Web 広告推薦のための長期的・短期的興味を考慮した ユーザの潜在的興味分析方式

 山口 由莉子 Panote Siriaraya^{††} 森下 民平^{†††} 稲垣 陽一^{†††} 中島 伸介^{††}

 張 建偉^{††††} 青井 順一^{†††††} 中島 伸介^{††}

† 京都産業大学大学院 先端情報学研究科 〒 603-8555 京都府京都市北区上賀茂本山 ††† 株式会社きざしカンパニー 〒 103-0015 東京都中央区日本橋箱崎町 20-14 日本橋巴ビル 6F ††† 岩手大学 理工学部 〒 020-8551 岩手県盛岡市上田 4-3-5

††††† 株式会社マイクロアド 〒 150-0045 東京都渋谷区神泉町 8-16 渋谷ファーストプレイス 5 階 †† 京都産業大学 コンピュータ理工学部 〒 603-8555 京都府京都市北区上賀茂本山 E-mail: †i1658164@cse.kyoto-su.ac.jp, ††{k6180,nakajima}@cc.kyoto-su.ac.jp,

†††{mimpei,inagaki,reyn}@kizasi.jp, ††††zhang@iwate-u.ac.jp, ††††aoi_junichi@microad.co.jp

あらまし 企業が製品やサービスのために行う宣伝活動の一形態として、Web 広告が注目されている。ただし、現在の Web 広告推薦の主流であるキーワードマッチングをベースとした手法では、数多く存在するであろう潜在的な購買者層に対して効果的に Web 広告を推薦することは困難である。そこで、我々はユーザの潜在的興味を分析することで、より効果的な Web 広告推薦方式を実現することを目指した研究を進めている。我々は先行研究において、潜在的興味判別器の精度は、学習データの特徴量に FQDN を使用した場合と Web ページのカテゴリを使用した場合とではカテゴリを使用した場合が良いという知見を得た。また、「分析対象となる閲覧履歴の取得期間は長い方が効果的である」という仮説を立て、検証実験を行った。しかしながら、仮説の妥当性を支持する結果ではなかった。その要因の一つに分析期間の長短にそれぞれメリット、デメリットがあるためと考察した。そこで本研究では、長期(ライフスタイル)と短期(直近の興味)の両方を考慮できるような、ユーザの潜在的興味分析方式を提案する。また、本方式に関する評価実験結果について考察したので報告する。

キーワード Web 広告, ユーザプロファイリング, アクセスログ分析

1. はじめに

企業が行う製品やサービスの宣伝活用の一形態として, Web 広告が注目されている。2016年、日本の Web 広告媒体費は初 めて1兆円を越え[1], ますます市場の拡大が見込まれる. Web 広告が注目されている要因の一つにリアルタイムでユーザ個人 に合わせた Web 広告を配信する仕組み、リアルタイムビッディ ング (RTB) [2] (図 1 参照) の普及が挙げられる. そしてまた, Web 広告推薦は、対象となるユーザの属性・嗜好に基づいた個 別の広告を表示できるターゲティング性と, ユーザのマウス操 作に合わせて能動的にアクションする等のインタラクティブ性 を有しており、従来では実現できなかった新たな広告推薦が可 能となっている. 現在, ターゲティング性が考慮された Web 広 告推薦方式としては, リスティング広告, 興味関心連動型広告, リターゲティング広告等が挙げられる. これら Web 広告推薦 方式では、ユーザの検索クエリや閲覧内容、および属性等を考 慮しているが、ユーザの潜在的興味を考慮した分析が行われて いるとは言えず、Web 広告を通じて購買者の層を広げるにはま だまだ改良の余地がある. 従来の方式は既にユーザが興味を持 ち,明確に認知しているキーワードの広告を掲載する,あるい は広告主サイトへのアクセス履歴があるユーザに広告を配信するものであり、広告主は潜在的興味を持つ新たな購買者、購買層をWeb 広告によって獲得することが難しい。また、ユーザが対象サイトに対して興味を持っている場合、および認知はしている場合でも、対象サイトにアクセスしていないということのみでそのユーザに対象Webサイトの広告を提示しない事は広告主にとって機会損失であると言える。そこで、我々はユーザの潜在的興味を分析することで、より効果的なWeb広告推薦方式を実現することを目指した研究を進めてきた。我々は先行研究[3]において、ユーザの潜在的興味分析に基づくWeb広告推薦方式を提案すると共に、興味判定器を作成する上で必要となる学習データについての評価実験を行った。その中で、潜在的興味判別器の精度は、学習データの特徴量にFQDNを使用した場合とWebページのカテゴリを使用した場合とではカテゴリを使用した場合が良いという知見を得た。

また、「分析対象 (学習データ) となる閲覧履歴の取得期間は 長い方が効果的である」という仮説を立て、検証実験を行った。 しかしながら、仮説の妥当性を支持する結果ではなかった。 そ の要因の一つに分析期間の長短にそれぞれ以下のようなメリット、デメリットがあるためと考察した。

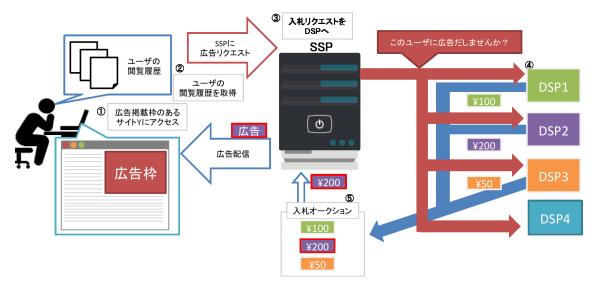


図 1 リアルタイムビッディング (RTB) 環境

分析する閲覧履歴が長い場合

メリット: 分析ページ数の確保が容易

デメリット: 閲覧履歴中の興味カテゴリのバラつきが生じ

易い

分析する閲覧履歴が短い場合

メリット: 閲覧履歴中の興味カテゴリのバラつきが生じ

難い

デメリット: 分析ページ数の確保が困難

そこで本研究では、短期の閲覧履歴と長期の閲覧履歴を用いることによる、ユーザの短期的・長期的興味を考慮した潜在的 興味分析することを提案し、本方式の精度に関する評価実験を 行ったので報告する.

以下,2節にて,関連研究について述べ,3節では短期的興味と長期的興味併せたユーザの潜在的興味に基づくWeb広告推薦方式について説明する。そして4節では,ユーザの短期と長期の閲覧履歴を学習データとして用いた興味判定器の精度について述べる。最後に5節にて,まとめと今後の課題について述べる。

2. 関連研究

以下に、Web 広告に関連した研究について述べ、我々の提案 方式との差異を示す。

鈴木らは Web サイトのアクセスログと関連データを用いて 消費者の購買行動を明らかにするため、購買行動に混合分布を 当てはめて、購買サイクルを推定し購買の前後の行動の特徴を 分析している [4]. また、生田目らは EC サイトのアクセスログ と関連データを用いてサイト会員の日常の閲覧行動を考慮した 購買予兆の発見モデルの提案 [5] をしており、また久松らはそ の購買予兆を発見するモデルをロジット・モデルを元に作成し ている [6]. 以上の研究ではユーザの購買予兆を発見し広告を表 示するという研究を行っているが、本研究では購買の予兆を発 見するのではなく、閲覧しているユーザの潜在的な興味に基づ いて広告を推薦するか否かを決める事を目的としている. 内野らはユーザが次に見たい情報を予測し、それに関する広告配信する Web 広告配信システムを kMER およびマルコフモデルを応用した研究を行っている [7]. この研究はマルコフモデルを使っているため、閲覧履歴の時系列パターンに着目した取り組みといえる。しかしながら、多少時系列パターンが異なっていたとしても、同様の Web サイト群を閲覧しているのであれば、ユーザの興味関心は類似している、というのが本研究の立場である。すなわち本研究による提案手法がより幅広く類似ユーザの検索・発見することを可能にすると考えている。

Web 広告における RTB のさまざまな側面を検討するため、 数多くの学術研究が発表されている. 入札プロセスそのものに 焦点を当て、RTB プロセスでの落札可能な価格を予測する研 究[8]や,コンバージョンされた際の利益に基づいて最適化され た円滑な予算配分へのアプローチを提供する研究[9],リアルタ イム入札のための最適戦略の特定についての研究がある[10]. ま た, RTB の概要と RTB の有用性について述べている研究 [11] や Web 広告の供給側から広告目録の最適な価格設定の調査が 行われている[12]. さらに、コンバージョン率(特定の広告を 見たユーザが行動を起こす確率)をリアルタイム入札環境でど のように見積もることができるか[13], クリック率(CTR)が オンライン広告のマルチメディア機能からどのように予測でき るか[14] についての研究などがある. また, Web 広告の推薦 システムに関しては、特定のウェブサイトに対して Web 広告の 作成に役立つ複数のキーワードを自動的に抽出し、推薦するシ ステムの開発が検討されている[15]. 本研究では RTB を用い てユーザが認知していない商品を認知してもらうことによって Web 広告での宣伝活動がより活性すると考えている.

Kuang-chih Lee らはユーザ、Web ページ広告をそれぞれ階層的にグループ化したものを組み合わせたときの CVR を推定している [16] が、本研究では Web サイトごとのユーザモデルによってユーザの潜在的興味を発見するという立場である. すなわち本研究による提案手法がより幅広く類似ユーザの検索・発見することを可能にすると考えている.

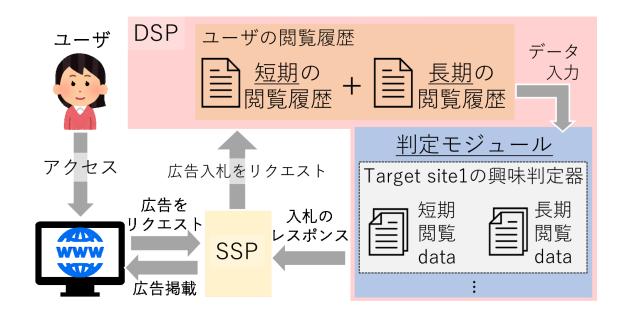


図 2 ユーザの潜在的興味に基づく Web 広告システム

3. 短期的興味と長期的興味併せたユーザの潜在 的興味に基づく Web 広告推薦方式

本節では、3.1 節にて、RTB の処理の流れ、3.2 節にて提案する短期的興味と長期的興味併せたユーザの潜在的興味に基づく Web 広告推薦方式の概要と処理手順について説明する.

3.1 リアルタイムビッディング (RTB) 環境

本研究で研究開発を行う Web 広告推薦方式では、リアルタイムビッディング (RTB) 環境での活用を想定している。そこでまずは、RTB について説明する(図1参照)。

RTB とは 1 配信 (1 インプレッション) 毎にリアルタイムで瞬時に,広告枠を買う側 (広告主や広告会社) が入札し,広告枠を供給する側 (媒体社) が入札価格の最も高い入札者に広告枠を売る仕組みのことである. SSP(サプライサイドプラットフォーム) とは,広告枠を供給する側,媒体社が使用するプラットフォームのことである. DSP(デマンドサイドプラットフォーム) とは,広告主や広告会社など,広告枠を買う側が使用するプラットフォームのことである. つまり, DSP が広告枠を買う側の都合の良い条件,(配信対象者や掲載面,配信時間など)をもとに入札し,SSP が最も高い入札価格を提示した DSP に広告枠を提供し(売り),広告を配信するという関係である.

次に、同じく図1を用いて、RTBの処理の流れを説明する。まず広告枠のある Web サイト(図1の場合、サイト Y)にユーザがアクセスすると同時に広告タグを読み込む。すると、SSP に広告リクエストがかかる。SSP は DSP にビッドリクエストを行う。ビッドリクエストとは「このような広告枠に、こんなユーザがアクセスしましたが、広告を表示させますか」というリクエストのことである。ビッドリクエストには、アクセスしてきたユーザを識別する ID(クッキー) や IP アドレス、アクセスに用いたブラウザ(ユーザエージェント)などのユーザに関する情報や、また広告先を掲載する掲載先のドメインとコンテ

ンツカテゴリー,広告枠のID,広告のサイズなど,広告枠や その掲載先の情報(図1の場合, Yサイトの情報)などが含 まれている. DSP 側は SSP から送られてきたビッドリクエス トの分析を行う. 例えば、ユーザは広告主が広告配信をしたい ターゲットユーザであるか,広告掲載先は広告主の広告を閲覧 するのに適した Web ページ, Web サイトであるか, など瞬時 に判断する. そして広告枠を買いたい金額を含めて, 買いたい 意思,ビッドレスポンスを SSP に送る. これが DSP の入札と なる、図1の場合、DSP1.2.3.4 がそれぞれビッドリクエストの 分析を行い,入札をするか,どの値段で入札するかを判断する. 今回の場合は、DSP1,2,3, はそれぞれ¥100,¥200,¥50 で入札 し DSP4 は広告枠を買わないと判断し、入札しなかった、SSP は各 DSP の中からの最も高い入札価格を提示した DSP に広 告枠を提供し広告を配信する. そして最も高い値段で入札した DSP の広告を広告枠に入れ、広告を掲載する(インプレッショ ン). 図1の場合,一番高額で入札した DSP2 が広告枠を落札 し、DSP2の広告が広告枠に掲載されるという流れである.

3.2 短期的興味と長期的興味併せたユーザの潜在的興味に 基づく Web 広告推薦方式

前節にて説明した従来の手法では、ユーザが既に興味を持ち、認知しているキーワードに関連する広告を提示するものであり、広告主にとっては新しい購買者、購買層を Web 広告によって獲得することが難しい. そこで、本研究ではユーザの潜在的興味を分析することで、より効果的な Web 広告推薦を実現することが可能なユーザの潜在的興味に基づく Web 広告推薦を目指す.

先行研究[3]では「分析対象(学習データ)となる閲覧履歴の取得期間は長い方が効果的である」という仮説を立て、検証実験を行った。しかしながら、仮説の妥当性を支持する結果ではなかった。その要因の一つとして、閲覧履歴の取得期間の長短にそれぞれメリットデメリットがあるためと考察した。そこ

で、ユーザの閲覧履歴を短期と長期に分けて用いることによってユーザの短期的・長期的興味を考慮した潜在的興味分析を提 案する.

ユーザの短期的・長期的興味を考慮した潜在的興味分析方式について図2を用いて説明する.この手法では、システムは事前にターゲットサイトにアクセスしたことのあるユーザの短期の閲覧履歴と長期の閲覧履歴を取得する.短期の閲覧履歴を取得することによって,日々揺れ動く興味のうち、現時点の興味を、長期の閲覧履歴を取得することによって対象ユーザのベースとなる定常的興味を考慮したユーザモデルを保持した判定器を作成することができ、閲覧履歴とターゲットサイトとの直接的な関連が小さい場合においても、ターゲットサイトに対してユーザの潜在的興味があるか推測することが可能になる.この判定器は閲覧履歴より特定の特徴量をベクトル化し、scikit-learn [17]を用いロジスティック回帰を行い作成する.また、本研究の実験では特定の特徴量は先行研究 [18] の結果より、Webページのカテゴリを用いる.カテゴリについては4.1節にて説明する.

実際に広告推薦を行う場合は、アクセスしてきたユーザの短期の閲覧履歴と長期の閲覧履歴を取得し、事前に作成した判定器にてユーザがターゲットサイトに対して潜在的興味があるかを推定する。この方法により、今まで広告を配信していなかったユーザへの広告配信が可能となり、ターゲットサイトの広告効果を高められる。つまり、ユーザの潜在的興味に基づくWeb広告推薦方式を用いることで新しい購買者、購買層をWeb広告によって獲得することが可能となる。

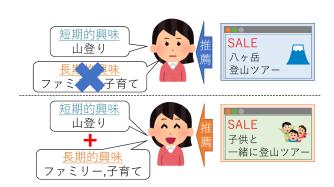


図3 短期的興味と長期的興味を併せて考慮していない場合と考慮している場合の広告推薦例

さらに短期の閲覧履歴でユーザの短期的興味,長期の閲覧履歴でユーザの長期的興味を考慮することができ、よりユーザにあった広告を推薦できると考えている。短期的興味が山登りで長期的興味が子育てであるユーザに広告を提示する場合を例に挙げて(図3参照)説明する。短期的興味のみを考慮した広告推薦手法を用いた場合、ユーザの山登りへの難易度などが考慮されていない広告が推薦候補にあげられ、掲載される可能性が高い。しかしながら、短期的興味と長期的興味を併せて考慮することによってユーザの山登りに関する難易度やライフスタイルを考慮した、よりユーザにあった広告推薦が可能になると考えられる。

以上が本研究の提案手法である.次節では、新たな提案手法となる短期的興味と長期的興味併せたユーザの潜在的興味を持つユーザモデルの学習方法に関する実験的考察を述べる.

4. 短期的興味と長期的興味併せたユーザの潜在 的興味を持つユーザモデルの学習方法に関す る実験的考察

本節では、短期的興味と長期的興味併せたユーザの潜在的興味を持つユーザモデルの学習方法に関して、実験に基づく検討を行ったので説明する。本評価実験は、あるターゲットサイトを閲覧したユーザの短期の閲覧履歴と長期の閲覧履歴をポジティブデータとして学習し、同様の閲覧履歴を持つ他のユーザが当該ターゲットサイトを閲覧しているかを調べることで、閲覧履歴である学習データの妥当性を検証するものである。また、本実験は提案手法で採用する閲覧履歴に基づく潜在的興味推定において、短期、長期の閲覧履歴を用いることや、どの程度の閲覧内容を要約した情報(カテゴリ区分)を使用することが適切かを検討する上で重要である。

4.1 節ではユーザモデル構築用学習データである閲覧履歴取 得区間が予測性能に及ぼす影響について,4.2 節ではユーザモ デル構築用学習データの特徴量の違いが予測性能に及ぼす影響 について述べる.

4.1 ユーザモデル構築用学習データである閲覧履歴取得区 間が予測性能に及ぼす影響

本節では、短期的閲覧履歴と長期的閲覧履歴に分けた閲覧履歴をユーザモデル構築用学習データに用いる事が予測性能に及ぼす影響についての評価実験行う.

本評価実験では、"ターゲットサイトに訪れたことのあるユーザらの短期の閲覧履歴、長期の閲覧履歴"をポジティブデータ、"ターゲットサイトに訪れたことのないユーザらの短期の閲覧履歴、長期の閲覧履歴"をネガティブデータとし、双方をあわせて学習データとした。この学習データを用いて、学習することでユーザモデルを構築し、別途用意したテストデータに基づいて予測性能を評価した。

以下,4.1.1節では実験手順と実験データについて,4.1.2節では実験結果と考察を述べる.

4.1.1 ユーザモデル構築用学習データである閲覧履歴取得 区間に関する実験手順と実験データ

前述の通り,"ターゲットサイトに訪れたことのあるユーザらの短期の閲覧履歴,長期の閲覧履歴"をポジティブデータ,"ターゲットサイトに訪れたことのないユーザらの短期の閲覧履歴,長期の閲覧履歴"をネガティブデータとし,双方をあわせて学習データとした。また,先行研究 [3] よりユーザモデル構築用学習データのポジティブ・ネガティブ比率は1:1 で問題ないという知見を得ているため,本実験では学習データのポジティブ・ネガティブ比率を1:1 で行うこととする。ターゲットサイトは表1031 サイトを使用した。

学習期間は、単一区間の場合 31 日間 $(8/1\sim31)$, 短期と長期で分けた場合の長期区間は 30 日間 $(8/1\sim30)$, 短期区間は 1日

表 1 ターゲットサイト

	表 1 ターゲットサイト
サイト No	サイト内容
1	まとめサイト (プロ野球チーム A)
2	口コミサイト (ゴルフ)
3	まとめサイト (車)
4	まとめサイト (女性向け旅行)
5	まとめサイト (浮気・不倫)
6	まとめサイト (アイドル X)
7	まとめサイト (既婚女性向け生活情報)
8	歌舞伎公式サイト
9	まとめサイト (アイドル Y)
10	アニメ情報サイト
11	まとめサイト (アイドル Y)
12	まとめサイト (事故物件)
13	自己啓発サイト
14	動画サイト (アニメ)
15	口コミサイト (就活)
16	ファッションサイト
17	まとめサイト (プロ野球チーム B)
18	まとめサイト (ファッションブランド)
19	まとめサイト (男性向け)
20	サッカーサイト
21	チラシ掲載サイト
22	情報配信サイト(ゴルフ)
23	まとめサイト(ソーシャルゲーム)
24	まとめサイト (サッカー)
25	情報配信サイト(テニス)
26	まとめサイト (既婚女性向け)
27	口コミサイト(沖縄移住)
28	まとめサイト (アイドル Z)
29	まとめサイト (戦隊もの)
30	出席,日程調整サイト
31	まとめサイト (プロ野球チーム С)

間 (8/31) とした. また,正解ラベルとなる,ターゲットサイトへのアクセスの有無の観測期間は8月31日に設定した. 閲覧履歴のデータにはユーザ ID,アクセス URL,アクセスページカテゴリ,アクセス日が含まれる. 先行研究 [3] により,ユーザモデル構築用の学習データの特徴量は Webページのカテゴリで問題ないという知見を得ているため,本実験では,ユーザモデル構築用の学習データの特徴量は Webページのカテゴリを使用する. Webページのカテゴリ分類については先行研究 [19]によって作成された Webページカテゴリ分類器を使用した.学習データ・予測データともに,クロールした Webページの内容を形態素解析し,得られた語句の頻度を特徴量とした.また,カテゴリ分類器にはライブラリとしては liblinear を用い,アルゴリズムとしてはロジスティック回帰を使用している.カテゴリ区分は大,中,小の3区分用意した(表2参照).

本研究で使用したユニークカテゴリ数,すなわち特徴量を大カテゴリにした場合の特徴量ベクトルの次元数は23個,特徴量を中カテゴリにした場合の特徴量ベクトルの次元数は274個,特徴量を小カテゴリにした場合の特徴量ベクトルの次元数は837個用意した。また,大カテゴリ,中カテゴリ,小カテゴ

表 2 大・中・小のカテゴリ区分の例

大カテゴリ	中カテゴリ	小カテゴリ
ファッション	服飾雑貨	ジュエリー
ファッション	服飾雑貨	バック
食料品	食材	果物&野菜
食料品	レストラン	ファーストフード
不動産	不動産購入	中古戸建て

リ全てを混合したカテゴリ区分混合の次元数は全カテゴリの合計である 1,134 個である. 本実験では大カテゴリ,中カテゴリ,小カテゴリ全てを混合したカテゴリ区分を用いた. つまり,単一区間での特徴量の次元数は 1,134 個,短期と長期と分けた場合の特徴量は短期期間での特徴量の次元数 (1134 次元)と長期期間での特徴量の次元数 (1134 次元)の合計なので 2,268 個使用した. なお,学習期間でユーザがターゲットサイトにアクセスしていた場合,そのアクセスデータは特徴量から除外している.

学習には scikit-learn [17] を用いてロジスティック回帰を行った。また、同じターゲットサイト、同じ特徴量を用い、学習データ、テストデータをランダムに 10 回選択し実験を行った。実験手順を以下に示す。

手順1 取得した閲覧履歴を先ほど述べた学習期間の内容に沿って短期の閲覧履歴と長期の閲覧履歴に分ける。ポジティブデータはターゲットサイトにアクセスした事のあるユーザの短期の閲覧履歴と長期の閲覧履歴、ネガティブデータはターゲットサイトにアクセスした事のないユーザの短期の閲覧履歴と長期の閲覧履歴を使用する。学習データのポジティブデータは表3と表4の内容を用いた。テストデータのネガティブデータは全てのターゲットサイトにおいて10,000人分のデータを使用した。また、学習データとテストデータは実験毎にランダムで取得する。

手順2 特徴量を Web ページのカテゴリとし, scikit-learn を用い, 手順1 で作成した学習データを学習させて 判別器を構築する. アルゴリズムはロジスティック 回帰を使用する.

手順3 手順2で作成した判定器を用いて,手順1で作成したテストデータをテストし,判定器の性能を求める.

上記手順により 31 個のターゲットサイトそれぞれの興味判定器を作成し、精度を求めた.実験結果については、次節にて考察する.また、テストデータのポジティブデータとネガティブデータの差が大きい理由は、世の中にあるポジティブデータが極端に少なくネガティブデータが明らかに多いという実際のデータ比率に近づけるためである.

なお本研究で構築する判定器の性能を判定する尺度としては、AUC[20]を用いる、AUCは式(1)で表される。

$$AUC = \int_{-\infty}^{-\infty} TPR(s) \, FPR'(s) \, ds \tag{1}$$

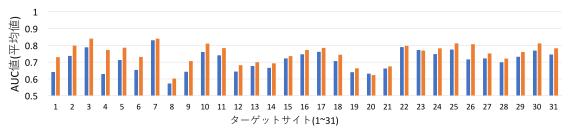
TPR は真陽性率 (true positive rate, 本当に閲覧したユーザ

		サイト 1	サイト 2	サイト3	サイト 4	サイト 5	サイト 6	サイト 7	サイト 8	サイト 9	サイト 10	サイト 11	サイト 12	サイト 13	サイト 14	サイト 15	サイト 16
対象サイト	・アクセスユーザ数	107	148	416	226	200	285	220	71	155	160	157	155	172	69	342	140
学習	ポジティブデータ数	57	100	300	200	100	200	200	35	100	100	100	100	100	59	200	100
データ	ネガティブデータ数	57	100	300	200	100	200	200	35	100	100	100	100	100	59	200	100
テストデータ	ポジティブデータ数	50	48	116	26	100	85	20	36	55	60	57	55	72	10	142	40

表 4 実験に用いる学習データ数, テストデータのポジティブデータ数 (サイト 17~31)

	サイト 17	サイト 18	サイト 19	サイト 20	サイト 21	サイト 22	サイト 23	サイト 24	サイト 25	サイト 26	サイト 27	サイト 28	サイト 29	サイト 30	サイト 31
対象サイトアクセスユーザ数	51	254	184	140	123	158	216	166	293	131	396	230	369	69	340
学習 ポジティブデータ数	26	200	100	100	100	100	200	100	200	100	300	200	209	300	300
データネガティブデータ数	26	200	100	100	100	100	200	100	200	100	300	200	209	300	300
テストデータ ポジティブデータ数	25	54	84	40	23	58	16	66	93	31	96	30	100	95	40

閲覧履歴取得区間別(単一期間,短期長期)比較実験結果



■単一期間(31日間) ■短期(8/31)長期(8/1~30))

図 4 閲覧履歴取得区間 (短期期間と長期期間) が予測性能の及ぼす影響に関する実験の AUC 値 の平均結果

を正しく閲覧したと判定した割合)、FPR は偽陽性率 (false positive rate、実際には閲覧しなかったユーザを誤って閲覧したと判定した割合)を表す。 ランダムな予測結果を返すモデルの AUC は 0.5 となり、必ず予測を的中させるモデルの AUC は 1.0 となる。したがって、少なくとも 0.5 以上の数値でなければ意味がなく、また 0.5 よりも明らかに大きな値であることが望ましい。

4.1.2 ユーザモデル構築用学習データである閲覧履歴取得 区間に関する実験結果および考察

モデル構築用学習データである閲覧履歴の取得区間が予測性 能に及ぼす影響について評価するために行った比較実験結果を 図 4 に示す. 図 4 に示した値は 10 回実験を行った AUC 値の 平均値である. 図 4 が示す通り, 31 サイト中 29 サイトが学習 データとなる閲覧履歴を短期期間と長期期間と分けた場合が, 閲覧履歴を単一区間にした場合と比べて興味判定器の性能が高 い結果となった. また, t 検定した結果, 1 %水準で有意 (p = 0.0000007013) だったため、学習データとなる閲覧履歴を短期 期間と長期期間と分けた場合の興味判定器の精度と、閲覧履歴 を単一区間にした場合の興味判定器の精度に有意な差があると 判断できた. つまり, ユーザモデル構築用学習データである閲 覧履歴の取得区間は、単一区間を取得するより、長期期間と短 期期間に分けて取得することによって興味判定器の性能が高く なる可能性があると言える. 今後は特徴ベクトルであるアクセ ス回数の上限値の設定や, アクセス回数の割合を用いるなど, 特徴ベクトルの正規化を行い、興味判定器の精度をあげる必要 があると考えている.

4.2 ユーザモデル構築用学習データの特徴量の違いが予測性能に及ぼす影響

4.1 節の実験では、特徴量を短期期間と長期期間共に大カテゴリ、中カテゴリ、小カテゴリ全てを混合したカテゴリ区分を使用したため、短期的興味、長期的興味を推定するに当たってそれぞれの適切なカテゴリ区分が不明であった。そこで 4.2 節では特徴量を短期期間と長期期間それぞれの適切なカテゴリ区分の選別と学習データの特徴量の違いが予測性能に及ぼす影響について実験的考察を行った。

4.2.1 節では手順 2 における特徴量を短期閲覧履歴ではカテゴリ区分混合を用い,長期閲覧履歴では小カテゴリ,中カテゴリ,大カテゴリの 3 パターンの学習データをそれぞれ学習し判別器を構築する。3 パターンの判別器それぞれの精度を求め,長期閲覧履歴の適切なカテゴリ区分を検討した。4.2.2 節では,4.2.1 節の結果を踏まえ手順 2 における特徴量を長期閲覧履歴でのカテゴリ区分を設定し,短期閲覧履歴では小カテゴリ,中カテゴリ,大カテゴリの 3 パターンの学習データをそれぞれ学習し判別器を構築する。3 パターンの判別器それぞれの精度を求め,短期閲覧履歴の適切なカテゴリ区分を検討した。

4.2.1 学習データとなる長期閲覧履歴の特徴量に関する実験的考察

a) 実験手順と実験データ

閲覧履歴の取得期間は 4.1 節での評価実験と同様である. 実験回数はそれぞれ 10 回行った. なお, 学習には scikit-learn を

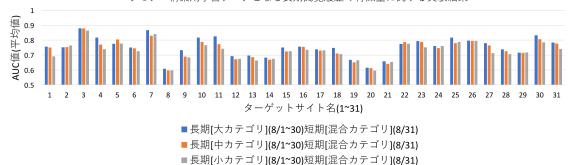


図 5 長期閲覧履歴の特徴量が予測性能の及ぼす影響に関する実験の AUC 値の平均結果

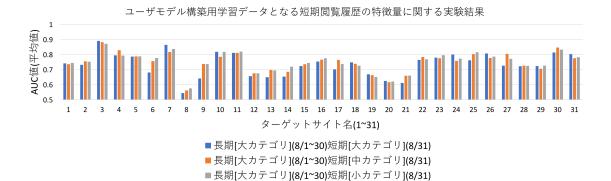


図 6 短期閲覧履歴の特徴量が予測性能の及ぼす影響に関する実験の AUC 値の平均結果

用い,アルゴリズムとしてはロジスティック回帰を使用した.実験手順,実験条件共に4.1節と同様である.しかしながら,手順2における特徴量を短期閲覧履歴ではカテゴリ区分混合,長期閲覧履歴では小カテゴリ,中カテゴリ,大カテゴリの3パターンの学習データを用意した.3つの学習データをそれぞれ学習し判別器を構築する.その後テストデータを用いて3パターンの判別器それぞれの精度を求めた.実験結果については,次節にて考察する.

b) 実験結果および考察

31 のターゲットサイト (サイト $(1\sim31)$) において,ユーザモデル構築用学習データとなる長期閲覧履歴の特徴量の違いが予測性能に及ぼす影響について評価するために行った実験結果を図 5 に示す.図 5 が示す通り,31 サイト中 27 サイトが,長期閲覧履歴のカテゴリ区分に大カテゴリを用いた場合が他のカテゴリ区分に比べて判定器の精度が高い結果となった.

また,長期閲覧履歴のカテゴリ区分が大カテゴリの場合と中カテゴリの場合との判別器の精度に 1 %水準で有意な差 (p=0.0000600264) が見られ,長期閲覧履歴のカテゴリ区分が大カテゴリの場合と小カテゴリの場合との判別器の精度においても 1 %水準で有意な差 (p=0.0000017075) が見られた.よって,長期の閲覧履歴でユーザの長期的興味を推測する場合は,細やかカテゴリ区分よりも,大カテゴリのような大まかなカテゴリ区分がユーザのライフスタイルなど,定常的な興味を現しやすいと考えられる.

4.2.2 学習データとなる短期閲覧履歴の特徴量に関する実験的考察

a) 実験手順と実験データ

閲覧履歴の取得期間は 4.1 節での評価実験と同様である. 実験回数はそれぞれ 10 回行った. なお, 学習には scikit-learn を用い, アルゴリズムとしてはロジスティック回帰を使用した. 実験手順, 実験条件共に 4.1 節と同様である. しかしながら, 手順 2 における特徴量を長期閲覧履歴は 4.2.1 節の結果を踏まえて大カテゴリとした. また, 短期閲覧履歴は小カテゴリ, 中カテゴリ, 大カテゴリの 3 パターンを用意した. 3 つの学習データをそれぞれ学習し判別器を構築する. その後テストデータを用いて 3 パターンの判別器それぞれの精度を求めた. 実験結果については, 次節にて考察する.

b) 実験結果および考察

31 のターゲットサイト (サイト $(1\sim31)$) において,ユーザモデル構築用学習データとなる短期閲覧履歴の特徴量の違いが予測性能に及ぼす影響について評価するために行った実験結果を図 6 に示す.

図6が示す通り、31サイト中8サイトが、短期閲覧履歴のカテゴリ区分に大カテゴリを用いた場合が他のカテゴリ区分に比べて判定器の精度が高く、31サイト中9サイトがカテゴリ区分に中カテゴリを用いた場合が他のカテゴリ区分に比べて判定器の精度が高く、31サイト中14サイトがカテゴリ区分に小カテゴリを用いた場合が他のカテゴリ区分に比べて判定器の精度が高い結果となった。ここで、表5に31サイトのAUC値平均値を示す。

表 5 3 1 サイトの AUC 値の平均値 (長期: 大カテゴリ)

短期カテゴリ区分	カテゴリ混合	大カテゴリ	中カテゴリ	小カテゴリ
AUC 値 (平均)	0.7542	0.7349	0.7482	0.7509

表5の結果より、短期のカテゴリ区分はカテゴリ区分混合が他のカテゴリ区分と比べて最も良いという結果となった.しかしながら、カテゴリ区分の差は小さいく、短期のカテゴリ区分は混合が必ず良いとは言い難い.また、長期のカテゴリ区分と短期のカテゴリ区分の全ての組み合わせの評価実験を行っていないため、今後は全ての組み合わせの評価実験を行い、さらなる検証を行う必要がある.

5. ま と め

本稿では、我々が研究を進めている、ユーザの潜在的興味分析に基づくWeb広告推薦方式に関する研究において、学習データとなるユーザの短期の閲覧履歴、長期の閲覧履歴を用いることによる、ユーザの短期的興味、長期的興味を考慮したユーザの潜在的興味分析方式について提案を行うと共に、本方式の精度に関する評価実験を行ったので報告した。なお、併せて学習データとなる特徴量の短期期間と長期期間それぞれの適切なカテゴリ区分の選別と学習データの特徴量の違いが予測性能に及ぼす影響について実験的考察を行ったので報告した。

学習データとなるユーザの短期の閲覧履歴,長期の閲覧履歴 を用いることによる,ユーザの短期的興味,長期的興味を考慮 したユーザの潜在的興味分析方式については,学習データとな るユーザの閲覧履歴を単一区間とした場合より,短期の閲覧履 歴,長期の閲覧履歴を用いた場合が興味判定器の精度が良いと いう結果となった.

今後の課題は、特徴量に含まれているノイズとなるデータを除去すべく、特徴量となるアクセス回数の上限値の設定や特徴量にアクセス回数の割合を用いるなど、特徴量の正規化を行う必要があると考える.

謝辞

本研究の一部は、JSPS 科研費 26330351、17H01822、岩手大学平成 29 年度研究人材育成支援経費による. ここに記して 謝意を表します.

文 献

- [1] 株式会社 電通,2016年日本の広告費,2016
- [2] 横山隆治, 菅原健一, 楳田良輝, DSP/RTB オーディエンス ターゲティング入門—ビッグデータ時代に実現する「枠」から 「人」への広告革命—, インプレス R & D, 2012 年.
- [3] 山口由莉子,森下民平,稲垣陽一,中本レン,張建偉,青井順一,中島伸介,Web 広告推薦のための閲覧カテゴリ情報を用いたユーザの潜在的興味分析方式,第9回データ工学と情報マネジメントに関するフォーラム(DEIM Forum 2017) B2-3, 2017 年.
- [4] 鈴木元也,生田目崇,購買前後のアクセスを考慮した Web サイトの顧客行動分析,日本オペレーションズ・リサーチ学会 2012 年秋季研究発表会 (2-F-3), 2012 年.
- [5] 生田目崇,朝日真弓,久松俊道,外川隆,顧客の閲覧行動を考慮

- した購買予兆発見モデル,日本オペレーションズ・リサーチ学会 2012 年秋季研究発表会 (2-F-2), 2012 年.
- [6] 久松俊道,外川隆,朝日真弓,生田目崇,EC サイトにおける購買予兆発見モデルの提案,オペレーションズ・リサーチ:経営の科学,2013年.
- [7] 内野英治,森田博彦,下野雅芳, Web 広告動的配信システム へのマルコフモデルと kMER の応用, 22nd Fuzzy System Symposium(Sapporo,Sept.6-8,2006)6B1-1, 2006 年.
- [8] W. C. H. Wu, M. Y. Yeh and M. S. Chen, "Predicting winning price in real time bidding with censored data." in Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1305-1314). ACM., 2015.
- [9] K. C. Lee, A. Jalali and A. Dasdan, "Real time bid optimization with smooth budget delivery in online advertising." in Proceedings of the Seventh International Workshop on Data Mining for Online Advertising (p. 1). ACM., 2013.
- [10] W. Zhang, S. Yuan and J. and Wang, "Optimal real-time bidding for display advertising." in Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 1077-1086). ACM., 2014.
- [11] Shuai Yuan, Jun Wang, Xiaoxue Zhao, Real-time bidding for online advertising: measurement and analysis, Proceedings of the Seventh International Workshop on Data Mining for Online Advertising, 2013 年.
- [12] A. Radovanovic and W. D. Heavlin, "Risk-aware revenue maximization in display advertising." in Proceedings of the 21st international conference on World Wide Web (pp. 91-100). ACM., 2012.
- [13] K. C. Lee, B. Orten, A. Dasdan and W. Li, "Estimating conversion rate in display advertising from past erformance data.," in Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 768-776), 2012.
- [14] J. Azimi, R. Zhang, Y. Zhou, V. Navalpakkam, J. Mao and X. Fern, "The impact of visual appearance on user response in online display advertising." in Proceedings of the 21st International Conference on World Wide Web (pp. 457-458). ACM, 2012.
- [15] S. Thomaidou and M. Vazirgiannis, "Multiword keyword recommendation system for online advertising." in International Conference on Advances in Social Networks Analysis and Mining (ASONAM (pp. 423- 427), IEEE, 2011.
- [16] Kuang-chih Lee, Burkay Orten, Ali Dasdan, Wentong Li, Estimating Conversion Rate in Display Advertising from Past Performance Data, Proc. of KDD 2012, 2012 年.
- [17] scikit-learn: Machine Learning in Python. http://scikit-learn.org
- [18] 山口由莉子,森下民平,稲垣陽一,中本レン,張建偉,青井順一,中島伸介,ユーザの潜在的興味に基づく Web 広告推薦方式の検討,第8回データ工学と情報マネジメントに関するフォーラム (DEIM Forum 2016) B1-2, 2016 年.
- [19] 森下民平,稲垣陽一,青井順一,オンライン広告データ分析と 分析基盤, SOFTECHS Vol. 34 No. 1 P36-P40, 2016 年.
- [20] 平井 有三, はじめてのパターン認識, 森北出版, 2012年.