

再帰型ニューラルネットワークによる消費者の商品探索行動データを用いた購買生起と購買カテゴリの予測に関する研究

大竹恒平*、橋本 鴻**、生田目 崇***

あらまし

近年、消費者の嗜好が多様化し、また消費者が様々な情報をもとに合理的な行動を行うようになってきた。こうした消費者行動の変化は企業のマーケティング活動にも大きく影響を与えている。特に EC サイトにおいては、顧客のニーズに併せた適切な推薦が必須の技術となっているが、その多くは、蓄積されたデータを分析し、閲覧もしくは購買された商品に対する推薦ルールを抽出したものであり、消費者の購買プロセスにおいては必ずしも有効に働くわけではない。たとえば、購買時点に近いのかそうでないのか、また閲覧プロセスにおいて興味の対象が移っているのかといった時点の変化を捉えるためには、時間推移を適切に扱う必要があり、従来の推薦手法では十分に考慮されていない。本論文では、ある EC サイトを対象に購買履歴データとアクセスログデータを用いた購買生起タイミングおよび購買商品カテゴリの2つの観点から消費者行動の予測を行う。具体的には、消費者の閲覧履歴を用い、再帰型ニューラルネットワーク (RNN) による時系列性を考慮した予測モデルの作成を試みる。さらに、本論文では複数の RNN のアルゴリズムを比較し、消費者行動の予測手法としての有効性を評価する。

キーワード：EC サイト、購買生起、購買カテゴリ、再帰型ニューラルネットワーク

I 背景

近年、インターネットは我々の生活に欠かせないものとなっている。総務省によれば、個人のインターネット利用者の割合は 86.2% であり、年代層別にみると 13 ~ 69 歳の各年齢階層で 9 割を上回っている [1]。このようなインターネットの普及を背景に、EC サイト (Electronic Commerce) 市場の拡大が著しい。EC とは、インターネットの通信ネットワークを利用して商品やサービスの販売を行う取引形態であり、EC の取引形態には、企業間取引の BtoB (Business to Business)、企業対個人取引の BtoC (Business to Consumer)、個人間取引の CtoC (Consumer to Consumer) の 3 種類がある。経済産業省によれば、物販系分野の BtoC-EC 市場規模は、安定した成長を続けており、EC 化率も年々上昇傾向にある [2]。また、総務省統計局によれば、2023 年の二人以上の世帯におけるネットショッピングを利用した世帯の割合は 53.5% であり、これは 2002 年の調査開始以来、過去最高水準であることが報告されている [3]。購買チャネルの変化により、消費者の購買行動も多様化しており、その解明が問われている。特に、EC サイトは、多種多様な消費者及び商品を有することが一般的であり、すべての消費者の購買行動を共通のパターンで表現することは適切ではない。

* 上智大学 経済学部, 東京都

連絡先 E-mail : k-otake@sophia.ac.jp

** 日本ビューレット・パッカード株式会社, 東京都

*** 中央大学 理工学部, 東京都

他方で、情報通信技術の進展に伴うデータ取得コストの低下により、企業が取得できるデータは質・量とも増加している。このような背景から、EC サイトでは消費者の行動履歴を取得し、それらのデータに基づいて顧客を管理する仕組みを導入している企業が多い。

EC サイトにおいては、訪問者の閲覧履歴がアクセスログデータとして記録される。顧客の過去の購買履歴を用いた協調フィルタリングに基づく商品推薦は、現在でも数多くの企業で行われているが、最近では、フリマアプリ、旅行など、様々なドメインにおいて、アクセス情報を活用した取組みが盛んに行われている [4], [5]。

II 先行研究ならびに本論文の目的

本論文においては、EC サイトにおける顧客の購買行動に焦点を当てる。EC サイトを対象とした研究としては、サイト上での消費者の探索行動に着目した研究が産学双方で注目されている [6]~[8]。このような先行研究により、消費者が商品を購入するまでの一連の流れ（探索行動プロセス）を利用することが消費者の購買意思決定に影響を与えることが知られるようになった。一方で、マーケティングの分野における購買意思決定に関する研究は、古くから「購買生起」、「商品選択」、「購買量」という3つの観点のいずれかを独立に対象とすることが多い [9], [10]。EC サイトでは実店舗に比べて、商品棚やバックヤードなどの物理的なスペースに関する制限が少ないことから、取り扱う商品カテゴリ数は多いことが一般的である。そのため、特定の商品を購入するために訪問する顧客のみならず、ウィンドウショッピングのように商品を探索する顧客や、特定の商品間の比較を行う顧客など、様々な目的を持って訪問される。また、EC サイトはいつでも顧客が好きなタイミングでアクセスすることができ、実店舗のように営業時間の制約は存在しない。気になった商品をショッピングカートに保存しておき、セールのタイミングを待って購入することも可能である。このことから、実店舗での購買行動に比べて、「衝動買い」「比較検討後の購入」「セールを待っての購入」など、購入機会が多様であることが推察される。以上を踏まえると、EC サイトでの購買行動を解明するためには、「いつ」、「何」を買うか、すなわち購買生起、商品選択の2つの観点が重要であり、EC サイトを対象とした既存の研究においてもこれら2つの観점에着目したものが多い。

岩田らは以下の一連の研究において、インターネット上の購買データを用いた消費者行動の評価、推定モデルを提案している。[11] では、時間順序関係にある購買データの順序関係を考慮した協調フィルタリングを用いたレコメンデーションを行っており、[12] では、時点毎に異なる混合分布を仮定した購買数分布の推定を行っている。さらに [13] は、映画と漫画を対象に、トピックモデルを用いて過去の購買からの顧客の興味推定を行い、次の時点での購買商品の推定を行っている。これらの研究は、顧客の多様性を論じるうえで鍵となる。

他方で、ニューラルネットワークは、その高度な汎用性と学習能力から、画像認識や自然言語処理、音声認識など様々な分野で一貫して高い精度を誇っている。複雑な非線形関係を捉える能力に優れており、従来のモデルでは困難であったパターンの発見や精緻な予測が可能であることから、マーケティング分野においては、購買予測や購買行動評価に用いられている。若林ら [14] は EC サイトを対象に集計された購買履歴及びサイト閲覧履歴の集計データを用いて2次元データを作成し、畳み込みニューラルネットワークモデル (CNN) による購買予測を行っている。新美ら [15] は、購買を含む多様な行動データを深層学習によるモデル化によって購買行動の予測をする試みを行っている。そして、一般化線形モデルと比較しその有用性について検討している。Korpusik ら [16] は、Twitter 上のツイート情報を入力変数としてそこに登場する商品を購入するか否かの判別を再帰型ニューラルネットワークによって行っている。Tweet の関連性の予測値をモデルに入れることで、精度の改善を試みている。Lang ら [17] は RNN により、

観測後7日内の購買生起をRNNで予測するモデルを示している。単純なRNNを用いながらも、セッション情報とイベント発生情報を用いることで従来の多変量解析手法に比べ高い予測精度が得られることを示している。Adelら[18]は、消費者の購買プロセスに焦点を当て、Tweetの内容から各消費者が購買プロセスのどの段階にいるかを推定するために、再帰項と畳み込みを併せたニューラルネットワークを提案しており、一連のTweetデータを用いた分析で高い精度を示していることを明らかにした。Sohiniら[19]は、コスメ、エレクトロニクスの2つのドメインに関するデータセットに対し、ディープラーニング、決定木、サポートベクターマシンなど、様々な機械学習モデルを活用したオンライン購買行動分析を試みた。その結果、従来のイベント情報に基づくモデルに対して、セッションレベルの特徴を考慮したLSTMによるモデルが高い精度で購入予測が可能であること、購買行動に基づくクラスタにより、予測のしやすさが異なることが示された。Diego[20]は、複数の機械学習手法を用いて購入タイミングの予測を試みた。その結果、顧客の過去の購買履歴に関連する変数が、性別や収入、プロモーションや割引などの他の変数と比べ、相対的に購入タイミングの予測に強く寄与することが明らかになった。また、DeepSurvモデルの予測精度が最も高いことが示された。

これらの研究においては、顧客の行動について「いつ」購入するか、もしくは「何」を購入するか、のいずれかの観点での分析を行っている。こうした既存の研究と比べて、本研究ではこれら2つの購買の状況、すなわち購買の「タイミング」と「商品」について同時に扱う点に新規性があると言える。ECサイトではリアルタイムのアクセス情報を取得できる。こうしたデータによって、どの商品をどのくらい閲覧しているのかという消費者の探索行動についても把握することができる。各時点での消費者の行動を評価するためには、こうした情報を随時追わなければ、適切な消費者の状態を把握することが難しい。つまり、消費者の行動を時系列に追った予測が必要であり、個々の消費者の時系列データの特徴を踏まえることで高い精度の消費者購買行動の予測が可能になることが期待できる。本論文では、消費者のECサイト内での行動履歴を元に、各時点での商品の購買意向を購買生起並びに商品選択を捉えることが目的である。

以上をまとめると、本論文ではECサイトのアクセスログデータを用いて、消費者が「いつ」、「何」を買うかという購買生起と商品選択の2つの観点から消費者行動の予測を試みる。具体的には、アクセスログデータをもとに抽出した消費者の探索行動から商品の購買確率を推定し、消費者がどの商品カテゴリーを購買するかを予測すると共にその消費者がどのタイミングで商品を購入するかを予測する。そのために本論文では、2つのモデルを提案し、それぞれのモデルを別々に用いる場合と2つのモデルを併用した際の評価を行う。提案する1つ目のモデルが購買商品カテゴリーの予測モデル、2つ目のモデルが購買生起の予測モデルである。これらのモデルにより、従来では困難であったECサイト上での消費者購買行動の状態を把握することが期待される。

本論文では、特に近年、文章や音声などの系列データに対して多くの成果を挙げている再帰型ニューラルネットワーク(RNN)を用いて、消費者の一連の探索行動を学習する。これは消費者のECサイトにおける閲覧行動(探索行動)を文脈と捉え、商品の閲覧を開始時点から購買に至る一連の行動を時系列データとして扱った解析を行う。モデルの特徴としては、購買商品カテゴリーの予測モデルにより得られた予測値を購買生起の予測モデルの入力の一部として取り入れることで、購買タイミングの精度向上を目指すところにある。これは商品カテゴリーの特徴によって気軽に購入されやすかったり、じっくりと購入するかを吟味する場合があるということを考慮したものである。また、本論文では複数のRNNの求解アルゴリズムを比較し、消費者行動の予測手法としての有効性を評価する。

Ⅲ 本論文で用いる分析手法

本論文では、再帰型ニューラルネットワーク（Re-current Neural Network; RNN）による購買行動の予測を行う [21]。内部に有向閉路を持つニューラルネットワークであり、再帰項によって過去の情報を一時的に保持することができる。この特徴により、RNN は主に文章や音声といった系列データに対して適用されている。

図 1 に RNN の基本的なネットワーク構造を示す。隠れ層を展開すると 2 つの層が存在し、 t 時点の情報だけでなく、 $t-1$ 時点の情報を保持している。 $t-1$ 時点の情報には $t-2$ 時点の情報が含まれるため、結果として過去の情報を時間をさかのぼり保持することになる。前時点の隠れ層を現時点の入力と合わせて学習に用いることで、時系列情報を考慮したネットワーク構造となっている。

RNN は可変な長さ T の系列データ (x_1, \dots, x_T) を入力として受け取る。 t 時点のネットワークへの入力

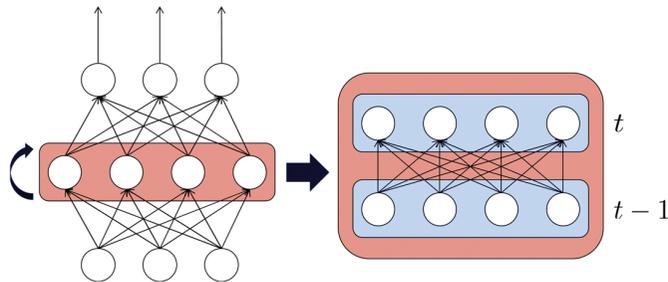


図 1 RNN の基本構造と隠れ層の内部構造

データを x_t とする。隠れ層への入出力を u_t, z_t とし、隠れ層の状態を h_t とする。このとき、RNN の順伝播計算は入力データ x_t と $t-1$ 時点の隠れ層の状態 h_{t-1} のセルから次のように計算することができる。

$$u_t = W_{input} x_t + W_{hidden} h_{t-1} + b \quad (1)$$

$$h_t = \sigma_{hidden}(u_t) \quad (2)$$

$$z_t = W_{out} h_t + b_{out} \quad (3)$$

$$y_t = \sigma_{out}(z_t) \quad (4)$$

W_{input} と W_{hidden}, W_{out} はそれぞれ入力層と隠れ層、出力層における学習重み行列であり、 b と b_{out} は学習バイアスである。また、 σ_{hidden} と σ_{out} は隠れ層と出力層における活性化関数である。隠れ層の状態 h_t は入力された系列データ (x_1, \dots, x_T) から、現時点 t までの情報を得る。これにより、学習開始初期の入力からの情報を時間経過とともに保持できる。

一方で、RNN には勾配消失問題が生じることが知られている。本論文では、勾配消失問題を抑制する 2 つの RNN アーキテクチャを消費者行動の学習に適用する。一つ目は Hochreiter らが提案した LSTM (Long Short-Term Memory) [22] であり、二つ目は Cho らが提案した GRU (Gated Recurrent Unit) [23] である。本論文では、これら 2 つの手法と隠れ層の活性化関数に双曲正接関数を適用した RNN のそれぞれを用いた商品カテゴリと購買生起の予測モデルを作成し、その有効性について比較する。

IV 対象データ

本論文では日本のゴルフ EC サイトのデータを用いる。データは 2014/01/01 ~ 2016/11/30 の期間におけるショッピングページの購買履歴データとアクセスログデータである。

分析で利用する商品カテゴリーは、購買履歴データ内の「クラブ」、「用品・小物」、「ウェア」といった、対象とした EC サイトの定める商品大分類（商品クラス）毎の購買割合が総購買金額に対して 5% 以上の商品カテゴリーに限定した。表 1 に、本論文で対象とした商品カテゴリーを示す。クラブ、用品・小物については 6 商品カテゴリーを、ウェアについては 7 商品カテゴリーを対象とした。

表 1 各商品クラスにおいて対象とした商品カテゴリーの一覧

商品クラス	商品カテゴリー
クラブ	アイアン、ウェッジ、ドライバー、パター、フェアウェイウッド、ユーティリティ
用品・小物	ボール、グローブ、シューズ、ラウンド小物、ティー、ヘッドカバー
ウェア	半袖ポロシャツ、ロングパンツ、ハット、ソックス、アンダーウェア、長袖ポロシャツ、アウターウェア

また、集計データを確認したところ、購買数が突出している一般顧客とは考えられない会員が含まれていることがわかった。こうした会員は、ゴルフ用品事業者などと推察される。これらのユーザは、一般消費者とは逸脱した消費行動をとるため、一般会員の探索行動の学習を行う上でノイズになると考えられる。そこで、本論文においては、累積購買回数並びに累積購買金額について、上限を設けることで、ゴルフ用品業者などの一般顧客とは明らかに異なる購買状況である会員は除くこととした。加えて、本論文においては、セッション単位での探索行動に着目して学習を行うため、学習時の購買が少ない場合、セッションごとのデータに集計すると購買回数が極端に少なくなってしまうことが想定される。そこで、本論文においては、累積購買回数・累積購買金額に関して下限を設けることで、ある程度 EC サイト上で購買を行ったユーザを対象と定める。具体的には、対象商品カテゴリーの累積購買回数が 4 回以上、30 回以下、累積購買金額が 3 万円以上、35 万円以下のユーザを選定した。次に、選定したユーザのアクセスログデータから閲覧履歴を抽出し、セッション回数の分布で上位および下位 5% 未満の会員は分析対象から除いた。

本論文におけるセッション回数とは、購買・非購買を問わずユーザが EC サイトにアクセスしてから離脱するまでを 1 回とした回数を指す。該当 EC サイトにおいては、ユーザのログイン時の情報を保持しており、一定時間が経過するまでの間にアクションを行った場合は、同一のセッション内の行動として記録される。本論文においては、セッション内に購買が行われたセッションを「購買セッション」、購買は行われず商品ページの閲覧だけ行われたセッションを「閲覧セッション」と呼び、区別する。また、購買セッションにおいて購買が行われた回数を「購買回数」、閲覧セッションにおける PV (Page View) が行われた回数を「閲覧回数」と呼ぶ。ここで、PV とは商品カテゴリーについてのページが表示された回数を指す。

これらの処理により選定した 92,748 人を本論文で対象とした。

V 分析モデルの概要

本論文では、消費者が探索行動を経て、購買に至る一連のデータを学習することで、購買商品カテゴリと購買生起をセッション単位で予測する。以下では、購買商品カテゴリの予測モデルをPC (Purchase Category)-model、購買生起の予測モデルをPT (Purchase Timing)-modelと呼ぶ。

5.1 商品カテゴリの予測モデルにおける入力変数

本モデルでは、ユーザがセッション時点において、どの商品カテゴリを選択するかを予測する。PC-modelの入力変数を表2に示す。

表2 商品カテゴリの予測モデルにおける入力変数一覧

変数名	ユニット数
各カテゴリのある閲覧（購買）セッションにおける閲覧（購買）回数	19
各カテゴリの累積購買回数	19
各カテゴリの累積閲覧回数	19
ユーザのデモグラフィック属性	8

表2中における、「各カテゴリのある閲覧（購買）セッションにおける閲覧（購買）回数」と「各カテゴリの累積購買回数」、「各カテゴリの累積閲覧回数」の3つの入力変数については、対象カテゴリ数に合わせて設定する。すなわち、1つのユニットが、「アイアン」や「ボール」といった表1に示した商品カテゴリ名に対応する。「各カテゴリのある閲覧（購買）セッションにおける閲覧（購買）回数」には、基本的にはユーザの閲覧セッションにおいて閲覧を行った回数が入るが、中には購買セッションも含まれる。購買セッションが現時点の学習レコードとなった場合、閲覧回数ではなく、購買したカテゴリについての購買回数となる。

ユーザのデモグラフィック属性については性別と年代に応じたユニットを与えている。性別は男性、女性の2つのユニットを与え、年代は10代以下、20代、30代、40代、50代、60代以上の6つのユニットを与えた計8ユニットとしている。例えば、36歳の男性の場合、男性と30代に対応するユニットに1が入り、他の6つのユニットには0が入る。表2に示した通り、PC-modelにおいては入力変数として全部で65個のユニットを使用するが、出力層には、各対象カテゴリの選択確率を求めるために、表1に示した19個のユニットを出力層に指定する。また、活性化関数にはロジスティックシグモイド関数を使用する。

PC-modelの学習イメージを図2に示す。はじめに、4節で対象と定めた92,748人のユーザについて、全ての閲覧セッション及び購買セッションにおける、商品カテゴリの閲覧回数を集計する。あるユーザの「ある閲覧セッションにおける閲覧回数」が最大だったカテゴリが“iron, iron, driver, driver, iron, putter”という順番であったとする。その後、ある時点で“iron”を購買したとする。各セッションにおいて、表2の入力を与えたとき、次のセッションにおける閲覧回数が最大のカテゴリを正解ラベルとして与える。図の場合、入力時、“iron, iron, driver, driver, iron, putter”となり、正解ラベルは“iron, driver, driver, iron, putter, iron”となる。ただし、該当するセッションが購買セッションであった場合は、同一セッション内で購買が行われた全ての商品カテゴリについて、正解ラベルを付与することとした。

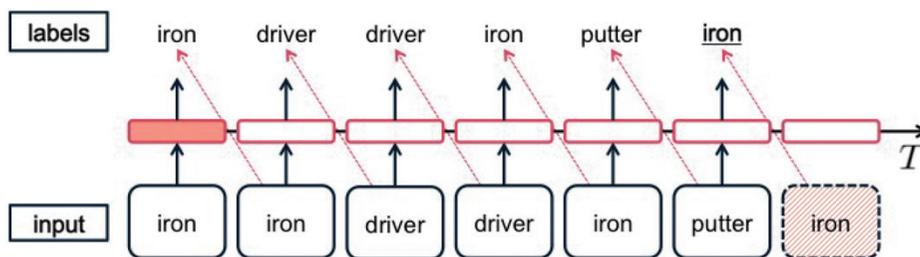


図2 PC-modelの学習イメージ

5.2 購買生起の予測モデルにおける入力変数

本モデルでは、ユーザがセッション内で購買するか、しないかという購買生起を予測する。PT-modelの入力変数を表3に示す。入力変数の「購買セッション」は学習時のレコードが購買セッションのレコードである場合は1、閲覧セッションの場合は0が入っている。また、入力変数の「PC-modelの出力値」はPC-modelからの出力値、すなわち各カテゴリーの購買されやすさをPT-modelの入力変数として使用することを意味している。

表3 購買生起の予測モデルにおける入力変数一覧

変数名	ユニット数
購買セッション (購買または非購買)	2
PC-modelの出力値	19

PC-modelの出力値はユーザごと、そして各ユーザのセッションごとに得られる。これは各ユーザのセッションごとの商品カテゴリーに対する出力である。言い換えるならば、ある時点でユーザが探索行動を通じ、どの商品カテゴリーに興味をもっているかの結果である。このデータを購買生起の予測を目的としたPT-modelの入力変数とすることで、購買生起を的確に予測することができる。PT-modelにおける出力層のユニット数は、購買または非購買の2個のユニットを出力層に指定する。また、活性化関数にはソフトマックス関数を使用する。

以下にPT-modelが「PC-modelの出力値」を使用して、学習するイメージを図3に示す。PT-model自体の学習は図2と同様であり、カテゴリーを予測するのではなく、購買セッションか、閲覧セッションが記録された系列データを学習する。

図3のミニバッチデータはバッチサイズが4の場合を想定した図になっている。各ユーザの行動履歴の長さが異なる可変長データが入っている。はじめに、PC-modelの学習からスタートする。学習に使用するのは、表2に示した「各カテゴリーのある閲覧(購買)セッションにおける閲覧(購買)回数」、「各カテゴリーの累積購買回数」、「各カテゴリーの累積閲覧回数」に関する65個のユニットである。ミニバッチの学習が終了した時点でミニバッチデータと同じ大きさの出力値が得られる。具体的には、1に示した19の商品カテゴリーに関する値が出力される。ここまでが、PT-modelについての学習のイメージとなる。本論文ではミニバッチ学習を採用しており、上記の流れを繰り返して、PC-modelとPT-modelの学習を行う。

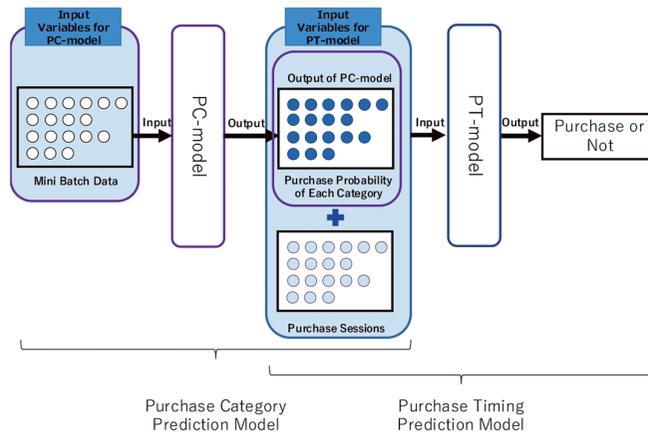


図3 PT-modelがPC-modelの出力を使用して、学習するイメージ

5.3 ネットワークモデルの概要と学習方法

本論文では3節で述べた、LSTM [22]、GRU [23] 並びに、隠れ層の活性化関数に双曲線正接関数を適用したRNNの3つのRNNのアーキテクチャを用いた予測モデルを作成し、予測精度を比較する。本節では前述の3つの手法を順に「LSTM」「GRU」「RNN」と表記する。その際に、PC-model、PT-modelは同じRNNアーキテクチャを使用した場合を1つのセットとする。すなわち、異なるRNNアーキテクチャを用いて作成した予測モデル同士を組み合わせることはしない。作成したネットワークの設定を表4に示す。ミニバッチ学習ではバッチサイズを1000とする。なお、本論文では分析対象ユーザ92,748人を訓練データ：検証データ：テストデータ = 8:1:1の割合に分割した。また、本分析では隠れ層のレイヤー数とAdam [24]のパラメータ α 、隠れ層のドロップアウト率について複数のケースを設けて学習を行う。隠れ層のレイヤー数については1, 2, 3, 最適化手法Adamのパラメータ α は0.001, 0.01, 0.2, 0.5, 隠れ層のドロップアウト率は0.0, 0.2, 0.5とそれぞれのパターンを用意する。これらのパラメータのすべての組合せ、 $3 \times 4 \times 3 = 36$ 通りについて結果を比較する。

表4 ネットワークモデルの概要

	ネットワークの設定
隠れユニット数	100
損失関数	交差エントロピー誤差
最適化手法	Adam
学習方法	ミニバッチ学習
エポック数	20

VI 結果と考察

本節では、作成したモデルに関する評価並びにモデルの考察を行う。

6.1 作成したモデルの評価

上記の36通りのパラメータの組合せで学習した場合のPC-modelの検証データに対する正答率を比較する。なお、PC-modelでは、次のセッションの閲覧及び購買商品カテゴリに対して、RNNの出力値の上位3つのカテゴリを予測リストとして与え、そのうちのどれか一つでも正解ラベルに含まれていれば正解として、正答率を計算する。複数カテゴリが正解の場合でも同様である。近年では、数多くのECサイトにおいて、購買者の閲覧履歴に基づく商品推薦が行われている。推薦対象に定める数については、取り扱う商品や価格帯によって異なるが、概ね3~5の商品が推薦されるのが一般的である。対象としたECサイトにおいては、データ期間において協調フィルタリング並びにコンテンツベースフィルタリングに基づき、5つの商品が推薦されている。ただし、本論文で対象としたECサイトの分析官とのディスカッションにおいて、実態としては上位3つの商品の閲覧が多いことがわかっている。本論文においては、上記の状況を加味し予測リスト数を3とした。また、一つでも実際に購買された商品が含まれた場合に正解とした理由は、一つには、実際のウェブサイトでは少数の推薦リストが表示され、顧客はそのうちから一つのみ選択(クリック)できることが挙げられる。また、本論文で対象としたECサイトでは、一時点において複数商品を購入する割合は高くないことから、よく用いられる評価指標である推薦リストの中で実際に購買された商品数を正答率とする場合には、推薦数を増やせば増やすほど正答率が下がってしまうという問題があるからである。なお、予測リスト数を1から18まで変化させた場合については後述とする。その際、勾配消失が起きたケースを除き、前節で示した3つの手法であるLSTM、GRU、RNNの学習済みモデルに対して検証データを当てはめ、正答率が他の2手法よりも高かった場合の数を集計する。また、隠れ層のレイヤー数が1層の場合にういつてはテストデータに対して正答率を算出し、同様にテストデータに対する正答率が他の2手法よりも高かった場合の数を集計し、表5にまとめる。

表5 PC-modelの正答率が他の2手法よりも高かったケース数

	LSTM	GRU	RNN
検証データ	16	13	4
テストデータ	8	3	0

表5より、PC-modelにおいてはLSTMが安定して高い精度を得ていることが分かる。LSTMは内部にメモリセルと呼ばれる長期記憶のためのセルを有しており、消費者の探索行動と考えられる過去の一連の情報を保持しやすい仕組みとなっているためと考えられる。このような仕組みを持ったネットワーク手法で探索行動を学習することが、商品カテゴリの予測を行う上で有効であると考えられる。精度については、LSTMで隠れ層のレイヤー数が1、Adamのパラメータ α が0.01、ドロップアウト率が0.5の場合、検証データに対する正答率が61.9%、テストデータに対する正答率が65.3%であった。

次に、商品カテゴリの予測モデル(PC-model)において、出力値の上位1つのカテゴリのみ予測リストに加えた場合や、対象カテゴリ数に近い上位18個の出力値を予測リストに加えた場合など、予測リストの

数に応じた正答率を示す。また、予測リスト数でランダムに商品カテゴリを選択した場合との比較を行う。

図4にPC-modelにおいて予測リストの数を変化させた場合の正答率の変化について示す。図4では、赤い曲線がPC-modelの予測リスト数を変化させたときの正答率を示しており、青い直線が予測リスト数でランダムに選択した際の正答率を示している。PC-modelは予測リストが増加するにつれて、対数関数のような推移を示しながら、正答率が増加している。また、予測リスト数に関わらず、ランダムな選択よりも常にはるかに高い正答率を示している。上位3カテゴリでおよそ50%の正答率を示しており、PC-modelは消費者の探索行動からパターンを学習し、商品カテゴリを予測できているといえる。

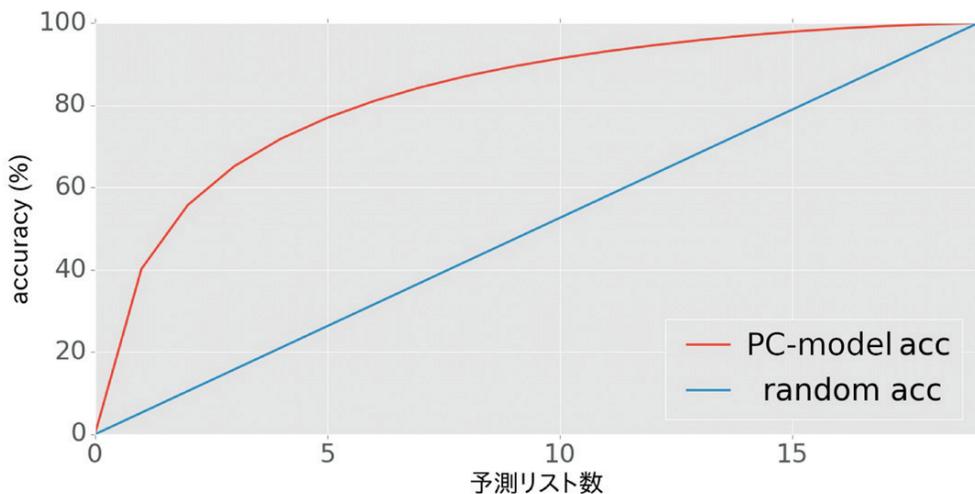


図4 PC-modelの予測リスト数に応じた正答率の変化

次に、PT-modelの購買確率について検討する。本来の2値分類の問題では閾値を0.5に設定して購買・非購買を判定すると考えられるが、購買・非購買のデータの割合が異なることに加え、購買生起を判定する上で明確な指標が存在するわけではない。購買生起の予測モデル(PT-model)の学習に用いたデータには、非購買データの割合が多い。そのため、多くのケースにおいて、非購買の出力ユニットの出力値が大きくなる傾向にあることから、通常のソフトマックス関数を適用した場合は、ほとんどが非購買と予測してしまう。そこで本論文では、購買及び非購買の2つの出力値に対して、活性化関数のソフトマックス関数を適用する。ソフトマックス関数を2つの出力ユニットに対して適用することで、2つの出力値を確率値に変換することができる。加えて、2つのモデルを併用した場合の評価を行うために、PT-modelが購買と予測する際の購買確率について、購買と判定する閾値を複数の場合にパラメトリックに変化させて精度を比較することで、購買と予測する閾値をどの値に設定するか検討する。具体的には、正答率の他に適合率、再現率、F値を算出することで2つのモデルを併用した際に用いる妥当な購買確率の閾値を検討する。

図5にPT-modelの出力値に対してソフトマックス関数を適用した場合の結果を示す。ここでは、LSTMを用いて、隠れ層のレイヤー数が1、Adamのパラメータ α が0.01、ドロップアウト率が0.5の設定で学習したモデルを使用する。

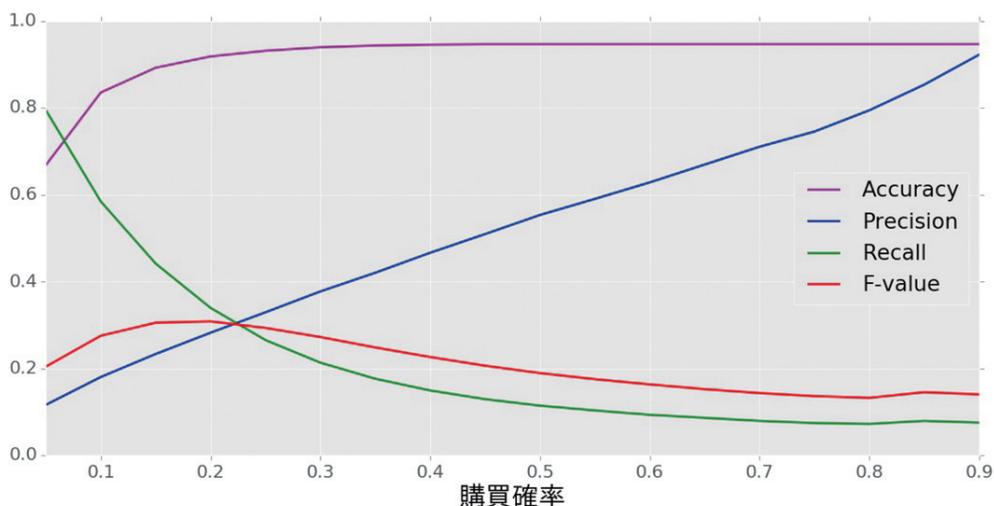


図5 PT-modelの購買確率の閾値に応じた正答率、適合率、再現率、F値の変化

図5では、異なる購買確率の閾値による正答率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、F値 (F-value) の違いを示している。正答率に着目すると、図5から、購買確率の閾値が0.05の場合、正答率が約67%となっている。また、購買確率の閾値が増加すると徐々に正答率が増加している。このことから閾値が低い場合、出力ユニットが購買と予測する数が増えるため、非購買のデータに対して購買と予測しているケースが多いことが考えられる。また、適合率と再現率に着目すると、購買ユニットの購買確率の閾値の変化に応じて、適合率は増加し、再現率は減少している。したがってPT-modelにおいて、適合率と再現率の間にトレードオフ関係があることが確認できた。

このトレードオフ関係を考慮するためにF値に着目する。図5より、閾値が0から0.2に向かうにつれてF値は0.309まで増加し、0.2より閾値を大きくする徐々にF値は減少している。F値は適合率と再現率のトレードオフ関係を考慮した総合的な評価指標であることから、本論文では、購買生起の予測モデル (PT-model) の閾値をF値が最大となった0.2とする。

6.2 2つのモデルを併用した消費者行動の予測精度の評価

以下の4つのシチュエーションを考え、PC-model (購買商品カテゴリーの予測モデル) とPT-model (購買生起の予測モデル) の2つを併用した際の評価を行う。

- (1) どちらのモデルも正解した場合 (S1)
- (2) PC-modelは不正解だったが、PT-modelは正解だった場合 (S2)
- (3) PC-modelは正解したが、PT-modelは不正解だった場合 (S3)
- (4) どちらのモデルも不正解だった場合 (S4)

(5)~(8) 式にそれぞれの計算式を示す。ただし、TPおよびFNはPT-modelの予測結果についての混同行列における True Positive、False Negative であり、4つのシチュエーションの分母は購買セッション数 (85,204) となる。また、式中の「PC-model_correct」は、PC-modelによる出力値 (各カテゴリーの選択確率) の上位3つのカテゴリーが入った予測リストに、実際に購買されたカテゴリーが含まれていたケースを指す。

反対に、「PC-model_incorrect」は、PC-modelによる出力値（各カテゴリの選択確率）の上位3つのカテゴリが入った予測リストに、実際に購買されたカテゴリが含まれていなかったケースを指す。

$$S1 = \frac{TP \cap PC\text{-model_correct}}{TP + FN} \quad (5)$$

$$S2 = \frac{TP \cap PC\text{-model_incorrect}}{TP + FN} \quad (6)$$

$$S3 = \frac{FN \cap PC\text{-model_correct}}{TP + FN} \quad (7)$$

$$S4 = \frac{FN \cap PC\text{-model_incorrect}}{TP + FN} \quad (8)$$

テストデータの購買セッションにおけるすべてのテストデータに対して予測を行った際の4つのシチュエーションの割合を算出する。前述の通り、PC-modelでは予測値の上位3つを予測リストとして使用する。PT-modelではF値などを参考に購買ユニットの購買確率が0.2を超えた場合は購買と判定し、0.2未満の場合は非購買と判定する。表6に評価した85,204の購買セッションの結果について、上記4つのシチュエーションの割合を示す。

表6 S1～S4の割合

シチュエーション	割合 (%)
S1	31.85
S2	0.26
S3	65.81
S4	2.08

表6より、本論文で目的としているS1は31.85%と購買セッションにおいて約3分の1を占めた。また、S2は0.26%と非常に小さい値となった。一方で、S3は65.81%と購買セッションにおいて約3分の2を占めている。S1とS3で全ケースの大半を占めており、購買セッションにおいてPC-modelは高い正答率であり、購買セッションにおける商品カテゴリの予測モデル(PC-model)は85,204の購買セッションのうち、83,205のセッション(約98%)における商品カテゴリを適切に予測することができた。一方で、PT-modelについては、85,204の購買セッションのうち、27,357のセッションを購買と予測した。これは、約32.1%の確率で購買生起を予測したこととなり、図5の購買確率0.2の場合の再現率とほぼ等しい。

また、図6は購買商品カテゴリをS1の割合が大きいカテゴリの順番で並び替えたグラフである。この図より、PC-modelとPT-modelを併用した場合に当てることができるカテゴリは“tee”や“socks”、“gloves”など、用品・小物やウェアといった比較的安価で、買い替え頻度の高い消耗品に関する商品カテゴリが多いことがわかる。一方で、PC-modelとPT-modelを併用した場合に当てることが難しいカテゴリとしては“driver”や“iron”、“putter”などゴルフクラブ類を中心とした比較的高価で、耐久性の高い商品カテゴリであることがわかる。ゴルフクラブなどの高価格帯の商品は、一般的に計画購買が多い。計画購買を行う際には、サイト内での類似商品の比較・検討といった、サイト内の探索行動が多くなること、

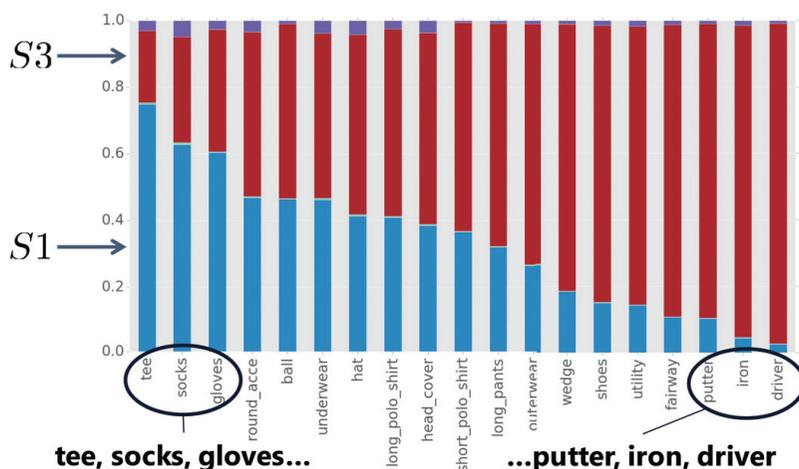


図6 各商品カテゴリにおけるシチュエーション別の帯グラフ

計画期間が長期間にわたることが推察される。購買に踏み切るまでに閲覧時間やセッション数が多くなるため、PT-modelが購買と予測するセッションも多くなる。そのため、S3の割合が大きくなり、S1の割合は小さくなることが考えられる。

VII まとめと今後の課題

本論文では、ECサイトのアクセスログデータを用いて、消費者が「いつ」、「何を」購入するかという購買生起と商品選択の2つの観点を同時に考慮した消費者行動の予測を試みた。そして、近年、時系列データの特徴を踏まえた予測手法として注目を集めているRNNを用いて、購買商品カテゴリの予測モデルと購買生起の予測モデルの2つを作成した。

精度の観点からは、GRU、隠れ層の活性化関数に双曲線正接関数を適用したRNNに比べて、LSTMを用いる方が消費者行動を学習する上で有効であった。また、学習の際に設定するパラメータについては隠れ層のレイヤー数が2,3の場合やAdamのパラメータ α が0.2, 0.5と大きい場合は勾配消失を引き起こすリスクが高いことが分かった。

商品カテゴリの予測結果を比較すると、PC-modelが消費者の探索行動からパターンを学習し、商品カテゴリを高い精度で予測できていることが分かる。また、購買生起の予測モデル(PT-model)はF値による評価を行い、2つのモデルを併用する場合に用いる最適な購買確率の閾値について検討を行った。

2つのモデルを併用した場合には実際の購買セッションのうち、両方とも正解である割合は約3分の1となり、商品カテゴリのみ正解だった場合は約3分の2であった。このことから、商品カテゴリの予測モデル(PC-model)は高い精度で購買商品カテゴリを予測するができた。しかし、購買生起の予測モデル(PT-model)について入力変数を工夫する、もしくはは閾値の設定を再設定するなどすることによる精度の改善も望まれる。こうした工夫と経て、商品カテゴリと時点の両者とも正しく予測できる割合を増加させることが期待できる。また、本論文では予測そのものに焦点を当てたが、例えばattention[25]を利用することで、隠れ層の挙動を評価し消費者がどのような情報探索、選択を行っているのかといった、意識構造を明らかにすることも今後の課題である。

謝辞

本研究にあたり、EC サイト事業者からデータの提供並びに有益なコメントを数多くいただいた。謝意を表したい。

文献

- [1] 総務省情報通信統計データベース, 「通信利用動向調査」, <https://www.soumu.go.jp/johotsusintokei/statistics/statistics05.html>, 参照 Jan. 30, 2025.
- [2] 経済産業省, 「令和5年度電子商取引に関する市場調査報告書」, <https://www.meti.go.jp/press/2024/09/20240925001/20240925001-1.pdf>, 参照 Jan. 30, 2025.
- [3] 総務省統計局, 「2023年家計消費状況調査結果の概況」, <https://www.stat.go.jp/data/joukyou/2023ar/gaikyou/pdf/gkall.pdf>, 参照 Jan. 30, 2025.
- [4] 「協調フィルタリングとベクトル検索エンジンを利用した商品推薦精度改善の試み」, https://engineering.mercari.com/blog/entry/20230612-cf-similar-item/?utm_source=chatgpt.com, 参照 Jan. 30, 2025.
- [5] 「観光産業に特化したウェブ解析ツールで出来ることとは?」, https://www.travelvoice.jp/20230929-154270?utm_source=chatgpt.com, 参照 Jan. 30, 2025.
- [6] 小池雄平, 菅谷健人, 住田潮, 高橋一樹, 平野智章, 山本浩平, “アクセスログデータに基づく重要顧客の‘リアルタイム’判別,” Department of Social Systems and Management Discussion Paper Series, no.117, University of Tsukuba, 2007.
- [7] 石井久治, 市川祐介, 佐藤宏之, 小林透, “Web アクセスログからのパターンマイニングによる購買行動の推定,” 信学技報. LOIS, ライフインテリジェンスとオフィス情報システム, vol. 109, no. 272, pp. 89-94, 2009.
- [8] 久松俊道, 外川隆司, 朝日弓未, 生田目崇, “EC サイトにおける購買予兆発見モデルの提案,” オペレーションズ・リサーチ, vol. 58, no. 2, pp. 93-100, 2013.
- [9] C. F. Mela, K. Jedidi and D. Bowman, “The Long-Term Impact of Promotions on Consumer Stockpiling Behavior,” *Journal of Marketing Research*, vol. 35, no. 2, pp. 250-262, 1998.
- [10] R. E. Bucklin, and S. Gupta, “Brand Choice, Purchase Incidence and Segmentation: An Integrated Modeling Approach,” *J. of Marketing Re.*, vol. 29, no. 2, pp. 201-215, 1992.
- [11] 岩田具治, 山田武士, 上田修巧, “購買順序を効率的に用いた協調フィルタリング,” 情処学論: 数理モデル化と応用, vol. 49, pp. 125-134, 2008.
- [12] 岩田具治, 田中利率, 山田武士, 上田修功, “分布が変化するデータにおけるモデル学習法,” 信学論 (D), vol. J92-D, no. 3, pp. 361-370, 2009.
- [13] 岩田具治, 渡部晋治, 山田武士, 上田修功, “購買行動解析のためのトピック追跡モデル,” 信学論 (D), vol. J93-D, no. 6, pp. 978-987, 2010.
- [14] 若林憲人, 生田目崇, “消費者の購買行動に対するディープラーニングの適用可能性の検討,” 日本ソーシャルデータサイエンス学会論文誌, vol. 1, no. 1, pp. 48-57, 2016.
- [15] 新美潤一郎, 星野崇宏, “顧客行動の多様性変数を利用した購買行動の予測: Deep Learning を応用した実店舗・Web・モバイルの多面的な分析,” 人工知能誌, vol. 32, issue 2, pp. B-G63_1-9, 2017
- [16] M. Korpusik, S. Sakaki, F. Chen, Y.-Y. Chen, “Re-current Neural Networks for Customer Purchase

- Prediction on Twitter,” Proceedings of the 10th ACM Conference on Recommender Systems, pp. 47-50, 2016.
- [17] T. Lang and M. Rettenmeier, “Understanding Consumer Behavior with Recurrent Neural Networks,” Proceeding of the International Workshop on Machine Learning Methods for Recommender Systems, 8 pages, 2017.
- [18] H. Adel, F. Chen and Y.-Y. Chen, “Ranking Convolutional Recurrent Neural Networks for Purchase Stage Identification on Imbalanced Twitter Data,” Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, vol. 2, pp. 592-598, 2017.
- [19] R. Sohini, A. Ebrahim and L. Wenxi, “OPAM: Online Purchasing-behavior Analysis using Machine learning,” 2021 International Joint Conference on Neural Networks (IJCNN), Shenzhen, China, pp. 1-8, doi: 10.1109/IJCNN52387.2021.9533658., 2021.
- [20] V. Diego, “Buy When? Survival Machine Learning Model Comparison for Purchase Timing,” <https://ssrn.com/abstract=4553680>, 16 pages, 2023.
- [21] Y. Bengio, R. Ducharme, P. Vincent and C. Jauvin, “A Neural Probabilistic Language Models,” Journal of Machine Learning Res., vol. 3, pp.1137-1155, 2006.
- [22] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” Neural Computation, vol. 9, no. 8, pp. 1735- 1780, 1997.
- [23] K. Cho, B. Merriënboer, C. Gulcehre, F. Bougares, H. Schwenk, and Y. Bengio, “Learning Phrase Representations using RNN Encoder-decoder for Statistical Machine Translation,” arXiv:1406.1078, 15 pages, 2014.
- [24] D. P. Kingma and J. L. Ba, “Adam: A Method for Stochastic Optimization,” arXiv:1412.6980 [cs.LG], 2014.
- [25] M.-T. Luong, H. Pham and C. D. Manning “Effective Approaches to Attention-based Neural Machine Translation,” Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, pp.1412-142, 2015.