

選好商品のクラスタリングに基づく嗜好の変化の検出

松村 冬子^{†1,†2} 廣安 知之^{†3} 三木 光範^{†4}
佐々木 康成^{†4} 大向 一輝^{†5,†6} 武田 英明^{†5,†6,†7}

E-Commerce(EC) サイトでは、商品推薦を用いることで、より個々のユーザの嗜好に合った商品を提示し、売上の向上を図っている。しかし、商品を探索中のユーザの嗜好や興味は、そのサイトへのアクセス開始時から変化する場合が多い。本研究では、嗜好の変化に対応した新しい推薦手法を実現し、個々のユーザの嗜好が変化するように商品提示を行うことで、サイト滞在時間を延ばし、販売機会の増加を図ることを目指す。そのため、本論文ではその基礎的検討として、ユーザの選好情報をクラスタリングすることで嗜好を把握し、そのクラスタリング結果の時系列変化を嗜好の変化として検出する手法について検討した。実験では、嗜好の変化を反映可能なクラスタの特徴量を特定し、これに基づいてエージェントによる嗜好の変化を提案手法により検出可能であることを確認した。ただし、被験者実験においては、多くの被験者に対して探索のコンセプトの変化を検出することが困難であった。

Detection of the Preference Shift Timing based on Clustered Products Preferred by a User

FUYUKO MATSUMURA,^{†1,†2} TOMOYUKI HIROYASU,^{†3}
MITSUNORI MIKI,^{†4} YASUNARI SASAKI,^{†4}
IKKI OHMUKAI^{†5,†6} and HIDEAKI TAKEDA^{†5,†6,†7}

E-commerce sites improve their sales by presenting products that match users' preferences using recommendation methods. A user's preference may change during the shopping. In this paper, this change is called a "preference shift". However, conventional methods suppose that user's preferences are static. Here, a new method is proposed, which responds to the preference shift and this method leads users to remain at the site longer than before. This paper discusses the detection method for finding the preference shift timing based on the transition of the clustering result of the products preferred by a user. It was confirmed that the proposed method can detect the preference shift of the agents using a feature of clusters which can describe the preference shift. However, the proposed method could not detect the concept drift of actual users in the subjective experiment.

1. はじめに

E-Commerce(EC) サイトにおいて商品探索中のユーザの嗜好は、過去にシステムを利用した時点やアクセス開始時から変化する可能性があるが、既存の推薦手法ではこれらの嗜好の変化を考慮していない。しかし、嗜好の変化を利用して商品提示を変えることで^{(4),(5)}、ユーザの嗜好や興味を変化させ続けて、サイトへの滞在時間を延ばすことなどが考えられる。本論文では、ユーザがある時に EC サイトにアクセスし、商品購入を決定するまで、もしくはその EC サイトを離れるまでを「1 回のアクセス」と表現し、その短期間における嗜好の変化とその要因の検出を行い利用することで、ユーザの嗜好を変化させ続ける商品推薦の実現を目指す。これに伴い、どのような商品提示によって嗜好が変化するかを検討するため、本論文ではまず嗜好の変化を検出する手法として、ユーザの選好商品をクラスタリングし、その時系列変化を嗜好の変化として検出する手法について提案する。

2. EC サイトにおける嗜好の変化

人間の嗜好の変化については機械学習などの分野で古くから研究されており^{(9),(11)}、下記のように“段階性”⁽¹⁰⁾と“期間”という2つの観点によって分類可能と考えられる。

- 段階性
 - 緩やかに嗜好が変化する場合
 - 急激に嗜好が変化する場合

†1 同志社大学 大学院工学研究科

Graduate School of Engineering, Doshisha University

†2 日本学術振興会

Japan Society for the Promotion of Science

†3 同志社大学 生命医科学部

Department of Life and Medical Sciences, Doshisha University

†4 同志社大学 理工学部

Department of Science and Engineering, Doshisha University

†5 国立情報学研究所

National Institute of Informatics

†6 総合研究大学院大学

The Graduate University for Advanced Studies

†7 東京大学

The University of Tokyo

• 期間

- 1 回のアクセス中に嗜好が変化する場合
- 複数回のアクセスを通して嗜好が変化する場合

本研究で扱う嗜好の変化は、上記の分類における嗜好の段階性としては双方を考慮しつつ、1 回のアクセス中という短期間でユーザが理想とする商品の傾向が変化する場合として定義する。例えば、あるユーザがドレスを探している場合を考える。そのユーザは最初は黒いドレスばかりを探していたが、閲覧しているうちに画面下部に小さく提示されていた鮮やかな色のドレスも魅力的だと気づき、ピンクやオレンジなどのドレスを探すようになる状態を本研究で対象とする嗜好の変化とする。このようにユーザごとに嗜好の変化を検出し、そのときに提示した商品や画面配置などの嗜好の変化の要因を特定し、蓄積する。

近年では、Koren³⁾ や稲村ら¹³⁾ により嗜好の変化を考慮した商品推薦手法が提案されているが、どちらの手法においても最小の時間単位が 1 日であることから本研究で対象とする 1 回のアクセスという短期間での嗜好の変化を扱っていないといえる。

3. 嗜好を表現するモデル

本研究では、ユーザが EC サイトにアクセスすると商品候補が提示され、ユーザが何らかの方法で自身の選好情報をシステムに提示すると、次の商品候補が提示されるようなシステムを想定している。ここでは、商品を探索している瞬間に理想とする商品の持つ傾向を嗜好として定義する。このため、選好商品の情報に基づいて特徴空間において嗜好に合う領域を対話的に特定することで、ユーザの嗜好を把握する。

一般に、ユーザは興味を持った商品をクリックし、その詳細を確認するため、ここではそれらの選好商品の集合からユーザの嗜好のモデルを特定するものとした。また、商品はその色や形などの複数の属性から構成される特徴空間におけるベクトルで表すものとする。先に示したドレスの探索の例において、ドレスが色と価格の 2 次元の特徴ベクトルで表現できる場合、閲覧したドレスの履歴は図 1 のように特徴空間にプロットすることが出来る。ただし、ユーザの嗜好は常に 1 つの傾向を示しているとは限らない。そのため、図 1 右側の $t = 14$ における特徴空間に示しているように、選好商品の集合に対して特徴空間上でクラスタリングを行うことで、ユーザが同時に持つ複数の嗜好を把握する。すでに著者らは、対話型遺伝的アルゴリズムを用いた EC サイトの実験から、選好商品へのクラスタリングによりユーザの複数の嗜好を把握可能であることを確認している¹²⁾。このように、嗜好のモデルを選好商品のクラスタリングにより対話的に特定することが可能ではあるが、特定し




図 1 特徴空間上でのクラスタリングと嗜好の変化の例

Fig. 1 An example of preference shift and clustering of preferred products on feature space of products.

た嗜好のモデルは様々な要因により変化する可能性がある。次章ではこれらの嗜好の変化の特定方法について提案する。

4. クラスタリング結果の変化による嗜好の変化の検出

本研究では第 2 章に示したように、商品推薦におけるユーザの嗜好の変化を 1 回のアクセス中での理想とする商品の傾向の変化と定義し、この嗜好の変化を選好商品のクラスタリング結果の変化を基に検出する手法を提案する。提案手法では、選好情報の時系列データにデータが追加されるごとにクラスタリングを適用し、その変化を検出する。以下に提案手法の具体的な処理を示す。なお、時間は離散時間とし、選好商品が 1 つ追加されたごとに時刻 t が 1 だけ進むものとする

Step 1 時刻 t において選好商品が追加されたら、特徴空間にプロットする。

Step 2 ウィンドウに含まれる最新 n 個の商品を特徴空間においてクラスタリングし、クラスタ $A_0(t), A_1(t), \dots, A_i(t), \dots, A_m(t)$ を得る。

Step 3 時刻 t におけるクラスタ $A_0(t), A_1(t), \dots, A_i(t), \dots, A_m(t)$ と、時刻 $t-1$ におけるクラスタ $A_0(t-1), A_1(t-1), \dots, A_j(t-1), \dots, A_k(t-1)$ の全ての組合せにおいて、Jaccard 係数に基づき次式で 2 つのクラスタ間の相関を算出し⁷⁾、相関が高い組合せから同一のクラスタであるとする。

$$C_{A_{ij}(t)} \equiv \frac{|A_i(t-1) \cap A_j(t)|}{|A_i(t-1) \cup A_j(t)|} \quad (1)$$




図 2 2つのクラスターの重心間の距離 $d_c(t)$ および領域の差 $d_S(t)$

Fig. 2 $d_c(t)$ is the distance between centroids of two clusters. $d_S(t)$ is the difference between the regions of two clusters.

Step 4 時刻 $t-1$ と時刻 t において同一のクラスターである $A_i(t-1)$ と $A_i(t)$ の差の特徴量を算出し、特徴量もしくはその特徴量の過去のデータから予測されたモデルに対する残差が閾値よりも大きければクラスタリング結果が変化すると判断する。

Step 5 選好商品の追加が終わるまで、Step 1 から 4 を繰り返す。

上記の手順のとおり、提案手法では時刻 $t-1$ におけるクラスター $A_i(t-1)$ と時刻 t におけるクラスター $A_i(t)$ が同じクラスターであると見なせるときに、 $A_i(t-1)$ と $A_i(t)$ を比較することで変化を検出する。なお、本研究では過去の古いデータの影響を除去するため、新しい順から一定数 n のサンプルデータを用いるスライディングウィンドウ方式をとる。また、提案手法では時刻 $t-1$ と時刻 t における同一のクラスターを比較して嗜好の変化を表現できるクラスターの特徴量が必要となる。ここでは、嗜好を表現するクラスターが含むデータの分布から、それらの分散共分散行列の固有値を長径および短径とする超楕円体で近似する。時刻 $t-1$ と時刻 t における同一のクラスター $A_i(t-1)$ と $A_i(t)$ を比較するため、

- $A_i(t-1)$ と $A_i(t)$ に含まれるデータの重心間の距離 $d_c(t)$
- $A_i(t-1)$ と $A_i(t)$ を近似した超楕円体が特徴空間に占める領域の差 $d_S(t)$

といった2つの超楕円体の物理的特徴量を嗜好の変化を表すクラスターの差の特徴量の候補とする。特徴空間が2次元の場合の2つのクラスターの変化の特徴量の例を図2に示した。

次章以降では、 $d_c(t)$ および $d_S(t)$ についてクラスターの特徴量としての検討を行う。次に、その特徴量を用いた Step 4 に相当する変化の検出方法について検討を行い、最後に被験者

実験によって実際の人間の嗜好の変化を検出可能か検討を行う。

5. 嗜好の変化を検出可能なクラスターの特徴量の検討

5.1 検討概要

提案手法の中で、どのような特徴量がユーザの嗜好の変化を適切に表現できるのかは分かっていない。そのため本章では、現時点と前の時点との比較でクラスタリング結果の変化を表現するために用いるクラスターの特徴量について検討を行う。具体的には、エージェントに設定した嗜好の変化に合わせて、各クラスターの特徴量の変化を確認する。また、クラスターの特徴量の変化が人間の主観により観察される嗜好の変化と一致するかも被験者にエージェントの選好履歴を閲覧させて検討する。

5.1.1 実験システム

本実験ではクラスターの特徴量について基礎的な検討を行うため、図 5.1.1 に示した blog のテンプレートデザインを選択するサイトを対象とした。テンプレートは、ヘッダ、サイドバー、ボディの3つの部分から構成されている。その色の表現には人間の色彩感覚に類似しており、色相 (Hue) ($0 \leq H \leq 360$)、彩度 (Saturation) ($0 \leq S \leq 1$)、明度 (Brightness) ($0 \leq B \leq 1$) の3つの実数値で色を表現する HSB (Hue Saturation Brightness) 表色系を用いた。なお、色相の軸は0と360が等しく、循環している。ただし、自然な配色となるようにヘッダとサイドバーの色は同じとし、サイドバーのみ透明度を0.4とした。また、題字が黒である場合のテンプレートデザインとして自然な色調になるように彩度と明度を0.5以上に設定した。ボディの色は白色で固定した。そのため、テンプレートの特徴空間はそのヘッダの色の色相 H 、彩度 S 、明度 B の3次元で表現される。

実験システムでは画面の単位をページとし、図 5.1.1 に示したように1ページ毎に12個のテンプレートを提示した。エージェントもしくは被験者は各ページにおいて最も嗜好に合うテンプレートを1つだけクリックして選択するものとした。選択されたテンプレートは図 5.1.1 に示したように、赤色の枠で囲んで表示した。

5.1.2 エージェントにより生成される選好情報の時系列データ

下記の嗜好を持つエージェントに24個のテンプレートを選択させて4種類の時系列データを用意した。なお、単位時間は1つのテンプレートの追加で、 $1 \leq t \leq 24$ となる。

(1) 単一の嗜好が変化する場合

エージェントは実験システムにより提示されたテンプレートの中から、12ページに渡って特徴空間上の部分領域である R_{1a} に相当するテンプレートを選択し、残りの12ペー



図 3 実験システムのインタフェース
Fig. 3 Experimental setup.

ジに渡って R_{1b} に相当するテンプレートを選択する．このエージェントの嗜好が変化した時刻は $t = 13$ であり，嗜好の急激な変化を表現している．

(2) 複数の嗜好のうち一方が変化する場合

エージェントは提示されたテンプレートの中から，12 ページに渡って R_{2a} に含まれるテンプレートを 8 個， R_{2b} に含まれるテンプレートを 4 個選択する．以降は， R_{2c} に含まれるテンプレートを 8 個， R_{2b} からテンプレートを 4 個選択する．このエージェントの嗜好が変化した時刻は $t = 14$ であり，嗜好の緩やかな変化を表現している．

(3) 複数の嗜好が別の単一の嗜好に変化する場合

エージェントは，16 ページに渡って， R_{3a} と R_{3b} それぞれから 8 個のテンプレートをランダムな順序で選択し，17 ページ以降では R_{3c} に含まれる 8 個のテンプレートを選択する．この時系列データにおいて嗜好が変化した時刻は $t = 17$ であり，嗜好の急激な変化を表現している．

(4) 嗜好が変化しない場合

エージェントは一貫して R_{4a} に含まれる 24 個のテンプレートを選択し続ける．これより，この時系列データにおいては嗜好は変化しない．

5.1.3 クラスタリング手法

各商品のデータ間の類似度をエッジの重みとするネットワークを対象として，ネットワークからのコミュニティ抽出を行う Newman 法⁶⁾ を，重み付きネットワークに適用できるように改良した手法を適用する．Newman 法では，クラスタ数は自動的に決定可能である．また，クラスタリングの対象とするデータはスライディングウィンドウ方式により最新の n 個のデータを用いるものとする．本実験では $n = 9$ とした．

5.1.4 実験手順

被験者は 20 歳代の男女 8 名 (男性 6 名，女性 2 名) であった．まず，エージェントが各ページにおいて提示されたテンプレート群と，エージェントによりそのページで選択された商品を各ページについて図 5.1.1 のように表示し，紙に印刷した．1 ページから 24 ページに渡り，印刷されたテンプレート群と選択されたテンプレートを被験者に選択の時系列が分かるように一度に提示した．被験者は提示されたエージェントによるテンプレートの選択過程を見て，「エージェントの嗜好が一定していたか」「エージェントの嗜好はどのページ間で変化したか」を回答した．

5.2 実験結果と考察

各エージェントによるテンプレートの選択についてのクラスタの特徴量の変化を検討する．図 4 に各エージェントによる選好情報の時系列データの時刻 t における全てのクラスタの $d_c(t)$, $d_S(t)$ の合計値の推移を示した．図 4 の左側の縦軸は $d_c(t)$ の合計値を，右側の縦軸は $d_S(t)$ の合計値を表している．横軸は時刻 t を表している．図中の点線はエージェントに嗜好の変化を設定した時刻を示している．なお，クラスタリングはノード数がウィンドウのサンプル数 $n = 9$ と等しくなった時点から適用を開始している．

図 4 より，全てのデータに対して， $d_c(t)$ と比較して $d_S(t)$ の方がエージェントに設定した嗜好の変化に沿って増減していることが分かる．また，エージェント間で $d_S(t)$ の推移を比較すると，エージェント 1 および 3 については嗜好の変化を設定した時刻において大きく増加しているのに対して，エージェント 2 では増加はしているものの他の時刻においてより大きく増加していることが分かる．これはエージェント 2 のような緩やかな変化と比較して，エージェント 1 および 3 のような嗜好の急激な変化の方が $d_S(t)$ で表現しやすいことを示唆している．

次に，クラスタの特徴量が被験者の主観により観察された嗜好の変化を表現できているかを検証する．ここでは $d_c(t)$ より $d_S(t)$ の方がエージェントに設定した嗜好の変化を反映していることから，図 5 に $d_S(t)$ と時刻 t において嗜好が変化したと判断した被験者数の推移を示した．左側の縦軸は時刻 t において嗜好が変化したと回答した被験者数を，右側の縦軸は $d_S(t)$ の合計値を表している．横軸は時刻 t を表している．図 5 より，どのエージェントのデータの $d_S(t)$ も嗜好の変化を判断した被験者数の変化と推移が類似しているため， $d_S(t)$ は人間の主観から観察される嗜好の変化を表現可能と考えられる．




図 4 エージェントの嗜好に対する $d_c(t)$ と $d_S(t)$ の合計値の推移

Fig. 4 Transitions of sum of $d_c(t)$ and sum of $d_S(t)$ of preferred products of agents.

6. クラスタの特徴量による嗜好の変化の検出方法の検討

6.1 AR モデルによる嗜好の変化の検出

第 5 章の実験結果より、クラスタが特徴空間に占める領域の差 $d_S(t)$ により嗜好の変化を表現できる可能性が確認されたことから、本章では $d_S(t)$ を用いて嗜好の変化が生じた時刻を検出する手法について検討する。一般に時系列データからの異常検出などを行う場合には、時系列データのモデルを予測して現在時刻の予測値と実測値の残差を求め、その残差が大きい際に異常として検出する。ここでは、時刻 $t-1$ までの $d_S(t)$ を用いて得た p 次の自己回帰モデル (Auto Regressive Model, 以降 AR モデル)¹⁾ による時刻 t における残差を算出する。なお、Yule-Walker 方程式を用いて、最適な AR パラメータと次数 p を求めた。

6.2 クラスタの特徴量と AR モデルによる嗜好の変化の検出の比較

嗜好の変化が生じた時刻を特定するために、クラスタの特徴量 $d_S(t)$ の時系列データ、および $d_S(t)$ から AR モデルを予測して得た残差 $r(t)$ の時系列データの中で外れ値が生じた時刻を嗜好の変化した時刻として検出した。ここで外れ値を判定する閾値の候補として、それぞれの時系列データの平均 $+1SD$ (Standard Deviation, 標準偏差), 平均 $+2SD$ を用いた。




図 5 エージェントの嗜好に対する $d_S(t)$ の合計値と嗜好の変化を観察した被験者数の推移

Fig. 5 Transitions of sum of $d_S(t)$ of preferred products of agents and the number of subjects who saw preference shift.

実験結果より、 $d_S(t)$ では平均 $+1SD$ のときにエージェント 1, 2, 3 についてエージェントに設定された嗜好が変化する時刻を検出できていたが、嗜好が変化しないエージェント 4 の場合に多くの誤検出が生じた。一方、 $d_S(t)$ の予測モデルの残差である $r(t)$ では、平均 $+2SD$ のときにエージェント 1, 3 についてエージェントに設定された嗜好が変化する時刻を検出でき、嗜好の変化が設定されていないエージェント 4 については嗜好の変化を一切検出しなかった。ただし、緩やかに嗜好が変化するエージェント 2 の場合においてのみ $r(t)$ では設定された嗜好が変化した時刻を検出することが出来なかった。これは、エージェント 2 において嗜好の変化が設定された $t=14$ よりも $t=22, 23$ において $r(t)$ が増大していたためと考えられる。今後、その他の線形離散時間システムを用いることで緩やかな変化を検出可能か検討を行う。

7. 被験者実験による嗜好の変化の検出の検討

7.1 実験概要と手順

本章では実際に被験者に blog のテンプレートデザインを選択させ、その嗜好の変化を検出可能かを検証した。ここでは、被験者に探索途中に理想とするテンプレートのコンセプト

トを変更するように指示することで、意図的な探索目標のコンセプトの変化を第5章や第6章において検討した手法を用いて検出が行えるかを確認する。

本実験では被験者に第5章におけるエージェントでの実験と同様に、blogのテンプレートを24個選択させた。このとき、探索前半の $t=1$ から $t=12$ では「読者が男性(女性)であるblog」というコンセプトで、探索後半の $t=13$ から $t=24$ においては逆に「読者が女性(男性)であるblog」というコンセプトでテンプレートを選択させ、 $t=13$ でコンセプトの変化が生じるように被験者に指示した。なお、被験者は20歳代の男女10名(男性6名、女性4名)であり、これらのコンセプトの提示順は被験者間でカウンタバランスをとった。

7.2 実験結果と考察

本実験では被験者に $t=13$ においてコンセプトを変更してテンプレートを選択するように指示した。クラスタの特徴量 $d_S(t)$ とその予測モデルの残差 $r(t)$ により第6章の実験で検討した閾値によってコンセプトが変化した時刻の検出を行った。まず $d_S(t)$ により、被験者10名のうち平均 $+1SD$ では1名、平均 $+2SD$ では0名のコンセプトの変化を検出した。また、 $r(t)$ により、平均 $+1SD$ では4名、平均 $+2SD$ では3名のコンセプトの変化を検出した。これより、双方ともに多くの被験者のコンセプトの変化を捉えることができなかったが、 $d_S(t)$ と比較すると $r(t)$ の方がコンセプトの変化を検出できていることが分かった。

このように多くの被験者についてコンセプトの変化を検出できなかった原因として、被験者によってはコンセプトに合うテンプレートデザインの特徴が多岐に渡る場合が考えられる。つまり、同じコンセプトでの探索においても、複数の嗜好に対する選好がコンセプトの変化よりも強い嗜好の変化として検出される場合があったためと推測される。今後は単一のコンセプトに基づいて探索する場合について被験者実験により検証する必要がある。

8. 結 論

本研究ではどのような商品提示によって個々のユーザの嗜好が変化するかを検討するため、まずユーザの嗜好の変化を検出する手法について提案した。本論文ではユーザの選好商品をクラスタリングすることで嗜好を把握し、嗜好の変化を表現できるクラスタの特徴量、およびクラスタリング結果の時系列変化を嗜好の変化として検出する手法について検討した。

まず嗜好の変化を表現可能なクラスタの特徴量について検討を行った結果、クラスタに含まれるデータが特徴空間に占める領域の差である $d_S(t)$ により人間の主観に合った嗜好の変化を検出できることが確認された。また、 $d_S(t)$ による嗜好の変化の検出においては緩やかな変化よりも急激な変化を正確に把握できることが分かった。さらに嗜好が変化した時刻

の検出には $d_S(t)$ の時系列データにより予測されたARモデルの残差 $r(t)$ を用いることで、エージェントに嗜好の変化を設定した時刻を検出可能であることが分かった。一方、被験者実験において意図的に探索途中に導入したコンセプトの変化は多くの被験者において提案手法により検出することが困難であった。これは、男性向けや女性向けというそれぞれのコンセプトが複数の嗜好によって構成されていることから、1つのコンセプトによる探索中においても被験者の嗜好が変化する場合があり、誤検出などを生じることが原因だと考えられる。今後はウィンドウのサンプル数の検討、他の線形離散時間システムの利用の検討、単一のコンセプトに基づいた被験者実験などを引き続き行う。

参 考 文 献

- 1) Box, G.E.P. and Jenkins, G.M.: Time Series Analysis; Forecasting and Control. Holden-Day, San Francisco (1970)
- 2) Konstan, J.A., Miller, B.N., Maltz, D., Herlocker, J.L., Gordon, L.R. and Riedl, J.: GroupLens: applying collaborative filtering to usenet news. Communications of the ACM, Vol.40, No.3, pp.77–87 (1997)
- 3) Koren, Y.: Collaborative Filtering with Temporal Dynamics. In: the 15th ACM SIGKDD international conference on Knowledge discovery and data mining, pp.447–456 (2009)
- 4) Koufaris, M., Kambil, A. and LaBarbera, P.A.: Consumer Behavior in Web-Based Commerce: An Empirical Study. International Journal of Electronic Commerce, Vol.6, No.2, pp.115–138 (2002)
- 5) Mandel, N. and Johnson, E.J.: When Web Pages Influence Choice: Effects of Visual Primes on Experts and Novices. Journal of Consumer Research, Vol.29, No.2, pp.235–245 (2002)
- 6) Newman, M.E.J.: Fast algorithm for detecting community structure in networks. Physics Review E, Vol.69, Issue 6, 066133 (2004)
- 7) Palla, G., Barabasi, A.L. and Vicsek, T.: Quantifying social group evolution. Nature, Vol.446, No.7136, pp.664–667 (2007)
- 8) Sarwar, B., Karypis, G., Konstan, J. and Reidl, J.: Item-based collaborative filtering recommendation algorithms. In: Proceedings of the 10th international conference on World Wide Web, pp.285–295 (2001)
- 9) Schlimmer, J. and Granger, R.: Beyond incremental processing: Tracking concept drift. In: Proceedings of the 5th National Conference on Artificial Intelligence, pp.502–507 (1986)
- 10) Stanley, K.O.: Learning concept drift with a committee of decision trees. Tech Report UT-AI-TR-03-302, Department of Computer Sciences, University of Texas at Austin, USA (2003)
- 11) Widmer, G. and Kubat, M.: Learning in the presence of concept drift and hidden contexts. Machine Learning, Vol.23, No.1, pp.69–101 (1996)
- 12) 伊藤冬子, 廣安知之, 三木光範, 横内久猛: 対話型遺伝的アルゴリズムにおける嗜好の多峰性に対応可能な個体生成方法. 人工知能学会論文誌, Vol.24, No.1, pp.127–135 (2009)
- 13) 稲村博央, 野間裕子, 荻野晃大, 庄司裕子: 飽きずに継続利用できる情報推薦の実現に向けた試み. 電子情報通信学会 第二種研究会技術研究報告 (第15回 Web インテリジェンスとインタラクション研究会) (2009)