

## ユーザの振る舞いに基づく興味推定によるコンテンツ閲覧支援手法に関する研究

顔, 洪

<https://doi.org/10.15017/1654898>

---

出版情報：九州大学, 2015, 博士（工学）, 課程博士  
バージョン：  
権利関係：全文ファイル公表済

ユーザの振る舞いに基づく興味推定による

コンテンツ閲覧支援手法に関する研究

顔 洪

ユーザの振る舞いに基づく興味推定による  
コンテンツ閲覧支援手法に関する研究

顔 洪

Hong Yan

2016年3月

# 目次

## 要旨

<b>1 序論</b> .....	<b>1</b>
1.1 研究の背景 .....	1
1.2 研究の目的 .....	4
1.3 論文の構成 .....	9
<b>2 関連研究</b> .....	<b>11</b>
2.1 情報推薦におけるフィードバックの活用に関する研究 .....	11
2.2 情報推薦に関する研究.....	14
2.3 ソーシャルメディアにおける閲覧支援に関する研究.....	15
<b>3 閲覧時の振る舞いに基づいたコンテンツの興味推定</b> .....	<b>17</b>
3.1 マイクロブログにおけるテキストコンテンツを閲覧時の振る舞いを利用した興味推定.....	18
3.2 オンラインショッピングにおける画像コンテンツを閲覧時の振る舞いを利用した興味推定.....	24
3.3 オンラインショッピングにおける画像とテキストの組み合わせのコンテンツを閲覧時の振る舞いを利用した興味推定 .....	28
<b>4 スマートフォンにおける効率的な商品選別を支援する商品リスト最適化手法</b> .....	<b>33</b>
4.1 スマートフォンにおける効果的な商品選別の必要性 .....	33
4.2 商品リスト最適化のアプローチ .....	37
4.3 ユーザの振る舞いに基づいた興味推定 .....	41
4.4 閲覧リストの最適化 .....	43
4.5 評価実験 .....	49
4.6 議論 .....	61

<b>5</b>	<b>マイクロブログにおける振る舞い協調フィルタリングによるコンテンツの効率的な閲覧手法</b> .....	<b>66</b>
5.1	マイクロブログ閲覧における閲覧支援 .....	66
5.2	マイクロブログの効率的な閲覧のためのアプローチ .....	68
5.3	他ユーザの振る舞いに基づいたタイムラインの最適化手法 .....	68
5.4	評価実験 .....	72
<b>6</b>	<b>スマートフォン自体の3次元加速度に基づいた興味推定</b> .....	<b>82</b>
6.1	振る舞いの特徴量として3次元加速度を利用する利点 .....	82
6.2	スマートフォンの動き .....	83
6.3	コンテンツ閲覧時の3次元加速度の特徴分析 .....	83
6.4	次元加速度データを利用したコンテンツ推定手法 .....	84
6.5	評価実験 .....	87
<b>7</b>	<b>結論</b> .....	<b>89</b>

謝辞

参考文献

業績一覧

## 概要

近年、インターネット上には膨大なコンテンツが存在し、利用者がそれらの中から、必要なコンテンツ探し出して利用することが一般に行われている。特に、オンラインショッピングやソーシャル・ネットワーキング・サービス(SNS)においては、コンテンツがリストとしてユーザに提供され、リスト化されたコンテンツの中から、ユーザが興味を持つコンテンツを目視で選別する機会が多い。しかし、近年普及したスマートフォンにおいては、狭い画面上でのタッチ操作によってコンテンツを閲覧する必要があり、PC上で閲覧する場合と比較して、選別の効率性が損なわれたり、ユーザにとって重要なコンテンツを見逃してしまう可能性が高くなるという問題がある。この問題を解決するために、本論文では、ユーザがスマートフォン上で効率的にコンテンツを閲覧する手法を提案し、その有効性を評価する。

本論文で提案する手法では、既読コンテンツに対するユーザの評価に基づいて、ユーザの意図や嗜好を推定し、リストの構成をユーザの意図や嗜好へ適合させるアプローチを採る。しかし、個々の既読コンテンツをユーザが明示的に評価するのは、ユーザに負担がかかるために現実的ではない。そこで、本論文では、ユーザに負担をかけないように、閲覧したコンテンツに対するユーザの評価が、ユーザのスマートフォンに対する操作時の振る舞いに反映されると考え、閲覧時の振る舞いを利用して、コンテンツに対するユーザの評価を推定する手法を提案する。本論文では、振る舞いを表すデータとして、コンテンツに対する閲覧時間、読み速度、及びスワイプ速度を利用して推定する手法を提案し、その有効性について評価する。

次に、スマートフォン上でのリスト形式によるコンテンツ閲覧が行われる代表的な応用である、オンラインショッピングにおける商品情報コンテンツの閲覧と、マイクロブログの

タイムラインの閲覧を対象に、既読コンテンツに対する評価推定に基づいたリストの最適化手法を提案する。オンラインショッピングにおける商品情報コンテンツの閲覧では、スマートフォン上での効率的な商品選別を支援することが目的である。本論文で提案する手法では、既読コンテンツに対する推定された評価に基づいて、ユーザの購買意図を推定し、商品リストの未読部分においてユーザの興味がある可能性が高い商品を優先的に提示する。本手法では、商品選別の際のユーザが注目する属性の偏りに注目し、属性の出現頻度に基づいて購買意図の推定を行い、商品情報リストの未読部分を最適化する。適合フィードバック手法を用いた購買意図推定に基づいた最適化をベースラインとして被験者実験を行い、提案手法の有効性を示す。一方、マイクロブログのタイムラインの閲覧においては、ユーザの未知のトピックに関する投稿が含まれるタイムラインにおいて、ユーザの興味を引く可能性が高いコンテンツを優先的に表示することにより、ユーザが興味をもつ情報を見逃す可能性を低減する手法を提案する。未知のトピックに関するコンテンツに対するユーザの評価を推定するために、代表的な情報推薦手法の一つである協調フィルタリングのアプローチを利用して、対象ユーザと似ている他のユーザがコンテンツを読んだ際の振る舞いに基づいてコンテンツに対する評価を推定し、興味のある可能性が高いと推定されるコンテンツを優先的に提示することにより、効率的な閲覧を実現する用にタイムラインを最適化する。この手法の有効性を評価するために、自然言語処理手法を用いた評価推定による最適化をベースラインとして、提案手法の有効性を評価する。

提案手法に基づいたプロトタイプシステムを利用した被験者実験により、オンラインショッピングにおける商品情報コンテンツの閲覧、およびマイクロブログのタイムライン閲覧において、提案手法はベースライン手法と比較して、ユーザの効率的な閲覧に効果があることが示され、ユーザの振る舞いを利用した閲覧リストの最適化が有効であることが明らかになった。

# 第 1 章

## 序論

### 1.1 研究の背景

インターネットの出現によって、世界中のコンピュータで情報をやり取りできるようになった。そして、インターネット上のハイパーテキストシステムである World Wide Web(WWW)の普及により、デジタル情報の蓄積と流通を容易に行うことができるようになり、WWWは日常生活の中で重要な役割を果たすようになった。特に、専門的な知識を持たないユーザが Blog 等のコンテンツ管理システム(CMS)を利用して WWW に気軽にコンテンツを投稿できる Web 2.0 と呼ばれる現象が発生して以来、ユーザは単にインターネットからの情報を受信するだけでなく、誰もが新たな情報を生み出し、それらを他のユーザと共有するようになった。しかし、インターネットのユーザ数の急速な成長と一般ユーザによる継続的な情報の生産は、情報の爆発的な増加をもたらした。そうした中で、「情報過多」(Information Overload)が深刻な問題となっている[1]。つまり、近年の「情報過多」の中で、ユーザは大量の情報から必要とする情報を効率的に見つけることができない状況が多発している。

一般に、蓄積されている膨大な情報の中から、ユーザが必要とする情報を見つけるためには、検索[2]は最も有効な手段の一つである。検索では、ユーザは検索要求をクエリとして表現し、検索システムはクエリに合致する情報を表すコンテンツを検索結果としてユーザに返す。クエリの形式としては様々なものが考えられるが、Google や Yahoo!などのウェブ検

検索エンジンで用いられているようなキーワードとしてクエリを表現する検索手法（キーワード検索）が一般的に利用されている。キーワード検索では、ユーザがクエリとして入力したキーワード（検索語）に適合するコンテンツを抽出してユーザに提示する。

検索は、オンラインショッピング等の様々な分野の Web サイトで利用されている機能である。検索はユーザが検索対象について十分な知識を有している場合には有効的に機能する。しかし、ユーザが検索対象となるドメインに対して十分な知識がない場合には、クエリを適切に表現することができないため、有効的に機能しない場合がある。

検索ではユーザがクエリを明示的に指定しなければならないが、近年、ユーザがクエリを明示的に指定せずに、ユーザの検索要求を満足する情報を提供する情報推薦が注目されている[3-5]。情報推薦ではユーザに関する情報を表したプロフィールを用いて、ユーザの検索要求を推定しアイテムとの適合度を推定する。情報推薦では、ユーザからのクエリを入力しなくてもユーザにとって価値があるコンテンツを提示できる。例えば、ユーザの購入履歴から、ユーザが興味があると思われる作家を推定し、その作家の書籍を推薦する事が考えられる。

情報検索と情報推薦は有用ではあるが、類似したコンテンツが大量に存在する場合には、大量の検索結果がユーザに返されるため、ユーザにとって価値のあるコンテンツが埋もれてしまう可能性がある。大量の検索結果を閲覧する場合、ユーザにとって負担がかかる。そのため、ユーザに与えられる検索結果や推薦結果の効率的な提示手法が必要であると考えられる。

一方、コンテンツを閲覧する環境にも近年大きな変化が生まれている。20 世紀末までは、デジタルコンテンツは、主にパーソナルコンピュータ（PC）を利用して閲覧するのが一般的であった。しかし、携帯電話が音声通信のみならず、データ通信を行うことができるようになり、前世代の PC に匹敵する性能を有するようになった[6]。さらに、Apple 社の iOS を搭載した iPhone と Google 社の Android を搭載したスマートフォンの出現と普及により、場所を問わず様々な種類のデジタルコンテンツの閲覧ができるようになった。近年、スマートフォンの利用者は急激に増加している。例えば、総務省の平成 27 年版情報通信白書[7]のデータによると、平成 26 年の日本において、スマートフォンの保有比率は、64%以上である。特に、若い世代（20 歳～39 歳）の保有比率は 92%以上である。現在も、世界中で、毎年数

億人単位で、利用者が増加しつつある。

スマートフォンが広く普及する中で、スマートフォンを利用したインターネット上のデジタルコンテンツの閲覧が一般的に行われるようになった。しかし、スマートフォンにおけるコンテンツ閲覧は、スマートフォンに搭載されたタッチスクリーンを利用して行わなければならない。スマートフォンの画面はPCにおいて一般的に利用されているディスプレイと比較して、画面サイズが小さく表示できる情報が少ない。また、コンテンツの表示領域の移動等の操作は、PCにおいては、マウスやトラックボール等を利用されるのに対して、スマートフォンにおいては、小さなディスプレイ上のタッチ操作であるため、PCよりも操作性が劣る。

近年、インターネットでは、コンテンツのリストを閲覧する操作が多く行われるようになった。代表的なコンテンツのリストとして、オンラインショッピングにおける商品リストと、SNSにおけるコンテンツのリストがある。オンラインショッピングでは、ユーザは購入対象のアイテムの条件をクエリとして指定する。しかし、ユーザが指定したクエリに対して条件を満足するようなアイテムが複数存在する場合がある。ユーザはクエリとして商品のおおまかなカテゴリのみを指定して、そのカテゴリの商品を閲覧しながら、購入対象の商品の特性を絞り込んでいくことが行われる。一方、SNSにおいては、ユーザは未知の情報を取得することを目的としているために、ユーザはクエリを明示的に与えることはしない。SNSでは、興味を持ちそうな情報を投稿する人を指定しておくことにより、指定した人が投稿した記事が常時自動的に配信されるようになる。そして、他者が投稿した記事のリストを閲覧することにより、興味のある情報を見つける。SNSにおいても、リスト化されたコンテンツから目視で選別を行なうことを前提としている。

ユーザが目視でリストからのコンテンツの選別を行う場合、大量のコンテンツが存在する場合には、コンテンツの選別が困難であり、時間がかかる。また、全てのコンテンツを閲覧しない場合は、重要なコンテンツの見逃しが生じる可能性がある。また、最初にユーザの目に触れる部分の重要性が高いと考えられるため、リスト内でのコンテンツの順番が重要となっている。

## 1.2 研究の目的

### 1.2.1 効率的な閲覧のためのアプローチ

本研究では、ユーザがスマートフォンでリスト化されたコンテンツに対する効率的な閲覧を支援する手法の開発を目的とする。本研究では、コンテンツ集合に対する閲覧リストの順序をユーザに対する適合度に基づいて構成することにより、ユーザが効率的にコンテンツを選別可能し、ユーザにとって価値が高いコンテンツの見逃しを低減する。

コンテンツの適合度に応じて適切にリストの順番を構成するためには、ユーザに対して、リストを構成するそれぞれのコンテンツの適合度を推定する必要がある。これまでに、ユーザに対するコンテンツの適合度の計算は、検索や推薦においても行われている。検索においては、ユーザが明示的に与えたクエリとコンテンツとの適合度を計算する。一方、コンテンツの推薦においては、明示的に指定したクエリの代わりに、ユーザの特性や嗜好を表すプロフィールとのコンテンツのユーザに対する適合度を推定する。本研究においても、ユーザのプロファイルに基づいて、コンテンツの適合度を推定するアプローチを採用する。

ここでは、ユーザプロフィールを、いかに構成するかが重要である。代表的なプロフィールの構成方法は閲覧履歴を用いるものである。この閲覧履歴を利用する手法では、ユーザは閲覧したコンテンツに興味があると考え、閲覧したコンテンツが有する共通の特徴をしかし、閲覧してもユーザにとって興味があるとは限らないため、ユーザからの明示的な評価が必要である。手動で明示的に評価するのはユーザにとって手間がかかるため、閲覧した全てのコンテンツを評価するのは現実的でない場合が多い。

閲覧したコンテンツに対する評価を取得するために、ユーザの明示的な評価付け以外に、ユーザの行動履歴等を利用した暗黙的なものもある[7]。人間はそれぞれの対象に異なる反応を行っている[8]。これまでも、ユーザの振る舞いを利用してユーザの興味・嗜好を推定する研究[9]が行われている。例えば、ユーザが興味を持ったコンテンツは、閲覧時間が長くなる一方で、ユーザが興味を持たないコンテンツは、閲覧時間が短くなる傾向があることが検証されている。このように、閲覧時の振る舞いを使うことで、ユーザのプロファイルを構築することができれば便利である。

本研究の貢献を、以下に示す。

1. ユーザのコンテンツ閲覧時の振る舞いを利用して、閲覧したコンテンツに対する評価を推定する手法を開発する。

2. 推定されたコンテンツに評価に基づいて、ユーザに提示されるコンテンツのリストを効果的に構成する手法を開発する．ここで、コンテンツのリストを効果的に構成することをコンテンツのリストの最適化と呼ぶ．

本研究は、検索・推薦が行われた結果に対して、図 1.1 を示すように、コンテンツを閲覧した際のユーザの振る舞いを用いてユーザの興味を推定する．そして、推定した興味に基づいて、ユーザに提示するコンテンツの提示形式を最適化する．提示形式の最適化としては、様々なものが考えられるが、本研究では、リストの最適化に焦点をあてる．本研究では、未読のコンテンツを選別できるように、ユーザにとって興味があるコンテンツを優先的に提示するという最適化を行う．

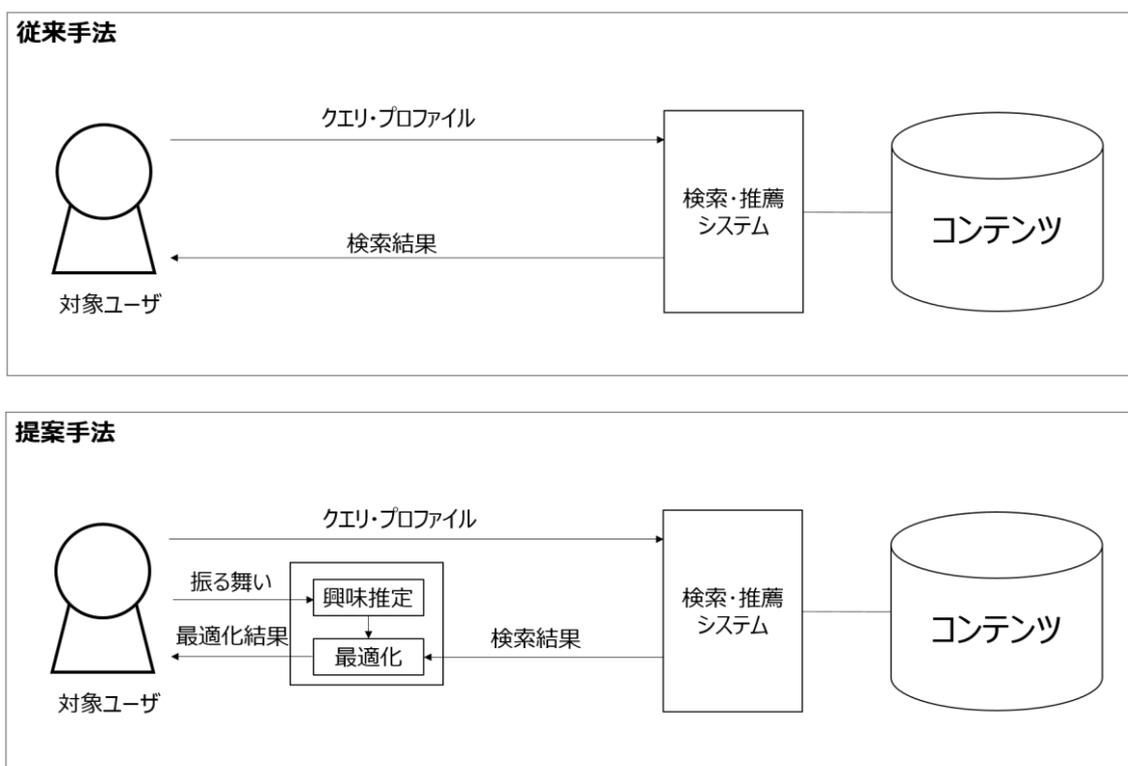


図 1.1. 提案手法と従来手法の比較

### 1.2.2 効率的な閲覧の支援手法

上に述べたように、本研究では、閲覧時の振る舞いを用いてユーザのプロファイルを構築し、最適化を行うことを目標とする．ユーザのプロファイルを用いた最適化は、自己最適化

と、協調的最適化に大別できる。

自己最適化は、ユーザのプロファイルを、ユーザ自身の閲覧活動の最適化に活用することである。自己最適化の特徴は、大量のコンテンツ集合に対して、ユーザが明確な条件を指定することができない場合に、大まかな条件を指定して得られた検索結果の絞り込みを支援することが可能になる。例えば、オンラインショッピングにおいて、本を購入する場合は、作者、ジャンル等の大まかな絞り込みを行なった検索結果から、ユーザの嗜好に基いて効率的な絞り込みを支援する。このような最適化を行う場合、ユーザの過去の嗜好に基づいて、ユーザが探しているコンテンツを絞り込むため、対象とするコンテンツの特徴が取得できるのであれば、他のユーザのプロファイルは必要ない。

しかし、自己最適化は、ユーザが未知のコンテンツに適用できない可能性が高い。例えば、マイクロブログの場合、刻一刻と新しいコンテンツがリアルタイムに配信される。ユーザにとって未知のコンテンツが多数に存在する。単に過去に興味があったコンテンツと類似したコンテンツを推薦しても、新たに興味を持つ可能性があるコンテンツを見逃してしまいう場合が多い。一方、協調的最適化は、いわゆる群衆の知恵（Wisdom of Crowds）を利用した最適化である。集団内のユーザが有する特徴からユーザ間の類似度を計算し、類似度が高いユーザが興味があるコンテンツを優先的に提示することで最適ナリストに徐々に近づける。ここでは、ユーザがコンテンツの内容や特徴について知らなくても、他のユーザの知恵から、コンテンツのリストを最適化することが可能となる。すなわち、他人の既読コンテンツに対する評価に基づいて、対象ユーザが興味を持つかどうかを推測することで、ユーザにとって未知のコンテンツの重要度を推定しリストの最適化に利用する。

上記の提案手法は、情報推薦手法の代表的なアプローチである内容ベースフィルタリングおよび協調フィルタリングを、閲覧支援に適用したものであると位置づけることができる。以下に、それぞれの支援手法の概要を示す。

#### ● 内容ベースフィルタリングに基づくコンテンツ閲覧の支援手法

オンラインショッピングを利用する際は、ユーザが興味を持たない商品を含む大量の商品から構成される商品リストを閲覧して、購入する商品を決定することが多い。もちろん、興味がない商品を検索結果から除外するように検索条件に指定することは可能である。し

かし、そのような指定を行うためには、対象に対する知識が必要となる場合が多い。従って、十分な知識を持たないユーザの場合は、ユーザにとって求める商品を選別できなくなる可能性がある。また、スマートフォンは画面が小さく、操作性が高くないため、このリストから商品を効率的に選別できないという問題がある。ユーザがスマートフォン上で効率的な商品選別を支援することを目的に、スマートフォン上で閲覧する際の閲覧・購買意図の推定に基づいて、商品リストの未読部分を動的に最適化する手法を提案する。図 1.2 に示すように、この手法では、商品リストの最適化を実現するために、記録されたユーザのプロファイルから、閲覧した既読商品に対するユーザの評価を自動的に推定することによって、ユーザの閲覧意図を推定する。推定された閲覧意図に基づいて、商品リストの未読部分においてユーザの興味がある可能性が高い商品を優先的に提示する。

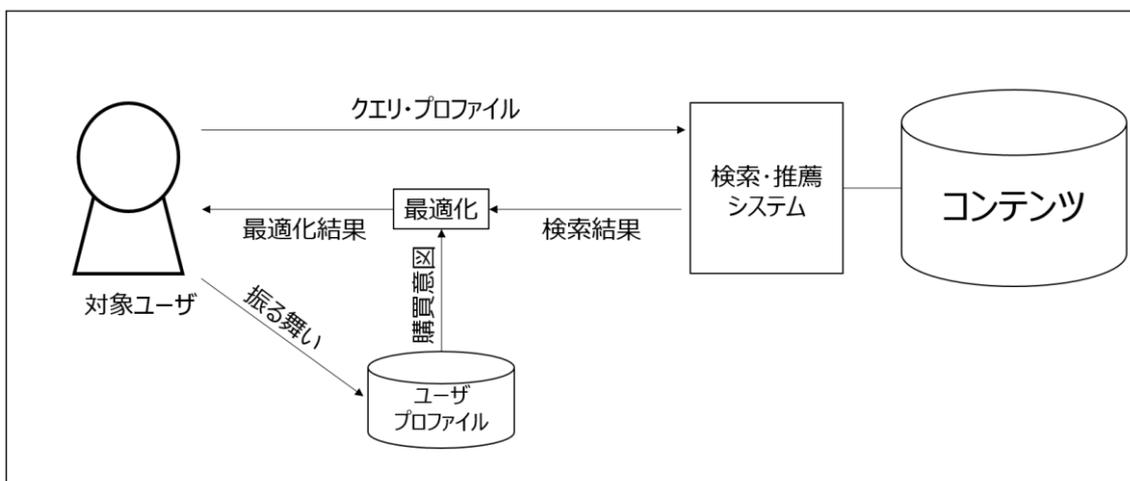


図 1.2. 提案する内容ベースフィルタリングのプロセス

- 協調フィルタリングに基づくコンテンツ閲覧の支援手法

Twitter, Weibo 等を代表とするマイクロブログを代表例として、未知な情報に対して、様々なコンテンツが一系列のストリームとなり、リアルタイムに新しいものから順にユーザに配信される。このようにユーザに配信された大量コンテンツの中には、ユーザにとって興味があるコンテンツもあれば、興味がないコンテンツもある。配信された大量のコンテンツをすべて閲覧することは、ユーザにとって負担が大きい。また、ユーザは、配信されるコンテンツのすべての内容を厳密に理解するわけではなく、「飛ばし読み」によって、ユーザにとって興味があると思われるコンテンツを見つけ、そのコンテンツの内容のみを正確に確認す

る。しかし、「飛ばし読み」を行った場合、未知の情報に対して、特定の内容に関連しない場合があるため、ユーザにとって興味があるコンテンツを見逃す可能性がある。それを解決するために、図 1.3 に示すように、ユーザにとって興味がある可能性が高いコンテンツを優先的に提示することにより、選別する時間を節約し、効率的な閲覧を実現することが可能だと考えられる。それを実現するために、情報推薦の代表的な手法である協調フィルタリングに、閲覧者間の類似度を適用することで、効率的なコンテンツ閲覧を実現する手法を提案する。

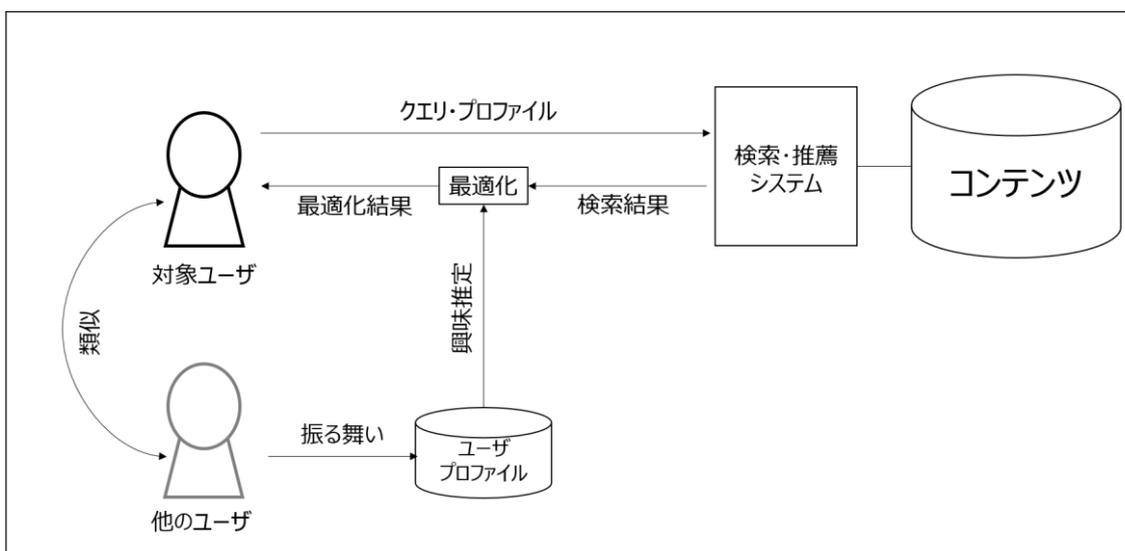


図 1.3. 提案する協調フィルタリング手法のプロセス

### 1.2.2 閲覧時の振る舞い

上記のように、ユーザの興味や嗜好を理解し、利便性の高い支援機能を実現するために、閲覧時の振る舞い情報を利用する。ユーザが閲覧したコンテンツに対する暗黙的な評価を自動的に推定するために、閲覧しているコンテンツに対するユーザの評価が、ユーザのスマートフォンに対する操作時の振る舞いに反映されると考え、閲覧したコンテンツに対する評価を推定するための指標として振る舞いを利用する。具体的には、図 1.4 に示すような、タッチディスプレイに対する振る舞いや、スマートフォン自体の運動の特徴を考慮することができる。

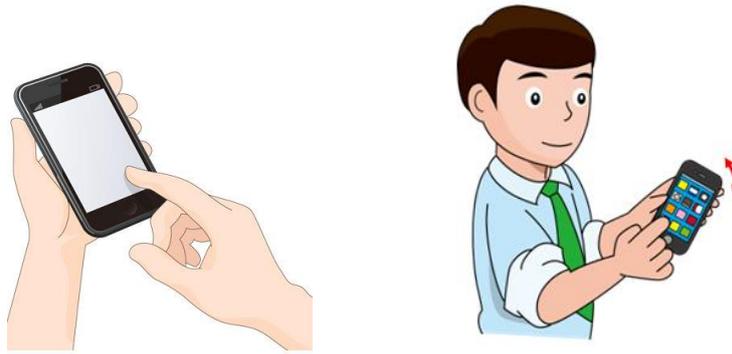


図 1.4. タッチディスプレイに対する振る舞い (左).  
閲覧時のスマートフォン自体の運動 (右).

### 1.3 本論文の構成

本論文では、ユーザの振る舞いに基づいたコンテンツ閲覧支援環境を実現するために重要な以下の4つのトピックに関して、具体的な手法を提案し、被験者実験に基づいてそれら进行评估した結果を示す。

1. スマートフォンにおけるユーザの閲覧時の振る舞いに基づいたコンテンツの興味の推定手法
2. スマートフォン上でオンラインショッピングにおけるユーザの商品閲覧時の振る舞いに基づいて、未閲覧商品の提示順序を変更し、効果的な商品選別を実現可能な閲覧リストを構成する手法
3. スマートフォン上でユーザがマイクロブログを閲覧時の振る舞いに基づいた協調フィルタリングを用いて、対象ユーザにとって未知のコンテンツを効率的に提示する手法
4. 3軸加速度データに基づいたコンテンツの価値の推定手法

本論文の構成は以下の通りである。2章では関連研究について述べる。3章ではスマートフォン上のユーザの振る舞いに基づいたコンテンツの価値の推定手法について述べる。4

章では振る舞いに基づいた未閲覧商品提示順序の最適化手法について述べる. 5章では振る舞いに基づいた未閲覧ツイートの効率的な閲覧手法について述べる. 6章ではスマートフォンの3軸加速度データに基づいたコンテンツの価値の推定手法について述べる. 7章では本稿のまとめを行う.

## 第2章

### 関連研究

#### 2.1 情報推薦におけるフィードバックの活用に関する研究

##### 2.1.1 ユーザの明示的なフィードバック

蓄積された膨大な情報空間の中から、ユーザにとって興味があるコンテンツを発見し提示する推薦システム[2]に関する研究は、これまでも活発に行われてきた。推薦システムにおいて、代表的な手法の一つに協調フィルタリング[5]がある。協調フィルタリングは、映画や音楽など推薦において広く用いられている。協調フィルタリングの基本的な考え方は、過去のユーザの評価や購入履歴に基づいて、ユーザ間の類似度を計算し、類似したユーザの評価に基づいて、推薦するコンテンツを決定するというものである。また、いくつかの推薦システム[3,4]では、ユーザが明示的なフィードバック(たとえば、推薦した結果に対してポジティブ評価あるいはネガティブ評価)を行うことにより、推薦内容を最適化する。多くの従来の手法では、ユーザが手動で与えた明示的なフィードバックに従って、推薦の精度を向上させる。しかし、ユーザに手動で明示的なフィードバックを要求することは、ユーザに負担の増大につながるという問題がある。

### 2.1.2 ユーザの暗黙的なフィードバック

明示的なフィードバックの問題を解決するために、情報検索や情報推薦の分野において暗黙的なフィードバックに関する研究[9-21]が行われている。

暗黙的なフィードバックでは、ユーザは明示的に評価を与えず、ユーザの行動という暗黙的な情報[10]を利用して評価を推定する。最も単純な暗黙的なフィードバック手法では、ユーザがアクセスしたコンテンツは、ユーザの興味を表していると考えられるものである。例えば、松尾[11]らは、Web ページアクセス履歴を利用してユーザの興味を推定する手法を提案している。しかし、アクセスしたすべてのコンテンツにユーザが興味を持っていたとは限らないという問題がある。

この問題を解決するために、Morita[12]らは、ネットニュースの記事を対象に、個々のニュースの閲覧時間を利用して、ユーザの興味を推定する手法を提案した。しかし、この手法はネットニュースという、ある程度の長さの文書を含むコンテンツを対象としている。そのようなコンテンツでは、文書を読むのに必要とされる標準的な時間は文書の長さによって予測できるため、文書の閲覧時間に基づいてユーザの興味を推定できると考えられる。しかし、オンラインショッピングにおける商品情報のように写真と短い文書から構成されるコンテンツに対して、従来の閲覧時間に基づいた興味推定手法が有効であるかは検証されていない。

Fox[9]らは、コンテンツ閲覧時におけるマウス操作、すなわち、スクロール要素とマウスクリックが、コンテンツに対するユーザの評価の予測に有効であることを示している。また、土岐[13]らは、SNS ストリームの閲覧時の、マウスのホイールを利用したスクロールの履歴を利用して、ユーザの興味を推定する手法を提案している。これらの手法では、長期的に不変な興味は推定可能であるが、短期的な興味の推定は困難である。ユーザの短期的な興味を対象とする場合、ユーザが閲覧したコンテンツに対する評価を推定し、その後の未閲覧のコンテンツの提示に利用することが重要である。また、PC 環境におけるマウスの利用を前提

としているため、対象とするスマートフォンでは適用が困難である。

Guo ら[14]は、スマートフォン固有の振る舞いを暗黙的フィードバックに利用することを提案しており、モバイル検索が成功したかどうかを判断するために、ズーム操作やスクロール操作の回数が有用な特徴量となる可能性を示している。さらに、Lagun ら[15]では、スマートフォン上で行われた Web 検索結果に対する満足度と、視線計測装置を利用して計測した視線の情報及び検索結果リスト上での表示領域の移動の特徴との関連を分析している。これらの研究では、対象が通常の Web ページや検索結果一覧のページであり、オンラインショッピングにおける商品リスト中の個々の商品に関する評価を推定していない。オンラインショッピングにおける商品情報は一般的な Web ページと比較して情報量が少なく、表示領域の移動などを利用することが困難である。また、これらの研究では、既に閲覧したコンテンツに対する評価を推定することのみを目的としているのに対して、本研究では、推定した結果を利用して、ユーザが未読の対象に対する評価を推定して効率的なコンテンツ選別を支援することを目的とする。

### 2.1.3 暗黙的なフィードバックに基づいた評価の推定手法

評価の推定は、典型的な機械学習[22]が適用可能な問題であり、分類問題と位置づけることができる。一般的に、機械学習の手法は、教師なし手法と教師あり手法に大別できる。例えば、教師なし手法としては、クラスタリングアルゴリズム(clustering algorithm)[23,24]やベイズアルゴリズム(Bayesian algorithm)[25,26]などの統計的手法を使用して、検索結果からいくつかの特徴的なパターンを検出に焦点を当てて分類する。しかし、一般的に、教師なし手法は、教師あり手法のような推定精度に至らない場合が多い。したがって、より高品質な結果を得るために、教師あり手法[27,28]を利用し、本研究では、ユーザの閲覧時の振る舞いとユーザの評価との規律を学習することで、コンテンツに対する評価を推定する。

## 2.2 情報推薦に関する研究

### 2.2.1 適合フィードバックを用いる情報推薦

情報検索・推薦の分野では、ユーザのフィードバックを利用して、適切な情報を提供するために、これまでに幾つかの手法[29-37]が提案されてきた。これらの手法では、閲覧した際のユーザからの反応を用いて、クエリを修正したり[29]、より適していると考えられるクエリに変更する[30]等、ユーザの検索意図を反映するようにユーザに提供する情報を最適化する。

代表的な手法として、Rocchio[31]のアルゴリズムが知られている。この手法では、ユーザが検索結果の一部分を手動で分類し、分類されたクラスごとに、そのクラスに含まれるオブジェクトの特徴ベクトルの重心を求める。そして、新しいオブジェクトを分類する時は、分類対象となるオブジェクトの特徴ベクトルと、各クラスの重心ベクトルとの距離を計算し、その値が最も小さいクラスに分類する。Rocchioの手法に基づいて、過去のフィードバックの影響を低減するために、減衰率を使用した手法[34]が提案されている。Wang[35]らは、適合フィードバックにおいては負のフィードバックの数が多く、それらが類似度計算に多大な影響を与えることが多いことに注目し、適合フィードバックの改良手法を提案している。一方、適合フィードバックを、確率理論に基づいた分類問題として扱っている手法も存在する[35-37]。これらの手法では、ベイズ理論を基に、ユーザからのフィードバックを通じ、クエリに対する検索対象の適合度を条件付き確率として計算する。これらの手法は、情報検索を対象としており、商品リストの最適化に適用した場合、全ての属性に対してユーザが同等の興味を有することを前提とし、評価された商品の特徴から、ユーザの購入意図を推定することになる。しかし、オンラインショッピングにおいては、ユーザは多くの特徴を総合的に判断するのではなく、注目する少数の商品属性にこだわりを持ち、それらに基づいて商品の選択を行う場合が多い[38-41]。したがって、ユーザが注目していない商品の属性が、注目する商品属性と同等に扱われてしまい、不適切な商品を提示する可能性がある。本研究では、

商品選択の際に、ユーザが興味を持つ属性の偏りの注目し、ユーザの購買意図を推定し、商品リストの最適化に利用する。

### 2.2.2 他のユーザのフィードバックを用いる情報推薦

ユーザの行動履歴を用いて、様々な手法が提案されている[41-53]。その中でも、他の類似したユーザの行動履歴を用いて、ターゲットユーザに有用な情報を推定する手法が提案されている[47-51]。Amazon, Taobao 等の商用サービスにおいて、最も広く使用されているのは、協調フィルタリングである。

協調フィルタリング手法は、ユーザ間の類似度に基づいて、他のユーザから評価したかつ対象ユーザが閲覧していないコンテンツに対する評価を予測し、トップ N 個項目をターゲットユーザに推薦する。ユーザ類似度計算方法は、古典的なコサイン類似度 (Cosine-based Similarity) [54]およびピアソン相関係数(Pearson Correlation Coefficient)[55]等が一般的である。

協調フィルタリング手法は、他のユーザを介すため、ユーザにとって興味がある、かつ目新しいコンテンツを推薦できると考えられる。特に、Twitter や Weibo 等のような未知のコンテンツに対して、ユーザにとってセレンディピティのツイートを推定可能である。

## 2.3 マイクロブログにおける閲覧支援研究

マイクロブログにおけるコンテンツには、テキストが主な役割を果たすものが多い。しかし、代表とする Twitter や Weibo では、利用されるテキストは他のいくつかの特徴が存在する。例えば、文字数の制限、特有の言いまわしと表現の存在、絵文字の利用等があげられる。これらの特徴のため、従来のテキスト処理による推定アプローチは、効果的な推定が困難であるという問題が存在している。いくつかのシステム[11,56]では、ユーザのフィードバックは推定の精度と速度を改善するために使用される。例えば Facebook での EdgeRank[56]アルゴリズムでは、ユーザとコンテンツの投稿者との適合度という指標をもとに、表示するコンテンツの順番を変更する。しかし、EdgeRank ではユーザとの関係に重みを扱っているが、

ユーザにとって興味があるかどうか等の情報を考慮していない。そのため、松尾ら[11]は、web 上のユーザの振る舞いから興味を把握し、個人化した情報提示を行う手法を提案している。具体的には、ユーザが閲覧した文書の履歴から、ユーザにとって重要度の高い語を抽出し、ブラウジングでの読み飛ばしを防ぐ。この手法では、ユーザが閲覧する度にユーザにとって「身近な語」を収集し、文書を閲覧する際に「身近な語」との共起語を重要語とした。興味をユーザの過去の閲覧文書から抽出し、個人化に利用する。コンテンツを「見落とされないように」重要語をハイライトする。しかし、この手法では、一般的な web 文書を対象としているため、ユーザの閲覧時の振る舞いは考慮していない。特に、スマートフォンを対象とする場合、閲覧時のフリック、スワイプ、ズームイン、ズームアウトなどのスマートフォン特有の振る舞いが十分に活用されていない。

## 第3章

### 閲覧時の振る舞いに基づいたコンテンツの興味推定

本研究の目的は、スマートフォン上でのユーザの効率的なコンテンツの閲覧を支援する手法を開発することである。そのために、ユーザがスマートフォン上で閲覧したコンテンツに対する興味の度合いを利用する。閲覧したコンテンツに対するユーザの興味の度合いを取得するためには、ユーザが明示的に評価値を指定することが考えられるが、これは、ユーザに対して多大な負担がかかるために現実的ではない。そこで、本研究では、閲覧したコンテンツに対するユーザの興味を、ユーザのスマートフォンに対する操作時の振る舞いを利用して取得する。

本章では、コンテンツを閲覧した際のユーザの振る舞いに着目し、ユーザがコンテンツを閲覧したときの振る舞いとそのコンテンツに対する興味の度合い（評価）を反映するという仮説の下で、ユーザの閲覧時の振る舞いと閲覧したコンテンツに対する興味の関連性について行った被験者実験の結果を示す。また、本研究で対象とするオンライン上でのコンテンツとして、テキスト、画像、あるいはテキストと画像の組み合わせという、3種類コンテンツを想定し、それぞれの種類のコンテンツに対して分析を行う。以下、3.1ではマイクロブログでのテキストコンテンツの興味と振る舞いの関係とについて述べる。3.2ではオンラインショッピングでの画像コンテンツに対する興味と振る舞いの関係について述べる。3.3ではテキストと画像が組み合わせられたコンテンツの興味と振る舞いの関係について述べる。

### 3.1 マイクロブログにおけるテキストコンテンツを閲覧時の振る舞いを利用した興味推定

本節では、Twitter や Weibo 上でのテキストコンテンツを対象に、ユーザがスマートフォンを利用する状況を想定し、閲覧時の振る舞いと、ユーザが閲覧したツイートに対する評価との関係について分析する。

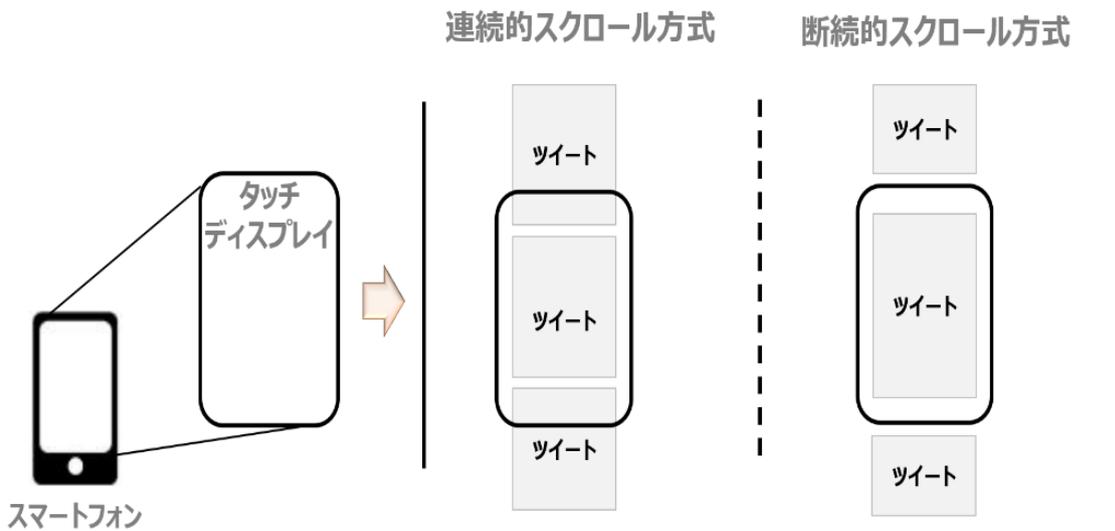


図 3.1. ストリーム型コンテンツの提示方法

#### 3.1.1 実験環境

本研究では、利用するスマートフォン上での振る舞いを取得するインタフェースについて述べる。ストリーム型コンテンツの提示方法には、図 3.1 に示すように、複数のコンテンツを表示する「連続的スクロール方式」と個々のコンテンツを表示する「断続的スクロール方式」がある。図 3.2 は、それぞれのスクロール形式におけるコンテンツの表示例を表す。連続的なスクロールでは、個々のコンテンツに対する振る舞いの区別が困難であるため、本研究では断続的なスクロール方法を採用する。そして、スマートフォン上で断続的なスクロールを実現でき、ユーザがそれを操作する際の振る舞いデータを記録可能なインタフェースを開発した。図 3.3 に開発したインタフェースの外見を示す。このインタフェースでは、コンテンツが 1 件ずつ表示され、ユーザはスワイプ操作で、次のコンテンツを表示できる。

連続的なスクロール



断続的なスクロール



図 3.2. ストリーム型コンテンツの提示方法の実例

### 3.1.2 特徴量

スマートフォン上でのユーザの閲覧時の振る舞いを表すために利用する特徴量について述べる。スマートフォン上での振る舞いを表す特徴量としては様々なものが考えられるが、本研究では、対象とする振る舞いとして、タッチディスプレイに対する振る舞いである読み速度やスワイプ速度を利用する。

- 読み速度

読み速度は単位時間でのユーザが処理したと考えられる文字数を表す。また、英単語、数字、符号等を 1 文字としてカウントする。ユーザが閲覧するコンテンツ列を  $\langle t_1, t_2, \dots, t_n \rangle$  とする。ここで、コンテンツ  $t_i$  に対する読み速度  $rv_i$  を、以下の式で形式的に定義する。

$$rv_i = \frac{length_i}{rt_i} \dots (3.1)$$

$length_i$  はコンテンツ  $t_i$  に含まれる文字数であり、 $rt_i$  はコンテンツ  $t_i$  の表示時間を表す。コンテンツ  $t_i$  の表示開始時刻を  $st_i$ 、表示終了時刻を  $et_i$  とするとき、表示時間  $rt_i$  を以下の式で

形式的に定義する.

$$rt_i = et_i - st_i \quad \dots (3.2)$$

読み速度とは, 閲覧したコンテンツに対するユーザの興味によって変化すると考えられる. ユーザがコンテンツに対して興味を持たない場合, 読み速度が速くなり, 興味を持つコンテンツの場合, 読み速度が遅くなると予想される.

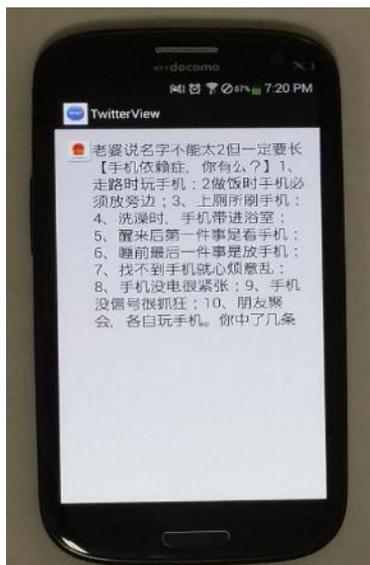


図 3.3. 実装したインタフェース

- スワイプ速度

スワイプ速度とは, スマートフォンにおいてスワイプ操作をする際の指の移動速度のことである. コンテンツ列中のコンテンツ $t_i$ を表示しているときに, 次のコンテンツを表示することを目的として, スワイプの開始のためにユーザが指でタッチディスプレイに触れた画面上の座標を $(sx_i, sy_i)$ とし, その時刻を $sst_i$ とする. 次にスワイプ操作が終わり, 指がタッチディスプレイから離れた画面上の座標を $(ex_i, ey_i)$ とし, その時刻を $set_i$ とする. このとき, このスワイプ操作の移動距離 (ピクセル)  $dist_i$ を以下の式で定義する.

$$dist_i = \sqrt{(sx_i - ex_i)^2 + (sy_i - ey_i)^2} \quad \dots (3.3)$$

また, このスワイプを操作の継続時間 (ミリ秒)  $dur_i$ を以下の式で定義する.

$$dur_i = set_i - sst_i \quad \dots (3.4)$$

$dist_i$ と $dur_i$ の概念図を図 3.4 に示す。コンテンツ*i*に対するスワイプ速度 $sv_i$ を以下の式で定義する。

$$sv_i = \frac{dist_i}{dur_i} \quad \dots (3.5)$$

スワイプ速度は、閲覧したコンテンツに対するユーザの興味によって変化すると考えられる。ユーザが興味を持たないコンテンツはスワイプ速度が速くなり、興味を持つコンテンツではスワイプ速度が遅くなると予想される。

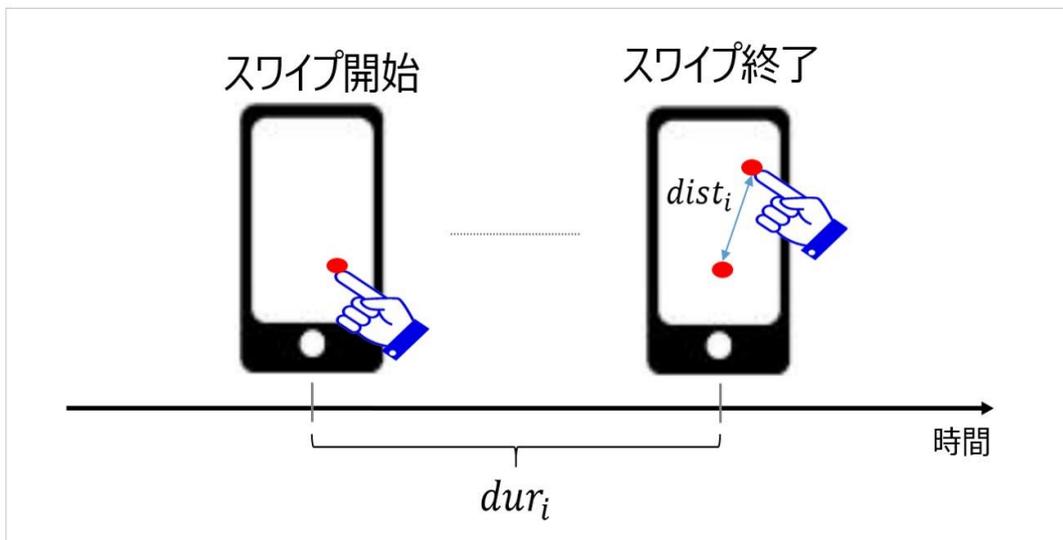


図 3.4.スワイプ速度の概念図

### 3.1.3 実験結果

上記に述べた 2 種類の振る舞いの特徴量を利用して、そのコンテンツに対するユーザの興味の判断を反映しているかどうかを検証する。

- 読み速度に関する実験

ユーザにとってのコンテンツの評価とそのときの振る舞いの大まかな傾向を見るために、提案した振る舞いの成否をよく分析しながら予備実験を行った。Weibo において 2013 年 11

月 30 日に配信されたツイートを選択し、100 個のツイートをデータセットと設定した。被験者は、日常的に Weibo を使用する大学生および大学院生の中国人学生 4 名である。被験者に対して、スマートフォンでデータセットのコンテンツを個々に読んでもらった。閲覧後、被験者は各コンテンツに関する興味を 1 (興味あり) か 0 (興味なし) かで評価した。また、個々のコンテンツを読む時間を計測し、コンテンツを読むのに要する閲覧時間と興味の関係性を分析する。

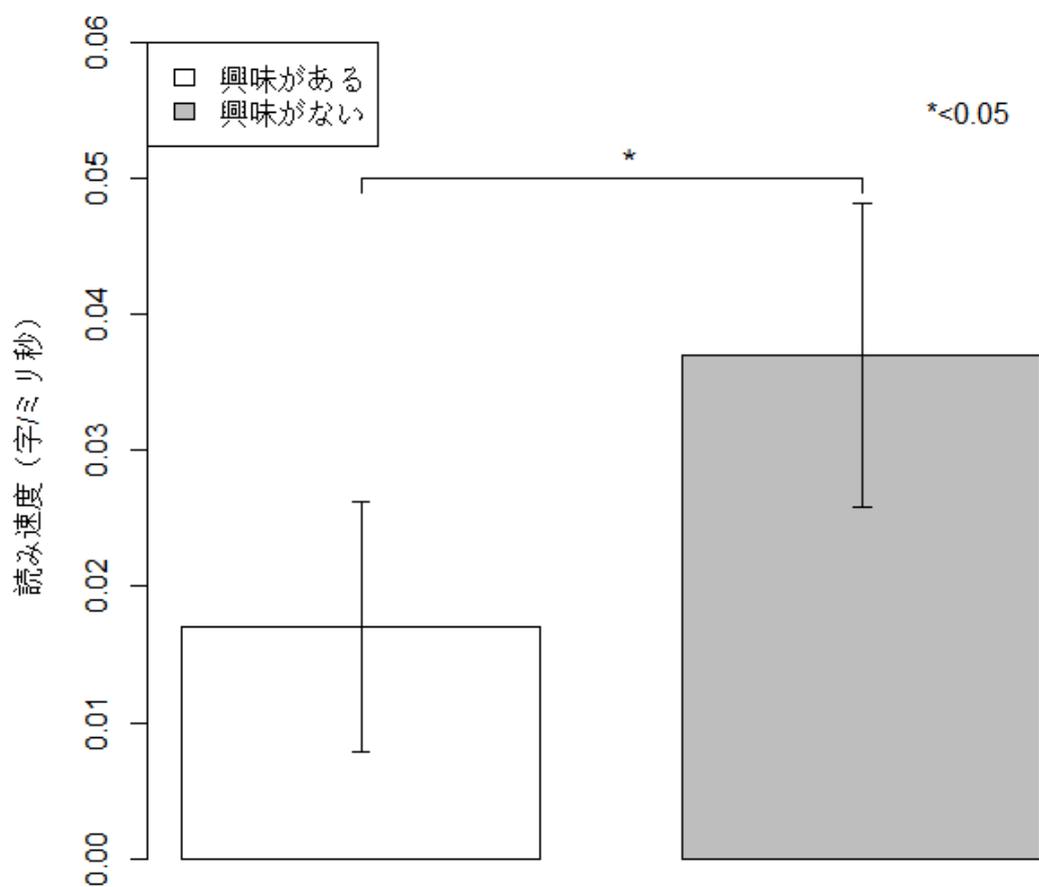


図 3.5. 平均読み速度と興味の関係

各被験者によるツイートに対する読み速度と、そのツイートに対する評価を獲得し、ツイートに対してユーザの評価と、各被験者の読むための平均速度の関係を図 3.5 に示す。興味があるツイートを閲覧する場合、被験者の読み速度の平均は 0.017 字/ミリ秒となり、興味がないツイートを閲覧する場合、被験者の読み速度の平均は 0.037 字/ミリ秒となった。また、t 検定手法を用いたところで、検定量は 0.017 となり、5%以下の有意差があったことが分かった。したがって、被験者が閲覧時の読み速度と、閲覧したコンテンツに対する興味に関連性がある。興味があるコンテンツほど読み速度が遅くなり、興味がないコンテンツほど読み速度が高くなる。

- スワイプ速度に関する実験

ユーザが次のコンテンツを表示するためのスワイプの振る舞いが、閲覧したコンテンツの興味と関連しているかを分析するための実験を行った。対象としたのは、Twitter から取得したツイートであり、それらを用いてデータセットを作成した。具体的には、2013 年 12 月 3 日に選択した 56 個ツイートをデータセットと設定した。被験者に、スマートフォンでデータセットの個々のツイートを読んでもらい、閲覧後に被験者に各ツイートに関する興味を 1（興味あり）か 0（興味なし）かで評価してもらった。被験者は大学学部または、大学院に所属し、常に twitter を利用する日本人学生 3 名である。

個々のツイートを閲覧した際のスワイプ速度を測り、スワイプ速度とツイートに対する被験者の評価に関係性があるかを分析した。各被験者によるコンテンツの振る舞い（スワイプ速度）とそのツイートの評価を獲得し、コンテンツの興味の評価によって各被験者のスワイプ速度の平均値を図 3.6 に示す。興味があるツイートを閲覧する場合、被験者のスワイプの平均値は 1.49 ピクセル/ミリ秒となり、興味がないツイートを閲覧する場合、被験者の読み速度の平均は 2.46 ピクセル/ミリ秒となった。また、t 検定手法を用いたところで、検定量は 0.03 となり、5%以下の有意差があったことが分かった。したがって、被験者が閲覧時のスワイプ速度と、閲覧したコンテンツに対する興味に関連性がある。ユーザにとって興味がないコンテンツに対してスワイプ速度が速くなり、興味がないコンテンツほどスワイプ速度が低くなる。スマートフォンでのマイクロブログ閲覧において、ユーザがツイートを閲覧するときの読む速度とスワイプ速度の振る舞いとツイートに対する評価の間に相関することが明らかになった。また、ユーザの閲覧時の振る舞いを利用し、ツイートに対するユーザの

評価を推定する可能であることが明らかになった。

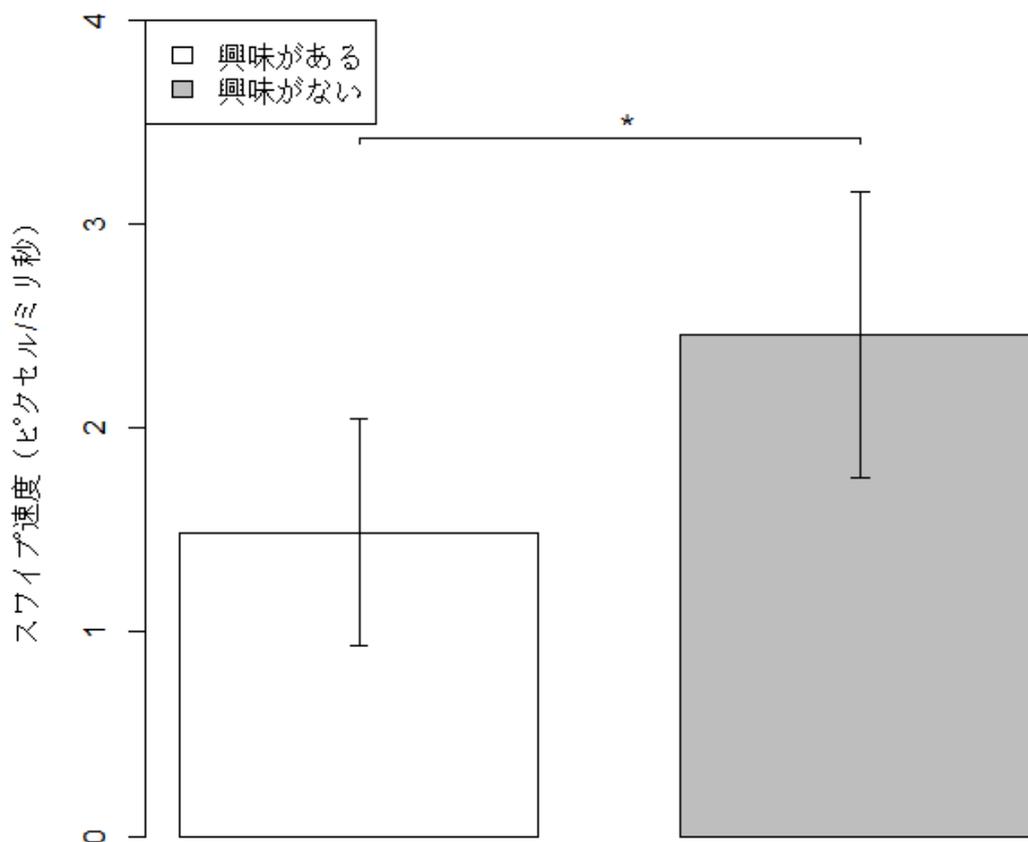


図 3.6. 平均スワイプ速度と興味の関係

### 3.2 オンラインショッピングにおける画像コンテンツを閲覧時の振る舞いを利用した興味推定

本節では、オンラインショッピングにおいてユーザがスマートフォンを利用する状況を想定し、閲覧時の振る舞いを利用する。そして、被験者実験により、振る舞いとユーザの商品アイテムに対する興味の評価の関係を明確化する。



図 3.7. 調査実験を行うためのインタフェース

### 3.2.1 実験環境

スマートフォン上で簡潔な操作を記録するインタフェース（図 3.7）を開発した。このインタフェースでは、断続的なスクロール方法を採用し、商品ページが 1 件ずつ表示され、ユーザはスワイプ操作で、次の商品ページを表示できる。

### 3.2.2 特徴量

本節では、対象とするスマートフォンを利用したオンラインショッピングにおいて、商品に対する興味の評価を推定するために利用するユーザの閲覧時の振る舞いの特徴量について述べる。

今回の対象とするオンラインショッピングの商品情報は、商品の画像が中心的な役割を果たし、スクロールしなくても全体像が確認できることを想定する。今回の対象に適した特徴として、閲覧時間とスワイプ速度を利用する。以下にそれぞれの特徴量について、具体的に述べる。

- 閲覧時間

閲覧時間はスマートフォン上で商品情報を表示していた時間である。一般的に、商品 $p_i$ の

表示開始時刻を $st_i$ 、表示終了時刻を $et_i$ とする。このとき、閲覧時間 $rt_i$ を式 3.2 で定義した。

一方、閲覧時間と閲覧した商品に対する評価との関連性については、興味がない商品ほど閲覧時間が短くなり、興味がある商品ほど閲覧時間が長くなると予想される。

- スワイプ速度

スワイプ速度とは、商品 $p_i$ に対して、次の商品を表示することを目的として、スマートフォンでスワイプ操作をする際の指の移動速度のことである。このとき、閲覧時間 $sv_i$ を式 3.5 で定義した。

一方、スワイプ速度と閲覧した商品に対する評価に関連性について、ユーザにとって興味がない商品に対してはスワイプ速度が速く、興味がある商品に対してはスワイプ速度が遅くなると予想される。

### 3.2.3 実験結果

閲覧時の振る舞いと商品に対する興味の関係性の分析を行うため、Amazon において 2014 年 6 月にベストセラーとした服装を選択し、50 件の服をデータセットと設定した。被験者は、日常的にスマートフォンを使用する大学生および大学院生 3 名である。被験者に対して、スマートフォンでデータセットの商品を個々に読んでもらった。閲覧後、被験者は各アイテムに関する興味が 1（興味あり）か 0（興味なし）かを点数化で評価した。興味があると評価された商品は興味があり、買う可能性がある。興味がないと評価された商品は興味がなく、買う可能性が全くない。また、個々の商品に対して閲覧時の振る舞いを計測し、商品を読むのに要する閲覧時間と閲覧後のスワイプ速度と閲覧した商品の興味の関係性を分析した。

閲覧時間と興味の関係の結果を（図 3.8）のグラフで表している。グラフの縦軸は商品アイテムに対する正規化された閲覧時間の平均値である。興味がある商品の場合、閲覧時間が長くなる傾向となり、逆に、興味がない場合、閲覧時間が短くなる傾向となる。

スワイプ速度と興味の関係の結果を（図 3.9）に表す。グラフの縦軸はアイテムに対する正規化されたスワイプ速度の平均値である。興味があるアイテムの場合、スワイプ速度が小

さくなる傾向となり，逆に，興味がない場合，スワイプ速度が大きくなる傾向となる．

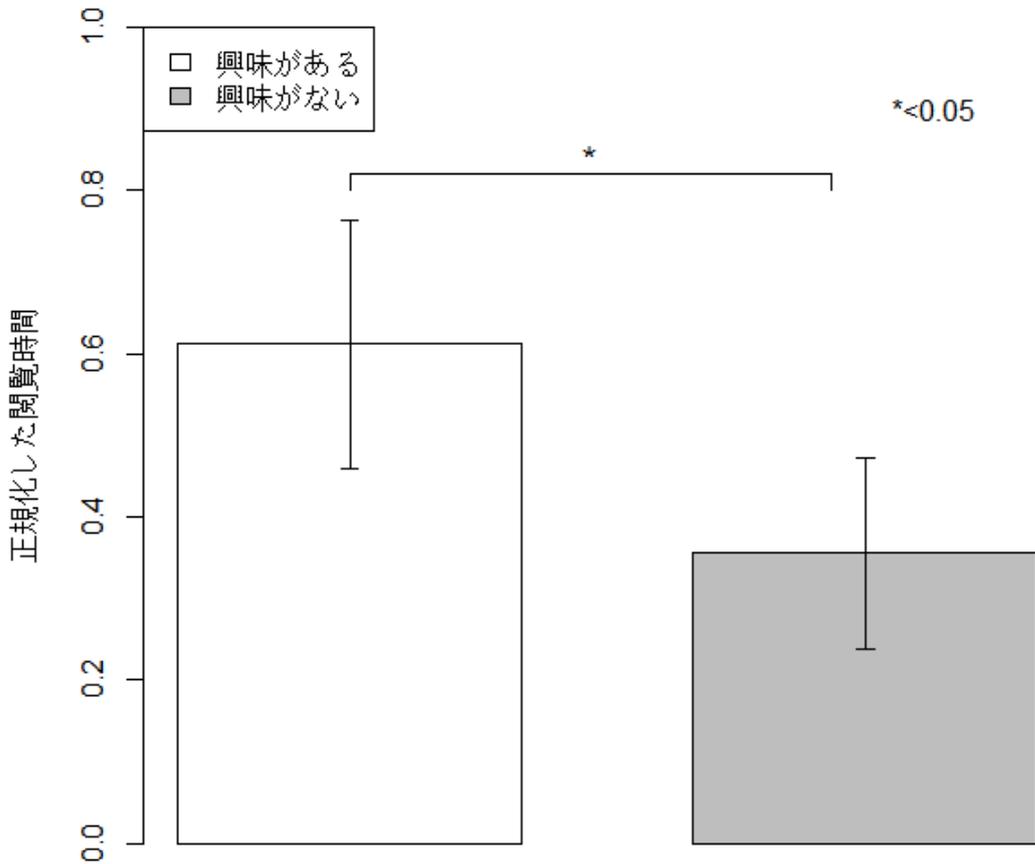


図 3.8. 閲覧時間と興味の関係

t 検定手法を用いて上記の結果を検定したところ，両方（閲覧時間と興味やスワイプ速度と興味）とも 0.05 以下となり，2つの結果も偶然でなく，商品の興味を推測することがわかった．すなわち，閲覧時間が短ければまたスワイプ速度が速ければ，閲覧した商品に興味がある可能性が低いとなる．一方，閲覧時間が長ければまたスワイプ速度が遅ければ，閲覧した商品に興味がある可能性が高くなる．

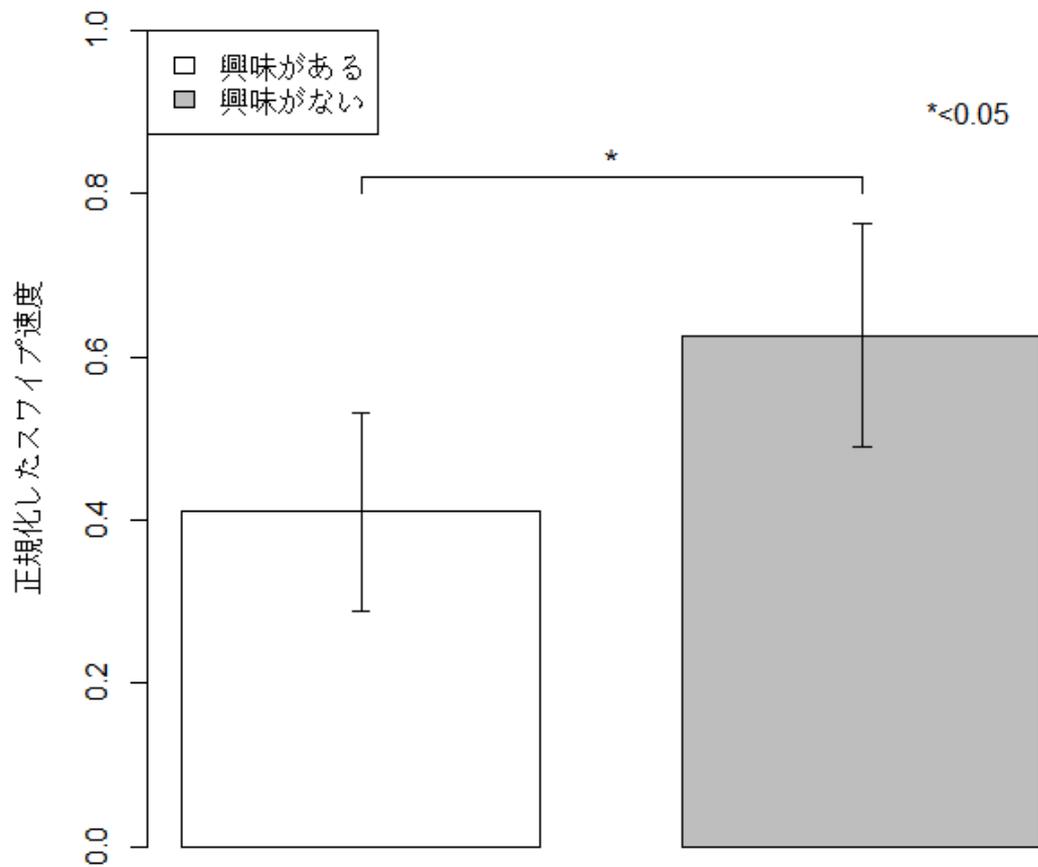


図 3.9. スワイプ速度と興味の関係

### 3.3 オンラインショッピングにおける複合型コンテンツの閲覧時の振る舞いを利用した興味推定

本研究対象とするオンラインショッピングの商品情報は、商品の画像が中心的な役割を果たすが、実際の商品情報は、商品についての画像だけではなく、それに付随するテキストコンテンツによる特徴の記述も含むのが一般的である。そこで、本節では、画像とテキストの組み合わせのコンテンツを閲覧する際の振る舞いが、商品アイテムに対するユーザーの興味の判断を反映しているかどうかを検証する。

### 3.3.1 実験環境

被験者に対しては、図 3.10 に示すようなインタフェースで商品情報を参照するように要求した。このインタフェースは断続的なスクロールで商品情報を閲覧する。一度に1つだけの商品情報を表示することができ、次の項目は、被験者のスワイプ操作で表示される。被験者は、スマートフォン上で指定された商品情報を閲覧しているときに、提案された振る舞いを得ることができる。



図 3.10. プロトタイプシステムの実行画面

### 3.3.2 実験結果

実験に使用した商品データセットは、Amazon において 2014 年 6 月「ベストセラー：本」上位 50 件を利用する。商品のすべての情報は、日本語で書かれている。被験者は日常的にスマートフォンでオンラインショッピングサイトを使用する大学生および大学院生 3 名である。実験対象は本とする。振る舞いデータを得るためのサンプリングレートは、1000 ポイント/秒と設定した。

被験者はスマートフォンで個々の商品を閲覧するように求めていた。あらかじめ予備実験をして、被験者はデータセットでのすべての商品情報についての知識が存在しないと確認した。被験者に「あなたが好きな本を買ってください」と依頼した。また、正確な振る舞

いを取得するために、被験者が閲覧していた前の商品に戻ることはできないと設定した。閲覧後に、我々は 0-1 スケールを使用し、1 の場合は「興味がある」、と 0 の場合は「興味がない」を表す。各被験者が個々の商品に対する評価を尋ね、記録された振る舞いと興味の関係の分析を行った。

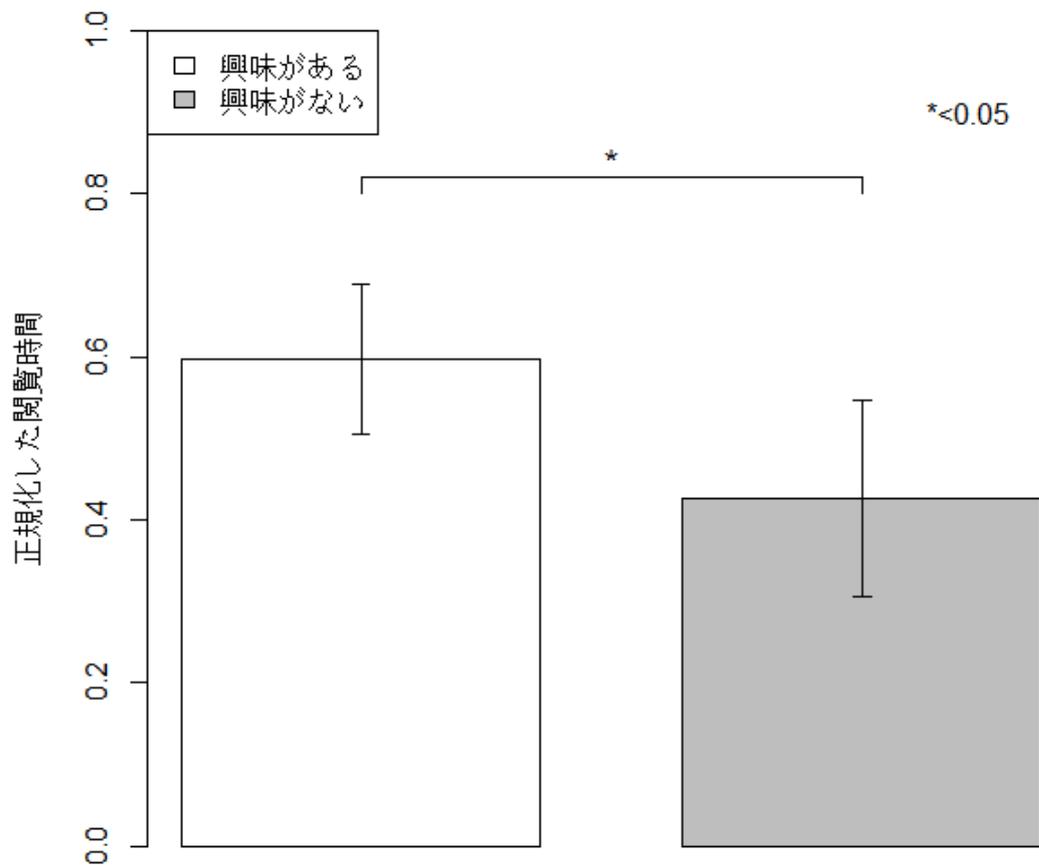


図 3.11. 閲覧時間と興味の関係

図 3.11 は閲覧時間と興味の間係を示す。横軸は「興味がある商品」と「興味がない商品」を示し、縦軸は正規化された閲覧時間の平均値を示す。その結果、ユーザが興味のある商品を閲覧するときに、閲覧時間が長くなる一方で、ユーザが興味のない商品を閲覧するときに、

閲覧時間は短くなった。また、興味がある場合とない場合、各被験者の平均閲覧時間に有意差が存在するかどうかを判断するために t 検定を行ったところ  $p < 0.05$  となり、有意水準 5% で有意差が存在することがわかった。

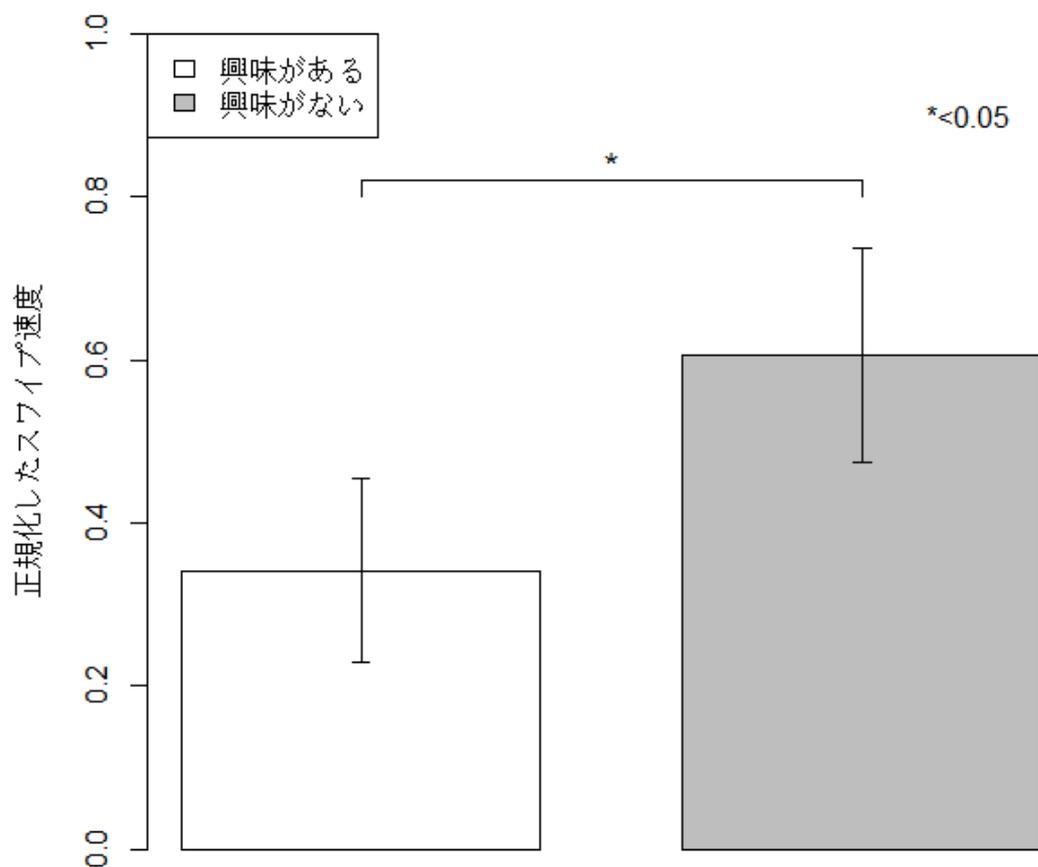


図 3.12. スワイプ速度と興味の関係

図 3.12 はスワイプ速度と興味を示す。横軸は「興味がある」商品と「興味がない」商品を示し、縦軸は正規化されたスワイプ速度の平均値を示す。その結果、ユーザが興味のある商品を開覧するときに、スワイプ速度が遅くなる一方で、ユーザが興味のない商品を開覧するときに、スワイプ速度は速くなった。また、興味がある場合とない場合、各被験者の

平均スワイプ速度に有意差が存在するかどうかを判断するために t 検定を行ったところ  $p < 0.05$  となり，有意水準 5% で有意差が存在することがわかった。

## 第4章

# スマートフォンにおける効率的な商品選別を支援する商品リスト最適化手法

### 4.1 スマートフォンにおける効果的な商品選別の必要性

近年、Web サイト上で商品を購入するオンラインショッピングが一般的に行われるようになった。特に、スマートフォンの普及によって、スマートフォンを利用したショッピングサイトの使用が大幅に増加している。例えば、平成 26 年度版の情報通信白書[68]によると、スマートフォンの利用者のうち、48.9%以上がオンラインショッピングの使用経験を有している。

オンラインショッピングサイトでは、莫大な商品集合からユーザの意図に適合した商品を選別可能とするために、検索機能を提供することが多い[2]。検索機能を利用すれば、ユーザはシステムにクエリを与えることにより、特定の条件を満足する商品のみを対象を絞り込むことができる。ユーザが予め目的とする商品が明確になっている場合には、適切なクエリを考えることができるため検索機能により効率的に商品を選別可能である。しかし、目的とする商品が明確になっていない場合には、適切なクエリを与えることができないため、効率的に商品の選別が行えない場合が多い。例えば、現在利用している洗剤と同一商品を購入するような場合には、希望する商品の名称や性能等をクエリとして検索することにより、効率的に商品を決定できる。しかし、購入する商品が明確になっていない場合には、商品のカ

カテゴリ等により、大まかな絞り込みを行い、候補とする製品に関する個々の属性や評判等を確認しながら、選別を行わなければならない場合が多い。

一般に、このような場合に、検索結果として返される商品は数百～数千となることが多く、ユーザが全ての商品の詳細を確認することは現実的でない。そのため、価格や人気度等の基準によって、検索結果となる商品を順序付けしたリストをユーザに提示することが一般的である。このようなリストには、ユーザにとって興味が低い商品が混在する場合が多い。特に、スマートフォンの小さい画面上で、商品の情報を確認する際には、商品一つ一つの商品の情報を閲覧するコストが大きく、ユーザの購買意図に合致しない商品が多く混在すると、ユーザの購買意欲を低下させる可能性が高い。

この問題を解決するためには、ユーザが商品リストを閲覧する際に、ユーザの購買意図に適合する商品を優先的に提示することによって、商品を効率的に選別できるようにすることが重要である。そこで、本研究では、ユーザの購買意図に基づいて、スマートフォン上で効率的に商品の選別が可能となるような商品リストの最適化手法を開発することを目的とする。

上記の目的を実現するためには、ユーザの購買意図を把握する必要がある。そこで、本研究では、既に確認した商品に対するユーザの評価を取得して、ユーザの購買意図を推測する。それにより、商品リストの未閲覧部分において、ユーザの購買意図が高いと予想される商品を上位に提示することにより、ユーザが効率的に商品を選別できるようにするアプローチを採用する。

例えば、図 4.1 (a) のように、ユーザがオンラインショッピングサイトで、衣服の一種である「アウター」を購入したい場合、「アウター」というキーワードを入力する場合を考える。このとき、検索結果は、何らかの基準（おすすめ順、安い順、レビューが多い順等）で順序付けられ、ユーザに提示される。ユーザはそれぞれの商品詳細を確認するたびに、その商品がユーザの目的に適しているかどうかを評価している。商品に対する評価を推定できれば、ユーザに提示する未閲覧商品に対するユーザの評価も推定することができ、ユーザの評価が高いと予想される商品から優先的にユーザに提示することにより、ユーザの商品選別を支援できると考えられる。

本手法を利用することにより、例えば、図 4.1 (b) のように、ユーザがある商品アイテム (赤色・通学用のアウター) を「いいね！」あるいは正の評価を行うと、その商品と類似の商品が表示リストの先に並び替えられ、優先的にユーザに提示する。逆に、ユーザが負の評価を行うと、その商品と類似の商品が表示リストの末に並び替える。評価の数回を増やせば増やすほど、ユーザのリアルタイムの購買意図が把握でき、購入意向が高い商品が洗い出され、優先的に表示することにより、効果的な閲覧を実現することが可能となる。



(a)



(b)

図 4.1. ユーザの意図に合わせる閲覧

しかし、上記を実現するためには、ユーザが閲覧した商品に対する評価を取得することが必要である。ユーザが閲覧した個々の商品を明示的に評価するのはユーザに負担がかかるため、現実的ではない。そこで、本研究では、ユーザが閲覧した商品に対する暗黙的な評価を自動的に推定する。具体的には、閲覧している商品に対するユーザの評価は、ユーザがスマートフォンに対する操作時の振る舞いに反映されると考え、閲覧した商品に対する評価を推定するための指標として振る舞いを利用する。

一般に、ユーザが対象に対する明示的な評価を行わずに、ユーザの振る舞いに基づいて、対象に対する評価を推定することは、暗黙的フィードバックと呼ばれる。例えば、Web ページの検索結果リストにおいては、ウェブページのタイトルとスニペットが提示されるが、ユーザがクリックしたページはユーザが興味を持っている内容を含んでいる可能性が高いと考え、ユーザのクリックを暗黙的フィードバックとしてユーザの意図を推定することが考えられる。本研究では、スマートフォン上での商品リストを対象に、ユーザが商品リスト閲覧時の暗黙的フィードバックを利用して、ユーザの購買意図を推定することを目指す。暗黙的フィードバックとして利用可能な振る舞いには様々なものが考えられる。例えば、ユーザにとって興味が高い商品には、閲覧時間が長くなる傾向があると予想される。本手法では、ユーザの閲覧時間とスワイプ速度を利用した商品に対するユーザの評価を推定する。

上記の背景の下、本章では、スマートフォンを利用したオンラインショッピングを対象として、閲覧時の振る舞いに基づいて閲覧した商品に対する評価を推定し、推定された評価に基づいて、商品リストの未閲覧部分を最適化する手法を提案する。そして、被験者実験を通じて、提案手法の有効性を評価する。

本研究で対象とする、商品リストの未閲覧部分の最適化という問題は、一種の商品推薦の問題であると考えることができる。なぜなら、ユーザが明示的なクエリを与えることなしに、ユーザに適した商品を推定する問題であると考えられるからである。商品推薦に関しては、これまでも多くの手法が提案されてきた。しかし、従来提案されてきた推薦手法の多くは、ユーザの嗜好が不変であることを前提とし、過去の購買履歴等からユーザの嗜好を推定し、推定した嗜好に適した商品を推薦する。しかし、今回対象とするような商品の効果的な選別のための商品リストの最適化では、ユーザ自身の嗜好に適した商品が必ずしも適切であるとは限らない。例えば、ユーザが友人へのプレゼントを選択する場合、ユーザの

嗜好に基づいて商品を推薦されてもユーザの効率的な商品選別には貢献しない。そこで、本研究では、ユーザが1つの商品リストを閲覧している間は、ユーザの購買意図は不変であると考え、既に関連した商品に対するユーザの購買意図を推定し、未読部分に含まれる商品の適合度を推定する。

本研究の目的は、ユーザの閲覧する商品リストを最適化することである。最適化のために、ユーザの購買意図をモデル化し、何らかの方法で購買意図を推定するというアプローチを採用する。本研究では、商品リストを上位から閲覧する操作に注目し、既に関連した商品に関する評価が推定できれば、それにより、その買い物におけるユーザの興味を推定できると考えた。つまり、本手法の基本的なアイデアは、商品リスト閲覧時に、既読商品に関するフィードバックを利用してユーザの購買意図を推定し、リストの未読部分の順番の最適化を行うというものである。本研究では、ユーザのフィードバックを利用した対象オブジェクトのランキング手法として、適合フィードバックを利用することを考えた。適合フィードバックとは、情報検索においてユーザが与えたクエリに対する検索結果に対して、ユーザの検索意図に適合する正例と適合しない負例を明示することによって、ユーザの検索意図に適したクエリを構成する手法である。適合フィードバックは、リストの未読部分の最適化を目的とするものではないが、我々は、ユーザの購買意図をクエリと考えると、適合フィードバックのアプローチを利用してフィードバックからユーザの意図を推定できると考えた。

適合フィードバックの代表的な手法として Rocchio のアルゴリズムが知られているが、この手法を商品リストの最適化に適用した場合、全ての属性に対してユーザが同等の興味を有することを前提として、評価された商品の特徴から、ユーザの購入意図を推定することになる。しかし、ユーザが商品を選別するときに、素材、機能、値段等、何らかの特徴にこだわった場合が多い。そこで、本章では、ユーザが注目する商品の特徴を考慮して、ユーザの購入意図を推定する手法を提案する。

## 4.2 商品リスト最適化のアプローチ

### 4.2.1 スマートフォンを利用した商品選別

一般的に、スマートフォンでのオンラインショッピングサイトでの商品を選別する際には、ユーザは下記的手段に従うと考えられる。

1. 検索によって大まかに商品を絞り込む.
2. 商品リストを閲覧して候補となる商品を選別する. ここで必要ならば再度検索を行うこともある.
3. 候補となる商品集合の中から購入する商品を決定する.

一般的なオンラインショッピングサイトでは、検索で得られる商品集合は数百～数千件に及ぶ. スマートフォンの画面は狭いため、1つの画面に表示できる商品の数が少なく、ユーザは商品リストの先頭から個々の商品を順番に閲覧する必要がある. これは、PC等の大型の画面で閲覧するよりもユーザに対する負担が大きく、効率が悪い. このような状況で、ユーザが興味のない商品を多く閲覧しなければならければ、ユーザの購買意欲が減少する可能性がある.

一般的に、ユーザは検索によって得られた商品リストに含まれる全ての商品を閲覧する訳ではない. 多くの場合、ユーザはリストの途中で閲覧をやめて、購入商品の決定を行う. しかし、商品リストの未閲覧部分に、購入候補となる商品が存在する可能性がある. そのため、ユーザの購買意図に一致した商品がリストの上位に現れることが望ましいと考えられる.

そこで、本研究では、既に閲覧した商品に対する評価からユーザの嗜好を推定し、未閲覧の商品リストにおいて、ユーザの嗜好に適した商品が上位になるようにリストを最適化する. 商品リストの上位にユーザが興味に応じるものが多く含まれれば、候補商品を発見する時間が短縮化され、ユーザの負担が軽減され、効率的に商品の選別が可能となる.

#### 4.2.2 提案手法の全体像

提案手法では、ユーザはスマートフォン上で商品リストの閲覧時の振る舞いに基づいて、既読部分に含まれる商品に対するユーザの評価を推定する. そして、推定した評価に基づいてユーザの購買意図に適する未読部分に含まれる商品の興味を推定し、ユーザにとって評価が高いと予想される商品から優先的に提示することにより、商品リストの未読部分を最適化する. これにより、ユーザの効率的な商品選別を支援する. この概念図を図4.2に示す.

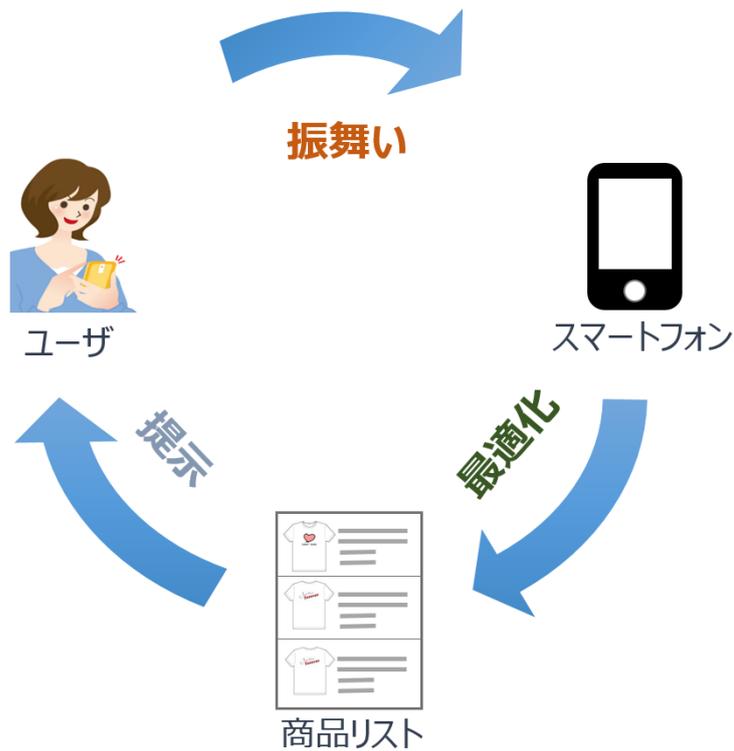


図 4.2. 提案システムの概念図

提案手法では、商品閲覧すると、商品リストを最適化し、ユーザに提示する。閲覧回数が多くなれば、正確にユーザの購入意図を推定でき、ユーザの購入意図により適した商品を優先的に提示可能となり、効率的な商品選別が可能となる。提案する最適化手法の概念図を図 4.3 に示す。

### 4.2.3 問題の形式化

ここでは、提案手法で対象とする問題を形式化する。

全ての商品からなる集合を $\Pi$ とする。 $\Pi = \{p_1, p_2, \dots, p_{|\Pi|}\}$ であり、 $p_i \in \Pi$ は商品を表す。商品集合 $\Pi$ は、複数の商品カテゴリ $C_i$ に分割され $C_i \subseteq \Pi$ であるとする。

ユーザは興味がある商品カテゴリ $C$ に含まれる商品から構成される商品リストを先頭から順番に閲覧する。商品リストを $List(C, order) = \langle p_1, p_2, \dots, p_N \rangle$ と表記する。ここで、 $p_i \in C$ であり、 $order$ は順序関係である。リスト中の商品に対して、 $i \leq j$ のとき、 $(p_i, p_j) \in order$

を満足するものとする．具体的な順序関係の例としては価格，登録日，レビュー数などが考えられる．いま，ユーザが既読部分に含まれる商品集合を $P_r$ とし，未閲覧の商品集合を $P_u$ とする．このとき， $P_u = C - P_r$ である． $List(P_u, order)$ として未閲覧の商品リストを表現できる．本研究の目的は，ユーザが効率的な商品選別が可能となるような未閲覧商品の順序付けの順序関係 $order$ を設定することである．

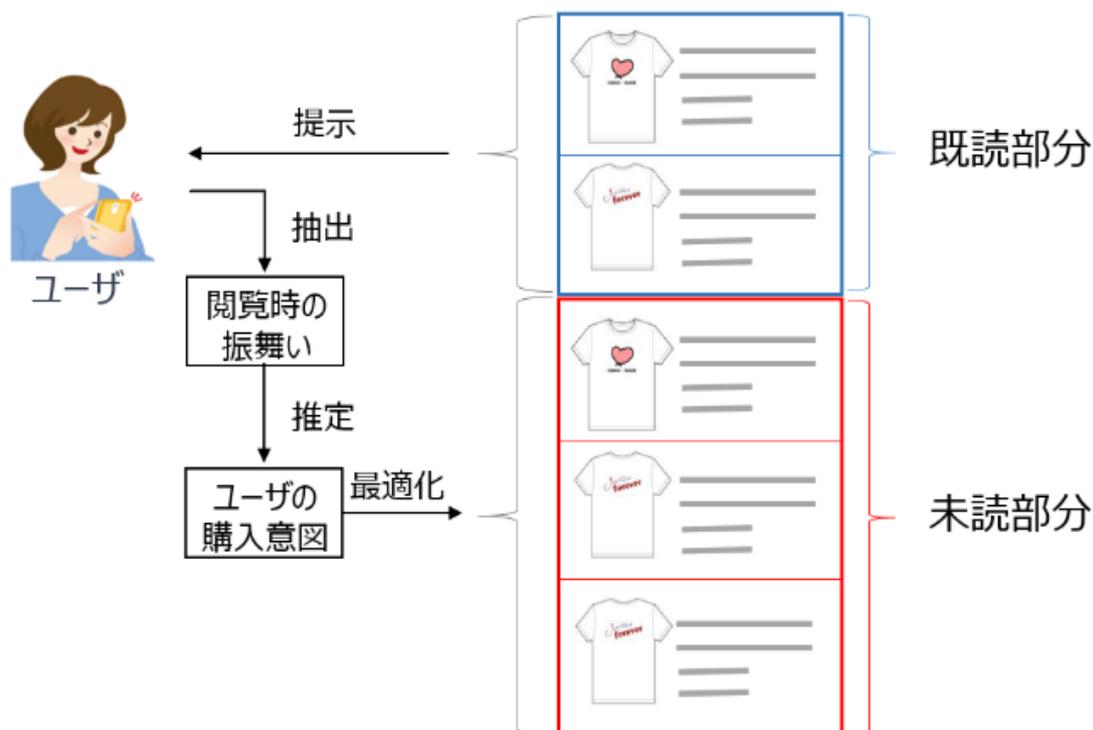


図 4.3. 提案する最適化手法の概念図

提案手法では，商品リスト閲覧中に既読部分に対するユーザの振る舞いからユーザの購入意図を推定し，それに基づいて閲覧中の商品リストの未読部分を最適化する．そのために，商品リストを構成する商品の特性をモデル化する必要がある．本手法では，商品の特性を特徴ベクトルで表す．具体的には，商品 $p_i$ の特徴ベクトルを $f_i = (v_{i1}, v_{i2}, \dots, v_{iL})$ と表現する． $L$ は全ての商品特徴の数を表す．ここで， $v_{ij}$ は商品 $p_i$ の特徴 $a_j$ の有無を表す．同一のカテゴリに所属する商品は，全て同次元の特徴ベクトルとして表現されるものとする．商品 $p_i$ が特徴 $a_j$ を有する場合は $v_{ij} = 1$ となり，有さない場合は $v_{ij} = 0$ となる．例えば，靴を対象とした場合の特徴としては，「通気性」，「雨の日」「幅広」「セール商品」などがある．図 4.4 に

靴を対象とした特徴ベクトルの例を示す。

なお、商品が有する特徴としては、上記のようなカテゴリカルな特徴の他に、価格やサイズなど連続量で表現される特徴が存在する。このような場合には、取りうる連続量を区間に分割（量子化）し、その区間に属する場合には1、属さない場合は0として表現する。その際、区間をいくつに分割すべきかは重要な問題であるが、最適な区間の決定方法についての検討は今後の課題である。

$$F = \begin{matrix} & a_1 & a_2 & a_3 & \dots & a_L \\ & \text{(通気性)} & \text{(ヒール)} & \text{(幅広)} & \dots & \text{(セール商品)} \\ p_1 & \left( \begin{array}{cccccc} 1 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 1 & 0 & \dots & 1 \end{array} \right) \end{matrix}$$

図 4.4. 靴を対象とした場合の特徴ベクトルの例

### 4.3 ユーザの振る舞いに基づいた興味推定

本手法では、商品リストの既読部分に含まれる商品に対するユーザの評価に基づいて、未読部分を最適化する。ユーザの評価を取得するための最も単純な手法は既読部分に含まれる個々の商品に対して、ユーザが明示的に評価を指定することである。しかし、この手法では、ユーザに負担が大きく、現実的ではない。この問題を解決するため、本手法では、閲覧時の振る舞いに注目する。我々は、ユーザが商品リストをスマートフォン上で閲覧する際に、表示されている商品に対する評価の違いが、スマートフォンを操作するユーザの振る舞いに影響を与えたと考えた。

本研究で対象とするスマートフォンを利用したオンラインショッピングにおける商品リストに関して、ユーザの閲覧時の振る舞いに基づいて商品リスト内の既読商品に関する評価を推定する。今回の対象に適した振る舞いの特徴として、閲覧時間とスワイプ速度を利用する。

### 4.3.1 振る舞いに基づいた興味の推定手法

ユーザの振る舞いに基づいて、商品の興味を推定する手法を説明する。

ユーザの振る舞いに基づいて、商品の興味を推定するために、ユーザ $u$ が、閲覧した商品 $T$ の価値 $V$ を推測することを考える。

いま、すべての商品集合を $S$ として、閲覧した商品集合を $T = \{t_1, t_2, \dots, t_n\}, T \subseteq S$ とする。そして、未閲覧商品集合を $W = \{w_1, w_2, \dots, w_k\} \in S$ とする。 $n, k$ はそれぞれ、閲覧した商品と未閲覧の商品、それぞれの数を表す。 $n + k = m$ となる。閲覧した商品集合 $T$ に対して、閲覧際の振る舞い $B = \{b_1, b_2, \dots, b_n\}$ とユーザが閲覧した商品 $T$ に対する評価値 $E = \{e_1, e_2, \dots, e_n\}$ を獲得する。ユーザ $u$ は $u = (T_u, B_u, E_u)$ として表現する。振る舞い $b_i$ は、 $b_i = (rt_i, sv_i)$ として、閲覧時間、スワイプ速度の組で表現する。

商品 $p_i$ に対する振る舞い $b_i = (rt_i, sv_i)$ は、閲覧時間、スワイプ速度の組で表現する。なお、あるユーザのセッション中の振る舞い集合 $S$ に含まれる振る舞い $b_i \in S$ に対して、 $rt_i, sv_i$ を以下のように正規化する。

$$rt_i = \frac{rt_{oi} - \bar{rt}}{\sigma_{rt}} \dots (4.1)$$

$$sv_i = \frac{sv_{oi} - \bar{sv}}{\sigma_{sv}} \dots (4.2)$$

ここで、 $rt_{oi}$ は $rt_i$ の正規化前の値であり、 $\bar{rt}$ はそのユーザの教師データ集合 $T$ に含まれる振る舞いの閲覧時間の平均値を表す。式(4.2)も同様である。 $\sigma_{rt}, \sigma_{sv}$ はそれぞれ、教師データ集合 $T$ に含まれる振る舞いの閲覧時間とスワイプ速度の標準偏差を表す。

本手法では、閲覧した商品に対する興味を推定するために、代表的な教師あり学習モデルである SVM を用いる。SVM のカーネルはガウシアンカーネルを利用する。教師データを収集するため、ユーザがシステムを利用する前に、商品データリストを閲覧してもらい、その後、それぞれの商品に対するユーザの評価を明示的に指示してもらい、それを教師用データとして SVM を生成する。そして、作成された SVM 分類器を利用して、新しい振る舞いデータから、閲覧した商品を分類することにより、商品に対するユーザの評価を推定する。

ユーザが商品 $p_i$ を閲覧する際のユーザの振る舞いをベクトル $\mathbf{b}_i = (b_{i1}, b_{i2}, \dots, b_{in})$ として表す。ここで、 $b_{ij}$ は、商品 $p_i$ に対する振る舞いの $j$ 番目の特徴量であり、 $n$ は、振る舞いベクトルの次元数を表す。また、教師データ集合は、 $T = \{(\mathbf{b}_1, \mathbf{e}_1), (\mathbf{b}_2, \mathbf{e}_2), \dots, (\mathbf{b}_m, \mathbf{e}_m)\}$ として表現できる。ここで、 $(\mathbf{b}_i, \mathbf{e}_i)$ における $\mathbf{e}_i$ は、商品 $p_i \in P_r$ に対するユーザが明示的に示した評価である。商品が購買意図に合っている場合は1、合っていない場合は0とする。また、 $m$ は教師データ集合に含まれる振る舞いベクトルの数である。

## 4.4 閲覧リストの最適化

### 4.4.1 ユーザの購入意図のモデルと最適化

ユーザの購買意図を、特徴に対する重みのベクトルとして表現する。具体的には、対象とするユーザの購買意図を $\mathbf{r} = (w_1, w_2, \dots, w_L)$ と表記する。ここで、 $w_i$ は、特徴 $a_i$ に対する重みを表す実数である。商品 $p_i$ のユーザの購買意図 $\mathbf{r}$ に対する適合度を $\text{sim}(\mathbf{f}_i, \mathbf{r})$ と表す。関数 $\text{sim}$ は以下に示すコサイン相関値として定義される。

$$\text{sim}(\mathbf{f}_i, \mathbf{r}) = \frac{\mathbf{f}_i \cdot \mathbf{r}}{\|\mathbf{f}_i\| \|\mathbf{r}\|} \dots (4.3)$$

いま、ユーザの購買意図を表すベクトル $\mathbf{r}$ が与えられたとする。また、商品リスト $\text{List}(P, \text{order})$ に対して、既読部分の商品集合を $P_r$ とする。このとき、未読部分に含まれる商品集合 $P_u = P - P_r$ から構成される商品リストを最適化することが必要である。本手法では、購買意図 $\mathbf{r}$ と商品との適合度に基づいて $P_u$ のリストを構成する。具体的には、上記の類似度に基づいて以下の順序集合 $\text{order}_{\text{sim}}$ とする。

$$\text{order}_{\text{sim}}(\mathbf{r}) = \{(p_i, p_j) \mid \text{sim}(\mathbf{f}_i, \mathbf{r}) \geq \text{sim}(\mathbf{f}_j, \mathbf{r})\} \dots (4.4)$$

これは直観的には、未読リストに含まれる商品に対して、購買意図 $\mathbf{r}$ との適合度が高い商品がリストの上位にくるようなリストを構成することを意味する。



図 4.5. 未閲覧商品を提示するための例

#### 4.4.2 購買意図の推定

上記の手法で未読部分の最適化を行うためには、ユーザの購買意図を適切に推定する必要がある。本研究では、ユーザの購買意図を、ユーザが対象としている商品リストの既読部分に対するユーザの振る舞いに基づいて推定する。

本手法では、まず、前節で述べたユーザ評価の推定手法を利用して、既読リストに含まれる商品集合 $P_r$ を、ユーザの購買意図に適合したと推定される商品集合 $P_r^+ \subseteq P_r$ と購買意図に適合していないと推定される商品集合 $P_r^- \subseteq P_r$ に分類する。

#### 4.4.3 閲覧した商品に対する評価に基づくユーザの購買意図の推定

本研究では、商品の特徴をベクトルとして表現し、ユーザの商品に対する評価に基づいて、

購買意図を推定する。  $P_r^+$  と  $P_r^-$  を利用して、ユーザの購買意図を推定するための最も典型的な手法としては、ユーザの購買意図をクエリとして捉え、  $P_r^+$  を検索結果に対する正のフィードバック、  $P_r^-$  を負のフィードバックとして、適合フィードバック手法を適用することである。具体的には、代表的な適合フィードバックアルゴリズムである *Rocchio* のアルゴリズムを利用すると、商品集合  $P_r^+$  と商品集合  $P_r^-$  を用いて、ユーザの購買意図  $\mathbf{r}$  を以下の式で求める事が考えられる。

$$\mathbf{r} = \alpha * \frac{1}{|P_r^+|} \sum_{p_i \in P_r^+} \mathbf{f}_i - \beta * \frac{1}{|P_r^-|} \sum_{p_i \in P_r^-} \mathbf{f}_i \dots (4.5)$$

ここで、  $\alpha$  と  $\beta$  は正のフィードバックと負のフィードバックの重みを表すパラメータであり、  $\alpha$  と  $\beta$  の和は1であるとする。

#### 4.4.4 ユーザのこだわりを反映したユーザの購買意図の推定

一般的に、ショッピングにおいて、ユーザが商品を選別するとき、素材、機能、値段等、注目する属性には偏りがあることが知られている[38-41]。上記の *Rocchio* のアルゴリズムを利用した推定手法では、商品の特徴ベクトルの次元が大きく、商品の属性が多い場合に、注目していない商品の属性の影響が、ユーザが注目している属性よりも大きくなり、不適切な商品を提示する可能性がある。

具体的な例を用いて、上記の現象を説明する。いま、5つの商品から構成される商品集合  $P = \{p_1, p_2, p_3, p_4, p_5\}$  を考える。これらに対する特徴として、5つの特徴「通気性」「ヒール」「幅広」「鏡面加工」「セール商品」を考える。それぞれの特徴の有無が図 4.5 の行列  $F$  のように与えられるとする。

いま、商品リスト  $\langle p_1, p_2, p_3, p_4, p_5 \rangle$  が与えられ、ユーザが上位3件を閲覧したとする。ここで、ユーザが通気性を有する靴に興味がある場合、閲覧した商品  $p_1 \sim p_3$  が特徴「通気性」があるために、  $P_r^+ = \langle p_1, p_2, p_3 \rangle$ 、  $P_r^- = \emptyset$  と推定されたとする。ここで、  $P_r^+$  に含まれる商品の特徴を図 5.6 の行列  $F_r^+$  に示す。ここで、上記の *Rocchio* の適合フィードバックに基づいた手法では、  $\mathbf{r} = (1, 0.66, 0.33, 0, 0)$  となる。なお、ここでは、  $\alpha = 1$  としている。

未読部分に含まれる商品  $p_4$  と  $p_5$  を考えると、商品  $p_4$  は「通気性」の機能がなく、興味があ

る可能性が低い。一方、商品 $p_5$ は「通気性」があり、興味がある可能性が高い。しかし、未閲覧商品 $p_4$ と $p_5$ の優先順位を計算すると、 $sim(f_4, r) = 0.376$ ,  $sim(f_5, r) = 0.336$ となる。つまり、商品 $p_4$ は商品 $p_5$ より適合度が高く、商品 $p_5$ より上位になり、優先的に提示することになる。つまり、興味がある可能性が高い商品 $p_5$ が優先されないことになってしまう。

いま、全ての特徴からなる集合を $A = \{a_1, a_2, \dots, a_{|A|}\}$ とする。また、 $A$ の全ての部分集合からなる冪集合 $AS = 2^A$ を以下のように定義する。

$$AS = \{as | \forall as \subseteq A\} \dots (4.6)$$

ここで、 $as \in AS$ を特徴集合と呼ぶ。いま、商品集合 $P$ が与えられたとき、 $P$ に対する特徴集合 $as$ のサポート値 $supp(as, P)$ を以下の式で定義する。

$$supp(as, P) = \frac{num(as, P)}{|P|} \dots (4.7)$$

ここで、 $num(as, P)$ は、 $P$ の要素である商品の中で、 $as$ に含まれる特徴を全て有するものの数である。

また、与えられた商品集合 $P$ に対する頻出パターン集合 $FP(P)$ を以下の式で定義する。

$$FP(P) = \{as | as \in AS \text{ かつ } supp(as, P) \geq min\_supp\} \dots (4.8)$$

ここで、 $min\_supp$ は、最小サポート値を表す閾値である。本論文では、頻出属性の抽出には、*FP-growth* アルゴリズム[56]を利用する。*FP-growth* アルゴリズムでは、Input と Output およびアルゴリズムは下記となる。

- Input : 商品の集合 $P_r$ と最小サポート閾値 $min\_supp$ .
- Output : 頻出特徴集合 $FP(P)$ および $fp \in FP(P)$ に対するサポート値 $supp(fp, P)$ .

図 4.5 の例を用いて、頻出パターンを抽出した例を表 1 に示す。

$rank(as, P)$ は、商品集合 $P$ に対して、特徴集合をサポート値の大きい順に並べたときの特徴集合 $as$ の順位を表す。

表 4.1. 頻出パターンを抽出した例

	集合	支持度 $supp(as)$	$Rank(as)$
$as_1$	{通気性}	1	1
$as_2$	{通気性,ヒール}	0.66	2
$as_3$	{ヒール}	0.66	2
$as_4$	{通気性,ヒール,幅広設計}	0.33	4
$as_5$	{通気性,幅広設計}	0.33	4
$as_6$	{幅広設計}	0.33	4

我々は、既読リストに含まれる商品集合における頻出パターンに基づいて、ユーザの購買意図を推定する手法を提案する。そのために、特徴集合 $as$ に対する特徴ベクトル $f_{as}$ を以下のように定義する。

$$f_{as} = (v_1, v_2, \dots, v_{|A|}) \dots (4.9)$$

ここで、

$$v_i = \begin{cases} 1 & (a_i \in as) \\ 0 & (a_i \notin as) \end{cases} \dots (4.10)$$

である。このとき、商品集合 $P_r$ に対して、 $P_r$ から頻出パターン集合 $FP(P_r)$ を用いて、ユーザの購買意図 $r'$ を式(15)のように推定する。

$$r' = \frac{\gamma}{|FP^+|} \sum_{as \in FP^+} \frac{1}{rank(as, P_r)} * f_{as} - \frac{\delta}{|FP^-|} \sum_{as \in FP^-} \frac{1}{rank(as, P_r)} * f_{as} \dots (4.11)$$

ここで、 $\gamma$ と $\delta$ はパラメータを表し、 $\gamma$ と $\delta$ の和は1とする。 $FP^+, FP^-$ は、それぞれ $FP^+ = FP(P_r^+)$ ,  $FP^- = FP(P_r^-)$ を表す。頻出属性パターンのサポート値 $supp(as, P_r)$ に基づいて、頻出属性パターンの順位 $rank(fp, P_r)$ を計算し、その順位に基づいて、頻出特徴の重みを決める。そのランクによって対応する頻出属性の値を与える。順位が高い特徴集合の値はより大きくなる。

---

### アルゴリズム 頻出パターンの抽出

---

1.  $FP - growth(Tree, \alpha)$  //  $\alpha$ は条件付きパターンベース(*conditional pattern base*), 初期値は $null$ とする
  2. *if*  $Tree$ がパス $P$ を包含する *Then*
  3. *for* パス $P$ の中のノードの各組み合わせ $\beta$
  4.  $\beta$ のサポート値は $\beta$ のノードの中の最小サポート値に等しい ;
  5. *if*  $\beta$ のサポート値  $\geq min\_sup$  閾値
  6.  $\beta$ を出力する
  7. *end if*
  8. *end for*
  9. *end if*
  10. *else if*
  11. *for each*  $\alpha_i$  //属性 $\alpha_i$ (頻度の逆順)
  12.  $\beta = \alpha_i \cup \alpha$ ,  $\beta$ のサポート値は $\alpha_i$ のサポート値に等しい ;
  13. 条件付きパターンベース $\beta$ を基に,  $FP - tree Tree_\beta$ を構築する ;
  14. *if*  $Tree_\beta \neq \emptyset$  *then*
  15.  $FP - growth(Tree_\beta, \beta)$ を呼び出す ;
  16. *end if*
  17. *end for*
  18. *end else if*
- 

例えば,  $\gamma = 1$ とし, 最小サポート値 $min\_supp$ は40%の場合, 式(4.11)で例を計算すると, 購買意図 $\mathbf{r}' = (0.5, 0.33, 0, 0, 0)$ となる. そして, 未閲覧商品 $p_4$ と $p_5$ に対して興味 $\mathbf{r}'$ との適合度を計算すると,  $sim(\mathbf{f}_4, \mathbf{r}') = 0.124$ ,  $sim(\mathbf{f}_5, \mathbf{r}') = 0.168$ となる. このことから, ユーザの未読部分の最適化により, ユーザのこだわりである「通気性」の靴(商品 $p_5$ )が優先して表示されるようになる.

## 4.5 評価実験

提案手法の有効性を検証するために、提案手法のプロトタイプシステムを実装し、それを用いて評価実験を行った。

オンラインショッピングサイトにおいて、ユーザの最初の動作は、クエリを入力することではなく、商品カテゴリを選択する場合が多い。そのため、提案するシステムはクエリを入力して得られる検索結果を対象としないことを前提とする。

評価実験として3種類の実験を行った。第1の実験は、振る舞いに基づいた既読部分に対する商品の評価の推定手法の有効性の検証である。第2の実験は、ユーザが明示的に商品の興味を指定した場合の提案手法の有効性の評価である。第3の実験は、既読部分に対して、ユーザが明示的な評価を指定せず、提案した振る舞いからの評価を利用して、最適化を行った場合の評価である。それぞれの実験の詳細は以下に述べる。

スマートフォン上で動作するプロトタイプシステムの実行画面を図 3.29 に示す。本システムのインターフェースでは、商品ページが1件ずつ表示され、ユーザはスワイプ操作で、次の商品ページを表示する。使用したスマートフォンのCPUは1.6GHzであり、メモリは2GBである。なお、表示用のディスプレイサイズは、4.8インチである。OSはAndroid™ 4.3である。

今回の実験では、靴とバッグを対象として実験を行った。靴に関しては、靴を対象としたオンラインショッピングサイトの一つである *Shoes-Street*[57]上で販売されている紳士靴を対象とした。このサイトに掲載されている536件の紳士靴と63個の商品特徴をデータセットと設定した。また、バッグ・ケースを対象としたオンラインショッピングサイトの一つである *Youshida-kaban*[58]上で販売されているPCバッグを対象とした。このサイトに掲載されている593件のPCバッグと69個の商品特徴をデータセットと設定した。

被験者は日常的にスマートフォンを使用する大学生および大学院生20名である。被験者は日常的にスマートフォンを使用する大学生および大学院生10名である。その中で、10名の被験者には、靴を対象とした評価実験行ってもらい、残りの10名の被験者には、バッグを対象とした評価実験を行ってもらった。画像のみのコンテンツとテキストや画像コンテ

シューズ比較するために、PC バッグと紳士靴をそれぞれ対象として実験を行い、実験結果をもとに並べた。

なお、商品特徴の抽出に関しては、商品の説明文、レビュー等から自動的に収集することが考えられるが、本研究の焦点ではないため、手動で抽出する方式で行なった。

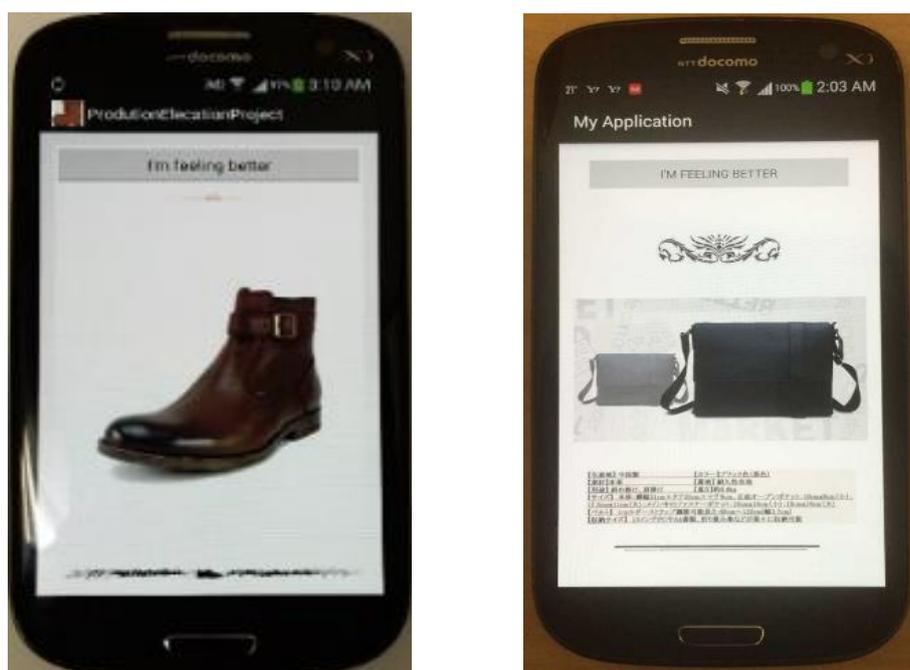


図 4.6. プロトタイプシステム

靴を対象とした実行画面(左), バッグを対象とした実行画面(右).

#### 4.5.1 振る舞いからの評価の推定

3章での予備実験を踏まえて、提案手法の有効性を検証するために、スマートフォンで商品リストを閲覧した際の振る舞いに基づいて、閲覧した商品に対するユーザの評価を推定する手法を提案した。この手法の有効性を評価するために以下の実験を行った。

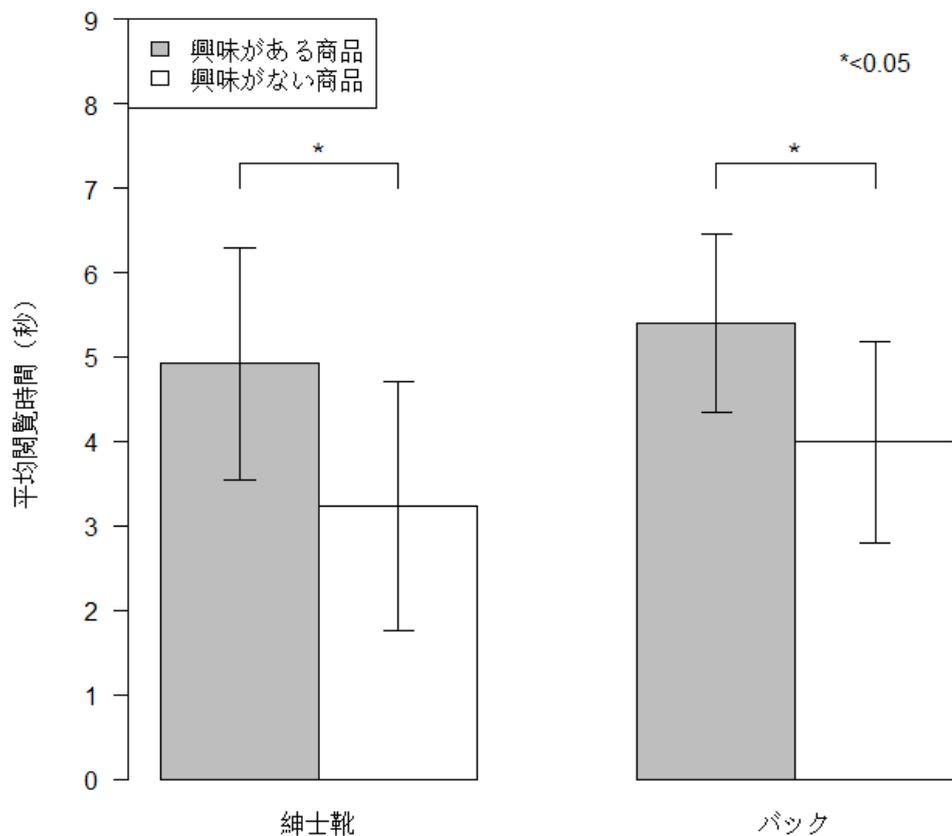


図 4.7. 閲覧時間と興味の関係

- 実験手法

被験者に対して、事前に準備した 100 件の商品をスマートフォンで閲覧してもらい、個々の商品に対して閲覧時の振る舞いを計測した。さらに、閲覧後、被験者は閲覧した全ての商品それぞれに関して、「興味がある」か「興味がない」の 2 種類の評価を行ってもらった。まず、今回利用した閲覧時間とスワイプ速度という 2 種類の特徴量と、ユーザの評価にどのような関係があるかを分析する。次に、さらに、提案する SVM を利用した推定手法を評価するために、実験で得られたデータに対して、*5-Fold Cross Validation* を行い、分類性能を分析する。

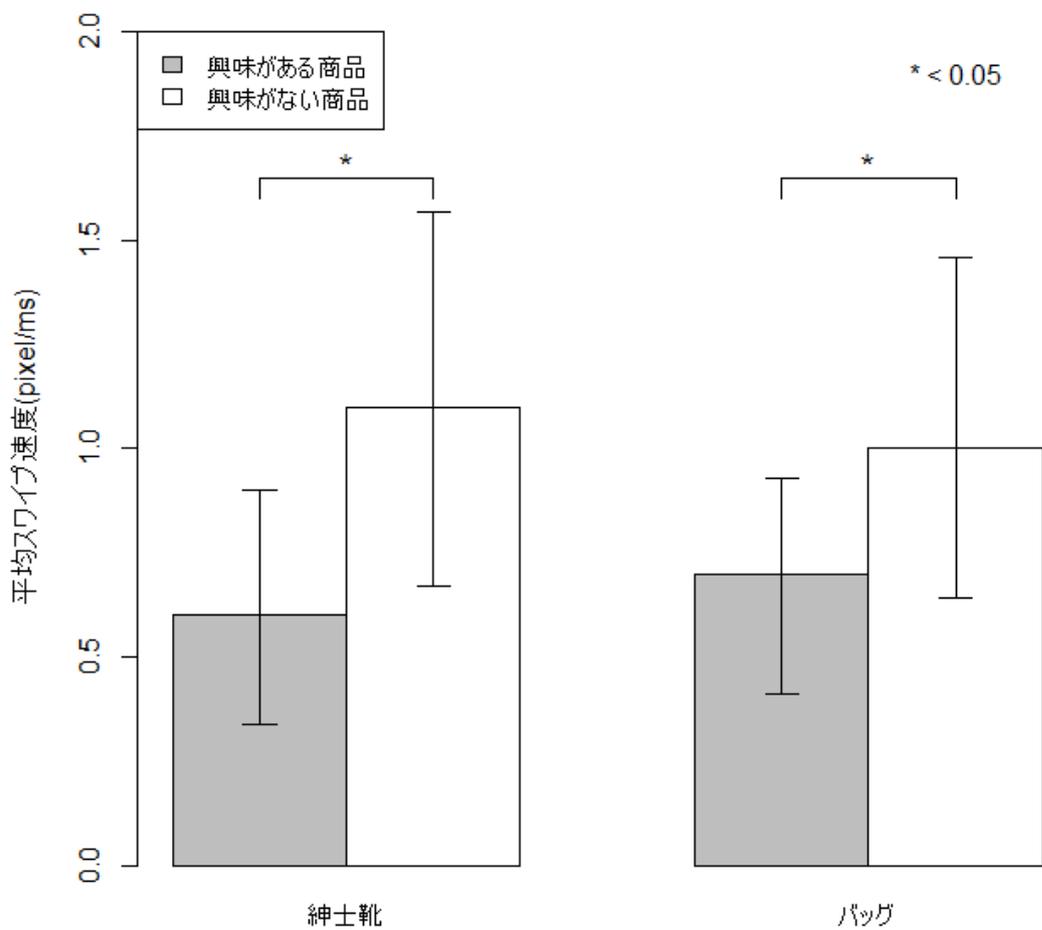


図 4.8. スワイプ速度と興味の関係

- 結果と考察

紳士靴を対象とした実験において、10名の被験者が興味があった商品の数は合計237件であり、興味がなかった商品の数は合計763件であった。バッグを対象とした実験では、被験者数は10名であり、興味があった商品の数は251件、興味がなかった商品の数は749件であった。紳士靴とバッグのそれぞれのカテゴリについて、興味がある商品と、興味が無い商品に対する閲覧時間の違いを図4.7に示す。

紳士靴を対象とした場合、興味がある場合には、平均閲覧時間は 4.95 秒 (SD=1.38) であったのに対して、興味がない場合には、3.23 秒 (SD=1.47) であった。一方、バッグを対象とした実験において、興味がある場合には、平均閲覧時間は 5.40 秒 (SD=1.05) であったのに対して、興味がない場合には 3.99 秒 (SD=1.19) であった。また、それぞれの商品カテゴリにおいて、興味がある場合とない場合、各被験者の平均閲覧時間に有意差が存在するかどうかを判断するために t 検定を行ったところ  $p < 0.05$  となり、有意水準 5% で有意差が存在することがわかった。

一方、閲覧した商品に対する被験者の評価によるスワイプ速度の違いを図 4.8 に示す。紳士靴を対象とした場合、興味がある場合には、平均スワイプ速度は  $0.62 \text{ pixel/ms}$  (SD=0.28) であったのに対して、興味がない場合の、平均スワイプ速度は  $1.12 \text{ pixel/ms}$  (SD=0.45) であった。一方、バッグを対象とした場合、興味がある場合には、平均スワイプ速度は  $0.67 \text{ pixel/ms}$  (SD=0.26) であったのに対して、興味がない場合には、平均スワイプ速度は  $1.05 \text{ pixel/ms}$  (SD=0.41) となった。また、それぞれの商品カテゴリにおいて、興味がある場合と興味がない場合に、各被験者の平均スワイプ速度に有意差が存在するかどうかを判断するために t 検定を行ったところ  $p < 0.05$  となり、有意水準 5% で有意差が存在することがわかった。

上記の結果から、今回対象とした 2 種類の商品カテゴリの商品では、閲覧時間やスワイプ速度は、興味がある場合と興味が無い場合とでは有意差が存在していることが明らかになった。さらに、興味がある商品を閲覧する際には、興味が無い商品を閲覧するよりも閲覧時間が長くなり、スワイプ速度は遅くなる傾向にあることが明らかになった。

上記の特徴量を利用して、ユーザの評価を推定する手法の評価を行う。評価のためには K-Fold Cross Validation を用いた。K 値は 5 と設定した。すなわち、100 個のサンプルデータを 5 分割し、4 ブロックを訓練データ、1 ブロックをテストデータに利用し、それぞれを全ての組み合わせで行った。性能を評価するための指標として、閲覧時間とスワイプ速度を特徴量として利用した場合の SVM による評価の分類の性能を評価する。評価手法として正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall) および F 値 (F Measure) を利用する [2]。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots (4.12)$$

$$Precision = \frac{TP}{TP + FP} \dots (4.13)$$

$$Recall = \frac{TP}{TP + FN} \dots (4.14)$$

$$F - Measure = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} \dots (4.15)$$

ここで、TP(True Positive)は興味がある商品と正しく分類した数であり、FP(False Positive)は興味がある商品と誤って分類した数である。また、FN(False Negative)は興味がない商品と誤って分類した数であり、TN(True Negative)は興味がない商品と正しく分類した数である。

表 4.2. 閲覧時の振る舞いによる推定結果

	正解率	適合率	再現率	F 値
紳士靴	0.71	0.73	0.66	0.69
バッグ	0.74	0.76	0.66	0.71

実験の結果を表 4.2 に示す。紳士靴を対象とする場合、正解率が 0.71、F 値が 0.69 であり、バッグを対象とする場合、正解率が 0.74、F 値が 0.71 であり閲覧時の振る舞いからユーザの評価をある程度正確に推定できることがわかった。また、被験者によって個人差があった。最良の結果であった被験者の正解率は 8 割(0.81)以上であったが、最も低い結果であつ

た被験者の正解率は7割弱(0.67)であった。

#### 4.5.2 ユーザの明示的な評価に基づく最適化

ユーザが予め目的とする商品が明確になっていない状況において、ユーザの既読部分の商品に対する正確な評価が取得可能な場合に、提案した未読部分の最適化手法の有効性を実験により評価した。

- 実験手法

実験用のデータセットから、20個のサンプル商品を予め選択し、被験者に閲覧してもらった。閲覧する前に、被験者に自分が好みの紳士靴を購入するようにと指示した。閲覧後、閲覧したサンプル商品に対して、個別に人手で「興味がある」か「興味がない」を評価してもらった。そして、提案手法を用いて商品リストの未閲覧部分の最適化を行い、ユーザは提示された最適化された部分に対して、商品リストに上位30件商品に対して被験者が全ての閲覧した商品にユーザの好みに対する主観的な適合度を1~5、5段階で評価してもらった。それぞれ、1:全く適合しない、2:適合しない、3:どちらもない、4:適合する、5:非常に適合するに対応している。提案手法に対するベースラインとして、オンラインショッピングの閲覧時に広く利用されていると考えられる人気順による順序付けと、単純な適合フィードバック手法である *Rocchio* のアルゴリズムを利用した順序付けによる結果と比較した。なお、各手法で用いたパラメータとしては、*Rocchio* 手法では $\alpha=0.75$ 、 $\beta=0.25$ とし、提案手法では、 $\gamma=0.85$ 、 $\delta=0.15$ とした。このパラメータは、予備実験を行い、それぞれの手法において nDCG の値が最も高くなる値を調査して決定した。

- 結果と考察

ランキング等の多段階の適合度を考慮できる尺度として一般的に利用されている nDCG (normalized Discount Cumulative Gain)の値を計算した。被験者がリストの評価数が上位と30件の場合の nDCG 平均値を図 4.9 (靴)、図 4.10 (バッグ) に示す。それぞれの商品カテゴリに対する nDCG@30 の場合において、提案手法は、ベースライン1やベースライン2と比べると、良好な結果を得ることができた。提案手法では、紳士靴を対象とした場合、nDCG@30 の結果は 0.69、(標準偏差 SD =0.04)であり、バッグを対象とした場合、nDCG@30 の

結果は 0.75(SD=0.05)であった。一方、ベースライン1では、紳士靴を対象とした場合 nDCG@30 の結果は 0.42(SD=0.08)であり、バッグを対象とした場合、nDCG@30 の結果は 0.39(SD=0.07)であった。ベースライン2では、nDCG@30 の結果は 0.63(SD=0.10)であり、nDCG@30 の結果は 0.67(SD=0.09)であった。提案手法とベースラインそれぞれの結果に対して、コルモゴロフ・スミルノフ検定を用いて、それぞれの正規分布に従うかどうかについて検定を行った結果、それぞれの商品カテゴリにおいて、提案手法やベースラインが 0.05 より大きく、共に正規分布に従うという仮説が採択できた。また、t 検定により、nDCG@30 の結果において、提案手法がベースライン1の間に有意差 ( $p < 0.01$ ) また、ベースライン2の間に有意差 ( $p < 0.05$ ) があることが確認された。

#### 4.5.3 振る舞いを利用した評価推定に基づいた商品リストの最適化手法の評価

ユーザが既読部分に対する明示的な評価を与えずに、既読部分に対する振る舞いからユーザの購買意図を推定し、未読部分の最適化を行った場合の評価を行った。

- 実験手法

被験者に、対象とするデータセットに含まれる商品を、提案手法と2種類の比較手法それぞれを用いて、30個の商品から構成される商品リストを閲覧してもらった。閲覧後に、それぞれの商品に対する興味の有無を回答してもらった。比較手法としては、人気順(ベースライン1)、および Rocchio 手法(ベースライン2)を利用した。なお、提案手法において、振る舞いに基づく評価の推定を行うための SVM の学習には 4.5.1 節で述べた振る舞いからの評価の実験において取得した 100 件分のデータを教師データとして利用した。

さらに、被験者の主観的な満足度を調査する目的で主観評価を行ってもらった。被験者に対して、それぞれの手法で閲覧した商品リストに対する7段階の評価値を回答してもらった。選択肢は「0:全く満足していない」、「1:満足していない」、「2:ちょっと満足していない」、「3:どちらともいえない」、「4:ちょっと満足している」、「5:満足している」、「6:とても満足している」である。

- 結果と考察

提案手法の性能を評価する尺度として、既に関連したリストの平均適合率(リスト中に含

まれるユーザが興味を持つ商品の割合) を比較した。

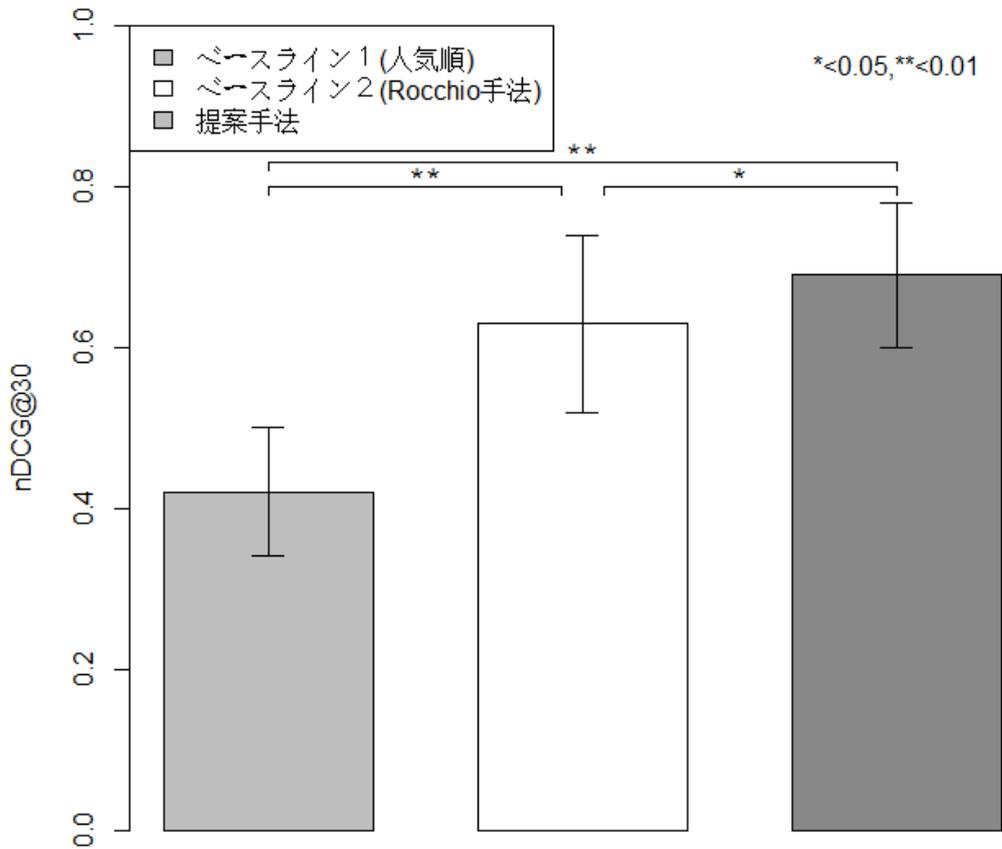


図 4.9. 靴を対象とした商品リストの上位 30 件に対する nDCG の平均値

紳士靴と PC バッグそれぞれに対して、10 件閲覧した時点での平均適合率( $p@10$ ), 20 件閲覧した時点での平均適合率 ( $p@20$ ), 30 件閲覧した時点での平均適合率 ( $p@30$ ) および、分散を表 4.3 に示す。実験結果から、紳士靴に関しては、 $p@10$ ,  $p@20$ ,  $p@30$  すべての場合で、提案手法はベースライン 1 およびベースライン 2 よりも高い値となった。

紳士靴を対象とした実験では、 $p@10$  の場合、適合率が 0.40 (SD=0.09)であり、 $p@20$  の場

合、適合率が 0.39 (SD=0.08)であり、 $p@30$  の場合、適合率が 0.42 (SD=0.08)であった。提案手法とベースラインそれぞれの結果に対して、コルモゴロフ・スミルノフ検定を用いて、それぞれの正規分布に従うかどうかについて検定を行った結果、提案手法やベースラインが 0.05 より大きく、共に正規分布に従うという仮説が採択できた。また、 $p@10$ ,  $p@20$ ,  $p@30$  の場合、t 検定を行ったところ、提案手法がベースライン 1 による結果との間に有意差 ( $p < 0.01$ )、ベースライン 2 による結果 (表 4.4) との間に有意差 ( $p < 0.05$ ) が存在していた。また、バッグを対象とした実験でも、同様に提案手法はどちらのベースラインよりも高い適合率となった。

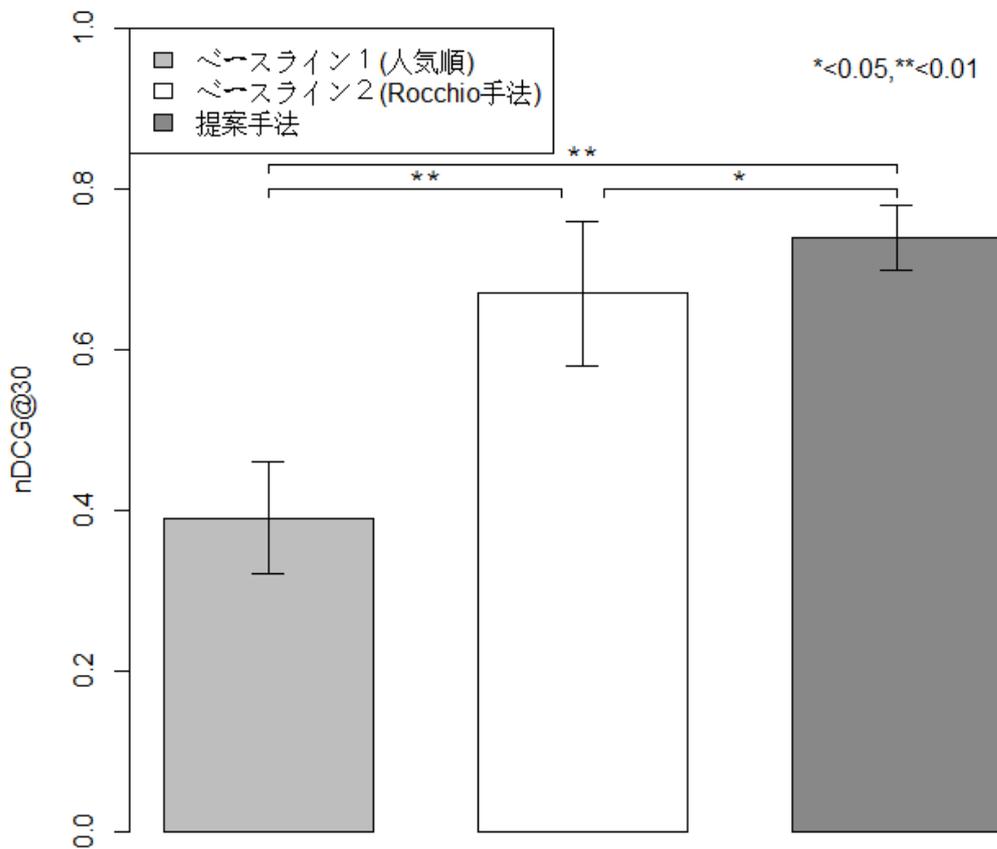


図 4.10. バッグを対象とした商品リストの上位 30 件に対する nDCG の平均値

次に、閲覧した商品の数とその時の適合率の関係を調べた。閲覧した1~30件の適合率の平均値を図4.11、4.12に示す。図4.11に紳士靴に対する結果を表すグラフ、図4.12にバッグに対する結果を表すグラフを示す。提案手法は、ベースライン1およびベースライン2よりも良好な結果をとっていた。提案手法はベースライン1よりも常に高い性能を示していた。提案手法とベースライン2に対して、被験者が閲覧開始後数件は、それほど違いはないが、5件を越えたあたりから常にベースライン2よりも高い性能を示していた。これらの結果から、提案手法は、ベースラインよりも効率的に商品を閲覧できることがわかる。

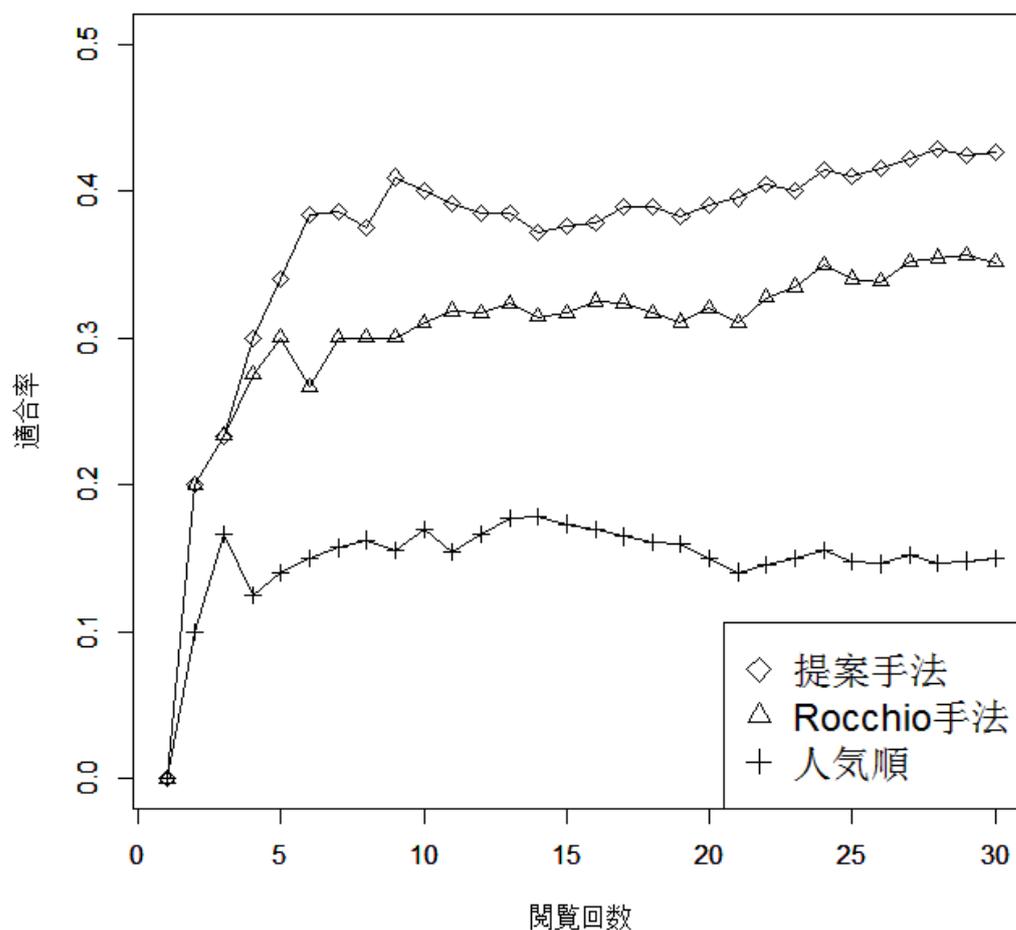


図4.11. 閲覧した商品の数と適合率(紳士靴)

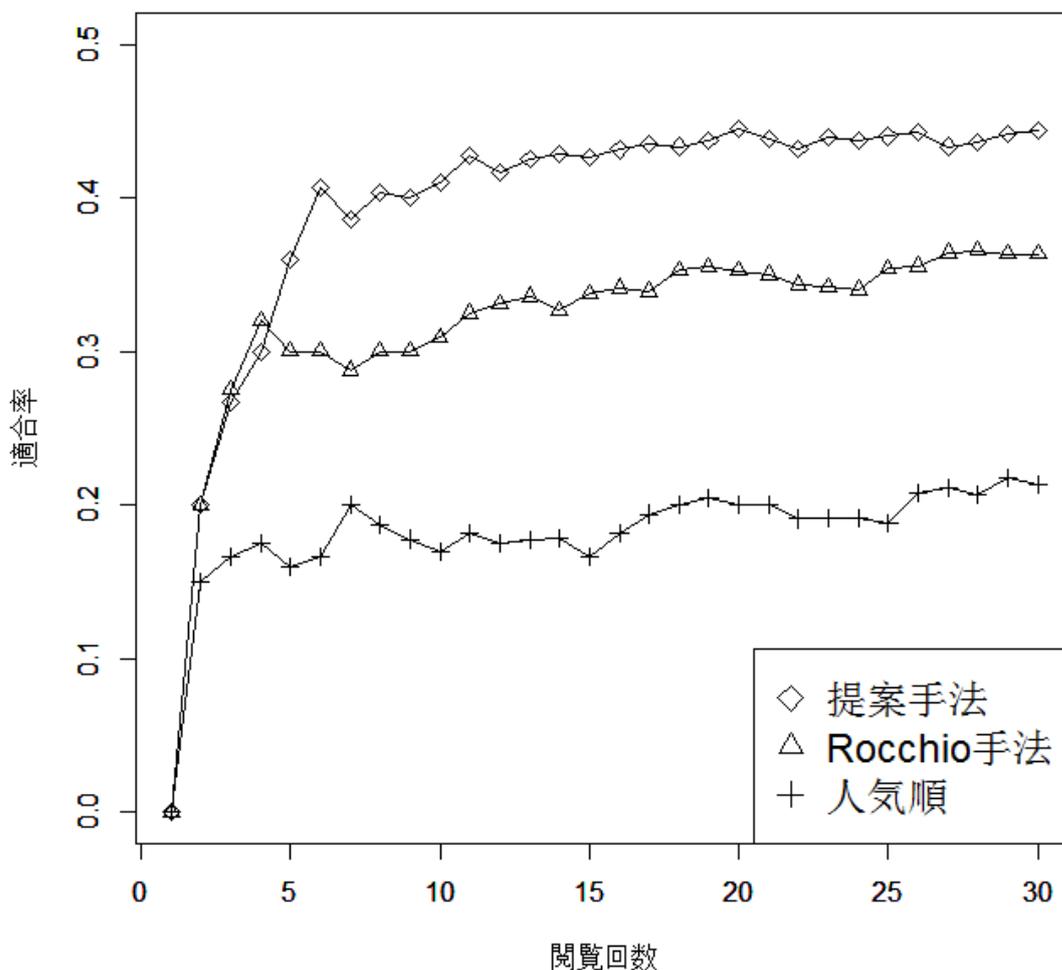


図 4.12. 閲覧した商品の数と適合率(バッグ)

実験後に、被験者に対する主観評価のアンケートを行なった。この結果を図 4.13 に表す。主観評価の平均値は、提案手法が最も高く、次にベースライン 2、ベースライン 1 の順番であった。t 検定を行ったところ、提案手法とベースライン 1 およびベースライン 2 の間には有意差 ( $p < 0.01$ ) が存在することが確認された。この結果から、提案手法が Rocchio 手法や人気順に比べて満足度が高いことが明らかになった。

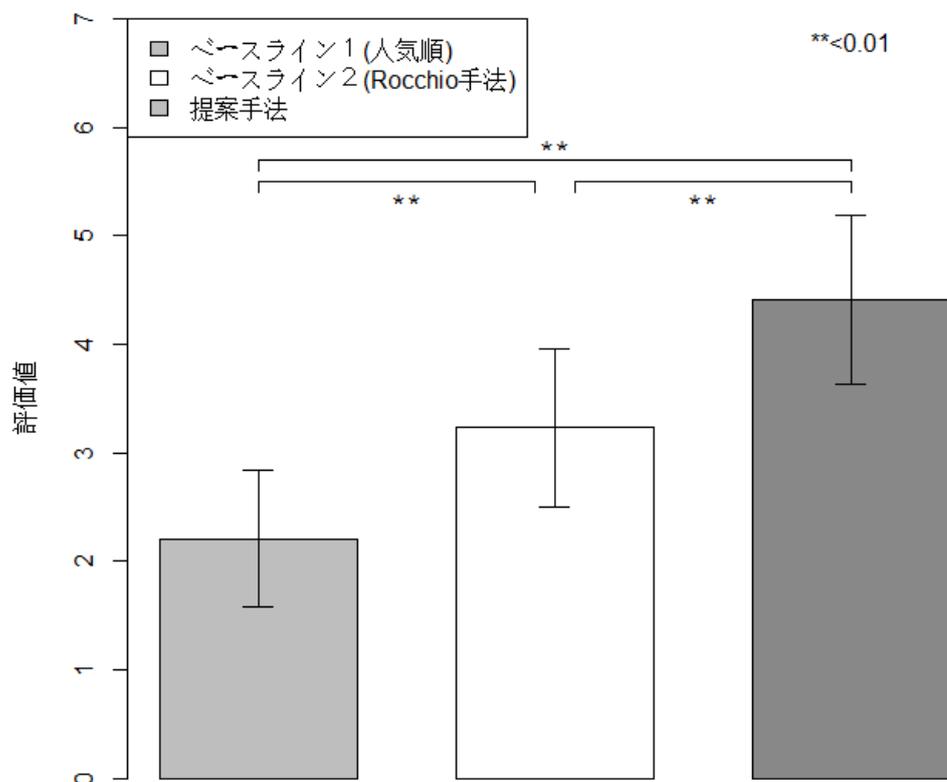


図 4.13. 手法に対する満足度

## 4.6 議論

本論文で提案した最適化手法は、適合フィードバックと同様な考え方である。我々は、ユーザが商品選択の際に、興味を持つ属性の偏りの注目し、提案手法では、頻出特徴パターンを利用して、ユーザの購買意図を適切に推測することを目指した。実験の結果、提案手法が採用したアプローチが効果的であったと考えられる。

実験では、図 4.11 と 4.12 において、実験対象の違いに関わらず、提案システムが同じ

ように有効に働いていることが示されている。被験者に提示する商品情報が異なっても、被験者の振る舞いから、閲覧する商品に対する評価は有効的であることが分かった。

提案手法では、ユーザの購入意図を推定し、購入意図との適合度の度合いによって、商品リスト中の提示順を決定した。この手法では、購入意図が正しく推定できれば、効率的に商品を選別できる可能性がある。しかし、この手法では、提示する商品の網羅性と多様性を低下させる可能性がある。しかし、ユーザにとって興味がある商品が提示されなければ、多様性を導入してもユーザの満足度の向上が見られないことが報告されているため[41]、今回は提示する商品の適合度を向上させることを目標として研究を行った。今後、提示した商品の多様性を考慮して手法の改善する予定である。

ユーザの興味を推測するために、代表的な機械学習手法の一つである SVM アルゴリズムを採用した。実験結果から、ユーザが興味のあるコンテンツを推測することが可能であることを示した。一方、振る舞いに基づいて推定精度を確保するために、教師あり学習モデルを利用したが、ユーザの振る舞いを学習することが必要であり、ユーザに教師データを用意してもらうことは、実用に向けての大きな問題となる。SVM アルゴリズムの他にも、機械学習には様々な教師なし学習手法が存在する。他の手法を採用する可能性について、ユーザによる教師データの提供を必要としない手法の開発を行いたいと考えている。

また、スマートフォンを対象とした場合、本研究では、対象とした閲覧時間とスワイプ速度の他の特徴の利用も検討できる可能性がある。我々は、スマートフォンに搭載される加速度センサーによる加速度データに基づいて、閲覧したコンテンツに対する評価を自動的に推測する手法を検討している。この手法では、閲覧時に生じる加速度の時系列の周波数スペクトルを利用する。

本章では、対象とする商品カテゴリーの特徴ベクトルを構成する特徴は、予め与えられたものとしていた。対象とする商品カテゴリーにおける特徴を人手で決定する場合、その作業コストが大きいため、Amazon のように多くの商品カテゴリーを持つサイトに適用することは現実的でない。しかし、商品の特徴の自動的な抽出に関しては、文献[59]を始めとして近年活発に研究が行われており、それらの成果を利用することで、特徴決定に関するコストを削減でき、多くの商品カテゴリーを持つサイトにも適用できる可能性がある。

本章で提案したユーザが重視する特徴を考慮したフィードバック手法は、機械学習の分野で行われる素性選択と類似した考え方であると考えられる[22]。しかし、素性選択では、相互情報量や情報利得等の特徴量は、素性のフィルタリングに利用するのに対して、本研究では特徴の出現頻度を利用して特徴の重み付けを行っている点が異なる。また、一般的に、相互情報量や情報利得等の確率値は、サンプル数が少ない場合に正確に推定できない可能性がある。これらの特徴量の適用可能性については今後検討していく予定である。

本章では、商品リストの閲覧方式として、断続的スクロールを採用した。断続的スクロールは、適用可能領域は限定的ではあるが、連続的スクロールと比較して、個々の商品情報の閲覧時間を正確に取得できることと、スワイプ速度が商品情報に対する評価を利用できる利点がある。本研究ではこれを利用して、我々が提案する、商品リストを閲覧するだけで、リストの未読部分が最適化される機能を実現し、プロトタイプシステムによって、この機能がユーザにとって有用性があることを示す事ができた。本論文で提案した購買意図推測と、リスト最適化の手法は、断続的スクロールに特化したものではないため、連続的スクロールを用いた対象であっても、閲覧した商品の評価を推定可能な特徴量を設計できれば、適用可能である可能性がある。今後、現在オンラインショッピングサイトで広く利用されている連続的スクロール方式を適用可能とする研究を行う予定である。

ユーザの振る舞いに基づいて評価を推定するという実現するために、制限した条件下でのプロトタイプを設計された。表示手段として連続的なスクロールが主流であるが、断続的なスクロールでは、個々の製品の閲覧時間やスワイプ速度をより正確に取得するという利点を有する。今後、連続的なスクロールを使用し、提案手法の有効性を検証することが、今後の課題として議論を取りたい。

本章では、スマートフォン上でのオンラインショッピングを対象に、研究を行った。今後の研究として、スマートフォンだけではなく、スマートフォン以外の情報機器に対しても適用可能性のある手法を検討していく必要がある。

表 4.3. 振る舞いに基づいたリストの最適の結果

	紳士靴			PCバッグ		
	ベースライン1 (人気順)	ベースライン2 (Rocchio手法)	提案手法	ベースライン1 (人気順)	ベースライン2 (Rocchio手法)	提案手法
適合率						
p@10	0.18(SD=0.11)	0.31(SD=0.12)	0.40(SD=0.09)	0.17(SD=0.13)	0.30(SD=0.11)	0.41(SD=0.11)
p@20	0.15(SD=0.09)	0.32(SD=0.06)	0.39(SD=0.08)	0.20(SD=0.09)	0.36(SD=0.08)	0.44(SD=0.06)
p@30	0.15(SD=0.08)	0.36(SD=0.06)	0.42(SD=0.08)	0.21(SD=0.08)	0.37(SD=0.04)	0.44(SD=0.07)

表 4.4 提案手法と Rocchio 手法の t 検定の結果

	p@10	p@20	p@30
紳士靴	0.045	0.027	0.014
バッグ	0.029	0.011	0.015

## 第5章

# マイクロブログにおける振る舞い協調フィルタリングによるコンテンツの効率的な閲覧手法

### 5.1 マイクロブログ閲覧における閲覧支援

近年、Twitter、Weiboなどを代表とするマイクロブログが普及し、スマートフォン上で日常的にマイクロブログを利用するようになった。マイクロブログでは、ユーザの経験、感想、興味等が含まれている実生活に関する様々な情報が、リアルタイムに配信されている。このような状況を背景に、蓄積された大量のストリームコンテンツの中から、興味があるコンテンツを効果的に発見・利用するための検索・推薦処理が注目されている。従来、莫大なデータ空間から必要な情報を取得するためにGoogleやYahoo!等のキーワード型の検索エンジンを用いて、ユーザにとって興味がある可能性が高いと推定される情報を優先的に提供してきた。しかし、TwitterやWeiboの場合は、ユーザに提供されるコンテンツストリーム（タイムライン）には、ユーザにとって興味があるコンテンツと興味がないコンテンツが混在している。また、コンテンツの主題も様々であり、ユーザにとって未知な情報である。ユーザは、このようなストリームとして提供される大量なコンテンツをすべて目視で確認するのは、ユーザに対する負担が大きい。一般に、ユーザは、ストリームとして配信されるコンテンツのすべての内容を厳密に理解するわけではなく、「飛ばし読み」によって、ユーザにとって重要と思われるコンテンツを見つけ、特定のコンテンツのみ内容をしっかりと確認する。しかし、「飛ばし読み」をした場合、重要なコンテンツを見逃す可能性がある。

これまでに、テキストデータを対象に、自然言語処理技術を用いて、ユーザにとって必要なコンテンツを推定するための研究が行われている。しかし、Twitter や Weibo のコンテンツにも、テキストデータは含まれるが、文字数が制限されているため、効果的な推定が困難であるという問題がある。

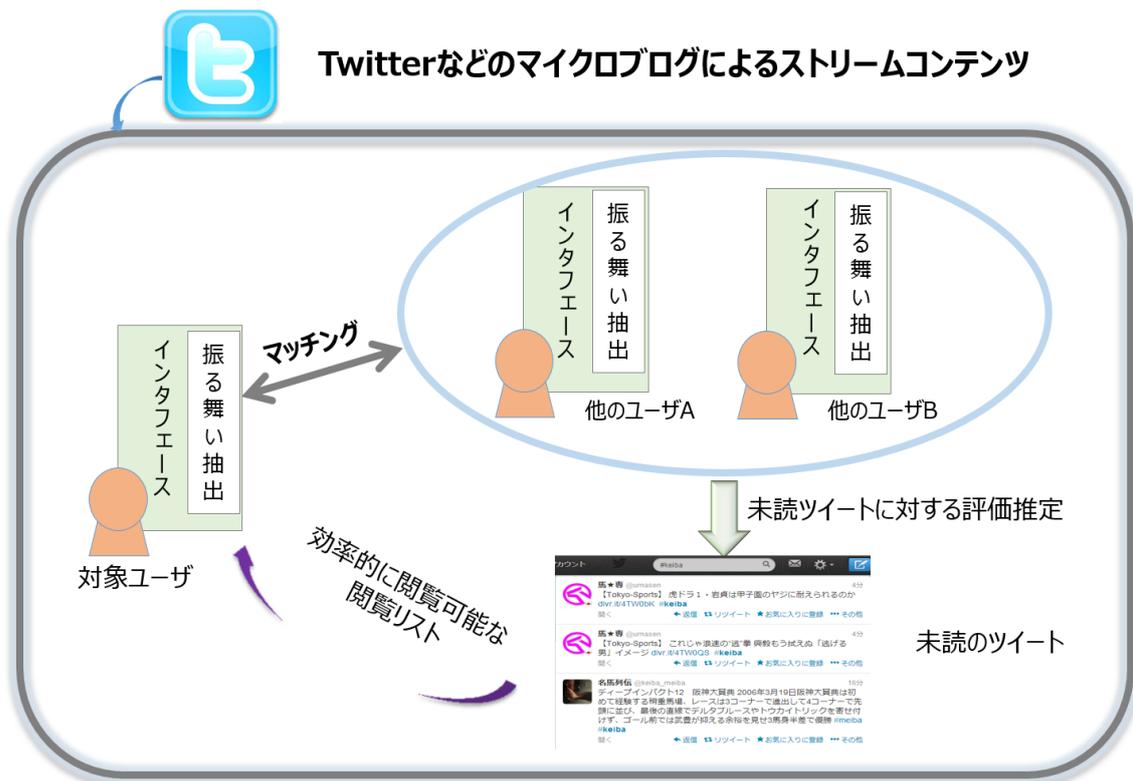


図 5.1. 提案手法のアプローチ

3章で述べたように、スマートフォンで閲覧時の振る舞いを利用して、閲覧したコンテンツに対するユーザの興味の度合い（評価）が推定できる。そこで、本研究では、対象閲覧者に対して、振る舞いの情報によって、情報推薦の典型的な手法である協調フィルタリングの考え方に基づいて、閲覧者間の振る舞いの類似性を用いて、マイクロブログの効率的なブラウジングを実現する手法を提案する。本手法のアプローチを図 5.1 に示す。本手法では、対象ユーザと振る舞いが似ているユーザがコンテンツを読んだ際の振る舞いに基づいて、対象ユーザの未読コンテンツに対する適切な提示順序を推定することにより、効率的な閲覧を実現する。

## 5.2 マイクロブログの効率的な閲覧のためのアプローチ

本研究では、マイクロブログにおいてユーザがスマートフォンを利用する状況を想定し、ユーザが未読のコンテンツを閲覧する際に、タイムラインを適切に処理可能な閲覧手法の実現を目指す。

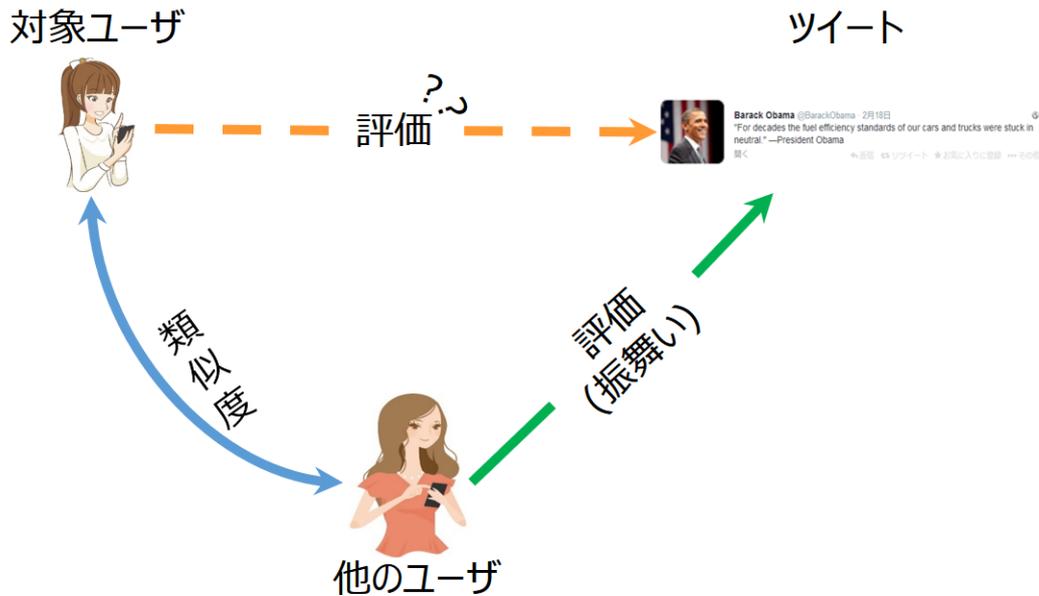


図 5.2. 提案手法のイメージ

提案手法では、マイクロブログにおけるタイムラインの効率的なブラウジングを実現するために、情報推薦の典型的な手法である協調フィルタリングを、閲覧者間の振る舞いに利用する。例えば、図 5.2 のように、対象ユーザの、ある未読コンテンツに対する興味を推定することを考える。このとき、他のユーザがコンテンツに対する振る舞いを観測し、コンテンツに対する相対的な振る舞いが対象ユーザの振る舞いと高い度合いで一致するユーザを探し出す。そこで、他のユーザがその未読コンテンツを閲覧したが、閲覧時の振る舞いに基づいて、対象ユーザが未読であるコンテンツに対する興味の評価を推測する。

## 5.3 他ユーザの振る舞いに基づいたタイムラインの最適化手法

本研究では、対象とする問題は、対象ユーザ $u$ が、読んでいないコンテンツの評価 $V_{uc}$ を推

測する。そのために、まず、対象ユーザが読んでいないコンテンツを閲覧した候補者を集める。さらに、候補者がコンテンツを閲覧時の振る舞いに基づいて、候補者の評価を推定する。そして、候補者と対象ユーザの振る舞いをマッチングすることにより、対象ユーザと他の候補者との類似度を求める。最後に、対象ユーザの未読コンテンツに対する評価を推定する。

### 5.3.1 閲覧時の振る舞いに基づいたツイートに対する評価推定

ユーザの振る舞いに基づいて、ツイートに対する評価を推定するための対象問題は、ユーザ $u$ が、読んでいたツイート $t_i$ の評価値 $V_i$ を推測する。ここで、ツイート集合 $T = \{t_1, t_2, \dots, t_n\}$ に対して、閲覧際の振る舞い $B = \{b_1, b_2, \dots, b_n\}$ と実際のユーザの評価値 $E = \{e_1, e_2, \dots, e_n\}$ を獲得した。ユーザ $u$ は $u = (C_u, B_u, E_u)$ として表現する。なお、振る舞い $b$ は、 $b = (rv, fv)$ として、読み速度とスワイプ速度の組で表現する。

コンテンツに関する振る舞いを利用して、個々のコンテンツの興味の尺度とし、候補者が閲覧したそれぞれのコンテンツの振る舞いとその評価に基づいて推測する。提案手法のツイートの興味の推定精度を確かめるために、高い性能を示している回帰曲線 (fitting curve) を用いる。学習するために、被験者は  $N$  個のコンテンツデータを閲覧し、評価してもらった。ユーザの評価からなる学習データ $(t_1, e_1) \dots, (t_n, e_n)$ とする。学習データ中の $i$ 番目のツイート $t_i$ の特徴ベクトル $\mathbf{b}_i = (rv_i, fv_i)$ で表現される。 $e_i \in (0,1)$ は $t_i$ 番目の学習ツイートに示す値である。

閲覧したツイートの興味を推測するために、振る舞いに対応する評価に基づいて回帰曲線 (fitting curve[63]) を求める。いま、獲得した振る舞いとその対応する評価値 $(\mathbf{b}_i, e_i)$  ( $i = 1, 2, \dots, n$ )があるとする。

このとき、回帰曲線 $P_m$ は以下の式で与えられるものとする。

$$P_m(x) = a_0 + a_1x + \dots + a_mx^m \dots (5.1)$$

次に、関数 $e_r' = fc(rv)$ をフィッティングする。すなわち、以下の関数値が最小値になるような $a_i$ を求める。

$$F(a_0, a_1, \dots, a_m) = \sum_{i=1}^n \sigma^2 = \sum_{i=1}^n [e_i - P_m(rv_i)]^2 \dots (5.2)$$

ここで,

$$\frac{\partial F}{\partial a_j} = 2 \sum_{i=1}^n [e_i - P_m(rv_i)] rv_i^j = 2 \sum_{i=1}^n \left[ e_i - \sum_{k=0}^m a_k rv_i^k \right] rv_i^j = 0 \dots (5.3)$$

であることから, 以下の条件が求まる.

$$\sum_{k=0}^m a_k \left( \sum_{i=1}^n rv_i^{k+j} \right) = \sum_{i=1}^n e_i rv_i^j \dots (5.4)$$

同様に,  $e_f' = fc(fv)$ の近似曲線も求めることができる. この式を利用して候補者が自分の振る舞いから自分に対して総合的に評価 $e'$ を推定する.

$$e' = \alpha \cdot e_r + (1 - \alpha) \cdot e_f \quad \alpha \in [0,1] \dots (5.5)$$

### 5.3.2 候補者の選択

対象ユーザが閲覧したコンテンツに対して, それを読んでいたユーザを集めて候補者とし, その中から対象ユーザにとって適切な候補者を選別する. 選別の際には, 以下の仮説を利用する.

- 対象ユーザと他のユーザが共に閲覧したコンテンツの数が多ければ多いほど, そのユーザは対象ユーザにとって有益である.
- 対象ユーザと他のユーザがどちらか一方しか閲覧していないコンテンツの数が少ないほど有益である.
- 受信されるコンテンツが少ないユーザは, 貢献度が低く, 候補者には相応しくないと考えられる.

上記の考えに基づいて, 対象ユーザ $u$ にとって候補者 $u_k$ の貢献度を以下の式で計算する.

$$\text{Contribution}(u, u_k) = \frac{|C_u \cap C_{u_k}|}{|C_u \cup C_{u_k}|} \dots (5.6)$$

ここで、 $C_u$ と $C_{u_k}$ は、それぞれユーザ $u$ と $u_k$ が閲覧したコンテンツを表す。例えば、図 5.3 を示すように、全て 3 つのツイートに対して、対象ユーザとあるほかのユーザが 1 つのツイートが重なっている。この場合、貢献度は 0.33 となった。

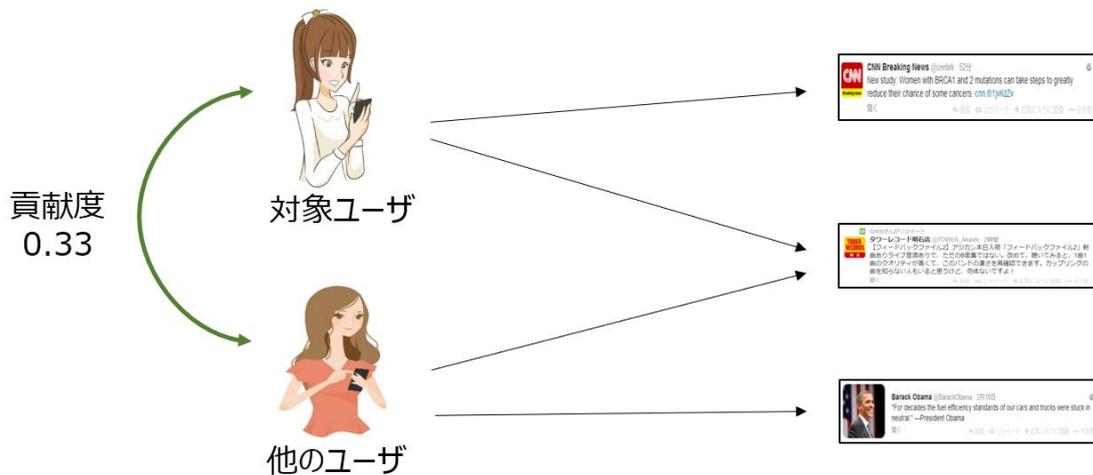


図 5.3. 貢献度の計算例

### 5.3.3 ユーザ間の類似度

コサイン類似度を用いて、対象ユーザと候補者の類似度を計算する。コサイン類似度は、ベクトル空間において、ユーザ同士を比較する際に用いられる類似度計算手法の一つであり、以下の式で定義される。

$$\text{sim}(u, u_k) = \cos\theta = \frac{\vec{u} \cdot \vec{u}_k}{|\vec{u}| \cdot |\vec{u}_k|} \dots (5.7)$$

図 5.4 のように、 $u$ と $u_k$ の類似度を計算し、1 に近ければ類似しており、0 に近ければ似ていないことになる。

### 5.3.4 未読コンテンツの興味の推測

最後に、ユーザ同士の類似度に基づいて対象ユーザに対して未読コンテンツの評価値 $V_{uc}$ を推測する.

$$V_{uc} = \bar{e}_u + \frac{\sum_{k=1}^N \text{sim}(u, u_k) * (e'_{uc} - \bar{e}_{u_k})}{\sum_{k=1}^N (\text{sim}(u, u_k))} \dots (5.8)$$

$\bar{e}_u$ は獲得した対象ユーザのすべての評価の平均,  $\bar{e}_{u_k}$ 獲得した候補者のすべての評価の平均,  $e'_{uc}$ は候補者 $u_k$ の未読コンテンツの評価の推定値である.

## 5.4 評価実験

評価実験として2種類の実験を行った. 第1の実験は, 閲覧時の振る舞いに基づいたコンテンツの評価推定手法の有効性の検証である. 第2の実験は, 振る舞いに基づいた協調フィルタリングによるタイムライン最適化手法の有効性の評価である. それぞれの実験の詳細は以下に述べる.

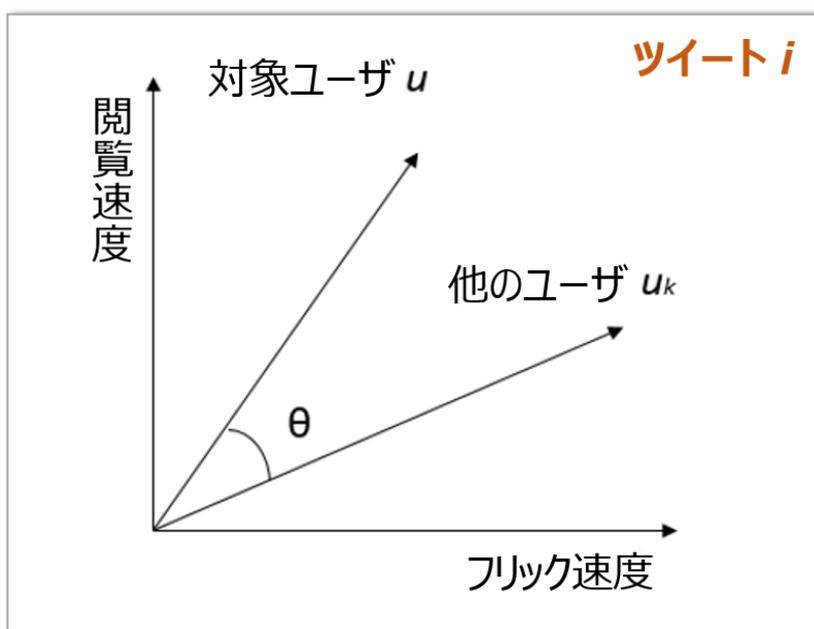


図 5.4. 類似度のイメージ

#### 5.4.1 閲覧時の振る舞いに基づいたコンテンツの評価推定の評価実験

提案手法の有効性を検証するために、提案手法のプロトタイプシステムを実装し、それを用いて評価実験を行った。評価実験の目的は、本論文で提案した振る舞いに基づいた既読ツイートに対する評価推定手法の有効性の検証である。

- 実験手法

今回の実験では、2013年12月23日に配信されたツイートを対象とし、ランダムに選出したTwitter全64件のデータセットおよびWeibo全96件のデータセットを利用する。被験者は、Twitterでは10名日本人学生であり、Weiboでは10名中国人学生である、各被験者が閲覧したツイートの読み速度、スワイプ速度を、コンテンツの特徴ベクトルの要素とする。 $rv, sv, e$ は以下のように正規化する。

$$rv_i = \frac{rv_{oi} - \bar{rv}}{\sigma} \dots (5.9)$$

$$sv_i = \frac{sv_{oi} - \bar{sv}}{\sigma} \dots (5.10)$$

$$e_i = \frac{e_{oi} - \bar{e}}{\sigma} \dots (5.11)$$

ここで、 $rv_{oi}$ は $rv_i$ の正規化前の値であり、 $\bar{rv}$ は平均値を表し、 $\sigma$ は標準偏差を表す。式(5.10)、(5.11)も同様である。

被験者に対して、スマートフォンでデータセットのデータを閲覧してもらい、閲覧後、被験者はツイートに関する評価として、「興味がある」か「興味がない」の2種類の評価を行ってもらった。個々のツイートに対して閲覧時の振る舞いを計測し、読み速度と閲覧後のスワイプ速度と閲覧したツイートの興味の関係性を分析した。さらに、SVMを利用した推定手法を評価するために、実験で得られたデータに対して、*K-Fold Cross Validation*を行い、有効性を分析した。データ解析環境にはおいて、Rを利用し、ガウシアンカーネルを使用したSVM分類器を学習する。

- 実験結果

閲覧したツイートに対するユーザの評価による読み速度の違いを図5.5, 5.6に示す. Twitterにおける日本人被験者は, 興味がない場合の読み速度は, 平均で 0.034 字/ミリ秒であった. 興味があるコンテンツの読み速度は, 平均で 0.02 字/ミリ秒であった. Weibo における中国人被験者は, 興味がない場合には, 平均で 0.029 字/ミリ秒であった. 興味がある場合には, 平均で 0.014 字/ミリ秒であった. また, t 検定を行ったところ,  $p < 0.01$  となり, 有意差が存在することがわかった.

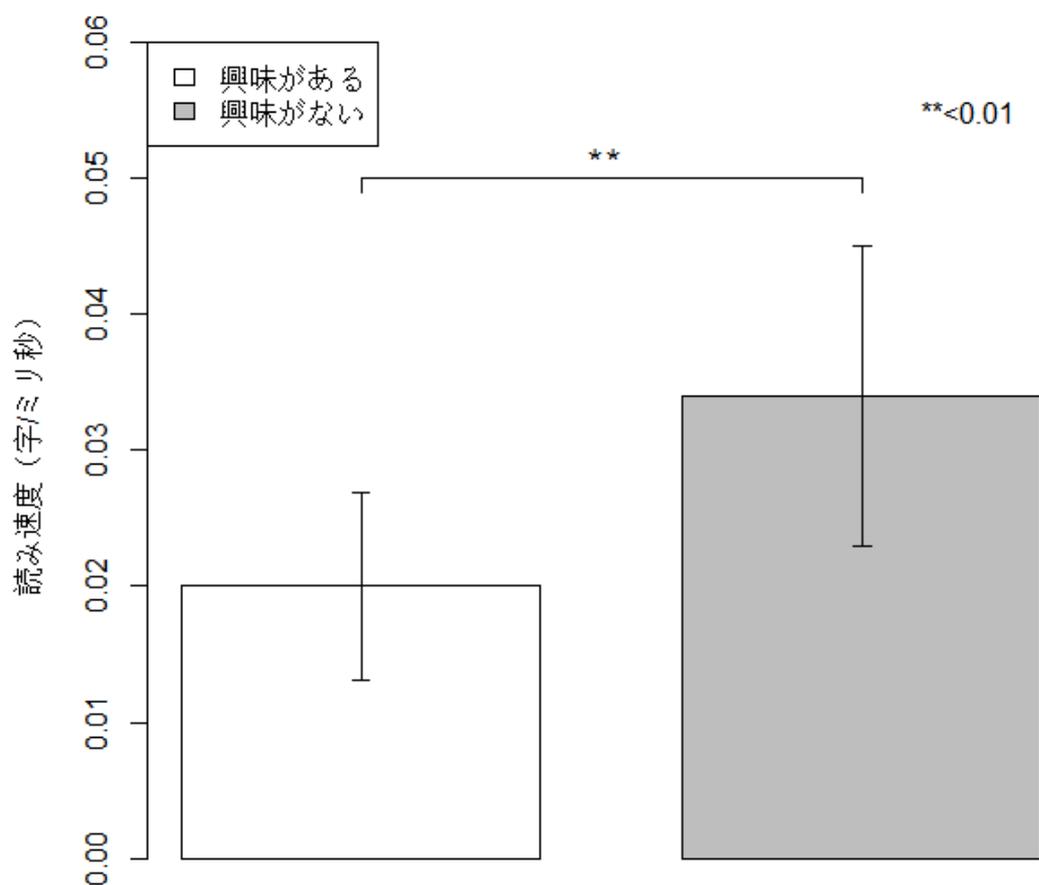


図 5.5. 日本人被験者による読み速度と興味の関係

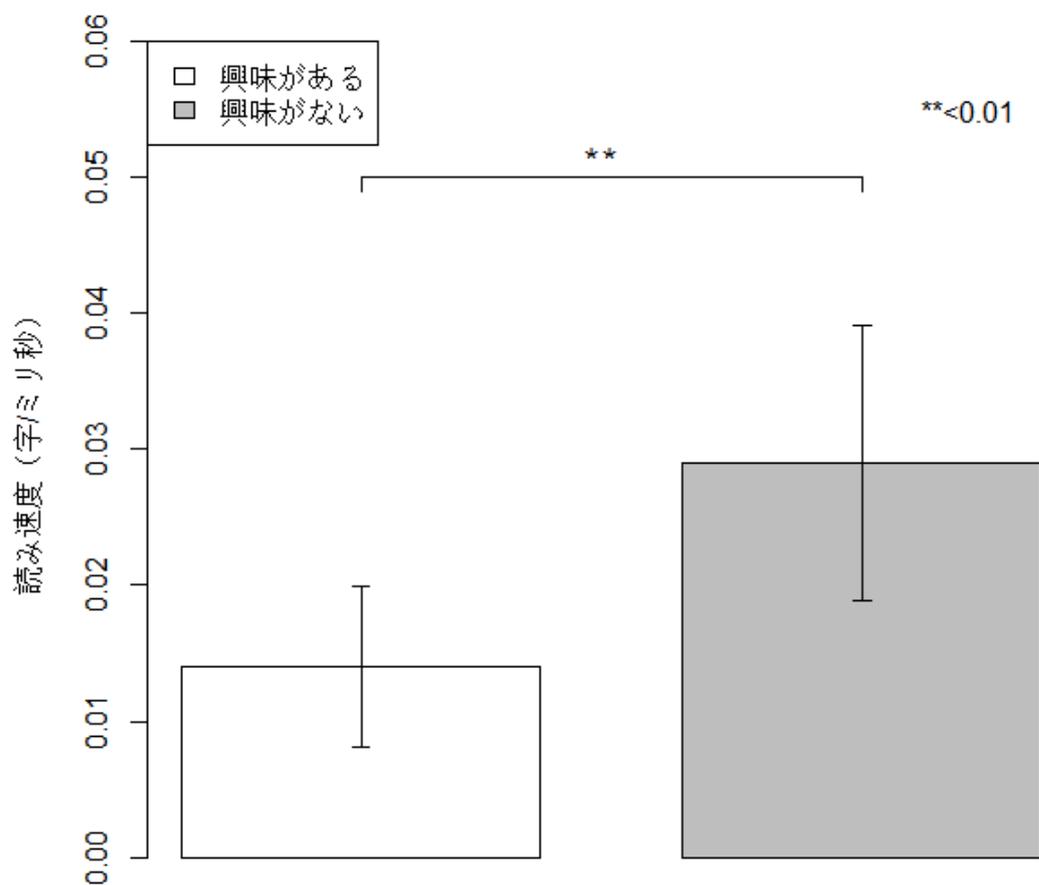


図 5.6. 中国人被験者による読み速度と興味の関係

一方、閲覧したツイートに対するユーザの評価によるスワイプ速度の違いを図 5.7, 5.8 に示す。Twitter における日本人被験者は、興味がない場合には、平均で1.63ピクセル/ミリ秒となる一方で、興味がある場合には、平均で0.78 ピクセル/ミリ秒であった。Weibo における中国人被験者は、興味がない場合には、平均で1.25 ピクセル/ミリ秒となる一方で、興味がある場合には、平均で0.69 ピクセル/ミリ秒となった。t 検定を用いて上記の結果を検定したところ、 $p < 0.01$  となり、有意差が存在することが示された。

上記の結果により、ユーザのツイートに対する評価の違いが、閲覧時の読み速度とスワイプ速度に影響を与えることが明らかになった。

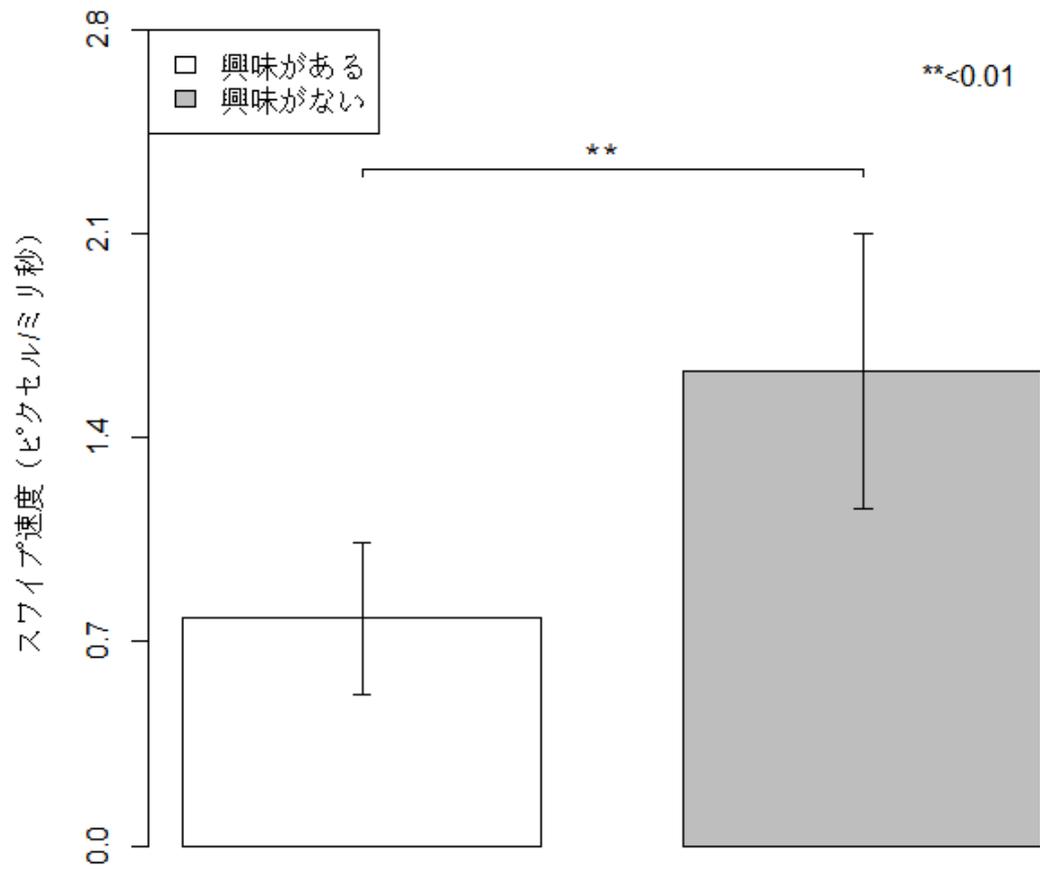


図 5.7. 日本人被験者によるスワイプ速度と興味の関係

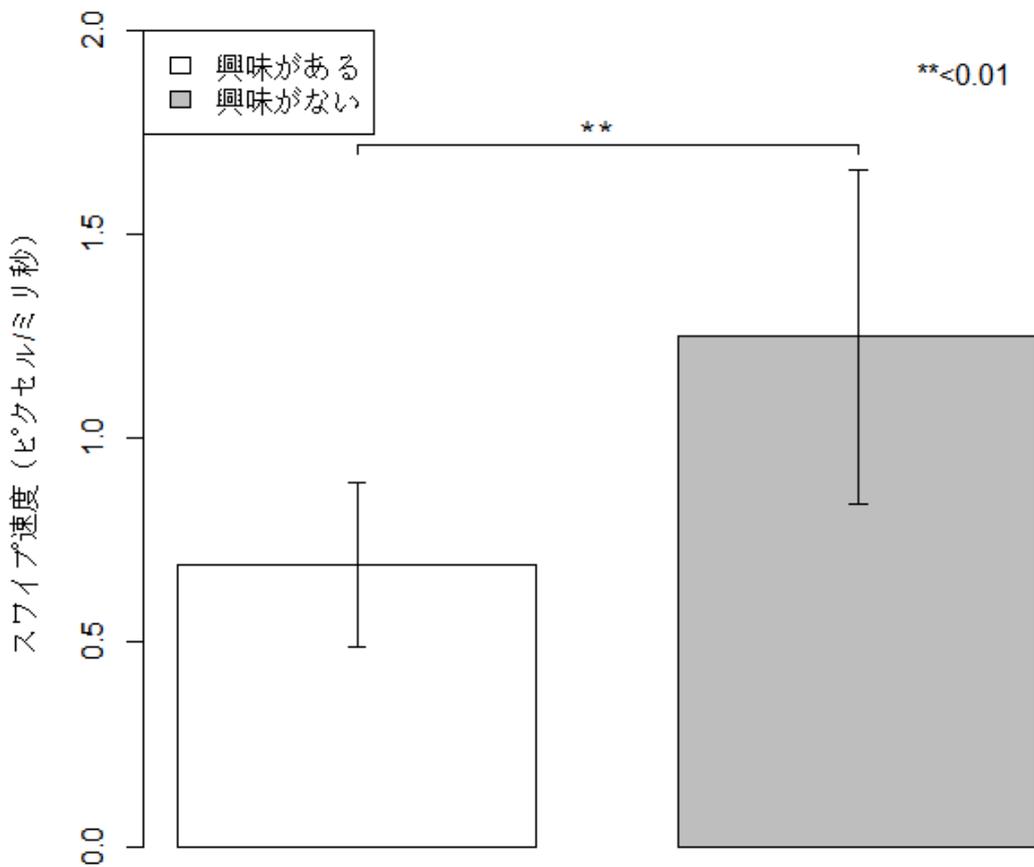


図 5.8. 中国人被験者によるスワイプ速度と興味の関係

したがって、上記の特徴量を利用して、ユーザの評価を推定する性能について評価を行う。すなわち、読み速度とスワイプ速度を特徴量として利用した場合の SVM による分類の性能を評価する。また、客観的な評価のためには *K-Fold Cross Validation* を用いた。K の値は 5 と設定した。本節では、興味があると評価したツイートを正解とする。評価手法として正解率(*Accuracy*)、適合率(*Precision*)、再現率(*Recall*)および F-値(*F-Measure*)を利用する。ここで、TP (True Positive) は興味があるツイートと正しく推定できた数であり、FP (False Positive) はユーザが興味がないと評価したコンテンツを誤って興味があると推定した数である。また、FN (False Negative) はユーザが興味があると評価したコンテンツを誤って興味がない

と判断した数であり、TN(True Negative)はユーザが興味がないと評価したコンテンツを正しく興味がないと判断した数である。

その実験結果は Twitter (表 5.1) と Weibo (表 5.2) に表している。Twitter における日本人被験者は、読み速度のみを利用した結果では、正解率は 0.77 となり、F 値は 0.71 となった。スワイプ速度のみを利用した結果では、正解率は 0.72 となり、F 値は 0.68 となった。読み速度とスワイプ速度を利用した結果では、正解率は 0.79 となり、F 値は 0.75 となった。

表 5.1. Twitter における日本人学生の実験結果

	正解率	適合率	再現率	F-値
読み速度	0.77	0.71	0.72	0.71
スワイプ速度	0.72	0.68	0.69	0.68
読み速度とスワイプ速度	0.79	0.74	0.77	0.75

一方、Weibo における中国人被験者は、読み速度のみを利用した結果では、正解率は 0.76 となり、F 値は 0.72 となった。スワイプ速度のみを利用した結果では、正解率は 0.73 となり、F 値は 0.70 となった。読み速度とスワイプ速度を利用した結果では、正解率は 0.82 となり、F 値は 0.76 となった。

中国語を使っている Weibo や日本語を使っている Twitter において、実験結果によって異なる言語に関わらず、ユーザの振る舞いに基づいて、ツイートの興味を有効的に推測できることが示せた。

表 5.2. Weibo における中国人学生の実験結果

	正解率	適合率	再現率	F-値
読み速度	0.76	0.73	0.71	0.72
スワイプ速度	0.73	0.72	0.68	0.70
読み速度とスワイプ速度	0.82	0.79	0.73	0.76

上述に、個々の振る舞いでは、読み速度は最も効果であるが、スワイプとする振る舞いはスマートフォンで特有な特徴として、ツイートの興味の推定のため、有意であったことも分かった。さらに、読み速度とスワイプ速度のハイブリッド推定方法は、最も有効であった。

• 考察

本節において、タッチディスプレイに対する振る舞いと、ツイートの興味の関連性について検証した結果を示した。検証した結果は以下の傾向が見られた。

- ユーザが高く評価するコンテンツの場合、読み速度が遅くなる傾向がある。逆に、ユーザの評価が低いコンテンツの場合、読み速度が速くなる傾向がある。
- ユーザが高く評価するコンテンツの場合、スワイプ速度が遅くなる傾向がある。逆に、ユーザの評価が低いコンテンツの場合、スワイプ速度が速くなる傾向がある。
- 日本語や中国語において、ユーザや、ユーザが使用した言語に関係が少なく、日本人被験者でも中国人でもコンテンツを閲覧時の振る舞いはコンテンツの評価を反映させると考えられる。他の言語を使っても、同様にユーザの閲覧時の振る舞いに基づいてコンテンツの興味が推測できるのではないかと考えられる。他の言語が適用できるか

どうかを今後の研究として検証したい。

ユーザの閲覧時の振る舞いに基づいて、コンテンツに対する興味の評価を推定する方法は、ユーザへの負担が少ないやり方で、コンテンツの評価推定を効果的に実験できることが示せた。

#### 5.4.2 他者の評価を利用した未読コンテンツの評価推定手法に関する実験

他者の評価を利用した未読コンテンツの評価推定手法の有効性を評価するため、提案手法と TF-IDF[64]法と TF-IDF を用いる協調フィルタリング手法とによる推測の評価ごとの平均絶対誤差 MAE[65]で有効性を検証する。ベースライン1は、ユーザが閲覧したコンテンツに基づいて、TF-IDF のテキスト処理を用いてユーザの嗜好との類似を計算し、未読コンテンツの興味が推定したものである。ベースライン2は、ユーザが閲覧したコンテンツに基づいて、TF-IDF のテキスト処理を用いて、他のユーザとの類似を計算し、未読のストリームコンテンツの興味が推定したものである。提案手法とベースラインの違いを表 5.3 に示す。

表 5.3. 各手法との比較

	Behavior-based推定	Text-based推定	ユーザ間の類似度
ベースライン1		√	
ベースライン2		√	√
<b>提案手法</b>	√		√

なお、ベースラインにおいては、対象ユーザの類似度を以下の式で計算する。

$$sim(u, u_k) = \frac{\sum_{i=1}^n |e_{u_i} - e_{u_{k_i}}|}{n} \dots (5.12)$$

そこで、平均絶対誤差 MAE (Mean Absolute Error) は数値予測問題における推測する質を評価する指標の 1 つである。予測値が実際の評価値から平均的にどの程度乖離しているかを表す。

$$MAE = \frac{\sum_{i=1}^n |e_i - e'_i| \pm \varepsilon}{n} \quad \varepsilon \in [0, 0.1] \dots (5.13)$$

$\epsilon$ は誤差である。実験の参加者は10人であり、各被験者が閲覧するツイートは100個であった。

各手法によるMAEの結果を図5.9に示す。MAEの値が小さいほど有効性が高いと考えられる。実験結果から、提案手法は2つのベースラインよりも効果的に未読コンテンツの評価を推定できることが明らかになった。なお、タイムライン閲覧時の振る舞いの数量が増えるごとに推定の質が高くなった。また、類似度が高い候補者が増えるごとに平均絶対誤差が減少していることがわかる。

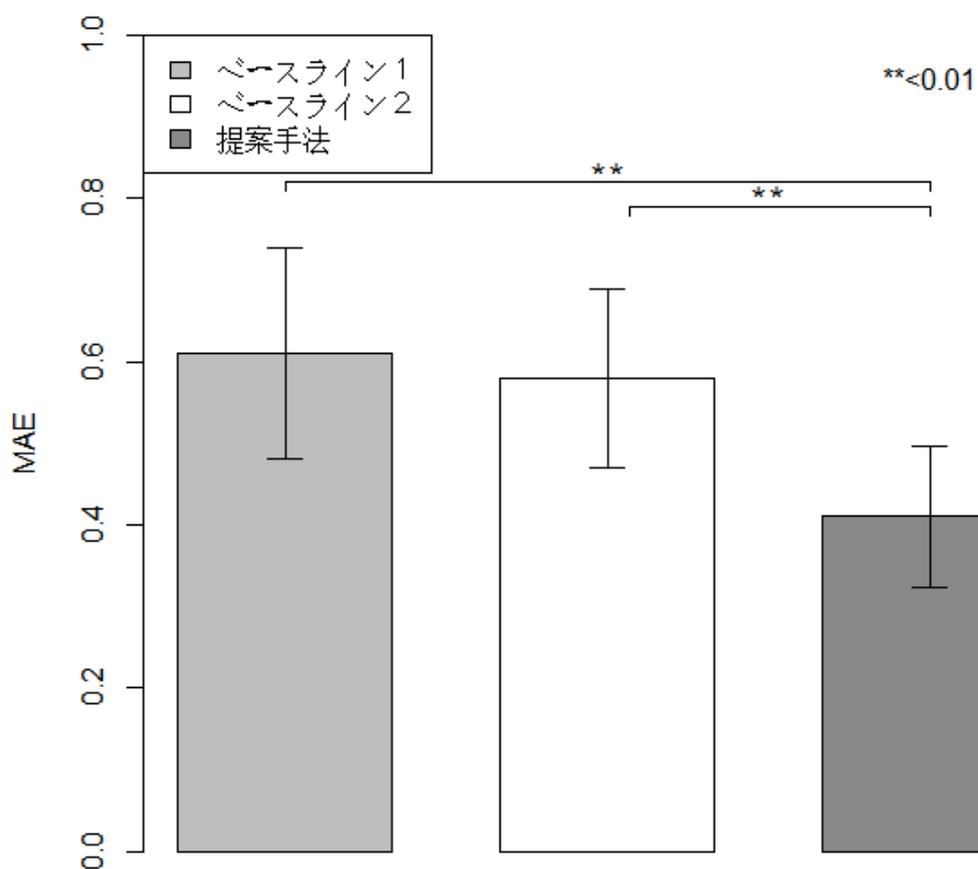


図 5.9. 対抗手法と提案手法の比較

## 第 6 章

# スマートフォン自体の 3 次元加速度に基づいた興味 推定

### 6.1 振る舞いの特徴量として 3 次元加速度を利用する利点

4 章, 5 章では, スマートフォンにおけるコンテンツ閲覧時の振る舞いを利用して, コンテンツの効率的な閲覧を実現する手法を提案し, 有効性を示した. これらにおいては, 振る舞いの特徴量として, 読み速度, フリック速度, 閲覧時間を利用していた. これらの手法を実用化するためには, 現実世界で起こりうる, 様々な状況を考慮しなければならない. 例えば, ユーザがコンテンツを閲覧する途中で, 他の作業を行ってしまうと, 閲覧時間は非常に長くなってしまう可能性がある. そのような場合には, そのコンテンツに対する興味があると判断される可能性が高いが, 現実には興味を持っていなかった可能性もある. そのように, 様々な状況において頑強な最適化を行うために, 様々な特徴量を利用して, それらの特徴量を総合的に利用して推定を行うことが重要である.

一方, 近年, 多くのスマートフォンに加速度センサーが採用され, ユーザの操作によるスマートフォンの自体の運動が計測可能となった. そうしたなかで, スマートフォンにおけるコンテンツ閲覧時の特徴量として 3 次元加速度の情報が利用できる可能性がある. そこで, 本章では, ユーザがコンテンツに対する興味の推定を補充するための特徴量としての, スマートフォンにおける 3 次元の加速度について評価する.

## 6.2 スマートフォンの動き

加速度センサーは、携帯端末、歩数計など多くの機器に組み込まれている。加速度センサーの中には、ある種の振り子が搭載されており、振動によって電圧が生ずる機構を利用し、加速度を計測する。

スマートフォンの3軸加速度は、スマートフォン自体の運動に基づいて上下、左右、前後の6つの方向に発生した加速度を表す。本研究で利用したスマートフォンにおける加速度の3次元の軸は、図6.1のようになっている。

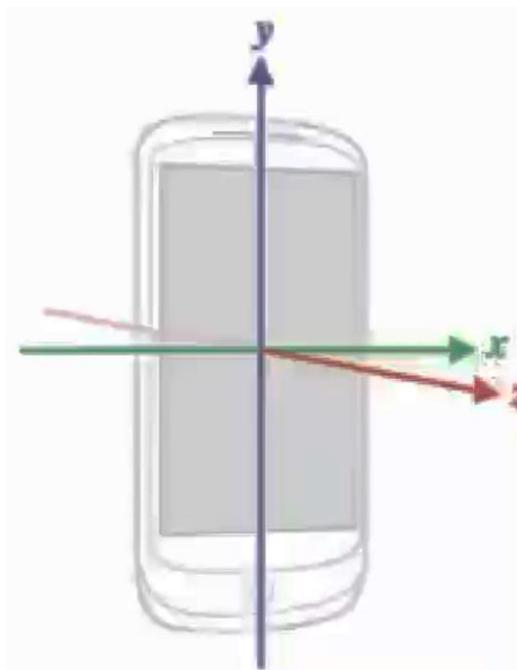


図 6.1. スマートフォンに搭載された加速度センサー

## 6.3 コンテンツ閲覧時の3次元加速度の特徴分析

本節では、ユーザのコンテンツの評価と閲覧時のスマートフォン自体の3次元加速度との関係性の検討を行う。

検討に利用するデータとして、Weiboにおいて2014年5月20日に配信されたツイートをランダムに選択し、94個のツイートを設定した。被験者は、日常的にWeiboを使用する中国人民大学学部生および大学院生3名である。被験者に対して、スマートフォンでデータセッ

トのツイートを読んでもらい、その時の3次元加速度のデータを取得した。更に、閲覧後、被験者は個々のツイートに関する興味を0か1か点数化で評価してもらった。

上記で取得した3次元加速度の時系列を分析する。スマートフォンの3次元加速度の時系列は、ユーザがツイートを閲覧している時に、ユーザがスマートフォンをどのように運動させたかを表す。図6.2のように、評価が低いツイートを閲覧する場合は、3次元加速度による時系列が大幅に振動している。一方、図6.3のように、評価が高いツイートを閲覧する場合は、3次元加速度による時系列が小幅な振動の結果を示している。

同一周期のデータの特徴を解析するために、フーリエ変換を適用した。図6.4, 6.5はそれぞれ図6.2, 6.3の加速度の時系列データをフーリエ変換に適用した結果である。実験結果は、図6.4のように、興味がないツイートに対しては、周波数成分の分布が大きくなる傾向が観測された。一方、図6.5のように、興味があるツイートでは、周波数成分の分布が周低周波成分の領域に集中している。

上記の分析から、閲覧時の振る舞いによるスマートフォン自体の3次元加速度とコンテンツの興味に関連性があると考えられる。ユーザにとって興味がある可能性が低いコンテンツに対しては、3次元加速度からのフーリエ変換の周波数成分の分布が分散していると考えられる。

### 6.4 3次元加速度データを利用したコンテンツ推定手法

スマートフォンにおけるコンテンツ閲覧時の3次元加速度データを利用して、ユーザの閲覧したコンテンツの評価を推定する手法について述べる。

本手法では、ユーザがスマートフォン上で閲覧したそれぞれのコンテンツに対して、そのコンテンツを閲覧中の3次元加速度の時系列から周波数スペクトルを求め、特徴ベクトルとして表現する。なお、処理コストを削減するために、すべての周波数スペクトルを利用するのではなく、各軸の低周波成分のみを利用する。閲覧した商品に対し興味を推定するために、代表的な教師あり機械学習手法であるSVMを用いて、特徴ベクトルを分類して評価を推定する。なお、SVMのカーネルはガウシアンカーネルを利用する。

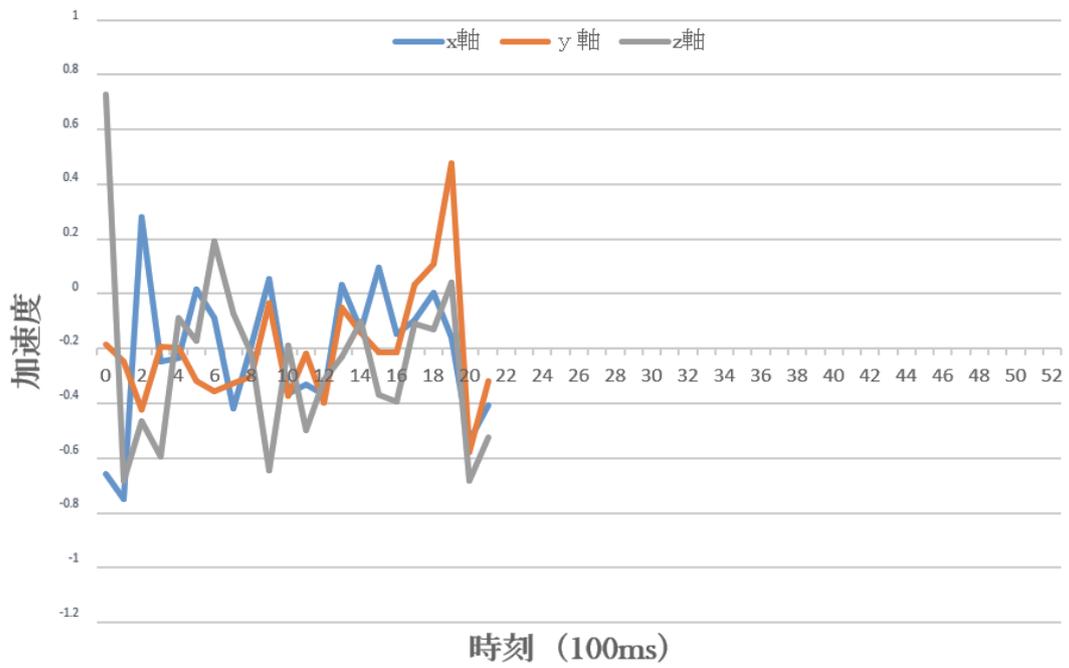


図 6.2. 興味がないツイートに対する 3次元加速度の変化

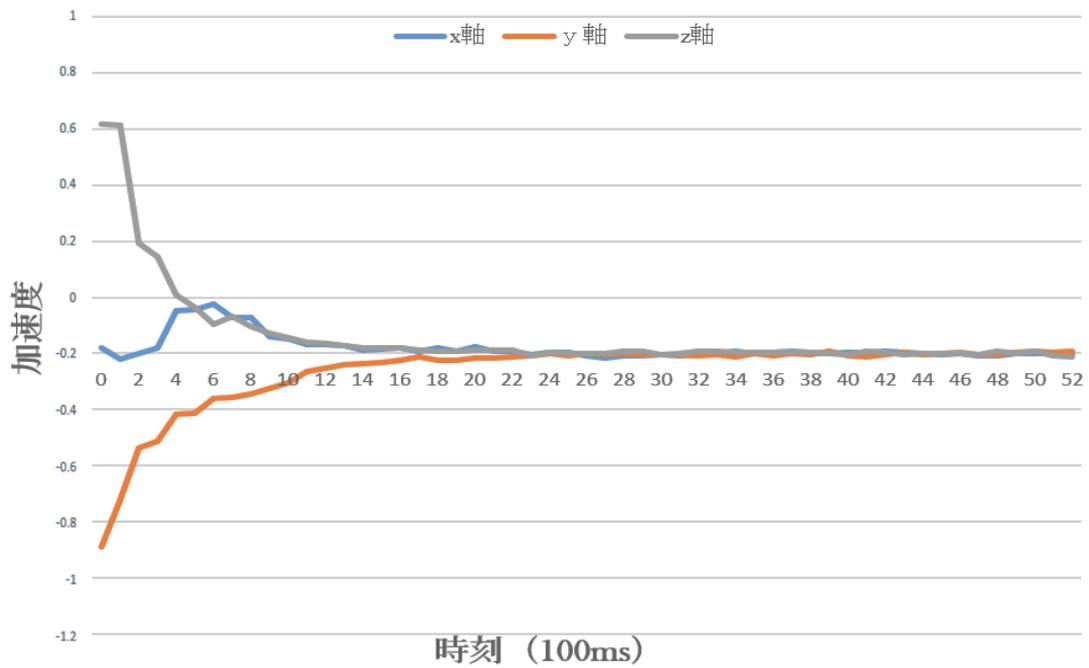


図 6.3. 興味があるツイートに対する 3次元加速度の変化

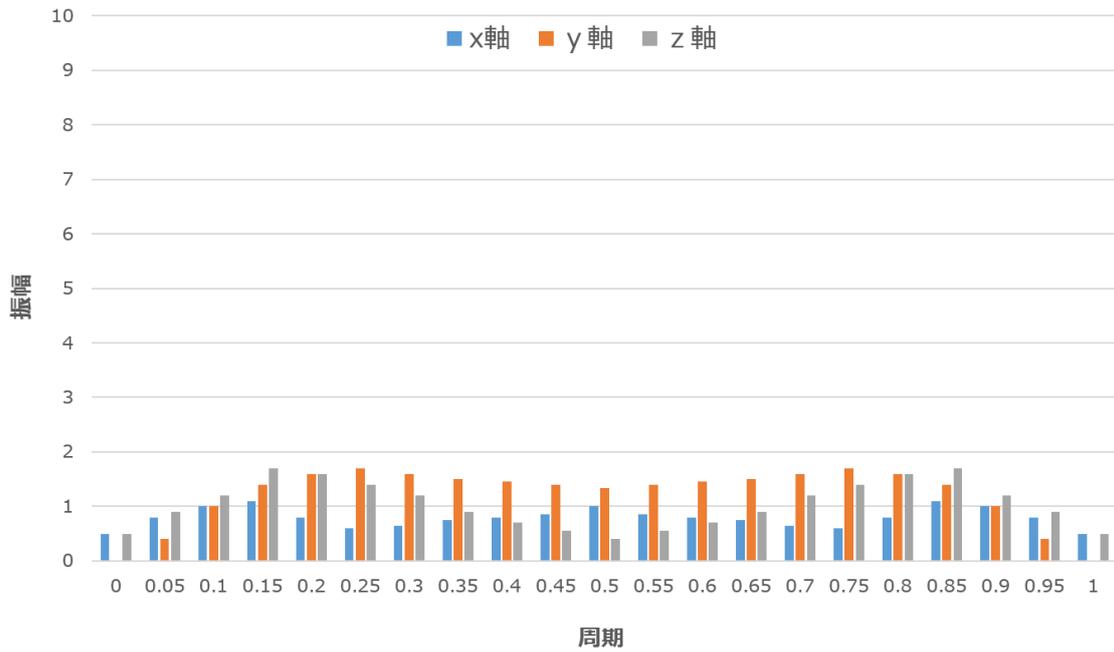


図 6.4. フーリエ変換によって得られた周波数成分（興味がないツイート）

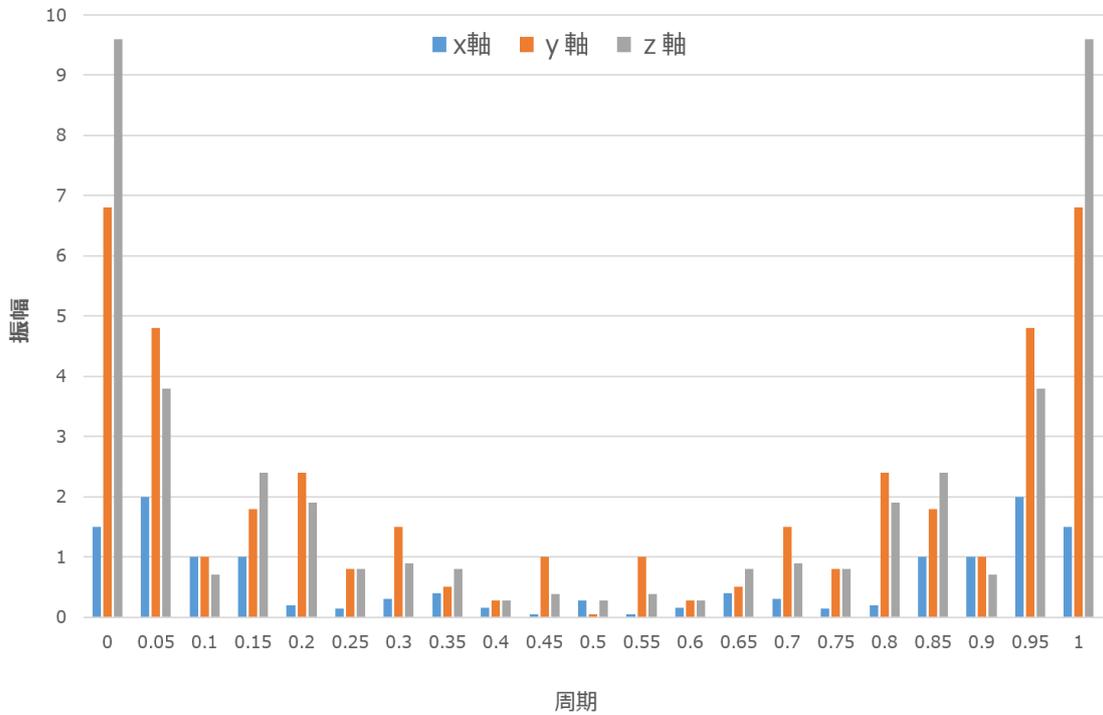


図 6.5. フーリエ変換によって得られた周波数成分（興味があるツイート）

## 6.5 評価実験

### 6.5.1 実験手法

前節で提案した手法の有効性を評価するために評価実験を行なった。対象とするデータセットとしては、2014年7月4日に Weibo 上で配信されたツイートの中からランダムに選出した 100 件のデータを利用する。被験者は中国人 15 名であり、各被験者が閲覧するコンテンツの評価と振る舞いに基づいて有効性を検証した。評価手法として正解率(Accuracy)、適合率(Precision)、再現率(Recall)および F 値(F Measure)を利用する。なお、3次元加速度データは単出で利用されるのではなく、読み速度、スワイプ速度等の特徴量と組み合わせて利用されることが多いため、「加速度データのみ」、「読み速度、スワイプ速度」、「読み速度、加速度」、「読み速度、加速度」、「読み速度、スワイプ速度、加速度」という様々な組み合わせの特徴量を用いた場合と比較する。

表 6.1. 結果

	正解率	適合率	再現率	F-値
加速度	0.71	0.7	0.66	0.68
読み速度、スワイプ速度	<b>0.80</b>	<b>0.79</b>	0.75	<b>0.77</b>
読み速度、加速度	0.75	0.72	0.73	0.72
読み速度、スワイプ速度、加速度	0.77	0.74	<b>0.77</b>	0.75

### 6.5.2 実験結果

実験結果を、表 6.1 に示す。閲覧時のスマートフォンの 3次元加速度データに基づいて、正解率は 0.71 となり、F 値は 0.68 となった。これにより、3次元加速度データはツイートの興味の推定に利用できることが示せた。

他の特徴量との比較を行った場合、今回の実験では、最も効果的な推定方式は読み速度とスワイプ速度の組み合わせであり、加速度データ単体や、加速度データを複合的に組み合わせてもそれよりも良い性能とはならなかった。しかし、加速度データを融合させることで、再現率が最も高くなっており、加速度データを利用することの可能性が示唆された。今後、さらに多様な状況において実験を行い、加速度データの利用の可能性について検討していく必要があると考えられる。

## 第 7 章

### 結論

近年，Web が巨大な情報空間となり，Web 上の検索や推薦によってユーザに与えられた結果に多くのコンテンツが含まれることとなり，それらを効率的に閲覧することが困難になっている．特に，近年，爆発的に普及したスマートフォンは，小さな画面で表示できる情報が少なく，操作は PC ほど快適でないため，ユーザにとって興味があるコンテンツが埋もれてしまう可能性がある．この問題を解決するため，ユーザに与えられる検索結果の効率的に閲覧するための手法が重要になっている．本論文では，図 7.1 を示すように，スマートフォンを対象とした効率的なコンテンツの閲覧を実現するために，主に以下の 2 つの手法を提案した

1. 閲覧時の振る舞いを利用してユーザが閲覧したコンテンツに対する評価を推定する手法
2. 推定された評価に基づいてユーザに与えられるコンテンツの効率的な提示方法を最適化する手法

本論文で提案した，閲覧時の振る舞いを利用してユーザが閲覧したコンテンツに対する評価を推定する手法では，コンテンツ閲覧時の読み速度，スワイプ速度，閲覧時間を利用し，被験者実験により，有効性が示された．また，今後のより正確な行うために利用できる可能性がある特徴としてスマートフォンに搭載される 3 次元加速度センサーによる加速度データの可能性について実験により評価した．

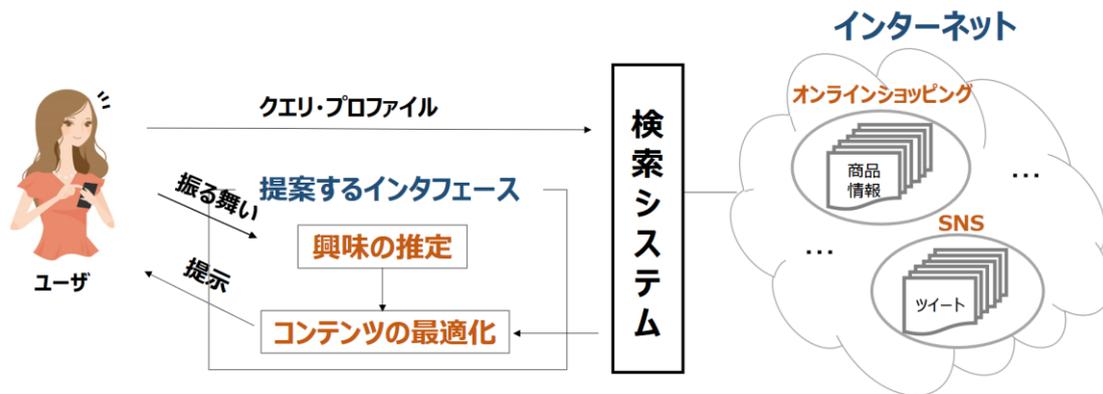


図 7.1. コンテンツ閲覧の支援手法

表 7.1. 提案手法と他の手法との比較

手法	アプローチ	対象	推定対象	環境
松尾ら[11]	アクセス履歴	Webページ	長期的な嗜好	PC
土岐ら[13]	表示時間	SNS	長期的な嗜好	PC
Foxら[9]	マウスの動き	Webページ	短期的な満足度	PC
Lagunら[15]	視線&表示領域	Webページ	短期的な満足度	smartphone
提案手法	閲覧時間&スワイプ速度	商品&マイクロログ	短期的な閲覧意図	smartphone

ユーザのプロファイルを構成するデータの取得への対応として、ユーザが手動で明示的に評価することの多いインタフェースを回避して、ユーザの閲覧時の振る舞いという暗黙的なフィードバックに基づいた手法を実現した。この手法ではユーザが明示的に評価する必要がなく、負担を減少できるという利点が存在する。これまでに提案されている暗黙的フィードバックと提案手法との比較を表 7.1 に表す。この表では、基本的なアプローチ、対象

とするオブジェクト, 推定する対象, 想定する環境を示している. この表から明らかなように, スマートフォン上で短期的な属性を推定するのは Lgun らの手法[30]と提案手法のみである. Lagun らの手法で利用している視線情報は, 計測に特別なデバイスが必要となり実用的でない. また, Lagun らの手法で利用されている表示領域の変化は, 本研究で対象としているように, 1つのコンテンツが一画面内で表示される状況では利用できない. したがって, 本研究で対象としているような, スマートフォンの 1 画面で表示可能なコンテンツを利用してスマートフォン上で短期的な閲覧意図を推定することは, 従来手法では困難であると考えられる. それに対して, 提案した手法は評価実験で有効的であることが明らかになった.

上記を踏まえて, スマートフォン上でのコンテンツを閲覧時の振る舞いに基づく最適化に基づくコンテンツ閲覧の支援手法を提案した. 本研究では, 自己最適化と協調的最適化の 2 種類の手法の提案を行った.

自己最適化に関しては, オンラインショッピングを利用する際, ユーザが興味を持たない商品も含む大量の商品から構成される商品リストがあるため, ユーザがスマートフォン上で効率的な商品選別を支援する目的で, スマートフォン上で閲覧する際の購買意図の推定に基づいて, 商品リストの未読部分を動的に最適化する手法を開発した. この手法では, 商品リストの最適化を実現するために, ユーザの閲覧時の振る舞いに基づいて推定されたユーザの評価を利用して, ユーザのプロファイルを構築する. そして, ユーザが商品選択の際に, 興味を持つ属性の偏りに注目し, 頻出特徴パターンを利用して, 構築されたプロファイルからユーザの購買意図を推定し, 推定された購買意図に基づいて, 商品リストの未読部分においてユーザの興味がある可能性が高い商品を優先的に提示する. この手法は一般的な推薦手法より, 単になる過去の構築したユーザのプロファイルを用いてユーザにとって必要なコンテンツを提示することではなく, その場で閲覧した商品に対する評価を, リアルタイムに取得したユーザの振る舞いを用いて推定することによって, ユーザの意図に応える推薦に適したコンテンツを適切に提示できる.

協調的最適化に関しては, Twitter, Weibo 等を代表とするマイクロブログを代表例として, ユーザにとって興味がある可能性が高いコンテンツを優先的に提示することにより, 選別する時間を節約し, 効率的な閲覧を実現する手法を提案した. この手法では, 対象ユーザと振る舞いが似ているユーザが, コンテンツを読んだ際の振る舞いに基づいて, ユーザの振る

舞いに基づいてコンテンツに対する興味の度合いを自動的に測定し、対象ユーザの未読コンテンツに対する適切な提示推定を推定することにより、効率的な閲覧を実現する。

本研究では、コンテンツリストの閲覧方式として、断続的スクロールを採用した。断続的スクロールは、適用可能領域は限定的ではあるが、連続的スクロールと比較して、個々のコンテンツ情報の閲覧時間を正確に取得できることと、スワイプ速度がコンテンツ情報に対する評価を利用できる利点がある。本研究ではこれを利用して、我々が提案する、コンテンツリストを閲覧するだけで、リストの未読部分が最適化される機能を実現し、プロトタイプシステムによって、この機能がユーザにとって有用性があることを示す事ができた。本論文で提案した評価推定と最適化の手法は、断続的スクロールに特化したものではないため、連続的スクロールを用いた対象であっても、閲覧したコンテンツの評価を推定可能な特徴量を設計できれば、適用可能である可能性がある。今後、広く利用されている連続的スクロール方式を適用可能とする研究を行う予定である。

本研究では、スマートフォン上で閲覧時の振る舞いとして、スワイプ速度、閲覧時間、読み速度、3次元化速度を対象とした。しかし、それらの他にも、ユーザの視線や画面をタップする指の圧力等の様々な振る舞いが考えられる。今後、それらの特徴量を利用してより高精度な評価推定を実現する手法を開発していく予定である。

本論文では、スマートフォンにおけるユーザの閲覧時間やスワイプ速度に基づいて、コンテンツ閲覧を支援する手法を提案したが、他の環境では、異なる振る舞いが利用できると考えられる。例えば、スマートウォッチ等に代表されるウェアラブルデバイスを対象に、それぞれの端末に対する特有な振る舞いを活用した評価推定とコンテンツの最適化手法を開発していきたいと考えている。

## 謝辞

本論文は、筆者が九州大学博士課程後期課程に在籍中の研究成果をまとめたものであります。

本研究を進めるにあたって、本学の牛尼剛聡准教授からは研究の遂行に関して終始ご指導を頂きました。ここに心より御礼を申し上げます。同時に、本論文をまとめるにあたって、ご多忙の中、多くの適切な助言と注意深いご検討を頂いた本学の富松潔教授、鶴野玲治准教授に対して深く感謝致します。

博士課程在学中、日々熱心にご討議を頂いた牛尼研究室の皆様には深く感謝申し上げます。貴重なご意見を頂いた関西学院大学総合政策学部 角谷和俊教授に深甚の謝意を表します。

また、ご指導を頂いた恩師である渡邊豊英先生に、心から感謝します。ご協力を頂いた関西大学システム理工学部 小尻智子准教授、大阪府立大学現代システム科学域 林佑樹助教、富士通株式会社 小柳佑介さんに心より御礼を申し上げます。

最後に、私を支え続けてくれた両親、いつも応援してくれた素晴らしい妻に、心より感謝します。

## 参考資料

- [1] C. D. Manning, P. Raghavan, H. Schütze: Introduction to Information Retrieval, Cambridge University Press, New York(2008).
- [2] Stefan Büttcher, Charles L. A. Clarke, and Gordon V. Cormack. Information Retrieval: Implementing and Evaluating Search Engines. MIT Press, (2010).
- [3] P. Resnick and H. R. Varian: Recommender Systems, Communication of the ACM, Vol.40, No.3, pp.56-58(1997).
- [4] D. R. Liu, and Y. Y. Shih: Hybrid Approaches to Product Recommendation based on Customer Lifetime Value and Purchase Preferences, Journal of Systems and Software, Vol.77, No.2, pp.181-191(2005).
- [5] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl: Item-Based Collaborative Filtering Recommendation Algorithms, Proceedings of the 10th International Conference on World Wide Web, pp.285-295(2001).
- [6] M. A. Hearst: Search User Interfaces, Cambridge University Press(2009).
- [7] 総務省情報通信白書平成 27 年版,  
  
<http://www.soumu.go.jp>
- [8] 杉本雅則：情報収集システムにおけるユーザモデリングと適応的インタラクション, 人工知能学会誌, Vol.14, No. 1, pp. 25-32 (1999).
- [9] S. Fox et al. Evaluating Implicit Measures to Improve Web Search, ACM Transactions on Information Systems, Vol.23, No.2, pp.147-168(2005).
- [10] 土方嘉徳: 情報推薦・情報フィルタリングのためのユーザプロファイリング技術, 人工知能学会論文誌, Vol.19, No.3, pp. 365-372(2004).
- [11] 松尾豊, 福田隼人, 石塚満: ユーザ個人の閲覧履歴からのキーワード抽出によるブラウジング支援, 人工知能学会論文誌, Vol.18, No.4E, pp.203-211(2003).
- [12] M. Morita and Y. Shinoda: Information filtering based on user behavior analysis and best match text retrieval, Proceedings of Research and development in information retrieval, pp.272-281(1994).
- [13] 土岐真里奈, 牛尼剛聡: ソーシャルストリーム閲覧時の振る舞いを利用したユーザプロフィール構成手法, 情報処理学会論文誌データベース, Vol.6, No.4, pp.35-45(2013).
- [14] Q. Guo and E. Agichtein: Beyond dwell time: estimating document relevance from cursor movements and other post-click searcher behavior, Proceedings of World Wide Web, pp.569-578(2012).

- [15]D. Lagun, C. Hsieh, D. Webster and V. Navalpakkam: Towards Better Measurement of Attention and Satisfaction in Mobile Search, Proceedings of the 37th international ACM SIGIR conference on Research & development in information retrieval, pp.113-122(2014).
- [16]S. Amini, Y. Li: Crowd Learner: Rapidly Creating Mobile Recognizers Using Crowdsourcing, Proceedings of the 26th annual ACM symposium on User interface software and technology, pp.163-172(2013).
- [17]Q. Xu, J. Erman, A. Gerber, Z. Mao, J. Pang, and S. Venkataraman: Identifying Diverse Usage Behaviors of Smartphone Apps, Proceedings of ACM SIGCOMM conference on Internet Measurement Conference, pp.329-344(2011).
- [18]H. Lee, Y. S. Choi, S. Lee, and E. Shim, "Smart pose: mobile posture-aware system for lowering physical health risk of smartphone users," Proceedings of CHI '13 Extended Abstracts on Human Factors in Computing Systems, 2013:2257-2266.
- [19]H. Yan and T. Ushiyama: Effective browsing technique based on behavioral collaborative filtering on social streams, Procedia Computer Science, Vol.35, pp.1702-1710(2014).
- [20]H. Yan and T. Ushiyama: A Study on Estimation of Preference on A Product Based on User Behaviors on Smartphone, Proceedings of International Conference of Asia Digital Art and Design Association, B-144(2014).
- [21]H. Yan and T. Ushiyama: Analysis of Relationships between Browsing Behaviors and Interests on Social Streams, IEICE Technical Report, Vol.114, No.101, pp.49-54(2014).
- [22]高村大也著:言語処理のための機械学習入門, コロナ社, 2010.
- [23]L. H. Ungar, and D. P. Foster, "Clustering Methods for Collaborative Filtering," Workshop on Recommender Systems at the 15th National Conference on Artificial Intelligence,1998 : 112-125.
- [24]M. Connor, and J. Herlocker, "Clustering Items for Collaborative Filtering," Proceedings of SIGIR 2001 Workshop on Recommender System,2001.
- [25]A. Singhal, "Modern Information Retrieval: A Brief Overview," Bulletin of the IEEE Computer Society Technical Committee on Data Engineering 24 (4): 35-43.
- [26]X. Tian, L. Yang, J. Wang, Y. Yang, X. Wu and X.S. Hua: Bayesian Video Search Reranking, Proceedings of ACM International Conference Multimedia, pp.131-140(2008).

- [27]W. H. Hsu, L. S. Kennedy and S.F. Chang: Video Search Reranking through Random Walk over Document-Level Context Graph, Proceedings of ACM International Conference Multimedia, pp.971-980(2007).
- [28]T. Hofmann, B. Scholkopf, A. J. Smola: Kernel Methods in Machine Learning, Annals of Statistics, Vol.36, No.3, pp.1171-1220(2008).
- [29]S. Gao, X. Cheng, H. Wang and L.T. Chia: Concept model-based unsupervised web image re-ranking, Proceedings of IEEE International Conference Image Processing, pp.793-796(2009).
- [30]Y. Liu, T. Mei, M. Wang, X. Wu and X. S. Hua: Typicality-based Visual Search Reranking, IEEE Transactions on Circuits and Systems for Video Technology, Vol.20, No. 5, pp.749-755(2010).
- [31]J. J. Rocchio: Relevance Feedback in Information Retrieval, The SMART Retrieval System: Experiments in Automated Document Processing, pp:313–323, Prentice-Hall, Inc. Upper Saddle River, NJ, USA(1971).
- [32]X. Tian, D. Tao, X. S. Hua and X. Wu: Active Reranking for Web Image Search, IEEE Transactions on Image Processing archive, Vol.19, No.3, pp.805-820(2010).
- [33]F. Jing, M. Li, H.J. Zhang and B. Zhang: An efficient and effective region-based image retrieval framework, IEEE Trans on Image Processing, Vol.13, No.5, pp.699-709(2004).
- [34]X. Wang, H. Fang and C. Zhai: A study of methods for negative relevance feedback, Proceedings of the 31st annual international ACM SIGIR conference on Research and development in information retrieval, pp. 219-226 (2008).
- [35]I.J. Cox: An optimized interaction strategy for Bayesian relevance feedback, IEEE Conference on Computer Vision and Pattern Recognition, pp. 553-558(1998).
- [36] I.J. Cox, M.L. Miller, T.P. Minka, T.V. Papatomas and P.N. Yianilos: The Bayesian image retrieval system, PicHunter: theory, implementation, and psychophysical experiments, IEEE Transactions on Image Processing, Vol.9, No.1, pp.20-37(2000).
- [37]S. Zhong, H.J. Zhang, S.Z. Li and S.P. Ma: Relevance feedback in content-based image retrieval: Bayesian framework, feature subspaces, and progressive learning, IEEE Transactions on Image Processing, Vol.12, No.8, pp.924-937(2003).
- [38]M. Rokeach: The Nature of Human Values, New York: The Free Press(1973).
- [39]M. B. Holbrook: Consumer Value: A Framework for Analysis and Research, Routledge(1999).
- [40]D. E. Vinson, J. E. Scott, and L. M. Lamont: The Role of Personal Values in Marketing and Consumer Behavior, The Journal of Marketing, Vol. 41, No. 2, pp. 44-50(1977).
- [41]M. Fishbein: Reading in Attitude Theory and Measurement, NewYork: John Wiley and Sons, Inc. (1967).

- [42]M. Balabanović, “An adaptive web page recommendation service,” Proceedings of the first International Conference on Autonomous Agents. 1997: 378-385.
- [43]C. Basu, H. Hirsh, and W. Cohen, “Recommendation as classification: using social and content based information in recommendation,” Proceedings of the 1998 workshop on Recommender Systems, 1998: 11-15.
- [44]S. Park, and D. M. Pennock, “Applying collaborative filtering techniques to movie search for better ranking and browsing,” Proceedings of the 13th ACM SIGKDD international conference on Knowledge discovery and data mining, 2007: 550-559 .
- [45]J. Delgado, and N. Ishii, “Memory-Based Weighted Majority Prediction for Recommender Systems,” Proceedings of the ACM SIGIR 1999 Workshop Recommender Systems: Algorithms And Evaluation, 1999.
- [46]R. F. Jia, and M. Z. Jin, and C. Liu, “A new clustering method for collaborative filtering,” Proceedings of International Conference on Networking and Information Technology, 2010: 488-492.
- [47]S. J. Gong, and H. W. Ye, “Joining user clustering and item based collaborative filtering in personalized recommendation services,” Proceedings of International Conference on Industrial and Information Systems, 2009: 149-151.
- [48]Y. Kabutoya, T. Iwata and K. Fujimura, “Collaborative Filtering based on Topic Models Considering an Account Shared by Multiple Users,” DBSJ Journal,vol.9,no.3, pp:7-12, 2011.
- [49]J. S. Breese,D. Heckerman,and C. Kaide, “Empirical Analysis of Predictive Algorithms for Collaborative Filtering,” Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence,1998 : 43-52.
- [50]J. L. Herlocker, J. A. Konstan, A. Borchers, and J. Riedl, “An algorithmic framework for performing collaborative filtering,” Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval, 1999: 230-237.

- [51]J. Herlocker, J. A. Konstan, and J. Riedl, “An Empirical Analysis of Design Choices in Neighborhood-Based Collaborative Filtering Algorithms,” *Information Retrieval*, 2002: 287-310.
- [52]J. B. Schafer, J. Konstan, and J. Riedl, “Recommender systems in E-commerce,” *Proceedings of the first ACM Conference on Electronic Eommerce*,1999:158-166.
- [53]B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, “Analysis of Recommendation Algorithms for E-Commerce,” *Proceedings of the 2nd ACM Conference on Electronic Commerce*,2000 : 158-167.
- [54]P. N. Tan, M. Steinbach and V. Kumar, "Introduction to Data Mining," Addison-Wesley.
- [55]J. L. Rodgers and W. A. Nicewander, “Thirteen ways to look at the correlation coefficient,” in *The American Statistician*, 42(1):59–66, February 1988.
- [56]J.W. Han, J. Pei, and Y. Yin: Mining Frequent Patterns without Candidate Generation, *Proceedings of 2000 ACM SIGMOD international conference on Management of data*, Vol.29(2000).
- [57] Shoes-Street 商品情報  
<http://www.shoes-street.jp/>
- [58] Yoshida 商品情報  
<http://www.yoshidakaban.com/>
- [59] R. Ghani, K. Probst, Y. Liu, M. Krema, and A. Fano: Text mining for product attribute extraction. *SIGKDD Explor. Newsl.* Vol.8, No.1, pp.41-48(2006).
- [60]P. Arabie, and Y. Wind, "Marketing and Social Networks." In Stanley Wasserman and Joseph Galaskiewicz, *Advances in Social Network Analysis: Research in the Social and Behavioral Sciences*. Thousand Oaks, Calif.: Sage Publications, pp. 254–273, 1994.
- [61] A. Agarwal, B. Xie, I. Vovsha, O. Rambow, and R. Passonneau, “Sentiment analysis of Twitter data,” *Proceedings of the Workshop on Languages in Social Media*, 2011:30-38.
- [62]N. J. Belkin, and W. B. Croft, “Information filtering and information retrieval: two sides of the same Coin,” *Communication of the ACM* 1992, 2(1):134-145.

- [63] A. Ralston and H. S. Wilf, *Mathematical Methods for Digital Computers*, John Wiley & Sons, New York, 1960.
- [64] G. Salton and M. J. McGill: *Introduction to modern information retrieval*. McGraw-Hill, ISBN 0-07-054484-0.
- [65] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *International Journal of Forecasting*, vol. 22, no. 4, pp: 679-688, 2006.
- [66] H. Yan and T. Ushiyama, “振る舞い協調フィルタリングによるソーシャルストリームの効率的な閲覧手法,” *The 6th Forum on Data Engineering and Information Management A4-3*, 2014.
- [67] H. Yan and T. Ushiyama, “スマートフォン上でのユーザの振る舞いに基づいた効果的な商品情報提示手法に関する検討,” *Proceedings of 1<sup>st</sup> ADADA Japan, A1-4*, 2014.
- [68] 総務省情報通信白書平成 26 年版,  
<http://www.soumu.go.jp>

## 業績一覧

- [1] Hong Yan, Yuki Hayashi, Tomoko Kojiri, and Toyohide Watanabe, “Feature Analysis of Learner’s Behaviors in e-Learning,” 平成 22 年度電気関係学会東海支部連合大会, 講演論文集, B2-4, 2010.
- [2] 顔洪, 渡邊豊英: “文書レイアウトに基づいた直感的ページ検索,” 平成 24 年度電気関係学会東海支部連合大会, 講演論文集, C4-2, 2012.
- [3] Hong Yan and Toyohide Watanabe, “Document page retrieval based on geometric layout features,” ACM Proceedings of the 7<sup>th</sup> International Conference on Ubiquitous Information Management and Communication, No.60, 2013.
- [4] Satoshi Yokoi, Hong Yan and Toyohide Watanabe, “Retrieval of Article-pages,” Using Geometric Layout Relationships among Document Components, Intelligent Interactive Multimedia Systems and Services, Volume 254, pp.51-60, 2013.
- [5] 顔洪, 牛尼剛聡, “振る舞い協調フィルタリングによるソーシャルストリームの効率的な閲覧手法,” 第 6 回データ工学と情報マネジメントに関するフォーラム, A4-3, 2014.
- [6] 胡玉龍, 趙耕弘, 顔洪, 宮原徹, 高山敏典, 森永久之, 出口貴嗣, 牛尼剛聡, “旅行者の移動履歴を利用した旅行情報のランキング手法,” 第 6 回データ工学と情報マネジメントに関するフォーラム, E9-3, 2014.
- [7] Hong Yan and Taketoshi Ushiyama, “Analysis of Relationships between Browsing Behaviors and Interests on Social Streams,” 信学技報, vol. 114, no. 101, DE2014-13, pp.49-54, 2014.
- [8] 顔洪, 牛尼剛聡, “スマートフォン上でのユーザの振る舞いに基づいた効果的な商品情報提示手法に関する検討,” Proceedings of 1<sup>st</sup> ADADA Japan, A1-4, 2014.

- [9] Hong Yan and Taketoshi Ushiana, "Effective Browsing Technique based on Behavioral Collaborative Filtering on Social Streams," *Procedia Computer Science*, Volume(s) 35, pp.1702-1710, 2014
- [10] Hong Yan and Taketoshi Ushiana, "A study on estimation of preference on a product based on user behaviors on Smartphone," *Proceedings of International Conference of Asia Digital Art and Design Association*, B-144, 2014.
- [11] 顔洪, 牛尼剛聡, "スマートフォン上でのユーザの振舞いに基づいた効果的な商品選別手法," 第7回データ工学と情報マネジメントに関するフォーラム, A4-2, 2015.
- [12] Hong Yan and Taketoshi Ushiana, "A Method for Estimating User's Preference about Shopping Items Based on User's Behaviors on Smartphone," *International journal of Asia digital art and design*, Vol.19, No.03, 2015.
- [13] 顔洪, 牛尼剛聡, "スマートフォンでの振舞いに基づいた商品閲覧リストの最適化," *Proceedings of 2nd ADADA Japan*, B2-1, 2015.
- [14] 顔洪, 牛尼剛聡, "スマートフォンでの効率的な商品選別を目的としたユーザの振る舞いに基づく閲覧リスト最適化手法," *情報処理学会論文誌:データベース*, Vol.8, No.4, pp1-15, 2015.