

# 特集記事 ヒューマンインタフェースのための人工知能技術特集 推薦システムにおけるインタラクション研究 へのいざない 大阪大学 土方 嘉徳

## 1. はじめに

本特集号の企画は、人工知能技術とヒューマンインタフェースとの関係について、様々な観点から紹介するものである。本稿では、知的システムとしては多くのユーザになじみ深い推薦システムを取り扱う。推薦システムでユーザに提供するものは、システムが知的処理を行った結果である推薦リストである。ユーザがシステムとの深いインタラクションを感じるには、あまりに簡素な結果と言える。しかし、推薦システムとユーザとのインタラクションは、当該ユーザがいったい何に興味を持っているのか、どういう嗜好をしているのかという、人間の深層心理に迫るものである。本稿では、システムがどのようにユーザの興味や嗜好を知覚するのか、その情報を基にどのように推薦するアイテム（推薦対象である情報や商品）を決定するのかについて説明し、そこにおけるインタラクションの役割や期待について述べる。

## 2. 推薦システムとのインタラクションの基本

現在多くのショッピングサイトで、推薦サービス（レコメンデーション）が行われている。代表的なショッピングサイトである amazon.com では、現在の閲覧商品や過去の購買履歴、明示的に入力したレーティング値（ユーザがアイテムに付与した評価値）に応じて、あの手この手で商品推薦を行ってくれる。例えば、「この商品を買った人はこの商品も買っています」や「新しく発売された商品」、「本の推薦」というような形式である。基本的には、推薦結果は図1のようなリストで表される。このように最終的にユーザに提示される表示形式は簡素であるが、このような推薦




図2 推薦システムにおけるユーザからの入力

を行うためには、当該ユーザから興味や嗜好に関する情報を収集し、また他のユーザからも同様の情報を集め、大量の行動データと商品に関する特徴データから高度な学習を行わなければならない。

ユーザは自分の興味や嗜好について明確に認識していることはまれである。自分の興味や嗜好については指摘されればそうかと思うが、自ら能動的にルール化したり、興味対象の特徴を列挙したりすることは困難である。そのため、多くの推薦システムでは、ユーザに事例を提示し、ユーザのその事例に対する反応を見ることで、興味や嗜好に関する情報を収集する（これは1980年代に広く商用化されたエキスパートシステムでの専門知識の獲得においても見られる）。そして、事例からの学習（これは一般に帰納学習と呼ばれる）により、ユーザの興味や嗜好に関するモデルを獲得する。この流れは図2ようになる。3章では、モデルの獲得方法の詳細について述べる。なお、以降では推薦対象の商品やコンテンツをアイテムと呼ぶ。

## 3. 推薦システムで用いられる人工知能技術

推薦システムで用いられる人工知能技術は、前述したとおり帰納学習と呼ばれるものである。これは多数の事例からその事例を一般化した法則やモデルを発見するものである。伝統的な帰納学習には、相関ルールや決定木などがある（詳細は、人工知能やデータマイニングに関する教科書を参考にされたい）。実際の推薦システムにもこれらのアルゴリズムが用いられることはあるが、本稿では最もよく用いられる2種類の方式について紹介する。推薦システムを実現するアプローチには、コンテンツに基づくフィルタリングと、協調フィルタリングがあるが、これらを実現する最も基本的なアルゴリズムについて紹介する。

### 3.1 コンテンツに基づくフィルタリング

コンテンツに基づくフィルタリングでは、当該ユーザの興味や嗜好に関する情報と、推薦対象のアイテム群の特徴に関する情報の2種類を用いて推薦を行う。処理の流れを図



図1 推薦システムからの推薦提示例 (amazon.com の場合)

3に示す。この方式では、システムはアイテムから特徴を抽出する必要がある。推薦対象のアイテムが新聞記事やブログ記事のようにテキストで書かれていれば、特徴の抽出は比較的容易である。しかし、音楽や映画のように特徴を抽出するのが容易ではないもの、また美術品や日用品のように、デジタルデータが付与されていないものについては、あらかじめ人手で特徴量を付与しておく場合もある。その後、これらの特徴量とユーザがそれらのアイテムに付与した評価値（暗黙的に閲覧履歴や購買履歴から得られることもある）を用いて、ユーザの興味や嗜好をモデル化したユーザプロフィールを構築する。この構築に帰納学習を用いる。推薦時には、アイテムから抽出した特徴量を用いて作成したコンテンツモデル（一般には特徴量を属性とその値で表現したもの）と、上記ユーザプロフィールを比較し、ユーザの興味や嗜好に適合すると判断されたものを推薦する。

ユーザプロフィールの構築には、(1) ルールベース方式 (rule-based method)、(2) メモリベース方式 (memory-based method)、(3) モデルベース方式 (model-based method) の3つがある。このうち、モデルベース方式は、事例（アイテムに対する評価値）から一般的な興味傾向をモデル化し、ユーザプロフィールとする方式である。ここには、伝統的な帰納学習である相関ルールや決定木、ニューラルネットワークなどのアルゴリズムが適用可能である。ルールベース方式は、ドメインにおける常識やあらかじめ得られた知見、ビジネスルールなどにに基づき、人手でフィルタリングのルールを設計しておくものである。これは帰納的推論を人間が行い、その結果を人手で入力したものを利用していると言える。

メモリベース方式は、コンテンツモデルとユーザプロフィールの両方をベクトルで表し、ベクトル空間上での距離により、推薦するか否かを決定する。厳密な意味でメモリベース方式を実現するアルゴリズムは、k-nearest neighbor法 (k-NN法) である。これは事例をそのままメモリ上に保存しておき、推薦対象のアイテムが入力されれば、そのベクトルとメモリ上の上記事例のベクトルを比較し、類似するアイテムに付与された好き・嫌いのクラスから推薦するかどうかを判定する。ユーザが次々とアイテムを閲覧したり評価したりしても、ユーザプロフィールの更新が容易であるのが利点である。しかし、リアルタイムでの実行速度に難があるため、適合性フィードバックという手法により一般的なベクトルを計算することが多い。

適合性フィードバックを用いたユーザプロフィールの更新は、Rocchioの式が用いられることが多い。

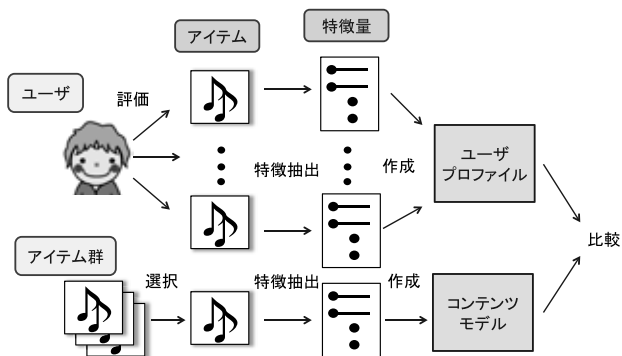


図3 コンテンツに基づくフィルタリングにおける処理の概要




図4 協調フィルタリングにおける処理の概要

$$\hat{p} = \alpha \mathbf{p} + \frac{\beta}{|D_R|} \sum_{d_i \in D_R} d_i - \frac{\gamma}{|D_N|} \sum_{d_i \in D_N} d_i$$

ここで、 $\mathbf{p}$  はユーザのユーザプロフィール、 $D_R$  と  $D_N$  は、それぞれユーザが閲覧したアイテムのうち興味があるとしたアイテム集合、興味がないとしたアイテム集合、 $\mathbf{d}$  は当該アイテムの特徴ベクトルである。

### 3.2 協調フィルタリング

協調フィルタリングでは、推薦対象のアイテム群の特徴に関する情報を必要としない。代わりに、当該ユーザだけでなく他のユーザの興味や嗜好に関する情報を獲得しておく必要がある。協調フィルタリングでは、ユーザ  $u$  がアイテム  $i$  に付与した評価値を、ユーザ×アイテムの行列により保管しておく（図4参照）。このように行列で表現すれば、その行を取り出せば、ユーザの特徴を表すベクトルとみなすことができる。逆に列を取り出せば、アイテムの特徴を表すベクトルとみなすことができる。ユーザに注目するとすれば、当該ユーザの行と似たような行を探せば、興味や嗜好の近いユーザを発見することができる。その発見したユーザが高く評価したアイテムで、自分がまだ評価していないものを推薦すれば、ユーザにとって価値のある推薦になる可能性が高い。

ユーザ集合を、 $A = \{a_1, a_2, \dots, a_n\}$ 、アイテム集合を  $B = \{b_1, b_2, \dots, b_m\}$  とし、ユーザ  $a_i$  がアイテム  $b_k$  につけた評価値を  $r_i(b_k)$  とすると、予測評価値  $p_i(b_k)$  は下のように定式化することができる。

$$p_i(b_k) = \bar{r}_i + \frac{\sum_{a_o \in \hat{A}_i} s(a_i, a_o) \cdot (r_o(b_k) - \bar{r}_o)}{\sum_{a_o \in \hat{A}_i} |s(a_i, a_o)|}$$

ここで、 $s(a_i, a_o)$  は、ユーザ  $a_i$  と  $a_o$  間の類似度である。 $\hat{A}_i$  はユーザ  $a_i$  の類似ユーザ集合である。 $\bar{r}$  は平均を表す。

## 4. 推薦システムとのインタラクション

推薦システムの研究において、ヒューマンファクタの観点からの研究のポイントについて述べる。具体的には、ユーザからの入力、ユーザへの出力、そして意外なアイテムの提示について述べる。

### 4.1 推薦システムへの入力

2章で述べたように推薦システムへの入力は、ユーザの事例への反応となる。推薦システムに限らず、知的システムにおいては、ユーザがそのシステムを利用始める前に、多くの入力が必要とすることは好ましくないと見られてきた。そのため、推薦システムの研究分野では、ユーザから明示的に興味や嗜好に関する情報を引き出すのではなく、暗黙的

に推定する試みが多くなされてきた。例えば、閲覧した商品に興味のある商品とみなしたり、訪れた Web ページのテキストから自動で興味のあるキーワードを抽出したりするような方法である。また、ページの遷移間隔を見れば、どのくらいそのページを閲覧していたかを予測することもできる。

このような情報は、Cookie を用いればサーバ側で取得できるが、Web ページ表示後にユーザが実際に何をしていたのかは（もしかすると、ページ表示後違う作業をしているかもしれない）分からない。そこで、クライアント側に特殊なソフトやプラグインを導入することにより、より詳細な行動を検出しようとした試みもある。例えば、マウスの挙動を検出するソフトを導入したり、視線計測の装置を備えたりするような試みである。このようなユーザ行動からユーザの興味を得るには、高度な推定技術が必要となる。

また、ユーザに明示的にアイテムに評価付けさせる場合でも、どのようなアンケート形式で尋ねるとより効率的かを、人間科学の観点から調査する研究もなされている。例えば、評価付けするアイテムの選択をユーザ任せにするかどうかや、評価付けするアイテム数、評価付けのスケールはどのくらいにすれば良いかなどを、ユーザ満足度の観点も含めて調べられている。

#### 4.2 推薦システムからの出力

推薦システムからの出力は、順位付きの推薦リストとなる。基本的には、ユーザがそのアイテムを好むであろう確率順に提示する。最も基本的な問題には、そのリストの長さをどれくらいにするかというものがある。推薦リストが長くなると、たくさん推薦結果を見ることができ、ユーザにとっては良いように思われる。しかし、多くの候補から一つを選択する労力が増加する。結果的に良いアイテムが選択できたとしても、その選択の意思決定に多くの労力がかかれば、推薦過程への満足度は低下するかもしれない。

また、推薦リストからユーザが分かることは、システムが何らかの観点から、何らかの方法で自分が好むであろうアイテムを、そのスコア順に提示しているということだけである。しかし、その観点や方法については知る方法がない。そのため、なぜそのアイテムが自分に推薦されたのか、その結果を信じてよいものか、ユーザは悩むことがある。そこで、推薦結果に対して説明付けを行う研究がある。この研究では、推薦されたアイテムに対して、それが推薦された様々な理由を提示している。その一つには、自分に近い好みのユーザのうち、そのアイテムを高く評価しているユーザがどれくらいいるのかを提示したものがある（図5参照）。推薦アルゴリズムには、協調フィルタリングを用いているが、このような内訳を教えてくれるだけでも、なぜそのアイテムが推薦されたのかと、それをどの程度信頼しても良いかを知ることができる。

#### 4.3 意外なアイテムの提示

情報検索がユーザの能動的な行為を支援するのに対し、情報推薦はユーザの受動的な行動を支援すると言われることがある。これはユーザがその場で明示的に入力したクエリに基づいた結果を返すのか、それとも長い時間をかけて獲得した長期的な興味や嗜好に基づいた結果を返すのかによると言える。情報検索では、ユーザが入力したクエリに適合する情報を返すことができているのかが重要となる。

Your neighbors rating for this movie

Rating	Number of neighbors
☆	1
☆☆	2
☆☆☆	7
☆☆☆☆	14
☆☆☆☆☆	9

図5 推薦結果の説明付け

すなわち最も重要な評価指標は推薦の正確性となる。一方、情報推薦では推薦結果が自分の興味や嗜好に合っているということは必要条件となるが、それがすぐにユーザの満足度につながるわけではない。

ユーザが検索エンジンで調べ物をするときは、ユーザが調べる対象についてあまり詳しくないことが想定される。そのため、ユーザの入力に適合した Web ページを返すことは、ユーザの興味に適合していて、なおかつユーザにとって知らない可能性の高い情報を返すことができる。一方、情報推薦は、過去の事例に対する反応から長期的に獲得した興味モデルに基づいて推薦が行われる。そのため、比較的ユーザがよく知っているカテゴリやドメインのアイテムが推薦結果に多く含まれるようになる（図1の例でも同じシリーズのアイテムばかりが推薦されている）。しかし、すでに知っているアイテムを推薦されたとしても、それはすでに持っているか、買わないと決めている可能性が高い。そのため、正確性に基づく評価だけでは不十分な場合がある。

ここ近年の推薦システム研究のトレンドは、この正確性以外の評価値を向上させることにある。例えば、アイテムの属するジャンルやカテゴリを多様にして推薦リストを構成する方法を提案していたり、ユーザがアイテムを知らない可能性を計算し、それとユーザがアイテムを好む可能性と結合させる方法を提案したりしている。前者の研究は、アイテムやすでに作成した推薦リストに対して、カテゴリやジャンルを要素とするベクトルを割り当て、その距離により多様性を計算している。後者の研究では、アイテムに対する既知／不既知に関する情報を獲得し、それを行列で保管することにより、協調フィルタリングのアルゴリズムを適用できるようにしている。いずれの方法も正確性に多少の犠牲を払ってでも、高いユーザ満足度を獲得しようとしている。

#### 5. ヒューマンファクターから見た推薦システムの魅力

最後にこれまで見てきた推薦システムにおけるヒューマンファクターに関する研究事例から、逆にヒューマンインタフェース研究者から見た時に、推薦システムの研究の魅力について述べる。

まず最初に述べておくと、システムの見え方や操作法で言うと、推薦システムの研究は極めて地味である。なぜかと言うと、システムに対する入力もシステムからの出力も、極めて制約を受けるからである。入力に実世界のデバイスを使う訳ではないし、実体を持つロボットに出力させるわけでもない（推薦サービスを受ける状況によってはこれら

の利用もあり得るが必須ではない)。基本は、入力事例に対する反応であり、出力は確率に基づいたアイテムのリストである。推薦システムを実現するには、人工知能の技術により興味や嗜好の推定を行わないといけないが、自動推定をさせるには、その入力形式はアルゴリズムに合わせざるを得ない。革新的なインタラクションを好む研究者にとっては、この制約はどうしようもない障害となる。

しかし、このような制約は、一つ一つの研究の価値を高める側面もある。例えば、あなたが推薦システムの説明付けに関する研究をしていたとする。そして、説明付けにはどんなアイテムへの評価が引き金になったかを示すことが有効だと分かったとする。その結果を論文にして発表したとしよう。ほとんどすべての商用推薦システムで、結果をリストで出力している現状を考えると、しばらく経てば、どんな推薦サービスを受けても、推薦リストに引き金になったアイテムが表示されるであろう(実際にamazon.com(図1参照)では、推薦の元になったアイテムが提示されている)。すなわち一つの発見が普及する範囲と言うのは、自由度の高いシステムよりも広くなるのである。このような分野で特許を抑えられると、どこの企業もそれを回避することができなくなってしまう。

また、このような制約は、英語を不得意とする研究者にとっても、トップカンファレンスに通すことが容易になる。すなわちその制約下で設定できる問題はすでに共有されており、その重要性も互いに認識し合っている。そのため、新しい概念の価値や前提となる思想について語る必要がないため、英語を得意としない研究者にとっても論文を通すことが容易になる。また、わずかな向上であっても、その波及効果について共通の認識があるため、研究としての価値を高く見てくれる傾向もある。これは革新性を重視するタイプのヒューマンインタフェース研究とは異なる点である。

また、入出力に制約はあるが、推薦システムが扱う対象である人間の知や文化に対する欲求というものは、非常に深淵なものがある。これは情報検索の知的欲求に比べるとはるかに複雑となる。人間が得た情報や商品に対して満足するのは、その人の欲求やニーズを満たしているかどうかは当然であるが、それ以上に発見を伴うものであったか、驚きを伴うものであったか、友達に伝えたいと思うものであったかなど、それ以外の要素も大きく絡んでくる。分かりやすい例えで言うと、日本のレストランではメニューには写真が載っていて、それとほぼ同一のものが出てくるが、ヨーロッパのレストランではメニューは短い文で書かれており、店員に聞いてもあまり具体的には答えてくれない。これは提供した時の驚きを重視しているからであろう。そのような限られた入出力の中で、いかにこれらの複雑な条件を取り込み解決していくかという点が面白いところである。

最後に、推薦システムはその入出力に制約があり、基本的な推薦アルゴリズムもすでに決まってはいるが、その利用範囲には無限の可能性がある。従来は単独での利用を考えていたが、グループでの利用も考えられる。それにはグループとしての利得を最大化する必要がある。また従来は自宅でPC環境で利用することを考えていたが、外で携帯端末から利用することを考える必要がある。外での利用であれば、移動に伴うコストも考える必要があるだろう。また従来はニュース記事や本、CDなどの推薦を考えてきたが、近年人気のソーシャルメディアでは人を推薦することもあるだろ

う。友人としてつながりたいかどうかは、共有する興味だけでなく、組織、年齢、性別なども影響してくるであろう。拡大する利用範囲を考えると、考えないといけない制約、コンテキスト、評価関数は、その数だけ存在する。すなわち、IT環境が変わるだけ、問題も生まれてくると言える。

## 6. おわりに

本稿では、推薦システムで用いられる基本的な人工知能技術と、インタラクションにおける研究のポイントについて紹介してきた。また、最後にヒューマンインタフェースの研究者にとっての推薦システム研究の魅力がどこにあるか紹介してきた。推薦システムの研究においては、その研究スタイルは機械学習や情報検索、自然言語処理のものを踏襲したため、ヒューマンファクタに関する研究はまだ多くない。その点で、ヒューマンインタフェース研究者が持つ、モデル設計技法や評価技法、統計的分析法などは強みになるはずである。十分に推薦システムの研究分野のサーベイを行い、研究の立ち位置をはっきりさせて研究を行えば、ACM Recommender Systemなどの国際会議に通すことも可能だと思われる。関連する研究をいくつか本文中で紹介しているが、そのうちの一部は著者の解説記事<sup>[1,2]</sup>にて紹介している。また、意外性のあるアイテムの推薦については、奥健太氏の解説記事<sup>[3]</sup>が分かりやすい。参考にされたい。本稿をきっかけに、多くのヒューマンインタフェース研究者に参画していただければ幸いである。

## 参考文献

- [1] 土方嘉徳: 情報推薦・情報フィルタリングのためのユーザプロファイリング技術, 人工知能学会誌, Vol.19, No.3, pp.365-372, 2004.
- [2] 土方嘉徳: 嗜好抽出と情報推薦技術, 情報処理学会誌, Vol.48, No.9, pp.957-965, 2007.
- [3] 奥健太: セレンディピティ指向情報推薦の研究動向, Vol.25, No.1, pp. 2-10, 2013.

## 著者紹介



### 土方 嘉徳 (ひじかた よしのり):

1996年大阪大学基礎工学部システム工学科卒業。1998年同大学大学院修士課程修了。同年日本アイ・ビー・エム(株)東京基礎研究所入社。2002年より大阪大学大学院基礎工学研究科システム創成専攻助手。2009年より同准教授。2005年インタラクション2005ベストペーパー賞、2006年ACM IUI Best Paper Award、DEWS2006優秀論文賞、2011年WebDBフォーラム2011最優秀論文賞、2012年WebDBフォーラム2011優秀論文賞、2013年インタラクション2013ベストペーパー賞、情報処理学会山下記念研究賞、各受賞。情報推薦、Webインテリジェンス、テキストマイニングの研究に従事。情報処理学会、人工知能学会、日本データベース学会ほか会員。電子情報通信学会シニア会員。博士(工学)。