

オンラインショッピングを対象とした正確性と意外性のバランスを考慮したリコメンダシステム

加藤 由花[†] 川口 賢二^{††} 箱崎 勝也[†]

本稿では、オンラインショッピングを対象に、推薦の正確性と意外性のバランスを考慮したリコメンダシステムを提案する。提案システムは、以下の3つの機能により推薦処理を実現する。1番目はユーザ特徴ベクトル作成機能であり、遺伝的アルゴリズムを用いてユーザの嗜好の変化に応じた特徴ベクトルを生成する。2番目はフィルタリング機能であり、商品特徴ベクトルのクラスタリングを行い最もユーザの嗜好にあったカテゴリが属するクラスタのみを推薦対象とすることにより、ユーザがまったく興味を持たないデータを推薦結果から除く。3番目はマッチング機能であり、商品特徴ベクトルとユーザ特徴ベクトルのマッチング処理において、順マッチングと交差マッチングの回数を確率的に変化させることにより、正確性と意外性の調和のとれた推薦処理を実現する。我々は、提案手法を実装した実験システムを利用し、推薦結果に対する主観評価実験を行った。本稿ではその結果についても考察する。

A Recommender System Indicating Accurate and Subconscious Items for On-line Shopping

YUKA KATO,[†] KENJI KAWAGUCHI^{††} and KATSUYA HAKOZAKI[†]

This paper proposes a recommender system indicating accurate and subconscious items for on-line shopping. The proposed system recommends items by using the following three functions. First is the function generating the user feature vectors, which uses the genetic algorithm and generates the vectors according to the transition of user preferences. Second is the filtering function, which removes uninteresting items of the user from the recommendation candidates by making some clusters of the category of items using the user feature vectors and by selecting the cluster containing the most preferable category of the user as the candidate. Third is the matching function, which conducts well-balanced recommendation of accuracy and subconsciousness by changing the number of items recommended by order matching and by cross matching according to the probability in order to match an item feature vector with a user feature vector. We implemented the experimental system of the proposed method, and conducted subjective assessments for the recommendation results by using the system. This paper also discusses the experimental results.

1. はじめに

近年、インターネットの爆発的な普及にとともに、インターネットを利用したサービスに対する注目が高まってきている。特にオンラインショッピングは、アクセスネットワークのブロードバンド化等の影響もあり、急激に利用者を増やしている。総務省情報通信白書¹⁾によると、PCからのインターネット利用用途における「商品・サービス購入」は、36.8%という高い割合

を示しており、一般消費者にまでサービスが普及していることがうかがえる。このようにオンラインショッピングの市場規模は拡大基調にあるが、個別のショッピング単位で見ると、一部の大手サイトもしくは優良サイトを除き苦戦が続いている状態である²⁾。そのため、店舗そのものに付加価値を付け、魅力のある店舗作りを行う技術に注目が集まっている。

その中でも、ユーザに対して、ユーザの好んでいそうな商品の情報を提供するリコメンダシステムは、購買プロセスの省力化や、多数の商品の中から必要な商品を選択する手段として有効であり、現在までに数多くの研究開発が行われてきた。これらは主に以下の4種類に分類される³⁾。

(1) 情報フィルタリング手法

[†] 電気通信大学大学院情報システム学研究所
Graduate School of Information Systems, The University of Electro-Communications

^{††} ヤフー株式会社

Yahoo Japan Corporation

データベースに含まれるキーワードに基づいてデータを提供する方法である。サイト運営者がコンテンツに対して定義する属性情報から、システムがユーザに対して推薦するコンテンツを決定する^{4),5)}。高品質な情報提供を行うためには、ユーザの嗜好に関する情報を大量に取得する必要があり、手入力によりユーザ情報を入手するケースが多い。

(2) 協調フィルタリング手法

ユーザの嗜好を過去の行動という形で記録し、そのユーザと似た行動をとっている他のユーザの嗜好情報に基づいて、ユーザの嗜好を推測する手法である。嗜好の似ている他のユーザの情報を用いて推薦を行うユーザベースアプローチと、同じアイテムを履歴に持つ他のユーザの情報を用いて推薦を行うアイテムベースのアプローチが存在する。ユーザベースアプローチとしては、GroupLens research system^{6),7)} によって、Usenet と映画のリコメンダシステムが提案されている。Amazon.com⁸⁾ はアイテムベースのアプローチを使用したりコメンダシステムを利用しており、ここでは同じ商品を購入した別のユーザによって購入された商品の推薦を行っている。その他の代表的なりコメンダ手法として、Ringo⁹⁾ と Video Recommender¹⁰⁾ がある。どちらもユーザベースのアプローチであり、Ringo は音楽 CD を対象とした推薦システムであり、Video Recommender は、電子メールにより各人が映画に点数を付け、嗜好が類似している他のユーザのデータをもとに映画を推薦するシステムである。

(3) ハイブリッド手法

(1) と (2) を組み合わせた手法であり、代表的なシステムとして Fab¹¹⁾ があげられる。これは Web ページを収集するマルチエージェントシステムであり、ユーザからのフィードバックにより推薦精度を向上させている。音楽の推薦において感性情報を用いたハイブリッドシステムも提案されている¹²⁾。ここでは、情報フィルタリング手法を用いて未評価アイテムに対する仮の予測値を算出し、協調フィルタリング手法を用いて予測値を決定することで評価値を求めている。

(4) モデルベース手法

ベイズネットワークやクラスタモデルを用いた、モデルに基づいた推薦手法である。ベイズネットワークでは、トレーニングセットに基づいて、各ノードと枝にユーザ情報を対応させた決定木を作成することにより、推薦処理を行う¹³⁾。モデルの構築はオフラインで行われるため、嗜好情報を頻繁に更新する必要がある環境には適さない。クラスタモデルでは、あらかじめ似た好みを持つユーザをグループ分けし、同じグループ内

の意見に基づいて推薦処理を行う。ここでは、正確さと処理速度との間にトレードオフの関係が内在する。

このように、これまでも様々な手法が提案されてきたが、従来手法をオンラインショッピングサイトに適用する場合には、以下の 3 つの問題点が存在する。

- ユーザの興味に即したプロフィール作成が難しい。
- 手入力のフィルタリング設定はユーザ負荷が高い。
- 潜在的に興味を持っている情報が推薦されにくい。

1 番目の問題に対しては、従来手法はユーザの特徴を表現する情報をできるだけ多く、詳細に取得することを目指してきた。しかし、ユーザの興味は時間とともに変化していくため、変化に適応可能なプロフィール作成手法が必要である。2 番目の問題に対しては、ユーザの特徴を表現する情報を手入力により取得する手法が大部分であるが、この処理はできるかぎり自動化することが望ましい。3 番目の問題に対しては、従来手法はユーザの嗜好に正確に適合した情報を推薦するという立場をとっており、推薦の精度を向上させることを目指している。推薦の意外性に着目した研究もなされているが¹⁴⁾、正確性と意外性のバランスのとれた推薦結果を得たいという要求には応えていない。

これらの問題を解決するため、本稿では、推薦の正確性と意外性のバランスを考慮したりコメンダシステムを提案する。提案システムは、以下の 3 つの機能により推薦処理を実現する。1 番目はユーザ特徴ベクトル作成機能であり、遺伝的アルゴリズムを用いてユーザの嗜好の変化に応じた特徴ベクトルを作成する。この機能により 1 番目の問題を解決する。2 番目はフィルタリング機能であり、商品特徴ベクトルのクラスタリングを行い、最もユーザの嗜好にあったカテゴリの属するクラスタのみを推薦対象とすることにより、ユーザがまったく興味を持たないデータを推薦結果から除く。この機能により 2 番目の問題を解決する。3 番目はマッチング選択機能であり、商品特徴ベクトルとユーザ特徴ベクトルのマッチング処理において、順マッチングと交差マッチングの回数を確率的に変化させることにより、正確性と意外性の調和のとれた推薦を実現する。この機能により 3 番目の問題を解決する。

以下、2 章で 3 つの機能からなるリコメンダシステムの提案を行った後、3 章で提案手法を実装した実験システムについて説明する。その後、4 章で実験システムを用いたユーザ実験の結果を述べ、5 章で考察を行った後、6 章で本稿をまとめる。

2. リコメンダシステムの提案

2.1 概要

本稿では、これまであまり注目されてこなかった「ユーザの嗜好に対して正確性と意外性を融合した情報を提示するシステム」を提案する。まず、推薦処理における正確性と意外性について定義しておく。

本稿ではオンラインショッピングにおけるリコメンダシステムを考察対象とするため、オンラインショップで扱われる商品の特徴がある複数の要素からなる商品特徴ベクトルとして表現されているとき、その同じ要素を用いてユーザの商品に対する嗜好をユーザ特徴ベクトルとして表現することができる。ここで、ユーザ特徴ベクトルは、ユーザの嗜好すべてを表現しているわけではなく、商品特徴ベクトルの要素を用いて、ユーザの嗜好のある一面を表現していることに注意する。このユーザ特徴ベクトルを用いると、候補となる全商品を以下の3つのグループに分類することができる。

- (1) ユーザ特徴ベクトルと商品特徴ベクトルの類似度が高く、対象ユーザの嗜好にあっている商品群。
- (2) ユーザ特徴ベクトルと商品特徴ベクトルの類似度は低いが、対象ユーザの嗜好にあっている商品群。
- (3) ユーザ特徴ベクトルと商品特徴ベクトルの類似度が低く、対象ユーザの嗜好にあっていない商品群。

(2)のグループが存在する理由は、ユーザ特徴ベクトルがユーザの嗜好の一面のみを表現していることによる。そのため、特徴ベクトルで表現されている要素以外の部分の嗜好にあっている商品が存在する可能性があり、このような商品は意外性を持っているが、ユーザの好みにあう可能性を秘めた商品であるといえる。本稿では(1)に含まれる商品を推薦することを正確性を重視した推薦処理(2)に含まれる商品を推薦することを意外性を重視した推薦処理と定義する。1章で述べたように、本稿ではこれらのバランスを考慮したりコメンダシステムの構築を目指す。

ここで(1)に含まれる商品群は、2つの特徴ベクトル間の距離を計算することにより容易に抽出可能であるが(2)に含まれる商品群の抽出には工夫が必要である。これには特徴ベクトルで表現される以外のユーザプロフィールを手入力させる等、いくつかの方法が考えられるが、本稿では、ユーザ特徴ベクトルを利用して商品をいくつかのグループにクラスタリングし、(1)に含まれる商品群が属しているクラスタに含まれる商品を(2)の商品の候補とする手法を採用する。各商品とグループ、クラスタの関係を図1に示す。図中




図1 商品とクラスタの関係

Fig. 1 A relationship between items and clusters.

に網掛けで示した部分(Favorite items of user 1)は、商品特徴ベクトルとユーザ特徴ベクトルの類似度が高い(1)に含まれる商品群である。また、網掛けで示した商品(item)は、これらのベクトル間の類似度は高くないが(1)に含まれる商品群と同じクラスタに含まれる商品であり、これが(2)に含まれる商品群である。それ以外の商品は、ユーザの嗜好にあわない可能性が高い(3)に含まれる商品群である。本稿では、この中で(1)に含まれる商品群と(2)に含まれる商品群をバランス良く推薦することを考える。

この推薦処理は以下の3つのステップで実現される。まず適切なユーザ特徴ベクトルを作成し(1)に含まれる商品群を抽出する。次に(1)の結果を利用し(2)に含まれる商品群を抽出する。そして最後にこの2つのグループに含まれる商品をバランス良く推薦する。提案システムでは、これらの処理を以下の3つの機能として実現する。

- ユーザ特徴ベクトル作成機能
- フィルタリング機能
- マッチング選択機能

以下、それぞれの機能について詳述する。

2.2 ユーザ特徴ベクトル作成機能

推薦処理を行うためには、ユーザの興味に即したユーザ特徴ベクトルを作成することが必要であり、特徴ベクトルの精度が推薦の精度に大きな影響を与える。これまで、テレビ番組録画のためのビデオサーバにおける推薦システム¹⁵⁾等が提案されており、最近の評価結果に重みを持たせることや、明示的なプロフィール(視聴した番組のメタデータ等)と暗黙的なプロフィール(視聴や削除等のユーザのアクション)を組み合わせるにより、精度の高い特徴ベクトルの生成が実現されている。しかし、本稿で対象とするオンラインショッピングにおいては、ユーザ情報が少ない環境であっても質の高い推薦を行う必要があり、評価結果に重みを持たせる方法や、暗黙データを利用する

方法は必ずしも有効ではない．また、ユーザの商品に対する嗜好（ある商品を好ましく思うかどうか）は数カ月、数年という時間の経過とともに変化していくものである．これは内的要因としてのユーザ自身の置かれている立場や生活環境の変化等が原因となるものから、外的要因としての流行や経済状況、国際情勢の変化等が原因になるものまで様々である．このような嗜好の経時変化にも対応する必要がある．

そこで、提案システムでは、長期的な時間の経過とともに変化していくユーザの嗜好をシステムに取り込むために、ユーザ特徴ベクトルを動的に更新する仕組みを導入する．ユーザの特性にあった情報を提示する研究としては、遺伝的アルゴリズムを用いたデザイン支援システムの提案が行われている¹⁶⁾．ここでは、ワンピースのデザイン支援を対象に、画面上に提示されたデザインの中で最も気に入ったものの選択を繰り返すことにより、ユーザの感性にあったデザイン候補を絞り込んでいく．初期状態では、デザインが表示される確率はすべて等しいが、ユーザが対話的にシステムに働きかけることにより評価関数を変化させ、その関数に応じて表示する候補案が作成される．

提案システムでも、ユーザの感性にあった特徴ベクトルを作成するために遺伝的アルゴリズム（GA）を利用し、上記の手法と同様な明示的なフィードバック機能を取り入れる．ここで、商品特徴ベクトルとユーザ特徴ベクトルは商品のカテゴリにより構成し、商品特徴ベクトルはあらかじめ商品ごとに設定されているものとする．一方、ユーザ特徴ベクトルは、カテゴリごとにランダムに選ばれた商品に対する評価値をユーザに入力させることにより、初期ユーザ特徴ベクトルを生成する．その後、ユーザの商品選択履歴を明示的なフィードバックとして与えることにより、時間の経過に従ってユーザ特徴ベクトルの更新を行う．

データの処理方法について、対立遺伝子の作成方法を図2に、遺伝子の作成方法を図3に示す．遺伝子型は c 個（カテゴリの個数）の実数の1次元配列で構成されており、ユーザ特徴ベクトルの各要素を遺伝子に対応させている．初期状態では c 個それぞれの遺伝子座に対して対立遺伝子を0から1.0まで0.1刻みで11個持たせ、それぞれの値に等しいポイント（5pt）を与える．処理の手順を以下に示す．

(1) 対立遺伝子に、カテゴリごとにランダムに選ばれた商品に対するユーザの評価値をポイントとして与える．商品には商品特徴ベクトルが与えられているので、このベクトルの各要素に評価値をかけた値を正規化してポイントとする．これにより、特徴ベクトルの要素




図2 対立遺伝子の作成
Fig. 2 A generating process of alleles.




図3 遺伝子の作成
Fig. 3 A generating process of genes.

がとりうる値の確率が設定される（図2）．
 (2) 各遺伝子座ごとに、設定されたポイントを基に1つのデータを確率的に選択し、GAのオペレータ（選択、交叉）を適用する．この操作により生成された遺伝子（図3）が初期ユーザ特徴ベクトルとなる．
 (3) 推薦処理では、推薦された商品に対してユーザは明示的な評価点を与える．この評価点を利用し、ユーザ特徴ベクトルを随時更新する．具体的には(1)と同様の手順でユーザの評価点を対立遺伝子それぞれにポイントとして与え（図2）、(2)の処理を繰り返す．これにより、評価結果を特徴ベクトルの要素がとりうる値の確率にフィードバックする．

2.3 フィルタリング機能

次に、フィルタリング機能について説明する．これは、意外性のある推薦を行うための商品（(2)に含まれる商品群）を抽出するための機能である．フィルタリング処理としては従来から多くの手法が提案されている．通常、ユーザ情報の登録時に、ユーザが興味を持っているカテゴリを入力させたり、各カテゴリの代表的なアイテムを提示しそれに対する興味度合いを答えさせたりすることにより、ユーザの興味や嗜好を把握する．しかし、フィルタリングの精度を高めようとすると多くの入力データが必要になり、ユーザに大きな負荷がかかる．またユーザの嗜好は時とともに変化していくため、一定期間ごとにデータを再入力させる必要があり¹⁷⁾、これは大きな負担になる．

提案システムにおけるフィルタリング処理では、前節で作成した初期ユーザ特徴ベクトルを利用し、カテ

ゴリ別のユーザ特徴ベクトルの初期値（ユーザが評価値を入力した商品の商品特徴ベクトルをカテゴリごとに合成したものを）を作成する．そして、これをいくつかのクラスタに分類する．ここで、各商品は複数のカテゴリに属することが可能であり、またユーザ特徴ベクトルも複数のカテゴリを要素に持つことに注意する．そして、ユーザ特徴ベクトルと商品特徴ベクトルの類似度が最も高い商品（(1)のグループに含まれる商品の代表）が所属しているクラスタを推薦対象のクラスタとして抽出する．カテゴリ別のユーザ特徴ベクトルは、ユーザが商品を選択するたびに更新されるので、ユーザの嗜好の変化に対応するために、一定期間ごとにデータを再入力する必要はない．このように、本手法では、商品の特徴を利用してカテゴリのクラスタ化を行うことにより、ユーザが詳細な嗜好データを入力しなくても、少ない手間と精度の高いフィルタリング処理を実現する．処理の手順を以下に示す．

(1) ユーザにカテゴリごとにランダムに選ばれた商品に対する評価値を入力させ、それらの商品の商品特徴ベクトルに評価値をかけ合わせたものをカテゴリごとに足し合わせる．これをカテゴリ別のユーザ特徴ベクトルの初期値とする．

(2) ユーザ特徴ベクトルの要素から、ユーザが最も好むカテゴリ C_{pref} を決定する．これは、ユーザ特徴ベクトルと商品特徴ベクトルの類似度が最も高い商品が含まれるカテゴリを抽出する処理に相当する．

(3) カテゴリ別のユーザ特徴ベクトル間のユークリッド距離を求め、カテゴリのクラスタリングを行う．

(4) 意外性のある推薦を行うための商品として、 C_{pref} が属するクラスタに含まれるカテゴリを抽出する．

(5) 推薦された商品をユーザが選択するたびに、カテゴリ別のユーザ特徴ベクトルを更新し、推薦対象となるカテゴリを抽出し直す．

2.4 マッチング選択機能

これまで、推薦の意外性を高める手法としては、順マッチングと交差マッチングを用いた手法が提案されている¹⁴⁾．順マッチングは、購買履歴（または選択履歴）があるカテゴリ A 内のユーザ特徴ベクトルと、カテゴリ A 内の商品特徴ベクトルとを比較することにより推薦アイテムを決定する方法である．一方、交差マッチングは、購買履歴のあるカテゴリ A 内のユーザ特徴ベクトルと、A 以外のカテゴリ B 内の商品特徴ベクトルとを比較することにより推薦アイテムを決定する方法である．順マッチングではユーザの嗜好に対して正確性の高いアイテムが、交差マッチングでは意外性の高いアイテムが推薦されるという被験者実験

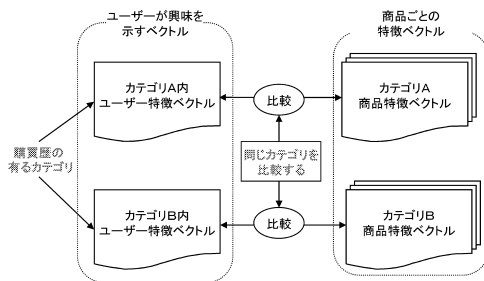


図 4 順マッチングのイメージ
Fig. 4 An image of order matching.

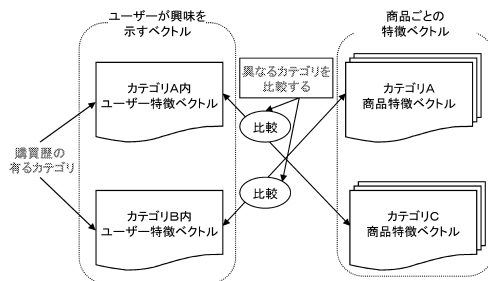


図 5 交差マッチングのイメージ
Fig. 5 An image of cross matching.

の結果が報告されている¹⁴⁾．順マッチングのイメージを図 4 に、交差マッチングのイメージを図 5 に示す．

ただし、この手法をそのまま用いた推薦では、ユーザに対して、順マッチングと交差マッチングのどちらか一方のみによる推薦結果を与えることになる．これらを組み合わせて用いた処理を想定していないためである．そこで提案システムでは、それぞれのマッチングを用いる推薦結果の個数を確率的に求めることにより、正確性と意外性を融和させた推薦処理を実現する．ここでの確率は、選択履歴をもとに、ユーザがよく選択する傾向にあるカテゴリから商品を選択した頻度と、それ以外のカテゴリから商品を選択した頻度をもとに求める．これにより、ユーザの意思とは異なるアイテムを提示することが可能になり、正確性と意外性のバランスをとることができる．処理の手順を以下に示す．

(1) フィルタリング機能により、ユーザが最も好む傾向にあるカテゴリと、交差マッチングにおいて選択の対象となるカテゴリを決定する．

(2) 順マッチングを用いて推薦する確率 p_o と、交差マッチングを用いて推薦する確率 p_c を、

$$p_o = \frac{I_o + N_o}{I_o + I_c + N_o + N_c} \quad (1)$$

$$p_c = 1 - p_o = \frac{I_c + N_c}{I_o + I_c + N_o + N_c} \quad (2)$$

として算出する．ここで I_o, I_c は、正確性を優先した推薦結果の個数（順マッチングを用いたもの）と意外性を優先した推薦結果の個数（交差マッチングを用いたもの）の初期値であり、ユーザが初期設定値としてシステムに与える値である．また N_o, N_c は、過去の履歴において正確性を優先した推薦結果と意外性を優先した推薦結果が何個ずつ選択されたかを表す値であり、ユーザの選択結果に従って更新されていく．

(3) 算出された選択確率から、順マッチングを用いて推薦する個数と交差マッチングを用いて推薦する個数を決定する．

3. システムの実装

3.1 システムの構成

提案するリコメンドシステムの実装検証を行うために、実験システムを構築した．リコメンドシステムの構成としては、システム的设计指針に従って様々な形態が想定される．本実験システムでは、プライバシーの保護を考慮したオンラインショッピング支援の実現を目指す指針を策定し、個人情報のサーバへの登録を強要しないシステム構成を採用することにした．従来のシステムがサーバ側にほとんどの処理を割り当てているのに対し、実験システムではクライアント側に主な処理を割り当てている．

ここでは対象商品として映画ビデオを取り上げ、ビデオの推薦機能を持つオンラインショップのプロトタイプシステムを構築した．これはクライアントであるユーザ PC と、サーバである店舗から構成される．クライアントは、ユーザ特徴ベクトルの作成、商品リストの取得、推薦機能を持つが、処理の過程でユーザを識別可能な情報をサーバに送信することはしない．サーバは、商品リストを保持し、クライアントからの要求に応じて商品情報を提供する．提案システムの構成を図 6 に示す．

クライアント PC 上には、Java 言語で開発したコントローラを実装し、Web ブラウザである Internet Explorer 6.X を組み合わせることにより、ユーザ情報の初期設定機能、および推薦機能を実現した．店舗であるサーバは、RedHatLinux 9 上に Servlet で実装し、MySQL を利用して構築したデータベースに対象商品である映画ビデオのデータを格納した．各ビデオはメタデータとして、ジャンル、英語タイトル、日本語タイトル、制作年、監督、主演男優、主演女優、受賞歴（アカデミー賞、カンヌ映画祭、ヴェネチア国際映画祭、ベルリン国際映画祭、ゴールデン・グローブ、NY 批評家協会賞、アポリアッツ映画祭、MTV ムー

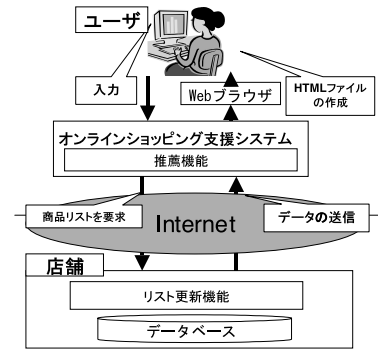


図 6 システムの構成

Fig. 6 System architecture.

表 1 ジャンルごとのタイトル数

Table 1 The number of movies for each genre.

ジャンル	タイトル数 (本)
Action	316
Adventure	103
Animation	53
Child	71
Comedy	291
Crime	100
Drama	474
Fantasy	49
Horror	124
Musical	26
Mystery	42
Romance	89
Science Fiction	114
Thriller	167

ビーアワード、日本アカデミー賞、その他)の7種類のデータを持ち、ユーザはこれらのデータを参考に対象商品の購買（視聴）の有無を決定できるようになっている．実験システムで用意した映画ビデオのタイトル数は1,029である．利用したジャンルの種類、および各ジャンルに含まれるタイトル数を表 1 に示す．

3.2 各ベクトルの定義

実験システムでは、推薦処理を実現するために、各ビデオの特徴を表現する商品特徴ベクトル M_i (i はビデオを識別するための ID)、各ユーザの嗜好を表現するユーザ特徴ベクトル P_{jt} (j はユーザを識別するための ID、 t は履歴における時間を識別するための ID) の2種類のベクトルを利用する．このうち P_{jt} は、ユーザのアイテム選択履歴に従って更新されていくベクトルである．実験システムにおける推薦のカテゴリは、映画ビデオの特徴を最もよく表現しているジャンルとし、それぞれのベクトルも表 1 に示した 14 個のジャンルを要素として持つベクトルとして定義する．各要素は、対象となる要素が含まれていれば 1、含まれていなければ

ば0の値を与え、さらに全要素を正規化することにより作成する。たとえば、映画のジャンルが Animation, Child, Fantasy であったとき、この商品特徴ベクトルは $M_i = (0, 0, 0.33, 0.33, 0, 0, 0, 0.33, 0, 0, 0, 0, 0)$ となる。ユーザ特徴ベクトルは、ユーザが初期データを入力することにより作成され、システムに推薦結果に対する評価をフィードバックすることにより更新されていく。

3.3 処理の流れ

3.3.1 初期設定

まずはじめに、ユーザ特徴ベクトルの初期値、ジャンル別のユーザ特徴ベクトルの初期値、推薦における正確性と意外性の割合の初期値を生成する。これらは、ユーザが Web ブラウザ上に表示される入力フォームに初期データを入力することにより作成する。

- (1) ユーザ特徴ベクトルを生成する。まず、各ジャンルから1つのアイテムをランダムに選択し、それをユーザに提示する。このとき、該当アイテムに対する評価として「+ 評価」「- 評価」のどちらかを選択してもらう。この結果に基づき、該当ジャンルに対するユーザ特徴ベクトルの要素の値を「+1」「-1」とする。ユーザ特徴ベクトルは、類似度を計算する時点でプラス要素とマイナス要素に対して正規化される。
- (2) ユーザ特徴ベクトルの生成時にランダムに選択したアイテムを利用して、ジャンル別のユーザ特徴ベクトルを生成する。まず、ここで選択したアイテムの商品特徴ベクトルに、そのアイテムに対するユーザの評価値をかけ合わせたベクトルを生成する。そして、それらのベクトルをジャンルごとに足し合わせることで、ベクトルの初期値を生成する。
- (3) 正確性と意外性の割合の初期値を生成する。ここでは、順マッチングと交差マッチングで推薦するデータの個数の割合を、ユーザに指定してもらう。スライダを利用し、0%から100%までの値を選択してもらう。

3.3.2 ユーザ特徴ベクトルの更新

ユーザ特徴ベクトルは、ユーザの選択履歴に従って更新されていくが、その過程において GA を用いることにより、ユーザの感性にあった特徴ベクトルを生成する。また、時間の経過にともなうユーザの嗜好の変化に対応して、特徴ベクトルを動的に変更していく。実験システムでは、算出されたユーザ特徴ベクトルと現在のユーザ特徴ベクトルとの類似度 Sim_{all} と、算出されたユーザ特徴ベクトルと前回 GA を利用してから直前までの選択履歴によって算出されたユーザ特徴ベクトルとの類似度 $Sim_{current}$ との和を適合度 F として定義した。つまり α ($0 \leq \alpha \leq 1$) を重みと

して、

$$F = \alpha \cdot Sim_{all} + (1 - \alpha) \cdot Sim_{current} \quad (3)$$

とした。 $0 \leq F \leq 1$ であり、実験システムにおいては $\alpha = 0.5$ である。ここで類似度は、推薦処理によく用いられる、ベクトルの内積を用いた方法により算出する。つまり、各ベクトル間の角度のコサインとして類似度 $Sim(U, V)$ を

$$Sim(U, V) = \frac{\sum u_i v_i}{\sqrt{\sum u_i^2} \sqrt{\sum v_i^2}} \quad (4)$$

と算出する。 $U = (u_0, u_1, \dots)$, $V = (v_0, v_1, \dots)$ である。処理の手順を以下に示す。

- (1) 選択履歴から、ユーザ特徴ベクトルの各要素がとりうる値(0から1.0)の確率を求める。
- (2)(1)で求めた確率から、初期データとなるユーザ特徴ベクトルを求める。
- (3)式(3)から適合度を算出し(4)(5)の処理を100世代繰り返した時点で終了する。
- (4)トーナメント選択により選択を行う¹⁸⁾。
- (5)一様交叉により生殖を行う¹⁸⁾(3)に戻る。

3.3.3 フィルタリング処理

算出したユーザ特徴ベクトルを利用し、ユーザが最も好むジャンル、および交差マッチングの対象となるジャンル(意外性のある推薦を行うための商品が含まれるジャンル)を決定する。処理の手順を以下に示す。

- (1) ユーザ特徴ベクトルの要素の中で、最も値が大きい要素に対応するジャンルを、ユーザが最も好むジャンルとして抽出する。
- (2) ジャンル別のユーザ特徴ベクトルを利用し、これらのベクトル間のユークリッド距離を求めることにより、ジャンルのクラスタリングを行う。
- (3) 生成したクラスタの中から、ユーザが最も好むジャンルが属しているクラスタを抽出する。
- (4) 抽出したクラスタに属するジャンルを、交差マッチングの対象となるジャンルとする(ただし(1)で求めたジャンルは除く)。
- (5) ユーザがアイテムを選択するたびに、それまでに選択された全アイテムの商品特徴ベクトルを利用し、ジャンル別のユーザ特徴ベクトルを更新する。

3.3.4 マッチング選択

マッチング選択では、正確性と意外性のバランスのとれた推薦情報の提示を目指す。ユーザは初期設定において、正確性と意外性の割合をシステムに指定するが、過去の選択履歴に従って、この割合はより適切なものに変更されていく。以下に処理の手順を示す。

- (1) システムは過去にユーザが選択したデータが、順マッチングで推薦されたものであったか、交差マッ

ングで推薦されたものであったかの履歴をログとして保持している。この履歴を式 (1)、式 (2) に代入し、各選択確率を算出する。

(2) 算出された個数に従って、順マッチングと交差マッチングで推薦するアイテムを決定する。ここでは、最新のユーザ特徴ベクトルと商品特徴ベクトルの類似度を計算することにより、類似度の大きい順に決められた個数のマッチング結果を抽出する。この類似度は、ユーザ特徴ベクトルの生成時と同様の方法で算出する。

4. 評価実験

本章では、被験者実験により提案した推薦手法の有効性を確認する。提案手法では、GA を用いてユーザ特徴ベクトルを生成しているが、ここで用いられる各種パラメータ値は実験により最適値を求める必要がある。そのため、まずこれらのパラメータ値を決定する。次に、これらの値を用いた推薦結果が、正確性と意外性の調和のとれた結果となっていることを確認する。

4.1 GA のパラメータを求める実験

4.1.1 実験の方法

一般に GA のパラメータとしては、交叉率については 0.6 から 0.95 の間、突然変異率については遺伝子の要素の逆数をとったもの、または 0.5% から 0.01% の間などが最適とされている¹⁹⁾。そのため本実験では、交叉率として 0.6, 0.8, 0.95 の 3 種類、突然変異率として 1/64, 1/16, 1/4 の 3 種類の値を適用し、その推薦結果に対する主観評価実験を行った。被験者に、それぞれのパラメータ値を変えた場合の推薦結果を提示し、正確性(好みのアイテムであり、推薦されることが予想できるアイテム)と意外性(予想外の推薦結果であるが、好みにあうアイテム)に対して 5 段階評価(良い/やや良い/ふつう/やや悪い/悪い)を行ってもらった。被験者は 20 代の男性 10 名である。

4.1.2 実験の結果

交叉率を変化させたときの実験結果を図 7 と図 8 に、突然変異率を変化させたときの実験結果を図 9 と図 10 に示す。ここで、交叉率を変化させる実験における突然変異率は 1/16、突然変異率を変化させる実験における交叉率は 0.95 とした。

まず交叉率については、正確性においては 0.6 が、意外性においては 0.95 が 5 回の平均において最も高い値をとっているが、全体的に安定した結果が得られている(分散が小さい)0.6 をパラメータとして選択することにした。次に突然変異率については、1/64 の場合に全体的に高い結果が得られているため、1/64 を選択することにした。正確性に対する評価において




図 7 交叉率に対する主観評価結果(推薦情報の正確性)
Fig. 7 Evaluation results for cross ratio (for accuracy).




図 8 交叉率に対する主観評価結果(推薦情報の意外性)
Fig. 8 Evaluation results for cross ratio (for subconsciousness).




図 9 突然変異率に対する主観評価結果(推薦情報の正確性)
Fig. 9 Evaluation results for mutation ratio (for accuracy).




図 10 突然変異率に対する主観評価結果(推薦情報の意外性)
Fig. 10 Evaluation results for mutation ratio (for subconsciousness).

は、3 回目に評価が低くなっているが、4 回目と 5 回目では評価が上昇している。これは、1 回目と 2 回目においてすでにユーザが最も高く評価するアイテムが提示されてしまったためと考えられる。

4.2 推薦結果を評価する実験

4.2.1 実験の方法

本実験では、提案手法に従って推薦された 10 個の

推薦結果に対し、被験者に前節の実験と同様の5段階評価を行ってもらった。実験は連続して9回行い、時間の経過とともに評価結果がどのように変化していくかを調べるため、初期(1~3回目)、中期(4~6回目)、後期(7~9回目)のそれぞれの推薦結果に対して主観評価値を記入してもらった。実験では、ユーザ特徴ベクトルの生成にGAを使った場合、3回に1回使った場合、使わなかった場合の3種類の結果を比較した。これは、GAを用いた場合、意外性に影響を与えずに正確性が向上しているかを確認するためである。GAのパラメータとしては、前節の結果から交叉率0.6、突然変異率1/64を用いた。被験者は前節の実験と同一の20代の男性10名である。

4.2.2 実験の結果

正確性に対する評価結果を図11に、意外性に対する評価結果を図12に示す。これらの結果から、GAを用いた場合、意外性を保ちながら正確性が向上していることが分かる。GAを用いる頻度としては、毎回用いる方が正確性、意外性ともに評価が高くなっている。

そこで、GAを毎回用いた場合を取り上げ、システム全体の評価結果を考察する。まず、GAを用いた場合、正確性が向上していることから、ユーザの嗜好を的確に反映したユーザ特徴ベクトルが作成されていることが分かる。既存の推薦手法では、推薦を繰り返すうちに徐々に正確性が向上していくが、提案手法では、実験の初期から高い正確性を実現しており、少ないユーザ情報であっても精度の高い推薦が可能であることを示している。また、意外性に対する評価も高くなっており、フィルタリング機能により意外性の高いジャンルを的確に抽出していると考えられる。さらに、通常、正確性が向上するにつれ推薦の意外性は低下していくが、提案手法では、推薦処理のたびに順マッチングと交差マッチングを適切な割合で組み合わせて推薦を行うため、時間の経過とともに意外性が低下するという現象は見られない。マッチング選択で提示する推薦結果の割合は人により異なるが、全体的に高い満足度が得られていることから、各人がそれぞれの割合に満足しており、システムの推薦結果に対して高い評価が得られていることが分かった。

本実験は、商品として映画を取り上げ、カテゴリとして映画のジャンルを利用した。提案手法では、ユーザ特徴ベクトルと商品特徴ベクトルを構成することができれば推薦処理を行うことができるため、この実験結果は、商品の入れ替え頻度、ユーザ層等には影響を受けないと考えられる。映画以外の商品への本手法の適用も可能ではあるが、この場合の商品は、カテゴ




図 11 推薦処理に対する主観評価結果 (推薦情報の正確性)
Fig. 11 Evaluation results for recommendation process (for accuracy).




図 12 推薦処理に対する主観評価結果 (推薦情報の意外性)
Fig. 12 Evaluation results for recommendation process (for subconsciousness).

リにより商品の特徴とユーザの嗜好を表現できるもの(本、衣類、食べ物等)である必要がある。

今回の実験では、連続した9回の推薦結果に対して評価を行った。つまり、時間の経過にもなうユーザ嗜好の変化に対する実験は行われていない。提案手法では、時間の経過にもなうユーザ特徴ベクトルを更新することにより、理論的にはそのときどきの嗜好を推薦結果に反映させることができる。しかし、この検証実験を行う必要があり、今後、より長期的な実験結果を蓄積していく必要がある。

5. 考 察

従来から提案されてきたオンラインショッピングを改善する手法は、人的資源や資本が潤沢にある大手企業を対象にしたものが主であった。それに対し提案手法は、中小規模のサイトであっても容易に改善が実現できることを目指している。本章では、提案手法と従来手法を比較することにより、この前提条件の下での提案手法の優位性を検証する。さらに、提案システムの問題点を分析し、実運用のために必要とされる実装設計への手がかりを与える。

5.1 推薦結果に対する考察

従来手法における推薦処理では、初期状態ではユーザの嗜好と遠い状態にあるユーザ特徴ベクトルを、ユーザの選択履歴を利用してユーザの嗜好に近づける作業を繰り返すことにより推薦の精度を高めている。した

表 2 提案システムと他のシステムの比較

Table 2 Comparison between the proposed system and conventional systems.

比較項目	提案システム	GroupLens	Amazon
システム構成	クライアント中心	サーバ中心	サーバ中心
推薦方法	IF ⁷	User-based CF	Item-based CF
プライバシー保護			
導入コスト		×	×
大規模 DB への適用			
小規模ユーザ群への適用		×	




図 13 従来からの推薦手法における改善シナリオ

Fig. 13 Recommendation scenario of conventional methods.




図 14 提案した推薦手法における改善シナリオ

Fig. 14 Recommendation scenario of the proposed method.

がって、推薦機能の利用を繰り返すごとにユーザの嗜好に近い正確性の高い情報を得る機会が増すことになる。それにともない、意外性の高い情報を得る機会は減少する。一方、提案手法では、正確性と意外性の調和のとれた情報の提供を実現する。これらの関係を示したものが図 13 と図 14 である。縦軸は予測される評価値であり、横軸は推薦される情報の特性を示している。リコメダシステムにおける推薦される情報の価値とは、推薦結果に対するユーザの満足度と考えることができる。正確性と意外性のバランスのとれた推薦結果はユーザの満足度を向上させると考えられるため、推薦される情報の価値も高くなる。図 13 と図 14 にはこの情報の価値もあわせて示している。提案手法では、この情報の価値が最大になる点を改善目標としている。

5.2 システムの特徴に対する比較

本節では、提案手法を実装した実験システムと、他のオンラインショッピングを支援するシステムとの比較を行う。比較対象としては、協調フィルタリング型システムの代表として GroupLens⁶⁾ を、商用オンラインショップの代表として Amazon⁸⁾ を取り上げ、システム構成、推薦方法、プライバシー保護、導入コスト、大規模 DB への適用、小規模ユーザ群への適用の 6 項目について比較を行った。比較結果を表 2 に示す。

システム構成については、提案システムは推薦処理の大部分をクライアント側で実行するのにに対し、他の

2 つのシステムでは大部分の処理をサーバ側で実行する。GroupLens や Amazon に限らず、一般に Web 上でサービスを提供しているサイトではサーバにほとんどの処理を実行させており、このシステム構成は提案システムの特徴の 1 つとなっている。

推薦方法については、提案システムが情報フィルタリング手法を採用しているのに対し、他の 2 つのシステムでは協調フィルタリング手法を採用している。この推薦方式により、提案システムではクライアント側で大部分の処理を実現することが可能になっている。これは、他のユーザの特徴ベクトルを取得する必要がないためである。

プライバシー保護については、提案システムでは、サーバにユーザの個人情報を送ることなしに、クライアント側で大部分の処理を実行するため、他のシステムに比べ個人情報の漏洩に対する危険性が非常に低くなっている。サーバ上での処理には、プライバシー保護対策を厳重に行った場合でも個人情報の漏洩に関する危険性は内在しており、ユーザも個人情報を提供することに抵抗を持っている場合が多い。

導入コストについては、提案システムは他のシステムと比較し、様々な商品カテゴリに容易に対応できるという点で、経済的なシステム構築が可能になっている。他のシステムでは、登録された個人情報を基にサーバ側で処理が行われるため、対象となる商品カテゴリに

あわせてシステムの大幅な更改が必要である。それに対し提案システムでは、クライアント側に1つのユーザ特徴ベクトルを持てば推薦処理を実現することができるため、汎用性が高く、サーバ側のシステムを大幅に変更する必要もない。サービスを提供するショッピングサイトは、推薦処理を行うアプリケーションの配布を行えばよく、導入コストが削減できる。

推薦対象となる商品の数(データベースの規模)およびユーザ数(扱う商品数に対するユーザ数の割合)については、それぞれのシステムにおいて適用可能な規模は異なってくる。提案システムでは、商品の情報をクライアント上に取り込む必要があるため、非常に大規模なデータベースへの適用は困難である。しかし、対象ユーザのユーザ特徴ベクトルのみで推薦処理が可能であるため、ユーザ数は推薦精度に影響を与えない。ユーザベースの協調フィルタリング方式を採用している GroupLens では、サーバ側で推薦処理を実現するため、大規模なデータベースへの適用が可能であるが、推薦処理に高い負荷がかかるため、計算機環境によるデータベース規模の限界は存在する。また、ユーザ間の類似度を利用して推薦処理を行うため、ユーザ数が少ない環境への適用が困難である。アイテムベースの協調フィルタリング方式を採用している Amazon.com では、サーバ側で推薦処理を実現するため、大規模なデータベースへの適用が可能である。またアイテムベース処理はユーザベース処理に比べ推薦処理にかかる負荷も低く、非常に大規模なデータベースへの適用を実現している。協調フィルタリング方式であるため、ユーザ数が少ない環境への適用は難しいが、ユーザベースの方式に比べると適用可能性はやや高い。

実験システムでは、ビデオを対象商品として取り上げた。しかし本研究の最終的な目的は、あらゆる商品群を対象としたオンラインショッピングの支援である。本稿ではメタデータとして映画のジャンルを利用したが、商品のメタデータとしてどのようなデータを用いるか、またそのデータをどのように作成するかについて、今後、より詳細に検討していく必要があるだろう。

6. ま と め

本稿では、オンラインショッピングを対象に、推薦の正確性と意外性のバランスと考慮したリコメンダシステムを提案した。提案システムは、以下の3つの機能により推薦処理を実現する。1番目はユーザ特徴ベクトル生成機能であり、GA を用いてユーザの嗜好の変化に応じた特徴ベクトルを生成する。2番目はフィルタリング機能であり、商品特徴ベクトルのクラスタリ

ングを行い、最もユーザの嗜好にあったカテゴリの属するクラスタのみを推薦対象とすることにより、ユーザがまったく興味を持たないデータを推薦対象から除く。3番目はマッチング選択機能であり、商品特徴ベクトルとユーザ特徴ベクトルのマッチング処理において、順マッチングと交差マッチングの回数を確率的に変化させることにより、正確性と意外性の調和のとれた推薦処理を実現する。従来手法がユーザの嗜好に対して高精度な情報を提供することを目指しているのに対して、提案手法は正確性の高い情報と意外性の高い情報を組み合わせることにより、より有益な情報の提供を実現した。本稿ではさらに、映画ビデオを対象にした実験システムを構築し、被験者実験を行うことにより、提案手法の有効性を確認した。

ただし、実システムへの適用を考えた場合、解決しなくてはならない課題がいくつか残されている。本稿の最後にこれらの課題をまとめておく。

- 本稿では GA のパラメータを実験により決定したが、より汎用的な利用を考えた場合、ユーザにとって最適なパラメータ値を選択できる仕組みが必要である。適応的にパラメータ値を決定する手法^{(20),(21)}や、パラメータフリーな手法⁽²²⁾の利用等が考えられる。

- 本稿では商品としてビデオを取り上げたため、ジャンルをメタデータとして利用した。しかし、他の商品では必ずしも適切なメタデータが利用できるとは限らない。感性語を用いたデータベース構築手法⁽²³⁾等を利用し、適切なデータを取得する必要がある。

- 提案システムは、長期間の利用によってその有効性が発揮されるが、本稿における評価実験は短期的な実験期間においてのみ実施された。また商品データ数も限られたもの(1,029個)であり、運用を見据えたシステムを構築するためには、より大規模なシステムで長期間の運用実験が必要である。

参 考 文 献

- 1) 総務省: <http://www.soumu.go.jp/>.
- 2) 中谷俊介: 人はなぜネットでものを買わないかタイプ別「潜在顧客」アプローチ法, ソフトバンクパブリッシング(2002).
- 3) Resnick, P. and Varian, H.: Recommender Systems, *Comm. ACM*, Vol.40, No.3, pp.56-58 (1997).
- 4) 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(2002).
- 5) 徳永健伸, 辻井潤一: 情報検索と言語処理: 言語と計算, 東京大学出版会(1999).
- 6) Konstan, J., Miller, B., Maltz, D., Herlocker, J., Gordon, L. and Riedl, J.: GroupLens: Ap-

- plying Collaborative Filtering to Usenet News, *Comm. ACM*, Vol.40, No.3, pp.77-87 (1997).
- 7) Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J.: An Open Architecture for Collaborative Filtering of Netnews, *CSCW'94* (1994).
- 8) Amazon.com: <http://www.amazon.com>.
- 9) Shardanand, U. and Maes, P.: Social Information Filtering: Algorithm for Automating 'Word of Mouth', *CHI'95* (1995).
- 10) Hill, W., Stead, L., Rosenstein, M. and Furnas, G.: Recommending and Evaluating Choices in a Virtual Community of Use, *CHI'95* (1995).
- 11) Balabanovic, M. and Shoham, Y.: Fab: Content-based Collaborative Recommendation, *Comm. ACM*, Vol.40, No.3, pp.66-72 (1997).
- 12) 黒瀬崇弘, 梶川嘉延, 野村康雄: 感性情報を用いた楽曲推薦システム, *DEWS2003* (2003).
- 13) Breese, J., Heckerman, D. and Kadie, C.: Empirical Analysis of Predictive Algorithms for Collaborative Filtering, *14th Conference on Uncertainty in Artificial Intelligence* (1998).
- 14) 廣岡康雄, 寺野隆雄, 大塚雄吉: 意外性の高い情報を提供するリコメンダーシステム, 人工知能学会知識ベースシステム研究会資料, Vol.SIG-KBS-9904-11, pp.61-66 (2000).
- 15) Yu, Z. and Zhou, X.: TV3P: An Adaptive Assistant for Personalized TV, *IEEE Trans. Consumer Electronics*, Vol.50, No.1, pp.393-399 (2004).
- 16) 中西泰人: 選考関数を用いた対話型進化システムの制御と評価—遺伝的プログラミングのデザイン支援システムへの応用, 人工知能学会誌, Vol.13, No.5, pp.36-43 (1998).
- 17) 寺野隆雄: Web上の情報推薦システム, 情報処理, Vol.44, No.7, pp.696-701 (2003).
- 18) 北野宏明(編): 遺伝的アルゴリズム, 産業図書 (1995).
- 19) 伊庭斉志: 遺伝的アルゴリズムの基礎—GAの謎を解く, オーム社 (1994).
- 20) 萩原将文: ニューロ・ファジィ・遺伝的アルゴリズム, 産業図書 (1994).
- 21) Hinterding, Z., Michalewicz, R. and Eiben, A.: Adaptation in Evolutionary Computation: A Survey, *4th IEEE International Conference on Evolutionary Computation*, pp.65-69 (1997).
- 22) 木津左千夫, 澤井秀文, 足立 進: 可変な局所集団の適応的探索を用いたパラメータフリー遺伝的アルゴリズムとその並列分散処理への拡張, 電子


情報通信学会論文誌, Vol.D-II-82, No.3, pp.512-521 (1999).

- 23) 矢野絵美, 北野有亮, 末吉恵美, 篠原 勲, ピンヤンシニーナット, 加藤俊一: 消費者の感性モデルを利用したレコメンデーションシステムの構築, 情報処理学会論文誌: データベース, Vol.44, No.SIG 8 (TOD 18), pp.46-54 (2003).

(平成 17 年 3 月 20 日受付)

(平成 17 年 7 月 11 日採録)

(担当編集委員 飯沢 篤志)



加藤 由花 (正会員)

1989年東京大学理学部卒業。同年日本電信電話株式会社入社。ATM網におけるトラフィック制御に関する研究, 双方向マルチメディアシステムの研究開発等に従事。2002年電気通信大学大学院情報システム学研究科博士後期課程修了。博士(工学)。同年より電気通信大学大学院情報システム学研究科助手。分散マルチメディアシステム, ユーザ指向 QoS 制御手法等の研究に従事。電子情報通信学会, IEEE 各会員。



川口 賢二 (正会員)

2003年工学院大学工学部卒業。2005年電気通信大学大学院情報システム学研究科博士前期課程修了。同年ヤフー株式会社に入社。現在に至る。在学中, オンラインショッピングを対象としたリコメンダシステムの研究に従事。



箱崎 勝也 (正会員)

1963年九州大学工学部電子工学科卒業。同年日本電気入社。中央研究所ソフトウェア開発グループにおいてシステム性能評価, コンピュータアーキテクチャ, OS, ネットワークの相互接続性等の研究開発に従事。1994年から電気通信大学大学院情報システム学研究科教授。工学博士。分散システム技術, マルチメディア応用システム, モバイルコミュニケーションシステム等の研究に従事。電子情報通信学会, IEEE, ACM 各会員。