASS というサービスを提案している。また、Asthana ら [9] は、買い物をしている店内限定であるが商品を提供するサービスを提案している。しかし、




図1 システムの概要図

これらの研究はユーザコンテキストとして位置情報のみを考慮しているものであるためコンテキストウェア推薦システムとして精度が高いとは言えないと考える。本手法は多くのコンテキストを考慮するが、ただ多くするのではなくユーザが意識するものやコンテキスト同士が競合しているものを考慮して設定している。

コンテキストを評価した技術として、食べログ[10]がコンテキストの評価分布を掲載している。この技術は、コンテキスト毎に9段階の評価を用いており、平均点として『夜の点数：3.20』というように掲載している。また、唯一『夜』と『昼』の予算のみ複合的に掲載されており、それ以外はコンテキスト毎の掲載であるため『夜にデート』といった場合の評価を見ることが出来ない。

ハイブリッド型推薦システムの技術と研究として、Amazon.com[1]は、協調フィルタリングを用いたユーザベース型推薦「Your Amazon.com」と今閲覧しているアイテムはどのアイテムを買ったユーザに買われているかを用いたアイテムベース型推薦「Customers Who Bought This Item Also Bought」の2つの手法を用いているが、それぞれ独立して提示しているため、組み合わせて提示する本システムとは異なる。また、吉井ら[11]は、ユーザの楽曲評価と音響的特徴を用いて楽曲の推薦システムを提案している。これは楽曲のみの推薦に対し、本システムはアイテムの特徴が取得できるアイテムであれば音楽等関係なく推薦できる点で異なると言える。また、一般的なハイブリッド型推薦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であり、本手法は既に有用性の示されている2つの手法[5][6]をハイブリッド的に組み合わせるため、既存のハイブリッドとは異なると言える。

3. 提案手法

本章では、3.1節において、システム全体の構成と想定する動きについて説明し、そのそれぞれの動作について3.2節ではユーザベース手法について、3.3節ではアイテムベース手法について、3.4節では統合システムについて述べる。さらに、3.5節ではユーザ毎の個別化について述べる。

3.1 システムの概要

本システムは、ユーザから取得したユーザコンテキストに基づきユーザベース手法とアイテムベース手法から選定された

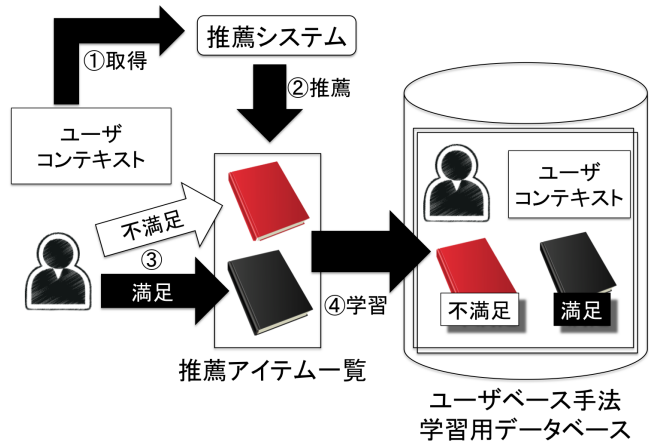


図2 ユーザベース手法：学習フェーズの流れ

アイテムを統合システムを用いて1つのランキングに統合し、ユーザに提示するものである。同時に新規アイテムと新規ユーザに対するコールドスタート問題を解決する。システムの全体図を図1に示し、動きを簡単に記述する。また、本システムの動作環境はWebサイトを想定している。

- step 1. ユーザからPCやモバイル端末を介してユーザコンテキストを取得する。
- step 2. 取得したユーザコンテキストとアイテムデータベースを用いてユーザベース手法により推薦アイテムを選定する。詳細は3.2節に記述する。
- step 3. 取得したユーザコンテキストとアイテムデータベースを用いてアイテムベース手法により推薦アイテムを選定する。詳細は3.3節に記述する。
- step 4. step 2, 3より選定されたアイテムを統合しランキングを作成する。詳細は3.4節に記述する。
- step 5. ユーザへランキングを提示する。

3.2 ユーザベース手法

ユーザベース手法はユーザの嗜好を学習したデータベースを用い、推薦アイテム選定機能によりユーザの嗜好を重視したアイテムを選定する。主な処理は学習フェーズと選定フェーズであり、それぞれの処理内容について説明する。これは以前の提案手法[5]であり、文献にて詳細を述べているのでここでは簡単に説明する。

3.2.1 学習方法

ユーザベース手法の処理の1つである学習方法について説明する。学習はシステムを利用したユーザ毎に行い嗜好を判別する手掛かりとなる。本手法では、1アイテムに2クラス（“満足”・“不満足”）どちらかの評価を与えることで学習を行う。学習の処理については図2に示す。図中のユーザは新規ユーザ及び既存ユーザどちらでも構わないとし、ユーザコンテキスト及び推薦システムは特に定義しないものとする。

- step 1. ユーザコンテキストを取得する。
- step 2. 推薦システムより推薦アイテム一覧が提示される。
- step 3. ユーザはstep 1のユーザコンテキストにおいて“満足”・“不満足”（例えば、“買いたい”・“買いたくない”）

表 1 学習データ例

UserId	ItemId	Class	UserWith	ItemBudget	...
user001	item001	1	友人	3000	...
user001	item005	0	恋人	5000	...
user002	item001	0	一人	3000	...
...	...	...	...	...	...




図 3 ユーザベース手法：選定フェーズの流れ

の評価をアイテムに与える。

step 4. ユーザの情報 (ログイン ID や携帯の識別番号等), アイテムの情報, step 1 のユーザコンテキスト及び step 3 の評価をユーザベース手法学習用データベースに追加していく。

追加後のデータベースの例は表 1 である。それぞれのカラム名について, UserId がユーザの情報, ItemId がアイテムの情報, Class が評価 (この例の場合, “満足 (1) “・“不満 (0) “), UserWith がユーザコンテキスト (この例の場合, 誰と居るかを表す), ItemBudget はアイテムパラメータ (この例の場合, 予算を表す) となり, それ以降はユーザから取得したコンテキスト及び利用するアイテムパラメータが続く。

3.2.2 選定方法

ユーザベース手法の処理の選定方法について説明する。アイテムの選定には 3.2.1 項で説明した学習方法により作成されたデータ, 新たに取得したユーザコンテキスト及び新規アイテムデータを用いて行う。選定の処理については図 3 に示す。図中の各取得データは特に定義しないものとする。

- step 1. ユーザコンテキストを取得する。
- step 2. ユーザがまだ利用していない新規アイテムのデータをアイテムデータベースより取得する。
- step 3. step 1 のユーザコンテキストと step 2 の新規アイテムのアイテムデータを合わせた融合データ集合を作成する。
- step 4. step 3 で作成した融合データを推薦アイテム判定機能が取得する。
- step 5. 3.2.1 項で説明した学習方法により追加されたデータに Support Vector Machine (SVM) [12] を用いて判別平

面を決定し, step 3 の融合データの各新規アイテムに対するユーザの嗜好 (“満足 “・“不満 “) を推測する。

step 6 step 5 で “満足 “と推測された新規アイテムを推薦対象アイテムとし, 価値判断基準モデル [5] に基づきランキングを作成する。作成したランキングは統合システムへ渡される。

3.3 アイテムベース手法

アイテムは利用される毎にそのアイテムを利用するユーザコンテキストが収束し, 一意のユーザコンテキストが決まるのでは無いかと考えた。例えば, あるアイテムは二次会でよく利用され, 別のあるアイテムは家族で良く利用するといったことが考えられる。そこで, アイテムベース手法ではアイテムがどのようなユーザコンテキストから利用されているのかをデータベースに蓄積し, そのデータベースを用い推薦アイテム選定機能により利用時のユーザコンテキストに適したアイテムを選定する。主な処理は蓄積フェーズと選定フェーズであり, それぞれの処理内容について説明する。これも以前に提案した手法 [6] であり, 文献にて詳細に述べているのでここでは簡単に説明する。




図 4 アイテムベース手法：蓄積フェーズの流れ

3.3.1 蓄積方法

アイテムベース手法の処理の 1 つである蓄積方法について説明する。蓄積を行うことでアイテムがどのようなユーザコンテキストに利用されるのか知ることや推測することができる。本システムでは, 3.2.1 項で “満足 “と評価されたアイテムについても蓄積の対象となる。つまり, ユーザベース手法学習用データベースとアイテムベース手法蓄積用データベースの両方に追加される。しかし, 追加されるデータの内容は, それぞれのデータベースの形式にフォーマットして行う。蓄積の処理については図 4 に示す。図中のユーザは新規ユーザ及び既存ユーザのどちらでも構わないとし, ユーザコンテキスト及び推薦システムは特に定義しないものとする。

- step 1. ユーザコンテキストを取得する。
- step 2. 推薦システムより推薦アイテム一覧が提示される。
- step 3. ユーザは step 1 のユーザコンテキストにおいて “満足 “であるアイテムを選択する。

表 2 蓄積データ例

ItemId	UserWith	...
item001	友人	...
item005	恋人	...
item001	一人	...
...	...	...




図 5 アイテムベース手法：選定フェーズの流れ

step 4. step 1 のユーザコンテキスト及び step 3 で選択したアイテムの情報をアイテムベース手法蓄積用データベースへ追加する。

追加後のデータベースの例は表 2 である。それぞれのカラム名について、ItemId がアイテムの情報、UserWith がユーザコンテキスト（この例の場合、誰と居るかを表す）となり、それ以降はユーザから取得したコンテキストが続く。

3.3.2 選定方法

アイテムベース手法の処理の選定方法について説明する。アイテムの選定には 3.3.1 項で説明した蓄積方法により作成されたデータ、ユーザコンテキストを用いて行う。選定の処理については図 5 に示す。図中では新規ユーザのコンテキストと記載しているが既存ユーザのコンテキストでも構わない。

- step 1. 新規ユーザのコンテキストを取得する。
- step 2. 3.3.1 項で説明した蓄積方法により追加されたデータと step 1 の新規ユーザのコンテキストを用い、k 近傍法により新規ユーザのコンテキストを中心に近傍を探索する。
- step 3. k の個数分蓄積データが含まれた時、k 個中一番多いアイテムを推薦対象アイテムとして選定する。（図 5 の場合、k=4 であり、一番多いアイテムはアイテム A である）
- step 4. step 3 で選定されたアイテム A を 1 位とし、もう一度 step 3 を行いアイテムの選定を行なっていく。この時、一度選定されたアイテムは再び選定されない。

アイテムベース手法のランキングは、step 3, 4 を数回行い作成し、統合システムへ渡される。この選定方法では、k 近傍法の k の数が重要になってくるが、この値の決定は実験を通し

表 3 2つの手法によるランキング

	ユーザベース手法 ランキング	アイテムベース手法 ランキング
1 位	アイテム U_1 (R-1 点)	アイテム I_1 (R-1 点)
2 位	アイテム U_2 (R-2 点)	アイテム I_2 (R-2 点)
3 位	アイテム U_3 (R-3 点)	アイテム I_3 (R-3 点)
4 位	アイテム U_4 (R-4 点)	アイテム I_4 (R-4 点)
5 位	アイテム U_5 (R-5 点)	アイテム I_5 (R-5 点)
...	...	...

て行う。

3.4 統合システム

3.2 節と 3.3 節の 2 つの手法により作成されるランキングは作成方法に違いがあるため、そのままでは統合することが出来ない。また、新規ユーザに提示するランキングはアイテムベース手法から作成されたものになるが、既存ユーザに提示するランキングは学習データがあるためユーザベース手法ランキングとアイテムベース手法ランキングの組み合わせだった 1 つのランキングにする必要がある。つまり、利用時のユーザコンテキストが同じであってもユーザが異なれば違うランキングでなければならない。そこで、それぞれのランキングのアイテム毎にスコア付けを行い新規ユーザ・既存ユーザ毎に適したランキングを算出する方法について説明する。

ユーザベース手法とアイテムベース手法のそれぞれの推薦結果ランキングを表 3 とする。この順位を決める方法については、3.2 節と 3.3 節で述べた通りである。このランキングからユーザベース手法は式 (1) のユーザベース手法スコア U_i とし、アイテムベース手法は『最大順位数－アイテム順位』(R-i 点) をアイテムベース手法スコア I_i とする。例えば、最大順位 (R) が 10 である場合、1 位 (i) のアイテムベース手法スコア I_1 の点数は 9 点、アイテムベース手法スコア I_2 なら 8 点とスコアを付ける。

$$\begin{aligned} & \text{アイテム } U_i(R-i \text{ 点}) \times \text{ユーザベース手法の確信度 } (C_{user}) \\ & = \text{ユーザベース手法スコア } U_i \quad (1) \end{aligned}$$

アイテム U_i (R-i 点) は、ランキング順位により決定される点数で“R”は最大順位数を表し、“i”はアイテムの順位を表している。例えば、最大順位 (R) が 10 までであるとする。1 位 (i) のアイテム U_1 の点数は 9 点となる。2 位のアイテム U_2 の点数は 8 点、アイテム U_3 なら 7 点、アイテム U_4 なら 6 点となる。

次に、ユーザ毎に適切な統合ランキングを決定する方法として、“ユーザベース手法の確信度 (C_{user})”を利用する。ユーザベース手法の確信度とは、1 人のユーザが評価したアイテム数に基づく指標である。本システムを新規ユーザが用いる場合、ユーザベース手法の学習データが一切ない状態から始める。つまり、新規ユーザに提示される統合ランキングはアイテムベース手法から作成されたランキングが直接提示されることになる。逆に既存ユーザが用いる場合、ユーザベース手法の学習データがあるので 2 つのランキングが組み合わせられたランキングが提示される。しかし、評価したアイテム数が少ない状態、つまり十分な学習が行えていない状態である可能性が高い場合に、




図 6 確信度決定方法の例

ユーザベース手法ランキングを統合ランキングに組み込むのは、そのユーザに適切なランキングであるとは言えない。そこで、ユーザが評価したアイテム数に基づく指標であるユーザベース手法の確信度を用いることで、十分な学習が行えているかシステム側で確信が持てるまで統合システムにユーザベース手法ランキングを反映させないようにすることができる。

図 6 は確信度決定方法の例である。データ量とは、1 人のユーザが評価したアイテム数、つまり、学習データ数のことである。例えば、学習データが 100 個あるとすると、ユーザベース手法の信頼度 (C_{user}) は 0.9 となる。この図 6 の値はあくまで例であるため実際に決定する際は、数回の検証を行う必要があると考える。また、例ではリニアで表しているが、実際は確信度がある一定の値で収束するようなグラフになることも考えられる。

最後に求まったユーザベース手法スコア U_i とアイテムベース手法スコア I_i をスコア順に並べることで統合ランキングを作成する。

3.5 ユーザ毎の個別化

3.4 節で説明したランキング方法でも十分に精度の高い推薦を行えると考えるが、よりユーザに適した推薦を行う方法について説明する。3.4 節では、統合ランキングを作成する際に重要となっているのはユーザベース手法の確信度である。例えば、学習データが少ない既存ユーザがいた場合、統合ランキングの上位はアイテムベース手法から選定されたアイテムが存在することになる。しかし、このユーザがユーザベース手法から選定されたアイテムをよく満足とするような場合にアイテムベース手法から選定されたアイテムを上位にするのはユーザに適切でなく、ユーザベース手法から選定されたアイテムを上位にするべきであると考え。逆に学習データが多い既存ユーザがいて、統合ランキングの上位にはユーザベース手法から選定されたアイテムが多く存在する場合に、このユーザがアイテムベース手法から選定されたアイテムをよく満足とするならば、統合ランキングの上位にはアイテムベース手法から選定されたアイテムを提示するのが適切であると言える。

そこで、我々はユーザベース手法スコア U_i とアイテムベース手法スコア I_i にそれぞれ “ α ” と “ $1-\alpha$ ” を加えた式 (2) と (3) を定義する。ユーザがどちらの手法から選定されたアイテムをよく満足とするかを記録し、その記録に基づき α の値を変えて 2 つのスコアから統合ランキングを作成し直すこと

ができる。

ユーザベース手法スコア $U_i \times \alpha$

= 個別化を考慮したユーザベース手法スコア U'_i (2)

アイテムベース手法スコア $I_i \times (1 - \alpha)$

= 個別化を考慮したアイテムベース手法スコア I'_i (3)

α の初期値は “0.5” としユーザが満足としたアイテムによって α の値を変動させていく。本システムでは、新規ユーザが利用する場合、ユーザベース手法の確信度が定まるまでアイテムベース手法から選定されたアイテムを利用することになる。つまり、システムでは「このユーザはアイテムベース手法から選定されたアイテムをよく利用する」と勘違いし、個別化を考慮したユーザベース手法スコア U'_i の値を小さくなることでユーザベース手法から選定されたアイテムが一切統合ランキングに提示されない問題が発生する。しかし、これはそれぞれのランキングのアイテムが統合ランキングに入るまで 0.5 のまま変動させないことで制御できると考える。

さらに統合システムでは、ユーザベース手法及びアイテムベース手法から同一アイテムが選定される問題がある。アイテム A がユーザベース手法では 15 位にあり、アイテムベース手法では 2 位にあるといった状況を考える。この場合、両方提示する方法も取れるが、これもユーザがどちらの手法から選定されたアイテムをよく満足するか記録することによってどちらを提示すべきか判断し、ユーザに適切なランキングを提示できる。例えば、ユーザがユーザベース手法から選定されたアイテムをよく利用するなら、2 位のアイテム A を削除して 15 位のみ残し、アイテムベース手法から選定されたアイテムをよく利用するなら、15 位のアイテム A を削除して 2 位のみ残すことになる。

4. プロトタイプシステム

プロトタイプシステム

図 7 プロトタイプシステム

今回、プロトタイプシステムの開発を行った。本システムは Web 上で動作し、ユーザコンテキストを自動取得して推薦することを目指しているが、プロトタイプでは被験者実験用として入力フォームのある Web サイトとして開発した。図 7 が本システムを PC で閲覧した際に表示される入力画面である。開発環境は、メインが動作する部分に PHP を使用し、一部の

動作に Java も使用した。データベースには MySQL を使用し、その他ユーザに操作しやすいものにするために JavaScript や jQuery 等も使用している。今回のプロトタイプシステムでは、推薦対象アイテムをリクルートが提供しているホットペッパー Web サービス [13] から取得できる飲食店としている。

飲食店を推薦対象アイテムとするため、使用するパラメータはユーザが飲食店を利用する際に考慮すると考えられる項目を設定した。パラメータは次元数毎にすべて 0~1 で正規化を行いアイテム選定機能 (SVM, k 近傍法) での利用やデータベースに追加される。例えば、予算が 3000 円の場合は (0.3)、月は以前に提案している周期型パラメータの表現方法 [5] を用いることで 2 月の場合は (0.933, 0.75) を利用することになる。

ユーザコンテキストとユーザプロフィールとして表 4, 5 を設定した。ユーザコンテキストはユーザの状況を表す項目を、ユーザプロフィールはユーザ固有の属性を表す項目を設定した。ユーザコンテキストは、次元数を抑えることでノイズの除去を行なっている。例えば、天気はこれまで “晴れ/曇り/雨/雪” のそれぞれで 1 次元を使用し 4 次元で表現していた。しかし、この表現では一部の季節に限定される “雪 “がほとんど考慮されない問題が起こる。そこで、 “曇り “は “降りそう” という点で雨や雪に近い状態であることと “雨 “と “雪 “は “降る” という現象が同じであることから、2 次元で表現する方法を採用した。具体的には、晴れ → (1, 0), 曇り → (0, 0), 雨 → (0, 1), 雪 → (0, 1) と表現される。プロトタイプシステムでは、ユーザが利用する際に表 4, 5 をユーザから取得して推薦を行う。

アイテムパラメータとして表 6 を設定した。これは API [13] から取得できる項目を設定した。

表 4, 6 で次元数が “0 “の財布内金額と営業時間は SVM や k 近傍法では利用せず、事後フィルタリングとして利用する。表 4 の “財布内金額 “は推薦された飲食店の予算が財布内金額に収まるかどうかの確認として、表 6 の “営業時間 “も推薦された飲食店が営業時間内であるかどうかの確認として利用する。表 5, 6 の “名前 “と “飲食店 ID “はユーザの識別とアイテムの識別に利用する。

ユーザベース手法では、設定したパラメータのすべての次元 (43 次元) とユーザの評価 (満足・不満足) を使用して嗜好学習及びアイテム選定を行う。このシステムでの評価は満足と不満足の 2 つを使用し、満足は “1 “、不満足は “-1 “として使用する。

表 4 ユーザコンテキスト

パラメータ項目	パラメータ	次元数
日時情報	月	1月~12月
	時刻	5:00~25:00
気象情報	天気	晴れ/曇り/雨/雪
ユーザ情報	休日	平日前の平日/休日前の平日/休日 前の休日/平日前の休日
	予算	1,000円~10,000円
	財布内金額	0円~
誰と	1人/家族/恋人/友人・先輩・後輩/上 司・部下/ビジネス/その他	6
人数	1人~10人	1

表 5 ユーザプロフィール

パラメータ項目	パラメータ	次元数
年齢	10歳~60歳	1
性別	男性 or 女性	1
名前	(例: shogo)	0

表 6 アイテムパラメータ

パラメータ項目	パラメータ	次元数
飲食店ID	(例: J000848049)	0
営業時間	00:00~23:59	0
予算	1,000円~10,000円	1
ジャンル	居酒屋/ダイニングバー/創作料理/和食/洋食/イタリアン・フレンチ/中華/焼肉・韓国料理/アジアン/各国料理/カラオケ・パーティ/バー・カクテル/ラーメン/お好み焼き・鉄板焼き/カフェ・スイーツ/その他	15
特徴	個室/座敷/貸切/駐車場/飲み放題/食べ放題/お子様連れ/カード/コース/禁煙席	9




図 8 Web 上の推薦アイテム提示

学習は図 8 のようにユーザに飲食店を提示し、満足か不満足を選ぶことで行う。例えば、満足を選択するとデータベースに [満足: 名前: 飲食店 ID: ユーザコンテキスト (16 次元): ユーザプロフィール (2 次元): アイテムパラメータ (25 次元)] が正規化された状態で追加される。アイテム選定は SVM のライブラリ LIBSVM [14] を用いて選定を行う。LIBSVM でのアイテム選定には、学習モデルを作成する必要がある。このモデル作成には、データベースにある学習データを用いて行う。次に作成したモデルを用いてアイテムの選定を行う。必要となるデータは “利用時のユーザコンテキスト “、 “ユーザプロフィール “及び “新規アイテムのパラメータ “であり、この 3 つを組み合わせたものを融合データと呼ぶ。LIBSVM に作成したモデルと融合データを用いることで新規アイテムの評価 (満足・不満足) を選定することができる。この選定したアイテムに対し価値判断基準モデル [5] に基づくランキングを行い、上位 10 件をユーザに提示する。

アイテムベース手法では、設定したパラメータの内、アイテムパラメータ (飲食店 ID は使用する) を除く 18 次元を使用して蓄積及びアイテム選定を行う。蓄積は図 8 の満足が選ばれたときのみ行う。データベースには

[飲食店 ID：ユーザコンテキスト (16 次元)：ユーザプロフィール (2 次元)] が正規化された状態で追加される。アイテム選定は k 近傍法を用いて選定を行う。このプロトタイプシステムでは k を “3” として実装し、“利用時のユーザコンテキスト＋ユーザプロフィール” と “蓄積データ” との類似度計算には cos 類似度を使用した。すべての蓄積データとの cos 類似度を測り、最も近い 3 つの蓄積データの中で一番多い飲食店 ID が何であるかでアイテムが選定される。これを 10 回行い 10 位までのランキングとして作成し、ユーザに提示する。

5. 評価実験

表 7 被験者 A のユーザコンテキストデータセット

月時刻	休日	予算	財布内金額	年齢性別	誰と	人数	天気
8	15 休日前の休日	8000	10000	40 男	友人・先輩・後輩	6	雨
8	15 平日前の平日	4000	5000	20 男	家族	9	曇り
4	15 休日前の平日	9000	10000	60 男	恋人	2	雨
12	21 平日前の平日	2000	5000	40 男	友人・先輩・後輩	6	曇り
1	18 平日前の平日	10000	10000	20 男	友人・先輩・後輩	5	曇り
11	15 休日前の休日	6000	10000	60 男	友人・先輩・後輩	5	雨
1	12 平日前の平日	7000	10000	60 男	ビジネス	10	雪
5	21 平日前の休日	7000	10000	40 男	友人・先輩・後輩	9	雨
7	21 平日前の休日	9000	10000	30 男	ビジネス	5	雨
10	18 休日前の休日	10000	10000	40 男	友人・先輩・後輩	10	晴れ
8	18 休日前の休日	4000	5000	22 男	友人・先輩・後輩	5	雨
10	21 平日前の平日	3000	5000	22 男	友人・先輩・後輩	3	曇り
12	15 休日前の平日	4000	5000	22 男	恋人	2	雪
1	15 休日前の休日	2000	5000	22 男	友人・先輩・後輩	8	曇り
12	15 平日前の平日	7000	10000	22 男	1人	1	曇り
3	21 平日前の平日	7000	10000	22 男	ビジネス	10	晴れ
9	24 平日前の平日	3000	5000	22 男	ビジネス	7	曇り
2	24 休日前の平日	9000	10000	22 男	友人・先輩・後輩	7	曇り
6	18 休日前の平日	2000	5000	22 男	家族	10	雨
9	24 平日前の平日	3000	5000	22 男	ビジネス	5	雨

4 章で説明したプロトタイプシステムを用いて評価実験を行った。目的は新規ユーザ及び新規アイテムのコールドスタート問題に対する有効性の確認である。

この評価実験において、ユーザベース手法の確信度は 0.5 とした。被験者の学習データとアイテムの蓄積データを集めるために、こちらでランダムに生成したユーザコンテキストデータセットを 20 個用意した。ユーザプロフィールの性別は男性のみを利用し、年齢はランダムに生成したもの 10 個と被験者の年齢を利用したもの 10 個に分け、ユーザコンテキストと組み合わせた。被験者 A の場合、表 7 の C_1 がアイテム蓄積に用いるデータセット、 C_2 が学習に用いるデータセットとなる。これを被験者 4 人に渡し、1 データセット毎に 10 店舗を評価してもらう。飲食店は被験者が頻繁に利用する京都河原町周辺をランダムに 50 店舗提示し、満足・不満足を評価してもらった。収集したデータは、1 人 100 個の学習データと約 800 個 (合計 333 店舗) の蓄積データとなった。

評価実験に利用する手法としてこれまで説明した 3 つの手法を用いる。

手法 1. ユーザベース手法 (3.2 節)

手法 2. アイテムベース手法 (3.3 節)

手法 3. 統合システム (3.4 節)

さらに、ユーザとアイテムの実験パターンを 3 つ用いる。

パターン 1. 利用ユーザは新規ユーザで、推薦対象アイテムは既存アイテム

表 8 パターン 1 で飲食店ランキングを評価した結果 (被験者 A)

	手法 1	手法 2	手法 3
1 位	3.8	7.4	5.8
2 位	2.8	5.6	6.4
3 位	4.4	5.6	6.0
4 位	5.2	6.0	6.2
5 位	3.6	6.2	4.8
6 位	4.4	5.0	3.8
7 位	4.8	5.0	5.0
8 位	4.2	6.0	5.2
9 位	3.2	5.8	4.8
10 位	2.6	5.8	4.4
平均	3.90	5.84	5.24

パターン 2. 利用ユーザは既存ユーザで、推薦対象アイテムは新規アイテム

パターン 3. 利用ユーザは既存ユーザで、推薦対象アイテムは既存アイテムと新規アイテム

これらの手法とパターンを組み合わせることによって比較を行う。比較方法としては、パターン 1 で手法 1～3 から選定された飲食店の評価を行い、同様にパターン 2 及び 3 も手法 1～3 から選定された飲食店の評価を行うことによって比較を行う。ただし、実験パターンに新規ユーザや新規アイテムを含む場合、新規ユーザはユーザベース手法、新規アイテムはアイテムベース手法からの推薦が行われない。そのため、飲食店を普段通り検索する方法としてホットペッパーグルメ [15] の検索結果を用いるものとする。

評価用データセットとして、被験者 3 人に実際にありうる状況を 1 人 15 セット考えてもらいユーザコンテキストに用いた。被験者 1 人にパターンを 1 つ割り当て、評価用データセットの状況で手法 1～3 から推薦された飲食店に 10 段階 (10 が最も満足, 1 が最も不満足) 評価で評価付けを行ってもらう。例えば被験者 A の場合、パターン 1 を割り当て、評価用データセット 5 個を使って手法 1 から推薦された飲食店を評価し、別の評価用データセット 5 個を使って手法 2 の飲食店を評価、手法 3 も同様に行う。

手法毎に評価用データセット 5 個を使用して評価したスコアの平均を算出した結果、表 8, 9, 10 となった。

評価結果より、表 8 からホットペッパーグルメの検索結果を用いた手法 1 が最も平均スコアが低く、手法 2・3 との差異が見て取れたため、新規ユーザに対しての推薦は行えていることがわかる。しかし、精度の高い推薦が行えているとは言えない結果であることもわかる。表 9 では、手法 1・3 と手法 2 の差異が大きければ、新規アイテムの推薦が既存の検索結果より行えていると言えるが、表からは差異が見られなかった。また、10 においても何故か手法 1 の平均スコアが低い結果となっている。このことからユーザの学習データ数が不十分であることや他の手法とのスコアの差が大きいため、プロトタイプシステム自体に問題がある可能性など検証する必要があると考えられる。同時に推薦精度の向上に向けた検討も必要である。

表 9 パターン 2 で飲食店ランキングを評価した結果 (被験者 B)

	手法 1	手法 2	手法 3
1 位	5.2	4.6	5.0
2 位	5.4	5.2	6.0
3 位	5.4	4.6	4.6
4 位	5.6	4.8	2.8
5 位	3.0	7.2	4.8
6 位	5.6	4.2	6.0
7 位	4.8	6.0	5.6
8 位	4.8	4.2	5.4
9 位	4.0	5.6	7.0
10 位	5.0	7.0	7.2
平均	4.88	5.34	5.44

表 10 パターン 3 で飲食店ランキングを評価した結果 (被験者 C)

	手法 1	手法 2	手法 3
1 位	5.0	7.0	3.8
2 位	4.8	5.8	4.8
3 位	4.8	5.6	5.4
4 位	4.6	4.4	4.6
5 位	4.6	5.0	6.0
6 位	3.6	5.6	5.0
7 位	4.0	3.8	6.4
8 位	4.0	5.0	5.2
9 位	3.8		5.4
10 位	4.0		3.8
平均	4.32	5.28	5.04

6. ま と め

本論文では、ユーザベース、アイテムベース手法をハイブリッド的に統合したコンテキストウェア情報推薦システムの提案を行い、プロトタイプシステムの開発をした。さらに、プロトタイプシステムを用いて評価実験を行った。今後の課題として、プロトタイプシステムのアルゴリズムに間違いが無いかの検証、学習データ及び蓄積データの数を増加させての評価実験、確信度の調査や個別化に向けた検討及び実装、さらにユーザコンテキストの自動取得の検討及び実装を行う。

謝 辞

本研究の一部は、文部科学省科学研究費助成事業 (学術研究助成基金助成金) 基盤研究 (C) (研究代表者: 中島伸介, 課題番号: 23500140) 及び文部科学省科学研究費補助金若手研究 (B) (研究代表者: 奥健太, 課題番号: 23700132) による。ここに記して謝意を表します。

文 献

- [1] 『Amazon.com』. <http://www.amazon.com/> (2014-02-14 確認)
- [2] 『Facebook』. <https://www.facebook.com/> (2014-02-14 確認)
- [3] 『Twitter』. <https://twitter.com/> (2014-02-14 確認)
- [4] 『1Click 飲み』. <http://garimacho.com/> (2014-02-14 確認)
- [5] 奥健太, 中島伸介, 宮崎純, 植村俊亮, 加藤博一: 情報推薦におけるユーザの価値判断基準モデルに基づくコンテキスト依存型ランキング方式, 情報処理学会論文誌, データベース, Vol.2, No.1(TOD 41), pp.57-80 (2009) .
- [6] 関匠吾, 中島伸介, 張建偉: アイテム利用時のユーザコンテキストを考慮した情報推薦システムの提案, DEIM Forum 2011, B1-1 (2011) .
- [7] 関匠吾, 奥健太, 中島伸介: ユーザ・アイテム統合モデルに基づく Context-Aware 推薦システムの開発と評価, DEIM Forum 2013, B10-3 (2013) .
- [8] Mark van Setten, Stanislav Pokraev and Johan Koolwaaij: Context-Aware Recommendations in the Mobile Tourist Application COMPASS. Adaptive Hypermedia and Adaptive Web-Based Systems, Lecture Notes in Computer Science, Vol.LNCS 3137, pp.235-244 (2004) .
- [9] Abhaya Asthana, Mark Cvavatts and Paul Krzyzanowski: An Indoor Wireless System for Personalized Shopping Assistance, Workshop on Mobile Computing Systems and Applications, IEEE Computer Society Press, pp.69-74 (1994) .
- [10] 『食べログ』. <http://tabelog.com/> (2014-02-14 確認) .
- [11] 吉井和佳, 後藤真孝, 駒谷和範, 尾形哲也, 奥乃博: ユーザの評価と音響的特徴との確率的統合に基づくハイブリッド型楽曲推薦システム, 情報処理学会 音楽情報科学研究会, 研究報告, Vol.2006, No.90, pp.45-52 (2006)
- [12] Corinna Cortes, Vladimir Vapnik: Support-Vector Networks, Machine Learning, 20, pp.273-297 (1995)
- [13] 『ホット ペッパー | リクルート WEB サービス』. <http://webservice.recruit.co.jp/hotpepper/> (2014-02-14 確認) .
- [14] 『LIBSVM』. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/> (2014-02-14 確認) .
- [15] 『ホットペッパーグルメ』. <http://www.hotpepper.jp/index.html> (2014-02-14 確認)