

商店を直線表現した TransRec モデルに基づく 電子商店街の商品推薦アルゴリズム

大堀 祐一^{1,a)} 楊 添翔^{1,b)} 山下 遥^{2,c)} 後藤 正幸^{1,d)}

受付日 2020年4月21日, 採録日 2020年11月5日

概要: 近年, 商品と消費者の嗜好の多様化を受け, 自動で顧客 (ユーザ) の嗜好に合致した商品 (アイテム) を提示する推薦システムの重要性が高まっている. 過去の購買履歴データを学習し, 個々のユーザに対して推薦アイテムを提示するための推薦ロジックには様々な方法が提案されているが, 近年では分散表現に基づく手法が目立っている. なかでも, 各顧客の購買順序も考慮した分散表現モデルである TransRec は, 各顧客の商品購買の時間的関係性に基づいて推薦アイテムを決定することができる. 一方, EC サイトの一形態として, 電子商店街 (ショッピングモール型 EC サイト) も一般的となり, 多くの消費者から利用されるようになった. 多数の商店からなる電子商店街では, 単一の小売企業による EC サイトとは異なり, ユーザは商店内のページを閲覧し, 販売されているアイテムのなかから購買を行うことが可能となっている. このような電子商店街の購買履歴データに対して TransRec をそのまま適用した場合, 商店の違いを考慮しないため, ユーザの商店に対する嗜好を十分に反映した推薦が困難になってしまう. そこで, 本研究では, TransRec におけるアイテムベクトルの学習に購買順序の遷移だけでなく, 商店が与えられたもとでのユーザの嗜好を考慮したモデルの構築を目的とする. その際, 商品やユーザと同様に, 商店を埋め込み空間上の点で表現しようとする, 顧客の購買行動を表現することが難しくなってしまうという問題が生じる. そこで, 本研究では, 商店を埋め込み空間上の直線 (ベクトル方程式) で表現し, ユーザによるアイテムの購買行動を点から直線への垂線によって表現するモデルを提案する. この方法により, 電子商店街における個々の商店特性を考慮したアイテムの推薦が可能となり, ユーザの購買確率が高いアイテムの予測精度の向上が期待できる. 本研究では, さらに楽天市場レビューデータを購買データと見なし用いた分析実験を通じ, 提案モデルによる分析の結果を考察するとともにその有用性を示す.

キーワード: 推薦システム, TransRec, Web マーケティング, 埋め込み表現

An Item Recommendation Algorithm on a Cyber Mall Based on TransRec Model Representing Stores by Linear Lines

YUICHI OHORI^{1,a)} TIANXIANG YANG^{1,b)} HARUKA YAMASHITA^{2,c)} MASAYUKI GOTO^{1,d)}

Received: April 21, 2020, Accepted: November 5, 2020

Abstract: In recent years, huge number of items are sold in EC sites, and the preference of consumers are become diversified. Therefore, the recommender system that enables the recommendation of items that suit the preference of each consumer has become more important. On the purchase activities of consumers, purchase of each item is considered to have a temporal relationship, and it is desirable to consider the user's purchase order when determining recommended items. Due to the above reason, this study focuses on the recommender model based on TransRec that can consider the order of purchasing actions. The EC sites called cyber malls, on which many stores open their shop pages on a site and sell items on there, is becoming popular. TransRec can be directly applied to this purchase history data; however, the store information may affect the user's preference on a cyber mall and it is difficult to reflect the difference of characteristics between shops for the estimation of users' preference for items sold in the shops. Therefore, in this study, we propose an improved TransRec considering store information. The proposed TransRec based model considers not only the transition of temporal relationship of purchase, but also the user's preference of the item sold on each shop in the cyber mall. The model is expected to improve the purchase prediction accuracy of items that are likely to be purchased by each consumer. Furthermore, we show the consideration of the analysis result and usefulness of the proposed model through the experiments using real-world review data of Rakuten Ichiba assuming as the purchase history data.

Keywords: recommender systems, TransRec, Web marketing, embedding propagation

1. はじめに

近年、電子商取引サイト（Electronic Commerce サイト；以下、EC サイト）上では大量の商品（アイテム）が扱われるようになり、消費者は、実店舗では不可能なレベルの種類数のアイテムにアクセスする手段を獲得している。これにともない、消費者の嗜好もますます多様化し、自動で各顧客の嗜好に合致した商品の提示を可能とする推薦システム [1] の重要性が高まっている。

推薦するアイテムを自動決定する枠組みとしては、アイテムの特徴を用いた協調フィルタリング [2], [3], [4], [5], [6] がよく知られている。協調フィルタリングのためのモデルとして、潜在クラスモデルをベースとしたモデル [7], [8], [9], [10], [11], 行列分解によるモデル [14], [15], ベイズ分類器を用いたモデル [12], [13] など様々な方法が提案されている。さらに Word2Vec [16] に代表される埋め込み表現モデル（Embedding model）に基づきユーザの購買履歴データを学習して得られるアイテムやユーザの関係性を特徴空間上に埋め込むアプローチが有効であることが指摘されており [17], 推薦アイテムの決定に活用されている。ここで、ユーザの直近の購買順序も考える必要があるという立場から、埋め込み空間上にアイテムとユーザを点（ベクトル）で表現し、あるアイテムを買った後に、次に買うアイテムを選択する際の嗜好をベクトルで表現している Translation-based Recommendation（以下、TransRec）[18] が提案され、ユーザが最後に買ったアイテムから、次に買う可能性の高いアイテムを推薦することが可能となっている。本研究では、この TransRec を用いて電子商店街の購買履歴データにおける推薦システムのための分析を行うことを考える。

電子商店街とは、複数の企業や個人商店が出店する形態のショッピングモール型 EC サイトであり、広く利用されるようになっている。電子商店街では、サイト運営企業は多数の電子商店が出店可能なサイト全体の運営と出店者の管理を行い、そして出店者（商店主）はサイト上に商店ページをオープンして、それぞれの商店が商品販売を行う形式となっている。この電子商店街の購買履歴データに対しても TransRec をそのまま適用することは可能である。しかし、ユーザによっては特定の商店を特に好み、その商店ページを中心に購買を行うというケースも多い。そのため、ユーザにとってアイテムに対する嗜好は、そのアイテムを取り扱っている商店により異なることが考えられる。

すなわち購買履歴データのみで学習を行ったモデルでは、商店による商品に対する嗜好の近いを十分に学習できないため、そのユーザに合致した商品の推薦が難しい。

そこで本研究では、ユーザの電子商店街における嗜好を推薦に反映させるため、商店情報を考慮した TransRec モデルを構築することを目的とする。そのために“商店の嗜好”と“商店が与えられたもとのアイテムに対する嗜好”との関係を、TransRec における購買アイテムの遷移に付け加えることにより、アイテムベクトルの学習に商店のもとのユーザの嗜好も反映させる。このとき、商店はアイテムに対して種類数が少なく出現頻度が高いため、商店をベクトルで表現しようとしても表現力が足りず、推薦システムへの活用に耐えうるモデルの構築が難しい。そこで、本研究では、商店を1つのベクトルで表される点ではなく直線（ベクトル方程式）で表現する方法を提案する。この方法は、従来手法によってモデル化されるユーザの嗜好を実際の電子商店街におけるユーザの嗜好に近づけることを可能とし、予測精度の向上が期待される。本研究では、さらに、楽天市場レビューデータを購買データと見なして用いた分析実験を通じ、提案モデルによる分析の結果を考察するとともにその有用性を示す。

2. 準備

2.1 推薦システム

推薦システム（Recommender system）[2] とは、利用者にとって有用と思われる対象、情報、または商品などを選び出し、それらを利用者の目的に合わせた形で提示するシステムである。本来の推薦システムは、「情報過多」[19] な状況に対応するため、利用者にとって有用な情報を見つけ出すシステムとして考案された。すなわち、推薦システムは、ユーザの意思決定を支援するためのシステムと解釈される。現在では、推薦システムは多方面で利用されるようになっている。Amazon.com [20], 楽天市場 [21] などの電子商取引サイト（EC サイト）や YouTube [22] などの動画投稿サイトが推薦システム活用している。

本研究では、電子商取引サイトにおいてアイテムを推薦するためのシステムに着目する。この方法により購買予測の精度の向上を実現し、ユーザにより適した推薦を可能とすることが期待される。

2.2 推薦システムにおける次元縮約と埋め込み表現

EC サイトなどにおいて蓄積される購買履歴データは、アイテム、ユーザの種類数およびそのデータの数が莫大である。そのため、購買履歴データを用いてそのまま推薦システムへと活用する場合、推薦するアイテムを決定するために膨大な計算時間が必要となる。そこで、アイテムやユーザを低次元のベクトルで表現することにより、計算時間を削減しながら精度の良い推薦を可能とするための研究 [23]

¹ 早稲田大学
Waseda University, Shinjuku, Tokyo 169–8555, Japan

² 上智大学
Sophia University, Chiyoda, Tokyo 102–8554, Japan

a) ohorry-you1@ruri.waseda.jp

b) you.tensyou@akane.waseda.jp

c) h-yamashita-1g8@sophia.ac.jp

d) masagoto@waseda.jp

が行われ、特にユーザが購買したアイテムのデータ行列を低次元の行列の積として表現する行列因子分解 [23] を用いた方法が提案されてきた。

一方、大量のデータを用いてデータどうしの関係から特徴空間を構成し、データをその空間に埋め込むことでデータを低ランク近似同様にアイテムやユーザを低次元ベクトルで表現するモデルである Word2Vec [24] などの埋め込み表現モデルが注目を集めている。埋め込み表現モデルでは、埋め込み空間を学習する際に購買されたアイテムの予測購買確率が未購入のアイテムよりも高くなるようにパラメータを調整することができる。さらに、購買の順序を考慮しつつ購買確率の高いアイテムの埋め込み表現を学習するための方法 Translation-based Recommendation [18] が提案されている。本研究ではこの埋め込み空間モデルに着目する。

2.3 Translation-based Recommendation [18]

TransRec とは、アイテムとユーザの嗜好を同一空間（埋め込み空間）上のベクトルとしたときに、最後にユーザが買ったアイテムとユーザの嗜好ベクトルの和と距離が近く、かつ人気度が高いアイテムの推薦を可能とする手法である。このモデルは購買には順序があるということを仮定しており、ユーザが買ったアイテムに応じて推薦アイテムを決定することができる。たとえば、TransRec では全体的にはよく食品全般を購買しているユーザであっても、直近ではペット用品の購買頻度が上がっていた場合、その人が今現在、購買意欲が上がっているであろうペット用品を推薦する。

2.3.1 変数定義

ユーザを $u \in \mathcal{U}$ 、アイテムを $i, j \in \mathcal{I}$ で表す。また、ユーザ u が購買したアイテムリストを $\mathcal{X}^u = \{x_1^u, x_2^u, \dots, x_{|\mathcal{X}^u|}^u\}$ と記述する。ただし、 $x_k^u \in \mathcal{I}$ ($k = 1, 2, \dots, |\mathcal{X}^u|$) である。TransRec の学習は、 K 次元ユークリッド空間 \mathcal{R}^K 上で行われる。このとき、アイテム i の意味ベクトルを $\vec{r}_i \in \mathcal{R}^K$ とする。また、あるアイテムから次に買うアイテムを選択するユーザ u の嗜好ベクトルを $\vec{T}_u \in \mathcal{R}^K$ とする。

また、本稿を通じて、事象の確率測度を $Prob(\cdot)$ で表す。簡単のため、離散変数に対しては確率を、連続変数に対しては確率密度として解釈する。

2.3.2 遷移関係の定式化

TransRec では、ユーザ u が、あるアイテム i を購買した後に j を購買する遷移関係を以下のように近似する。

$$\vec{r}_i + \vec{T}_u \approx \vec{r}_j \quad (1)$$

このように定式化することで、ユーザ固有の嗜好に加えて、連続して購買されるアイテムの関係性を考慮した嗜好のモデル化が可能となる。

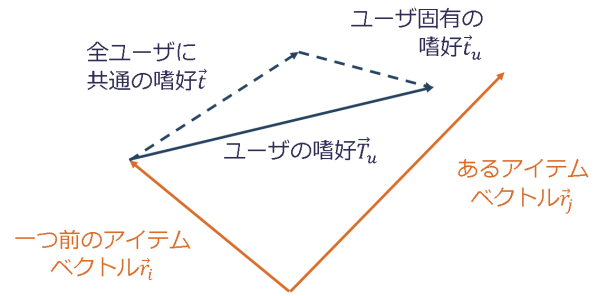


図 1 遷移関係イメージ

Fig. 1 Transition relation image.

2.3.3 アイテムに対する嗜好ベクトル

ユーザ u の嗜好ベクトル \vec{T}_u は、すべてのユーザに共通する嗜好 $\vec{t} \in \mathcal{R}^K$ と各ユーザ固有の嗜好 $\vec{t}_u \in \mathcal{R}^K$ から成り立つと定義する。式にすると以下ようになる。

$$\vec{T}_u = \vec{t} + \vec{t}_u \quad (2)$$

式 (1) と式 (2) のイメージを図 1 に示す。

2.3.4 購買確率の定式化

購買確率はアイテムの人気度と式 (1) の遷移関係によって決まるものとし、ユーザ u がアイテム i を買った後にアイテム j を購買する確率 $p_{u,i,j} = Prob(j|u,i)$ を以下のように定義する。

$$p_{u,i,j} \propto \beta_j - d(\vec{r}_i + \vec{T}_u, \vec{r}_j) \quad (3)$$

s.t. $\vec{r}_i \in \Psi \subseteq \mathcal{R}^K, \forall i \in \mathcal{I}$

ただし、 β_j はアイテム j の人気度、 $d(x,y)$ は x と y の距離を表す。すなわち、人気度 β_j が高いほど、アイテム j のベースとなる購買確率が高いが、 $\vec{r}_i + \vec{T}_u$ と \vec{r}_j の距離が大きいと購買確率は低下する。また、 Ψ は中心点からの距離が 1 以下の K 次元空間（単位球）を表している。これは、 \vec{r}_i のベクトルの大きさを 1 以下に制限することで、次元の呪いの影響を減衰させる効果がある [25], [26]。最終的に、ユーザ u がアイテム i を買ったもとの、 $p_{u,i,j}$ が最も大きくなるアイテム j を推薦する。

2.3.5 パラメータの推定

式 (3) のパラメータは Sequential Bayesian Personalized Ranking (S-BPR) [27] を用いたランキング最適化によって推定する。いま、 $i \in \mathcal{X}^u$ をユーザ u がアイテム $j \in \mathcal{X}^u$ を買う 1 回前に購入したアイテムとすると、このように定義される i は、ユーザ u が 2 番目以降に購入したアイテムに対して定義される（最初の購入アイテムは、1 回前の購入がないため）。このもとの、ユーザが今までに購入したことがあるアイテム j に対しては、購入したことのないアイテム $j' \in \mathcal{I} \setminus \mathcal{J}$ よりも、実際に購入された i が与えられたもとのアイテム j の購入確率が高くなるように学習を行う。すなわち、 $>_{(u,i)}$ をユーザ u がアイテム i を購入したもとの大小関係を表す不等号として、式 (4) のように

パラメータを学習する.

$$\begin{aligned} \hat{\Theta} &= \arg \max_{\Theta} \ln \prod_{u \in \mathcal{U}} \prod_{j \in \mathcal{X}^u} \prod_{j' \notin \mathcal{X}^u} \text{Prob}(j >_{(u,i)} j' | \Theta) \text{Prob}(\Theta) \\ &= \arg \max_{\Theta} \sum_{u \in \mathcal{U}} \sum_{j \in \mathcal{X}^u} \sum_{j' \notin \mathcal{X}^u} \ln \sigma(p_{u,i,j} - p_{u,i,j'}) \\ &\quad - \Omega(\Theta) \end{aligned} \quad (4)$$

Θ は推定すべきパラメータであり, $\beta = (\beta_1, \beta_2, \dots, \beta_{|I|})$, $\mathbf{r} = (\vec{r}_1, \vec{r}_2, \dots, \vec{r}_{|I|})$, $\mathbf{t} = (\vec{t}_1, \vec{t}_2, \dots, \vec{t}_{|U|})$ と定義したもとの, $\Theta = (\beta, \mathbf{r}, \mathbf{t}, \vec{t})$ で与えられる. $\sigma(\cdot)$ はシグモイド関数, $\Omega(\Theta)$ は L_2 正則化項を表す. この式 (4) は, 1 回前の購入アイテム i のもとで, 実際に購入された次のアイテム j の条件付尤度を高め, 購入されていない他のアイテム j' の条件付尤度を下げる構造を有している.

TransRec では, 式 (4) の目的関数を局所最大化するよう, 確率的勾配上昇法に基づき次式によってパラメータを更新する.

$$\begin{aligned} \Theta \leftarrow \Theta + \epsilon \left(\sigma(p_{u,i,j} - p_{u,i,j'}) \frac{\partial(p_{u,i,j} - p_{u,i,j'})}{\partial \Theta} \right. \\ \left. - \frac{\partial \lambda_{\Theta} \Omega(\Theta)}{\partial \Theta} \right) \end{aligned} \quad (5)$$

ただし, ϵ は学習率であり, λ_{Θ} は正則化のハイパーパラメータである.

2.4 関連研究

TransRec を基礎とした拡張モデルは数多く提案されている. たとえば, アイテムに関する知識グラフを考慮した遷移の埋め込みにより未来の購買を予測するためのモデルが Li らにより提案されている [36]. Tengkiattrakul らは Rating の予測を目的とした遷移の埋め込みモデルとして, 人, アイテム, 評価を埋め込み空間上に写像し, そこから評価の予測を行うためのモデルを提案している [37]. Chairatanakul らは, ユーザがアイテムを購入する遷移データに対する埋め込みモデルを定式化する際にユーザとアイテムの関係性に RNN モデルおよび LSTM モデルを入れ込み, ユーザの特徴空間上での位置が時間によって変わるようなモデルを提案している [38]. Wu らは, 遷移データを埋め込むモデルを定義する際にユーザとアイテムの関係性を Attention ネットワークで表し, それを用いて推薦アイテムを決定している [39]. そして, Zhang らは, 商品, ユーザ, 商品のカテゴリに対して階層構造を仮定し, アイテムどうしとの関係性はカテゴリベクトルの関係性, ユーザの嗜好はアイテムベクトルの関係性に基づき決定するという仮定のもとに購買の予測モデルを構築している [40]. さらに階層グラフの行動系列グラフを作成し, 推薦アイテムを決定する方法を提案している.

以上のように, TransRec はその提案以来, 様々な観点から拡張されており, このこと自体が, TransRec のモデ

ルとしての魅力を端的に表している. しかし, これらの研究は電子商店街での適用を想定しておらず, 電子商店街を対象とした本研究とは拡張の方向性が本質的に異なる.

2.5 電子商店街

電子商店街は EC サイトの一形態であり, インターネットモール, サイバーモール, オンラインモール, ネット商店街などと呼ばれることもある [28]. 単一企業が運営する EC サイトでは, この企業がすべてのアイテムを出品・販売を行っているのに対し, 電子商店街におけるサイト管理企業はサイト全体の管理を行い, このサイト上に出店した個人や企業がそれぞれ商店ページでアイテムの販売を行う. 店主は, 趣味で販売をする個人から, 本業の個人事業者, 実店舗を有する大手企業まで多様である. 電子商店街の管理企業は, サイト全体の魅力度を高め, 店主がサイト上で販売活動をしやすいようなプラットフォームを提供する. これにより, 店主は, 最初から EC サイトを立ち上げ, それを周知するための宣伝費用をかけることなく, 比較的少ない初期投資で, オンライン販売を手掛けることができる. また, 電子商店街の魅力度やブランド価値は, その運営企業が高める努力をしてくれているため, 店主はそのサイト上で販売するアイテムの管理に注力することができる. このような電子商店街のビジネスモデルや戦略については, 比較的早くから経営学的な考察はなされている [29], [30], [31].

一方, 電子商店街ではサイト内に様々な商店が存在するため, 単一企業による EC サイトよりもユーザの購買行動も多様となる傾向がある. たとえば, ユーザが目的のアイテムを検索してから, 各商店での出品価格などを比較検討して購入するケースや, 先にお気に入りの商店ページを訪問し, そこで売られているアイテムを閲覧して, 気に入ったものがあれば購入するケースも考えられる.

以上のように, 単一企業による EC サイトと電子商店街ではユーザのサイトの利用方法も異なるという特徴が存在する. すなわち, 電子商店街での購買データに TransRec [18] を適用する場合, 商店を考慮したユーザの嗜好をモデルのなかに組み込むことが望ましい. このような電子商店街における商品推薦については, 横田ら [32] によるレコメンド機能機能を有するサイバー商店街といった提案もあるが, 顧客の購買履歴データを活用せずに, アイテムの購買履歴を用いた方法となっている.

3. 提案手法

3.1 提案手法への着眼点

電子商店街は出店者が各自のページ (店舗) においてアイテム販売している. そのため, ユーザ側からは同じアイテムであっても商店ページごとに比較して購買することが可能である. また, 電子商店街においてユーザは商店ペー

ジを閲覧してから、アイテムを比較検討し、購買を行うことが可能である。

ここで得られたデータに対して従来手法である TransRec を適用する場合、その前に購買したアイテムが与えられたもとでアイテムを選択する嗜好をモデル化することになる。一方で電子商店街において多くのユーザは商店のアイテムを閲覧してから購買に至っている。よってユーザの嗜好をとらえる際に商店に売られているアイテムのなかでの嗜好をとらえる必要があると考えられる。そこで、電子商店街において商店に売られているアイテムを選択するユーザの嗜好を学習することで、ユーザが好んでいるアイテムの予測購買確率を高く学習できるようなモデルを提案する。

そのためにまず、素直な拡張として、新たに商店ベクトルを定義して、商店を空間上の点として TransRec に追加する方法（単純拡張モデルと呼ぶ）を考えてみる。すなわち、商店ベクトルを埋め込み空間に布置すると同時に、商店が与えられたもとでのアイテムに対する嗜好ベクトルを埋め込み空間に追加する。これにより、従来のアイテムに対する嗜好に加えて、商店が与えられたもとでのアイテムに対する嗜好もモデルに加わり、電子商店街におけるユーザの嗜好をモデル化することが期待できる。しかし、実際にはこの方法では、ユーザとアイテム、店舗がすべてベクトル（点）で表現されているため、これらの位置関係を購買履歴データに合わせて定めることは難しいタスクであると考えられる。そこで、この単純拡張モデルの問題点を改善した手法として、店舗を直線で表現して、アイテムやユーザと同一空間（埋め込み空間）上に埋め込む方法を提案する。

以下では、商店を点で追加した単純拡張モデルと商店を直線で表現した提案モデルの順で詳細を示す。

3.2 単純拡張モデル：商店を点で追加した TransRec

本研究では、TransRec における購買アイテムの遷移を考慮したユーザの嗜好に加えて、商店と商店におけるユーザの嗜好を同一空間（埋め込み空間）上に埋め込む方法を検討している。そのためにまず、単純な拡張として、商店と商店におけるユーザの嗜好を、ユーザやアイテムと同様にベクトル（点）で表現した単純な拡張方法を考えてみる。その際に購入したアイテムに対して、その前に買ったアイテムとユーザの嗜好ベクトルの和と距離が近く、さらにアイテムを購入した商店とその商店におけるユーザの嗜好ベクトルの和が近くなるように学習を行う。

3.2.1 変数定義

ユーザを $u \in \mathcal{U}$ 、アイテムを $i, j \in \mathcal{I}$ 、ユーザ u が購買したアイテムリストを $\mathcal{X}^u = \{x_1^u, x_2^u, \dots, x_{|\mathcal{X}^u|}^u\}$ と定義する。加えて、埋め込む空間の次元数を K として、商店を $l \in \mathcal{L}$ 、商店 l を表す意味ベクトルを $\vec{s}_l \in \mathcal{R}^K$ 、ユーザ u における商店が与えられたもとでのアイテムに対する嗜好




図 2 アイテムベクトルと商店との関係のイメージ

Fig. 2 Relation image about an item vector and a store.

ベクトルを $\vec{T}_u \in \mathcal{R}^K$ と定義する。ここで、このモデルにおいて 1 つ 1 つの商店は考慮していないため、添え字 l が入っていないことに注意が必要である。ユーザ u が購買を行った商店リストを $\mathcal{Y}^u = \{y_1^u, y_2^u, \dots, y_{|\mathcal{Y}^u|}^u\}$ とする。

3.2.2 商店における購買の定式化

ユーザ $u \in \mathcal{U}$ の商店 $l \in \mathcal{Y}^u$ におけるアイテム $j \in \mathcal{X}^u$ の購買を以下のように近似する。

$$\vec{s}_l + \vec{T}_u \approx \vec{r}_j \quad (6)$$

このように定義することで、購入するアイテム \vec{r}_j は商店ベクトル \vec{s}_l と商店が与えられたもとでのアイテムに対する嗜好 \vec{T}_u を考慮したモデル化が可能となる。また、商店が与えられたもとでのアイテムに対する嗜好 \vec{T}_u はユーザ固有であり、かつユーザが購買を行ったすべての商店 \mathcal{Y}^u を考慮したモデルとなっている。

3.2.3 商店が与えられたもとでのアイテムに対する嗜好ベクトル

まず全ユーザに共通する商店が与えられたもとでのアイテムに対する嗜好 $\vec{t} \in \mathcal{R}^K$ と各ユーザの商店が与えられたもとでのアイテムに対する嗜好 $\vec{t}_u \in \mathcal{R}^K$ を用いて、嗜好ベクトル \vec{T}_u を以下のように定式化する。

$$\vec{T}_u = \vec{t} + \vec{t}_u \quad (7)$$

単純拡張モデルにおけるアイテムベクトルと商店との関係を表現した式 (6) と式 (7) のイメージを図 2 に示す。

3.2.4 モデルの定式化

購買確率はアイテムの人気と式 (6) と式 (1) の遷移関係によって決まると定義する。ユーザ u が商店 l においてアイテム i を購買した後に j を購買する確率は以下ようになる。

$$p_{u,i,j,l} \propto \beta_j - d(\vec{r}_i + \vec{T}_u, \vec{r}_j) - d(\vec{s}_l + \vec{T}_u, \vec{r}_j) \quad (8)$$

$$\text{s.t. } \vec{r}_i \in \Psi \subseteq \mathcal{R}^K, \forall i \in \mathcal{I}$$

$$\vec{s}_l \in \Psi \subseteq \mathcal{R}^K, \forall l \in \mathcal{L}$$

従来手法と同様に、 β_j はアイテム j の人気度であり、推薦を前提とした本研究のモデルにおいて重要なパラメータとなる。また、 $d(x, y)$ は x と y の距離を表し、 Ψ は中心点か

らの距離が1以下の K 次元空間 (単位球) を表している. このように定式化することで, 従来手法に商店ベクトル \vec{s}_i と商店が与えられたもとのアイテムに対する嗜好 \vec{T}_u を加えることが可能となる. これにより, ある商品が人気であり, かつ購買順序の観点からはユーザの嗜好に合致した商品であったとしても, 商店が与えられたもとのアイテムに対する嗜好に合致していない場合は予測購買確率が低くなるなど, 電子商店街におけるユーザの嗜好を考慮した推薦が期待できる.

3.2.5 パラメータの推定

式 (8) のパラメータは従来手法同様 Sequential Bayesian Personalized Ranking (S-BPR) [3] を用いた以下の目的関数のランキング最適化によって求める.

$$\hat{\Theta}_1 = \arg \max_{\Theta_1} \sum_{u \in \mathcal{U}} \sum_{j \in \mathcal{X}^u} \sum_{j' \notin \mathcal{X}^u} \sum_{l \in \mathcal{Y}^u} \ln \sigma(p_{u,i,j,l} - p_{u,i,j',l}) - \Omega(\Theta_1) \quad (9)$$

ただし, i はユーザ u がアイテム j の1つ前に購入したアイテム $i = i_{u,j}$ である. Θ_1 は推定すべきパラメータであり, $\beta = (\beta_1, \beta_2, \dots, \beta_{|\mathcal{I}|})$, $\mathbf{r} = (\vec{r}_1, \vec{r}_2, \dots, \vec{r}_{|\mathcal{I}|})$, $\mathbf{t} = (\vec{t}_1, \vec{t}_2, \dots, \vec{t}_{|\mathcal{U}|})$, $\mathbf{s} = (\vec{s}_1, \vec{s}_2, \dots, \vec{s}_{|\mathcal{L}|})$, $\mathbf{t}' = (\vec{t}'_1, \vec{t}'_2, \dots, \vec{t}'_{|\mathcal{U}|})$ と定義したもとの, $\Theta_1 = (\beta, \mathbf{r}, \mathbf{t}, \mathbf{s}, \mathbf{t}', \vec{t})$ で与えられる. 式 (9) が最大化するようにパラメータを更新する. パラメータは従来手法同様に確率的勾配上昇法によって更新される.

$$\Theta_1 \leftarrow \Theta_1 + \epsilon \left(\sigma(p_{u,i,j,l} - p_{u,i,j',l}) \frac{\partial(p_{u,i,j,l} - p_{u,i,j',l})}{\partial \Theta_1} - \frac{\partial \lambda_{\Theta_1} \Omega(\Theta_1)}{\partial \Theta_1} \right) \quad (10)$$

3.3 単純拡張モデルの問題点

図 3 に式 (8) の図形的イメージを示す. 図 3 は1つの商店のもとで連続で3つのアイテムを購入したユーザを学習した際の式 (8) のすべてのベクトルを示している. 図 3 のように同じ商店における購買が多いユーザを考えたとき, 提案モデルは同じ商店で購入されたすべてのアイテムに対




図 3 単純拡張モデルにおけるパラメータの学習

Fig. 3 Parameter estimation of the simple expansion model.

して, ある商店ベクトル \vec{s}_i と商店が与えられたもとのアイテムに対する嗜好ベクトル \vec{T}_u の和を近づけるように学習を行う. しかし, 同じ商店で購入されたすべてのアイテムに近づけようとしてしまうため, どれか1つのアイテムに近づいたり, どのアイテムにも近づき切らない中途半端なベクトルになったりするなど, 同じ商店で購入されたすべてのアイテムにベクトルの和を十分に近づけることは不可能である. そのため, 同じ商店で購入を続けるユーザの嗜好を埋め込み空間上で表現することができない.

3.4 提案手法: 直線で表現した商店情報を追加した TransRec

本節では, 前節で示した単純拡張モデルの問題点を克服するため, TransRec をベースとして直線で表現される商店, および商店が与えられたもとのアイテムに対する嗜好ベクトルを追加したモデルを提案する. このモデルは, 「アイテムに対する嗜好」と「商店が与えられたもとのアイテムに対する嗜好」を同時に表現している. さらに, 商店を1点ではなく直線で表現することにより, 媒介変数の値を変化させることで同じ商店で購入されたすべてのアイテムに商店ベクトルと商店が与えられたもとのアイテムに対する嗜好ベクトルの和を十分に近づけることが可能となる. これにより, 商店が与えられたもとのアイテムに対する嗜好も矛盾なく表現でき, 十分な学習によって商品の嗜好も反映した推薦が可能となる.

ここで, 提案手法では, 各商店を特徴空間上の (点ではなく) 直線で表し, この直線上のすべての点が同じ商店を意味できるという条件のもとで, 各商店の購買履歴を最もよく表現可能な直線を探索している. したがって, 学習データを用いた学習が終了した時点では, 各商店は特徴空間上の直線で表されており, その上のいずれの点も同じ商店を表している. 一方で, 1つ1つの購買系列を学習済みの埋め込み空間モデルにあてはめた場合には, その購買系列に最もマッチする直線上の1点を選ばれることには注意が必要である.

3.4.1 直線による商店の表現

提案手法では商店をベクトル (点) でなく, ベクトル方程式 (直線) によって表している. これまでの研究において, 埋め込み表現を拡張する際に, Word2gauss [33] のようにベクトルの代わりに正規分布を用いる手法がある. Word2gauss では, 正規分布で表現することで, 位置関係だけでなく, 意味的な広がり表現している. しかし, TransRec は時系列モデルであり, このモデルに正規分布を導入したとしても, 正規分布ではユーザが購買するすべてのアイテムの位置に対して距離を普遍的に保つことはできない.

そのため, 被購買数が少ない商店であっても, その商店で売られるアイテムの購買間隔が広がった場合, 分散が大

きくなってしまい、被購買数が多い商店として扱われてしまう。これに対して、商店を直線によって表すことにより、被購買間隔が大きいアイテムに対しても距離を普遍的に保つことができるため、被購買数の少ない商店はユーザーの嗜好ベクトルと直角に近い直線で表すことができる。さらに被購買数が多い商店はユーザーの嗜好ベクトルと平行になるように学習される。このように被購買数に応じた商店のモデル化が可能となる。

3.4.2 商店情報を考慮した被購買アイテムの遷移

商店 l を直線である $s_l = \alpha \vec{m}_l + \vec{n}_l$ と定義する。 \vec{m}_l は直線の方向ベクトル、 α は媒介変数である。このとき、ユーザー u が商店 l を選択した後に、購入するアイテム j との関係を下のように近似する。

$$\alpha_{u,i,j} \vec{m}_l + \vec{n}_l + \vec{T}'_u \approx \vec{r}_j \quad (11)$$

商店が与えられたもとのアイテムに対する嗜好ベクトル \vec{T}'_u は、単純拡張モデルと同様 $\vec{T}'_u = \vec{t}' + \vec{t}'_u$ である。このときの $\alpha_{u,i,j}$ を以下のように定義する。

$$\alpha_{u,i,j} = \frac{-\sum_k \vec{m}_k \cdot (\vec{n}_l - (\vec{r}_j - \vec{T}'_u))}{\sum_k \vec{m}_k^2} \quad (12)$$

ここで媒介変数 $\alpha_{u,i,j}$ のイメージを図 4 に示す。

式 (12) は図 4 のように、アイテムベクトルと商店が与えられたもとのアイテムに対する嗜好の逆ベクトルの和と最も近い直線により表現される商店 s_l 上の点を指す際の $\alpha_{u,i,j}$ を算出している。

ここで図 5 のように、得られた $\alpha_{u,i,j}$ を用いた商店ベクトル $\alpha_{u,i,j} \vec{m}_l + \vec{n}_l$ と商店が与えられたもとのアイテムに対する嗜好ベクトル \vec{T}'_u の和とアイテムベクトル \vec{r}_j を近づけるように各ベクトルを学習する。

3.4.3 モデルの定式化

購買確率はアイテムの人気と式 (11) と式 (1) の遷移関係によって決まると定義する。ユーザー u が商店 l においてアイテム i を購買した後に j を購買する確率は以下のようになる。

$$p_{u,i,j,l} \propto \beta_j - d(\vec{r}_i + \vec{T}'_u, \vec{r}_j) - d(\alpha_{u,i,j} \vec{m}_l + \vec{n}_l + \vec{T}'_u, \vec{r}_j)$$

$$\text{s.t. } \vec{r}_i \in \Psi \subseteq \mathcal{R}^K, \forall i \in \mathcal{I}$$

$$\vec{m}_l \in \Psi \subseteq \mathcal{R}^K, \forall l \in \mathcal{L}$$

$$\vec{n}_l \in \Psi \subseteq \mathcal{R}^K, \forall l \in \mathcal{L}$$

$$\alpha_{u,i,j} = \frac{-\sum_k \vec{m}_k \cdot (\vec{n}_l - (\vec{r}_j - \vec{T}'_u))}{\sum_k \vec{m}_k^2} \quad (13)$$

図 6 に提案手法のイメージを示す。図 6 は図 3 と同様に 1 つの商店のもとの連続で 3 つのアイテムを購買したユーザーを対象にしており、 α が変化した際の商店を表す s_l を示している。 α が変化することで、直線上の点であればどの点においても同一の商店ベクトルとして扱うことができる。

このように商店を直線で表現することにより、同一の商店で購買を続けるユーザーであっても、ある商店ベクトル s_l と商店が与えられたもとのアイテムに対する嗜好ベクトル \vec{T}'_u の和を同じ商店で購入されたすべてのアイテムに十分に近づけることが可能となる。

また、方向ベクトル \vec{m}_l と通過点 \vec{n}_l (ベクトル) の線形和によって表される直線のうち方向ベクトル \vec{m}_l は直線の方法を意味するため、学習後の商店の直線の方法を意味するベクトルとして一意に決定さる。一方、通過点 \vec{n}_l は基準として便宜的に決定した点になる。ここで、直線は埋め




図 5 提案手法の遷移関係イメージ
Fig. 5 Transition relation image of proposed method.




図 4 $\alpha_{u,i,j}$ 算出のイメージ
Fig. 4 Image of $\alpha_{u,i,j}$ calculation.




図 6 同一商店で複数購買したときの提案手法のイメージ
Fig. 6 Image of the proposed method when a user buys multiple items in a shop.

込み空間上で直線を表現しているが、この空間の1つ1つの軸の意味については明確にすることはできない。すなわち、埋め込み空間上に配置された商店やアイテムについては、その絶対的な直線の式や点の座標自体が本質的な意味を持つものではなく、商店やアイテム間の相対的な位置関係を空間上に学習していると位置付けられる。

3.4.4 パラメータの推定

式 (13) のパラメータを推定することを考える。従来手法ではユーザが買っていないアイテムよりも買ったアイテムの方が購買確率が高くなるように学習を行った。しかし、提案手法においては、①ユーザが利用する商店において買っていないアイテム（ユーザの購買履歴に存在しないアイテム）と②利用していない商店において買っているアイテム（ユーザの購買履歴に存在するアイテム）の両方よりも、利用する商店において実際に購入したアイテムの方が購買確率が高くなるように学習を行う必要がある。

そこで、以下のように①と②に対応する2つの目的関数を設定し、交互に2つの目的関数を最大化するようにパラメータを更新する。

$$\begin{aligned} \hat{\Theta}_2 &= \arg \max_{\Theta_2} \sum_{u \in \mathcal{U}} \sum_{j \in \mathcal{X}^u} \sum_{j' \notin \mathcal{X}^u} \sum_{l \in \mathcal{Y}^u} \ln \sigma(p_{u,i,j,l} - p_{u,i,j',l}) \\ &\quad - \Omega(\Theta_2) \end{aligned} \quad (14)$$

$$\begin{aligned} \hat{\Theta}_3 &= \arg \max_{\Theta_3} \sum_{u \in \mathcal{U}} \sum_{j \in \mathcal{X}^u} \sum_{l \in \mathcal{Y}^u} \sum_{l' \notin \mathcal{Y}^u} \ln \sigma(p_{u,j,l} - p_{u,j,l'}) \\ &\quad - \Omega(\Theta_3) \end{aligned} \quad (15)$$

ただし、 i は従来モデルや単純拡張モデルと同様に、ユーザ u がアイテム j の1つ前に購入したアイテム $i = i_{u,j}$ である。 Θ_2 と Θ_3 は学習するパラメータであり、

$$\begin{aligned} \beta &= (\beta_1, \beta_2, \dots, \beta_{|I|}) \\ \mathbf{r} &= (\vec{r}_1, \vec{r}_2, \dots, \vec{r}_{|I|}) \\ \mathbf{t} &= (\vec{t}_1, \vec{t}_2, \dots, \vec{t}_{|U|}) \\ \mathbf{m} &= (\vec{m}_1, \vec{m}_2, \dots, \vec{m}_{|L|}) \\ \mathbf{n} &= (\vec{n}_1, \vec{n}_2, \dots, \vec{n}_{|L|}) \\ \mathbf{t}' &= (\vec{t}'_1, \vec{t}'_2, \dots, \vec{t}'_{|U|}) \end{aligned}$$

と定義したもとの、 $\Theta_2 = (\beta, \mathbf{r}, \mathbf{t}, \vec{t}, \mathbf{m}, \mathbf{n}, \mathbf{t}', \vec{t}')$ 、 $\Theta_3 = (\mathbf{r}, \mathbf{m}, \mathbf{n}, \mathbf{t}', \vec{t}')$ と与えられる。

ここで、提案モデルにおいて式 (14)、(15) のように交互最適化ではなく、最適化問題の和として目的関数を定義し、同時に最適化（探索）する方法を考えることもできる。しかしながら、本研究のモデルはパラメータの数が非常に多く、複雑な構造を有するため、同時に探索すると、探索空間が広がり、パラメータの特性の違いも考慮した勾配法

の微妙なチューニングが必要となってしまう。一方で、交互最適化のアプローチによりシンプルな手続きを構成することが可能となる。そこで、本研究では交互最適化のアプローチを採用している。

3.5 予測購買確率

得られたパラメータを以下のようにそのまま用いることで、ユーザ u が商店 l においてアイテム i を買った後にアイテム j を購入する確率が算出でき、商店ごとに何が購入されやすいかを予測することができる。

$$\begin{aligned} \hat{p}_{u,i,j} &= \beta_j - d(\vec{r}_i + \vec{T}_u, \vec{r}_j) - d(\alpha_{u,i,j} \vec{m}_l + \vec{n}_l + \vec{T}'_u, \vec{r}_j) \\ \alpha_{u,i,j} &= \frac{-\sum_k \vec{m}_k \cdot (\vec{n}_l - (\vec{r}_i - \vec{T}'_u))}{\sum_k \vec{m}_k^2} \end{aligned} \quad (16)$$

これに対して、通常のECサイトと同じようにユーザが好むであろうアイテムが推薦され、商店ごとに推薦アイテムは決定されない場合が考えられる。そのため、実応用を考えたときに商店は関係なく、ユーザごとに予測購買確率を算出する必要がある。そこで、本研究では提案手法の予測購買確率を以下のように定義する。

$$\hat{p}_{u,i,j} = \beta_j - d(\vec{r}_i + \vec{T}_u, \vec{r}_j) \quad (17)$$

このように商店に関する距離の項を考慮せず、従来のTransRecと同様のパラメータを用いて予測購買確率が計算される。

4. 実験

本章では、電子商店街の実データを用いて、従来法と提案法の予測精度について検証する。このとき、単純拡張モデルやパラメータを通常のS-BPRを用いて推定した場合の提案手法（比較手法）と比較することで、詳細に予測精度向上の考察を行う。

4.1 実験条件

実験では、楽天データ公開のサイト [34] で提供されている2010年度楽天市場レビューデータセットを用いる。レビューデータは基本的にユーザが購入したアイテムに対する評価をしたものであるため、このレビュー系列を購買履歴データと見なし、従来法と提案法で学習し、その予測精度を比較検証する。本来であれば、各ユーザの購買履歴データそのものを用いることが理想であるが、上記サイトではそのようなデータは公開されておらず、評価実験に用いることが困難であるため、レビューデータを仮想的購買履歴データと見なして実験を行うこととする。

このとき、購買履歴は総計で7,959,919件、ユーザ数は1,337,020（人）、アイテム数は2,501,495（件）、商店数は37,380（件）である。ユーザにおける購買数の平均は4.89件、アイテムごとの平均被購買数は8.43件、商店ごとの

ユーザの利用回数は 4.61 件であった。このうち、評価数が 4 件以下のユーザ、もしくは被評価数が 4 件以下のアイテムのデータは取り除いた。結果として、購買履歴は総計で 3,666,079 件、ユーザ数は 333,543 (人)、アイテム数は 257,082 (件)、商店数は 17,721 (件) となった。このときのユーザにおける購買数の平均は 10.99 件、アイテムごとの平均被購買数は 14.26 件、商店ごとのユーザの利用回数は 7.33 件であった。

実験では、ユーザをランダムに 5 つのデータセットに振り分け、それぞれのデータセットにおいて評価指標を算出する。対象となるデータにおいてユーザが最後に購入したアイテム $S_{|S^u|}^u$ とその前の購入アイテム $S_{|S^u|-1}^u$ をテストデータ、 $S_1^u, S_2^u, \dots, S_{|S^u|-2}^u$ を学習データとした。また、評価指標には以下の Area Under the ROC Curve (AUC) と Hit@50 を用いる。

AUC :

$$AUC = \frac{1}{|U|} \sum_{u \in U} \frac{1}{|I \setminus S^u|} \sum_{j' \in I \setminus S^u} 1(R_{u,g_u} < R_{u,f'}) \quad (18)$$

Hit@50 :

$$Hit@50 = \frac{1}{|U|} \sum_{u \in U} 1(R_{u,g_u} \leq 50) \quad (19)$$

g_u は実際にユーザが最後に購入したアイテムであり、 $R_{u,i}$ はユーザ u のアイテム i に対する予測購買確率のランキング (値が小さいほど良い)、 $1(A)$ はインジケータ関数であり、事象 A が成り立てば 1、そうでなければ 0 を返す。AUC は予測購買確率のランキングにおいて、実際に購入したアイテムの順位が高いほど大きな値をとる指標である。Hit@50 は実際に購入したアイテムが予測購買確率のランキングの上位 50 件以内に入っている数が多いほど大きな値をとる指標である。

4.2 比較手法

実験では以下の 4 つの手法を用いて、比較を行う。

- 従来モデル：TransRec
- 単純拡張モデル：商店と商店が与えられたもとのアイテムに対する嗜好をベクトルで追加した TransRec
- 比較モデル：提案手法においてパラメータ推定アルゴリズムを従来手法と同様に通常の S-BPR を用いたモデル。予測購買確率は式 (17) を用いた。
- 提案モデル：直線で表現される商店、および商店が与えられたもとのアイテムに対する嗜好を追加した TransRec。予測購買確率は式 (17) を用いた。

ここで比較手法では、特徴空間上での商店やアイテムの表現モデルは提案モデルと同一であり、推定方法が異なるモデルである。提案手法では、「商店」と「アイテム」の 2 つの概念が特徴空間上で表現されており、ユーザの嗜好は「よく利用する商店」と「よく購入するアイテム」の双方に

よって表している。よって提案手法の学習フェーズでは、ユーザが「利用経験がある商店において、(他店も含めて) 購入経験のないアイテムを購入する確率 (A)」と「利用経験のない商店において、(他店で) 購入経験のあるアイテムを購入する確率 (B)」の両方よりも、「過去にそのアイテムを購入した商店で、同じアイテムを購入する確率」が高くなるように学習を行っている。一方、比較手法では、ユーザが「利用経験のある商店において (他店も含めて) 購入経験のないアイテム (ユーザの購買履歴に存在しないアイテム) を購入する確率 (A)」よりも「利用経験のある商店において、その商店で実際に購入したアイテムを購入する確率」が高くなるように (A) のみの確率を考慮して学習を行っている。よって提案手法と比較手法により、(B) の確率を考慮することの有効性を評価することができると考えられる。

4.3 分析結果

まず、特徴空間の次元数 k の数を 20 から 70 まで 10 ずつ増加させ、そのときの 4 つの手法 (従来手法、単純拡張法、比較手法、提案手法) について、2 つの評価指標 (AUC, Hit@50) から判断した。結果を表 1, 表 2, 表 3, 表 4 に示す。ただし、正則化パラメータ λ については、事前実験を行い、適切な値を探索的に求めた。

上記の結果より、従来手法に対して、すべての k に対して他の 3 手法いずれも優れた結果を示していることから、TransRec に電子商店街における商店情報を加えることは

表 1 学習データにおける AUC

Table 1 AUC of the training data.

k の数	20	30	40	50	60	70
従来	0.716	0.716	0.717	0.715	0.716	0.717
単純拡張	0.736	0.736	0.736	0.734	0.734	0.734
比較	0.740	0.740	0.741	0.740	0.739	0.739
提案	0.743	0.744	0.743	0.743	0.743	0.742

表 2 学習データにおける Hit@50

Table 2 Hit@50 of the training data.

k の数	20	30	40	50	60	70
従来	0.054	0.060	0.065	0.064	0.066	0.067
単純拡張	0.047	0.049	0.049	0.048	0.049	0.048
比較	0.060	0.064	0.066	0.065	0.065	0.064
提案	0.075	0.083	0.087	0.090	0.092	0.093

表 3 テストデータにおける AUC

Table 3 AUC of the test data.

k の数	20	30	40	50	60	70
従来	0.703	0.704	0.705	0.703	0.704	0.703
単純拡張	0.716	0.716	0.717	0.716	0.715	0.715
比較	0.722	0.722	0.724	0.723	0.722	0.721
提案	0.725	0.726	0.726	0.726	0.727	0.725

表 4 テストデータにおける Hit@50
Table 4 Hit@50 of the training data.

k の数	20	30	40	50	60	70
従来	0.046	0.048	0.051	0.051	0.051	0.052
単純拡張	0.040	0.041	0.043	0.041	0.042	0.041
比較	0.047	0.049	0.050	0.051	0.050	0.049
提案	0.059	0.064	0.067	0.068	0.072	0.071

有用であるということが分かる。また、単純拡張モデルに対して提案モデルと比較モデルが優れた結果を示していることから、商店を直線で表現することは有用であり、かつ α を式 (12) のように算出することで直線であっても商店を表現できていることが分かる。さらに、提案モデルが比較モデルよりも優れていることから、2つの目的関数をどちらも最大化するようにパラメータを学習できていることが分かる。

ここで、以降の分析のために k の値を1つに定める必要がある。実際の推薦では Hit 率を上げることが推薦精度の向上につながるため、その観点では Hit 率による評価が重要となるものと考えられる。しかしながら、Hit 率は、上位何件までに含まれれば正解とカウントするかの閾値の設定によって値が変化し、この閾値を高くすると値が非常に小さくなってしまい、正確な評価が困難になる。そのため、Hit 率は分析目的ではなく、上位アイテムの推薦精度の確認として参考とするのが妥当である。一方、AUC はランキング上位だけでなく、アイテム全体のあてはまりを考慮した指標である。各商店の特徴を分析するには、少数の上位アイテムのあてはまりだけでなく、アイテム全体に対するあてはまりの良いモデルで分析する方が妥当であるため、以下では AUC を用いて適切な特徴空間の次元を決定し、店舗どうしの関係性の分析を行うこととする。

上記の実験の結果より、学習データとテストデータに対する AUC の値は $k = 30$ 以降、値がほぼ一定になっていることが分かる。このことから、本研究ではこの範囲でモデルの推定精度にはほぼ差がないと考え、中間をとって $k = 50$ を採用した。以降、 $k = 50$ の結果に着目して商品どうしの距離の分析を行う。

5. 商店どうしの距離の分析

本研究では、同一の商店において購買を続けるユーザーを考慮するために商店を直線で表現した。これに対して、ユーザー個人単位で見のではなく空間全体で見たとき、商店がベクトルによる直線で表現されているため、一部のアイテムだけでも商店間で関係があれば、その商店の直線どうしの最短距離は近くなると考えられる。たとえば、寝具とアクセサリを売っている商店があった場合、その商店に対して寝具専門店やアクセサリ専門店が近づくといったように、異なるカテゴリのアイテムを販売している商店

どうしても、一部で似たようなアイテムを販売しているならば、その距離は近くなるという関係性があると考えられる。この関係性があるならば、商店を直線で表現することにより電子商店街におけるアイテムと商店の関係を正確に表現可能となったといえ、精度が向上した要因であるといえる。そこで商店を表現する直線を分析することで、その関係性が現れているかを確認する。

5.1 分析方法

分析する方法として、ある商店に着目し、その商店が実際に販売しているアイテムのベクトル \vec{r}_j と全ユーザーに共通する商店が与えられたもとのアイテムに対する嗜好ベクトル \vec{t} の逆ベクトルの和の距離 $d_{j,l}$ が短い商店 l を列挙する。 $d_{j,l}$ は以下のように定義される。

$$d_{j,l} = d(\vec{r}_j - \vec{t}, \alpha \vec{m}_l + \vec{n}_l) \quad (20)$$

このときの α は以下のように定義される。

$$\alpha = \frac{-\sum_k \vec{m}_k \cdot (\vec{n}_l - (\vec{r}_j - \vec{t}))}{\sum_k \vec{m}_k^2} \quad (21)$$

$d_{j,l}$ は商店 l において、全ユーザーからするアイテム j の購入されやすさを表している。 $d_{j,l}$ が小さいほどアイテム j は商店 l において購入されやすい。この $d_{j,l}$ が小さい商店どうしはアイテム j を販売している確率が高い商店であり、かつその商店どうしで近いといえるため、上記のような関係性を持つといえる。

5.2 分析

分析対象とする商店はネックレスや靴が主に売れており、加えて食べ物やペット用品も売れている商店とする。分析を行う対象の商店が実際に売っているアイテムは以下のとおりである。

- ネックレス X_1, X_2
- 靴 X_3, X_4
- 食品 X_5
- ペット用品 X_6

分析結果を以下に示す。

表 5, 表 6, 表 7, 表 8, 表 9, 表 10 より、どの商品から見ても、対象の商店と同様にネックレスや靴がともに売られている商店が多く出現している。同様の商店が多く出現していることから、商店の学習により分かる。また、食品やペット用品から見た際に、ネックレスや靴が売られている商店のみ出現している。これは、直線では表現力が足りず、データ数の少ない食品やペット用品を十分に学習できなかったためであると考えられる。

次に、ネックレスや靴と距離の近い商店 TOP20 のなかで、ネックレスか靴のどちらかのみを扱っている商店を列挙した。その結果を表 11 に示す。表 11 より、アクセサ

表 5 ネックレス X_1 に近い TOP10 の商店

Table 5 Top 10 shops that are nearest from the necklace X_1 .

1	対象の商店
2	スポーツ用品店 A_1
3	アクセサリや靴, 服を販売しているアパレル店 B_1
4	雑貨店 C_1
5	アクセサリや靴, 服を販売しているアパレル店 B_2
6	鞆や靴, アクセサリを販売している店 D_1
7	アクセサリや雑貨を販売している店 E_1
8	アクセサリや靴などを販売している雑貨店 F_1
9	アクセサリや服を販売しているアパレル店 G_1
10	ペット用品店 H_1

表 6 ネックレス X_2 に近い TOP10 の商店

Table 6 Top 10 shops that are nearest from the necklace X_2 .

1	対象の商店
2	アクセサリや靴, 服を販売しているアパレル店 B_3
3	アクセサリや靴, 服を販売しているアパレル店 B_1
4	鞆や靴, アクセサリを販売している店 D_1
5	アクセサリや靴, 服を販売しているアパレル店 B_2
6	アクセサリや靴, 服を販売しているアパレル店 B_4
7	スポーツ用品店 A_1
8	雑貨店 C_1
9	アクセサリや靴などを販売している雑貨店 F_1
10	服や靴を販売しているアパレル店 I_1

表 7 靴 X_3 に近い TOP10 の商店

Table 7 Top 10 shops that are nearest from the shoes X_3 .

1	対象の商店
2	アクセサリや靴, 服を販売しているアパレル店 B_1
3	アクセサリや靴, 服を販売しているアパレル店 B_2
4	靴専門店 J_1
5	服や靴を販売しているアパレル店 I_2
6	アクセサリや靴, 服を販売しているアパレル店 B_5
7	アクセサリや靴などを販売している雑貨店 F_1
8	服や靴を販売しているアパレル店 I_1
9	アクセサリや靴, 服を販売しているアパレル店 B_3
10	アクセサリや雑貨を販売している店 K_1

表 8 靴 X_4 に近い TOP10 の商店

Table 8 Top 10 shops that are nearest from the shoes X_4 .

1	対象の商店
2	アクセサリや靴, 服を販売しているアパレル店 B_1
3	鞆や靴, アクセサリを販売している店 D_1
4	アクセサリや靴, 服を販売しているアパレル店 B_2
5	アクセサリや服を販売しているアパレル店 G_1
6	アクセサリや靴, 服を販売しているアパレル店 B_4
7	スポーツ用品店 A_1
8	アクセサリや雑貨を販売している店 K_1
9	雑貨店 C_1
10	アクセサリや靴などを販売している雑貨店 F_1

表 9 食品 X_5 に近い TOP10 の商店

Table 9 Top 10 stores that are nearest from the food X_5 .

1	対象の商店
2	アクセサリや靴, 服を販売しているアパレル店 B_1
3	鞆や靴, アクセサリを販売している店 D_1
4	アクセサリや靴, 服を販売しているアパレル店 B_3
5	アクセサリや靴, 服を販売しているアパレル店 B_2
6	スポーツ用品店 A_1
7	アクセサリや靴, 服を販売しているアパレル店 B_4
8	雑貨店 C_1
9	アクセサリや靴などを販売している雑貨店 F_1
10	アクセサリや雑貨を販売している店 K_1

表 10 ペット用品 X_6 に近い TOP10 の商店

Table 10 Top 10 stores that are nearest from the pet supplies X_6 .

1	対象の商店
2	鞆や靴, アクセサリを販売している店 D_1
3	雑貨店 C_1
4	スポーツ用品店 A_1
5	アクセサリや雑貨を販売している店 K_1
6	アクセサリや靴, 服を販売しているアパレル店 B_1
7	アクセサリや靴, 服を販売しているアパレル店 B_2
8	薬局 L_1
9	アクセサリや靴などを販売している雑貨店 F_1
10	アクセサリや靴, 服を販売しているアパレル店 B_3

表 11 ネックレスか靴のどちらかのみを扱っている商店

Table 11 A shop that sells only necklaces or shoes.

1	アクセサリや雑貨を販売している店 K_1
2	アクセサリや服を販売しているアパレル店 G_1
3	服や靴を販売しているアパレル店 I_3
4	アクセサリも販売している天然石販売店 M_1
5	服や靴を販売しているアパレル店 I_1
6	アクセサリ専門店 N_1
7	アクセサリや服を販売しているアパレル店 G_2
8	服や靴を販売しているアパレル店 I_5
9	靴専門店 J_1
10	靴専門店 J_2
11	靴も売っているスポーツ用品店 O_1

りも販売している天然石販売店 A や靴も売っているスポーツ用品店 P_1 などが抽出されていることが分かる。このように、異なるカテゴリのアイテムを販売している商店どうしても、一部で似たようなアイテムを販売しているならば、その距離が近づくように学習できていることが分かる。

6. 考察

6.1 本研究の提案モデルとその改良に関する考察

本研究では、商店を埋め込み空間上の直線で表現する方法を提案した。これにより、アイテムとユーザが点として

与えられている場合においても、様々なアイテムを扱う商店の多様な特性を表現することが可能となった。加えて、アイテムを直線で表現することも有効に働く可能性がある。本研究のようにユーザごとの全購買履歴データに適用する場合、1人のユーザが同じアイテム購入する可能性は高く、従来の TransRec では、そのようなアイテムを表現することができない。そのため、アイテムを直線で表現することは有効となる可能性がある。

また、提案モデルでは、TransRec を電子商店街の購買履歴データへ適用することを想定し、TransRec に商店と商店におけるアイテムに対する嗜好を追加している。しかし、2.4.2 項に示したように電子商店街には様々な使い方がある。本研究でのモデル化は、商店ページを閲覧した後に購買を行うユーザを想定しているが、商品を決定した後に値段などを比較して購入する商店を決定するユーザを考慮することでも予測精度が向上すると考えられる。

一方、提案モデルにおいて商店が与えられたもとのアイテムに対する嗜好を表現したが、商店ページを閲覧してから購買を行うユーザにはどの商店を好むかという商店に対する嗜好も存在する。そのため、提案モデルに対して、さらに商店に対する嗜好を追加することが考えられる。

さらに、本研究では TransRec に対して商店情報を補助情報として分析に用いることを提案したが、これ以外にも精度を向上させる方法は多々考えられる。1つは、ジャンルなどに応じてそれぞれにモデルを構築する方法である。これは、EC サイトを使う際にたとえばゴルフクラブ→布団→ゴルフバッグといったように、必ずしもアイテムの前後間に関係があるとは限らない。よって、この場合はゴルフクラブとゴルフバッグの空間、それとは別に布団の空間を作る必要がある。そこで、混合回帰 [35] などの考え方を応用して複数のモデルを構築することで精度の向上が可能であると考えられる。

以上のように本研究の提案モデルには様々な改良の余地があると考えられる。これらを比較、検討していくことが必要となる。

6.2 提案モデルを用いた分析に関する考察

次に、提案モデルに基づく分析について考察をする。本研究で得られた商店の直線を用いて商店どうしの関係性を分析しようとした場合、3つ以上の商店間の類似性を考えると、「店舗 A と店舗 B は最小距離が小さい」かつ「店舗 B と店舗 C は最小距離が小さい」ということが成り立っていたとしても「店舗 A と店舗 C は最小距離が非常に大きい」という例を簡単に作るができる。すなわち、「直線間の最小距離」を2店舗間の類似性として見なすことは可能であるものの、これを距離と定義してクラスタリングなどを行うことが難しい。そこで、点ではなく、直線のような図形によって類似した直線どうしをまとめ、クラスタリ

ングするような手法は有効なアプローチとなりうることから、今後の課題とする。

6.3 レビューデータの使用に関する考察

本研究は、購買履歴データへの適用を想定したモデルを提案しているが、適用例としてレビューの履歴データの分析結果を提示している。本来であれば EC サイトの購買履歴データに対して本研究の提案手法を適用し、その結果を評価することが最適である。しかしながら、今回はそのようなデータの利用が不可能であったために、レビューデータにより代替した。

ただし、レビューデータはユーザが実際に購買した商品に対する評価であり、レビューを投稿したユーザは必ず該当する商品を購入している。レビューデータが購買データからランダムにサンプリングされたデータと見なせれば、購買データにおけるユーザ、商店、アイテムの関係性はレビューデータにも保存されていると位置づけられるため、本稿の結果については、ある程度の妥当性があると判断できる。ただし、「人気商品にはレビューが付きやすい」、「ユーザによってレビューの頻度が異なる」など、レビューデータには偏りが生じることも考えられる。この偏りがどの程度のものなのか、実際の分析結果にどのような影響を与えるのかについての検証は今後、検証していくことが必要である。

6.4 提案手法の実応用に関する考察

最後に、実応用について考察する。本研究における提案の評価では、電子商店街におけるレビューデータを用いているため、実応用への妥当性を確認するためには、購買履歴データを用いて検証することが望ましい。レビューデータと異なり購買履歴データにはユーザごとに同じアイテムが複数存在すると考えられ、そのデータを取り除くことやデータ数が莫大になることでユーザの嗜好を表現するのに十分な表現力を得ることが難しくなるといった問題が考えられる。この点に関しては十分な検証が必要である。また、推薦するアイテムを決定した後に、どの商店のアイテムを推薦するか決める方法を定めなくてはならない。このことは、実際の EC サイト管理上、特定の商店のアイテムが自動的に何度も推薦されてしまう可能性も有するため、単なる予測精度上の観点からの推薦だけでなく、実ビジネスや取引上の制約も考慮する必要が出てくると考えられる。これらの実応用上の課題を解決することも今後の課題である。

7. 結論と今後の課題

本研究では、従来手法である TransRec をベースとし、直線で表現された商店と各商店でアイテムを選択するユーザの嗜好をベクトルで表現したモデルを提案した。商店ベク

トルを点ではなく線で表現することにより、電子商店街に対するユーザの嗜好が学習され、これを考慮した推薦が可能となる。このことを示すために、電子商店街の実データを用いた実験を通じて、提案手法の有効性を示すことができた。また、実データを用いた分析を通じて、商店を表現する直線（ベクトル方程式）が似たようなアイテムを販売しているならば、その商店どうしが近づくように学習できていることを示した。本研究の成果により、ショッピングモール型の EC サイトである電子商店街において、ユーザの商店が与えられたもとのアイテムに対する嗜好を考慮した購買行動分析や商品推薦が可能になったといえる。これに対して実データを用いた実験により、電子商店街の購買履歴データに対して提案手法が有効であることを示した。

本研究において今後検討すべき課題は以下のとおりである。まず、提案手法は従来手法と比較してパラメータ数が多いため、データ数が少ないユーザに対しては有効でない可能性がある。そのため、検証を行い、データ数が少ないユーザも考慮したモデルに改良する必要があると考えられる。また、本研究では提案手法は2つの目的関数を最大化するようにパラメータを更新したが、これが最も良いパラメータになるとは限らないという点についても今後の課題となる。購買が行われていない商店を学習する際に、本提案モデルは従来手法と異なりアイテムからアイテムに対してではなく、商店からアイテム間に嗜好を設定しているため、商店とアイテムの距離ができるだけ離れるように学習されてしまうという問題がある。そのため、提案手法のパラメータを1つの目的関数で推定できるような推定手法の検討が必要である。

謝辞 本研究で用いた楽天市場データセットは、国立情報学研究所の IDR データセット提供サービスにより楽天株式会社様からご提供いただきました。ご協力に心より感謝申し上げます。

参考文献

- [1] Adomavicius, G. and Tuzhilin, A.: Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions, *IEEE Trans. Knowledge and Data Engineering*, Vol.17, No.6, pp.734–749 (2005).
- [2] 神島敏弘：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 (2007).
- [3] Gunawardana, A. and Shani, G.: A Survey of Accuracy Evaluation Metrics of Recommendation Tasks, *Journal of Machine Learning Research*, Vol.10, pp.2935–2962 (2009).
- [4] Jannach, D., Zanker, M., Felfernig, A. and Friedrich, G.: *Recommender Systems: An Introduction*, Cambridge University Press (2010).
- [5] Park, D.H., Kim, H.K., Choi, I.Y. and Kim, J.K.: A Literature Review and Classification of Recommender System Research, *Expert Systems with Applications*, Vol.39, No.11, pp.10059–10072 (2012).
- [6] Aggarwal, C.C.: *Recommender Systems: The Textbook*, Springer (2016).
- [7] Hofmann, T. and Puzicha, J.: Latent Class Models for Collaborative Filtering, *Proc. 16th International Joint Conference on Artificial Intelligence*, Vol.2, pp.688–693 (1999).
- [8] Hofmann, T.: Gaussian Latent Semantic Models for Collaborative Filtering, *Proc. 26th Annual International ACM SIGIR Conference*, Vol.22, No.1, pp.259–266 (2004).
- [9] Si, L. and Jin, R.: Flexible Mixture Model for Collaborative Filtering, *Proc. 2003, International Conference on Machine Learning*, Vol.2, pp.704–711 (2003).
- [10] Hofmann, T., Latent Semantic Models for Collaborative Filtering, *ACM Trans. Information Systems (TOIS)*, Vol.22, No.1, pp.89–115 (2004).
- [11] Suzuki, T., Kumoi, G., Mikawa, K. and Goto, M.: A Design of Recommendation Based on Flexible Mixture Model Considering Purchasing Interest and Post-Purchase Satisfaction, *Journal of Japan Industrial Management Association*, Vol.64, No.4E, pp.570–578 (2014).
- [12] Miyahara, K. and Pazzani, M.J.: Improvement of Collaborative Filtering with the Simple Bayesian Classifier, *IPSJ Journal*, Vol.43, No.11, pp.3429–3437 (2002).
- [13] Wang, K. and Tan, Y.: A New Collaborative Filtering Recommendation Approach Based on Naive Bayesian Method, *ICSI 2011, LNCS*, Vol.6729, Part II, pp.218–227 (2011).
- [14] Li, T., Wang, J., Chen, H., Feng, X. and Ye, F.: A NMF-based Collaborative Filtering Recommendation Algorithm, *2006 6th World Congress on Intelligent Control and Automation*, DOI: 10.1109/WCICA.2006.1714249 (2006).
- [15] Koren, Y., Bell, R. and Volinsky, C.: Matrix Factorization Techniques for Recommender Systems, *Computer*, Vol.42, No.8, pp.30–37 (2009).
- [16] Mikolov, T., Sutskever, I., Chen, K., Corrado, G.S. and Dean, J.: Distributed representations of words and phrases and their compositionality, *Advances in Neural Information Processing Systems* (2013).
- [17] Barkan, O. and Koenigstein, N.: Item2vec: Neural Item Embedding for Collaborative Filtering, *2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP)* (2016).
- [18] He, R., Wang-Cheng, K. and McAuley, J.: Translation-based Recommendation, *11th ACM Conference on Recommender Systems (RecSys '17)*, pp.161–169, ACM (2017).
- [19] Maes, P.: Agents that reduce work and information overload, *Comm. ACM*, Vol.37, No.7, pp.30–40 (1994).
- [20] Amazon, available from (<http://www.amazon.co.jp/>).
- [21] 楽天市場, 入手先 (<http://www.rakuten.co.jp/>).
- [22] YouTube, available from (<https://www.youtube.com/>).
- [23] Ma, H., Zhou, D., Liu, C., Lyu, M.R. and King, I.: Recommender systems with social regularization, *Proc. 4th International Conference on Web Search and Web Data Mining, WSDM 2011*, pp.287–296 (2011).
- [24] Mikolov, T., Sutskever, I., Chen, K., Corrado, G.S. and Dean, J.: Distributed representations of words and phrases and their compositionality, *Advances in Neural Information Processing Systems 26, 27th Annual Conference on Neural Information Processing Systems 2013*, pp.3111–3119 (2013).
- [25] Bordes, A., Usunier, N., Garcia-Duran, A., Weston, J. and Yakhnenko, O.: Translating embeddings for model-

- ing multi-relational data, *Advances in Neural Information Processing Systems (NIPS)*, pp.2787-2795 (2013).
- [26] Lin, Y., Liu, Z., Sun, M., Liu, Y. and Zhu, X.: Learning entity and relation embeddings for knowledge graph completion, *AAAI Conference on Artificial Intelligence (AAAI)*, pp.2181-2187 (2015).
- [27] Rendle, S., Freudenthaler, C. and Schmidt-Thieme, L.: Factorizing personalized Markov chains for next-basket recommendation, *International Conference on World Wide Web (WWW)*, pp.811-820 (2010).
- [28] 幡鎌 博: インターネットモール事業のビジネスモデル比較, 経営情報学会 2017 年秋季全国研究発表大会, D3-2 (2017).
- [29] 宮内拓智: 小売マーケティング革新と業態コンセプトの戦略性, 京都創成大学紀要, Vol.2, pp.53-80 (2002).
- [30] 丸山将一, 根来龍之, 栗田 学: 電子商店街における収益性コントロールの歴史的な分析, 経営情報学会全国研究発表大会要旨集 (2006).
- [31] 成 耆政: インターネットショッピングモール企業における CRM 戦略の構築, 朝日大学経営論集, Vol.21, pp.35-54 (2006).
- [32] 横田智久, 浜田康宏, 関 良明: レコメンデーション機能を有するサイバー商店街の提案, 電子情報通信学会技術研究報告 OFS, オフィスシステム, Vol.100, No.540, pp.7-12 (2001).
- [33] Vilnis, L. and McCallum, A.: Word representations via Gaussian embedding, arXiv preprint arXiv:1412.6623 (2014).
- [34] 楽天株式会社: 楽天市場データ, 国立情報学研究所情報学研究データリポジトリ (オンライン), DOI: 10.32130/idr.2.1 (2014).
- [35] Grun, B. and Leisch, F.: FlexMix Version 2: Finite Mixtures with Concomitant Variables and Varying and Constant Parameters, *Journal of Statistical Software*, Vol.28, No.4, pp.1-35 (2008).
- [36] Li, H., Liu, Y., Mamouli, N. and Rosenblum, D.S.: Translation-Based Sequential Recommendation for Complex Users on Sparse Data, *IEEE Trans. Knowledge and Data Engineering*, Vol.32, No.8, pp.1639-1651 (2019).
- [37] Tengkiattrakul, P., Maneeroj, S. and Takasu, A.: Translation-based Embedding Model for Rating Conversion in Recommender Systems, *2019 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, pp.217-224 (2019).
- [38] Chairatanakul, N., Murata, T. and Liu, X.: Recurrent Translation-Based Network for Top-N Sparse Sequential Recommendation, *IEEE Access*, Vol.7, pp.131567-131576 (2019).
- [39] Wu, B., He, X., Sun, Z., Chen, L. and Ye, Y.: ATM: An Attentive Translation Model for Next-Item Recommendation, *IEEE Trans. Industrial Informatics*, Vol.16, No.3, pp.1448-1459 (2020).
- [40] Zhang, Y., He, Y., Wang, J. and Caverlee, J.: Adaptive Hierarchical Translation-based Sequential Recommendation, *Proc. Web Conference 2020 (WWW'20)*, pp.2984-2990, Association for Computing Machinery (2020).



大堀 祐一

1994 年生。2018 年早稲田大学創造理工学部経営システム工学科卒業。2020 年同大学大学院創造理工学研究科経営デザイン専攻修了。機械学習を用いたデータ分析に関する研究に興味を持つ。



楊 添翔 (正会員)

1988 年生。2015 年早稲田大学大学院国際通信研究科修士課程修了。現在、早稲田大学大学院創造理工学研究科経営システム専攻博士課程在籍中。2019 年より早稲田大学創造理工学部助手。機械学習に基づく購入履歴データに関

する研究に従事。



山下 遥

1987 年生。2010 年東京理科大学理工学部経営工学科卒業。2012 年慶應義塾大学大学院修士課程修了。2015 年慶應義塾大学大学院博士課程修了。博士 (工学)。2015 年早稲田大学創造理工学部助手。2017 年より上智大学理

工学部助教。品質管理, 統計学, 情報工学を融合させた新たなデータ解析方法に関する研究に従事。応用統計学会, 日本経営工学会, 日本品質管理学会等, 各会員。



後藤 正幸 (正会員)

1994 年武蔵工業大学大学院修士課程修了。2000 年早稲田大学大学院博士課程修了。博士 (工学)。1997 年早稲田大学理工学部助手。2000 年東京大学大学院工学系研究科助手。2002 年武蔵工業大学環境情報学部助教授。

2008 年早稲田大学創造理工学部経営システム工学科准教授。2011 年同大学教授。主に機械学習モデルを活用したビジネスアナリティクス, データサイエンスの研究に従事。著書に、『入門パターン認識と機械学習』, コロナ社 (2014), 『ビジネス統計 統計基礎とエクセル分析』, オデッセイコミュニケーションズ (2015) 等。IEEE, INFORMS, 電子情報通信学会, 人工知能学会, 経営情報学会等, 各会員。