

異種ドメインのユーザ・アイテムクラスタ情報を用いたペア ワイズ学習に基づく購買予測手法

海保 拓真¹ 原 隆浩² 黒川 茂莉³ 米川 慧³ 天方 大地² 前川 卓也²

概要：オンラインショッピングサービス上の膨大な量のアイテムからユーザの嗜好に合うアイテムを優先して推薦するためのランキング学習は重要である。ランキング学習には、ユーザの行動情報が大量に必要となるが、実際にユーザがもつ購買履歴は非常に少ない。本論文では、広告配信サービスの閲覧履歴をクラスタリングして得られたユーザクラスタの行動特徴を利用し、購買履歴の少ないユーザへの商品推薦を可能にする購買予測手法を提案する。提案手法では、ユーザ・アイテム間の関連度予測モデルのランキング学習の際にユーザクラスタの行動特徴を利用し、推薦対象のユーザとの購買履歴がないアイテムのランキングを予測できるように学習を行う。これにより、ユーザの嗜好を捉えた商品推薦が可能となり、ユーザが購買していないアイテムの推薦によってユーザの購買率の上昇を実現する。

キーワード：レコメンドシステム、ランキング学習、ネガティブサンプリング、クロスドメイン推薦

1. はじめに

近年、様々なオンラインショッピングサービスが広く普及している。オンラインショッピングサービスでは、ユーザの嗜好パターンやアイテムの購買の傾向を分析し、ユーザごとに興味のあるアイテムや情報を抽出して表示する、アイテムの推薦が行われている。オンラインショッピングサービス上のアイテム推薦では、各ユーザに対して、同時に提示不可能な量のアイテムが存在するため、ユーザが欲しいアイテムを適切にランキングし、ユーザの嗜好に合うアイテムを優先して推薦するためのランキング学習 (Learning to rank) が注目を集めている。

代表的なランキング学習アルゴリズムの1つにペアワイズ学習がある [11]。ペアワイズ学習は、2つのアイテムペアに対してユーザがどちらを好むかを学習することでユーザの全アイテムに対するランキングを予測する。代表的なペアワイズ学習手法の1つに Bayesian Personalized Ranking (BPR) がある [12]。BPR は、「あるユーザが購買したアイテムは、購買しなかったアイテムに比べて興味がある」という仮定を基に、ユーザが購買していないアイテムより購買したアイテムを好む確率を最大化するように学習する。そのため、購買していないアイテムの相対的なランキング順序を推定可能になり、購買していないアイテム間の

ランキング順序の推定も可能になる。しかし、学習に十分な購買履歴がない場合、アイテム間のランキング順序を決定するための購買アイテムが不足するため、購買していない未評価アイテム間のランキング順序を学習することが難しい。

そこで本研究では、異種ドメインのユーザ・アイテムクラスタ情報を用いたペアワイズ学習に基づく購買予測手法を提案する。提案手法では、ユーザのインタラクションが豊富な他のドメインでユーザの行動情報を基に共クラスタリングを行い、得られたユーザクラスタの行動特徴をターゲットドメインへ転移することで未評価アイテム間のランキング順序の学習を可能にするペアワイズ学習を用いる。また、ドメイン間でユーザモデリングを統一するために、プライバシーや権益の保護の観点から、ユーザの ID 情報を用いず、個人識別不可能なユーザクラスタ情報でソースドメインのユーザの行動モデルを表現し、ターゲットドメインへ転移することでプライバシーにも配慮しつつ、ユーザモデルの転移を可能にする。本研究では、提案手法でのペアワイズ学習を基に、ユーザのインタラクションが少ない場合を想定し、ユーザやアイテムの属性情報を入力とするニューラルネットワークモデルを利用して、ユーザ・アイテム間の関連度を予測して、各ユーザの購買予測を行う。

提案手法の性能を評価するために、実際のオンラインショッピングサービスのデータと広告配信サービスのデータを用いて実験を行った。ユーザのインタラクションが豊

¹ 大阪大学大学院情報科学研究科マルチメディア工学専攻

² 大阪大学情報科学研究科

³ 株式会社 KDDI 総合研究所

富なソースドメインからのユーザクラスタ情報の転移が、インタラクションのデータが疎であるターゲットドメイン自身から抽出したユーザクラスタ情報に比べて、効果的であることを検証するため、ソースドメインのデータセットとして、オンラインショッピングサービスと広告配信サービスの2つのデータセットからユーザクラスタ情報の抽出を行った。そして、本研究ではデータセットのインタラクション数の違いが推薦精度に与える影響を比較するために、異なる2つのドメインに対し、それぞれインタラクション数の異なる2つのデータセットを用意して実験を行った。提案手法は単純な手法より高い推薦精度を達成し、提案手法のネガティブサンプリングによる推薦の有効性を確認した。

以下、第2章では関連研究を紹介し、本研究との関連を述べる。第3章では本研究における定義や想定する環境について説明する。第4章では本研究で提案する異種ドメインのユーザクラスタ情報を用いたペアワイズ学習に基づく購買予測手法について説明する。第5章では提案モデルの評価及びその結果の考察を行う。最後に第6章で本研究のまとめと今後の課題について述べる。

2. 関連研究

2.1 ランキング学習

ランキング学習 (Learning to rank) は、クエリごとに適したデータを取り出すためのランキングを機械学習によって予測する手法で、主に情報検索の分野で応用されている [9]。商品推薦も同様に各ユーザへ適したアイテムを推薦するためにアイテムランキングを必要とするため、ランキング学習の手法が大きな成果をあげている。推薦システムにおけるランキング学習では、一般的なランキング学習と異なり、ランキングを推定するために大量のアイテムをユーザごとに並び替える必要があり、また、得られるユーザの行動履歴は閲覧や購買といった暗黙的な評価が多く、ユーザがアイテムを好んでいないという評価を得られないという、one-class problem がある [13]。商品推薦では、各ユーザへ推薦するアイテムを決定する際に、ユーザ・アイテム間の正確な関連度予測が重要ではなく、各ユーザのアイテム間の相対的なランキング順序が重要である。そのため、ユーザ・アイテム間の関連度の推定にアイテム間のランキング順序を考慮するためにペアワイズ学習が用いられる [12]。ペアワイズ学習は、アイテム間のランキング順序を相対的に学習するため、ポイントワイズランキングでは関連度予測が難しい未評価アイテムの相対的な順位を学習することができ、未評価アイテム間のランキング順序を推定することで、one-class problem の影響を小さくできる。しかし、データセットの密度がスパースであり、購買アイテムが非常に少ないコールドスタート問題では、アイテム間のランキング順序の正解ラベルとなるユーザのインタラ

クションが非常に少ないため、アイテム全体のランキングを正しく推定することが難しく、ユーザの嗜好に合った未評価アイテムを推薦することが困難である。

ペアワイズ学習の1つにBPRがある。BPRでは「ユーザは購買していないアイテムより購買したアイテムをより好む」と仮定し、ユーザが購買していないアイテムより購買したアイテムを好む確率の尤度関数を基にしたペアワイズ損失を最小化することでアイテム全体のランキングの学習を行う。BPRによるペアワイズ学習を行うための損失関数BPR-OPTは以下の式で定義される。

$$BPR - OPT = \sum_{(u,i,j) \in D_S} \ln \delta(\hat{y}_{ui} - \hat{y}_{uj}) - \lambda_{\Theta} \|\Theta\|^2 \quad (1)$$

Θ は学習するモデルのパラメータを表し、 \hat{y}_{ui} , \hat{y}_{uj} は関連度予測モデルが出力したユーザとアイテムの関連度を表す。 δ はシグモイド関数を表す。 $\lambda_{\Theta} \|\Theta\|^2$ は予測モデルのパラメータの正則化項を表し、過学習を防ぐ。

本研究では、損失関数としてBPR-OPTを用いて、購買したアイテムと購買していないアイテムとのペアワイズ学習および未評価アイテム間のペアワイズ学習を行うことでコールドスタート問題の影響を小さくする。

2.2 ネガティブサンプリング

推薦分野では、一般的にユーザの行動履歴としてアイテムの閲覧や購買といった暗黙的な評価を用いる。情報検索でのランキング学習は商品推薦とは異なり、クリックスルーデータから直接ランキング可能であるが、推薦分野におけるランキング学習は、正の観測値のみからなる暗黙的な評価からしか推測できない [4]。そのため、一般的には、ユーザが好むアイテムは他のアイテムより上位にランキングされるべきであると仮定して、ユーザにアイテムのランキングリストを提供する [1]。

しかし、実際のオンラインショッピングサービス上では、情報検索でのランキング学習と比べ、ランキングを考慮すべきアイテムの数が非常に多く、またユーザの購買したアイテムの集合は、全体のアイテム集合と比べて、非常に少ないため、購買したアイテムと未評価アイテムの数が不均衡なデータを扱わなければならない。そのため、推薦分野におけるランキング学習では、一般に、ユーザが購買したアイテムはすべて正例であると仮定し、ユーザが購買していないアイテムの一部を負例として選択する。このように、ユーザの未評価アイテム集合から、ある戦略に基づいて学習に効果的な負例を選択する手法をネガティブサンプリングと呼ぶ [3]。Uniform Sampling はネガティブサンプリングの候補となるアイテムから一様分布に基づき、アイテムをサンプリングする。Dynamic Negative Sampling (DNS)[15] は、学習途中のモデルの出力に応じてサンプリ

ング分布を動的に変化させ、各エポックのサンプリング品質を向上させる手法である。モデルの学習過程において、負例がモデルにもたらす情報はモデルの学習とともに変化し続ける。DNSは、ネガティブサンプリングを行うたびに学習途中のモデルをサンプリングモデルとして使用し、各サンプルのスコアを付け、スコアの高いサンプルを負例として選択することで、学習途中のモデルにとって、効果的な負例を動的に選択できる。このように、モデルにとって、予測の困難なネガティブサンプルはハードネガティブサンプルと呼び、パラメータに大きな勾配を与える [5]。ハードネガティブサンプルは正例と類似した負例であるため、ハードネガティブサンプルを学習することで、予測モデルは正例と負例の決定境界をより効果的に学習することができる [14]。

3. 提案手法

提案手法は、Codebook Construction, Codebook Transfer [7], ペアワイズ学習の3つの学習ステップからなる。Codebook Constructionは、ユーザのインタラクションが豊富なソースドメイン上のユーザの各アイテムへの閲覧数を要素とする評価行列について、共クラスタリングを行い、得られたユーザ・アイテムのクラスタごとに評価値を集約することで、各ユーザのアイテムクラスタレベルの評価パターンをユーザクラスタの行動特徴として学習する。Codebook Transferは、得られたユーザクラスタの評価パターンのうち、ターゲットドメインの評価行列の各行のユーザのベクトルとの誤差が最も小さいユーザクラスタをターゲットドメインのユーザにマッピングすることでソースドメインから学習したユーザクラスタの評価パターンを転移する。提案手法のペアワイズ学習では、転移したコードブックを基に購買したアイテムと未評価アイテムおよび未評価アイテム間のペアワイズ学習を行う。転移したコードブックを基に、関連度予測モデルの学習に適した負例をサンプルおよび合成することで効果的なペアワイズ学習を行うことが出来る。提案手法のペアワイズ学習では、さらに、ユーザが購買したアイテムから正例をサンプルして学習する部分とコードブックを基に未評価アイテムから正例と負例をそれぞれサンプルして学習する部分からなる。未評価アイテム間のペアワイズ学習を行うことで、正例のサンプリング候補となる購買したアイテムが少ない場合でも、学習を行うことができ、コールドスタート問題の影響を小さくすることができる。学習を行うユーザ・アイテムの関連度予測モデルには、ユーザプロフィールやアイテムコンテンツを表すカテゴリ特徴や連続値を入力とするコンテンツベースのニューラルネットワークモデルを用いる。

3.1 Codebook Construction

Codebook Construction [7] では、ソースドメインの評価行列 X_{aux} に共クラスタリングを行い、得られたユーザ・アイテムのクラスタを表す分解行列 U_s, V_s を基にコードブックを生成する。IONMTF (Incomplete Orthogonal Nonnegative Matrix Tri-factorization) [8] は、分解行列の要素の非負性および直交性制約を考慮し、評価行列との欠損なし要素の誤差を小さくするよう分解行列の学習を行うことで共クラスタリングを行う。本研究では直交性制約を損失関数に反映させて、次のロス関数を最小化する。

$$\min_{U_s \geq 0, V_s \geq 0, S \geq 0} \|W \odot (X_{aux} - U_s S V_s^T)\|_F^2 + \|(\mathbf{U}_s \mathbf{1} - 1)\|_F^2 + \|(\mathbf{V}_s \mathbf{1} - 1)\|_F^2 \quad (2)$$

W は X_{aux} と同じサイズの行列で X_{aux} において欠損値のある点の要素に1、それ以外の点の要素に0が入力された行列を表す。 $\|\mathbf{U}_s \mathbf{1} - 1\|_F^2$ は、分解行列 U_s の各行の和を1にし、 $\|\mathbf{V}_s \mathbf{1} - 1\|_F^2$ も同様に分解行列 V_s の各行の和を1にする。分解行列 U_s, V_s の各行の和を1にすることで、各クラスタへの所属確率を学習すると考えられる。本研究では、各ユーザの嗜好を単一クラスタの評価パターンにより表現することは困難であると考え、ユーザ・アイテムの各クラスタへの所属確率によるソフトクラスタからユーザ・アイテムの評価パターンを表現する。得られた分解行列 U_s, V_s をユーザ・アイテムのクラスタ指標として用いて、コードブックを次の式で計算する。

$$B = [U_s^T X_{aux} V_s] \odot [U_s^T \mathbf{1} \mathbf{1}^T V_s] \quad (3)$$

\odot はアダマール除算を表す。式 (3) は、ユーザ・アイテムの共クラスタ内のすべての評価を平均化することでクラスタレベルの評価パターンを表す。

3.2 Codebook Transfer

Codebook Transfer [7] では、3.1 項で述べた Codebook Construction で得られたコードブックをターゲットドメインへ転移し、ターゲットドメインのユーザ・アイテムをコードブック上の共クラスタと対応付けることで評価行列 X_{tgt} を再構築する。具体的には、以下の二次損失関数を最小化することによって、ターゲットドメインのユーザとアイテムをコードブック上の共クラスタにマッピングする。

$$\min_{U_{tgt} \geq 0, V_{tgt} \geq 0} \|W \odot (X_{tgt} - U_{tgt} B V_{tgt}^T)\|_F^2 + \|(\mathbf{U}_{tgt} \mathbf{1} - 1)\|_F^2 + \|(\mathbf{V}_{tgt} \mathbf{1} - 1)\|_F^2 \quad (4)$$

式 (4) では、ターゲットドメインの評価行列と分解行列とコードブックの積 $U_{tgt} B V_{tgt}^T$ との誤差を最小化することで、各ユーザ・アイテムに対して、評価行列との誤差が小さいコードブック上のクラスタを選択するように分解行

列 U_{tgt} , V_{tgt} が学習し、評価行列が表す購買履歴を適切に表すクラスタをターゲットドメインのユーザ・アイテムへマッピングする。得られたユーザ・アイテムのクラスタ指標行列 U_{tgt} と V_{tgt} を基に、ターゲットドメインの評価行列 X_{tgt} の未評価値を補完する。補完された評価行列 \hat{X}_{tgt} は、次のように定義される。

$$\hat{X}_{tgt} = W \odot X_{tgt} + [1 - W] \odot [U_{tgt} B V_{tgt}^T] \quad (5)$$

3.3 コードブックを用いたペアワイズ学習

3.3.1 BPR を用いたペアワイズ学習

提案手法のペアワイズ学習では、ネガティブサンプリングの候補となる未評価アイテムのうち、ユーザに対するコードブックの値が大きいアイテムを関連度の予測が困難なハードネガティブサンプルとみなして、優先してサンプリングを行う。具体的には、まず、ネガティブサンプリングの候補アイテムを Uniform Sampling により選択する。次に、候補アイテムがもつコードブックの値でソートし、コードブックの値が高いアイテムをサンプルとする。しかし、コードブックの値はあらかじめ計算された行列の値であり、ペアワイズ学習の過程でサンプリング分布が変化することはない。また、学習途中のモデルにとってハードネガティブサンプルかどうかを考慮できない。

そこで、学習途中のモデルが予測する正例と負例との順序に着目し、正例より高いスコアをもつ負例をサンプリングするまで、繰り返し負例をサンプリングすることで、順序が異なるアイテムを優先してサンプリングする。具体的には、関連度予測モデル f_{ui} に対して、正例のアイテムを v_+ 、負例のアイテムを v_- とすると、 $f_{ui}(v_-) > f_{ui}(v_+)$ を満たすアイテムが見つかるまで、繰り返し候補アイテムからネガティブサンプリングを行う。関連度予測モデルが推定するアイテム間のランキング順序を考慮することで、コードブックを用いたネガティブサンプリングのサンプリング分布を関連度予測モデルの学習に応じて動的に変化させることができる。

3.3.2 購買していないアイテム間のペアワイズ学習

購買していないアイテム間のペアワイズ学習では、ネガティブサンプリングの候補アイテムから新たに正例、負例のアイテムをサンプリングしてペアワイズ学習を行う。しかし、候補アイテムはいずれも購買していないアイテムであるため、サンプリングした2つのアイテムのうち、どちらのアイテムをユーザが好むかは分からない。そこで、本研究では、ネガティブサンプリングの候補アイテムのうち、ユーザに対して、コードブックの値の差が大きなアイテムのペアをサンプリングし、値がより大きなアイテムを正例、値がより小さなアイテムを負例としてサンプリングする。コードブックの差が大きなアイテムのペアをサンプリングすることで、候補アイテムから未評価アイテム間のランキ

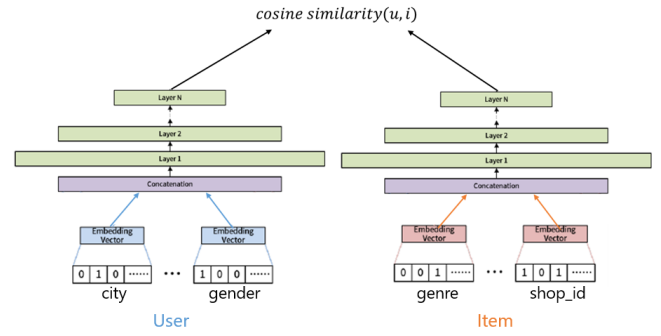


図1 提案手法で用いる関連度予測モデルの構造

ング順序を誤って学習をすることを防ぐ。しかし、コードブックの値とは異なるランキング順序をもつ、アイテムクラスタの外れ値となるアイテムをサンプリングしてしまうことで誤ったランキング順序を学習してしまう場合が存在するため、提案手法では、「コードブックの同じクラスタに属するアイテムは、似た購買パターンをもつ」という仮定を基に、負例のアイテムが属するコードブックのクラスタ内のアイテムの埋め込み表現を負例の埋め込み表現に合成することで、アイテムクラスタの外れ値の影響を小さくする。ペアワイズ学習全体の損失関数は2.1項で述べたBPRの損失関数であるBPR-OPTを用いて、次式のように表す。

$$L = \ln \delta(e_u \cdot e_{v_+} - e_u \cdot e_{v_-}) + \ln \delta(e_u \cdot e_{v_-} - e_u \cdot e_{v_{--}}) \quad (6)$$

e_{v_+}, e_{v_-} はそれぞれ正例、負例のアイテムの埋め込み表現を表し、 $e_{v_{--}}$ は未評価アイテム間のペアワイズ学習における負例のアイテムの埋め込み表現を表す。

3.4 提案手法に用いる関連度予測モデル

本節では、ユーザ・アイテム間の関連度予測に用いるモデルについて述べる。用いるモデルは購買履歴の蓄積が少ないユーザ・アイテムへの推薦を想定し、コンテンツベースのモデルを利用する。図1に提案手法で用いる関連度予測モデルの構造を示す。

このモデルは、User&Item Embedding module, User preference estimator, Similarity layer で構成される。ユーザ・アイテムの one-hot 表現がモデルの入力として与えられる。one-hot embedding は、特徴が名義尺度である場合のカテゴリデータから one-hot 表現を生成する手法である。本研究では、one-hot encoding を応用して、ユーザプロフィールやアイテムコンテンツからカテゴリ特徴を埋め込む。one-hot encoding では、各特徴は 1-of- Z 表現に変換される。 Z はその特徴に含まれるユニークな値の数を意味する。例えば、カテゴリが3つあるカテゴリ特徴量 $C = c_1, c_2, c_3$ が与えられたとき、 c_1 を $[1, 0, 0, 0]$, c_2 を $[0, 1, 0, 0]$, c_3 を

[0, 0, 1, 0], カテゴリ未知を [0, 0, 0, 1] としてそれぞれ表現する。各ユーザ・アイテムの one-hot 表現には、ユーザプロフィールやアイテムコンテンツを表すカテゴリ特徴や連続値が割り当てられている。User&Item Embedding module では、入力したユーザ・アイテムのコンテンツ情報を基にユーザ・アイテムに対して埋め込み表現を生成する。埋め込み表現の生成には、経験的に推薦性能の向上に有効であることが示されている embedding layer[2], [10] を用いて、ユーザ・アイテムのコンテンツ情報から有用な潜在的特徴を自動的に抽出する。ユーザ・アイテムの埋め込み表現は各特徴の埋め込み表現を学習し、連結した埋め込み表現を用いることで表現する。また、ユーザプロフィールやアイテムコンテンツを表す連続値を入力する場合、正規化した後の値をそのまま e_{uv} に連結する。

各特徴の埋め込み表現を結合したユーザ・アイテムの埋め込み表現を最適化するために、User preference estimator において、複雑な非線形ユーザ嗜好の学習に広く用いられている多層完全連結ニューラルネットワークを適用することでユーザやアイテムの表現を最適化しながら学習を行う。具体的には、同じ構造をもつ MLP を 2 つ用意し、ユーザ・アイテムの埋め込み表現をそれぞれ学習する。出力されたユーザ・アイテムの埋め込み表現を基にユーザとアイテムの関連度を求めるために Similarity layer では、ユーザ・アイテムの関連度をユーザ・アイテムの埋め込み表現のコサイン類似度として表現する。コサイン類似度は以下の式で定義される。

$$\cos(\vec{x}, \vec{y}) = \frac{\vec{x} \cdot \vec{y}}{|\vec{x}| |\vec{y}|} = \frac{\vec{x}}{|\vec{x}|} \cdot \frac{\vec{y}}{|\vec{y}|} = \frac{\sum_{j=1}^m x_j y_j}{\sqrt{\sum_{j=1}^m x_j^2} \cdot \sqrt{\sum_{j=1}^m y_j^2}} \quad (7)$$

4. 評価実験

4.1 評価環境

提案手法におけるユーザクラスタ情報を用いたペアワイズ学習の有効性を検証するために、オンラインショッピングサービスと広告配信サービスにより実際に収集された 2 つの異なるドメインの実データを用いて、ユーザへのアイテム推薦の精度の評価を行った。収集されたデータのうち、2017 年 4 月 27 日から 2017 年 6 月 7 日の間に収集されたデータを実験に用いた。実際に推薦を行うターゲットドメインの学習データのうち、購買数が 5 件未満のユーザを削除し、それに伴い、購買履歴が存在しなくなったアイテムを削除したデータを利用して実験を行った。トレーニングデータおよびバリデーションデータは各ユーザのアイテムの購買数を要素とする評価行列で、テストデータは、各ユーザごとの実際に購買したアイテムリストである。テストデータは、学習データに存在していたユーザ・アイテムの購買ログのみを抽出して作成し、学習・テスト期間の

表 1 ソースドメインのデータセットの統計情報

	広告配信サービス	オンラインショッピングサービス
ユーザ数	32,064 人	748 人
アイテム数	17,482 個	1,780 個
総行動履歴	1,575,075 件	4,280 件

表 2 ターゲットドメインのデータセットの統計情報

	オンラインショッピングサービス
ユーザ数	830 人
アイテム数	1,886 個
総行動履歴	59,041 件

両方で購買を行い、かつ学習データに存在しているアイテムをテストデータの期間に購入しているユーザを対象に推薦を行い、提案手法の評価を行う。

ソースドメインのデータセットとして、オンラインショッピングサービスと広告配信サービスの 2 つのデータセットを用いることで、ユーザのインタラクションが豊富なソースドメインのデータセットからのコードブックの転移は、データセットが疎なターゲットドメインの評価行列自体からコードブックを抽出するより効果的であることを検証する。Codebook Construction を行う際には、行動履歴から作成した評価行列のうち、行動履歴の件数の多いユーザとアイテムを 500 ずつ選んだ部分行列を抽出し、クラスタリングを行う。本実験で用いたソースドメインおよびターゲットドメインのデータセットの統計情報を表 4.1 に示す。

4.2 評価手順

本実験では、ソースドメインの学習データの閲覧履歴を用いて評価行列を作成し、3 章で説明した Codebook Transfer を用いて、コードブックを学習した。そして、得られたコードブックを基にターゲットドメインの評価行列の未評価値の欠損値補完を行い、得られた補完行列を利用して、ペアワイズ学習を行ったユーザ・アイテムの関連度予測モデルが各ユーザへのアイテム推薦ができるかについて性能を評価した。具体的には、ユーザに対する各アイテムの関連度を予測し、大きな関連度をもつアイテムを上位で推薦するような推薦リストを全ユーザについて作成し、Top-k リストを作成する。テストデータにおけるユーザの購買したアイテムリストと Top-k リストの重複した要素数により、提案手法の性能を計測した。評価指標には $HR@k$ ($Hit Rate@k$) を用いた。 $HR@k$ は、あるテストユーザ r に対してアイテムの推薦リストの上位 k にユーザ r の購買リストのアイテムと同一のアイテムが含まれているか否かの精度を測る指標である。 $HR@k$ は以下の式で定義される。

$$HR@k = \frac{1}{N_{item}} \sum_{i=1}^{N_{te}} \sigma(t_i \in S_i(k)) \quad (8)$$

ここで N_{item} はテストユーザの購買したアイテムの総数であり、 N_{te} はテストユーザの総数を表す。また、 t_i はテストユーザ r の購買したアイテムの集合を表す。 $S_i(k)$ はテストユーザ r への推薦リストの上位 k のアイテム集合である。 $\sigma(t_i \in S_i(k))$ は集合同士の重複した要素の個数を返す関数であり、 t_i が $S_i(k)$ に含まれる要素の個数を返す。

提案手法の推薦精度に対するコードブックの影響を検証するため、ソースドメインとターゲットドメインからそれぞれ抽出したコードブックとランダムな値で埋めたコードブックの3つのコードブックを用いてそれぞれ提案手法の学習を行った場合で実験を行った。

本実験では、提案手法の推薦精度を評価するための比較手法として、以下の4種類の手法を用いた。

- MSE: ポイントワイズ学習の損失関数の1つである MSE を用いて、提案手法の関連度予測モデルを学習した手法。
- BPR: ペアワイズ学習の損失関数の1つである BPR-OPT を用いて、提案手法の関連度予測モデルを学習した手法。
- NMF: 行列分解を用いた欠損値補完手法。
- Top popular: 購買数順にアイテムをソートした人気順のアイテムリストを推薦する手法。

また、提案手法の推薦精度に対するネガティブサンプリングの影響を検証するための比較手法として、以下の3種類の手法を用いた。

- Uniform Sampling: 一様分布に基に、ネガティブサンプルをサンプリングする手法。
- DNS: 2.2項で述べた学習途中の関連度予測モデルが最も高いスコアをつけたアイテムを適応的にネガティブサンプリングする手法。
- Codebook-based negative sampling: 提案手法で用いたコードブックの値を重みとして重み付きサンプリングを行う手法。

提案手法の推薦精度に対するコードブックの影響を検証するための手法として、以下の3種類の手法を用いた。

- Source-codebook: ソースドメインのデータセットから転移したコードブックを用いた提案手法。
- Target-codebook: ターゲットドメインのデータセットから抽出したコードブックを用いた提案手法。
- Random-codebook: ランダムな値で埋めたコードブックを用いた提案手法。

4.3 実装

提案手法のネットワークは PyTorch^{*1}を用いて実装した。学習するパラメータの初期値はガウス分布 $N(0, 0.01^2)$ からランダムに初期化される。学習の最適化には Adam[6]

*1 <https://pytorch.org/>




図2 ユーザに対するアイテム推薦精度




図3 異なるネガティブサンプリングを用いた場合のユーザに対するアイテム推薦精度

を使用した。学習のバッチサイズは、同じコードブック上のクラスタに属するアイテムセットをバッチとして、学習を行った。学習率は $[10^{-3}, 10^{-5}, 10^{-7}]$ 、ユーザ・アイテムのカテゴリ特徴の埋め込み表現の次元数は $[16, 32, 64]$ の値を試し、最も損失関数の値が小さくなる 32 を選んだ。損失関数の計算の際のネガティブサンプリングにおいて、ネガティブサンプリングの候補アイテムのサンプル数は 100 とし、候補アイテムからネガティブサンプリングを行った。

4.4 実験結果

図2より、提案手法と比較手法の精度を比較すると、すべての k において、提案手法は比較手法より高い精度を達成している。提案手法はソースドメインからターゲットドメインへ転移したコードブックを基に未評価アイテム間のペアワイズ学習を行うことで、ユーザに対して購買履歴の少ないアイテムについてもランキング順序を学習できるため、高い精度を達成していると考えられる。また、MSE と比べて、BPR が高い精度を達成していることが分かる。これは、商品推薦のランキング学習では、ユーザとアイテムとの関連度だけでなく、アイテム間のランキング順序を考慮して学習を行う BPR が有効であると考えられる。図3より、すべての閾値 k において、提案手法のネガティブサンプリング手法が他の手法と比べて高い推薦精度を達成している。提案手法が Codebook-based negative sampling を用いた推薦に比べて、高い精度を達成していることが分かる。Codebook-based negative sampling はコードブック




図 4 異なるコードブックを用いた場合のユーザに対するアイテム推薦精度

の値のみを基にネガティブサンプリングを行うため、関連度予測モデルの学習状況に合わせて、動的にサンプリング分布を変化させることができず、学習初期では大きい勾配を得られるが、学習が進むにつれて、コードブックの値の高いアイテムから得られる情報量が少なくなってしまう。提案手法では、Codebook-based negative sampling に加えて、サンプルした正例と負例との順序に着目し、正例より高いスコアをもつアイテムを優先的に負例としてサンプルすることで、関連度予測モデルの学習状況に応じて、適したアイテムをネガティブサンプリングできるため、高い精度を達成していると考えられる。また、負例への埋め込み表現の合成により、未評価アイテム間のペアワイズ学習によって得られる情報量が増えて、Codebook-based negative sampling を用いた推薦に比べて、精度が向上したと考えられる。図 4 より、ソースドメインのコードブックを用いることで高い推薦精度を達成していることがわかる。これは、ユーザのインタラクションが少ないターゲットドメインから抽出したコードブックと比べて、ソースドメインのコードブックを用いた方が各ユーザに適切な評価パターンを転移できていると考えられる。

5. まとめ

本研究では、異種ドメインのユーザクラスタ情報を用いたペアワイズ学習に基づく購買予測手法を提案し、提案手法の未評価アイテム間のペアワイズ学習の有効性を確認した。

また、本研究ではソースドメインのデータセットとしてオンラインショッピングサービスのデータと広告配信サービスのデータを実験に用いたが、コードブックを変更した場合の実験からソースドメインとターゲットドメインとの関連度に応じて、提案手法による推薦精度が変化することが考えられる。そこで、今後の研究の課題として別のソースドメインデータを用いた場合の性能評価が挙げられる。

謝辞

本研究は、JST CREST (JPMJCR21F2) の支援を受けたものである。

参考文献

- [1] S. H. Bach, B. Huang, J. L. Boyd-Graber, and L. Getoor. Paired-dual learning for fast training of latent variable hinge-loss mrfs. In *Proc. Int'l Conf. on Machine Learning*, pages 381–390, 2015.
- [2] O. Barkan and N. Koenigstein. Item2vec: Neural item embedding for collaborative filtering. In *Proc. Int'l Workshop on Machine Learning for Signal Processing*, pages 1–6, 2016.
- [3] J. Ding, F. Feng, X. He, G. Yu, Y. Li, and D. Jin. An improved sampler for bayesian personalized ranking by leveraging view data. In *Proc. Int'l Conf. on World Wide Web*, pages 13–22, 2018.
- [4] Z. Hu, Y. Wang, Q. Peng, and H. Li. Unbiased lambda-damart: An unbiased pairwise learning-to-rank algorithm. In *Proc. Int'l Conf. on World Wide Web*, pages 2830–2836, 2019.
- [5] J. Huang, A. Sharma, S. Sun, L. Xia, D. Zhang, P. Pronin, J. Padmanabhan, G. Ottaviano, and L. Yang. Embedding-based retrieval in facebook search. In *Proc. ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*, pages 2553–2561, 2020.
- [6] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. *arXiv:1412.6980*, 2014.
- [7] B. Li, Q. Yang, and X. Xue. Can movies and books collaborate? Cross-domain collaborative filtering for sparsity reduction. In *Proc. Int'l Joint Conf. on Artificial Intelligence*, pages 2052–2057, 2009.
- [8] B. Li, Q. Yang, and X. Xue. Transfer learning for collaborative filtering via a rating-matrix generative model. In *Proc. Int'l Conf. on Machine Learning*, volume 382, pages 617–624, 2009.
- [9] T. Pahikkala, E. Tsivtsivadze, A. Airola, J. Boberg, T. Salakoski, et al. Learning to rank with pairwise regularized least-squares. In *SIGIR 2007 Workshop on Learning to Rank for Information Retrieval*, volume 80, pages 27–33, 2007.
- [10] W. Pei, J. Yang, Z. Sun, J. Zhang, A. Bozzon, and D. M. Tax. Interacting attention-gated recurrent networks for recommendation. In *Proc. ACM on Conf. on Information and Knowledge Management*, pages 1459–1468, 2017.
- [11] S. Rendle. Item recommendation from implicit feedback. *arXiv:2101.08769*, 2021.
- [12] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme. BPR: bayesian personalized ranking from implicit feedback. In *Proc. Conf. on Uncertainty in Artificial Intelligence*, pages 452–461, 2009.
- [13] J. Sun, S. Wang, B. J. Gao, and J. Ma. Learning to rank for hybrid recommendation. In *Int'l. Conf. on Information and Knowledge Management*, pages 2239–2242, 2012.
- [14] R. Ying, R. He, K. Chen, P. Eksombatchai, W. L. Hamilton, and J. Leskovec. Graph convolutional neural networks for web-scale recommender systems. In *Proc. ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*, pages 974–983, 2018.
- [15] W. Zhang, T. Chen, J. Wang, and Y. Yu. Optimizing top-n collaborative filtering via dynamic negative item sampling. In *Proc. Int'l Conf. on Research and Development in Information Retrieval*, pages 785–788, 2013.