

商品探索時におけるユーザの嗜好のモデルの変化の獲得

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

f E-Commerce(EC) サイトにおいて、商品閲覧しているユーザの嗜好のモデルやその変化を獲得できれば、ユーザごとに適応した商品の提示や、商品の選び方などを利用したマーケティングが可能になり、売上の向上が期待できる。著者らは既に、ユーザが選好した商品をクラスタリングすることで、ユーザの嗜好のモデルを獲得する手法およびそのクラスタリング結果の変化に基づいて嗜好のモデルの変化を検出する手法について提案し、その有効性をエージェントによるシミュレーションによって検証している。後者の嗜好の変化を検出する提案手法の検証について、本稿では、これまでのシミュレーションによる検証に加えて、被験者実験により、嗜好の変化が生じるか、および実際に EC サイトを閲覧しているユーザの嗜好の変化を獲得可能かを検証した。

Extraction of The Shift of The Preference Model from User Behaviors on E-Commerce Sites

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

Extracting a user's preference model and its transition on e-commerce sites improves their sales by presenting products that match the user's preference and marketing based on product choices of users. A method to obtain a user's preference model based on clustering result of products preferred by the user, and a method to detect the preference shift timing were already proposed and confirmed their efficiencies by simulation result. In this paper, the existence of the actual user's preference shift on e-commerce sites and the availability of detection of its timing by the proposed method were confirmed in subjective experiments.

1. はじめに

多くの EC サイトでは、商品ページにユーザが購入する可能性が高いと予測される商品を共に提示するなど、商品推薦の仕組みを導入している。商品推薦では、ユーザの購買履歴などに基づいてユーザの嗜好を静的に予測している。ただし、実際には EC サイトにおけるユーザの嗜好のモデルは、提示される商品やその提示方法などの様々な要因によって、そのサイトにアクセスした時点や過去に利用した時点から変化する場合がある^{5),8),9)}。それに対して、協調フィルタリング (Collaborative Filtering, CF)^{3),13)} などの従来の推薦手法では、過去の様々な状況のユーザの嗜好に基づいて推薦を行うので、このような嗜好のモデル動的な変化を考慮していない。

そこで、著者らは、ユーザの動的な嗜好に対応した商品推薦やマーケティングの実現を目指して、EC サイトにおけるユーザの嗜好のモデルの変化を検出する手法^{2),16)}、および嗜好のモデルがどのように変化したかを分析する手法を提案した¹⁸⁾。なお、提案手法では、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の「1 回のアクセス」における嗜好のモデルの変化を対象としている。嗜好の変化を設定したエージェントによるシミュレーション結果から、提案手法により嗜好のモデルの変化を捉えられる可能性が示唆された。しかし、被験者実験による実際の人間の嗜好の変化を検出可能かは検討されていない。

本論文では被験者実験により、実際の人間の嗜好のモデルが変化する期間を提案手法で特定可能かを検証を行う。実験では、blog のテンプレートデザインを対象商品とする実験システムを構築し、被験者に嗜好に合う商品を選択させ、嗜好の変化の検出を行う。

2. 嗜好のモデルとその獲得

本研究では、全てのユーザが嗜好のモデルを内包しており、何らかの対象がそのモデルに

†1 同志社大学

Doshisha University

†2 日本学術振興会

Japan Society for the Promotion of Science

†3 国立情報学研究所

National Institute of Informatics

†4 総合研究大学院大学

The Graduate University for Advanced Studies

入力されると、そのユーザの嗜好にどの程度適合しているかが出力されるものとしている。この嗜好に適合している度合いを、嗜好への適合度と呼ぶ。嗜好のモデルは、入力に対して嗜好への適合度を出力することから、適合度関数と考えることができる。この嗜好のモデルもしくは適合度関数というものは、ユーザ自身にも分からない。

このような未知の嗜好のモデルを獲得する方法としては、ユーザがその嗜好のモデルに最も適合する対象を探索する過程から獲得することが考えられる。対話型遺伝的アルゴリズム (interactive Genetic Algorithms: iGAs)¹⁴⁾ はその一種であり、ユーザの評価に基づいて対象を最適化する。iGAにおいては、ユーザに最適解領域に相当する対象を提示できれば、良い探索であるといえる。つまり、適合度関数の峰を獲得する必要がある。そのため著者らは、適合度の高い峰が大域的に複数存在する場合に、選好商品の特徴空間におけるクラスタリングによって、それらの峰全てを獲得する手法を提案し、その有効性を確認している^{2),16)}。

3. 選好商品のクラスタリングによる嗜好のモデルの変化の検出

本研究では、選好商品のクラスタリングによってユーザの嗜好のモデルを獲得できることから、そのクラスタリング結果の変化から、嗜好のモデルの変化を検出する手法についても既に提案している¹⁸⁾。この提案手法は、嗜好の変化を設定したエージェントによって選好された商品の時系列データに適用され、その有効性が示されている。以降、嗜好のモデルの変化を検出する提案手法の詳細を述べる。

本研究では商品推薦におけるユーザの嗜好のモデルの変化を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している。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、得られたクラスタの特徴量の変化によって嗜好のモデルの変化を表現する。また、前の時刻までに得られたデータに基づいて自己回帰モデル (Auto Regressive Model, AR モデル)¹⁾ を構築し、その予測値と現在の時刻で得られた実測値の差から、嗜好のモデルの変化を検出する。

コンセプトの変化を検出する手法としては、FLORA^{6),7),15)} などが提案されているが、これらは1つのコンセプトの変化のみを追うものであり、提案手法のように複数の嗜好の傾向が存在する場合は想定されていない。また、近年では、嗜好の変化を考慮した推薦手法がいくつか提案されている^{4),17)}、それらは1回のアクセスという短期間を対象としていない点で、提案手法と異なる。

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^{11),12)}、相関が高い組合せから同一のクラスタであるとする。

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

- Step 4 時刻 $t-1$ と時刻 t において同一のクラスタである $A_i(t-1)$ と $A_i(t)$ の差の特徴量を算出し、時刻 $t-1$ までの特徴量のデータから構築された AR モデルによる予測値との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したと判断する。なお、最適な AR パラメータと次数は Yule-Walker 方程式により求めた。外れ値を判定する閾値には、予備実験から時系列データの平均 $+2SD$ (Standard Deviation, 標準偏差) を用いた。
- 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 $A_i(t-1)$ と時刻 t におけるクラスタ $A_i(t)$ が同じクラスタ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を比較して嗜好の変化を表現できるクラスタ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の平方根を各次元における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 $A_i(t-1)$ と $A_i(t)$ を比較するため、 $A_i(t-1)$ 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 $d_S(t)$ を嗜好の変化を表すクラスタの差の特徴量とする。特徴空間が2次元の場合の2つのクラスタの変化の特徴量の例を図1に示した。

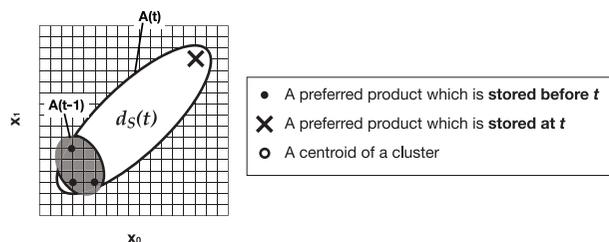


図 1 嗜好のモデルの変化の程度を表現する特徴量 (2つのクラスタの領域の差 $d_S(t)$)
Fig.1 $d_S(t)$ is the difference between the regions of two clusters.

4. 検証実験

4.1 実験概要

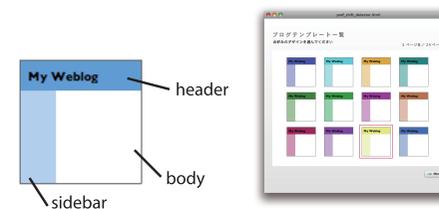
本章では、被験者に嗜好に合う商品を選択させ、その嗜好が変化する期間を検出可能かを検証した。実験システムとしては、blogのテンプレートデザインを対象商品とするECサイトを模擬して構築したシステムを利用した。被験者は20歳代の男女8名(男性6名、女性2名)であった。なお、被験者には次のような教示を与えて、実験に参加させた。

あなたは自分のblogを開設することになりました。
blogのテンプレートは全部で288個と大量なので、あなたはこのシステムを使って、その中から採用したいテンプレートの候補リストを作り、そして最終的に採用するものを決定することにしました。
では、blogのテンプレートの候補リストを、このシステムで作ってください。

4.2 実験システム

本実験では図2(a)に示したblogのテンプレートデザインを対象商品とするサイトを構築した。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。

このテンプレートは、図2(a)に示すヘッダの色の色相、彩度、明度の3次元の特徴空間の点として表現される。なお、本実験においては、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。そのため、特徴空



(a) blogのテンプレートデザインの構成 (b) 実験システムのインタフェース

図 2 実験システムのインタフェースと対象商品の表現
Fig. 2 Experimental setup and the expression of a product

間の定義域は、 $0 \leq H \leq 360$, $0.5 \leq S \leq 1.0$, $0.5 \leq B \leq 1.0$ となる。なお、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。ボディの色は白色で固定した。

なお、クラスタリング手法にはNewmanらが提案したネットワークからコミュニティを抽出する手法¹⁰⁾を用い、クラスタリングの適用対象とする最新の商品数、つまりウィンドウの幅 w には、7~12の6つのパラメータを適用し、その違いも検討する。

4.3 実験手順

実験システムでは画面の単位をページとし、図2(b)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。なお、選びやすいように、各ページにおいて色相が均等に提示されるように、提示するテンプレートを生成した。被験者は24ページに渡って288個のテンプレートを閲覧し、各ページにおいて嗜好に合うテンプレートを全てクリックして選択するものとした。なお、嗜好に合うテンプレートが提示されなかった場合はクリックしなくてよいものとした。選択されたテンプレートは図2(b)に示したように、赤色の枠で囲んで表示した。実験終了後、被験者に、自身のテンプレートの選び方や好みについてアンケートを実施した。

4.4 評価方法

本実験では、嗜好の変化を“出現 (appearance)”および“消滅 (disappearance)”の2パターンに分類できるものとし、各被験者の選好商品の時系列データがいずれかの変化のパターンを含むかを検証する。

まず、商品の探索期間を“序盤 (beginning)”, “中盤 (middle)”および“終盤 (end)”の3つの期間に分類する。本実験では24ページにわたって商品を探索するため、序盤は1~8

ページ, 中盤は 9~16 ページ, 終盤は 17~24 ページとした。

次に, 各被験者が選好した商品数が n のとき, 全体で i 番目に選好された商品は $x_i (i = 1, 2, \dots, i, \dots, n)$ と表されるものとする。

また, 被験者に選好された, ある x_k に類似した提示商品の集合を探索期間ごとに, $S_{beginning}(k)$, $S_{middle}(k)$, $S_{end}(k)$ と表現する。なお, ここでは, 2 つの商品 x_i と x_j の特徴ベクトルのユークリッド距離 $Distance(x_i, x_j)$ が次式で示される閾値 thr 以下である場合に, 2 つの商品が類似していると定義する。色相については, 各ページで提示個体数に合わせて均一に表示していたため, 定義域を提示個体数である 12 で分割した距離を, 彩度と明度については, その違いを視認することが困難なため, 定義域を 5 分割した距離を基に閾値 thr を設定した。なお, 次式における H_{max} , H_{min} , S_{max} , S_{min} , B_{max} , B_{min} はそれぞれ色相, 彩度, 明度の最大値および最小値を指す。

$$thr = \sqrt{\left(\frac{H_{max} - H_{min}}{12}\right)^2 + \left(\frac{S_{max} - S_{min}}{5}\right)^2 + \left(\frac{B_{max} - B_{min}}{5}\right)^2} \quad (2)$$

ここで, 被験者が選好した商品の集合 P を期間ごとに $P_{beginning}$, P_{middle} , P_{end} と定義する。被験者が選好したある商品 x_k に類似している商品のうち, 被験者が選好した商品の集合 $SP(k)$ を期間ごとに分けると, $SP_{beginning}(k)$, $SP_{middle}(k)$, $SP_{end}(k)$ となり, それぞれ $SP_{beginning}(k) = S_{beginning}(k) \cap P_{beginning}$, $SP_{middle}(k) = S_{middle}(k) \cap P_{middle}$, $SP_{end}(k) = S_{end}(k) \cap P_{end}$ と表現できる。

このとき, ある選好商品 x_k について, $S_{beginning}(k) \neq \phi$, $S_{middle}(k) \neq \phi$, $S_{end}(k) \neq \phi$ のもとで, 嗜好の出現および消滅は次のように定義される。

- 出現
 - $SP_{beginning}(k) = \phi$ かつ $SP_{middle}(k) = \phi$ かつ $SP_{end}(k) \neq \phi$ が成立する場合
 - $SP_{beginning}(k) = \phi$ かつ $SP_{middle}(k) \neq \phi$ かつ $SP_{end}(k) \neq \phi$ が成立する場合
- 消滅
 - $SP_{beginning}(k) \neq \phi$ かつ $SP_{middle}(k) = \phi$ かつ $SP_{end}(k) = \phi$ が成立する場合
 - $SP_{beginning}(k) \neq \phi$ かつ $SP_{middle}(k) \neq \phi$ かつ $SP_{end}(k) = \phi$ が成立する場合

つまり, 出現については, 序盤, もしくは中盤で, x_k に類似した商品が提示されているにもかかわらず選好されず, 中盤もしくは終盤になってその類似した商品を選択するような選好行動を指す。一方, 消滅についても同様に, 序盤, もしくは中盤で, x_k に類似した商品が提示され, 選好しているにもかかわらず, 中盤もしくは終盤になって, x_k に類似した商品が提示されても選択しなくなるような選好行動を指すものとする。

ただし, 同じ被験者が選好した商品 $x_i (I \neq k)$ について, $SP(k) \cap SP(l) \neq \phi$ であれば, 類似した嗜好の変化として $SP(k)$ と $SP(l)$ を統合して $SP(k) \cup SP(l)$ を 1 つの嗜好の変化とする。

これより, 被験者ごとに, その被験者の全ての選好商品の集合 P に含まれる商品 x_i について, 嗜好の変化を調査し, 各期間において, 全ての x_i について嗜好の出現と消滅が生じた述べ回数を, 各被験者の嗜好の変化の検証用データとする。本実験では, 被験者の選好商品の時系列から, 提案手法により嗜好が変化した期間を特定し, 各被験者の検証用データと比較する。

4.5 実験結果と考察

4.5.1 実際に生じた嗜好の変化の確認

まず, 被験者の選好した商品の時系列データから, 4.4 節の嗜好の変化の定義に基づいて, 検証用の嗜好の変化のデータを構築し, 嗜好の変化が実際に存在するか確認する。図 3 に被験者ごとに抽出した嗜好の出現と消滅の累計を示した。図 3 から分かるように, どの被験者にも嗜好の変化が生じていることが分かる。さらに, 嗜好の消滅は 8 名中 7 名という大半の被験者において観察されているが, 嗜好の出現を含む被験者は全体の半数の 4 名であった。

4.5.2 ユーザ自身の嗜好の変化に対する認識

また, 実験終了後に実施したアンケートの「実験中に好みや選び方が変わった, と感じる場合は具体的にその内容を教えてください」という問いに対する被験者の回答のうち, 嗜好の変化を具体的に認識していたのは, 被験者 8 名中 5 名であった。被験者が認識した嗜好については「途中で, 落ち着いた黄緑色のテンプレートを選ぶようになった」「濃い緑もいいかなと思った」などのように嗜好の出現に関する回答が多く見られたが, 嗜好の消滅を回

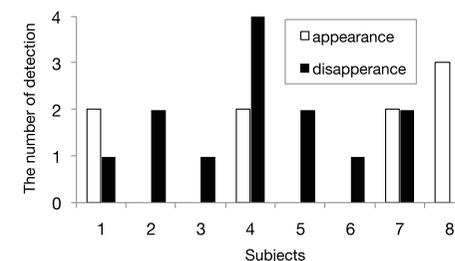


図 3 嗜好の出現と消滅の累計

Fig. 3 The numbers of appearance and disappearance of each subject's preference.

答した被験者は5名中2名のみに残った。このことから、ユーザは新たに出現した嗜好については自身でも認識できることが多いと考えられる。一方で、検証用データには出現よりも消滅の方が多く確認されているが、ユーザ自身では消滅した嗜好を認識することが困難な傾向があると考えられる。また、被験者が自認していた嗜好の変化と、その被験者の嗜好の変化の検証用データと一致したのは、5名中3名であった。これら3名のうち2名の選好商品の時系列からは、嗜好の出現と消滅の双方が確認されている。

4.5.3 提案手法による嗜好の変化が生じた期間の特定

次に、4.4節の嗜好の変化の定義に基づいて構築した検証用データに含まれる嗜好の変化と、選好商品の時系列クラスタリングに基づいた提案手法によって検出された嗜好の変化を比較する。商品探索の全体、そして序盤、中盤、終盤のそれぞれの探索期間における、検証データに含まれる嗜好の変化（出現、消滅は問わない）の提案手法による被験者間の平均検出率を図4に示した。図4の立て縦軸は検出率、横軸はウィンドウサイズ w （クラスタリングが適用される最新の商品数）を表している。

図4より、探索全体における最も高い検出率は、 $w = 8, 9, 10$ のときに確認された54%であった。このうち、 $w = 10$ については、各期間における検出率にばらつきが見られないことから、本実験においては $w = 10$ が嗜好の検出に最も適したウィンドウサイズであったといえる。また、どのウィンドウサイズの場合も序盤における検出率が、中盤および終盤よりも低い。検証データにおいて、序盤には嗜好の消滅のみが含まれているため、提案手法では嗜好の消滅の検出が出現よりも困難である可能性がある。

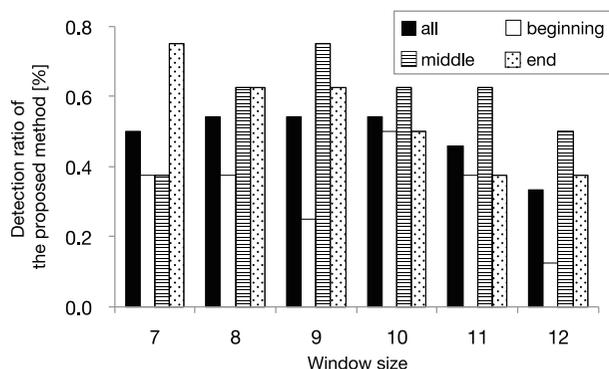


図4 検証用データに含まれる嗜好の変化の提案手法による検出率（被験者間平均）

Fig. 4 Detection rates of proposed method (Inter-subject average).

提案手法による検証用データに含まれる嗜好の変化の検出精度が高くない原因としては、その変化の捉え方の違いが挙げられる。提案手法では、ある時刻 t において、ウィンドウサイズの時間単位に含まれる商品群のみで局所的にクラスタリングを行い、隣り合う時刻との比較のみを行っている。それに対して検証用データでは、あるページに選好された商品を基点として、他の全てのページにおいてその商品と類似した商品が選好されているかを確認し、期間ごとの選好パターンによって嗜好の変化を抽出している。そのため、ウィンドウサイズよりも離れて類似した商品が選好された場合、提案手法と検証データでは異なる嗜好の変化を抽出すると考えられる。このため、今後はさらにウィンドウサイズのパラメータ検討を行うとともに、検証用データで確認されている嗜好の変化と、提案手法により検出される嗜好の変化の違いを確認する。

5. 結 論

本研究では、ECサイトにおける商品推薦やマーケティングへの活用を目指し、ユーザの嗜好のモデルやその変化を獲得する手法を提案している。提案手法では、ユーザが選好した商品群に対してクラスタリングを適用し、そのクラスタリング結果の変化から、嗜好のモデルの変化を特定する。提案手法の有効性は、嗜好の変化を設定したエージェントを用いたシミュレーションによって確認されている。本稿では、シミュレーションによる検証に加えて、ECサイトにおいて実際に人間の嗜好のモデルが変化するか、また、その変化を提案手法によって獲得可能かを被験者実験により検証した。被験者の選好商品の時系列データから、本実験における嗜好の変化の定義に基づき、抽出した嗜好の変化を検証用データとし、その検証用データに含まれる変化の提案手法による検出率を検証したところ、最も高い検出率は54%であった。これは、提案手法のクラスタリングの対象となる商品数（ウィンドウサイズ）より離れて、類似した商品が選好される場合に、提案手法と検証用データでは異なる変化を抽出することが原因の一つと考えられる。本実験における提案手法の検出性能は決して高くはないが、提案手法では嗜好のモデルが変化した期間を特定するだけでなく、嗜好のモデルを各時刻において獲得していることから、どのように嗜好のモデルが変化したか観察することが可能であると考えられる。これより、今後は提案手法によって得られた嗜好のモデルの変遷についても検討を行う。

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) Ito, F., Hiroyasu, T., Miki, M. and Yokouchi, H.: Discussion of Offspring Generation Method for Interactive Genetic Algorithms with Consideration of Multimodal Preference. Simulated Evolution and Learning, Lecture Notes in Computer Science, Springer, Vol.5361, pp.349–359 (2008)
- 3) 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)
- 4) Koren, Y.: Collaborative Filtering with Temporal Dynamics. In: the 15th ACM SIGKDD international conference on Knowledge discovery and data mining, pp.447–456 (2009)
- 5) 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)
- 6) Kubat, M.: Floating approximation in time-varying knowledge bases. Pattern Recognition Letters, Vol.10, pp.223–227 (1989)
- 7) Kubat, M. and Widmer, G.: Adapting to drift in continuous domains. Technical report, Austrian Research Institute for Artificial Intelligence, Vienna (1994)
- 8) 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)
- 9) Mandel, N., Nowlis, S.M.: The Effect of Making a Prediction about the Outcome of a Consumption Experience on the Enjoyment of That Experience. Journal of Consumer Research, Vol.35, No.1, pp.9–20 (2008)
- 10) Newman, M.E.J.: Fast algorithm for detecting community structure in networks. Physics Review E, Vol.69, Issue 6, 066133 (2004)
- 11) Palla, G., Derenyi, I., Farkas, I. and Vicsek, T.: Uncovering the overlapping community structure of complex networks in nature and society. Nature, Vol.435, No.7043, pp.814–818 (2005)
- 12) Palla, G., Barabasi, A.L. and Vicsek, T.: Quantifying social group evolution. Nature, Vol.446, No.7136, pp.664–667 (2007)
- 13) 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)
- 14) Takagi, H.: Interactive evolutionary computation: Fusion of the capabilities of ec optimization and human evaluation. In: Proceedings of the IEEE, Vol.89, No.9, pp.1275–1296 (2001)
- 15) 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)
- 16) 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)
- 17) 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), WI2-2009 (2009)
- 18) 松村冬子, 廣安知之, 三木光範, 佐々木康成, 大向一輝, 武田英明: 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)