

## 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

奥 健太<sup>†1</sup> 中島 伸介<sup>†2</sup> 宮崎 純<sup>†1</sup>  
植村 俊亮<sup>†3</sup> 加藤 博一<sup>†1</sup>

情報推薦システムにより判定された推薦候補アイテム集合に対し、ユーザの状況すなわちユーザコンテキストごとに変化する価値判断基準に基づいたランキング手法を提案する。この価値判断基準はユーザコンテキストにより変化するため、一意なランキングを行うことはできない。そこで本論文では、ユーザコンテキストに依存するユーザの価値判断基準モデルを定義したうえで、このモデルに基づいたコンテキスト依存型ランキング手法を提案する。本手法の流れは次のとおりである。(1) 学習データからのユーザコンテキストに依存する価値判断基準モデルの構築。(2) 価値判断基準モデルに基づく推薦候補アイテム集合に対するランキング処理。本論文では、上記の各手順について説明し、飲食店情報推薦を対象とした被験者実験により、提案手法の有効性を示す。

### A Context-aware Ranking Method Based on User's Value Judgement Model for Information Recommendation

KENTA OKU,<sup>†1</sup> SHINSUKE NAKAJIMA,<sup>†2</sup> JUN MIYAZAKI,<sup>†1</sup>  
SHUNSUKE UEMURA<sup>†3</sup> and HIROKAZU KATO<sup>†1</sup>

This paper proposes a ranking method based on a user's value judgement model depending on user contexts. Since the user's value judgement is depending on user contexts, it is impossible to make a unique ranking. Therefore, in this paper, we define the user's value judgement model depending on user contexts, and propose a context-aware ranking method based on the model. This method consists of the following steps: (1) Makes user's value judgement model depending on user contexts from a user's training data set. (2) Makes a ranking for recommendation items based on the user's value judgement model. This paper explains each step and shows the effectiveness of the proposed method by using experimental results.

### 1. はじめに

膨大な情報の中からユーザの嗜好に合った情報を提供する情報推薦技術が注目されている。特に、ユーザの嗜好だけでなく、ユーザがそのときおかれている状況(ユーザコンテキスト)にふさわしい情報を提供するコンテキスト依存型情報推薦技術に対する関心が高まっている。我々は、これまでに、コンテキスト依存型情報推薦を目的とし、コンテキスト依存型ユーザ嗜好モデル化方式を提案している<sup>1),2)</sup>。これは、2クラス分類手法である Support Vector Machine (SVM)<sup>3)</sup>により、ユーザコンテキストに応じて多様に变化するユーザの嗜好をモデル化する方式である。具体的には、その時々ユーザコンテキストにおける、ユーザのアイテムに対する好き/嫌いを学習することによりモデルを構築するものである。このモデルを用いることにより、推薦時のユーザコンテキストにおいて適切なアイテムを推薦候補としてユーザに提供することが可能となる。

しかしながら、これまでに我々が行った研究では、推薦候補の判定までは行っているものの、上述の推薦候補アイテムに対する適切なランキングの提供は行っていない。推薦候補が膨大になると、ユーザはこの中から最も適切なアイテムを探す手間がかかり、ユーザの負担が大きくなる。したがって、推薦におけるユーザ満足度の向上のためには、推薦候補アイテム集合に対して適切なランキングを行うことが重要といえる。

推薦候補に対する単純なランキング方法としては、たとえば飲食店を推薦対象とした場合では、「料金の安さ」を基準にしたランキング、ユーザの「現在地からの距離の近さ」を基準にしたランキングなどがあげられる。しかしながら、本当に適切なランキングの基準は、ユーザ個人によっても、コンテキストによっても異なる。あるユーザは、「安さ」重視で店を選ぶかもしれないし、また別のユーザは、「近さ」重視で店を選ぶかもしれない。また、同じユーザであっても、「1人ではいるときは安い店」を選ぶかもしれない、「恋人といるときは高級な店」を選ぶかもしれない。つまり、ユーザがそのとき直面しているコンテキストにおいて、何を重視しているかを考慮したうえで、ランキングを行う必要があると考える。

ランキングを提供する手法としては、Multi-Class SVMを用いた方法<sup>8),9)</sup>、Ranking SVM

<sup>†1</sup> 奈良先端科学技術大学院大学情報科学研究科  
Graduate School of Information Science, Nara Institute of Science and Technology

<sup>†2</sup> 京都産業大学コンピュータ理工学部  
Faculty of Computer Science and Engineering, Kyoto Sangyo University

<sup>†3</sup> 奈良産業大学情報学部情報学科  
Department of Informatics, Faculty of Informatics, Nara Sangyo University

を用いた方法<sup>10)-12)</sup>などがあげられる。これらは、あらかじめ学習データとして与えられるアイテム間に順序関係があることを前提とした手法である。しかしながら、先の例のように、アイテム選択に対するユーザの判断基準は、ユーザがそのときおかれているコンテキストによって変化する<sup>1),2)</sup>ため、コンテキストが変われば、アイテム間の順序関係も変わってしまう。したがって、Multi-Class SVM や Ranking SVM をそのまま情報推薦におけるランキング手法として適用することは妥当でない。

本論文では、ユーザの価値判断がユーザコンテキストによって変化することを考慮に入れた、ユーザの価値判断基準モデルを定義する。このモデルに基づいて推薦候補アイテム集合に対するスコア付けを行うことにより、ユーザコンテキストに合ったランキングを実現する。

本論文で提案するコンテキスト依存型ランキング手法の流れは、次のとおりである。

- (1) 学習データからのユーザコンテキストに依存する価値判断基準モデルの構築
- (2) 価値判断基準モデルに基づく推薦候補アイテム集合に対するランキング

なお、ここでいう推薦候補アイテム集合とは、事前に我々のこれまでの提案手法である、SVM によるコンテキスト依存型ユーザ嗜好モデル<sup>1),2)</sup>により判定されたものである。このようにランキングを行う前に、ユーザコンテキストに合った推薦候補アイテム集合を判定しておくことにより、事前にユーザにとって不要なアイテム集合を取り除くことができるため、ランキング結果に対するユーザ満足度の向上につながる。我々のユーザ嗜好モデルに基づいて判定された推薦候補アイテム集合に関しては、すでに検証実験により高いユーザ満足度を示すことを実証しているため、この推薦候補アイテム集合に対してランキング処理を行うことの有効性は高い。

ただし、本論文における提案方式、すなわち価値判断基準モデルの構築およびこれに基づくランキングの実装部分に関しては、アイテムの特徴を表す属性およびコンテキストの特徴を表す属性を持つユーザの学習データに基づくものであり、SVM に依存するものではない。

以下、本論文の構成を示す。2章では、関連事項および関連研究について述べる。3章では、ユーザの価値判断基準モデルの定義を行い、提案手法であるコンテキスト依存型ランキング手法について説明する。4章では、我々のコンテキスト依存型情報推薦プロトタイプシステムについて説明し、本論文における提案手法の位置付けを示す。5章では、提案手法に対する評価実験および考察を行い、6章で、本論文をまとめ、今後の検討課題を提示する。

## 2. 関連事項および関連研究

### 2.1 SVM を用いたコンテキスト依存型ユーザ嗜好モデル化方式

我々は、これまでの研究において、コンテキスト依存型情報推薦の実現を目的とし、SVM を用いたコンテキスト依存型ユーザ嗜好モデル化方式<sup>1),2)</sup>を提案している。SVM<sup>3)</sup>は、主要な2クラス分類手法の1つであり、他の分類手法に比べ高い汎化性能(未知データに対する識別性能)を有する<sup>2)</sup>。

ユーザ嗜好モデル構築の際に用いる学習データに関しては、推薦対象のアイテムに由来する特徴パラメータ(以降、アイテムパラメータ)とユーザコンテキストに由来する特徴パラメータ(以降、コンテキストパラメータ)とを合わせた特徴ベクトルで表現している。これより、ユーザのコンテキストに応じて多様に化する推薦対象アイテムに対する好み(“満足”・“不満足”)の学習を可能としている(図1参照)。

図1(i)のように、単純にはユーザの嗜好は、特徴ベクトル化されたアイテムに対する“満足”・“不満足”をSVMにより学習することによってモデル化することが可能である。

しかしながら、実際には同じアイテムであってもユーザコンテキストによってユーザの嗜好(“満足”・“不満足”)が異なる場合が考えられる。たとえば、飲食店を推薦対象アイテムとしたとき、同じ焼肉店に対しても、「夜に友達といるときに推薦される焼肉店に対しては“満足”であるが、朝に1人でいるときに推薦される焼肉店に対しては“不満足”である」といったことがあげられる。このように、コンテキストによってユーザの嗜好が異なるデータが混在している場合、正しくユーザ嗜好をモデル化することができない(図1(ii))。

そこで、我々のユーザ嗜好モデル化方式では、図1(iii)のように、アイテムパラメータに加えてコンテキストパラメータも合わせて1つの特徴ベクトルとして表現することにより、異なるコンテキストにおいて評価付けされたデータを別々のデータとして扱っている。先の例では、「夜に友達といるときに焼肉店」と「朝に1人でいるときの焼肉店」とはまったく別のデータとして扱われる。こうすることにより、ユーザコンテキストに応じて多様に化するユーザの嗜好を適切にモデル化することが可能になる。

なお、このモデル化方式は、飲食店や音楽、映画などさまざまなコンテンツに対し適用可能なものであるが、我々のこれまでの研究では、飲食店を推薦対象コンテンツとした情報推薦プロトタイプシステムを実装し、この有効性を実証している<sup>1),2)</sup>。このときに用いたアイテムパラメータおよびコンテキストパラメータは、それぞれ、表1および表2のように設定している。




図 1 SVM を用いたコンテキスト依存型ユーザ嗜好モデル化方式

Fig. 1 A context-aware user's preference modeling method using an SVM.

表 1 アイテムパラメータの設定例 (飲食店を推薦対象コンテンツとした場合)

Table 1 Feature parameters for items.

パラメータ項目	次元数	パラメータ
料理ジャンル	8	[和食] / [洋食] / [中華] / [居酒屋] / [アジア] / [ラーメン] / [カフェ、スイーツ] / [その他]
料金	2	[席の料金] / [後の料金 (1~10,000円)]
店の設備/サービス	11	[個室] / [駐車場] / [禁煙席] / [カラオケ] / [深夜営業] / [食べ放題] / [ランチ] / [カード可] / [ライブ] / [テイクアウト] / [貸し切り可]
店の雰囲気	7	[アット向き] / [接待向き] / [宴会・パーティー向き] / [合コン向き] / [ファミリー向き] / [1人でも可] / [少人数向き]

表 2 コンテキストパラメータの設定例 (飲食店を推薦対象コンテンツとした場合)

Table 2 Feature parameters for user's contexts.

パラメータ項目	次元数	パラメータ
時間情報	-	2 [月] (1~12月)
	-	2 [曜日] (日~土)
	-	2 [時刻] (00:00~23:59)
気象情報	天気	4 [晴れ] / [曇り] / [雨] / [雪]
	-	1 [気温] (0~40°C)
ユーザ情報	-	2 [休日] / [休日前]
	-	1 [予算] (0~10,000円)
	-	1 [余裕時間] (0~4時間)
同伴者情報	同伴者グループ	7 [一人] / [家族] / [恋人] / [友人・先輩・後輩] / [上司・部下] / [ビジネス] / [該当なし]
	-	2 [人数(男性)] / [人数(女性)] (0~10人)

本論文において提案する手法は、本節で示した、アイテムパラメータおよびコンテキストパラメータの両方を持つ、ユーザの学習データに基づいて、コンテキスト依存のランキングを実現するものである。

## 2.2 SVM を用いたランキング手法

SVM を用いたランキング手法としては、文書検索の分野において、いくつかの研究が行われている。

平尾らは、重要文抽出に SVM を用いている<sup>4),5)</sup>。重要文抽出を、文書中の各文に対し、重要(正事例)、非重要(負事例)のクラスを付与する 2 クラス分類問題として扱っている。この研究では、SVM の識別関数(識別平面)による値に基づき、文の重要度の算出を行っている。具体的には、識別関数による値が大きい(すなわち特徴空間上で識別平面から遠くにある)事例ほど、重要であると見なしている。しかし、SVM の識別関数による値をそのままランキングに適用させることが妥当であるかどうかについては、理論的な根拠は明らかでない<sup>6),7)</sup>。

Weston らは、多クラス分類問題に対応した Multi-Class SVM を提案している<sup>8),9)</sup>。この手法では、 $k$  クラス分類問題を  $k$  段階の 2 クラス分類問題として扱っている。たとえば、

第  $n$  段階の分類問題は、クラス  $n$  とそれ以外の  $k-1$  個のクラスとの 2 クラス分類問題と見なすことができる。ここで、クラスをランクとして扱うことにより、Multi-Class SVM をランキング手法として適用することが可能である。

Herbrich らは、Ranking SVM を提案している<sup>10)-12)</sup>。この手法では、事例のペアを学習データとして用い、SVM によりこのペアの順序関係を学習することにより、新しい事例に対するランク付けを行う。

Multi-Class SVM や Ranking SVM は、あらかじめ学習データとして与えられるアイテム間に順序関係があることを前提とした手法である。しかしながら、情報推薦という問題においては、ユーザの嗜好や価値判断基準は、ユーザがそのときおかれているコンテキストによって変化する<sup>1),2)</sup> ため、コンテキストが変われば、アイテム間の順序関係も変わってしまう。したがって、Multi-Class SVM や Ranking SVM をそのまま情報推薦におけるランキング手法として適用することは妥当でない。これに対し、本論文での提案手法は、ユーザコンテキストによってユーザの価値判断基準が変化することを考慮しているため、推薦時のユーザコンテキストに相応しいランキングを提示することが可能である。

### 2.3 その他の手法を用いたランキング

2.2 節では、SVM を用いたランキング手法について取り上げたが、より単純なものととしてベクトル空間モデル<sup>13)-15)</sup> やベイズ分類器<sup>16),17)</sup> を用いてランキングを行う方法があげられる。

ベクトル空間モデルは、情報検索における検索モデルとして知られている<sup>13)</sup>。検索対象の文書および検索質問を特徴ベクトルで表現し、ベクトル間の類似度を計算することにより検索質問に適した文書を提示する。この類似度の高さに基づくことにより、検索質問に合ったランキングを行うことが可能である。

ここで、ユーザ嗜好を何らかの方法により特徴ベクトル化することによって、ユーザ嗜好に合ったランキング結果を提示することができると考えられる。しかしながら、ユーザの嗜好はユーザコンテキストにより多様に変化するため、ユーザ嗜好を 1 つの特徴ベクトルで表現することは容易でない。ユーザ嗜好が適切に表現できなければ、これにともなうランキング結果に対する信頼性も乏しい。

ベイズ分類器<sup>16)</sup> は、確率モデルに基づく分類手法であり、対象となるデータを学習データに基づいて確率的に分類するものである。スパムメールのフィルタリングなどに応用されている例があげられる<sup>17)</sup>。ここでも、ユーザ嗜好を確率モデルにより表現することにより、ユーザ嗜好に合わせたランキングを提供することが可能となるが、先と同様、ユーザ嗜好

をより適切に表現するためには、ユーザ嗜好のコンテキスト依存性を考慮に入れる必要がある。

これらの方法に対し、本論文での提案手法では、ユーザコンテキストに依存した価値判断基準モデルを構築することにより、コンテキストに合ったランキングを提供する。

## 3. 提案手法

本章では、提案手法であ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手法（以降、提案手法）について説明する。

本章の構成は以下のとおりである。

- (1) ユーザの価値判断基準モデルの定義
- (2) 学習データからの価値判断基準モデルの構築方法の説明
- (3) 価値判断基準モデルに基づくランキング方法の説明

まず、3.1 節において、ユーザの価値判断基準モデルの定義を行う。つづいて、3.2 節において、この価値判断基準モデルをユーザの学習データから構築する方法について述べる。3.3 節において、この価値判断基準モデルに基づくランキング方法について説明する。

### 3.1 ユーザの価値判断基準モデル

ユーザがあるアイテム集合の中から欲しいアイテムを選択する際、そのユーザは何らかの独自の判断基準を持っているといえる。たとえば、数多くある飲食店の中から行きたい店を選ぶ際、ユーザは飲食店に対して、「安い店が良い」、「近い店が良い」、「バーが良い」といった判断基準を持つ。このユーザが持っている判断基準のことを、本論文では、ユーザのアイテム選択に対する価値判断基準とよぶ。

図 2 は、あるユーザの飲食店選択に対する価値判断基準を図で表したものである。図 2 (a) は、ユーザ A、ユーザ B およびユーザ C の 3 人のユーザが存在し、それぞれ「安い店が良い」、「安くて近い店が良い」、「5,000 円程度のバーが良い」といった価値判断基準を持っていることを示している。

それぞれのユーザの価値判断基準をモデル化したものが図 2 (b) である。このモデルの横軸は各アイテムパラメータ（ここでは、[料金]、[現在地からの距離]、[料理ジャンル]）の値を示し、縦軸はそのパラメータ値に対するユーザの満足度（正  $\Rightarrow$  満足、負  $\Rightarrow$  不満足）を示している。このようにユーザの価値判断基準を表現したモデルを、本論文では、ユーザの価値判断基準モデルとよぶ。このモデルは、ユーザ A のように飲食店のただ 1 つのパラメータ（ここでは [料金]）により表現される場合もあれば、ユーザ B やユーザ C のように

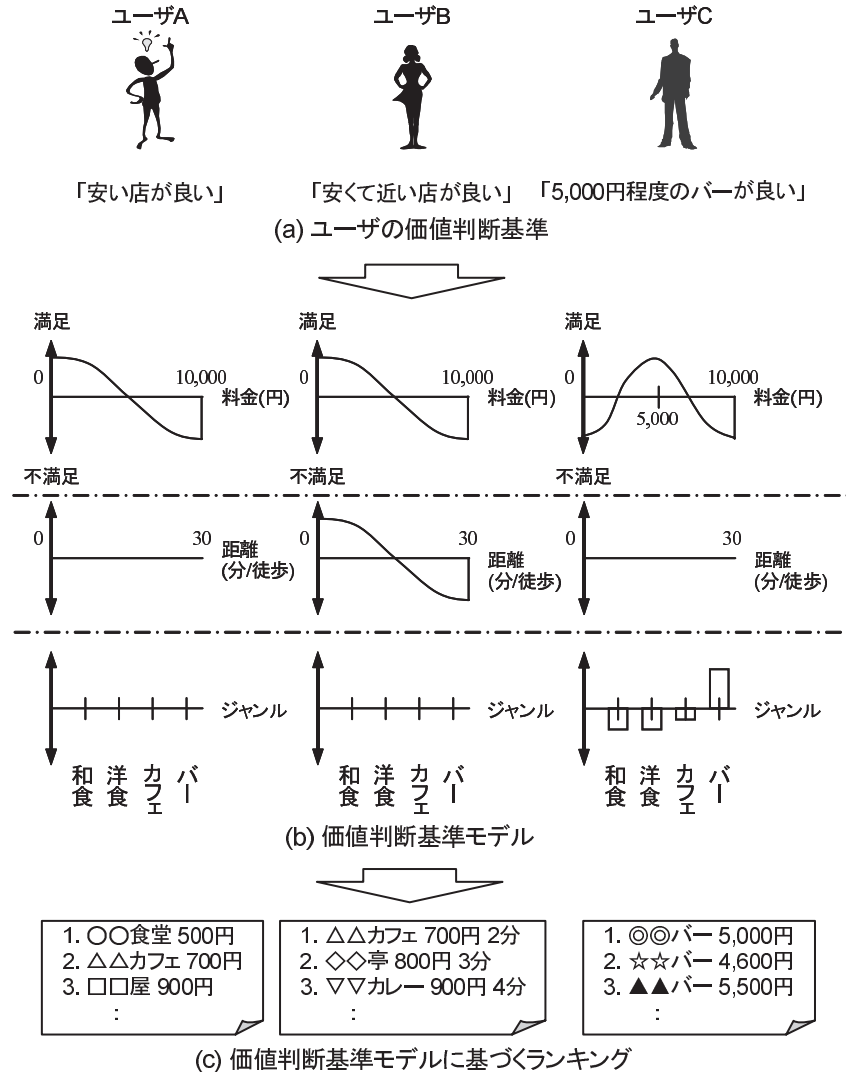


図2 ユーザのアイテム選択に対する価値判断基準（飲食店選択の例）

Fig. 2 User's value judgement for choosing items (example of restaurant choice).

複数のパラメータにより複合的に表現される場合もある。

図2(c)は、各ユーザの価値判断基準モデルに沿って推薦候補である飲食店集合に対しランキングを行っている例である。このようにユーザの価値判断基準を適切にモデル化することができれば、価値判断基準に沿ったランキングを行うことは容易である。

しかしながら、ユーザの価値判断基準はユーザコンテキストに応じて変化するものである。たとえば、同じユーザAであっても、1人では「安い店が良い」、友人といるときには「近い店が良い」、恋人といるときには「5,000円程度のバーが良い」といったようにユーザコンテキストによって価値判断基準は大きく変化するものと考えられる。したがって、推薦候補アイテム集合に対するランキングも必然的にユーザコンテキストに応じて変えなければならない。このことから、ユーザに対し、一意な価値判断基準モデルを作ることは適切でなく、推薦時のユーザコンテキストに合ったモデルを作る必要がある。

提案手法では、ユーザコンテキストに適切なランキングを提示するために、推薦時のユーザコンテキストに依存したユーザの価値判断基準モデルを構築する。まず、3.2節では、ユーザの学習データからユーザコンテキストに依存した価値判断基準モデルの構築方法について述べる。つづいて、3.3節では、この価値判断基準モデルに基づいたランキング方法について説明する。

### 3.2 学習データからの価値判断基準モデルの構築

本節では、ユーザの学習データからユーザコンテキストに依存した価値判断基準モデルを構築する方法について述べる。本節の流れは次のとおりである。

- (1) ユーザの学習データ形式の定義
- (2) 当該コンテキストに関連する学習データの特定方法の説明
- (3) 当該コンテキストにおけるユーザの価値判断基準モデルの構築方法の説明

以下、各項目について述べる。


#### 3.2.1 ユーザの学習データ形式

まず、価値判断基準モデルの構築方法について説明する前に、元となるユーザの学習データの形式について説明する。

図3は、推薦対象アイテムを飲食店とした場合の学習データの例である。図3(a)は、ユーザのアイテム利用履歴データの例を表したものであり、以下の情報を持つ。

- あるユーザコンテキストにおいて利用したアイテムに対する評価（“満足”・“不満足”）
- 利用したアイテムの特徴に関する情報
- アイテム利用時のユーザコンテキストの特徴に関する情報

(a) ユーザのアイテム利用履歴データの形式



(b) ユーザの学習データの形式

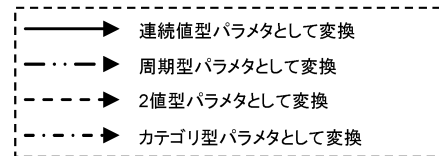


図3 ユーザのアイテム利用履歴データと提案手法で扱う学習データ形式への変換

Fig. 3 User's historical data of item usage and scaling to training data for our proposed method.

この利用履歴データを提案手法で扱える形にするために、図3(b)に示すようなデータ形式に変換する。学習データは次のような情報から構成される。

- $y = \{+1, -1\}$ : 利用したアイテムに対する評価クラスラベル
- $x_1, x_2, \dots, x_p$  ( $0 \leq x_i \leq 1$ ): 利用したアイテムの特徴を表現する  $p$  次元特徴パラメータ (つまり、アイテムパラメータ)

- $c_1, c_2, \dots, c_q$  ( $0 \leq c_j \leq 1$ ): アイテム利用時のユーザコンテキストを表現する  $q$  次元特徴パラメータ (つまり、コンテキストパラメータ)

図3に示すように、アイテムパラメータおよびコンテキストパラメータは、その表現方法により、以下のいずれかの型のパラメータとして扱われる。

- 連続値型パラメータ:  $[0, 1]$  の連続値により表現 ([料金] や [予算] など)




図4 周期性パラメータの表現（[時刻] の例）  
Fig. 4 A cyclic parameter (in the case of “Time”).

- 周期性パラメータ： $([0, 1], [0, 1])$  の 2 次元の連続値型パラメータにより表現（[時刻] など）
- 2 値型パラメータ： $\{0, 1\}$  の 2 値により表現（[個室あり] や [休日] など）
- カテゴリ型パラメータ：3 次元以上の子パラメータを持ち、該当する子パラメータに “1” を、それ以外の子パラメータに “0” を与えることにより表現（[料理ジャンル] や [同伴者] など）

ここで、周期性パラメータは、[時刻] や [月]、[曜日] など周期性を持つものを表現するために扱われる。たとえば、[時刻] は “23:59” の 1 分後が “0:00” となるように、始点と終点が一致するような周期性を持っている。この周期性を表現するために、図 4 に示すように [時刻] を 2 つの次元 (時刻 1, 時刻 2) により表現している。たとえば、“3:00” は  $(0.854, 0.854)$  で表現し、“6:00” は  $(1, 0.5)$  で表現する。また、“24:00” = “0:00” は  $(0.5, 1)$  で表現することができ、始点と終点を同値として扱うことができる。

また、カテゴリ型パラメータの例としては [同伴者] があげられる。[同伴者] は親パラメータであり、子パラメータとして {[なし], [家族], [恋人], [友人], ...} を持つ。家族といることを表現するためには、子パラメータ [家族] に対し “1” を、それ以外の子パラメータに対し

“0” を与える。

本論文では、以降、カテゴリ型パラメータは、[同伴者:家族] のように、[親パラメータ名:子パラメータ名] と表記することにする。また、パラメータの持つ値を示すときは、[予算] = “1,500 円”，[休日] = “1”，[同伴者:家族] = “1” のように、[パラメータ名] = “パラメータ値” と表記する。

### 3.2.2 当該コンテキストに関連する学習データの特定

ユーザコンテキストに依存した価値判断基準モデルを構築するための前処理として、当該コンテキストに関連する学習データの特定を行う必要がある。

当該コンテキストに関連する学習データを特定する方法として、単純には、当該コンテキストと完全一致するような学習データを選べばよい。たとえば、いま、ユーザ A の推薦時のユーザコンテキストが  $C_A = \{[同伴者:恋人] = “1”, [休日] = “1”, [予算] = “5000” \dots\}$  であった場合、ユーザの全学習データの中から、 $C_A$  と一致するユーザコンテキストを持つ学習データを選ぶ。

しかし、すべてのコンテキストパラメータの値が一致するような学習データの数は、ユーザの全学習データ数に対して極少であると考えられる。極少な学習データからでは、適切な価値判断基準モデルを構築することは困難である。したがって、ここでは、すべてのコンテキストパラメータの値の一致をみるのではなく、着目すべきコンテキストパラメータを選定したうえで、このパラメータの値の一致をみる方法を考える。このように着目すべきコンテキストパラメータの数を絞り込むことによって、確保できる学習データ数が増加する。

そこで、本論文では、多次元の特徴ベクトルの中から重要な属性を選択する方法（特徴選択手法<sup>20)</sup>）の 1 つとして、一般によく用いられる情報利得<sup>19)</sup>を用いて、着目すべきコンテキストパラメータの選定を行う。各特徴パラメータに対し、情報利得を求め、最も大きい情報利得を持つ特徴パラメータを選定する。

いま、推薦時のユーザコンテキストが  $C = \{[同伴者:恋人] = “1”, [休日] = “1”, [予算] = “5000” \dots\}$  であったとする。このとき、各コンテキストパラメータ [同伴者:恋人]、[休日]、[予算] について、情報利得を求める。

以下、パラメータの型ごとに、情報利得の求め方について説明する。

#### カテゴリ型・2 値型パラメータの情報利得の算出方法

カテゴリ型パラメータである [同伴者:恋人] を  $c_i$  とすると、このパラメータの情報利得  $Gain_i$  は次式により求められる。

$$Gain_i = E_1 - E_{2i} \quad (1)$$

$$E_1 = -\frac{n^+}{N} \log_2 \frac{n^+}{N} - \frac{n^-}{N} \log_2 \frac{n^-}{N} \quad (2)$$

$$E_{2i} = -\frac{n^+_{|c_i=1}}{N} \log_2 \frac{n^+_{|c_i=1}}{n^+_{|c_i=1}} - \frac{n^-_{|c_i=1}}{N} \log_2 \frac{n^-_{|c_i=1}}{n^-_{|c_i=1}} - \frac{n^+_{|c_i=0}}{N} \log_2 \frac{n^+_{|c_i=0}}{n^+_{|c_i=0}} - \frac{n^-_{|c_i=0}}{N} \log_2 \frac{n^-_{|c_i=0}}{n^-_{|c_i=0}} \quad (3)$$

ここで、 $N$  は全学習データ数、 $n^+$ 、 $n^-$  は正クラス、負クラスの学習データ数、 $n^+_{|c_i=v}$  はコンテキストパラメータ  $c_i = v (v = \{0, 1\})$  の条件下における学習データ数、 $n^+_{|c_i=v}$ 、 $n^-_{|c_i=v}$  は  $c_i = v$  の条件下における正クラス、負クラスの学習データ数を表す。

なお、2 値型パラメータである [休日] についても、カテゴリ型パラメータと同様に情報利得を求めることができる。

連続値型・周期型パラメータの情報利得の算出方法

連続値型パラメータである [予算] を  $c_j$  とすると、上記の式 (3) は、次式のようになる。

$$E_{2i} = -\frac{n^+_{|c_j \approx w}}{N} \log_2 \frac{n^+_{|c_j \approx w}}{n^+_{|c_j \approx w}} - \frac{n^-_{|c_j \approx w}}{N} \log_2 \frac{n^-_{|c_j \approx w}}{n^-_{|c_j \approx w}} - \frac{n^+_{|c_j \neq w}}{N} \log_2 \frac{n^+_{|c_j \neq w}}{n^+_{|c_j \neq w}} - \frac{n^-_{|c_j \neq w}}{N} \log_2 \frac{n^-_{|c_j \neq w}}{n^-_{|c_j \neq w}} \quad (4)$$

ここで、 $w$  は、現在のユーザコンテキストのパラメータ  $c_j$  の値である。この例では、[予算]=“5000 円”であるため、正規化し  $w = 0.5$  となる。

なお、条件としている  $c_j \approx w$  については、その許容範囲を設け、次のように定義する。

$$0.5 - \alpha \leq c_j \leq 0.5 + \alpha (0 \leq \alpha \leq 1) \quad (5)$$

ここで、 $\alpha$  の設定方法については以下のとおりである。

### $\alpha$ の設定方法

$\alpha$  を小さくすると、より現在のユーザコンテキストに限定した学習データを選定することができるため、そのコンテキストによるユーザの価値判断への影響をより強くモデルに反映させることができる。一方で、コンテキストを限定することにより確保できる学習データ数が少なくなり、コンテキスト依存の価値判断基準モデルの構築が困難になる。したがって、モデル構築に十分な学習データ数を確保しつつ、コンテキストによる影響をより強く反映させられるような  $\alpha$  を求める必要がある。

$\alpha$  の設定目標としては、モデル構築に十分な学習データ数を確保できる範囲で、できるだけ小さい値を選択する。具体的には、次の手順により  $\alpha$  を設定する。

step 1 モデル構築に必要なとなる最小限の学習データ数（後述）を決める。

step 2 現在のコンテキストパラメータの値を基準に、 $\alpha$  を 0.1 刻みなど、徐々に大きくしていきながら、そのとき確保できる学習データ数を見る。

step 3 step 1 で決めた最小限の学習データ数を確保できる最小の  $\alpha$  を採用する。

モデル構築に必要なとなる最小限の学習データ数は、推薦対象とするコンテンツなどにも依存することから、情報推薦システムの設計時において実証実験を通じて求める必要がある。具体的には、学習データ数 {10, 20, 30, ...} とテストデータに対する識別性能の関係から、識別性能が収束する最小の学習データ数を選ぶ。なお、5 章における評価実験においては、予備実験により最小限の学習データ数を求めている。

ここでは、連続値型パラメータについての情報利得の算出方法を示したが、周期型パラメータに関しても、2 つの次元を同時に扱うことを除き、連続値型パラメータと同様の方法で情報利得を求めることができる。

以上の方法により、各コンテキストパラメータ  $c_i$  の情報利得  $Gain_i$  を算出し、最も大きい情報利得  $Gain^*$  を持つコンテキストパラメータ  $c^*$  を、着目するコンテキストパラメータとして選定する。そして、全学習データの中から、着目するコンテキストパラメータの値が推薦時のユーザコンテキストのパラメータの値と一致する学習データを特定する。

たとえば、今回の例の場合、[同伴者] が着目するコンテキストパラメータとして選定された場合、[同伴者]=“1” の条件を満たす学習データを選定する。[予算] が着目するコンテキストパラメータとして選定された場合、 $0.5 - \alpha \leq [予算] \leq 0.5 + \alpha (0 \leq \alpha \leq 1)$  (正規化後) の条件を満たす学習データを特定する。

### 3.2.3 当該コンテキストにおけるユーザの価値判断基準モデルの構築

特定された当該コンテキストに関連する学習データに基づいて、当該コンテキストにおけ



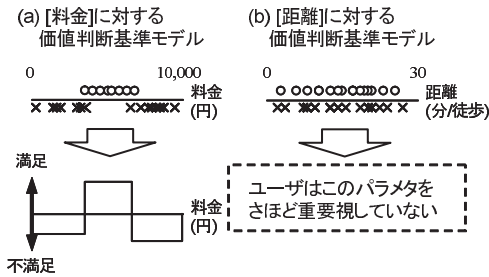


図 5 アイテムパラメータ軸上における正負データの分布に基づく価値判断基準モデルの構築

Fig. 5 Making a user's value model based on the distribution of positive and negative data on the axis of an item parameter.

るユーザの価値判断基準モデルを構築する。


ユーザの価値判断基準モデルは、図 5 に示すように、着目しているアイテムパラメータ軸上における正負データ（ユーザが“満足”・“不満足”と評価付けしたデータ）の分布に基づいて構築される。図 5 (a) は、たとえばアイテムパラメータ [料金] の軸上における正負データの分布を示したものである。この例では、正データが [料金]=5,000 円あたりに集中しているため、ユーザは 5,000 円程度の店に対し満足しているということが読み取れる。

一方で、着目するアイテムパラメータ軸によっては、図 5 (b) のように、正データおよび負データが混在してしまい、有効な価値判断基準モデルを構築できない場合もありうる。しかし、これはそもそもこのアイテムパラメータからでは正負クラスの判別が不可能であるということを意味し、ユーザはこのアイテムパラメータ（図 5 (b) の例では [距離]）をさほど重要視していないととらえることができる。したがって、このようにユーザが重要視していないアイテムパラメータに対しユーザの価値判断基準モデルを構築することはあまり意味がない。

そこで、提案手法では、ユーザが重要視しているアイテムパラメータを選定し、このアイテムパラメータを対象にユーザの価値判断基準モデルを構築する。以下、まず、ユーザが重要視しているアイテムパラメータの選定方法について述べ、つづいて、このアイテムパラメータを対象としたユーザの価値判断基準モデルの構築方法について説明する。

(i) ユーザが重要視しているアイテムパラメータの選定

あるアイテムパラメータに対しユーザがどの程度重要視しているかを示す指標を、このアイテムパラメータに対する重要度と定義する。図 5 (a) のように、着目しているアイテムパ



アイテムパラメータ  $x_i$  の重要度

$$w_{xi} = \left( \frac{2 \times 3}{4(4-1)} + \frac{2 \times 3}{5(5-1)} - \frac{2 \times 2}{4 \times 5} \right) = +0.6$$




図 6 アイテムパラメータの重要度の算出例とデータペアの重なり判定（連続値型パラメータの場合）

Fig. 6 Calculating of importance of an item parameter and overlapped data pair (in the case of continuous parameter).

ラメータ軸上で、正および負の学習データが明確に分離されているような場合には、この重要度は大きくなる。なぜなら、このパラメータによって、正および負のデータを分離することが容易になるからである。一方、図 5 (b) のように、正データおよび負データが混在しているデータが多い場合には、この重要度は小さくなる。

このことをふまえ、アイテムパラメータ  $x_i$  に対する重要度  $w_{xi}$  を、次式のように定義する。

$$w_{xi} = \text{正データの密集度合い} + \text{負データの密集度合い} - \text{正負データの混在度合い} \quad (6)$$

図 6 は、式 (7) に従って、アイテムパラメータ  $x_i$  の重要度を算出している例である。式 (7) の第 1 項（第 2 項）は、アイテムパラメータ  $x_i$  軸上で、正（負）データがどの程度密集しているかを、また、第 3 項は、正負データがどの程度混在しているを示し、具体的に

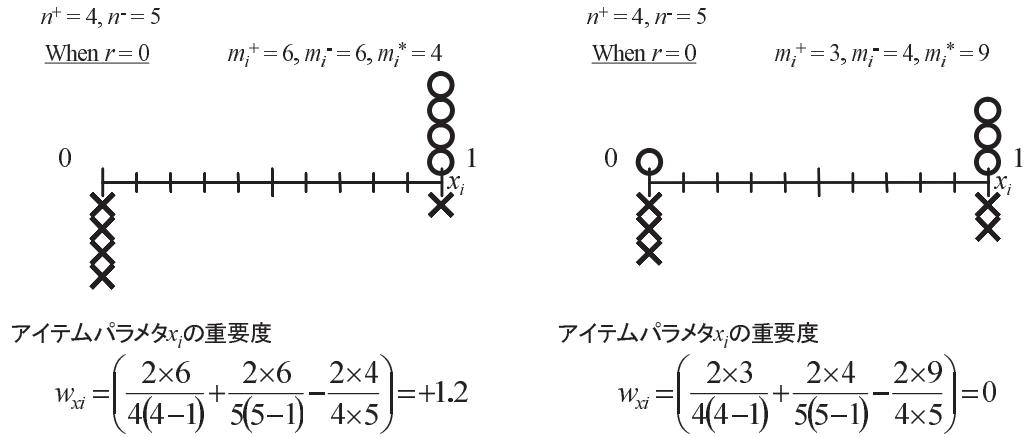


図 7 アイテムパラメタの重要度の算出例 (2 値型およびカテゴリ型の場合)  
Fig. 7 Calculating of importance of an item parameter (in the case of binary and categorical parameter).

は、次式で求められる。

$$\text{正データの密集度合い} = \frac{2m_i^+}{n^+(n^+ - 1)} \tag{7}$$

$$\text{負データの密集度合い} = \frac{2m_i^-}{n^-(n^- - 1)} \tag{8}$$

$$\text{正負データの混在度合い} = \frac{2m_i^*}{n^+n^-} \tag{9}$$

ここで、 $n^+$ 、 $n^-$  はそれぞれ正データ数、負データ数である。図 6 の例では、それぞれ  $n^+ = 4$ 、 $n^- = 5$  となる。正データおよび負データの密集度合いを算出するために、図 6 に示すように任意のデータ幅  $r$  ( $0 \leq r \leq 1$ ) (後述) を設ける。この幅  $r$  を考慮したとき、重なり合っているデータのペアの数を数える。ここでは、重なり合っているデータのペアをデータペアとよび、図 6 の例に示すように、

- 正データペア：正データどうしが重なり合っているデータペア
- 負データペア：負データどうしが重なり合っているデータペア
- 正負データペア：正負データが重なり合っているデータペア

とよぶことにする。式 (7)、(8)、(9) の  $m_i^+$ 、 $m_i^-$ 、 $m_i^*$  は、それぞれ正データペア、負データペア、正負データペアの数である。図 6 の例では、それぞれ  $m_i^+ = 3$ 、 $m_i^- = 3$ 、 $m_i^* = 2$

となる。

図 5 (a) のように、ある領域に正 (負) データが密集していれば、第 1 項 (第 2 項) の値は大きくなり、図 5 (b) のように、ある領域に正負データが混在していれば、第 3 項の値が大きくなる。したがって、(第 1 項+第 2 項) の値と第 3 項の値との差が大きいほど、着目しているアイテムパラメタは重要であるということの意味する。

なお、図 6 は連続値型パラメータでの算出例を示した。2 値型パラメータおよびカテゴリ型パラメータの場合は、パラメータ値のとりうる値が  $\{0, 1\}$  のどちらかであるため、重要度の算出は連続値型パラメータの場合よりも単純になる。図 7 は、ある 2 つの 2 値型のアイテムパラメータの重要度算出例を示したものである。図 7 左の例のように、正負データの分布が偏っている方が、重要度が高くなっていることが確認できる。

この重要度が高い 1 つ以上のアイテムパラメータを対象に、ユーザの価値判断基準モデルを構築する。

$r$  の設定方法

正データどうし、負データどうしが密集しているようなアイテムパラメータの場合、 $r$  が小さいうちは、正データの密集度合い、負データの密集度合いがそれぞれ大きく、正負データの混在度合いが小さくなる。 $r$  を徐々に大きくしていくと、重なり合うデータペアも増えるため、その分、正データの密集度合い、負データの密集度合いも大きくなるが、それ以上




図 8 正負データの分布に基づく価値判断基準モデルの構築手順

Fig. 8 Procedure of making a user's value model based on the distribution positive and negative data.

に正負データの混在度合いも大きくなる．したがって，十分に重なり判定ができる範囲で  $r$  を小さくする必要がある．


あるアイテムパラメータ  $x_i$  に着目し， $r$  を  $0 \leq r \leq 1$  の範囲で，0.01 刻みなどに变化させたとき， $w_{x_i}$  が最大となる  $r$  を求める． $w_{x_i}$  が最大となる  $r$  が複数存在する場合は，その中で最小の  $r$  を採用する．このときの  $r$  を  $r^*$  とする． $r^*$  のときの  $w_{x_i}$  を  $w_{x_i}^*$  とし，これを着目しているアイテムパラメータに対する重要度とする．

(ii) ユーザの価値判断基準モデルの構築

図 8 は，ユーザの価値判断基準モデルの構築過程を示したものである．ここでは，ユーザが重要視しているアイテムパラメータとして， $x_i, x_j$  が判定されたものとする．なお， $x_i$  は連続値型パラメータ， $x_j$  は 2 値型パラメータとする．ユーザは重要視しているアイテムパラメータ軸上で，正データが密集している領域において，より満足し，負データが密集している領域において，より不満に感じると考えられる．この観点から正データおよび負データのヒストグラムを作成し，このヒストグラムに基づいて価値判断基準モデルを構築する．

以下，モデルの構築手順を示す．

- step 1 アイテムパラメータ  $x_i, x_j$  軸上の正負データの分布に基づき，正データ，負データ別にヒストグラムをプロットする（ここでは，級の間隔を 0.1 とする）．正データのヒストグラムは正方向に，負データのヒストグラムは負方向にそれぞれプロットする．
- step 2 正データ，負データのそれぞれで，ヒストグラムの総面積が 1 になるように正規化



(a) ユーザの価値判断基準モデル

(b) 推薦候補アイテム集合 ( ()内は対応するパラメタ値に対するスコア)

店舗名	ジャンル	料金 (円)	距離 (分徒歩)	...	ランキングスコア計
●●屋	和食 (-0.2)	3,000 (+0.2)	5 (0)	...	0
◎◎バー	バー (+0.8)	5,000 (+0.6)	10 (0)	...	+1.4
△△カフェ	カフェ (-0.1)	700 (-0.1)	2 (0)	...	-0.2
☆☆バー	バー (+0.8)	8,000 (-0.2)	4 (0)	...	+0.6

図 9 推薦候補アイテムに対するランキングスコアの算出

Fig. 9 Calculating ranking score of recommended items.

を行う．

- step 3 正データ，負データのヒストグラムを足し合わせることで，ユーザのアイテムパラメータ  $x_i, x_j$  に対する価値判断基準モデルを構築する．

この価値判断基準モデルは，横軸に着目しているアイテムパラメータのとり値を示し，縦軸は，このパラメータの値に依存したユーザの満足度を示す．正方向（満足側）に大きいほど，ユーザはそのアイテムパラメータの値に満足していることを意味する．次節では，この価値判断基準モデルに基づくランキングスコアの算出方法について具体的に説明する．

3.3 価値判断基準モデルに基づくランキング

ユーザの価値判断基準モデルに基づいて，推薦候補アイテム集合に対し，ランキングスコアを算出する．

ユーザの価値判断基準モデルが図 9 (a) に示すようであったとし，また，図 9 (b) に示すような推薦候補アイテム集合が与えられたとする．このとき，推薦候補アイテム集合に対するランキングスコアは，図 9 に示すように算出される．

たとえば，[ジャンル] がバーであるようなアイテムには，[ジャンル] パラメータに対するユーザの価値判断基準モデルから，ランキングスコア “+0.8” が加算される．[料金] に関しても，[料金] パラメータに対する価値判断基準モデルから，料金に応じてランキングスコアが加算される．ただし，[距離] パラメータに関してはランキングスコアは加算されない．これは，このユーザが [距離] に対しては重要視していないためである．このようにユーザが

重要視しているアイテムパラメータのみをランキングスコア加算の対象とすることにより、ユーザの価値判断基準を適切に反映させたランキングスコアの算出が可能となる。

最終的に、こうして得られたランキングスコアを集計することにより、推薦候補アイテム各々のランキングスコアが算出される。このランキングスコアが高いものを上位にし、ユーザに提示する。

#### 4. コンテキスト依存型情報推薦プロトタイプシステム

我々はこれまでに、2.1 節で述べたコンテキスト依存型ユーザ嗜好モデルを含めた、コンテキスト依存型情報推薦プロトタイプシステムを実装した<sup>2)</sup>。図 10 は、そのコンテキスト

依存型情報推薦プロトタイプシステムの構成図である。細部の詳細は文献 2) で述べているため割愛するが、ここでは、これまでの研究において提案した部分と本研究が対象としている部分を明示する。

我々のこれまでの研究では、コンテキスト依存型ユーザ嗜好モデルに基づいて、ユーザコンテキストに合った推薦候補アイテム集合の判定までを行っている。3 章で述べた、本論文での提案手法では、この推薦候補アイテム集合を対象にランキングを行うものである。

このようにランキングを行う前に、ユーザコンテキストに合った推薦候補アイテム集合を判定しておくことにより、事前にユーザにとって不要なアイテム集合を取り除くことができるため、ランキング結果に対するユーザ満足度の向上につながる。我々のユーザ嗜好モデル

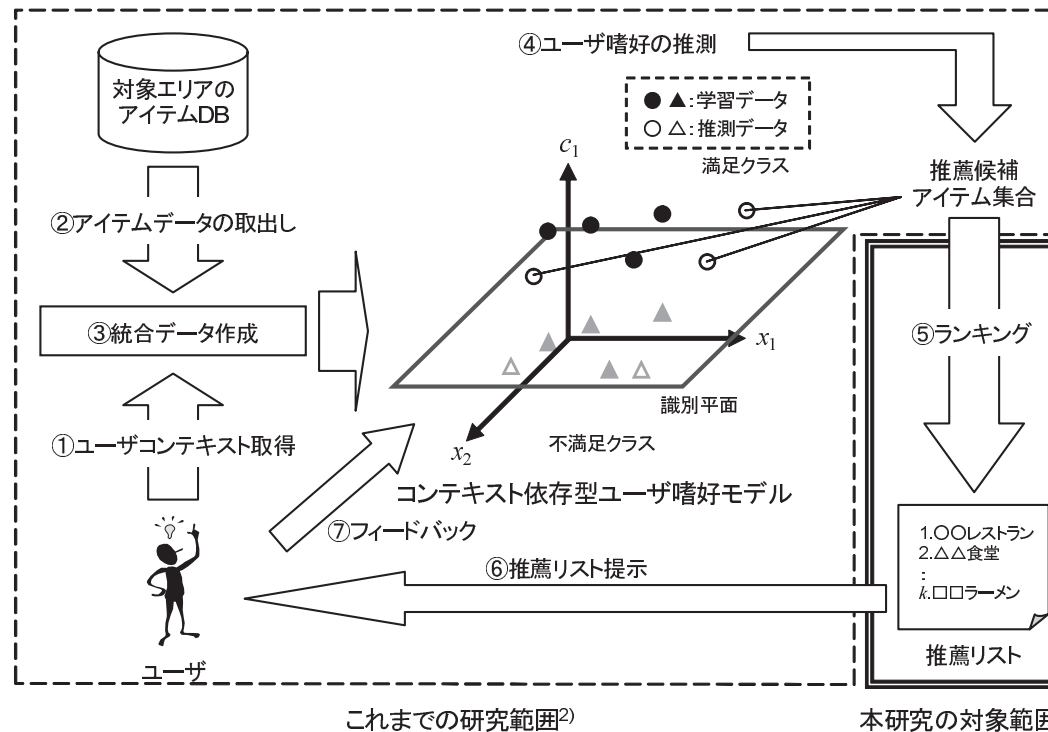


図 10 コンテキスト依存型情報推薦プロトタイプシステム  
Fig. 10 A prototype of context-aware recommendation system.

表 3 実験で用いた学習データ形式

Table 3 A format of training data used for experiments.

クラス / パラメタ種別	記号	パラメタ名	パラメタの型	実験で取りうる値		
クラス	class	ユーザ満足度		{5, 4, 3, 2, 1}※		
アイテムパラメタ	$x_1$	ジャンル:和食	カテゴリ型	いずれか一つ:1 それ以外:0		
	$x_2$	ジャンル:洋食				
	$x_3$	ジャンル:中華				
	$x_4$	ジャンル:アジア・焼肉・エスニック・無国籍				
	$x_5$	ジャンル:カフェ				
	$x_6$	ジャンル:和風居酒屋				
	$x_7$	ジャンル:洋風居酒屋				
	$x_8$	ジャンル:アジア・無国籍居酒屋				
	$x_9$	ジャンル:ダイニングバー・ビアレストラン				
	$x_{10}$	ジャンル:バー・パブ				
	$x_{11}$	ジャンル:スペース・エンターテイメント				
	$x_{12}$	ジャンル:ファミレス・ファーストフード				
	$x_{13}$	料金			連続値型	[0, 1]
	$x_{14}$	距離			連続値型	[0, 1]
コンテキストパラメタ	$c_1$	時刻	連続値型	{0.333, 0.500, 0.792}		
	$c_2$	休日	2値型	{0, 1}		
	$c_3$	休日前	2値型	{0, 1}		
	$c_4$	予算	連続値型	{0.1, 0.2, 0.3, 0.5}		
	$c_5$	同伴者:なし	カテゴリ型	いずれか一つ:1 それ以外:0		
	$c_6$	同伴者:家族				
	$c_7$	同伴者:恋人				
	$c_8$	同伴者:友人				

※5.2.3節で述べる、提案方式および識別平面からの距離に基づく方法では、ユーザ満足度{5, 4, 3, 2, 1}のうち、3以上を満足(正)クラス、2以下を不満足(負)クラスとして扱う。Multi-Class SVMを用いた方法では、{5, 4, 3, 2, 1}をそのまま5クラスとして扱う。

に基づいて判定された推薦候補アイテム集合に関しては、すでに検証実験により高いユーザ満足度を示すことを実証しているため、この推薦候補アイテム集合に対してランキング処理を行うことの有効性は高い。

## 5. 評価実験

提案手法の有効性を評価するために被験者実験を行った。本実験では、飲食店データを推薦対象アイテムとした学習データセットを用いて、被験者の飲食店選択に対する価値判断基準モデルを構築した。そして、学習データセットとは別に作成した評価用データセットに対

し、このモデルに基づいたランキングを行い、その有効性を評価した。

### 5.1 実験条件

本実験では、一般向けグルメ情報検索サイトである『ぐるなび』<sup>21)</sup>が提供している『ぐるなびAPI』<sup>22)</sup>を利用し、飲食店データセットを作成した。対象エリアとして、さまざまなジャンルの飲食店が豊富に存在する「大阪：なんば」エリアを選択した。このエリアに登録されている全飲食店データの中から1,000件を無作為に選んだ。

なお、表3は、本実験で用いる学習データセットの形式であり、飲食店データの特徴は、表3に示す14次元のアイテムパラメタ、ユーザコンテキストは、8次元のコンテキスト

パラメータにより、それぞれ表現している。これらのパラメータは、我々がこれまでに行った被験者実験<sup>2)</sup>により、被験者の価値判断基準に影響を及ぼしていると判定されたパラメータを扱っている。

本実験における被験者は、22歳から36歳の男女10人である。いずれの被験者も、「大阪：なんば」エリアには何度か訪れたことがあり、これらのエリアの雰囲気などについてはある程度把握している。このように被験者が把握しているエリアを実験対象として選択したのは、研究室内で仮想的に実験を行うため、本実験を行うにあたって、できるだけ被験者にユーザコンテキストを想像しやすくするためである。

### 5.2 実験方法

実験方法について説明する。本実験は以下の4段階のフェーズに従って遂行する。

- フェーズ1 被験者の学習データセットの作成
- フェーズ2 被験者の評価用データセットの作成
- フェーズ3 評価用データセットに対するランキング処理
- フェーズ4 ランキング結果に対する評価

以下、各フェーズについて詳細に説明する。なお、ここでは、実際に実験の被験者となった被験者Aによる実験過程およびデータを例に示しながら説明を行う。

#### 5.2.1 フェーズ1：被験者の学習データセットの作成

まず、以下の手順に従って、あらかじめ各被験者の学習データセットを作成する。

- (1) 被験者には、各自「大阪：なんば」エリアにおいて、現実起こりうるコンテキストを想像してもらい、表3に示すコンテキストパラメータのとりうる値の組合せから、20個のコンテキストパターン  $\{C_1, C_2, \dots, C_{20}\}$  を設定してもらう。この20個のコンテキストパターンは、可能な限り、多様なものになるようにする。
- (2) 被験者には、1つのコンテキストパターンあたり、飲食店データセットの中から無作為に抽出された10件の飲食店データに対し、5段階の満足度評価  $\{5, 4, 3, 2, 1\}$  (5: 最も満足, 1: 最も不満足) を与えてもらう。
- (3) 満足度評価に基づいて、被験者1人あたり計200個 (=20コンテキストパターン × 10飲食店データ) の学習データからなる学習データセットを作成する。

例として、被験者Aが設定したコンテキストパターンを図11に示す。図11(a)は、被験者Aが設定した20個のコンテキストパターンであり、図11(b)は、1つめのコンテキストパターン  $C_1$  をベクトルで表現した例である。なお、連続値型パラメータである[時刻]および[予算]に関しては、本実験では、これらの設定を容易にするため、表3に示すよう

(a) 被験者Aが設定した実験用コンテキストパターン

コンテキストパターン	時刻	休日	休日前	予算(円)	同伴者
* コンテキスト $C_1$	8:00	true	false	1000	なし
コンテキスト $C_2$	19:00	false	false	2000	家族
コンテキスト $C_3$	8:00	true	false	1000	家族
* コンテキスト $C_4$	19:00	true	true	5000	恋人
コンテキスト $C_5$	12:00	true	false	2000	恋人
コンテキスト $C_6$	19:00	true	true	5000	友人
コンテキスト $C_7$	19:00	false	false	1000	なし
* コンテキスト $C_8$	12:00	false	false	1000	友人
コンテキスト $C_9$	19:00	true	false	2000	友人
コンテキスト $C_{10}$	12:00	false	false	1000	なし
コンテキスト $C_{11}$	12:00	true	false	2000	友人
コンテキスト $C_{12}$	19:00	false	false	2000	恋人
コンテキスト $C_{13}$	19:00	true	true	2000	なし
* コンテキスト $C_{14}$	12:00	true	false	2000	家族
コンテキスト $C_{15}$	19:00	false	true	3000	恋人
コンテキスト $C_{16}$	19:00	false	false	2000	友人
* コンテキスト $C_{17}$	19:00	true	true	3000	家族
コンテキスト $C_{18}$	19:00	true	false	3000	恋人
コンテキスト $C_{19}$	12:00	true	false	2000	なし
コンテキスト $C_{20}$	8:00	false	false	1000	家族

\*は評価用データセット作成時に選ばれたコンテキストパターン。

(b) コンテキストのベクトル表現  
(コンテキスト  $C_1$  の場合)

コンテキストパターン	時刻	休日	休日前	予算(円)	同伴者
コンテキスト $C_1$	8:00	true	false	1000	なし

$$C_1 = \{c_1, c_2, c_3, c_4, c_5, c_6, c_7, c_8\}$$

$$= \{0.333, 1, 0, 0.1, 1, 0, 0, 0\}$$

図11 実験用コンテキストパターンの設定例(被験者Aの場合)

Fig. 11 An example of context patterns for experiments (in the case of user A).

に、あらかじめとり得る値を用意しておき、この中から被験者に選んでもらうようにした。

被験者Aが作成した学習データセットの一部を抜粋したものを図12(a)に示す。図12(a)のように、各コンテキストパターンにおいて10個ずつの学習データが作成されている。

図12(b)のように、1つの学習データは、

- ユーザ満足度: class  $\{5, 4, 3, 2, 1\}$
- 評価対象のアイテムパラメータ:  $(x_1, x_2, \dots, x_{14})$
- 評価時のコンテキストパラメータ:  $(c_1, c_2, \dots, c_8)$

により構成されている。

71 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

(a) 被験者Aの学習データセット (一部抜粋) (全200データ)

no	class	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	$c_1$	$c_2$	$c_3$	$c_4$	$c_5$	$c_6$	$c_7$	$c_8$
1	1	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
2	5	0	0	0	0	1	0	0	0	0	0	0	0	0.060	0.5	0.333	1	0	0.1	1	0	0	0
3	1	0	1	0	0	0	0	0	0	0	0	0	0	0.440	0.1	0.333	1	0	0.1	1	0	0	0
4	1	0	0	0	0	0	1	0	0	0	0	0	0	0.300	0.3	0.333	1	0	0.1	1	0	0	0
5	1	0	0	0	0	0	0	1	0	0	0	0	0	0.280	0.3	0.333	1	0	0.1	1	0	0	0
6	3	0	0	0	0	0	0	0	0	0	0	1	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
7	1	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.3	0.333	1	0	0.1	1	0	0	0
8	1	0	0	0	0	0	0	0	0	1	0	0	0	0.350	0.3	0.333	1	0	0.1	1	0	0	0
9	1	0	0	0	1	0	0	0	0	0	0	0	0	0.265	0.1	0.333	1	0	0.1	1	0	0	0
10	1	0	0	1	0	0	0	0	0	0	0	0	0	0.110	0.5	0.333	1	0	0.1	1	0	0	0
11	1	0	0	1	0	0	0	0	0	0	0	0	0	0.380	0.4	0.792	0	0	0.2	0	1	0	0
12	2	0	0	0	0	0	0	0	0	0	1	0	0	0.100	0.1	0.792	0	0	0.2	0	1	0	0
13	1	0	0	0	0	0	0	0	0	1	0	0	0	0.300	0.5	0.792	0	0	0.2	0	1	0	0
14	5	1	0	0	0	0	0	0	0	0	0	0	0	0.120	0.1	0.792	0	0	0.2	0	1	0	0
15	3	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.3	0.792	0	0	0.2	0	1	0	0
16	1	0	0	0	1	0	0	0	0	0	0	0	0	0.350	0.5	0.792	0	0	0.2	0	1	0	0
17	1	0	0	0	0	1	0	0	0	0	0	0	0	0.300	0.2	0.792	0	0	0.2	0	1	0	0
18	2	0	0	0	1	0	0	0	0	0	0	0	0	0.100	0.1	0.792	0	0	0.2	0	1	0	0
19	2	0	1	0	0	0	0	0	0	0	0	0	0	0.300	0.1	0.792	0	0	0.2	0	1	0	0
20	1	0	0	0	0	0	0	1	0	0	0	0	0	0.280	0.2	0.792	0	0	0.2	0	1	0	0
21	1	0	0	0	0	0	0	0	1	0	0	0	0	0.200	0.3	0.333	1	0	0.1	0	1	0	0
22	1	0	0	0	0	0	0	1	0	0	0	0	0	0.280	0.2	0.333	1	0	0.1	0	1	0	0
23	1	0	0	0	1	0	0	0	0	0	0	0	0	0.300	0.3	0.333	1	0	0.1	0	1	0	0
24	1	0	0	0	0	1	0	0	0	0	0	0	0	0.370	0.3	0.333	1	0	0.1	0	1	0	0
25	1	0	0	1	0	0	0	0	0	0	0	0	0	0.700	0.1	0.333	1	0	0.1	0	1	0	0
26	4	0	0	0	0	0	0	0	0	0	1	0.050	0.1	0.333	1	0	0.1	0	1	0	0	0	0
27	1	1	0	0	0	0	0	0	0	0	0	0	0	0.800	0.5	0.333	1	0	0.1	0	1	0	0
28	5	0	0	0	1	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	0	1	0	0
29	1	0	1	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	0	1	0	0
30	1	1	0	0	0	0	0	0	0	0	0	0	0	0.160	0.1	0.333	1	0	0.1	0	1	0	0
31	5	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.3	0.792	1	1	0.5	0	0	1	0
32	4	0	0	0	0	0	0	1	0	0	0	0	0	0.280	0.2	0.792	1	1	0.5	0	0	1	0
33	1	0	0	0	0	0	0	0	0	0	1	0	0	0.100	0.1	0.792	1	1	0.5	0	0	1	0
34	4	0	0	0	0	1	0	0	0	0	0	0	0	0.250	0.3	0.792	1	1	0.5	0	0	1	0
35	1	0	0	0	1	0	0	0	0	0	0	0	0	0.065	0.1	0.792	1	1	0.5	0	0	1	0
36	1	0	0	1	0	0	0	0	0	0	0	0	0	0.110	0.5	0.792	1	1	0.5	0	0	1	0
37	4	0	0	1	0	0	0	0	0	0	0	0	0	0.350	0.2	0.792	1	1	0.5	0	0	1	0
38	3	0	1	0	0	0	0	0	0	0	0	0	0	0.450	0.5	0.792	1	1	0.5	0	0	1	0
39	1	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.2	0.792	1	1	0.5	0	0	1	0
40	3	1	0	0	0	0	0	0	0	0	0	0	0	0.250	0.3	0.792	1	1	0.5	0	0	1	0
41	1	0	0	0	0	1	0	0	0	0	0	0	0	0.150	0.3	0.500	1	0	0.2	0	0	1	0
42	1	0	0	0	0	0	0	1	0	0	0	0	0	0.350	0.5	0.500	1	0	0.2	0	0	1	0
43	1	0	0	0	0	0	0	0	1	0	0	0	0	0.250	0.5	0.500	1	0	0.2	0	0	1	0
44	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.500	1	0	0.2	0	0	1	0
45	2	0	0	1	0	0	0	0	0	0	0	0	0	0.080	0.5	0.500	1	0	0.2	0	0	1	0
46	4	0	0	0	1	0	0	0	0	0	0	0	0	0.120	0.1	0.500	1	0	0.2	0	0	1	0
47	1	0	0	0	0	0	0	0	0	0	1	0	0	0.350	0.5	0.500	1	0	0.2	0	0	1	0
48	2	0	0	1	0	0	0	0	0	0	0	0	0	0.350	0.5	0.500	1	0	0.2	0	0	1	0
49	2	0	1	0	0	0	0	0	0	0	0	0	0	0.300	0.4	0.500	1	0	0.2	0	0	1	0
50	1	1	0	0	0	0	0	0	0	0	0	0	0	0.450	0.5	0.500	1	0	0.2	0	0	1	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
200	1	1	0	0	0	0	0	0	0	0	0	0	0	0.600	0.3	0.333	0	0	0.1	0	1	0	0

(b) 学習データの説明 (データNo.1の場合)

no	class	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	$c_1$	$c_2$	$c_3$	$c_4$	$c_5$	$c_6$	$c_7$	$c_8$	
1	1	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0	0

ユーザ満足度: 1      評価対象のアイテム: {ジャンル:和食="1"  
 [料金(円)]=1000"  
 [距離(分/徒歩)]=1"}      評価時のコンテキスト:  $C_1$

図 12 実験で用いた学習データセット (被験者 A の場合)

Fig. 12 A training data set used for experiments (in the case of user A).

5.2.2 フェーズ 2: 被験者の評価用データセットの作成

つづいて、学習データセットとは別に、以下の手順に従って、各被験者の評価用データセットを作成する。

- (1) 学習データ作成時に設定した 20 個のコンテキストパターン  $\{C_1, C_2, \dots, C_{20}\}$  の中から、パラメータの値が可能な限りばらつくように 5 個のコンテキストパターンを選ぶ。
- (2) 被験者には、1 つのコンテキストパターンあたり、データセットの中から無作為に抽出された 40 件の飲食店データに対し、学習データ作成時と同様に、5 段階の満足度評価を与えてもらう。
- (3) 満足度評価に基づいて、1 つのコンテキストパターンあたり 40 個のアイテムデータからなる評価用データセットを作成する。最終的に、被験者 1 人あたり、各コンテキストパターンに対応した 5 個の評価用データセットが作成される。

被験者 A の例では、図 11 に \* を示したように、 $\{C_1, C_4, C_8, C_{14}, C_{17}\}$  の 5 個のコンテキストパターンを選んでいる。被験者 A が作成した評価用データセットを図 13 に示す。図 13 は、上記で示した 5 個のコンテキストパターンのうち、 $C_1$  に対応した評価用データセットを示している。

5.2.3 フェーズ 3: 評価用データセットに対するランキング処理

各コンテキストパターンにおける評価用データセットに対し、ランキング処理を行う。

5.3 節で述べる比較実験においては、(I) 提案方式のほかに、以下の 2 つのランキング方式を比較対象とする。

- 機械学習手法による出力値に基づくランキング方式
- 多クラス分類手法に基づくランキング方式

本実験では、(II) の方式として、SVM の識別平面からの距離に基づくランキング方法<sup>4),5)</sup> (III) の方式として、Multi-Class SVM<sup>8),9)</sup> に基づくランキング方法を取り上げる。いずれも SVM<sup>3)</sup> をベースとしたランキング方法であるが、これは、SVM が現在知られている手法の中で、最も認識性能の高い学習モデルの 1 つである<sup>23)</sup> という根拠に基づき、基本的には SVM には依存しない。

なお、いずれのランキング方式においても、学習データセットおよび評価用データセットは、5.2.1 項および 5.2.2 項で説明したものをを用いる。

本節では、提案方式によるランキング手順とあわせ、上記 2 つの方式によるランキング手順についてそれぞれ説明する。



72 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

被験者Aの評価用データセット (コンテキスト $C_1$ におけるデータセット)

no	class	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	$c_1$	$c_2$	$c_3$	$c_4$	$c_5$	$c_6$	$c_7$	$c_8$
1	1	0	0	1	0	0	0	0	0	0	0	0	0	0.300	0.5	0.333	1	0	0.1	1	0	0	0
2	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
3	1	0	0	0	1	0	0	0	0	0	0	0	0	0.360	0.2	0.333	1	0	0.1	1	0	0	0
4	1	0	0	0	0	0	1	0	0	0	0	0	0	0.250	0.4	0.333	1	0	0.1	1	0	0	0
5	5	0	0	0	0	1	0	0	0	0	0	0	0	0.063	0.2	0.333	1	0	0.1	1	0	0	0
6	3	0	0	0	0	0	0	0	0	0	0	1	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
7	1	0	0	0	0	0	0	0	0	1	0	0	0	0.300	0.3	0.333	1	0	0.1	1	0	0	0
8	3	1	0	0	0	0	0	0	0	0	0	0	0	1.000	0.2	0.333	1	0	0.1	1	0	0	0
9	1	0	1	0	0	0	0	0	0	0	0	0	0	0.400	0.5	0.333	1	0	0.1	1	0	0	0
10	1	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.5	0.333	1	0	0.1	1	0	0	0
11	1	0	1	0	0	0	0	0	0	0	0	0	0	0.300	0.5	0.333	1	0	0.1	1	0	0	0
12	1	0	0	0	0	0	0	0	0	1	0	0	0	0.250	0.3	0.333	1	0	0.1	1	0	0	0
13	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
14	1	0	0	0	0	1	0	0	0	0	0	0	0	0.320	0.2	0.333	1	0	0.1	1	0	0	0
15	1	0	0	0	1	0	0	0	0	0	0	0	0	0.350	0.1	0.333	1	0	0.1	1	0	0	0
16	1	0	0	0	0	0	0	1	0	0	0	0	0	0.250	0.1	0.333	1	0	0.1	1	0	0	0
17	5	0	0	0	0	1	0	0	0	0	0	0	0	0.070	0.1	0.333	1	0	0.1	1	0	0	0
18	4	0	0	0	0	0	0	0	0	0	0	0	1	0.050	0.1	0.333	1	0	0.1	1	0	0	0
19	3	0	0	1	0	0	0	0	0	0	0	0	0	0.085	0.1	0.333	1	0	0.1	1	0	0	0
20	1	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.6	0.333	1	0	0.1	1	0	0	0
21	3	0	0	0	0	0	0	0	0	0	1	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
22	1	0	0	1	0	0	0	0	0	0	0	0	0	0.300	0.5	0.333	1	0	0.1	1	0	0	0
23	1	0	1	0	0	0	0	0	0	0	0	0	0	0.480	0.1	0.333	1	0	0.1	1	0	0	0
24	5	0	0	0	0	1	0	0	0	0	0	0	0	0.055	0.1	0.333	1	0	0.1	1	0	0	0
25	1	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.1	0.333	1	0	0.1	1	0	0	0
26	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.333	1	0	0.1	1	0	0	0
27	1	0	0	0	1	0	0	0	0	0	0	0	0	0.350	0.2	0.333	1	0	0.1	1	0	0	0
28	1	0	0	0	0	1	0	0	0	0	0	0	0	0.380	0.3	0.333	1	0	0.1	1	0	0	0
29	1	1	0	0	0	0	0	0	0	0	0	0	0	0.600	0.5	0.333	1	0	0.1	1	0	0	0
30	1	0	0	0	0	0	0	1	0	0	0	0	0	0.300	0.5	0.333	1	0	0.1	1	0	0	0
31	1	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.3	0.333	1	0	0.1	1	0	0	0
32	1	0	1	0	0	0	0	0	0	0	0	0	0	0.250	0.3	0.333	1	0	0.1	1	0	0	0
33	1	0	0	0	1	0	0	0	0	0	0	0	0	0.440	0.1	0.333	1	0	0.1	1	0	0	0
34	1	0	0	0	0	0	0	0	0	0	1	0	0	0.350	0.5	0.333	1	0	0.1	1	0	0	0
35	1	0	0	0	0	0	0	1	0	0	0	0	0	0.250	0.1	0.333	1	0	0.1	1	0	0	0
36	3	1	0	0	0	0	0	0	0	0	0	0	0	0.130	0.5	0.333	1	0	0.1	1	0	0	0
37	1	0	0	1	0	0	0	0	0	0	0	0	0	0.280	0.2	0.333	1	0	0.1	1	0	0	0
38	5	0	0	0	0	1	0	0	0	0	0	0	0	0.060	0.5	0.333	1	0	0.1	1	0	0	0
39	1	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.1	0.333	1	0	0.1	1	0	0	0
40	2	0	0	0	0	0	1	0	0	0	0	0	0	0.150	0.3	0.333	1	0	0.1	1	0	0	0

評価時のコンテキスト: $C_1$

図 13 実験で用いた評価用データセット (被験者 A の場合)

Fig.13 A test data set used for experiments (in the case of user A).

(I) 提案方式によるランキング

(i) 当該コンテキストに関連する学習データの特定

3.2.2 項で述べた説明に従って、以下の手順により、当該コンテキストに関連する学習データを特定する。

- (1) 被験者の学習データセットに基づき、各コンテキストパラメータ  $c_i$  について、情報利得を算出する。
- (2) 情報利得の最も大きいコンテキストパラメータの値に基づいて、当該コンテキストに

表 4 各コンテキストパラメータに対する情報利得 (コンテキスト  $C_1$  における被験者 A の場合)

Table 4 Information gain for each context parameter (in the case of user A at context  $C_1$ ).

コンテキストパラメータ	情報利得
$c_1$ 時刻	0.0076
$c_2$ 休日	0.0005
$c_3$ 休日前	0.0085
$c_4$ 予算	0.0138
$c_{5-8}$ 同伴者	0.0039

関連する学習データを特定する。

被験者 A の学習データセットを対象にしたとき、当該コンテキストパターンが  $C_1$  の場合の各コンテキストパラメータ  $c_i$  の情報利得を求める。

例として、コンテキストパラメータ  $c_4$ 、すなわち [予算] パラメータの情報利得を求める。被験者 A の学習データセットより、式 (2)、(4) で用いる各値は、次のようになった。

$$\begin{aligned}
 N &= 200 & n^+ &= 77 & n^- &= 123 \\
 n|_{c_4 \approx 0.1} &= 60 & n^+|_{c_4 \approx 0.1} &= 17 & n^-|_{c_4 \approx 0.1} &= 43 \\
 n|_{c_4 \neq 0.1} &= 140 & n^+|_{c_4 \neq 0.1} &= 60 & n^-|_{c_4 \neq 0.1} &= 80
 \end{aligned} \tag{10}$$

なお、提案方式では、class が 5 段階のうち 3 以上のデータを正データ、2 以下のデータを負データとして扱っている。上記の値を、それぞれ式 (2)、(4) に代入すると、

$$E_1 = 0.9615 \tag{11}$$

$$E_2 = 0.9477 \tag{12}$$

を得る。したがって、式 (1) より、 $Gain_4$  は、

$$Gain_4 = 0.9615 - 0.9477 = 0.0138 \tag{13}$$

となる。同様に、各コンテキストパラメータ  $c_i$  の情報利得は、表 4 のとおりとなった。

この中で、コンテキストパラメータ  $c_4$ 、すなわち [予算] の情報利得が最も大きかったため、[予算] パラメータを着目するコンテキストパラメータとして選定する。

したがって、この  $c_4$  の値に基づいて、学習データを特定する。つまり、 $0.1 - \alpha \leq c_4 \leq 0.1 + \alpha$  ( $\alpha = 0$ ) となる学習データを選ばよいため、被験者 A の学習データセットから特定した学習データ数は 60 個となる。

なお、連続値型パラメータの情報利得算出時に用いる  $\alpha$  (3.2.2 項参照) は、 $\alpha = 0$  とし






図 14 予備実験：学習データ数と未知データに対する識別性能の関係

Fig. 14 Preliminary experiment: relationship between the number of training data and model accuracy for untrained data.

た．これは，本実験で用いたすべての被験者のデータセットにおいては， $\alpha = 0$  で十分な学習データ数を確保できるためである．


ここでいう，十分な学習データ数は事前に行った予備実験により決定した．図 14 は，予備実験において，学習データ数と未知データに対するモデルの識別性能の関係を示したものである．データセットとしては，本実験で用いた被験者の学習データセット，未知データとしての評価用データセットを用いた．図 14 より，学習データ数が 30 のときに，すでに識別性能が収束しているといえるため，本実験における十分な学習データ数は 30 と判断した．いずれのデータセットにおいても， $\alpha = 0$  としたとき，学習データ数 30 は確保できることを確認したため，本実験では  $\alpha = 0$  を採用した．

なお，ここでは，着目するコンテキストパラメータとして，最も大きい情報利得を持つコンテキストパラメータを 1 つ選定する方法を示した．情報利得に基づいて上位いくつかのコンテキストパラメータを選定することにより，より推薦時のコンテキストに限定した学習データを特定することが可能であるが，やはり確保できる学習データ数との兼合いが重要となる．後述する，5.5 節では，選定するコンテキストパラメータの数について考察を行っている．

#### (ii) 被験者の価値判断基準モデルの構築

3.2.3 項で述べた説明に従って，以下の手順により，当該コンテキストにおける被験者の価値判断基準モデルを構築する．

- (1) 特定された被験者の学習データセットに基づき，各アイテムパラメータ  $x_i$  の重要度を算出する．

図 15 アイテムパラメータ  $x_{13}$  軸上における正負学習データの分布 (コンテキスト  $C_1$  における被験者 A の場合)  
Fig. 15 A distribution map on an axis of item parameter  $x_{13}$  (in the case of user A at context  $C_1$ ).

- (2) 重要度の最も大きいアイテムパラメータ軸における，学習データの分布に基づいて，当該コンテキストにおける被験者の価値判断基準モデルを構築する．

被験者 A の特定された学習データセットに基づいた場合の各アイテムパラメータ  $x_i$  の重要度  $w_{xi}$  を求める．例として，アイテムパラメータ  $x_{13}$ ，すなわち [料金] パラメータ軸に着目したときの正負データの分布は，図 15 のようになった．図 15 は，横軸にアイテムパラメータ  $x_{13}$  の値，縦軸に学習データのクラスをとっている．

ここで，式 (6)，(7)，(8)，(9) で用いる各値は， $r = 0.14$  のとき，次のようになった．

$$n^+ = 17 \quad n^- = 43 \quad (14)$$

$$m_i^+ = 94 \quad m_i^- = 343 \quad m_i^* = 134 \quad (15)$$

これを，それぞれ式 (6)，(7)，(8)，(9) に代入すると，

$$w_{x_{13}} = 0.7044 \quad (16)$$

となる．なお，ここでは， $r$  を  $0 \leq r \leq 1$  に変えながら， $w_{x_{13}}$  を求めていった結果， $r = 0.14$  のときに  $w_{x_{13}}$  が最大となったため， $r = 0.14$  とした．

同様に，各アイテムパラメータ  $x_i$  の重要度  $w_{xi}$  および  $r$  は，表 5 のとおりとなった．この中で，アイテムパラメータ  $x_{13}$ ，すなわち [料金] パラメータの重要度が最も大きかったため，被験者 A の価値判断基準モデルは，この [料金] パラメータに基づいて構築される．

図 15 の正負データの分布に基づく，被験者 A の価値判断基準モデルは，図 16 のようになる (3.2.3 項 (ii) 参照)．図 16 は，横軸にアイテムパラメータ  $x_{13}$  の値，縦軸にその値に依存するランキングスコアをとっている．各棒グラフの上端に示している数値は，ランキングスコアを表す．

なお，ここでは，着目するアイテムパラメータとして，最も大きい重要度を持つアイテムパラメータを 1 つ選定する方法を示した．2 つ以上のアイテムパラメータを選定した場合には，各アイテムパラメータ軸上における学習データの分布を調べ，それぞれのアイテムパラ

74 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

表 5 各アイテムパラメータの重要度 (コンテキスト  $C_1$  における被験者 A の場合)

Table 5 Importance of each item parameter (in the case of user A at context  $C_1$ ).

アイテムパラメータ		$w_{x_i}$	$r$
$x_1$	ジャンル:和食	0.3471	0
$x_2$	ジャンル:洋食	0.4631	0
$x_3$	ジャンル:中華	0.4631	0
$x_4$	ジャンル:アジア・焼肉・エスニック・無国籍	0.5698	0
$x_5$	ジャンル:カフェ	0.1912	0
$x_6$	ジャンル:和風居酒屋	0.5698	0
$x_7$	ジャンル:洋風居酒屋	0.5233	0
$x_8$	ジャンル:アジア・無国籍居酒屋	0.5465	0
$x_9$	ジャンル:ダイニング・バー・ビアレストラン	0.5233	0
$x_{10}$	ジャンル:バー・パブ	0.5465	0
$x_{11}$	ジャンル:スペース・エンターテイメント	0.2794	0
$x_{12}$	ジャンル:ファミレス・ファーストフード	0.2794	0
$x_{13}$	料金	0.7044	0.14
$x_{14}$	距離	0.4690	0




図 16 アイテムパラメータ  $x_{13}$  に対するユーザの価値判断基準モデル (コンテキスト  $C_1$  における被験者 A の場合)

Fig. 16 A user's value model for item parameter  $x_{13}$  (in the case of user A at context  $C_1$ ).

メータに対する価値判断基準モデルを構築する。そして、ランキングスコアは各モデルに基づいた算出された総和により求められる。後述する 5.4 節では、選定するアイテムパラメー

タの数について考察を行っている。

(iii) 価値判断基準モデルに基づくランキング

最終的に、各評価用コンテキストパターンにおける価値判断基準モデルに基づき、対応するコンテキストパターンごとの評価用データセット内の各データに対しスコアを算出する。このスコアに基づいてランキングを行う。つまり、評価用データセット内の 40 個のデータに対し、提案方式により 1~40 位までのランク付けを行う。

被験者 A のコンテキスト  $C_1$  における評価用データセットを  $C_1$  における価値判断基準モデルに基づきランキングした結果は、図 17 (a) のようになる。なお、図 17 (b) に示すように、たとえば、データ No.5 の場合、重要アイテムパラメータである  $x_{13}$  の値が  $0 \leq x_{13} \leq 0.1$  の範囲にあるので、図 16 の  $0 \leq x_{13} \leq 0.1$  に対応するランキングスコアより、0.8358 が加算される。このランキングスコアを各データに対し算出し、高いものから上位にランク付けする。

これをコンテキストパターンの異なる 5 個の評価用データに対し行う。この結果を提案方式によるランキング結果とする。

(II) 機械学習手法による出力値に基づくランキング

機械学習手法では、入力データに基づいて何らかの値を出力し、その出力値に基づいて入力データの識別などを行う。そこで、単純には、この出力値の大きさや、目標値との近さなどに基づいて入力データに対するランキング処理を行うことができると考えられる。

SVM では、次式で表される判別関数に基づいて、入力データ  $x$  を正負クラスに分類する<sup>3)</sup>。

$$f(x) = \text{sgn}(g(x)) \tag{17}$$

$$g(x) = w^t x + b \tag{18}$$

ここで、 $w$  および  $b$  は、学習データセットに基づいて決定される。このとき、 $f(x) = +1$  となる  $x$  を正クラス、 $f(x) = -1$  となる  $x$  を負クラス、としてそれぞれ判別する。

$g(x)$  に着目すると、特徴空間上、 $g(x) = 0$  となる超平面が識別超平面を表す。この識別超平面を境界に、 $g(x) > 0$  となる  $x$  を正クラス、 $g(x) < 0$  となる  $x$  を負クラス、としてそれぞれ判別される。このとき、単純には、 $g(x) \gg 0$  のとき、特徴空間上で、 $x$  は識別超平面から、より遠くに位置するため、確信的に正クラスに属すると考えることができる。この考えに基づくと、 $g(x)$  の値に基づいたランキング<sup>5)</sup> が可能となる。

本実験では、学習データセットとして、提案方式で用いたものと同等のもの (5.2.1 項) を用いて学習を行う。ここで、提案方式と同様に、class が 5 段階のうち 3 以上のデータを

75 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

(a) 提案方式による評価用データセットに対するランキング (コンテキスト $C_1$ における被験者Aの場合)

no	class	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	score
5	5	0	0	0	0	1	0	0	0	0	0	0	0	0.063	0.2	0.8358
17	5	0	0	0	0	1	0	0	0	0	0	0	0	0.070	0.1	0.8358
24	5	0	0	0	0	1	0	0	0	0	0	0	0	0.055	0.1	0.8358
38	5	0	0	0	0	1	0	0	0	0	0	0	0	0.060	0.5	0.8358
18	4	0	0	0	0	0	0	0	0	0	0	0	1	0.050	0.1	0.8358
19	3	0	0	1	0	0	0	0	0	0	0	0	0	0.085	0.1	0.8358
2	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.0246
6	3	0	0	0	0	0	0	0	0	0	0	1	0	0.100	0.1	0.0246
13	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.0246
21	3	0	0	0	0	0	0	0	0	0	0	1	0	0.100	0.1	0.0246
26	3	1	0	0	0	0	0	0	0	0	0	0	0	0.100	0.1	0.0246
36	3	1	0	0	0	0	0	0	0	0	0	0	0	0.130	0.5	0.0246
40	2	0	0	0	0	0	1	0	0	0	0	0	0	0.150	0.3	0.0246
8	3	1	0	0	0	0	0	0	0	0	0	0	0	1.000	0.2	0.0000
29	1	1	0	0	0	0	0	0	0	0	0	0	0	0.600	0.5	-0.0465
9	1	0	1	0	0	0	0	0	0	0	0	0	0	0.400	0.5	-0.0698
23	1	0	1	0	0	0	0	0	0	0	0	0	0	0.480	0.1	-0.0698
33	1	0	0	1	0	0	0	0	0	0	0	0	0	0.440	0.1	-0.0698
1	1	0	0	1	0	0	0	0	0	0	0	0	0	0.300	0.5	-0.2093
3	1	0	0	1	0	0	0	0	0	0	0	0	0	0.360	0.2	-0.2093
7	1	0	0	0	0	0	0	0	0	1	0	0	0	0.300	0.3	-0.2093
10	1	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.5	-0.2093
11	1	0	1	0	0	0	0	0	0	0	0	0	0	0.300	0.5	-0.2093
14	1	0	0	0	0	0	1	0	0	0	0	0	0	0.320	0.2	-0.2093
15	1	0	0	0	1	0	0	0	0	0	0	0	0	0.350	0.1	-0.2093
20	1	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.6	-0.2093
22	1	0	0	1	0	0	0	0	0	0	0	0	0	0.300	0.5	-0.2093
25	1	0	0	0	0	0	0	0	0	1	0	0	0	0.300	0.1	-0.2093
27	1	0	0	0	1	0	0	0	0	0	0	0	0	0.350	0.2	-0.2093
28	1	0	0	0	0	0	1	0	0	0	0	0	0	0.380	0.3	-0.2093
30	1	0	0	0	0	0	0	0	1	0	0	0	0	0.300	0.5	-0.2093
31	1	0	0	0	0	0	0	0	0	1	0	0	0	0.300	0.3	-0.2093
34	1	0	0	0	0	0	0	0	0	0	1	0	0	0.350	0.5	-0.2093
39	1	1	0	0	0	0	0	0	0	0	0	0	0	0.350	0.1	-0.2093
4	1	0	0	0	0	0	1	0	0	0	0	0	0	0.250	0.4	-0.4419
12	1	0	0	0	0	0	0	0	0	0	1	0	0	0.250	0.3	-0.4419
16	1	0	0	0	0	0	0	0	1	0	0	0	0	0.250	0.1	-0.4419
32	1	0	1	0	0	0	0	0	0	0	0	0	0	0.250	0.3	-0.4419
35	1	0	0	0	0	0	0	0	1	0	0	0	0	0.250	0.1	-0.4419
37	1	0	0	1	0	0	0	0	0	0	0	0	0	0.280	0.2	-0.4419

(b) スコア算出の例 (データNo.5の場合)

no	class	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{14}$	score
5	5	0	0	0	0	1	0	0	0	0	0	0	0	0.063	0.2	0.8358

重要アイテム/パラメタである $x_{13}$ の値が0-0.1の間であるから、価値判断基準モデルより対応するスコア0.8358を加算。

図 17 提案方式による評価用データセットに対するランキング (被験者 A の場合)  
Fig. 17 A ranking for test data set (in the case of user A).

正データ, 2 以下のデータを負データとして扱う。そして, 同じく提案方式で用いたものと同等の, 5 個のコンテキストパターンにおける評価用データセット (5.2.2 項) に対して,

$g(x)$  に基づくランキングを行う。

なお, SVM の実装には, LIBSVM<sup>(24),(25)</sup> を用い, SVM の学習に必要なパラメータ  $C$  および  $\gamma$  は, grid-search<sup>(24)</sup> により学習データセットにとって最適な値を設定した。また, カーネルトリックとして, RBF カーネルを使用した。

(III) 多クラス分類手法に基づくランキング方式

入力データを多クラスに分類する多クラス分類手法がある。このクラスを, たとえば  $\{5, 4, 3, 2, 1\}$  のようなランクと見立てることにより, 多クラス分類手法に基づくランキングを行うことができる。

SVM は 2 クラス分類手法であるが, これを多クラス分類へと拡張したものが Multi-Class SVM<sup>(8),(9)</sup> である。

Multi-Class SVM では,  $k$  クラス分類問題を  $k$  段階の 2 クラス分類問題として扱っている。たとえば, 第  $n$  段階の分類問題は, クラス  $n$  とそれ以外の  $k-1$  個のクラスとの 2 クラス分類問題と見なすことができる。

本実験では, 被験者満足度として  $\{5, 4, 3, 2, 1\}$  の 5 クラスを用いている。このとき, 学習データセット内の各データのクラスを次のように定義する。

- 正クラス  $\{5\}$  vs. 負クラス  $\{4, 3, 2, 1\}$
- 正クラス  $\{4\}$  vs. 負クラス  $\{5, 3, 2, 1\}$
- 正クラス  $\{3\}$  vs. 負クラス  $\{5, 4, 2, 1\}$
- 正クラス  $\{2\}$  vs. 負クラス  $\{5, 4, 3, 1\}$
- 正クラス  $\{1\}$  vs. 負クラス  $\{5, 4, 3, 2\}$

上記の 2 クラスで定義された各学習データセットに基づいて学習モデルを構築する。そして, このモデルに基づき, 各評価用データセット内の各データを  $\{5, 4, 3, 2, 1\}$  の 5 クラスに分類する。この分類結果に基づき,  $\{5, 4, 3, 2, 1\}$  の順にランキングを行う。

なお, Multi-Class SVM においても, 学習データセットおよび評価用データセットは, 提案方式で用いたものと同等のものを用いる。また, SVM の実装は, (II) で示した設定と同様である。

5.2.4 フェーズ 4: ランキング結果に対する評価

以上の各手法によるランキング結果を比較することで, 提案手法の有効性を評価するのであるが, 評価尺度として, DCG (Discounted Cumulative Gain)<sup>(26)</sup> を用いる。DCG は, 多段階の適合性に適した評価尺度であり, 次式で定義される。

$$DCG(i) = \begin{cases} G(1) & \text{if } i = 1 \\ DCG(i-1) + \frac{G(i)}{\log_2 i} & \text{otherwise} \end{cases} \quad (19)$$

ここで、 $G(i)$  は、第  $i$  位にランク付けされたアイテムの適合性を示す。本実験では、被験者による満足度評価として、“5” と与えられたアイテムを“最適”，“4” と与えられたアイテムを“高適合”，“3” と与えられたアイテムを“適合”，それ以外を“不適合”とし、 $G(i)$  を次のように定義する。

$$G(i) = \begin{cases} 5 & \text{最適の場合} \\ 4 & \text{高適合の場合} \\ 3 & \text{適合の場合} \\ 0 & \text{不適合} \end{cases} \quad (20)$$

本実験では、ランキング結果の上位 5, 10, 15, 20 件に対し、DCG を算出する。この DCG の値が大きいほど有効なランキングであることを示す。

ランキング手法などの評価尺度には、アイテムの適合・不適合だけに基づいて算出される適合率が用いられることが多いが、以上のように多段階の適合性を考慮して定義される DCG を用いることで、被験者の満足の程度をより反映させた評価が行うことができる。

### 5.3 各ランキング方式との比較

図 18 は、各ランキング方式によるランキング結果から上位 5, 10, 15, 20 件に対する DCG を算出した結果を示している。いずれの件数においても、提案方式の方が既存のラン




図 18 ランキング手法の比較

Fig. 18 Comparison between ranking methods.

キング方式に対し、DCG が上回っていることが確認できた。

以下、まず比較対象の各ランキング方式が、提案方式よりも DCG が下回った根拠について考察する。特に、図 19 をふまえて、各方式により判定されたランキングがどれだけユーザの嗜好を反映できているか、という観点から考察を行う。図 19 は、被験者 A のコンテキストパターン  $C_1$  における評価用データセットに対し、各方式によるランキング結果を示している。それぞれ、データ No., 被験者 A が与えた満足度、各方式によるスコアを示している。

まず、図 19 (II) より、SVM の識別平面からの距離に基づく方法では、 $g(x)$  の符号により、データの正負クラスの判別はある程度行えているものの、 $g(x)$  の値が大きいほど、被験者満足度が高いという結果にはならなかった。この結果より、ユーザの嗜好に関しては、 $g(x)$  の符号により、満足か不満足かの判別は行えるが、 $g(x)$  の値そのものがユーザの嗜好の程度を表しているとはいえない。したがって、 $g(x)$  の値に基づいてランキングを行うことは適切ではないと考えられる。

つづいて、図 19 (III) より、Multi-Class SVM に基づく方法では、最上位クラス（この例ではクラス“4”）と判定されたデータは 6 個あったが、その中には被験者満足度“3”や“1”と評価されたデータも混在している。このように、Multi-Class SVM により判定された結果が、被験者が与えた満足度と一致していない。これは、学習データセット作成時に評価付けされた各データに対する満足度が、一貫した評価基準に基づいて付けられたものではないということが原因であると考えられる。たとえば、満足度“5”と評価付けされたデータは、他の“5”と評価付けされたどのデータとも、一貫して同等のものであることが保証されていない。しかし、実際にはユーザによる満足度評価は曖昧なものであり、あるコンテキストにおいて“5”と評価付けされたデータと、また別のコンテキストにおいて“5”と評価付けされたデータは、それぞれ違ったコンテキスト下における相対的な価値観に基づくものになる。このため、これらのデータが必ずしもユーザにとって同等のランクに属するとは限らない。このようにコンテキストが異なる場合に、ユーザの価値判断基準も変わってしまう場合、多段階に分割されたユーザ満足度を、そのままランキングのためのクラスとして扱うことは適切でないと考えられる。このことは、Multi-Class SVM に限ったことではなく、一般に多クラス分類手法を用いた場合にもいえることであると考えられる。

以上に対し、図 19 (I) より、提案方式では、算出されたランキングスコアと被験者満足度とがほぼ一致していることが分かる。提案方式では、まず推薦時のコンテキストにより限定された学習データを特定したうえで、さらにユーザが重要視するアイテムパラメータ軸

(I) 提案方式による ランキング			(II) SVMの識別平面 に基づくランキング			(III) Multi-Class SVM に基づくランキング		
no	被験者 満足度	提案方式 によるスコア	no	被験者 満足度	$g(x)$	no	被験者 満足度	Multi-Class SVMにより 判定されたクラス
38	5	0.8358	38	5	3.050	17	5	4
24	5	0.8358	36	3	2.792	24	5	4
17	5	0.8358	37	1	2.333	13	3	4
5	5	0.8358	32	1	2.259	19	3	4
18	4	0.8358	26	3	1.702	32	1	4
19	3	0.8358	24	5	1.687	37	1	4
36	3	0.0246	20	1	1.215	5	5	3
26	3	0.0246	18	4	1.138	6	3	3
21	3	0.0246	21	3	0.984	8	3	3
13	3	0.0246	19	3	0.965	21	3	3
6	3	0.0246	17	5	0.949	26	3	3
2	3	0.0246	13	3	0.870	4	1	3
40	2	0.0246	10	1	0.650	10	1	3
8	3	0.0000	8	3	0.250	20	1	3
29	1	-0.0465	6	3	0.130	18	4	2
9	1	-0.0698	4	1	0.065	38	5	1
23	1	-0.0698	2	3	0.000	2	3	1
33	1	-0.0698	9	1	-0.580	36	3	1
20	1	-0.2093	11	1	-0.790	40	2	1
10	1	-0.2093	7	1	-0.850	1	1	1
11	1	-0.2093	12	1	-0.875	3	1	1
7	1	-0.2093	15	1	-0.915	7	1	1
15	1	-0.2093	5	5	-0.929	9	1	1
3	1	-0.2093	3	1	-0.992	11	1	1
14	1	-0.2093	14	1	-1.015	12	1	1
25	1	-0.2093	23	1	-1.042	14	1	1
1	1	-0.2093	16	1	-1.115	15	1	1
27	1	-0.2093	25	1	-1.196	16	1	1
22	1	-0.2093	1	1	-1.200	22	1	1
28	1	-0.2093	27	1	-1.321	23	1	1
31	1	-0.2093	22	1	-1.620	25	1	1
30	1	-0.2093	29	1	-1.631	27	1	1
39	1	-0.2093	28	1	-1.770	28	1	1
34	1	-0.2093	31	1	-1.961	29	1	1
37	1	-0.4419	30	1	-2.034	30	1	1
32	1	-0.4419	33	1	-2.123	31	1	1
4	1	-0.4419	35	1	-2.243	33	1	1
12	1	-0.4419	39	1	-2.451	34	1	1
16	1	-0.4419	34	1	-2.497	35	1	1
35	1	-0.4419	40	2	-3.209	39	1	1




図 20 アイテムパラメータ選定によるランキング結果に対する DCG の値の違い  
Fig. 20 DCG for ranked items by item parameters selection.

に着目したときに、その軸上での満足データおよび不満足データの分布に基づいて、厳密にランキングスコアを算出している。このため、推薦時のコンテキストにおけるユーザの価値判断基準をより忠実に反映したランキングを提供することが可能である。結果として、本実験において提案方式が優位性を示したといえる。

#### 5.4 ユーザの価値判断基準モデル構築の対象とするアイテムパラメータ選定に関する考察

3.2.3 項で述べたように、ユーザの価値判断基準モデル構築の対象とするアイテムパラメータは、ユーザのアイテムパラメータに対する重要度に基づいて選定される。本実験では、重要度の高い順にアイテムパラメータを選定し、このパラメータを対象に価値判断基準モデルを構築したとき、アイテムパラメータの選び方により、ランキング結果に対する DCG の値がどのように変化するか検証する。

図 20 は、アイテムパラメータ選定によるランキング結果に対する DCG の値の違いを示したものである。ここでは、アイテムパラメータに対する重要度に基づき、以下のそれぞれのアイテムパラメータに着目し、被験者の価値判断基準モデルを構築したときのランキング結果に対する DCG を算出している。

- (1) 第 1 位のアイテムパラメータ
- (2) 第 2 位のアイテムパラメータ
- (3) 第 3 位のアイテムパラメータ

この結果から、いずれの件数においても、第 1 位のアイテムパラメータに着目したときが、最も高い DCG を示していることが確認できる。つづいて、第 2 位のアイテムパラメータに着目したときも高い DCG を示している。この結果は、重要度が高いアイテムパラメータ

図 19 各方式による評価用データセットに対するランキング (コンテキスト  $C_1$  における被験者 A の場合)  
Fig. 19 A ranking for test data set by each ranking method (in the case of user A at context  $C_1$ ).



夕ほど、被験者の価値判断基準モデルが適切に構築されていることを示す。したがって、この結果から本論文で定義した重要度の算出方法は妥当であったといえる。

一方で、第3位のアイテムパラメータに着目したときには、第1,2位のとときと比べ、DCGの値が極端に小さくなっている。これは、今回の実験では被験者が飲食店を評価するにあたり、第3位のアイテムパラメータに関しては、ほとんど注目していなかったことが原因であると考えられる。実験結果を詳細に見ると、第3位のアイテムパラメータは、ほとんどの被験者において「距離」パラメータであった。実際に、被験者に対するヒアリング調査結果からも、「距離」パラメータに関しては、ほとんど注目していなかった」という回答が多かった。この結果からも、被験者が注目していないようなアイテムパラメータが下位に判定されたことから、重要度の算出方法の妥当性が確認できる。

以上のように、ユーザがほとんど注目していないようなアイテムパラメータを対象に価値判断基準モデルを構築することはかえってノイズになることが考えられるため、モデル構築の対象からは除外することが望ましいと考えられる。このような観点から、モデル構築を行った際、DCGスコアを低下させるようなアイテムパラメータを除外することで、ランキング結果に対するユーザ満足度をより向上させることができると考えられる。

#### 5.5 ユーザの価値判断基準に影響を及ぼすコンテキストパラメータ選定に関する考察

3.2.2 項で述べたように、ユーザコンテキストに関連する学習データの特定にあたり、着目するコンテキストパラメータは、コンテキストパラメータのユーザの価値判断基準への影響度に基づいて選定される。本実験では、この影響度の高い順にコンテキストパラメータを選定し、このパラメータに基づいて、学習データの特定を行ったとき、コンテキストパラメータの選び方により、ランキング結果に対するDCGの値がどのように変化するか検証する。

図21は、コンテキストパラメータ選定によるランキング結果に対するDCGの値の違いを示したものである。ここでは、コンテキストパラメータのユーザの価値判断基準への影響度に基づき、以下のそれぞれのコンテキストパラメータに着目し、被験者の価値判断基準モデルを構築したときのランキング結果に対するDCGを算出している。

- (1) コンテキストパラメータに着目しない
- (2) 第1位のコンテキストパラメータ
- (3) 第1,2位のコンテキストパラメータ
- (4) 第1,2,3位のコンテキストパラメータ

ここで、コンテキストパラメータに着目しない場合は、被験者の全学習データに基づいて




図 21 コンテキストパラメータ選定によるランキング結果に対する DCG の値の違い  
Fig. 21 DCG for ranked items by context paramters selection.

価値判断基準モデルが構築される。この場合、コンテキストパラメータに着目した場合に比べ、ランキング結果に対する DCG の値が小さくなっている。この結果は、コンテキスト依存のランキングを行うためには、ユーザコンテキストに関連する学習データを特定したうえで、価値判断基準モデルを構築することが重要であるということを示している。

全体的に見ると、第1位のコンテキストパラメータに着目したときに比べ、第1,2位、第1~3位と、DCGが減少傾向にある。これは、着目するコンテキストパラメータの数が増えることにともない、そのコンテキストパラメータに関連する学習データ数が減少してしまうため、適切な価値判断基準モデルが作成できていないことが原因であると考えられる。

したがって、各コンテキストパラメータの影響度を考慮し、DCGスコアが低下しない範囲において、複数のコンテキストパラメータ群を考慮したランキングを行うことが可能となる。これにより、ユーザにとって満足度の高い多様なアイテムの提示が可能になるといえる。

## 6. おわりに

本論文では、ユーザの価値判断基準モデルを定義したうえで、このモデルに基づいたコンテキスト依存型ランキング手法を提案した。

本手法の流れは次のとおりである。

- (1) 学習データからのユーザコンテキストに依存する価値判断基準モデルの構築
- (2) 価値判断基準モデルに基づく推薦候補アイテム集合に対するランキング

本研究では、また提案手法の有効性を評価するために、飲食店情報推薦を対象とした被験者実験を行った。本実験により得られた成果と知見を以下に示す。

- 提案手法では、ユーザコンテキストに応じて変化するユーザの価値判断基準を適切にモ

デル化することにより、ユーザの直面しているコンテキストにおいてふさわしいランキング結果を提供することができる。

- ユーザのアイテムパラメータに対する重要度に基づいて、ユーザが重要視しているアイテムパラメータを適切に選定することにより、ランキング結果に対するユーザ満足度をより向上させることができる。
- コンテキストパラメータのユーザ嗜好に対する影響度に基づいて、影響の大きいコンテキストパラメータのみに着目し学習データを特定することにより、ユーザの直面しているコンテキストにおいて、よりふさわしいランキング結果を提供することができる。

今後、重要度および影響度に関する検討を進めていくことにより、提案手法によるランキングに対するユーザ満足度を向上させる余地があると考えている。

謝辞 本研究の一部は、科研費補助金特定領域研究「情報爆発時代に向けた新しいIT基盤技術の研究」(A01-34, 課題番号 19024058), および科研費補助金若手研究(B)(課題番号: 20700089)による。ここに記して謝意を表します。

#### 参 考 文 献

- 1) Oku, K., Nakajima, S., Miyazaki, J. and Uemura, S.: Investigation for Designing of Context-Aware Recommendation System Using SVM, *The 2007 IAENG International Conference on Internet Computing and Web Services (IMECS2007)*, pp.970-975 (2007).
- 2) 奥 健太, 中島伸介, 宮崎 純, 植村俊亮: 状況依存型ユーザ嗜好モデリングに基づく Context-Aware 情報推薦システム, 情報処理学会論文誌: データベース, Vol.48, No.SIG11(TOD34), pp.162-176 (2007).
- 3) Cortes, C. and Vapnik, V.: Support-Vector Networks, *Machine Learning*, Vol.20, No.3, pp.273-297 (1995).
- 4) Hirao, T., Isozaki, H., Maeda, E. and Matsumoto, Y.: Extracting Important Sentences with Support Vector Machines, *Proc. 19th Int. Conf. on Computational Linguistics*, pp.342-348 (2002).
- 5) 平尾 努, 磯崎秀樹, 前田英作, 松本裕治: Support Vector Machine を用いた重要文抽出法, 情報処理学会論文誌, Vol.44, No.8, pp.2230-2243 (2003).
- 6) 賀沢秀人, 平尾 努, 前田英作: Order SVM: 一般化順序統計量に基づく順位付け関数の推定, 電子情報通信学会論文誌 D-II, Vol.J86-D-II, No.7, pp.926-933 (2003).
- 7) 柳本豪一, 大松 繁: カーネル法を用いた関連フィードバックによる興味抽出, 電気学会論文誌 C (電子・情報・システム部門誌), Vol.126, No.3, pp.395-400 (2006).
- 8) Weston, J. and Watkins, C.: Multi-class support vector machines, Technical report csd-tr-98-04, Royal Holloway, University of London, Surrey, England (1998).
- 9) Weston, J. and Watkins, C.: Support vector machines for multi-class pattern recognition, *Proc. 7th European Symposium on Artificial Neural Networks (ESANN-99)*, Verleysen, M. (Ed.), Bruges, Belgium, pp.219-224 (1999).
- 10) Herbrich, R., Graepel, T., Bollmann-Sdorra, P. and Obermayer, K.: Learning a preference relation for information retrieval, *Proc. AAAI Workshop Text Categorization and Machine Learning* (1998).
- 11) Herbrich, R., Graepel, T. and Obermayer, K.: Large Margin Rank Boundaries for Ordinal Regression, *Advances in Large Margin Classifiers*, pp.115-132 (2000).
- 12) Qin, T., Liu, T.Y., Lai, W., Zhang, X.D., Wang, D.S. and Li, H.: Ranking with Multiple Hyperplanes, *Proc. 30th Annual International ACM SIGIR Conference* (2007).
- 13) 北 研二, 津田和彦, 獅々堀正幹: 情報検索アルゴリズム, 共立出版 (2001).
- 14) Rocchio, J.J.: Relevance feedback in information retrieval, *The SMART Retrieval System: Experiments in Automatic Document Processing*, Salton, G. (Ed.), pp.313-323, Prentice Hall (1971).
- 15) Salton, G., Wong, A. and Yang, C.S.: A vector space model for automatic indexing, *Comm. ACM*, Vol.18, No.11, pp.613-620 (1975).
- 16) Mitchell, T.M.: *Machine Learning*, McGraw Hill (1997).
- 17) Sahami, M., Dumais, S., Heckerman, D. and Horvitz, E.: A Bayesian Approach to Filtering Junk E-Mail, *AAAI-98 Workshop on Learning for Text Categorization* (1998).
- 18) Joachims, T.: Text categorization with support vector machines: Learning with many relevant features, *Proc. Europia Conf. Machine Learning (ECML)*, pp.137-42 (1998).
- 19) Quinlan, J.R.: *C4.5: Programs for Machine Learning*, The Morgan Kaufmann Series In Machine Learning (May 1993).
- 20) 大津展之: パターン認識における特徴抽出に関する数理的研究, 電子技術総合研究所研究報告, Vol.818 (1981).
- 21) 『グルメ情報検索サイトぐるなび』. <http://www.gnavi.co.jp/> (2008-03-20 確認)
- 22) 『ぐるなび Web サービス』. <http://api.gnavi.co.jp/api/service.htm> (2008-03-20 確認)
- 23) 小野田崇: サポートベクターマシンその仕組みと応用—分類手法の新展開, オペレーションズ・リサーチ学会誌 2001 年 5 月号, Vol.46, No.5, pp.224 (2001).
- 24) Chang, C.C. and Lin, C.J.: *LIBSVM: a Library for Support Vector Machines* (2006).
- 25) LIBSVM. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/> (2008-3-20 確認)
- 26) Järelin, K. and Kekäläinen, J.: IR evaluation methods for retrieving highly relevant documents, *Proc. 23rd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.41-48 (2000).

(平成 20 年 9 月 20 日受付)

(平成 21 年 1 月 9 日採録)

(担当編集委員 井上 潮)



奥 健太 (学生会員)

1981 年生。2004 年大阪市立大学工学部土木工学科卒業。2006 年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。同年同大学院同研究科博士後期課程入学，現在に至る。日本データベース学会，電子情報通信学会，ACM 各学生会員。



中島 伸介 (正会員)

京都産業大学コンピュータ理工学部准教授。博士 (情報学)。1997 年神戸大学大学院自然科学研究科博士前期課程修了。2004 年京都大学大学院情報学研究科博士後期課程修了。奈良先端科学技術大学院大学助教を経て，2008 年より現職。主に Web マイニングおよびマルチメディアコンテンツ検索の研究に従事。日本データベース学会，IEEE CS 各会員。



宮崎 純 (正会員)

奈良先端科学技術大学院大学情報科学研究科准教授。博士 (情報科学)。1992 年東京工業大学工学部情報工学科卒業。1997 年北陸先端科学技術大学院大学情報科学研究科博士後期課程修了。同大学助手を経て，2003 年より現職。2000～2001 年テキサス大学アーリントン校客員研究員。2003～2007 年科学技術振興機構さきがけ研究員。高性能・高機能データベースならびに情報検索の研究に従事。電子情報通信学会，日本データベース学会，ACM，IEEE CS 各会員。



植村 俊亮 (フェロー)

奈良産業大学情報学部情報学科教授。工学博士。1966 年京都大学大学院工学研究科修士課程修了。同年電気試験所 (現，産業技術総合研究所)。マサチューセッツ工科大学電子システム研究所客員研究員，東京農工大学教授，奈良先端科学技術大学院大学教授を経て，2007 年より現職。データ工学，データベースシステムの研究に従事。情報処理学会フェロー，電子情報通信学会フェロー，IEEE Fellow。



加藤 博一 (正会員)

奈良先端科学技術大学院大学情報科学研究科教授。博士 (工学)。1986 年大阪大学基礎工学部制御工学科卒業。1988 年同大学院修士課程修了。1989 年同大学基礎工学部助手。1996 年講師。1998 年ワシントン大学客員研究員。1999 年広島市立大学情報科学部助教授。2003 年大阪大学大学院基礎工学研究科助教授を経て，2007 年より現職。拡張現実感，ヒューマンインタフェースの研究に従事。ヒューマンインタフェース学会，日本 VR 学会，ACM 等各会員。