

行動履歴を用いたユーザの状態推定

熊谷 雄介[†] 倉島 健[†] 高屋 典子[†] 内山 匡[†]

[†] 日本電信電話株式会社 NTT サービスエボリューション研究所 〒 239-0847 神奈川県横須賀市光の丘 1-1
E-mail: †{kumagae.yusuke,kurashima.takeshi,takaya.noriko,uchiyama.tadasu}@lab.ntt.co.jp

あらまし E-Commerce(EC) サイトにおいて問題になるのは、ユーザがカートに商品を投入したにも関わらず購入せず離脱してしまう事である。現状は購入から離脱したユーザに対して事後的にアクションが行われているが、もしユーザの欲求、特に購入に向けたユーザの内的状態、及びその変化を推定する事ができれば、購入を離脱する兆候を検出し、その瞬間に適切なアクションを行う事が可能になる。本研究では、EC サイトにおける行動履歴を用いたユーザの購入に影響を与える状態の推定を行う。本研究では「ユーザ自身の状態と、一つ前の行動とに従って、ユーザの現在の行動が決まる」という仮定を持つユーザ行動モデルを、階層型隠れマルコフモデルによって学習する。学習したユーザ行動モデルを実際の EC サイトにおけるアクセスログに対して適用することにより、ユーザの購入に向かう状態、及び状態間の変化について推定を行った。実験の結果、マルコフ連鎖と同程度の行動予測精度を保ちつつ、ユーザにおける状態の変化関係、購入に向かう、及び購入から離脱する状態の変化を発見するに至った。

キーワード ユーザ行動モデル, E コマース, 階層型隠れマルコフモデル

Yusuke KUMAGAE[†], Takeshi KURASHIMA[†], Noriko TAKAYA[†], and Tadasu UCHIYAMA[†]

[†] NTT Service Evolutions Laboratories, NTT Corporation

Corporation Hikarinooka 1-1, Yokosuka-shi, Kanagawa, 239-0847 Japan

E-mail: †{kumagae.yusuke,kurashima.takeshi,takaya.noriko,uchiyama.tadasu}@lab.ntt.co.jp

1. はじめに

E-Commerce(EC) サイトにおける重要な指標として、EC サイトを訪れたユーザが購入に至る割合であるコンバージョン率がある。EC サイトにおけるユーザに向けた施策、例えば新商品や類似した購入傾向を持つユーザが購入した商品を推薦するレコメンデーション、送料無料サービスやクーポンメールなどの値引き、ユーザインタフェースの改善、返品無料サービスなどは全てコンバージョン率を改善するために行われている。

コンバージョン率を下げる要因の一つとして、ショッピングカート (カート) ^(注1) まで商品を投入したユーザが閲覧行動を続ける中で購入を留保し、そのままサイトから離脱していく現象が挙げられる。そのような現象を回避するため、EC サイトでは様々な試みが行われている。例えば、ZOZOTOWN ^(注2) ではカートに投入されたままの商品は一定時間で削除されるようになっている ^(注3)。これは、カートに商品を投入したまま購

入しないユーザを追い立てる役割があると考えられる。また、Amazon.co.jp ^(注4) では「お買い忘れはありませんか?お客様のショッピングカートに、購入されずに残っている商品があります」といった文面のリマインダーメールを送信することにより、購入をためらっているユーザへの後押しを行なっている。

そういった状況において、EC サイト運営者が把握しようとしているのは購入へと向かう **ユーザの内的状態 (状態) の変化** である。ユーザの行動履歴からユーザの状態、及びその変化が記述できるならば、現状行われているように購入から離脱したユーザに後からアクションを取るのではなく、離脱へと向かう兆候を検出し、その瞬間に離脱を引き止めるアクションを取る事が可能になるからである。

よって本研究では EC サイトにおける行動履歴を用いたユーザの購入に影響を与える状態の推定を行う。本研究では、ユーザの状態を、データからは直接観測されない変数 (潜在変数) として扱い、潜在変数を含んだ行動モデルを学習することによって状態推定を実現する。本研究では、「ユーザ自身の状態と、一つ前の行動とに従って、ユーザの現在の行動が決まる」という仮定に基づき、階層型隠れマルコフモデル (HHMM) を用いて

(注1) : 実店舗におけるショッピングカートと同様に、EC サイトにおいて購入したい商品を一時的に登録する機能

(注2) : <http://zozo.jp/>

(注3) : http://zozo.jp/_help/default.html?cid=6#help_3200

(注4) : <http://www.amazon.co.jp/>

表 1 URL に対して付与した機能単位とその説明.

機能	説明
cart	ショッピングカート
info	特集などの静的コンテンツ
item	商品単体のページ
item_size	商品サイズ
list	商品の一覧
order	購入完了
preorder	住所入力などの購入手続き
sale	セール情報
search	キーワード検索の結果
top	トップページ

ユーザ行動モデルを表現する. 実際の EC サイトのアクセスログを用いた実験において, 単純なマルコフ連鎖と同程度の行動予測性能を保ちつつ, 購入へと向かう一連のユーザの状態推定, 特にそのまま購入へと進むか, 購入から離脱するかの状態の切り替わりを検出できるような状態, 及び状態間の変化を発見するに至った.

本論文の構成を述べる. 2 章では, 今回の実験において対象としたデータの性質について述べる. 3 章では本研究で仮定したユーザ行動モデルの詳細, 及び階層型隠れマルコフモデルによる推定について述べる. 4 章では EC サイトのアクセスログに対して実験を行い, 本研究のユーザ行動モデルの妥当性を検証する. 5 章では結論を述べ, 最後に 6 章において今後の課題について述べる.

2. 対象データ

2.1 概要

今回対象とするのは EC サイトにおける 2012 年 4 月のアクセスログである. アクセスログには EC サイトのアカウント情報が紐付いていないため, 今回はアクセスログに記録された IP アドレスを仮想的なユーザ id とし, IP アドレスごとにアクセスログを分割した. また, IP アドレスごとのアクセスログについても, 購入完了ページへのアクセスがあった時点で 1 つの**行動履歴**として分割を行った. これによって得られた行動履歴は 2,252 セッション, 392,053 ページビューからなる.

また, ユーザの行動単位をどのレベルで扱うかについては, ユニークな URL 単位で扱うとデータが非常に疎になってしまうため, URL を予め人手で設定した EC サイト固有のルールに基づき**機能単位**へと変換した. ルールの例を挙げると '/category/001/007/860/category860_0' という URL はカテゴリ id が 860 の商品一覧ページであるため, list という機能を付与した. 付与した機能の一覧を表 1 に示す. また, 今回の実験においては, ユーザがある機能単位にアクセスした事をユーザの行動と呼び, 機能単位あたりに変換したアクセスログを行動履歴として用いた.

2.2 行動履歴におけるマルコフ性

機能単位に変換した行動履歴の内訳を見ると, 特定の行動が非常に多く現れている. 例えば行動履歴から部分行動として全ての 4-gram(長さ n の行動履歴を $\{x_1, x_2, \dots, x_n\}$ とした場合,

表 2 全行動履歴の 4-gram における頻出閲覧行動の上位 10 件とその頻度. 太字は全て同じ機能を閲覧したもの.

閲覧行動	出現頻度
list, list, list, list	84,148
item_size, list, list, list	13,592
item_size, item_size, item_size, item_size	13,161
list, list, list, item_size	10,325
item_size, item_size, list, list	8,906
list, list, list, item	8,361
list, item_size, item_size, list	7,416
list, list, item_size, item_size	7,194
list, item_size, list, list	5,638
list, list, item_size, list	5,496

任意の位置 $t(\geq 4)$ における 4-gram は $\{x_{t-3}, x_{t-2}, x_{t-1}, x_t\}$ である) を列挙したものが表 2 である. 最も多く登場する部分行動は list を 4 連続で閲覧するものであり, その合計回数は 84,148 回, 全部分行動 385,297 回の約 22% を占めている. 次に登場する部分行動も item_size のあとに list を 3 回閲覧する行動 (13,592 回), item_size を 4 連続で閲覧する行動 (13,161 回) などである. このような順序的規則性 (マルコフ性) の強さは, ユーザが Web ページの構造に従った行動を取る傾向にあるからだと考えられる. そのため, 「ユーザの行動履歴 $\{x_1, x_2, \dots, x_t\}$ が与えられた場合, そのユーザが x_{t+1} にどのような行動を取るか」という行動予測問題を行うのであれば, 単純な n 次のマルコフ連鎖

$$\hat{x}_{t+1} = \arg \max_x \frac{\#x}{\#\{x_{t-n+2}, x_{t-n+3}, \dots, x_t\}}$$

によって 6 割程度の精度で予測を実現することが予備実験の結果判明している. しかしこの精度は, 同一機能の連続した閲覧行動, 例えば「list を 3 回連続で見た時次に list を見る」といった行動や, 前述した頻出する閲覧行動の予測における成功が多くを占めているが, そのようなユーザ行動の予測が真に必要なとされているとは言い難い. 重要なのは「リストを連続して閲覧していたユーザがいつ別のページにアクセスするか」といったような, 同一機能の連続した閲覧行動からの変化の予測であり, 特に「リストを連続して閲覧していたユーザがある商品ページにアクセスするか」「商品ページからカートにアクセスするか」といった購入に繋がる行動の予測である. 詳しくは後で述べるが, そういった場合においてはマルコフ連鎖による予測では精度が低くなる事が判明している.

3. 隠れマルコフモデルに基づく状態推定

3.1 ユーザ行動モデルにおける仮定

本研究の目的はユーザの状態推定であり, ここで推定する**状態**とは, 「**ユーザのある時点での心理的なありさまであり, ユーザの行動に影響を与える要因の一つ**」である. 本研究では, ユーザの行動選択に影響を与える一要因としてユーザ状態を表現した行動モデルを観測された行動履歴から学習し, ユーザの状態推定を実現する.

ここで我々は, ユーザの行動と状態の関係性に関して次のよ




図 1 階層数 2 の階層型隠れマルコフモデルのグラフィカルモデル。
 z_{ij} は潜在変数, x は観測変数であり, 矢印は依存関係を示している。

うな仮定を設けた。

仮定 1 ユーザ自身の状態と、一つ前の行動とに従って、ユーザの現在の行動が決まる。

仮定 2 行動クラスが決まれば、ユーザが実際に取る行動が決まる。

仮定 3 一つ前のユーザの状態に従ってユーザの現在の状態が決まる。

この具体例として、ある女性の買い物の様子を考える。暇つぶしのためにファッションブランドにやってきた彼女はコートや靴などを手にとっては棚に戻している。そんな中、気に入ったブラウスを見つけた彼女は試着をし、店員に話しかけ自分に似合うかどうか尋ね、財布を取り出したとする。この時、例えば店内の監視カメラによって観測されるのは「コートを手に取りすぐに戻す」「靴を手に取りすぐに戻す」「ブラウスを手に取る」「試着する」「店員と会話する」「財布を取り出す」といった**実際に取った行動**である。しかし、彼女がとった「コート/靴を手に取りすぐに戻す」といった一連の行動は「ウインドウショッピングをする」といった行動の集合、すなわち**行動クラス**として解釈することが可能である。同様に、「ブラウスを手に取る」「試着する」「店員と会話する」「財布を取り出す」といった行動は「商品を吟味する」という行動クラスとして解釈することが可能である。また、その行動の背後では、彼女の「漠然と商品を見ている」という**状態**が「商品を買おうか迷っている」という状態に変化している。

ここで行動と状態の関係を考える。まず、商品を買おうか迷っている状態の人は漠然と商品を見ている状態の人よりも「商品を吟味する」という行動を行いやすいと考えられる。また、「商品を吟味する」という行動をとっている人はウインドウショッピングをしている人よりも試着しやすいと考えられる。また、漠然と商品を見ている状態の人がウインドウショッピングを行ううちに気になる商品を見つけ、買おうか迷っている状態に変化するということも考えられる。よって、行動と状態の間にはマルコフ性が存在すると考えられる。このようなユーザ行動に関する仮定は階層型隠れマルコフモデル (HHMM) [4] で表現可能である。次章にその理由を述べる。

3.2 階層型隠れマルコフモデル

階層型隠れマルコフモデル (HHMM) [4] は隠れマルコフモデル (HMM) [16] を階層的に表現したものであり、図 1 は HHMM のグラフィカルモデルである。これからわかるように、HHMM では各階層における潜在変数間にマルコフ性が存在するとしてモデル化を行なっている。HHMM の大きな特徴はこの階層性である。3.1 章で述べた実際に取った行動、行動クラス、状態の関係性は、図 1 における最も上の層の要素が状態、上から二段目の層が行動クラス、最下層が実際に取った行動として表現することが可能である。すなわち、HHMM を用いる事により、今回仮定したユーザ行動モデルの推定が可能になる。また、事前知識として観測変数に何らかの規則性があり、長期間同じパターンが続く事を知り得ている場合や、潜在変数のある程度の期間持続するような形で推定したい場合などに HHMM を用いると、潜在変数の敏感な変化が第 d 階層で起こったとしても、そのひとつ上の第 $d-1$ 階層における潜在変数には変化が起こりにくくなっている。その結果として、細かな潜在変数の変化を観測することなく、より長期的に変化する潜在変数の推定が可能となる。

階層数 D の HHMM は、長さ N の観測変数列 $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ が与えられた時に、その背後に存在する長さ最大 $N \times D$ の潜在変数列 $\mathbf{Z} = \{z_1^1, z_1^2, \dots, z_1^D, z_2^1, \dots, z_N^D\}$ 、潜在変数と観測変数の関係、及び潜在変数間を推定するモデルである。以下、前提として観測変数及び潜在変数が離散値であり、観測変数 x は W 種類の値を取りうる離散値であり、1-of- W 符号で表現されたものとする。潜在変数 z についても同様に 1-of- K 符号で表現されたものとする。また、潜在変数 z については t 番目の観測変数における第 1 階層から第 d 階層までの潜在変数の集合を $\mathbf{z}_t^{1:d}$ で表し、 j 番目の観測変数 i である場合 $x_{j,i} = 1$ 、同様に第 t 階層における j 番目の潜在変数が i である場合には $z_{j,i}^t = 1$ と表す。

HHMM において推定すべきモデルのパラメータは第 d 階層の t 番目の観測変数における潜在変数 $\mathbf{z}_{t,i}^d, \mathbf{z}_{t,j}^d$ 間の**遷移確率** $\mathbf{A}_{ij}^d \equiv p(z_{t,j}^d = 1 | z_{t-1,i}^d = 1)$ 、観測変数 $x_{*,i}$ が潜在変数 $\mathbf{z}_*^{1:D}$ から出力される確率 (**出力確率**) $\phi_{i,j} \equiv p(x_{*,i} = 1 | \mathbf{z}_*^{1:D})$ 、及び**初期状態確率** π の三つである。HHMM におけるモデル推定とはパラメータ $\theta = (\pi, \mathbf{A}, \phi)$ を推定する事である。

階層数 D の HHMM では、任意の第 d 階層における状態 $\mathbf{z}_t^d$ は $t-1$ における第 1 階層から第 d 階層すべての状態 $\mathbf{z}_{t-1}^{1:d} = \{z_{t-1}^1, z_{t-1}^2, \dots, z_{t-1}^d\}$ に依存している。同様に、観測変数 x_t についても t における第 1 階層から第 D 階層すべての状態 $\mathbf{z}_t^{1:D} = \{z_t^1, z_t^2, \dots, z_t^D\}$ に依存している。よって、遷移確率において階層性が存在する。すなわち、全ての階層 $d = 1, \dots, D$ について状態変数間の遷移確率 $\mathbf{A}_{ij}^d$ の推定が必要になる。出力確率 ϕ については $\{z_t^1, z_t^2, \dots, z_t^D\}$ で条件付けされているとはいえ、通常の HMM と同様に扱う事が可能である。

まとめると、観測変数列 $\mathbf{X}$ と潜在変数列 $\mathbf{Z}$ の間には

$$p(\mathbf{X}, \mathbf{Z} | \pi, \mathbf{A}, \phi) = p(\mathbf{z}_1^1 | \pi) \prod_{n=2}^N p(\mathbf{z}_n^D | \mathbf{z}_{n-1}^{1,D}, \mathbf{A}) \prod_{m=1}^N p(x_m | \mathbf{z}_m^{1,D}, \phi)$$

の関係が成立する。

HHMM のパラメータ推定には一般化 Baum-Welth アルゴリズム [4], 活性化 Forward-Backward アルゴリズム [18], ジャンクションツリーを用いたアルゴリズム [14] などが存在する。等価な階層化されていない通常の HMM に置き換える事が可能 [19] であるため、一般的な HMM のパラメータ推定の手法も利用可能である。今回は HHMM を通常の HMM に置き換えた上で MCMC(Markov Chain Monte Carlo) [11] を用いてパラメータ推定を行った。

3.3 状態推定

ここまで述べたのは、HHMM を用いたユーザの行動履歴に基づく状態間の関係 $\mathbf{A}$ 及び、状態と行動の関係 ϕ の推定手法である。本研究の目的はユーザの状態推定である。そのため、長さ N の行動履歴 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ が与えられた時に、それぞれの $1, \dots, N$ 番目における行動の状態を推定した上で、まだ行動が観測されていない $N+1$ 番目における状態の推定を行う。そのためには、 $\mathbf{X}$ を用いてパラメータ $\theta = (\pi, \mathbf{A}, \phi)$ を推定した上で、潜在変数を取りうる値 $i = 1, \dots, K$ について t 番目の行動における前向き確率 $\alpha_t(i)$ を次式に従って求める。

$$\alpha_t(i) = \begin{cases} p(\mathbf{z}_1^D | \pi, \mathbf{A}) p(\mathbf{x}_1 | \mathbf{z}_1^{1,D}, \phi) & (t = 1) \\ p(\mathbf{x}_t | \mathbf{z}_t^{1,D}, \phi) \sum_{k=1}^K \alpha_{t-1}(k) p(\mathbf{z}_t^D | \mathbf{z}_{t-1}^{1,D}, \mathbf{A}) & (t > 1) \end{cases}$$

この前向き確率 $\alpha_t(i)$ はいわば、「ユーザの行動 t において状態 i が存在する程度」と解釈できる (正確には $\frac{\alpha_t(i)}{\sum_i \alpha_t(i)}$ とする必要がある)。そのため、これを $1, \dots, N$ まで求める事により、ユーザの各行動時における状態を推定する事が可能である。通常の HHMM であれば、この前向き確率に対し Viterbi アルゴリズムなどを適用することにより、観測変数それぞれについて最も取りうる潜在変数を 1 つずつ決定するという処理を行うが、今回はユーザの状態は一意に定まるものではなく、ひとつの行動において複数の状態が重ね合わせで表現されていると考えるため、前向き確率のみを用いて表現する。また、ユーザの $N+1$ 番目の行動、すなわちまだ観測されていない行動における状態については、 N 番目の行動における前向き確率 $\alpha_N(i)$ 及び遷移確率 $\mathbf{A}$ を用いて

$$\sum_{k=1}^K \left[\alpha_N(k) p(\mathbf{z}_t^D | \mathbf{z}_{t-1}^{1,D}, \mathbf{A}) \right]$$

として求める。

推定した $N+1$ 番目の行動における状態を用いて、ユーザの $N+1$ 番目の行動を予測する事も可能である。そのためには、

$$p(x_{N+1,j} = 1) = \sum_{k=1}^K \alpha_N(k) p(\mathbf{x}_{N+1} | \mathbf{z}_{N+1}^D, \phi) p(\mathbf{z}_{N+1}^D | \mathbf{z}_N^{1,D}, \mathbf{A})$$

が最大となる行動を予測行動とする。これは、 $N+1$ 番目の行動における状態を推定した上で、その状態から出力される可能性が最も高い行動を出力するという操作である。

4. 実験

本来の目的であるユーザの購入に向けた状態を推定するため、




図2 第1階層における潜在変数間の遷移関係、及び潜在変数ごとの取りうる行動を有向グラフにしたもの。枝は各状態における遷移確率について、自己遷移確率を取り除いたものの中で実線は最も強かったもの、破線は次いで強かったものである。

HHMM を用いた実験を行い、その解釈が可能かを検証する。その後、ユーザの行動を説明するモデルとして、推定された状態が妥当であるかの検証として行動予測実験を行う。

4.1 状態推定

この実験では HHMM を用いて状態推定を行った。パラメータ $(\pi, \mathbf{A}, \phi)$ の推定には 2.1 で述べた 2,252 件の行動履歴のうち、半分の 1,126 件を用いた。潜在変数の数については第1階層の潜在変数数を 3 から 6 まで、第2階層の潜在変数数は 3 から 5 までとした。パラメータ推定はディリクレ過程に基づく MCMC [11] によって 500 回のサンプリングを行った。基底測度には一様分布を用い、ハイパーパラメータ α, β は共に 0.1 とした。

4.1.1 推定結果

表3及び表4に示したのは推定された HHMM における第1階層、つまり状態を示す潜在変数における潜在変数間の遷移確率 $\mathbf{A}$ 及び潜在変数、つまり状態ごとの行動の出力確率 ϕ のそれぞれ上位3つである。この時、出力確率 ϕ については、第2階層に関わらず、第1階層と観測列のみに着目するため、状態 j から行動 i が出力される確率 $p(x_{*,i} = 1 | z_{*,j}^1 = 1)$ を、

$$p(x_{*,i} = 1 | z_{*,j}^1 = 1) = \frac{\sum_k^K p(x_{*,i} = 1 | z_{*,j}^1 = 1, z_{*,k}^2 = 1)}{\sum_w^W \sum_k^K p(x_{*,w} = 1 | z_{*,j}^1 = 1, z_{*,k}^2 = 1)}$$

として求める。また、潜在変数間の関係、及び潜在変数と出力行動の関係についてより明確にするため、自己遷移を取り除いた上で潜在変数の遷移関係を有向グラフとして図2に示す。

まず潜在変数、すなわち状態の遷移確率 (表3) について着目すると、状態2、状態3、及び状態4の自己遷移確率が非常に高い状態となっている。自己遷移確率が高いということは、これらの状態は継続して現れる傾向が強いという事を意味している。反対に、状態5の自己遷移確率の低さは、状態5がすぐに他の状態に移り変わる事を意味している。続いて状態ごとの出力確率 (表4) に着目し、各状態においてどのような行動が特徴的なのかの解釈を行う。最も特徴的なのは状態3における cart の出力確率の高さである。よって状態3は購入への意志が高まり、商品をカートに入れる、言わば「買う気が生じ始めている」

表 3 状態ごとの遷移確率上位 3 件.

FROM	TO	Prob	FROM	TO	Prob	FROM	TO	Prob
0	0	0.5626	1	1	0.5769	2	2	0.8636
	3	0.1869		5	0.3512		3	0.0647
	2	0.0928		4	0.0709		1	0.0394
FROM	TO	Prob	FROM	TO	Prob	FROM	TO	Prob
3	3	0.8294	4	4	0.9450	5	5	0.3847
	2	0.0858		2	0.0174		1	0.3812
	0	0.0725		3	0.0119		2	0.1340

表 4 推定した状態ごとの出力確率上位 3 件.

状態	行動	確率	状態	行動	確率	状態	行動	確率
0	top	0.4250	1	list	0.5847	2	item_size	0.3727
	preorder	0.1407		item_size	0.3728		list	0.3011
	search	0.1098		top	0.0228		item	0.2261
状態	行動	確率	状態	行動	確率	状態	行動	確率
3	cart	0.3698	4	list	0.4377	5	list	0.5272
	item_size	0.2911		item_size	0.2806		item	0.4054
	list	0.2078		top	0.1758		top	0.0199




図 3 購入へ向かう状態の遷移関係


状態であると解釈できる。また、状態 0 についても、preorder, すなわち購入手続きの出力確率が高い状態である。よって、状態 0 は「買う気が非常に高まっている」状態である、と解釈できる。しかし、これら 2 つの状態以外では、list や item_size といった行動が出力確率の上位に存在しており、行動の出力確率レベルでの解釈は困難である。

そこで、状態間の遷移確率と出力確率を組み合わせた図 2 を用いて、購入への気分の高まりを遡ることにより状態の解釈を行う。まず、ユーザが状態 0、すなわち購入への気分が非常に高まる前の状態を見てみると、状態 3 から遷移している事が判る。これは、出力確率を見ても「cart に入れたのち、preorder に進む」という行動と合致する。では、状態 3 にはどの状態から遷移しているかを確認すると、状態 2 から強く遷移しているのがわかる。状態 2 において行われる行動は item_size, list であり、これはすなわち、「カートに商品を入れる前に、商品一覧ページや商品サイズを確認している」という行動だと解釈できる。同様に、状態 2 には状態 5、及び状態 4 から、状態 5 には状態 1 から、状態 4 には状態 1 から遷移しているのが確認できる。


この関係を図示したのが図 3 である。注意すべきは、状態の

変化は図 3 では非可逆で描かれているが実際は図 2 で示したように可逆性があるという点である。この図から、購入へと向かうユーザの状態の変化を考えると「状態 1 → 状態 5 → 状態 2 → 状態 3 → 状態 0」、及び「状態 1 → 状態 4 → 状態 2 → 状態 3 → 状態 0」の 2 つの変化があることが見て取れる。ここで重要なのは状態 4 における自己遷移確率の高さである。この自己遷移確率の高さと状態 4 における出力確率が最も高いものが list であることを合わせると、状態 4 は「商品一覧ページを連続して閲覧し続ける状態」と解釈できる。また、状態 4 から状態 2 への遷移確率は 0.0174 と非常に低いため (よって図 3 では破線で記した)、状態 4 から状態 2 へと変化して購入へと向かうのは非常に困難であると考えられる。すなわち、状態 4 は購買からの離脱へと向かう状態、「半離脱状態」と考えられる。よって、EC サイト側としては、ユーザの状態が半離脱状態へと変化するのを避ける必要がある。そのためには状態 1 の時点でアクションを取り、半離脱状態への遷移を阻止し、ユーザを状態 5 に遷移させる事が必要であると解釈できる。その場合、ユーザのこれまでの状態変化に応じて二種類のアクションが考えられる。まず、商品をカートに入れるなどしていたユーザが購入を留保し、状態が半離脱状態に変化し始めた場合には、「この商品は残り x 点です」といった購入への煽りや、「今注文すると $X\%$ 割引」といった値引きを行う事により、ユーザの状態を再度購入へと高めるためのアクションを取る必要がある。また、EC サイトの閲覧開始時からユーザの状態が購入へと近づいていない場合に半離脱状態に変化した場合には、レコメンデーションなどを行う事によって、ユーザに当該 EC サイトに対する興味を抱かせる必要がある。

このモデルによって推定したユーザの状態を図 4 に示す。図 4(a) は購入に向かう行動履歴における状態の推定結果の一例である。これは、商品一覧ページを閲覧していたユーザが商品



(a) 購入に向かう行動履歴における推定した状態の変化。



(b) 購入から遠ざかる行動履歴における推定した状態の変化。

図 4 推定した状態変化。横軸は左から時系列順に並べた行動履歴であり、縦軸は各状態がその行動を行った際に占める割合である。

をカートに投入し、購入手続きまで進むも一度カートに戻るという行動履歴であるが、状態 2 から状態 3、状態 0 へと、ユーザの状態がゆるやかに図 3 で示したような変化を起こしているのが把握できる。状態 3 が強くなる過程に着目してみると、商品一覧ページから商品サイズ、商品ページへと遷移するに従って状態 3 が高まっている事が確認できる。これは、ユーザが商品一覧から嗜好に合う商品を見つけ、購入への意欲が高まった状態として解釈できる。また、購入手続きに一度進んだあとにカートに戻っているが、この時でも状態 0 が弱くなっているとはいえ、持続しているのが確認できる。このような行動を行った場合、HMM では状態が変化してしまうが、HHMM では状態を維持し続けることが可能になっている。

また、図 4(b) は購入から遠ざかる行動履歴における状態の推定結果の一例である。この場合、list の連続閲覧によって状態 4 が高くなっているが、6 回目の list へのアクセスにおいて状態 1 の値が高くなっており、その後、半離脱状態 (状態 4) が強くなり続けている。よって、この状態 1 が高くなった時点が購入への意欲が強くなるか否かの分岐点だった事が推定できる。

4.2 行動予測

続いて、4.1 章で推定したモデルがユーザの行動を説明するものとして妥当かどうかを検証すべく、行動予測実験を行う。

4.2.1 実験設定

行動予測実験の入力と出力は次のものである。

学習 行動履歴集合 $\mathcal{D}_{train} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n\}$

入力 長さ t_i の行動履歴 $\mathbf{X}_i = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{t_i}\}$ の集合

$\mathcal{D}_{predict} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m\}$

出力 $t_i + 1$ 番目に行われるとされる行動 $\hat{\mathbf{x}}_{t_i+1}$ の集合 $\{\hat{\mathbf{x}}_{t_i+1}, \hat{\mathbf{x}}_{t_i+2}, \dots, \hat{\mathbf{x}}_{t_i+m+1}\}$

評価 $t_i + 1$ 番目に実際に行われた行動 $\mathbf{x}_{t_i+1}$ の集合 $\{\mathbf{x}_{t_i+1}, \mathbf{x}_{t_i+2}, \dots, \mathbf{x}_{t_i+m+1}\}$ との適合率、再現率、及び F 値による比較

行動履歴における各要素 $\mathbf{x}$ が取りうる値は cart, info, item, item_size, list, order, preorder, sale, search, top の 10 種類である。今回は購入につながる重要な行動である「カートへ商品を入れる」及び「商品ページにアクセスする」という二つの行動の予測を重視し、各入力行動履歴 $\mathbf{X}_i$ における予測対象行動 $\mathbf{x}_{t_i+1}$ は全て item, cart のいずれかとした。また、1. 章でも述べたように、予測対象である行動 $\mathbf{x}_{t_i+1}$ がその前から連続して k 回行われている場合、すなわち $\mathbf{x}_{t_i+1} = \mathbf{x}_{t_i} = \dots = \mathbf{x}_{t_i-k}$ の時には $\mathbf{x}_{t_i+1}$ の予測は容易である。よって今回は、予測対象である行動 $\mathbf{x}_{t_i}$ は全て一つ前の行動と異なるものであり、すなわち $\mathbf{x}_{t_i} \neq \mathbf{x}_{t_i-1}$ を満たすものとした。

学習データには 2.1 で述べた 2,252 件の行動履歴のうち、半分の 1,126 件を用いた。予測対象は学習データに含まれない行動履歴のうち、これらの条件を満たすものとして、cart, item をそれぞれ 2,000 点を予測対象とした。

予測手法については、マルコフ連鎖、HMM, HHMM を比較した。マルコフ連鎖は 2.2 章で述べたように、予測対象である $\mathbf{x}_{t+1}$ を n 個前のデータを遡り、

$$\hat{\mathbf{x}}_{t+1} = \arg \max_{\mathbf{x}} \frac{\#\mathbf{x}}{\#\{\mathbf{x}_{t-n+2}, \mathbf{x}_{t-n+3}, \dots, \mathbf{x}_t\}}$$

に従って予測するものである。それぞれのパラメータについては、マルコフ連鎖は次数を 1 から 5 まで、HMM については潜在変数数を 3 から 5 まで、HHMM については第 1 階層の潜在変数数を 3 から 6 まで、第 2 階層の潜在変数数を 3 から 5 までを設定し、計 38 パラメータで実験を行った。パラメータ推定はディリクレ過程に基づく MCMC によって行い HMM は 1000 回、HHMM は 500 回のサンプリングを行った。基底測度には一様分布を用い、ハイパーパラメータ α, β は 0.1 とした。モデルの評価指標としては適合率 (A と予測したものうち、真に A だったものの割合)、再現率 (真に A だったもののうち、A と予測されたものの割合)、F 値 (適合率と再現率の調和平均) を用いた [2]。

4.2.2 結果

実験結果を表 4 に示す。HHMM についてはそれぞれの F 値が高いモデル 2 つを掲載した。

まず、1 次及び 2 次のマルコフ連鎖、及び HMM では item への遷移を全く予測できていない事が判る。低次のマルコフ連鎖については 2.2 章で述べたように、パターン性が強く遷移行動の予測には向かないことがここから判る。HMM については、行動ごとに状態が変化するため、連続して行われない行動については状態が変化し、適切に予測ができなかったと考えられる。この結果から、HMM と比較した場合、階層性を用いた事により、HHMM がユーザの状態を推定するのにより適したモデル

表 5 行動予測の結果. 手法列はそれぞれマルコフ連鎖 (MC, 数字は次数), HMM(数字は隠れ状態数), HHMM(数字は第 1, 第 2 階層の状態数). 機能列は予測対象の機能. 太字は, 各機能における適合率, 再現率, F 値が最も高かったもの.

手法	機能	適合率	再現率	F 値	手法	機能	適合率	再現率	F 値
HHMM 6 4	item	0.2996	0.0103	0.0198	MC 1	item	0.0000	0.0000	0.0000
	cart	0.1649	0.1015	0.1257		cart	0.0000	0.0000	0.0000
HHMM 6 5	item	0.2971	0.0106	0.0204	MC 2	item	0.0000	0.0000	0.0000
	cart	0.1641	0.0994	0.1238		cart	0.0477	0.0380	0.0423
HMM 3	item	0.0000	0.0000	0.0000	MC 3	item	0.0936	0.0160	0.0273
	cart	0.0896	0.0765	0.0825		cart	0.1264	0.0580	0.0795
HMM 4	item	0.0000	0.0000	0.0000	MC 4	item	0.0805	0.0120	0.0209
	cart	0.0550	0.0428	0.0481		cart	0.2111	0.1100	0.1446
HMM 5	item	0.0000	0.0000	0.0000	MC 5	item	0.0881	0.0170	0.0285
	cart	0.0419	0.0317	0.0361		cart	0.2216	0.1110	0.1479

であると言える.

次に, 3 次以上のマルコフ連鎖と HHMM を比較する. 5 次のマルコフ連鎖における item 及び cart の F 値が 0.0285, 0.1479 であるのに対し, HHMM の第 1 階層の状態数が 6, 第 2 階層の状態数が 5 のモデルにおける item 及び cart の F 値が 0.0204, 0.1238 となっておりこの結果から, HHMM を用いた予測によって, マルコフ連鎖と同程度の行動予測精度を実現しつつ, ユーザの状態を推定することが可能になったと言える.

また, 今回は状態数について 3 から 6 という範囲内での検証を行った. 状態数の増減による行動予測精度の変化や得られる状態と行動の関係の変化, 及び最適な状態数の自動的な決定 [9] などは今後の検討課題である.

5. 結 論

今回我々は, EC サイトにおけるユーザの欲求, 特に購入へと向かう状態の推定に取り組んだ. 本研究では (1) ユーザ自身の状態と, 一つ前の行動とに従って, ユーザの現在の行動が決まる, (2) 行動クラスが決まれば, ユーザが実際に取る行動が決まる, (3) 一つ前のユーザの状態に従ってユーザの現在の状態が決まるという仮定をユーザ行動モデルに設け, 階層型隠れマルコフモデルを用いてユーザ行動モデルを推定することによって, 購入へと向かう状態の変化の推定, 及び, 購入から離脱する状態への遷移を発見した. これにより, 購入からの離脱の兆候を検出することが可能になった. また, ユーザ状態を含んだ状態で推定したモデルを用いることにより, 同様にユーザ状態を仮定した隠れマルコフモデルを上回る適合率でユーザの行動予測が可能であること, 及び, ユーザ状態を仮定しないマルコフ連鎖と同程度の精度でユーザの行動予測が可能であることを確かめた. 今回の結果を用いることにより, 従来であれば購入から離脱したユーザに取られていたアクションが, 離脱の兆候を検出した時点で可能になり, コンバージョン率の向上につながると考えられる.

6. 今後の課題

今後の研究としてはまず, 時間情報を用いたより適切な状態の推定が挙げられる. 今回の行動履歴にはユーザのアクセス時

刻が記録されているため, 2 つの行動間のアクセス時刻の差分を取れば, 各ページの閲覧時間を算出する事が可能である. 各ページの閲覧時間がそのページにおけるコンテンツの重要性に強く関係している事が知られているため [6], 閲覧時間を用いる事により, ユーザの状態をより適切に推定することが可能になると考えられる. 既存の隠れマルコフモデルにおいて, 観測変数に時間などの要素が関係する分野は信号処理や映像処理であるが, それらは系列の時間間隔などは考慮せず, 一定間隔で信号を区切る事によって隠れマルコフモデルを適用している. よって, 時間情報の隠れマルコフモデルへの導入はより汎的な課題であると考えられる.

次に, EC サイトにおけるアクセスログだけでなく, 他データへの適用が挙げられる. 今回の対象データは EC サイトにおけるアクセスログであったが, ユーザの状態推定においては Web 特有の情報などは用いず, 離散的な行動履歴という形式を用いて推定を行った. よって, その他の離散的な行動情報で構成された実世界の行動データ, 例えば実店舗での購買行動や GPS 情報などのライフログへの適用も可能であると考えられる.

最後に, Dynamic Topic Model [1] などのマルコフ性を取り入れたトピックモデルを用いる事も検討している. Dynamic Topic Model では, 状態間に直接のマルコフ性を仮定するのではなく, ハイパーパラメータにマルコフ性を仮定するものであるが, 行動の出力確率が動的に変化するモデルが構築できるため, より適切にユーザの行動及び状態が推定できると考えられる.

6.1 行動モデリング

EC サイトにおける購買モデリングとして, Poel ら [15] は EC サイトにおけるユーザのページ遷移情報がある間隔で区切ったもの (セッション) ごとに特徴量を付与し, そのセッションで購買行動が起こるか否かについての予測が行われている. この研究は特徴量としてクリックスルーデータなどのセッションにおけるユーザの行動情報を用いている. Guo ら [7] は検索を行っているユーザが購入の意欲があるか, 商品について検索しているのみであるかの予測を行った. Guo らは同時に, 先に述べた 2 つの状態を用いてユーザが広告をクリックするかどうかの問題にも取り組んでいる. これらの研究は, ユーザが行った

一連の閲覧行動に対して、購入意欲があるか否か、または購入するか否かを推定するものである。本研究は、ユーザの各閲覧行動ごとに購入に向けた状態がどの程度のものかを推測しているという点で大きく異なっている。

より汎的な、Web におけるユーザの遷移行動における既存研究として、Mabroukeh ら [13] によるマルコフ連鎖に基づく行動予測が挙げられる。これは、ページの内容を用いて人出でデータをアノテーションし、より精度の高い予測を行なっている。マルコフ連鎖を用いたユーザモデリングとしては他にも、Hassan ら [8] による検索行動におけるユーザ満足度の推定が挙げられる。これは、マルコフ連鎖を用いて、検索結果において上位に存在する文書群とクエリとの関連度よりも、ページ遷移などのユーザの行動履歴情報のほうが、ユーザの満足度推定に有効であることを示したものである。また、Lin ら [12] による遷移行動を用いて言語処理分野における言語モデルを構築したものなどが存在する。しかし、本研究で行ったような、Web におけるユーザの遷移行動に対して、階層型隠れマルコフモデルによって表現されるモデル化を行ったものは存在しない。

その他の購買行動に関する研究として、Iwata ら [10] による購買ログデータからユーザの興味を潜在変数として扱い、その時系列変化を逐次的に推定するものが挙げられる。

6.2 消費者行動

消費者行動における代表的な研究として Fishbein による多属性モデル [5]、Engel らによる EKB モデル [3]、Bettman らによる情報処理モデル [17] などが挙げられる。Fishbein [5] による多属性モデルではまず、商品やブランドは複数の属性を持つものとされる。そして、これら複数属性に対する重み付けの総和で、消費者のある商品またはブランドに対する評価、態度をモデル化した。また多属性モデルにおいては、消費者はこの態度が高いものを選択するとされている。Engel らによる EKB モデル [3] では、消費者の広告などからの刺激に対する反応がモデル化されている。EKB モデルでは外部刺激によって消費者は問題認識をし、それを達成すべく情報検索を行う。検索によって得た情報に対し評価を行い、最終的に購入し、評価を行うのが EKB モデルである。Bettman ら [17] による情報処理モデルは消費者は外部からの刺激にのみ反応するのではなく、自ら目的達成に向けて情報を探索し、それにより得た情報を処理し、最終的な行動を行うというモデルであり、これまでの刺激反応モデルとは大きく異なっている。また、Bettman モデルでは長期記憶と短期記憶の概念が導入されている点も刺激反応モデルとは異なっている。

文 献

- [1] D. M. Blei and J. D. Lafferty. Dynamic topic models. In *Proceedings of the 23rd international conference on Machine learning*, ICML '06, pages 113–120, New York, NY, USA, 2006. ACM.
- [2] S. Buettcher, C. L. A. Clarke, and G. V. Cormack, editors. *Information Retrieval*. The MIT Press, New York, NY, 2010.
- [3] J. F. Engel, D. T. Kollat, and R. D. Blackwell. Personality measures and market segmentation : Evidence favors interaction view. *Business Horizons*, 12(3):61–70, June 1969.

- [4] S. Fine, Y. Singer, and N. Tishby. The hierarchical hidden markov model: Analysis and applications. *Mach. Learn.*, 32(1):41–62, July 1998.
- [5] M. Fishbein. Attitude and the prediction of behavior. *Readings in attitude theory and measurement*, pages 477–492, 1967.
- [6] S. Fox, K. Karnawat, M. Mydland, S. Dumais, and T. White. Evaluating implicit measures to improve web search. *ACM Trans. Inf. Syst.*, 23(2):147–168, Apr. 2005.
- [7] Q. Guo and E. Agichtein. Ready to buy or just browsing?: detecting web searcher goals from interaction data. In *Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval*, SIGIR '10, pages 130–137, New York, NY, USA, 2010. ACM.
- [8] A. Hassan, R. Jones, and K. L. Klinkner. Beyond dcg: user behavior as a predictor of a successful search. In *Proceedings of the third ACM international conference on Web search and data mining*, WSDM '10, pages 221–230, New York, NY, USA, 2010. ACM.
- [9] K. A. Heller, Y. W. Teh, and D. Görür. Infinite hierarchical hidden markov models. *Journal of Machine Learning Research - Proceedings Track*, 5:224–231, 2009.
- [10] T. Iwata, S. Watanabe, T. Yamada, and N. Ueda. Topic tracking model for analyzing consumer purchase behavior. In *IJCAI*, pages 1427–1432, 2009.
- [11] M. Johnson. Why Doesn't EM Find Good HMM POS-Taggers? In *Proceedings of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning (EMNLP-CoNLL)*, pages 296–305, 2007.
- [12] J. Lin and W. J. Wilbur. Modeling actions of pubmed users with n-gram language models. *Inf. Retr.*, 12(4):487–503, Aug. 2009.
- [13] N. R. Mabroukeh and C. I. Ezeife. Semantic-rich markov models for web prefetching. In *Proceedings of the 2009 IEEE International Conference on Data Mining Workshops*, ICDMW '09, pages 465–470, Washington, DC, USA, 2009. IEEE Computer Society.
- [14] K. P. Murphy and M. A. Paskin. Linear time inference in hierarchical hmms. In *Proceedings of Neural Information Processing Systems*, 2001.
- [15] D. V. D. Poel and W. Buckinx. Predicting online-purchasing behaviour. *European Journal of Operational Research*, 166:557–575, 2005.
- [16] L. Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2):257–286, feb 1989.
- [17] I. Ross and J. R. Bettman. An information processing theory of consumer choice. *Journal of Marketing*, 43(3):124+, FebFeb 1979.
- [18] K. Wakabayashi and T. Miura. Forward-backward activation algorithm for hierarchical hidden markov models. In P. Bartlett, F. Pereira, C. Burges, L. Bottou, and K. Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pages 1502–1510. 2012.
- [19] M. Weiland, A. Smaill, and P. Nelson. LEARNING MUSICAL PITCH STRUCTURES WITH HIERARCHICAL HIDDEN MARKOV MODELS. 2005.