

ECサイトにおける閲覧履歴を用いた 購買に繋がる行動の変化検出

財津 大夏^{1,a)} 三宅 悠介^{1,b)}

概要: EC サイトにおいて、ユーザーは購買に向けて「商品の探索」「商品の絞り込み」のように行動を変化させる。ユーザーの行動の変化にリアルタイムで追従して、EC サイトのシステムを適応的に変化させることで購買率の向上が期待されるため、この変化を検出することは EC サイトの運営者にとって有用である。リアルタイムでの処理を行うためには、計算量やメモリ使用量の観点から、単純な特徴量によって変化を検出できることが望ましい。Moe(2003) は、EC サイトの閲覧履歴を用いて、ユーザーの来店目的に対応する情報探索のタイプと商品ページの閲覧パターンを 4 つに分類した。初期段階では購買を検討する商品集合を形成するために多くの種類の商品を閲覧する一方で、購買の直前では閲覧する商品の種類が少なくなることが示されている。そこで本報告では、直近の閲覧履歴から、商品の閲覧回数に対する商品の属性の種類の比のみを特徴量として、統計的仮説検定を用いて特徴量の値の変化をリアルタイムに検出する手法を提案する。EC サイトのプロダクション環境の閲覧履歴を用いて、商品に紐づく複数の属性ごとに特徴量を計算し、購買に至るまでの時系列における変化から特徴量の有効性を確認した。また、実際に購買を行ったユーザーに関して、提案手法が特徴量の値の変化を検出できることを確認した。

Change Detection in Behavior Followed by Possible Purchase Using Electronic Commerce Site Browsing History

HIROKA ZAITSU^{1,a)} YUSUKE MIYAKE^{1,b)}

Abstract: In Electronic Commerce (EC) sites, consumers change their behavior toward purchasing, such as "search products" and "narrow products." Detecting this change is useful for EC site operators since the purchase rate is expected to be improved by following the changes in consumer behavior in real-time and adaptively changing the EC site system. For performing real-time processing, changes should be able to be detected by simple feature values from considering the amount of calculation and memory usage. Moe (2003) classified the types of information search and the browsing patterns of product pages corresponding to the purpose of visiting customers using EC site browsing history. Moe shows that many types of products are browsed to form a set of products to be considered for purchase in the initial stage, but the types of products browsed before the purchase are decreased. In this paper, we propose a method for detecting changes in feature values in real-time using statistical hypothesis testing, using only the ratio of the type of product attributes to the number of product visits based on the most recent browsing history. Using the browsing history of the production environment of a EC site, the feature amount was calculated for each attribute associated with the product. The effectiveness of the feature amount was confirmed from the change in the time series up to purchase. We confirmed that the proposed method can detect changes in feature values for consumers who actually made purchases.

¹ GMO ペパボ株式会社 ペパボ研究所
Pepabo Research and Development Institute, GMO Pepabo, Inc.

^{a)} zaitsu@pepabo.com

^{b)} miyakey@pepabo.com

1. はじめに

日本国内の消費者向け電子商取引（以下 EC）の市場規模は 2010 年代に拡大を続け、2018 年時点では BtoC（企

業-消費者間)で18.0兆円(前年16.5兆円,前年比8.96%増),CtoC(消費者-消費者間)のフリマアプリで6,392億円(前年4,835億円,前年比32.2%増)に達している[13].

ECサイトを訪れるユーザーは、「購買を目的としないウィンドウショッピング」「購買する商品の探索」「特定の商品の購買」等,その時々に応じた複数の目的を持っており,ECサイトの運営者が閲覧履歴として観測できる「サイト内での商品の検索」「商品の閲覧」「商品の購買」等のユーザーの行動は,目的によって変化すると考えられる.

この行動の変化に合わせてECサイトのシステムを適応的に変化させることで,購買率の向上が期待される.例えば,「商品の探索を行っているユーザーに対する推薦手法を,商品の画像や説明文の類似性を用いる内容ベース型推薦と比較して,多くの利用者の評価から導かれる多様な商品を提案することでユーザーの興味を惹く可能性が高い[2],[3],[8]協調フィルタリング^{*1}に切り替える」「商品の絞り込みを終えて購買を行おうとしているユーザーに対して,決済導線を表示して購買を促す」等の振る舞いの変更により,ユーザーが商品を購入する可能性が高くなり,ECサイトの運営者にとっては売上の,ユーザーにとっては利便性の向上に繋がる.このような振る舞いの変化のためには,ユーザーの行動の変化を検出することが必要である.

ユーザーの行動の変化に追従してECサイトのシステムを適応的に変化させるためには,ユーザーが何らかの行動をとった直後に変化を検出する必要がある.行動の変化を検出するための特徴量には,ECサイトのアクセスログから得られるデータや,ユーザーや商品のメタデータ等が考えられる.ただし,どの特徴量を選択すべきかはECサイトごとに未知であり,多くの特徴量が存在する場合はどの特徴量が寄与するか事前には不明であるため,これらの特徴量を全て用いる学習ベースの手法がある.しかし,学習ベースの手法では,特徴量の次元数が増えるほど必要なサンプルサイズが増大し,モデルの汎化性能を向上させることが困難になる課題があり[17],サンプルサイズの増大は計算量の増加にも繋がる.ユーザーが行動をとった直後に変化を検出するためには,計算量や計算時間の観点から,次元数の少ない単純な特徴量を用いることが望ましい.

既存研究におけるユーザー行動の分析として,ユーザーの目的に対応する閲覧パターンの分類が試みられており,「購買が認識された初期の段階に行われる探索行動」ではカテゴリーページと商品ページを多く閲覧し,「購買決定の直前に行われる探索行動」では少数の商品に閲覧が集中することが示されている[9],[18].ある期間の探索行動における商品の閲覧数と商品の種類の数を特徴量と捉えた場

合,次元数の少ない単純な特徴量という条件を満たすが,ECサイトやユーザーごとに異なる範囲の値を取ると考えられる.学習ベースの手法ではユーザーごとに教師データを与えることで差異を踏まえた学習を行える可能性があるが,ECサイトのすべてのユーザーについて事前にデータを用意することは難しいため,ユーザーによって値が取りうる範囲に差がある特徴量の場合は,学習不要なアプローチを用いる必要がある.

そこで本報告では,閲覧数に占める商品の種類の比の値を特徴量と捉え,統計的仮説検定を用いて有意差を検証することで,購買に繋がるユーザーの行動の変化を検出する手法を提案する.ユーザーが行動を行う度に直近の行動履歴から特徴量の値を計算し,その推移を任意の点で二分した群について,平均値に有意差がある場合に変化として検出する.我々は,GMOペパボ株式会社が運営するECサイト「minne[12]」において,商品に紐づく複数の属性から特徴量の値を計算し,購買を行ったユーザーについては特徴量の値が連続的に下がり,購買を行わなかったユーザーについては値が一定する傾向から,単純な特徴量によってモデルの学習を行わずにユーザーの行動の変化を検出できることを見出した.また,ユーザーごとの閲覧履歴から特徴量の値を作成し変化を検出することで,ECサイトやユーザーごとに特徴量の値のスケールが異なる場合にも対応する.統計的仮説検定を用いてユーザーが何らかの行動をとる度に検定を行うことで,行動をとった直後に変化を検出することができ,有意水準をパラメータとして与えることが可能となる.

本報告の構成を述べる.2章では,ECサイトにおけるユーザーの行動の変化検出の課題を述べる.3章では,提案手法の特徴量作成と変化検出のアルゴリズムを述べる.4章ではminneのプロダクション環境のデータに提案手法を適用して有効性の検証と考察を行い,5章でまとめとする.

2. ユーザーの行動の変化検出における課題

ユーザーの行動の変化を検出するためにどのような特徴量を選択すべきかはECサイトごとに未知である.行動の変化を検出するための特徴量には,ECサイトのアクセスログから得られるデータや,ユーザーや商品のメタデータ等多くのものが考えられるが,どの特徴量が変化検出に寄与するかは事前には不明であるため,これらの特徴量を複合して用いるディープラーニングや隠れマルコフモデル[15],[19]等の学習ベースの手法がある.

しかし,学習ベースの手法では特徴量の次元数が増加すると必要なサンプルサイズが増大し,モデルの汎化性能を向上させることが困難になる課題があり[17],サンプルサイズの増大はモデルの学習時の計算量や計算時間の増加にも繋がる.高次元の特徴量に対しては,潜在的な意味を保

^{*1} あるユーザーと他のユーザーの嗜好が何らかの観点で似ていることを用いて推薦を行う手法.例えば,商品a,bを購入したユーザーAが存在する場合,商品aを購入したユーザーBに対して,商品bも好む可能性が高いとして推薦を行う.

持したまま次元数を減らす次元削減 [20] の手法をとることができるが、次元削減のための追加計算が必要となる。EC サイトにおいては時間帯や曜日によってユーザーの行動の傾向が変化することが確認されているため [14], 1 日分以上のデータで学習を行うことが望ましいが、モデルの学習に用いたデータと推論対象のデータの時間差により特徴量にずれが生じ、時間経過によりずれが大きくなる可能性がある。よって、次元数の少ない単純な特徴量でユーザーの行動の変化を検出できることが望ましい。

マーケティング・リサーチの分野では、EC サイトにおけるユーザーの行動の分析として、閲覧履歴からユーザーの来店目的に対応する情報探索のタイプと商品ページの閲覧パターンを分類する研究がなされている。「購買が認識された初期の段階に行われる探索行動」では、購買を検討する商品集合を形成するためにカテゴリーページと商品ページを多く閲覧する一方で、「購買決定の直前に行われる探索行動」では閲覧する商品の種類が少なくなることが示されている [9], [18]。ある期間の探索行動における商品の閲覧数と商品の種類の数は、次元数の少ない特徴量という条件を満たすが、特徴量を取りうる値の範囲が EC サイトやユーザーごとに異なると考えられる。学習ベースの手法でユーザーごとの差異を踏まえた学習を行うためにはユーザーごとに教師データを与える必要があるが、EC サイトのすべてのユーザーについて事前にデータを用意することは難しいため、この特徴量をユーザーの行動の変化検出に用いるためには学習が不要なアプローチによることが望ましい。

3. 提案手法

2 章の議論を踏まえて本報告では、ユーザーの行動の変化に追従して EC サイトのシステムを適応的に変化させるために、次元数の少ない特徴量を用いた、学習が不要なアプローチにより行動の変化を検出する手法を提案する。

ユーザーが閲覧する商品の種類の数、購買が認識された初期の段階と購買決定の直前とで変化することに着目した上で、閲覧履歴から商品の閲覧回数に対する商品の属性の種類比を、次元数の少ない単純な特徴量として用いる。更に、ユーザーごとの特徴量の値の時系列に対して統計的仮説検定による平均値の差の検定を行い、ある時点の前後で有意な差がある場合に変化として検出することで、学習によらない変化検出を行う。ユーザーが何らかの行動をとる度に検定を行うことで、ユーザーが行動をとった直後に変化を検出することができる。また、検定における有意水準をパラメータとして与えることが可能である。

2 章で述べた課題に対して、提案手法ではデータ量と計算量の観点において、ユーザーの閲覧履歴と閲覧対象となった商品の属性のみから単純な特徴量の値を計算可能である。学習を行わず直近の行動履歴から変化検出を行うた

め、時間経過による特徴量の値のずれが生じない。また、ユーザー本人の行動履歴だけを用いるため、ユーザーごとに特徴量の値が取る範囲に差がある環境にも適用可能であり、モデルの学習によらず検定統計量の計算のみで変化検出が可能である。

以降に、提案手法における特徴量の作成と変化検出の具体的な方法を述べる。

3.1 特徴量の作成

まず、ユーザー u の行動履歴 a を時刻 t 順に並べた系列 S_u から、直近の閲覧履歴を表すウィンドウ $W_u(t)$ を作成する。行動履歴 a には、商品の閲覧 a^{view} 、商品の購買 $a^{purchase}$ 、商品の検索 a^{search} 等の種類がある。系列 S_u の系列長を l 、ウィンドウ $W_u(t)$ の幅を w とおくと、

$$S_u = \begin{pmatrix} a_1 & a_2 & \dots & a_l \end{pmatrix} \quad (1)$$

$$W_u(t) = \begin{pmatrix} a'_1 & a'_2 & a'_3 & \dots & a_t \end{pmatrix} \quad (2)$$

である。ここで、

$$a'_1 = a_{t-w+n}$$

$$a'_2 = a_{t-w+n+1}$$

$$a'_3 = a_{t-w+n+2}$$

であり、 n は $(1 \leq n \leq w)$ かつ $t - w + n > 0$ を満たす最小の自然数である。

このウィンドウ $W_u(t)$ から、商品の閲覧 a^{view} の対象となった商品の属性 $attr$ に関する特徴量の値 $r^{attr}(W_u(t))$ を求める。商品の属性 $attr$ の集合を $\mathbb{A}$ とおき、特徴量の値を以下の式で定義する。

$$r^{attr}(W_u(t)) = \frac{|\mathbb{A}|}{count(a^{view})} \quad (3)$$

即ち、時刻 t における特徴量の値 $r^{attr}(W_u(t))$ は、直近の閲覧履歴 $W_u(t)$ に含まれる商品閲覧回数に対する商品の属性の種類比である。商品の属性としてはカテゴリやメーカー等が想定される。

3.2 変化検出

3.1 節で定義した特徴量の値 $r^{attr}(W_u(t))$ を用いてユーザーの行動の変化を検出するために、幅 w' のウィンドウ W' を定義する。

$$W'_u(t) = \begin{pmatrix} r'_1 & r'_2 & r'_3 & \dots & r^{attr}(W_u(t)) \end{pmatrix} \quad (4)$$

なお、ここで

$$r'_1 = r^{attr}(W_u(t - w + n))$$

$$r'_2 = r^{attr}(W_u(t - w + n + 1))$$

$$r'_3 = r^{attr}(W_u(t - w + n + 2))$$

である。

提案手法では、ウィンドウ $W_u(t)$ を任意の点で二分したウィンドウ W'_1 と W'_2 に対して統計的仮説検定による平均値の差の検定を適用し、有意水準 s において有意に差があると見なされた場合に行動に変化があったと見なす。ウィンドウ $W_u(t)$ に存在する変化点を漏れなく検出するために、分割は $W'_1 = (r_1), W'_2 = (r_2, \dots, r_{w'})$ から $W'_1 = (r_1, \dots, r_{w'-1}), W'_2 = (r_{w'})$ までの $w' - 1$ パターンについて行う。平均値の差の検定には、分布の歪みに対応でき [11]、標本の母分散が等しくない場合にも広範に対応しうる [5] 手法として、Student の t 検定の改良である Welch の t 検定を用いる。Student の t 検定は、標本の母集団が正規分布に従い、母分散が等しいと仮定した場合、統計量が自由度に依存する t 分布に従うことを利用して、2 組の標本の平均に有意差があるかどうかを検証する手法である。Welch の t 検定は母分散が等しいことを仮定しない。

提案手法におけるハイパーパラメータは、閲覧履歴から特徴量の値 r^{attr} を求める際のウィンドウの幅 w 、特徴量の値 r^{attr} の変化を検出する際のウィンドウの幅 w' 、Welch の t 検定の有意水準 s の 3 つである。

以上を踏まえて、変化検出のアルゴリズムを Algorithm 1 に示す。

Algorithm 1 Change detection in the proposed method.

Require:

```
Stream of values:  $\{a_1, a_2, \dots\}$ 
Window size:  $w, w'$ 
Significance level:  $s$ 
1:  $W \leftarrow \{\}$ 
2:  $W' \leftarrow \{\}$ 
3: for  $t = 1, 2, \dots$  do
4:    $W \leftarrow W \cup \{a_t\}$ 
5:   if the number of  $W$  elements  $> w$  then
6:     Drop tail element of  $W$ .
7:    $W' \leftarrow W' \cup \{r^{attr}(t)\}$ 
8:   if the number of  $W'$  elements  $> w'$  then
9:     Drop tail element of  $W'$ .
10:  Apply Welch's  $t$ -test for every split  $W' = W'_1 \vee W'_2$ .
11:  /* The time series of  $W'_1, W'_2$  should be continuous. */
12:  if  $p$ -value  $< s$  then
13:     $t$  of the  $W'_2$ 's first element is a change point.
```

Algorithm 1 の 4 行目から 7 行目が 3.1 節で述べた特徴量の作成にあたり、7 行目から 13 行目が 3.2 節で述べた変化検出にあたる。

4. 実験と考察

提案手法の有効性を検証するため、3 章で実装した手法を、GMO ペパボ株式会社の運営する EC サイト「minne」のプロダクション環境における閲覧履歴に適用した。4.1 節で実験に用いたデータセットについて述べ、4.2 節で作品*2に紐づく属性のうち提案手法に適したものを考察す

*2 minne はハンドメイド品を売買する EC サイトであり、出品物




図 1 購買ユーザーの作品 ID を用いた特徴量の値の変化

Fig. 1 Feature values of purchasing users based on the product ID.




図 2 購買ユーザーの作品の出品者 ID を用いた特徴量の値の変化

Fig. 2 Feature values of purchasing users based on the product's seller ID.

る。次に 4.3 節で提案手法のハイパーパラメータについて検討する。最後に 4.4 節で提案手法による変化検出の結果と計算時間を確認する。購買を行ったユーザーでは時刻 t が進むほど作品閲覧回数に占める作品属性の種類の比の値が低下し、購買を行わなかったユーザーでは時刻 t に関わらず作品閲覧回数に占める作品属性の種類の比の値が変化しないという仮説に基づき、データセット中で購買を行ったユーザー（以下、購買ユーザー）と購買を行わなかったユーザー（以下、非購買ユーザー）にデータセットを分割して計算した。

図 1 から図 8 に、購買ユーザーと非購買ユーザーそれぞれの作品属性ごとの特徴量の値の変化を箱ひげ図で示す。箱の中の横線は中央値を、箱の上端は第三四分位数を、箱の下端は第一四分位数を、ひげの上端は第三四分位数に四分位範囲の 1.5 倍を足した値を、下端は第一四分位数から四分位範囲の 1.5 倍を引いた値を、ひげの上下の点は外れ値を表す。x 軸は、購買ユーザーでは購買までの特徴量の変化を捉えるために $a^{purchase}$ までの行動回数を表し、右方向に値が減少する。非購買ユーザーではデータセット中でユーザーが行動を開始してから行動回数を表し、右方向に値が増加する。y 軸は特徴量の値を表す。図 1 から図 4 の図中の赤線は、代表的な系列における提案手法の挙動を示すために、x 軸の値ごとの y 軸の中央値の系列に対して提案手法を適用し検出した変化点である。

は作品と呼ばれる。




図 3 非購買ユーザーの作品 ID を用いた特徴量の値の変化

Fig. 3 Feature values of non-purchasing users based on the product ID.




図 4 非購買ユーザーの作品の出品者 ID を用いた特徴量の値の変化

Fig. 4 Feature values of non-purchasing users based on the product's seller ID.




図 5 購買ユーザーの作品カテゴリを用いた特徴量の値の変化

Fig. 5 Feature values of purchasing users based on the product's category.




図 6 購買ユーザーの作品カテゴリグループを用いた特徴量の値の変化

Fig. 6 Feature values of purchasing users based on the product's category group.

4.1 データセットの概要

データセットには 2020 年 3 月 1 日（日曜日）の閲覧履歴を用いた。図 1 から図 8 より、ユーザーが行動を開始した直後は特徴量の値の変動が大きい傾向を確認できるため、本報告では系列長 $l \geq 6$ のユーザーを対象として実験




図 7 非購買ユーザーの作品カテゴリを用いた特徴量の値の変化

Fig. 7 Feature values of non-purchasing users based on the product's category.




図 8 非購買ユーザーの作品カテゴリグループを用いた特徴量の値の変化

Fig. 8 Feature values of non-purchasing users based on the product's category group.

を行った。なお、minne では休日と平日で時間ごとのアクセス数の傾向に差があることが確認されている [14]。そこで 2020 年 3 月 2 日（月曜日）の閲覧履歴との比較を行ったところ、作品閲覧は平日の方が 9.8% 多く、購買の回数は休日の方が 25.8% 多かった。このことから、平日は閲覧だけを行い、購買は休日に行うという傾向を読み取れるが、提案手法における特徴量の値の変化は平日と休日で同じ傾向を示すことを確認している。アクセス数の傾向は、1 日のうちの時間帯への依存が大きいため、1 日分の閲覧履歴を用いることで minne における特徴量の有効性を十分に検証することができる。

4.2 特徴量に用いる作品属性

今回の評価において特徴量に有効な作品属性を検討するため、作品に紐づく次の 4 つの属性ごとに特徴量の値を計算した。

- 作品 ID
- 作品の出品者 ID^{*3}
- 作品カテゴリ
- 作品カテゴリグループ^{*4}

「作品 ID」と「作品の出品者 ID」に関しては、購買ユーザーでは行動が $a^{purchase}$ に近づくにつれて特徴量の値が

^{*3} minne は CtoC の EC サイトであり、出品者と購買者がともにユーザーである。

^{*4} minne の作品カテゴリは幾つかのグループに分かれている。例えば「T シャツ」カテゴリと「ワンピース」カテゴリは「ファッション」カテゴリグループに属する。

表 1 異なる w と w' における変化点の検出数

Table 1 Number of detected change points at different w .

w	w'	データセット	作品属性	
			作品 ID	作品の出品者 ID
5	3	購買ユーザー	0	0
		非購買ユーザー	0	0
	5	購買ユーザー	1	6
		非購買ユーザー	1	2
10	3	購買ユーザー	0	0
		非購買ユーザー	0	0
	5	購買ユーザー	2	6
		非購買ユーザー	1	1

減少することが図 1 と図 2 から確認でき、非購買ユーザーでは行動回数に関わらず値が変化しない様子が図 3 と図 4 から確認できるため、提案手法を用いた minne のユーザー行動の変化検出に有用であると考えられる。一方で、「作品カテゴリ」と「作品カテゴリグループ」に関しては、購買ユーザーと非購買ユーザー共に早い段階で特徴量の値が減少し、その後変化しなくなることが図 5 から図 8 より確認できるため、購買に向かうユーザーの行動の変化を検出するための特徴量としては適していない。よって以降の実験では「作品 ID」と「作品の出品者 ID」を特徴量に用いる作品属性とする。

4.3 ハイパーパラメータ

提案手法に存在するハイパーパラメータとして、閲覧履歴から特徴量の値 r^{attr} を求める際のウィンドウの幅 w と、特徴量の値 r^{attr} の変化を検出する際のウィンドウの幅 w' の値を本節で検討する。実用上は、ユーザーが閲覧を開始した後に早い段階で変化検出を行えるよう w と w' ともに小さいことが望ましいが、提案手法では W_1' と W_2' に含まれる r^{attr} の平均値の差により変化を検出するため、 w と w' があまりに小さいと W_1' と W_2' が平均値の差のある時刻 t の範囲を含まないか、少数の r^{attr} から変化を過剰に検出する問題が起こりうる。4.1 節のデータセットに対して、 w が {5, 10} と w' が {3, 5} の組み合わせにおいて検出した変化点の数を表 1 に示す。 w' に関しては、 $w' = 3$ ではいずれの w 、データセット、作品属性の組み合わせにおいても変化点を検出できなかった。 w に関しては、 $w = 10$ のとき購買ユーザーに関してより多くの変化点を検出し、非購買ユーザーに関して少ない変化点を検出している。そこで、本報告では $w = 10$ と $w' = 5$ を実験に用いる。なお、他のハイパーパラメータである Welch の t 検定の有意水準 s は、慣例的に用いられる値の 0.05 を用いる [4], [6]。

4.4 変化検出と計算時間

ここまでの検討を踏まえて、提案手法による変化検出の結果と計算時間を確認する。

変化を検出するべき購買ユーザーについて、図 1 から作

品 ID は特徴量の値が下がり始めた直後に、図 2 から作品の出品者 ID は特徴量の値が下がるごとに変化を検出できている様子が示された。一方、変化を検出するべきでない非購買ユーザーでは、図 3 と図 4 からいずれの作品属性でも特徴量の値の変化が少なく、変化点もほぼ検出されていないことが分かる。作品の出品者 ID を用いる場合に行動回数 = 1 で変化を検出しているが、作品 ID を用いる場合も作品の出品者 ID を用いる場合も、行動回数 = 5 近辺までは特徴量の値が安定していない。minne においては、ユーザーが行動を開始した直後は行動の傾向が定まっていないことが分かるため、行動回数 = 6 以降で変化検出を行う等の工夫が必要と考えられる。

また、個別のユーザーに対する精度を検討するため、EC サイトにおけるユーザー行動の分析に用いられる [15], [19] 隠れマルコフモデル (HMM) [10] との比較を行う。提案手法は「変化点を検出した場合」に、隠れマルコフモデルは「隠れ状態のうち特徴量の値の平均が低い状態に遷移した場合」に予測ラベルを「購買ユーザー」として、手法ごとの出力結果を予測ラベルに対応させる。隠れマルコフモデルの隠れ状態数は 2 とし、学習には Baum-Welch アルゴリズムを、推定には Viterbi アルゴリズムを用いた。モデルの構築のためデータセットを訓練データ:テストデータ=9:1 に分割し、ユーザー数は訓練データが 87,285 ユーザー、テストデータが 9,699 ユーザーである。また購買ユーザーに関しては購買以前の特徴量の値の変化を考察するために購買後の作品閲覧を行動履歴から除き、系列長 $l < 6$ となった場合は評価対象から除いたため、テストデータにおいて実際に評価されたユーザー数は 9,523 ユーザーである。

テストデータにおいて作品 ID を特徴量に用いる場合の混同行列を表 2 に、作品の出品者 ID を特徴量に用いる場合の混同行列を表 3 に、偽陽性率と偽陰性率を表 4 に示す。作品 ID を特徴量に用いる場合と、作品の出品者 ID を特徴量に用いる場合のいずれにおいても、提案手法よりも隠れマルコフモデルの方が積極的に「購買ユーザー」のラベルを付けた。隠れマルコフモデルがテスト対象を積極的に「購買ユーザー」と見なした理由として、「購買しなかった」にマッピングされる隠れ状態の分布が平均 1.0、標準偏差 1.16×10^{-8} となっており、僅かでも特徴量の値が減少すると「購買した」隠れ状態に遷移していたため、真の購買ユーザーに対する精度は隠れマルコフモデルの方が高い一方で、真の非購買ユーザーに関しては提案手法の方が精度良く分類できた。提案手法の精度を更に改善する方策としては、特徴量の値が変化する際の正負方向を予測ラベルを付ける際に考慮することや、ユーザーが行動を開始した直後の、特徴量の値に変動がある期間を除外することが考えられる。

また、提案手法のウィンドウ $W_u'(t)$ あたりの計算時間は、3.1GHz クアッドコア Intel Core i7 を利用する評価環

表 2 作品 ID を特徴量に用いた場合の混同行列

Table 2 Confusion matrix when the product ID is used as a feature.

		正解ラベル	
		購買	非購買
予測ラベル	提案手法	購買	526
		非購買	201
	HMM	購買	662
		非購買	65

表 3 作品の出品者 ID を特徴量に用いた場合の混同行列

Table 3 Confusion matrix when the seller ID of a product is used as a feature.

		正解ラベル	
		購買	非購買
予測ラベル	提案手法	購買	483
		非購買	244
	HMM	購買	679
		非購買	48

表 4 偽陽性率と偽陰性率

Table 4 False positive rate and false negative rate.

		偽陽性率	
		偽陽性率	偽陰性率
作品 ID	提案手法	0.517	0.276
	HMM	0.633	0.089
作品の出品者 ID	提案手法	0.650	0.336
	HMM	0.801	0.066

境において、1.71 ミリ秒から 1.75 ミリ秒であった。ウェブサイトの読み込み時間は 1,000 ミリ秒未満となることが望ましいとされており [7], 提案手法による変化検出に掛かる時間は十分に小さいことが確認された。統計的仮説検定によるウィンドウ内の変化検出について, W' を各要素で分割するのではなく一箇所で等分割し, 精度を維持しながら速度を改善する手法も提案されており [1], 提案手法に適用することで更に計算時間を短縮できる可能性がある。

加えて, 統計的仮説検定の手法に関しても, サンプルサイズが小さい標本に対してより頑健な種々の手法 [16] を検討してウィンドウの幅 w および w' を小さくすることで, 更にリアルタイム性を向上させられる余地があると考えられる。

5. まとめ

本報告では, EC サイトの運営者にとって有用な情報である, 購買に繋がるユーザーの行動の変化検出について, ユーザーごとの直近の閲覧履歴から特徴量を作成し, 統計的仮説検定によって変化検出を行う手法を提案した。そして, 提案手法の有効性を示すために, 実際の EC サイトのプロダクション環境のデータを用いて, 特徴量に用いる商品属性の検討と, 精度および計算時間の確認を行った。提案手法の計算時間は 1.7 ミリ秒から 1.8 ミリ秒程度であり, EC サイトへの導入において問題ないことが確認された。非購買ユーザーに関する精度に関しては隠れマルコフモデル

を上回っており, 偽陽性率に対して偽陰性率が低いことは購買に繋がるユーザーの行動の変化検出の目的に沿っている。今後の課題としては, 特徴量の値が変化する際の正負方向のモデルへの組み込みや, 特徴量の値の変動が大きい期間の除外等により, 高精度に検出を行う仕組みの検証を行う必要がある。また, 変化検出に用いるウィンドウを各要素で分割するのではなく一箇所で等分割することによる計算時間の短縮, 小標本に対して頑健な統計的仮説検定の手法を検討したい。

参考文献

- [1] Bifet, A. and Gavaldà, R.: Learning from Time-Changing Data with Adaptive Windowing, Proc. 7th SIAM International Conference on Data Mining, SIAM (2007).
- [2] Bobadilla, J., Ortega, F., Hernando, A. and Gutiérrez, A.: Recommender systems survey, Knowledge-Based Systems, Vol.46, pp.109-132 (2013).
- [3] Burke, R: Hybrid Recommender Systems: Survey and Experiments, User Modeling and User-Adapted Interaction, Vo.12, No.4, pp.331-370 (2002).
- [4] Cowles, M. and Davis, C.: On the Origins of the .05 Level of Statistical Significance, American Psychologist, Vol. 37, No.5, pp.553-558 (1982).
- [5] Fagerland, W.M. and Sandvik, L.: The Wilcoxon-Mann-Whitney test under scrutiny, Statistics in Medicine, Vol.28, Issue 10, pp.1487-1497 (2009).
- [6] Fisher, R.A.: Statistical Methods for Research Workers 5th Edition, p.45, Oliver and Boyd (1934).
- [7] Kearney, M., Osmani, A., Basques, K. and Miller, J.: Measure Performance with the RAIL Model, Web Fundamentals, Google Developers (Online), 入手先 (<https://developers.google.com/web/fundamentals/performance/rail>) (2020.04.06).
- [8] Lops, P., Gemmis, D.M. and Semeraro, G.: Content-based Recommender Systems: State of the Art and Trends, Recommender Systems Handbook, pp.73-105, Springer (2011).
- [9] Moe, W.W.: Buying, searching, or browsing: Differentiating between online shoppers using in-store navigational clickstream, Journal of Consumer Psychology, Vol.13, Issues 1-2, pp.113-123 (2003).
- [10] Rabiner, L.R.: A tutorial on hidden Markov models and selected applications in speech recognition, Proc. IEEE, Vol.77, No.2, pp.257-286 (1989).
- [11] Rasch, D., Kubinger, K.D. and Moder, K.: The two-sample t test: Pre-testing its assumptions does not pay off, Statistical Papers, Vol.52, No.1, pp.219-231 (2011).
- [12] GMO ベバボ株式会社: minne, minne (オンライン), 入手先 (<https://minne.com/>) (2020.04.06).
- [13] 経済産業省 商務情報政策局 情報経済課: 平成 30 年度我が国におけるデータ駆動型社会に係る基盤整備 (電子商取引に関する市場調査), 経済産業省 (オンライン), 入手先 (<https://www.meti.go.jp/press/2019/05/20190516002/20190516002-1.pdf>) (2020.04.06).
- [14] 三宅悠介, 松本亮介, 力武健次, 栗林健太郎: アクセス頻度予測に基づく仮想サーバの計画的オートスケーリング, 情報処理学会研究報告, Vol.2017-IOT-038, No.13, pp.1-8 (2017).
- [15] 中野暁, 近藤文代: 混合隠れマルコフモデルによるオンライン・オフラインチャネル選択行動のモデリング, オ

- ペレーションズ・リサーチ 経営の科学, Vol.63, No.10, pp.635-646 (2018).
- [16] 名取真人: マン・ホイットニーの U 検定と不等分散時における代表値の検定法, 霊長類研究, Vol.30, No.1, pp.173-185 (2014).
- [17] 岡野原大輔: 機械学習の理論と実践, 第 11 回先進的計算基盤システムシンポジウム (SACSIS 2013), SACSIS 2013 (オンライン), 入手先 (http://sacsis.hpcc.jp/2013/files/sacsis2013_ml.okanohara.pdf) (2020.04.06).
- [18] ウィラワン・ドニ・ダハナ: 情報探索の目的を考慮した購買決定モデル, マーケティング・サイエンス, Vol.25, No.1, pp.15-35 (2017).
- [19] 山口景子: 消費者の心理状態の変化を考慮した動的モデルによる購買量分析, マーケティング・サイエンス, Vol.23, No.1, pp.61-78 (2015).
- [20] Zheng, A. and Casari, A.: Feature Engineering for Machine Learning, O'Reilly Media (2018). 株式会社ホクソエム (訳): 機械学習のための特徴量エンジニアリング—その原理と Python による実践, O'Reilly Japan (2019).