

マイクロブログ上の購入報告に注目した 商品購入後に取りべき行動の検索

神田 拓実[†] 莊司 慶行[†] Martin J. Dürst[†]

[†] 青山学院大学 理工学部 情報テクノロジー学科 〒252-5258 神奈川県 相模原市 中央区 淵野辺
E-mail: †kanda@sw.it.aoyama.ac.jp, ††shoji@it.aoyama.ac.jp, †††duerst@it.aoyama.ac.jp

あらまし 本論文では、商品名をクエリとして、その商品を買った際に取りべき現実行動を検索するアルゴリズムを提案する。EC サイトにおいて、商品の推薦が一般的になりつつあるが、例えばカメラを購入した際、旅行や花火などに持ち出してカメラを堪能するのが先で、追加のレンズを購入するのはしばらく経ってからのことが多い。このような場合、商品の推薦より先に現実行動を推薦することで、より購入者の満足度が高まると考えられる。そこで、Twitter 上での商品名を含む購入報告に注目し、その商品を購入した人の行動変化を分析し、購入後に有意に増加した行動を含んだ tweet をランキングする。そのために商品名を直接含まない投稿へのクエリ拡張、投稿のトピックを推定しての購入前後の行動の比較を行った。2 年分のツイートと価格コムデータをを用いた被験者実験を通して、商品カテゴリ名を使ったクエリ拡張、SVM による購入報告の抽出、関連度を考慮したランキング手法の、それぞれが有効であったことを明らかにした。

キーワード 行動推薦, SNS 分析, 情報推薦, ショッピングサイト

1 はじめに

人は様々な商品を購入しながら、生活を改善してゆく生き物である。ギターを買った人は、ギターを練習するようになったり、バンド仲間を見つけてライブで演奏するようになったり、音楽に関係する行動をより積極的に取るようになるかもしれない。高いカメラを買った人は、旅行に行くようになったり、帰り道に少し寄り道をして被写体を探したり、撮影に関係する行動をより多くとるようになるかもしれない。このように、何かを購入することで、行動や生活様式に変化が生じることは、日常生活において一般的な現象である。

現在、オンラインサービスにおいてアイテムを購入したユーザに別のアイテムを推薦する機能が一般化してきている。例えば、オンラインショッピングサイトでは、ユーザが買った商品をもとに、同じ商品を買ったユーザが他に何を買っているかを表示する機能が広く採用されている。「Amazon」や「楽天」などのオンラインショッピングサイトで買い物をする際に、商品の推薦機能をもとに別の商品を購入することは、すでに生活の一部になっている。他の推薦の例として、動画配信サービスでは、ユーザが見る動画の傾向に合わせてユーザが好みそうな動画を推薦している。動画の推薦機能を持つサービスとして有名なものは動画配信サイトの「YouTube」や「Netflix」などがある。これらのサイトでは、ユーザの視聴傾向から、次に見るであろう動画を予想して推薦する。

このように、商品を購入した際に別の商品を推薦されることは一般化しているが、商品を買った後に、いきなり次の商品を買うことは、まれである。例として、従来の推薦システムを有する電子商取引サイトで「デジタル一眼カメラ」を購入した場

合を考える。「デジタル一眼カメラ」を買ったユーザに対して、前述したショッピングサイトでは「買ったカメラに対応したレンズ」や「液晶保護フィルム」、あるいは別の一眼カメラを推薦する。しかし、カメラを買ったユーザがいちばん初めにすることは「そのカメラをアップグレードするために別の商品を購入する」行為ではなく「買ったままのカメラで何かを撮影する」行為である。このように、実際に商品を購入した際に求められる推薦機能として、別の商品ではなく、購入者が次に何をすべきかを推薦するシステムであると考えられる。

そこで、我々はマイクロブログで一般的に行われる商品の購入報告に注目する。購入報告とは、例えば「 $\alpha 7$ を買ったよ!」や、「SONY のミラーレス一眼カメラを購入しました。」など、何らかの商品を購入したことを報告している投稿を指す。このような投稿を収集することで、アイテムを買ったユーザが購入前と購入後で投稿文の内容がどう変わったのかを分析できる。本研究では、このような購入報告の前後の投稿の内容の変化を分析することで、商品名を入力すると、そのあとにどのような行動をとるべきかを推薦する、検索システムを提案する。具体的な手法として、まず、クエリとしてある商品名が与えられた際に、その商品の購入報告を行なっているユーザの前後の投稿をトピックで表す。そして、購入前後の投稿のトピックの分布を比較し、購入後に有意に増加したトピックに属する投稿をランキングすることで、商品購入後に取りべき行動を表示する。

本論文の構成は次の通りである。第 2 章では本研究に関連する研究として、オンライン行動とオフライン行動を紐付けた先行研究やイベント分類の手法を提案している関連研究を紹介し、本研究との差異について述べる。第 3 章ではマイクロブログの投稿から商品の購入前後で文章のトピックが変化したか解析し、行動を推薦する手法について述べる。第 4 章では提案手法の

用性を明らかにするため、2年分のツイートと価格コムデータをを用いた被験者実験のタスク及び、結果について述べる。

2 関連研究

本研究はマイクロブログ上の購入報告を用いて、ユーザが商品を購入した後にとるべき行動を検索するアルゴリズムを提案するものである。ECサイトにおいて、ユーザにアイテムを推薦する機能が一般的なものとなっているほか、推薦アルゴリズムに関する研究も多く行われている。また、本研究のようにオンラインとオフラインの行動を紐付けた研究も存在する。

2.1 SNSと実世界での行動の関連付け

インターネットの普及により、SNSへ文章を投稿する等のオンライン行動と現実世界での行動は不可分なものになりつつある。このような社会の変化をうけて、SNS上の投稿と現実の行動を結びつけ、消費者行動を分析したり、情報推薦を行う研究が行われている。消費者行動を分析する研究として中村ら [1] はアクセスログからECサイトにおけるユーザの消費者関与を分析している。リアルタイムに時系列データを解析してバーストの有無を検出する手法 [2] を用いたほか、既存のリアルタイムバースト検出手法を改良し、追加した機能が、消費者関与の高いユーザを選択的に取得する機能として、有用であることを示した。

SNS（ソーシャルネットワーキングサービス）の投稿と現実世界での行動を関連づけた情報推薦の研究として、田中ら [3] はオンライン履歴とオフライン履歴からあるサービス内のコンテンツを推薦する手法を提案している。田中らによって提案された推薦システムは推薦システムの運用目的の分類 [4] に従って「行動履歴を個人の単位で解析しそれに基づき情報を選択する緊密な個人化を行う推薦システム」と分類できるが、本研究で提案する手法は「行動履歴を一時的個人の単位で解析し、それに基づき関連アイテムを発見するために一時的な個人化を行う推薦システム」と分類できる。本研究も同様に、オンライン行動とオフライン行動を関連づけた推薦手法を提案している。田中らによる研究は非推薦者の端末にアプリケーションをインストールし、本人の詳細な行動ログからコンテンツの推薦を行っている。一方で、本研究では第三者のマイクロブログ上の購入報告及びその前後の投稿を入力としている。また推薦対象も、田中らによる研究では、あるWebサービス上のコンテンツに限られているが、本研究は実世界での行動である。

また、対象を購入行動に絞り、SNSの投稿と実世界での行動を関連付けた研究として、梅本ら [5] による、実世界で行動を起こすきっかけとなった他者の投稿の発見が挙げられる。この研究ではある投稿者が商品を購入したかどうか判別するために、ECサイトでの商品を購入したときにSNSに商品を購入したことをシェアする機能を用いている。この際、商品を購入したユーザ自身の投稿ではなく、そのユーザが見ていた他者の投稿を収集する。収集した他者の投稿に対し、投稿内容の商品との関連性、投稿者の商品購入者との親密性および近接性、投稿文

体の情動性および宣伝力という、5種類の特徴量を用いることで、購買行動に影響を与えた他者の投稿を検出した。本研究も同様に、オンラインサービスでのユーザの投稿から現実世界行動とオンライン行動を関連づけている。梅本らの研究は商品購入前に注目することで分析を行なっているのに対し、本研究では商品購入後に注目し、商品購入後にとるべき行動を検索可能にしている。

ソーシャルメディアの実世界行動への影響を調査した先行研究として、Althoffら [6] はSNSとワークアウトの関係を分析している。この研究ではオンラインヘルスケア用のスマートフォンアプリケーションを通じて、長期にわたって記録されたユーザのアクティビティと、連携しているSNSの利用傾向との関係性を調査している。結果として、新しいオンライン上での接続の作成によりユーザのオンラインでのアプリケーション内アクティビティや、アプリケーションの使用を継続する確率、及びユーザの実世界での身体活動が増加することがわかった。また、この研究ではこの調査を活用してソーシャルネットワーク上で周りの影響を受けやすいユーザを正確に予測するモデルについても作成している。本研究が購買行動に注目しSNSとの関係を分析している一方で、この研究は実世界でのユーザの活動に注目している。

2.2 情報推薦

本研究はある商品名を入力すると、購入後にとるべき行動のランキングを出力する検索アルゴリズムを提案している。これは、広義の情報推薦システムのひとつである。近年、協調フィルタリングなどの推薦アルゴリズムが一般化したことで、ECサイトにおける商品などアイテムの推薦システムが一般的なものになった。神島ら [4] は、近年多くのECサイトなどで推薦機能が採用されるようになったのには、2つの理由からであると述べている。1つ目の理由は大量の情報が発信されるようになったことである。これは、情報化技術の進展により、個人や団体が容易かつ低コストで情報が発信できるようになったためである。2つ目の理由は大量の情報の蓄積や流通が容易になったことで、誰もが大量の情報を得ることができるようになったことである。これも計算機の記憶媒体の大規模化や、通信の高速化によるものである。これらのことから、大量に発信された情報に誰もがアクセスできるようになったが、情報過多な状態になり、その中から必要な情報を発見できないという状況が生じた。そのため、利用者にとって有用な情報を見つけ出す推薦システムの必要性が増した。

このように、オンラインサービスでアイテムの推薦が一般的になった一方で、現実行動を推薦するシステムはあまり一般的ではない。例えば田中ら [3] は、本研究と同様に現実世界とオンライン世界を関連づけた情報推薦システムを提案している。田中らは、アイテムを推薦するために必要な人間個人の活動は、単一のWebサイト、あるいはインターネットなどオンラインの領域に限定されず、むしろ実世界、オフラインの領域の方が広いと考え、行動履歴からWebコンテンツを推薦するエンジンの開発を提案した。しかし田中らの研究も推薦対象は現実行

動ではない。

2.3 購買行動前後でのユーザの行動変化

購買行動に注目し、商品を購入したことでユーザにどのような変化が起こったのかを分析する研究も行われている [7,8]. Lo ら [9] は商品を購入する前、ユーザの SNS 上での振る舞いどのような兆候が見られたかを調べ、モデル化した。Pinterest¹ という、Web サイトや他の人が集めた写真や投稿をピン留めし、情報を集めることを目的とした Web サービスのデータを利用して、Pinterest ユーザの購買行動とその前の行動を分析した結果、オンライン行動における購入の予兆は、購入が行われる数週間前から表れることを明らかにした。この分析により、普段行われるオンライン行動と購入前に行われるオンライン行動には差があることがわかった。本研究との差異として、Lo らによる研究は購入前のユーザの行動変化に注目しているのに対し、本研究では購入後のユーザの行動変化に着目している。

Sweeney ら [10] は、SNS においてどのような口コミが購買意欲に対して正の影響があるか、TAM (Technology Acceptance Model) に基づき分析した。本研究との相違点として、Lo らによる研究と同様に Sweeney らによる研究は購入前のユーザの行動変化に着目しているのに対し、本研究では購入後のユーザの行動変化に着目している。また、Sweeney らの研究では行動に影響を与える口コミを分析している一方で、本研究では変化した行動を分析している。

2.4 イベント分析

本研究では商品購入後にとるべき行動を検索することを目的としているが、現実世界でのイベントを検出し、それを分類することを目的とした研究が多く行われている [11-13]. 本研究と関係の深い例として、Thelwall ら [14] はマイクロブログ上の位置情報付き発言の量からイベントを検出する手法を提案している。実際に 1ヶ月間の Twitter 上の投稿を分析することで、人気のあるイベントが否定的な感情を持つ発言の増加量と相関していることを明らかにした。本研究との相違点として、Thelwall らの研究では実世界のイベントを分析することを目的としているが、本研究では商品購入後特有の投稿を分析している。

イベント分類に関連した研究として、河野ら [15] は、SNS のフォロー関係を用いて、実世界のイベントを分類する手法を提案している。SNS の普及により、多くのユーザが GPS による位置情報を付与した現実世界の情報をリアルタイムに発信するようになりつつある。この研究ではイベントを分類することを目的とし、位置情報付きツイートを投稿したイベント参加者のフォロー関係を分析している。これにより、イベントの「大衆性」というイベントが万人に受けるものか、あるいは一部のみに支持されるイベントかという、新しい分類軸でイベントを分類可能にしている。

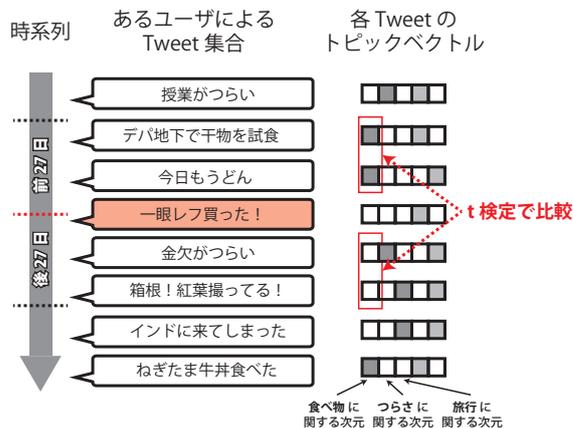


図 1 提案手法の概要。購入報告の前後 27 日分の tweet をトピックベクトルで表し、各次元ごとに t 検定で比較する。この例では、カメラを購入すると、食べ物に関する投稿が減り、旅行に関する投稿が増えている。この場合、旅行に関する行動を推薦すればよい。

3 提案手法

本章ではソーシャルネットワーキングサービスから商品を購入したことを示唆する投稿を見つけ、商品の購入前と購入後で文章のトピック分布に変化があったかを分析し、商品購入後に取るべき行動を発見する手法について説明する。手法の全容を図 1 に示す。はじめに商品名が含まれる投稿を収集し、その中から購入報告を分類器によって抽出する。次に購入報告前後の投稿群を収集し、それらをトピックからなるベクトルで表す。作成したベクトルの各次元に対して、購入前と購入後で t 検定で比較する。ある商品を購入したことでどのような話題を含む投稿が増加したかを明らかにすることで、投稿が商品を購入した後特有の投稿であるかを測ることができる。最後に、投稿後特有の投稿をランキングし、出力する。

3.1 購入報告収集のためのクエリの作成

はじめに、マイクロブログから購入報告を収集するためのクエリを作成する。SNS から、ある商品の購入に関する投稿を分析に十分な量収集するためには、適切な粒度のクエリを設定する必要がある。例えば「パソコン (PC)」というクエリは多くの投稿を発見可能だが、粒度が粗く、分析に適さない。このクエリでは、購入したのがデスクトップ PC かノートパソコンかも区別がつかないためである。デスクトップ PC とノート PC では用途が大きく異なり、購入後とるべき行動も異なる。反対に、細粒度のクエリとして、固有の PC の機種名を入力した場合を考える。例えば「Let's Note SV8 2019 年モデル」などの商品名や、「CF-LV80RJQP」などの型番では、正確にこれらの話を含んだ投稿は少なくなり、多くの場合、分析するために必要な量のデータが集まらない。そこで、自動的に分析に適した粒度のクエリを作成するために、商品情報サイトの商品カテゴリの情報を利用した。

1 : <https://www.pinterest.jp/>

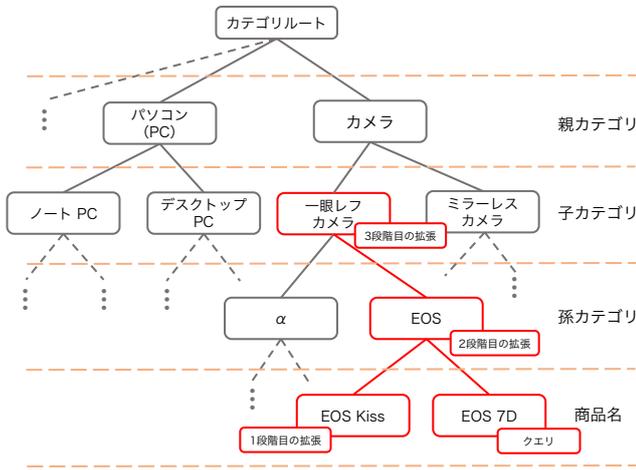


図 2 商品情報サイトにおける木構造の商品カテゴリ

多くの商品情報サイトには商品をカテゴリ別に検索できる機能がある。商品カテゴリは、多くの商品情報サイトにおいて木構造をとっている。これを図 2 に示す。「カテゴリルート」の 1 つ下流に存在するノードは「パソコン (PC)」や「カメラ」など、商品の大きなジャンルを区分している。これを「親カテゴリ」と呼ぶ。「カテゴリルート」の 2 つ下流に存在するノードは、親カテゴリをより詳細に区分している。例えば親カテゴリが「パソコン (PC)」であれば「ノートパソコン」や「デスクトップパソコン」、「カメラ」であれば「ミラーレスカメラ」や「一眼レフカメラ」などが配置されている。これを「子カテゴリ」と呼ぶ。そして、「子カテゴリ」の 1 つ下流に存在するノードは「EOS」や「α」など、メーカーが製造したシリーズ全体の総称が並ぶ。これを「孫カテゴリ」と呼ぶ。「孫カテゴリ」の下流に存在するノードには「EOS 8000D」や「α 6500」など、商品名が配置される。

分析可能なだけの投稿を集められるように、本手法では、ある商品名 q_{in} を入力すると、製品名ツリーを 3 段階にわたって遡り、拡張クエリからなる集合 Q_q を作成する。1 段階目の拡張として、 q_{in} の兄弟にあたるノード（すなわち、同じ孫カテゴリに属する他の商品名） q_b もクエリとして用いる。2 段階目の拡張としては、 q_{in} の 1 つ上流であるノード（すなわち、孫カテゴリ）にあるノード q_p もクエリとして用いる。3 段階目の拡張として、 q_{in} の 2 つ上流のノード（すなわち、子カテゴリ）である q_{gp} もクエリとして用いる。この時 $Q_q = \{q_{in}, q_b, q_p, q_{gp}\}$ である。

具体的に、商品名としてクエリに「EOS 7D」が入力された場合を考える。1 段階目の拡張として、この商品の兄弟にあたるノードとして、商品名である「EOS Kiss」もクエリに含め、 q_b として用いる。

2 段階目の拡張として、孫カテゴリである「EOS」もクエリに含め、 q_p として用いる。3 段階目の拡張として、さらにもう 1 段階上流のノードである「一眼レフカメラ」もクエリに含め、 q_{gp} として用いる。そのため、実際にクエリとして用いられるのは $Q_q = \{EOS 7D, EOS Kiss, EOS, 一眼レフカメラ\}$ である。

表 1 購入報告かの分類に用いた特徴

注目する要素	実際の特徴	次元数
使われている語	購入示唆動詞	28
	「商品名」+購入示唆動詞（連続）	28
	「キャンペーン」などの語	2
	商品名を名詞として含む	1
	クエリ名	37
メタデータ	URL を含む	1
	引用を表す語	1
	「欲しい」などの語	3
	「～した方が」などの語	2
	他ユーザの投稿の引用である	1
ユーザネーム	他ユーザへの返信である	1
	同様の投稿数	1
	投稿の長さ	1
時間	末尾に bot を含む	1
	時刻	24

商品情報サイトの多くは人間用に作られているため、マシンリーダブルでない。そのため、前処理として、「イヤホン・ヘッドホン」など中点やその他記号で 2 つの商品カテゴリ名が 1 つの文になっている場合、記号を区切り文字として、あらかじめ分離した。また商品の孫カテゴリには「パーフェクト」や「メンズ」など、検索した時に同型異義語を多く発見するような一般名詞からなるものも多い。そのため孫カテゴリを形態素解析し、同型意義語を多く発見する一般名詞からなるものであった場合、クエリから除外した。

3.2 購入報告の抽出

マイクロブログ上の全ての投稿集合 T から、拡張済みのクエリ集合に含まれる語 $q \in Q_q$ を 1 つ以上含む投稿集合 T_q を収集する。商品名や商品カテゴリ名を含む投稿のうち、全てが購入報告であるとは限らない。例えばその商品の購入を検討していることを伝える投稿かもしれないし、または商品の宣伝のための企業による投稿かもしれない。

そこで、次はクエリ q から収集した投稿集合 T_q から、実際に商品を購入したことを報告している投稿集合 $T_{buy}(q)$ を抽出する。そのために、商品名を含む投稿を、SVM (Support Vector Machine) を用いて、購入報告とそうでないものに分類した。

はじめに、収集したデータの一部について、人手でラベル付けし、学習用の正解データを作成した。次に分類するための特徴量を作成した。ある 1 つの投稿がある商品の購入報告であるかを分類するために用いた特徴量を、表 1 に示す。購入報告であることが明確である投稿には、「買いました」や「購入した」など、商品の購入を示唆する動詞が含まれている可能性が高い。これらの動詞群を「購入示唆動詞」と呼び、特徴として使用した。また、「キャンペーン」や「応募」などの語が含まれている投稿には「企業がキャンペーンとして、抽選で商品を手入できる投稿」が多いため、これらの語も特徴として使用した。また、マイクロブログから収集されたデータに含まれた、「ユーザネーム」や「投稿日時」などの情報も特徴として使用した。

また、一般的に商品名やカテゴリ名を含む投稿のうち、実際

に購入報告である投稿は全体に対して極端に少ない（具体的には、今回のデータでは、0.055%に過ぎなかった）。分類器を学習する上で不均衡であるため、オーバーサンプリングにより、正例と負例の数をそろえた。

ここで、 q_{in} だけでなく、拡張したクエリである q_p , q_{gp} についてもそれぞれ同様の処理を行い、 $T_{buy}(q_{in})$, $T_{buy}(q_b)$, $T_{buy}(q_p)$, 及び $T_{buy}(q_{gp})$ を抽出した。

3.3 購入前後の投稿の収集

次に、購入報告を投稿したユーザの、購入前後の投稿を収集する。この際、購入報告の投稿された日時から前後 27 日の投稿を対象とした。これは Lo ら [9] が行った先行研究に倣うものである。全てのユーザによる、ある商品の購入報告の集合 $T_{buy}(q)$ は、ある q に対するユーザ u の購入報告を $t_{buy}(u, q)$ をすると、

$$T_{buy}(q) = \{t_{buy}(u_1, q), t_{buy}(u_2, q), \dots, t_{buy}(u_n, q)\}$$

と表される。 $t_{buy}(u, q)$ に対し、購入前の投稿集合 $T_{pre}(t_{buy}(u, q))$ 、購入後の投稿集合 $T_{post}(t_{buy}(u, q))$ を収集する。あるユーザ u の q に対する購入報告 $t_{buy}(u, q)$ と、それから収集した購入報告前後の投稿を $T_{timeline}(t_{buy}(u, q))$ とすると、

$$T_{timeline}(t_{buy}(u, q)) = (T_{pre}(t_{buy}(u, q)), t_{buy}(u, q), T_{post}(t_{buy}(u, q)))$$

と表される。

こうして、 q_{in} から収集し、抽出した購入報告 $T_{buy}(q_{in})$ 、拡張済みクエリを用いて抽出した購入報告 $T_{buy}(q_p)$, $T_{buy}(q_{gp})$ について、それぞれ前後の投稿を収集した。収集した全ての投稿に対し、どの商品に対する購入報告の前後の投稿であるか、購入してから何日前、何日後の投稿であるか、及び何段階目の拡張で収集した購入報告の前後の投稿であるか、タグ付けた。

3.4 トピックの分布の比較

収集した投稿について、ある商品の購入前後での投稿の話題の変化を分析する。そのために、LDA (Latent Dirichlet Allocation) を用いて、各投稿を M 次元のトピックからなるベクトルで表す。

投稿中の単語を潜在的なトピックに基づいてベクトル化するために、Wikipedia のすべての記事を用いて LDA のトピックモデルを学習した。前処理として、Wikipedia の各記事を単語に分割し、ストップワードを除去した。また、「名詞」、「動詞」、「形容詞」の 3 つの形態素を抽出し、これらのみを用いた。また、動詞は基本形への変換を行った。このように作成したコーパスで、トピックモデルを学習した。

次に、作成したトピックモデルを用いて、購入前後の投稿群をそれぞれトピックからなるベクトルで表し、トピックごとの変化を比較する。ある投稿を行なったユーザの前後の投稿をそれぞれ、トピックモデルを作成した時と同様に形態素解析し、「名詞」、「動詞」、「形容詞」だけ残した。次に、Wikipedia を用いて学習したトピックモデルで、それぞれの投稿をベクトルで

表した。この際、投稿ごとのトピックの割合は L1 ノルムで正規化した。

正規化したトピックベクトルについて、次元ごとに購入前と購入後の違いを t 検定により検証した。有意に増加している次元を発見できれば、そのトピックに属する投稿は、購入者に推薦すべき行動であると考えられる。任意のユーザ u による任意の投稿 $t_i \in T_{timeline}(t_{buy}(u, q))$ について、LDA でベクトル化し、L1 ノルムで正規化したものを $t = (t_{i_1}, t_{i_2}, t_{i_3}, \dots, t_{i_m})$ とおく。あるユーザ u による、ある商品 q を購入した購入報告 $t_{buy}(u, q)$ に対して、前 27 日以内の投稿を $t_{pre,j}, \dots, t_{pre,2}, t_{pre,1} \in T_{pre}(t_{buy}(u, q))$ 、後 27 日以内の投稿を $t_{post,1}, t_{post,2}, \dots, t_{post,k} \in T_{post}(t_{buy}(u, q))$ とそれぞれ表す。

ここで、 $T_{post}(t_{buy}(u, q))$ に含まれるすべての t_i の m 次元めの系列をベクトルとみなし、 $\mathbf{l}_{post_m}(u, q) = (t_{post,1_m}, t_{post,2_m}, \dots, t_{post,k_m})$ と表す。同様に、 $T_{pre}(t_{buy}(u, q))$ に含まれるすべての投稿の m 次元めも $\mathbf{l}_{pre_m}(u, q)$ と表す。 $\mathbf{l}_{pre_m}(u, q)$ と $\mathbf{l}_{post_m}(u, q)$ はそれぞれ値域の等しい実数からなる系列であるため、Student の t 検定によりその平均に有意差があるか計算できる。

$\mathbf{l}_{pre_m}(u, q)$ と $\mathbf{l}_{post_m}(u, q)$ に有意差があるか計算する検定統計量 S は

$$S = \frac{\overline{\mathbf{l}_{pre_m}(u, q)} - \overline{\mathbf{l}_{post_m}(u, q)}}{\sqrt{\left(\frac{1}{|\mathbf{l}_{pre_m}(u, q)|} + \frac{1}{|\mathbf{l}_{post_m}(u, q)|}\right)U_{\mathbf{l}_{pre_m}(u, q)\mathbf{l}_{post_m}(u, q)}^2}}$$

と表せる。ただし、 $\overline{\mathbf{l}_{pre_m}(u, q)}$ と $\overline{\mathbf{l}_{post_m}(u, q)}$ はそれぞれの平均を表す。

この時、 $U_{\mathbf{l}_{pre_m}(u, q)\mathbf{l}_{post_m}(u, q)}^2$ は

$$U_{\mathbf{l}_{pre_m}(u, q)\mathbf{l}_{post_m}(u, q)}^2 = \frac{(\overline{\mathbf{l}_{pre_m}(u, q)} - 1)U_{\mathbf{l}_{pre_m}(u, q)}^2 + (\overline{\mathbf{l}_{post_m}(u, q)} - 1)U_{\mathbf{l}_{post_m}(u, q)}^2}{\overline{\mathbf{l}_{pre_m}(u, q)} + \overline{\mathbf{l}_{post_m}(u, q)} - 2}$$

と表せる。ただし、 $U_{\mathbf{l}_{pre_m}(u, q)}^2$ は $\mathbf{l}_{pre_m}(u, q)$ の不偏標準偏差を表す。

ここで、 $\mathbf{l}_{pre_m}(u, q)$ と $\mathbf{l}_{post_m}(u, q)$ において有意差が認められ、かつ増加していた（ここでは $\overline{\mathbf{l}_{pre_m}(u, q)} < \overline{\mathbf{l}_{post_m}(u, q)}$ であった） $t_{buy}(u, q)$ の件数 i_m を各次元ごとに計算し、ベクトル $\mathbf{i} = (i_1, i_2, \dots, i_m)$ を作成する。

3.5 出力する投稿のランキング

計算した、各トピックの購入後有意に増加した購入報告数のベクトル \mathbf{i} を用いて、クエリ集合 Q_q に関する購入報告から収集した購入後投稿群 $T_{post}(Q_q)$ をランク付けする。この時、ランキング上位の投稿は少なくともクエリと関連している必要がある。そのため、投稿 t のクエリとの関連度 D_t を計算する。

まず、投稿 t を形態素解析し、名詞のみを抽出した $N(t) = n_1, n_2, \dots, n_c$ を作成する。任意の $n \in N(t)$ と任意のクエリ q との単語間類似度を $sim(n, q)$ とすると、 D_t は名詞 n とクエリ q について $sim(n, q)$ の最大値を返す。つまり、

$$D_t = \max\{sim(n, q) | n \in N(t), q \in Q_q\}$$

と表せる。

また、 q_{in} の購入後投稿がランキング上位に来るように、クエリの拡張度合いに応じて重み（例えば q_{in} から収集した購入報告であれば 1.00, q_b , または q_p からであれば 0.66, q_{gp} であれば 0.33 など） $w(q)$ を課す。

また、投稿 t が増加したトピックをどれだけ表しているかを表す変化度 I_t を求める。 I_t は

$$I_t = \sum_{m=1}^M i_m \times t_m$$

と表される。

これらを元に、購入後投稿 $t_{post}(q)$ が購入後に特有な投稿であったかを表す特有量 $Unique(t_{post}(q))$ を求める。 $Unique(t_{post}(q))$ について

$$Unique(t_{post}(q)) = \sqrt[3]{w(q)} \times D_t \times \sqrt{I_t}$$

と表す。この特有量を、クエリ集合 Q_q から収集した全ての購入後投稿に対して算出する。これにより、商品名クエリと投稿の入力から、その商品の購入後にとるべき行動を含む投稿をランキングする。

4 評価実験

本章では、提案手法の有用性を示すために行った評価実験に用いたデータセット、評価方法の詳細及び、その結果について述べる。評価実験として、用意した 15 種類の商品名について、提案手法とベースライン手法を含めた計 4 手法で、商品購入後取るべき行動を検索した。それぞれの手法で出力された各 10 件の tweet について、被験者にクエリとの関連度と tweet 内容の有用度をラベル付けさせた。

4.1 データセット

実験では、マイクロブログの実際のサービス例として、Twitter のデータを用いた。はじめに、購入報告を収集するために、2018 年 4 月から Twitter Streaming API 経由で集めた tweet を用いた。これらの tweet は Apache Solr で管理され、任意のキーワードクエリで検索可能である。直接的に商品名を含む tweet 178,608 件、拡張したクエリ集合の内いずれか 1 つ以上を含む tweet 1,078,738 件を収集した。

次に、SVM を用いて収集された tweet を「購入報告」と「購入報告でないもの」の 2 つに分類した。学習のため、500 件の投稿を人手でラベル付けした。また学習データのランダムオーバーサンプリングは、Python の不均衡データ用ライブラリである imblearn²内の実装を用いた。研究の再現性のため、RandomOverSampler の乱数を制御するパラメータは 72 で統一した。

続いて、それらの tweet が投稿された日時的前後 27 日を範囲として、同じユーザが投稿した tweet それぞれ最大 500 件を、Twitter のユーザのタイムラインから個別に収集した（これは、

Twitter Streaming API 経由で収集されたデータがサンプリングされているためである）。

投稿のトピックに基づくベクトル化のために、Python のトピックモデリングライブラリである Gensim の LDA の実装を用いた。トピックの次元数は少なすぎるとうまく分散せず、大きく取りすぎると検定で多くの次元で有意差が検出される可能性がある。今回の実装では、次元数は 200 とした。また、1 回の学習あたりに 1 つのコーパスを使用する回数 (passes) は 10 とした。学習に用いた他のパラメータは gensim のデフォルト値を用いた。

4 つの手法を比較するために、あらかじめ 15 個のクエリを用意し、商品購入後に特有な tweet を抽出した。まず、本実験のために、15 個のクエリをあらかじめ人手で作成した。そのために、商品情報サイト「価格.com」の木構造化された商品データから、よく利用されている商品を人手で選定した。なお、「ゲーム」カテゴリのみ、実際のサイト上のデータが木構造でなかったため、人手でサブカテゴリ名をつけ、木構造化した。実際に用いたクエリを表 2 に記す。

4.2 評価対象の手法

提案手法の有用性を評価するために、本実験では 4 つの手法を比較した。提案手法と、2 つの拡張それぞれを比較するための比較手法 2 つ、そしてどちらの拡張も用いないベースライン手法 1 つである。本節では、評価対象とする各手法の詳細について述べる。

4.2.1 提案手法：分類器の適用+クエリ拡張 (SVM + クエリ拡張)

3.2 節で述べた、学習済み分類器による購入報告の抽出、及びクエリ拡張を用いた手法である。今回の実験では、拡張を行った全クエリから収集した投稿 1,078,738 件のうち、抽出できた投稿は 6,531 件であった。この投稿の中から商品購入後に特有な tweet を抽出し、出力した。クエリごとの重み $w(q)$ の値は、商品名そのもの（すなわち、無拡張）の場合は 3.0、その 1 つ上流にあるノードの場合は 2.0、さらにその 1 つ上流にあるノードの場合は 1.0 とした。

4.2.2 比較手法 1：分類器の適用のみ (SVM)

購入報告かどうかの分類のみ行い、クエリの拡張を行わない手法である。すなわち、商品名を直接含む tweet のみを購入報告とみなした。そのため、 $w(q)$ の値は常に 1 とした。

4.2.3 比較手法 2：クエリ拡張のみ (クエリ拡張)

分類器による、購入報告かどうかによるクレンジングを行わず、クエリ拡張のみを行った手法である。提案手法と同様に商品名からなるクエリから、3 段階の拡張を行った。クエリ集合 Q_q 内の語を 1 つ以上含む投稿は 1,078,738 件であった。これらの投稿それぞれから、同じユーザが行った 27 日後までの投稿を、10,241,093 件収集した。

4.2.4 ベースライン手法：拡張なし

SVM によるクレンジングも、クエリ拡張も行わなかった手法である。商品名を直接含む tweet は 178,608 件であり、これらから収集した前後 27 日以内の tweet を 2,821,481 件用いた。

2 : <https://imbalanced-learn.readthedocs.io/>

表 2 実験に用いたクエリ

カテゴリ	サブカテゴリ	シリーズ名	クエリ (商品名)
カメラ	デジタル一眼カメラ	EOS	EOS Kiss α 7
	ミラーレス一眼	α	α 6500 α 6300 α 6000
	ノートパソコン	Surface	Surface Book Surface Pro
パソコン	タブレット PC	iPad	iPad Pro iPad mini
	家電	液晶テレビ	BRAVIA
生活雑貨	万年筆	ラミー 2000	ラミー 2000 L02
	消しゴム	MONO	MONO
		プレイステーション	プレイステーション 4
ゲーム	ゲーム機本体		Nintendo Switch
		Nintendo Switch	Nintendo Switch Lite

4.3 被験者による正解作成

それぞれの手法の有用度を測るため、実際にそれぞれの手法による検索結果の上位 10 件の投稿に対し、3 名の被験者がラベル付けを行った。

被験者は商品名と投稿のペアに対し、「有用度」をラベル付けた。「有用度」は、「実際に商品を購入したユーザにその投稿が有用であるか」を表す。これは、「有用である」、「やや有用である」、「あまり有用でない」、「有用でない」の 4 段階でラベル付けた。

4.4 実験結果

手法ごとの適合率を表 3 に示す。上位 5 件の適合率を表す $p@5$ について、全クエリ平均を見ると、提案手法が最も適合率が高い結果となった。

被験者間の評価者間の一致度を測るために、Fleiss の κ 係数を計算したところ、 $\kappa = 0.22$ であった。 κ の値が 0.21 から 0.40 までである場合には、被験者の意見について「まずまずの一致 (fair agreement)」があるとされる。したがって、本実験の回答結果には、評価者間に偶然以外の理由による、ある程度の一致が存在すると考えられる。

また、各手法において購入後投稿をランキングする際、クエリとの関連度を考慮したランキングを行なった。これについての有用性を評価するため、提案手法によって収集した購入後投稿をランキングする際、関連度を考慮しない場合についても出力結果を他と同様の方法で評価した。これはすなわち、

$$Unique(t_{\text{post}}(q)) = \sqrt[3]{w(q)} \times \sqrt{I_t}$$

としたものである。クエリと tweet の関連度を考慮しない場合、 $p@5$ 、 $p@10$ いずれとも適合率が 0.1 未満まで下がった。

5 考察

実験結果から、提案手法がほかのどの手法よりも、多くの商品購入後にとるべき行動を含む投稿を発見できたことが分かった。各手法がこのような精度になった原因について考察する。はじめに、日用品や普及率が高いと予想される商品カテゴリについて、どの手法とも購入後に特有な投稿を発見しにくかった

傾向が見られた。例えば、「BRAVIA X8500F」という液晶テレビをクエリとした時、どの手法ともテレビについて言及していると思われる購入後投稿が少なく、適合率が低くなった。反対に、「カメラ」などの商品は、多くの場合、提案手法での適合率が高かった。これにより、普及率が高いと思われる商品は買い替えである場合が多く、購入後に有意に増加するトピックが少ないため、購入後投稿を上手くランキングできないことがわかった。

また、「MONO」という消しゴムの商品名をクエリとした場合、2 つ上流の「消しゴム」もクエリとして拡張しても、提案手法での $p@10$ について 0.00 となり、購入後に特有な行動を含む投稿は見つけれなかった。反対に、「ラミー 2000 L02」という万年筆をクエリとした場合、「最近買った万年筆紹介」など、その商品を紹介する投稿が多く見られた。これにより、同じ「文房具」というジャンルに属す商品であっても、商品の普及率によって購入後にその商品について言及している投稿数が増減することが考えられる。

今回の実験において、4 手法の中で、 $p@5$ 、 $p@10$ とも分類器適用の適合率が最も低かった。これは分類器によって購入報告を抽出することで全体の購入後投稿数が減り、有用であるとされる投稿が分析に十分な量収集できなかったためだと考えられる。一方でクエリ拡張手法の $p@k$ に注目すると、相対的に高い値をとっている。これは、クエリ拡張を行うことで購入後投稿数をより多く収集できたことで、購入後にとるべき行動を含む投稿をより正確に発見可能になったためだと考えられる。

また、今回の実験結果では、クエリによって適合率に差があった。クエリ間にて適合率の差が生じた原因として、商品名にクエリとは別の俗称や愛称が存在することが挙げられる。例えば今回の実験において、「プレイステーション 4」というクエリを用いた。「プレイステーション 4」には「PS4」などの略称が存在し、略称をクエリとすることでより多くの購入報告を発見可能である。しかし今回の提案手法では、商品情報サイトのカテゴリツリーに存在する商品名やカテゴリ名からクエリを拡張するため、これらの愛称や略称を含む購入報告を発見できなかった。

6 まとめと今後の課題

本論文では、商品名をクエリとして、その商品を買った際に取るべき現実行動を検索できるアルゴリズムを提案した。このようなアルゴリズムを実現するために、商品情報サイトの商品情報と、マイクロブログ上の商品名を含む投稿を利用した。購入前・後の投稿のトピックの変化を t 検定で分析することで、購入後に優位に投稿内に増加したトピックを抽出した。被験者評価により、実際に検索結果に購入後特有の行動が含まれているか、投稿単位で評価した。結果から、SVM による購入報告の抽出、クエリ拡張、関連度によるランキングをすべて用いた提案手法が最も高精度であることが分かった。今後の課題として、より幅広いクエリに対応できるよう、手法を改善することが挙げられる。今回の手法では日用品や普及率の低い商品につ

表 3 手法ごとの有用度による適合率 (p@k)

クエリ	拡張なし		分類器適用		クエリ拡張		提案手法			
							関連度なし		関連度あり	
	p@5	p@10	p@5	p@10	p@5	p@10	p@5	p@10	p@5	p@10
EOS Kiss	0.60	0.70	0.00	0.00	0.80	0.90	0.20	0.50	1.00	0.90
α 7	0.00	0.00	0.00	0.10	0.80	0.70	0.00	0.00	0.20	0.30
α 6500	0.40	0.40	0.00	0.20	0.60	0.70	0.20	0.10	0.80	0.70
α 6300	1.00	1.00	0.00	0.00	0.20	0.30	0.00	0.00	0.60	0.40
α 6000	0.20	0.00	0.00	0.00	0.40	0.40	0.00	0.00	0.00	0.00
Surface Book	0.20	0.30	0.20	0.20	0.20	0.30	0.00	0.00	1.00	1.00
Surface Pro	0.00	0.00	0.40	0.30	0.20	0.30	0.00	0.00	1.00	0.90
iPad Pro	0.00	0.00	0.00	0.00	0.40	0.70	0.00	0.00	0.80	0.80
iPad mini	0.00	0.00	0.00	0.00	1.00	0.70	0.00	0.00	1.00	1.00
BRAVIA X8500F	0.00	0.00	0.20	0.10	0.80	0.50	0.00	0.00	0.40	0.40
ラミー 2000 L02	0.00	0.10	0.20	0.10	0.00	0.00	0.00	0.00	0.80	0.80
MONO	0.20	0.10	0.00	0.00	0.20	0.50	0.00	0.00	0.00	0.00
プレイステーション 4	1.00	1.00	0.20	0.30	0.80	0.50	0.50	0.00	0.20	0.20
Nintendo Switch	0.00	0.10	0.00	0.00	0.40	0.30	0.00	0.00	0.40	0.20
Nintendo Switch Lite	0.00	0.00	0.00	0.00	0.20	0.30	0.00	0.00	0.40	0.20
平均	0.24	0.25	0.080	0.087	0.47	0.47	0.027	0.040	0.57	0.53

いて、購入後に増加したトピックを十分に発見できず、購入後に特異な投稿が得られなかった。また、手法内で行なったクエリ拡張について、商品情報サイトのカテゴリツリーから拡張を行うため、商品情報サイトに存在しない商品ではクエリを拡張して検索を行うことができなかった。分類器を用いてマイクロブログ上の全ての投稿から購入報告を集め、名詞を抽出し、何を購入した購入報告なのかをクラスタリングすることで、より幅広いクエリから購入後にとるべき行動を含む投稿の検索が可能になると考えられる。

謝 辞

本研究はJSPS 科研費 18K18161 (代表: 莊司慶行), 18H03243 (代表: 田中克己) の助成を受けたものです。ここに記して謝意を表します。

文 献

- [1] 中村健二, 外山諒, 田中成典, 藤本雄紀. EC サイトにおけるユーザの消費関与の分析に関する研究. 日本知能情報ファジィ学会 ファジィ システム シンポジウム 講演論文集, Vol. 33, pp. 507–510, 2017.
- [2] 蝦名亮平, 中村健二, 小柳滋. リアルタイムバースト検出手法の提案. 日本データベース学会和文論文誌, Vol. 9, No. 2, 11 2010.
- [3] 田中克明, 堀浩一, 山本真人. 個人行動履歴に基づく情報推薦システムの開発. 人工知能学会論文誌, Vol. 23, No. 6, pp. 412–423, 2008.
- [4] 敏弘神島. 推薦システムのアルゴリズム (1). 人工知能学会誌, Vol. 22, No. 6, pp. 826–837, nov 2007.
- [5] 梅本和俊, 豊田正史. 実世界での行動に影響を与える情報のソーシャルメディアからの発見. 日本データベース学会和文論文誌, Vol. 16-J, No. 15, 3 2018.
- [6] Tim Althoff, Pranav Jindal, and Jure Leskovec. Online actions with offline impact: How online social networks influence online and offline user behavior. Vol. 2017, pp. 537–546, 02 2017.
- [7] Yehuda Koren. Collaborative filtering with temporal dynamics. Vol. 53, pp. 447–456, 01 2009.
- [8] Frank M. Thiesing and Oliver Vornberger. Forecasting sales using neural networks. In *Computational Intelligence: Theory and Applications - Proceedings of Fifth Fuzzy Days International Conference*, pp. 321–328. Springer-Verlag, 1997.
- [9] Caroline Lo, Dan Frankowski, and Jure Leskovec. Understanding behaviors that lead to purchasing: A case study of pinterest. pp. 531–540, 08 2016.
- [10] J. Sweeney, Geoffrey Soutar, and Tim Mazzarol. Factors influencing word-of-mouth effectiveness: Receiver perspectives. *European Journal of Marketing*, Vol. 42, pp. 334–364, 04 2008.
- [11] Takeshi Sakaki, Makoto Okazaki, and Yutaka Matsuo. Earthquake shakes twitter users: Real-time event detection by social sensors. In *In Proceedings of the Nineteenth International WWW Conference (WWW2010)*. ACM, 2010.
- [12] Ryong Lee and Kazutoshi Sumiya. Measuring geographical regularities of crowd behaviors for twitter-based geo-social event detection. pp. 1–10, 01 2010.
- [13] James Lanagan and Alan Smeaton. Using twitter to detect and tag important events in sports media. 01 2011.
- [14] Mike Thelwall, Kevan Buckley, and Georgios Paltoglou. Sentiment in twitter events. *Journal of the American Society for Information Science and Technology*, Vol. 62, No. 2, pp. 406–418, 2011.
- [15] 河野慎, 米澤拓郎, 中澤仁, 川崎仁嗣, 太田賢, 稲村浩, 徳田英幸. ソーシャルネットワークにおけるフォロー集合分析に基づく実世界イベント分類手法. 情報処理学会論文誌, Vol. 56, No. 1, pp. 72–82, jan 2015.