

# グラフニューラルネットワークによる分離表現学習を用いた推薦の多様化

杉山 拓都<sup>†</sup> 吉田 壮<sup>††</sup> 棟安 実治<sup>††</sup>

<sup>†</sup> 関西大学大学院 理工学研究科 〒564-8680 大阪府吹田市山手町 3-3-35

<sup>††</sup> 関西大学 システム理工学部 〒564-8680 大阪府吹田市山手町 3-3-35

E-mail: †{k226567,sohy,muneyasu}@kansai-u.ac.jp

**あらまし** Graph neural network (GNN) は, collaborative filtering における精度を向上させることで, 推薦システムを大きく進歩させてきた. しかし, この進歩はしばしば, ユーザ満足度の要因である推薦の多様性を見落としている. このギャップに対処するため, 本論文では分離表現 GNN (Disentangled representation GNN: DRGNN) を提案する. DRGNN は 2 つのモジュールを用いて, 多様化を推薦候補となるアイテムの生成段階に統合する. 1 つ目のモジュールは, アイテムの嗜好とカテゴリの嗜好を分離するために, 分離表現学習を用いることで, 推薦におけるカテゴリの偏りを緩和する. 2 つ目のモジュールは, ポジティブサンプルの選択に焦点を当て, カテゴリの偏りをさらに軽減する. このアプローチは, GNN の高次接続性を維持するだけでなく, 推薦の多様性を大幅に改善する. DRGNN を代表的な二つの Web サービスのデータセット, Taobao と Amazon Beauty で広範に検証した結果, DRGNN は精度で最先端の手法に匹敵するだけでなく, 推薦における精度と多様性のバランスの取れたトレードオフを達成することに優れていることが示された.

**キーワード** 推薦システム, 多様性, グラフニューラルネットワーク, 分離表現学習

## 1 はじめに

インターネットの急激な発展に伴い, 情報過多の問題が顕在化している. この課題に対応するため, ユーザのニーズに合わせたアイテムを予測・提示する推薦システムが, Web サービスにおいて広く利用されている [1,2]. これらのシステムは, 個々のユーザに対して関心のあるアイテムを推薦することで, ユーザ体験の向上やビジネス成長を促進させるため, パーソナライズされた推薦の重要性が高まっている.

パーソナライズされた推薦システムの中核をなすのは, collaborative filtering (CF) [3] であり, これは類似したアイテム評価を行うユーザ間に共通の好みが存在するという前提に基づいている. 従来のアプローチ, 例えば matrix factorization (MF) [4] は, ユーザとアイテム間の相互作用から潜在的な要因を学習し, 推薦システムにおいて効果的なベンチマークを提供している. さらに, 最近では neural network を活用した潜在因子の学習が提案されている [5,6]. 特に, graph neural network (GNN) の導入は, この分野に顕著な進化をもたらしている [7,8]. GNN ベースの推薦システムは, ユーザとアイテムの相互作用から構築される二部グラフを利用して高次の接続性を捉え, 精度の向上を実現している.

しかし, CF などの推薦システムは, 多様性を犠牲にして精度に重点を置く傾向がある. 一般的に, アイテムはカテゴリに分類され, 多様性は推薦リスト内のカテゴリの種類によって測定されることが多い [9]. 本論文では, カテゴリレベルの多様性の強化に焦点を当てる. 推薦システムにおける多様性の向上は, フィルターバブルの解消や目新しいアイテムを推薦する機会の増加により, ユーザ満足度を高めることが知られている [10].

これは, 優れた推薦システムの開発に不可欠な要素である. しかし, 多様性は, 精度とのトレードオフを伴うため, 精度を損なうことなく多様性を高めることが課題である.

多様化された推薦システムは従来, スコアに基づいて並び替えを行うリランキングなどの後処理に依存してきた [11-13]. しかし, これらの手法は, 推薦候補となるアイテムの生成段階での精度と多様性のトレードオフに直接対処していない. この問題に対応するため, 推薦するアイテムの候補を生成する段階で GNN に基づいて多様性を向上させる手法が提案されている [14,15]. これらの手法は, 観測済みの相互作用であるポジティブサンプルのカテゴリバイアスに対処するものの, 特定のケースに限定されることがある. さらに, アイテム嗜好とカテゴリ嗜好の区別が別の重要な課題である. アイテム嗜好は, ユーザの特定のアイテムに対する好みを指し, その特徴や過去の相互作用に基づく. 一方で, カテゴリ嗜好は, より幅広いアイテムが属するカテゴリに対するユーザの全体的な関心に関連付ける. 推薦モデルがカテゴリ嗜好の影響を強く受ける場合, 推薦が特定のカテゴリに偏り, ユーザの個別のアイテム嗜好や過去の行動と一致しないアイテムが推薦される可能性がある.

本稿では, 推薦システムにおけるカテゴリレベルの多様性を強化するために, 分離表現 GNN (Disentangled representation GNN: DRGNN) を提案する. DRGNN は, 学習過程においてアイテム嗜好とカテゴリ嗜好を分離するための損失関数を用いた分離表現学習を実装する. また, DRGNN は, ポジティブサンプル選択における二重レベルのカテゴリバイアスを緩和する新しいサンプリング戦略を特徴とする. この戦略は, 1) ユーザとアイテムとの相互作用におけるカテゴリの不均衡を是正し, 推薦プロセスにおいて頻繁に相互作用しないカテゴリを考慮に入れること, 2) 広範なデータセットレベルのカテゴリの不均衡

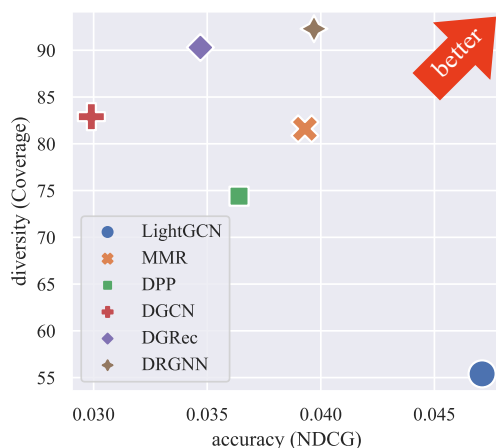


図 1: Performance comparison on Taobao. Our DRGNN addresses the trade-off between diversity and accuracy in recommendations.

に対処し、多様なカテゴリからアイテムが推薦されるようにする、という 2 点で構成される。これらの改善により、DRGNN は、推薦システムにおける精度と多様性を効果的に調整し、バランスの取れた多様な推薦を提供することができる。

本論文の主要な貢献は以下の 3 点である：

(1) 分離表現学習を取り入れた GNN ベースのモデルの導入。このモデルは、アイテム嗜好とカテゴリ嗜好を特徴表現で分離することにより、推薦性能を向上させ、個々のユーザーの興味に合わせた推薦を可能にしながらカテゴリバイアスを最小限に抑える。

(2) ユーザとデータセット全体の 2 つのレベルで存在するカテゴリバイアスに対処するポジティブサンプル選択の開発。この戦略により、カテゴリの不均衡を是正し、推薦プロセスにおける多様性を強化する。

(3) 実際の Web サービスのデータセットを用いた DRGNN の包括的な検証。図 1 に示すようにこの検証により、DRGNN が推薦の精度と多様性のバランスを取ることに於いて、既存の最先端 (SOTA) 手法を上回る能力を持つことを示した。

## 2 関連研究

### 2.1 Collaborative Filtering

CF [3] は、パーソナライズされた推薦システムの基礎を築いた。特に、行列分解 (MF) [4] を用いたモデルベースの CF は、大規模かつ疎なデータに対しても有効的な結果を得ている。MF では、ユーザとアイテムを表す潜在的な要因を学習し、ユーザのアイテムに対する評価を予測する。深層学習の進歩に伴い、Deep MF [5] や Neural CF [6] は、より複雑な潜在表現を得るためにニューラルネットワークを活用している。

### 2.2 Graph Neural Network

GNN は、グラフ構造を入力として扱うニューラルネットワークである [16–18]。Neural graph CF (NGCF) [7] は、GNN を用いて複雑なユーザ・アイテムの相互作用をモデル化する。こ

れは、ユーザとアイテムのノードを持つ二部グラフを構築し、非線形変換を取り入れながら、グラフ畳み込み処理によって隣接ノードからの階層的集約を通じて埋め込みを更新する。Light graph convolutional network (LightGCN) [8] は、NGCF で最も効果的なグラフ畳み込み処理のみを使用し、NGCF よりも高速かつ高精度な推薦を可能としている。近年では、埋め込み表現における整合性と均一性を考慮した、対照損失を統合することに注目が集まっている [19–22]。

### 2.3 Disentangled Representation Learning

相互作用から学習される埋め込み表現は、さまざまな要因から構成される。これらの要因を明確化し、分離することで、頑健性と解釈可能性をもたらすことができる [23]。Wang ら [24] は、潜在要因をチャンクに分割し、複数の意図として分離することで、有望な結果を得た。Zheng ら [25] は、ユーザの興味と適合性を分離し、人気度バイアスを抑制した。Zhang ら [26] は、人気度バイアスだけでなく、人気度分布の変化など、より一般的な実世界シナリオに対しても頑健な表現を学習する方法を提案した。

### 2.4 Diversified Recommendation

多様化推薦は、ユーザに様々なアイテムを提供し、興味の幅を広げ、目新しいアイテムを発見する機会を与えることができる。Maximum marginal relevance (MMR) のようなベンチマークとなる多様化推薦手法は、アイテムの類似性を考慮してリランキングを行うことで、多様な推薦を提供する [11]。Chen ら [12] は、推薦リストのリランキングのために Determinantal point process (DPP) を用いた。従来のパラメータのない DPP モデルとは対照的に、Chen らはパラメータを組み込むことで、多様な推薦において重要な機能である精度と多様性のトレードオフを柔軟に制御することを可能にした。一方で、これらの手法は、後処理に基づいており、生成段階でのアイテムに依存している。GNN ベースの手法は、隣接ノードのカテゴリのリバランスなど、生成段階での多様化を自然に統合することを可能にする。Diversified graph convolutional network (DGCN) [14] は、生成段階から多様性を考慮した最初の GNN ベースの手法である。DGCN は、隣接ノードのカテゴリの不均衡を解消、カテゴリ内のユーザ嗜好の学習、埋め込み空間においてカテゴリを遠ざけることによって多様性を向上させる。Diversified GNN-based RecSys (DGRec) [15] は、隣接ノードのカテゴリの不均衡に対処するためのサブモジュール関数、過剰平滑化に対処するためのレイヤーアテンション。カテゴリ内のアイテム数に応じたサンプルへの再重み付けなどを用いて多様性を促進する SOTA である GNN ベースの多様化推薦法である。

## 3 提案手法

DRGNN は GNN 技術を活用し、新たにカテゴリ嗜好のための分離表現学習モジュール (Disentangled Representation Learning Module for Category Preference, **DCP**) を導入する。DCP の主な目的は、GNN を通じて得られる嗜好表現か

らカテゴリ嗜好表現を分離し、アイテム嗜好とカテゴリ嗜好に分離して学習することである。DCPに加えて、DRGNNにはカテゴリを考慮したポジティブサンプル選択モジュール(Category-aware Positive Sampling Module, CPS)も導入されている。これらのモジュールの組み合わせは、DRGNNの他のいくつかの調整可能なパラメータとともに、DRGNNの効果を高める。

### 3.1 準備

本節では、提案手法の基盤となるLightGCNのアーキテクチャについて説明する。LightGCNは、埋め込み層、埋め込み伝播層、そして予測層の3つの層から構成されている。埋め込み層では、ユーザ $u$ 及びアイテム $i$ を $d$ 次元の埋め込み $\mathbf{e}_u^{(0)}$ および $\mathbf{e}_i^{(0)}$ で表現し、次の式に従って埋め込み行列を生成する。

$$\mathbf{E}^{(0)} = [\mathbf{e}_{u_1}^{(0)}, \dots, \mathbf{e}_{u_M}^{(0)}, \mathbf{e}_{i_1}^{(0)}, \dots, \mathbf{e}_{i_N}^{(0)}], \quad (1)$$

ここで、 $M$ と $N$ はそれぞれユーザとアイテムの総数を表す。埋め込み伝播層では、相互作用グラフを通じて埋め込み行列の伝播が行われる。対象となる相互作用グラフは、ユーザとアイテムをノード、ユーザとアイテムのインタラクションをエッジとする2部グラフである。このグラフの隣接行列 $\mathbf{A}$ は、次の式によって表現され、インタラクションが観測済みであれば1、未観測であれば0を要素とする評価行列 $\mathbf{R}$ を利用する。

$$\mathbf{A} = \begin{bmatrix} \mathbf{0} & \mathbf{R} \\ \mathbf{R}^\top & \mathbf{0} \end{bmatrix}, \quad (2)$$

$K$ 層のネットワークを考慮すると、 $k$ 層目における情報伝播は次の式に従って行われる。

$$\mathbf{E}^{(k+1)} = \left( \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right) \mathbf{E}^{(k)}, \quad (3)$$

ここで、 $\mathbf{D} = \text{Diag}(D_{11}, D_{22}, \dots, D_{(M+N)(M+N)})$ であり、 $D_{ii}$ はノード $i$ の次数である。予測層では、各層を連結した埋め込みから評価の予測が行われる。最終的な埋め込みは次の式で表される。

$$\mathbf{e}_u = \frac{1}{K+1} \sum_{k=0}^K \mathbf{e}_u^{(k)}, \mathbf{e}_i = \frac{1}{K+1} \sum_{k=0}^K \mathbf{e}_i^{(k)}. \quad (4)$$

式(4)で得られるユーザ $u$ およびアイテム $i$ の埋め込み $\mathbf{e}_u$ ,  $\mathbf{e}_i$ を用いて、次の式によりユーザに対するアイテムの評価予測が行われる。

$$\hat{y}_{ui} = \mathbf{e}_u^\top \mathbf{e}_i. \quad (5)$$

ネットワークの学習のため、BPR損失[27]を最小化する。これは、既に相互作用が観測されているユーザとアイテムのペアが、観測されていないペアよりも予測評価が高くなるという仮定に基づいて学習が行われる。

$$l(\mathbf{e}_u, \mathbf{e}_i, \mathbf{e}_j) = -\log \sigma(\hat{y}_{ui} - \hat{y}_{uj}), \quad (6)$$

ここで、 $\sigma(\cdot)$ はシグモイド関数を表す。最近の研究では、BPR損失の代わりに対照損失を用いることで良い結果を得てい

る[20,21]。本研究では、次に定義されるInfoNCE損失を採用する。

$$l(\mathbf{e}_u, \mathbf{e}_i) = -\log \frac{\exp(\cos(\mathbf{e}_u, \mathbf{e}_i)/\tau)}{\sum_{j \in I} \exp(\cos(\mathbf{e}_u, \mathbf{e}_j)/\tau)}, \quad (7)$$

ここで、 $I$ はミニバッチ内のアイテム集合を、 $\tau$ は温度パラメータを表す。埋め込みは損失の勾配に基づいて最適化される。推論時には同様に情報伝播が行われ、式(5)により評価予測が行い、値が最大となるアイテムから順に推薦される。

### 3.2 分離表現学習

本節では、アイテム嗜好とカテゴリ嗜好を区別するための表現学習法について説明する。我々が提案するDCPは、アイテム嗜好の表現を推定するエンコーダ、カテゴリ嗜好表現を推定するエンコーダ、そしてこれらの表現を分離する2つの損失関数から構成される。これらの損失関数は、カテゴリに依存しない表現を得ることを目的とし、カテゴリ嗜好をアイテム嗜好から分離するように設計されている。

アイテム嗜好を推定するエンコーダは、前節で述べたLightGCNエンコーダを使用する。ユーザとアイテムの最終的なアイテム嗜好表現 $\mathbf{e}_u, \mathbf{e}_i$ は次の式で表される。

$$\mathbf{e}_u, \mathbf{e}_i = \text{LightGCN}(u, i). \quad (8)$$

カテゴリ嗜好を推定するエンコーダも同様にLightGCNエンコーダを使用するが、アイテム嗜好との区別のために異なる埋め込み行列を用いる。具体的には、ユーザ $u$ とアイテム $i$ のカテゴリ嗜好は $d$ 次元の埋め込み $\bar{\mathbf{e}}_u^{(0)}$ ,  $\bar{\mathbf{e}}_{c(i)}^{(0)}$ として表され、次の式で埋め込み行列が構築される。

$$\mathbf{E}_c^{(0)} = [\bar{\mathbf{e}}_{u_1}^{(0)}, \dots, \bar{\mathbf{e}}_{u_M}^{(0)}, \underbrace{\bar{\mathbf{e}}_{c(i_1)}^{(0)}, \dots, \bar{\mathbf{e}}_{c(i_N)}^{(0)}}_{\text{Share embeddings in the same category}}], \quad (9)$$

ここで、 $c(i)$ はアイテム $i$ のカテゴリを示し、括弧で囲まれた部分の埋め込みにおいて同じカテゴリのアイテムは同じ埋め込みを持つ。式(9)の埋め込み行列を使用したモデル $\text{LightGCN}_c(\cdot)$ により、最終的なカテゴリ嗜好表現 $\bar{\mathbf{e}}_u, \bar{\mathbf{e}}_i$ が次の式により計算される。

$$\bar{\mathbf{e}}_u, \bar{\mathbf{e}}_i = \text{LightGCN}_c(u, i). \quad (10)$$

これらのエンコーダは相互作用を利用して学習されるが、互いの埋め込みに影響を与えないため、アイテム嗜好の表現にカテゴリ嗜好が含まれる可能性がある。したがって、2つの損失関数を用いることでアイテム嗜好とカテゴリ嗜好の正確な分離を促進する。ユーザとアイテムはそれぞれ2つの埋め込み、すなわちアイテム嗜好とカテゴリ嗜好を持ち、これは次のように表される。

$$\mathbf{e}_u^* = \mathbf{e}_u \parallel \bar{\mathbf{e}}_u, \mathbf{e}_i^* = \mathbf{e}_i \parallel \bar{\mathbf{e}}_i, \quad (11)$$

ここで、 $\parallel$ はベクトルの連結を示す。カテゴリ嗜好を必要としないアイテム嗜好の表現を得るため、拡張された表現を使用する。具体的には、ユーザとアイテムのカテゴリ嗜好の表現を別のユーザ-アイテムペアのカテゴリ嗜好の表現に置き換えると、次のようになる。

$$\mathbf{e}'_u = \mathbf{e}_u \parallel \bar{\mathbf{e}}_u, \mathbf{e}'_i = \mathbf{e}_i \parallel \bar{\mathbf{e}}_i. \quad (12)$$

埋め込みとその拡張された表現をポジティブサンプルとした拡張損失を最小限に抑えることにより、モデルはカテゴリ嗜好によらない、一貫した嗜好の表現を獲得するように学習される。

$$\mathcal{L}_{\text{aug}} = l(\mathbf{e}'_u, \bar{\mathbf{e}}_u) + l(\mathbf{e}'_i, \bar{\mathbf{e}}_i). \quad (13)$$

さらに、アイテム嗜好の表現とカテゴリ嗜好の表現が独立していることを確保するため、表現を分離するために広く使用される距離相関 [28] を最小化する [25, 26].

$$\mathcal{L}_{\text{dis}} = d\text{Cor}(\mathbf{e}_u, \bar{\mathbf{e}}_u) + d\text{Cor}(\mathbf{e}_i, \bar{\mathbf{e}}_i), \quad (14)$$

$$d\text{Cor}(\mathbf{e}, \bar{\mathbf{e}}) = \frac{d\text{Cov}(\mathbf{e}, \bar{\mathbf{e}})}{\sqrt{d\text{Var}(\mathbf{e}) \cdot d\text{Var}(\bar{\mathbf{e}})}}, \quad (15)$$

ここで、 $d\text{Cov}(\cdot)$  は距離共分散、 $d\text{Var}(\cdot)$  は距離分散を表す。

式 (16) における損失関数の最適化により、カテゴリ嗜好を含まないアイテム嗜好の表現を獲得する。推論中には、式 (8) のエンコーダから得られた埋め込みを使用して評価を予測する。

$$\mathcal{L} = \sum_{(u,i) \in \Omega} (l(\mathbf{e}_u, \mathbf{e}_i) + \lambda_1 l(\bar{\mathbf{e}}_u, \bar{\mathbf{e}}_i) + \lambda_2 \mathcal{L}_{\text{aug}} + \lambda_3 \mathcal{L}_{\text{dis}}), \quad (16)$$

ここで、 $\Omega$  は学習サンプル集合を表す。 $\lambda_1$  はカテゴリの好みを推定する影響を制御するパラメータ、 $\lambda_2$  は拡張損失の影響を調整するパラメータ、 $\lambda_3$  はアイテム嗜好とカテゴリ嗜好の表現間の独立性の強さを決定する正則化パラメータである。

### 3.3 カテゴリを考慮したポジティブサンプリング

ポジティブサンプルにおけるカテゴリの偏りは多様性の低下に繋がる。本手法では学習に使うポジティブサンプルをカテゴリを考慮して選択することで多様性の向上を図る。提案する手法を Algorithm 1 に示す。学習データにおける偏りは2つに分けられる。1つめはユーザが接触したカテゴリの偏りである。ユーザが多く見ているカテゴリのアイテムに圧倒され、ユーザが少ししか見えていないカテゴリへの学習がおろそかになる。しかし、観測したカテゴリではあるため、興味のあるカテゴリである可能性が高い。本手法ではこのようなサンプルを用いる確率を高くする。具体的には、ユーザが接触したカテゴリのアイテム数  $|u_c|$  の逆数を用いることで学習への寄与度の向上を図る。 $\alpha$  はこの偏りを調節するパラメータである。値を大きくするほど、少ない接触のカテゴリを重要視する。2つめはデータセット全体におけるカテゴリの偏りである。アイテムを多く持つカテゴリはよく学習されるのに対して、少ししかアイテムを持たないカテゴリはより良い表現を学習することが困難である。この問題を対処するために、アイテムが属するカテゴリのアイテム数  $|c|$  の逆数を用いる。この2つの偏りを考慮した確率を各サンプルに割り当て、多様性を向上させる。 $\beta$  はこの偏りを調節するパラメータである。値を大きくするほど、アイテムが少ないカテゴリを重要視する。

### Algorithm 1 Category-aware positive sampling

**Input:** users  $U$ ; trade-off parameter  $\alpha, \beta$

**Output:** training samples  $\Omega$

```

1: for all  $u \leftarrow U$  do
2:    $I \leftarrow \text{GETPOSITIVEITEMS}(u)$  ▷ Get a list of positive items
   that interacted with the user
3:   for all  $i \leftarrow I$  do
4:      $c \leftarrow \text{GETCATEGORY}(i)$  ▷ Get the category of item  $i$ 
5:      $r_i \leftarrow \frac{1}{|u_c|^\alpha |c|^\beta}$  ▷ Calculate dual-level category bias
   assigned to an item
6:   end for
7:   for all  $i \leftarrow I$  do
8:      $p_i \leftarrow \frac{r_i}{\sum_{i=0}^{|I|} r_i}$  ▷ Convert ratio to probability
9:      $P \leftarrow P + [p_i]$  ▷ Append probability
10:  end for
11:  $i_{\text{pos}} \leftarrow \text{SAMPLINGITEMWITHPROBABILITY}(I, P)$  ▷ Sample
   item based on probability assigned to each item
12:  $\Omega \leftarrow \Omega \cup \{(u, i_{\text{pos}})\}$  ▷ Add training sample
13: end for
14: return  $\Omega$ 

```

表 1: Statistics of the dataset.

Dataset	#users	#items	#categories	#interactions
Taobao	82,633	136,710	3,108	4,230,631
Beauty	8,159	5,862	41	98,566

## 4 実 験

### 4.1 データセット

本実験では、カテゴリレベルの多様化推薦システムを評価するために、2つの実世界のウェブサービスデータセットを用いた。本実験では、最新の文献 [15] で使用されている条件に基づいて比較している。1つ目のデータセットは、EC サイト Taobao から収集された **Taobao** [29] で、クリックや購入などのユーザの相互作用を暗黙的フィードバックとして扱っている。このデータセットは 10-core 設定が採用され、各ユーザとアイテムは最低 10 回の相互作用を持っている。二つ目のデータセットは、Amazon が提供する **Beauty** [30] で、ユーザとアイテムの両方に少なくとも 5 回の相互作用がある 5-core 設定を採用している。各データセットの詳細な統計は、表 1 の通りである。データセットは訓練、検証、テストデータに分割され、検証データに基づいて早期終了を行っている。

### 4.2 実験条件

実験に用いた条件は以下の通りである。畳み込み層、埋め込み次元、バッチサイズは既存研究 [14, 15] に基づき、1層、32次元、2048を採用した。オプティマイザには Adam [31] を使用する。モデルは PyTorch を用いて実装した。提案手法に用いたデータセットごとのハイパーパラメータは以下の通りである。Taobao では  $\tau = 0.15, \lambda_1 = 1.0, \lambda_2 = 0.5, \lambda_3 = 0.01, \alpha = 0.4, \beta = 0.05$  を、Beauty では  $\tau = 0.75, \lambda_1 = 0.5, \lambda_2 = 0.5, \lambda_3 = 0.01, \alpha =$

表 2: Performance comparison on Taobao.

	Taobao (Top-K=300)					Taobao (Top-K=100)				
	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$
LightGCN [8]	<b>0.121</b>	<b>0.0471</b>	55.4	2.77	0.651	<b>0.0660</b>	<b>0.0325</b>	24.2	2.23	0.563
MMR [11]	<u>0.105</u>	0.0393	81.6	3.37	0.584	0.0544	0.0259	36.7	2.87	0.485
DPP [12]	0.0985	0.0364	74.4	3.34	0.595	0.0478	0.0229	34.2	2.87	0.493
DGCN [14]	0.0835	0.0299	82.9	<u>3.55</u>	<u>0.560</u>	0.0397	0.0180	37.4	<u>3.05</u>	<b>0.452</b>
DGRec [15]	0.0918	0.0347	<u>90.3</u>	3.47	0.570	0.0457	0.0222	<u>39.4</u>	2.95	0.469
DRGNN	0.102	<u>0.0397</u>	<b>92.3</b>	<b>3.64</b>	<b>0.558</b>	<u>0.0551</u>	<u>0.0270</u>	<b>40.0</b>	<b>3.07</b>	<u>0.462</u>

表 3: Performance comparison on Beauty.

	Beauty (Top-K=300)					Beauty (Top-K=100)				
	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$
LightGCN [8]	<b>0.420</b>	<b>0.120</b>	24.6	2.29	0.663	<b>0.264</b>	<b>0.0942</b>	15.6	2.03	0.570
MMR [11]	0.383	0.102	26.6	2.46	0.643	0.215	0.0683	17.3	2.21	0.556
DPP [12]	0.325	0.0836	26.2	2.47	0.636	0.180	0.0577	17.4	2.19	0.572
DGCN [14]	0.356	0.0964	27.2	<u>2.57</u>	<u>0.622</u>	0.215	0.0733	18.9	<u>2.38</u>	<u>0.540</u>
DGRec [15]	<u>0.385</u>	0.101	<u>27.5</u>	2.42	0.663	0.219	0.0730	<u>19.3</u>	2.25	0.577
DRGNN	0.377	<u>0.106</u>	<b>29.1</b>	<b>2.63</b>	<b>0.609</b>	<u>0.231</u>	<u>0.0817</u>	<b>21.0</b>	<b>2.48</b>	<b>0.514</b>

0.8,  $\beta = 0.4$  を用いた.

### 4.3 比較手法

本節では、比較手法について説明する。実験では、提案手法 (DRGNN) を以下に示すベースラインの手法と最先端 (SOTA) とされる多様化推薦手法と比較した。

i) **LightGCN $\dagger$**  [8]: SOTA の GNN ベースの推薦システム。比較のために、オリジナルの LightGCN とは異なり、InfoNCE 損失を損失関数として使用した。

ii) **MMR $\ddagger$**  [11]: 後処理ベースのベンチマークとなる多様化推薦手法。この手法では、冗長性を最小限に抑えるために、貪欲アルゴリズムに基づいてアイテムをリランキングする。

iii) **DPP $\ddagger$**  [12]: 後処理ベースのベンチマーク多様化推薦手法。予測スコアとアイテムの類似度行列から構築されたカーネルを利用して、多様なアイテムの集合を選択する。

iv) **DGCN $\dagger$**  [14]: GNN ベースのベンチマーク多様化推薦手法。

v) **DGRec $\dagger$**  [15]: SOTA の GNN ベースの多様化推薦手法。

$\dagger$  でマークされた手法は、著者によって提供された公式コードを使用している。また、 $\ddagger$  でマークされた手法は、我々独自のコードを使用して実装した。比較評価においては、[15] の実験設定に従い、Top-K を 100 および 300 に設定した。MMR や DPP などの後処理ベースの多様化手法では、LightGCN を使用してアイテム生成段階で Top-3K 候補アイテムを生成し、その後スコアに基づいてリランキングする。その後、Top-K のアイテムを推薦リストとした。DGCN, DGRec, DRGNN などの手法は、Top-K アイテムを含む推薦リストを直接出力する。

### 4.4 評価指標

我々は、2つの精度評価指標と3つの多様性評価指標を用いた。精度評価には、既存研究で広く使用されている [7, 8], **Recall@K** と **NDCG@K** を採用した。ここで、カテゴリレ

バルの多様性を評価するために、Top-K の推薦リストに  $n$  個のカテゴリ  $C = \{c_1, \dots, c_n\}$  が含まれている場合、各カテゴリに対応するアイテムの頻度を  $M = [m_1, \dots, m_n]$  とする。多様性評価指標を以下に示す。

- **Coverage@K** は、Top-K の推薦アイテムにどれだけ多くの異なるカテゴリが表されているかを評価する。これは  $Coverage@K = |C|$  として定義される。

- **Entropy@K** は、推薦リスト内のカテゴリ分布を評価する。Entropy は、推薦リストに現れるカテゴリのランダム性や予測不可能性を定量化し、 $Entropy@K = -\sum_{i=1}^n p_{c_i} \log p_{c_i}$  として計算される。ここで  $p_{c_i} = m_i / \sum_{j=1}^n m_j$  である。

- **Gini Index@K** は、推薦リスト内のカテゴリの不平等を測定する。Gini Index が低いほど、カテゴリ内での平等性が高いことを示す。これは  $Gini@K = \sum_{i=1}^n \sum_{j=1}^n (|m_i - m_j|) / (2n^2 \bar{M})$  として定義される。

## 4.5 実験結果

### 4.5.1 結果

提案手法である DRGNN と比較手法を評価した。結果は表 2 および 3 に示されており、最高の値は太字、次点は下線で示されている。SOTA 推薦手法である LightGCN は最高の精度を達成したが、多様性を考慮していないため多様性の低下が見られた。MMR や DPP のような後処理ベースの多様化推薦手法は多様性を高めるが、生成された候補のアイテムの多様性に依存するため、大幅な多様性向上には至らなかった。一方、GNN ベースの多様化推薦手法は、高い多様性と精度を示している。DGCN は高い Entropy と Gini Index を有し、カテゴリの不均衡を大幅に改善するが、精度は他の手法に比べて低下した。SOTA の多様化推薦方法である DGRec は、精度のわずかな低下で非常に高い Coverage を達成したが、Entropy と Gini Index は DGCN よりも劣っており、偏ったカテゴリ分布であることが確認できる。DRGNN は、多くの多様性評価指標で最




図 2: Parameter sensitivity of  $\lambda_i$  ( $i = 1, 2, 3$ ),  $\alpha$ , and  $\beta$  for the Taobao dataset.  $\lambda_i$  controls the influence of the components in the loss function for the DCP.  $\alpha$  and  $\beta$  are used to adjust the strength of the CPS.

表 4: Ablation study on Taobao.

	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$
LightGCN	0.121	0.0471	55.4	2.77	0.651
DRGNN	0.102	0.0397	92.3	3.64	0.558
w/o DCP	0.106	0.0413	80.6	3.46	0.577
w/o CPS	0.118	0.0461	60.7	2.89	0.644

表 5: Ablation study on Beauty.

	Recall $\uparrow$	NDCG $\uparrow$	Coverage $\uparrow$	Entropy $\uparrow$	Gini $\downarrow$
LightGCN	0.420	0.120	24.6	2.29	0.663
DRGNN	0.377	0.106	29.1	2.63	0.609
w/o DCP	0.380	0.107	27.6	2.58	0.613
w/o CPS	0.412	0.119	25.0	2.30	0.664


高の値を達成し、精度では LightGCN に次ぐものであった。したがって、DRGNN は多様性向上において優れた手法であるといえる。

#### 4.5.2 パラメータ分析

さまざまな状況で精度と多様性のバランスを取ることは難しく、トレードオフを調整する能力は多様性を意識した推薦システムにおいて重要な側面である。図 2 は、Taobao データセットにおける精度と多様性の間のトレードオフに対するハイパーパラメータの影響を示している。パラメータ分析のために変更されたもの以外のすべてのパラメータは、4.2 節に準じている。カテゴリの好みを推定するエンコーダーの影響を決定するパラメータ  $\lambda_1$  は、その値が増加するにつれて多様性が向上する。また、このパラメータは、DCP の中で、精度と多様性のバランスを取る上で最も影響力があることが確認できる。拡張損失の影響力を調節するパラメータ  $\lambda_2$  は、表現がカテゴリ嗜好に影響を受けないことを保証する。しかし、 $\lambda_2$  の値が過剰に高くなると多様性の低下につながる。これは、損失を最小限に抑えるためにすべての表現がアイテム嗜好表現に含まれてしまう可能性が考えられる。パラメータ  $\lambda_3$  は、アイテム嗜好表現とカテゴリ嗜好表現との間の独立性を調整する。 $\lambda_3$  の特定の値は良い精度と多様性を維持するが、過度に高い値は学習能力を低下させることが確認できる。CPS のパラメータ  $\alpha$  と  $\beta$  は、ユーザが相互作用したカテゴリのバイアスと全体的なデータセットのバイアスの 2 つのレベルを制御する。 $\alpha$  と  $\beta$  は、精度と多様性のトレードオフを調整するために重要であることが確認できる。


#### 4.5.3 アブレーション研究

提案手法の DCP と CPS の有効性を検証するため、アブレーション



(a) Categ. dist. (b) LightGCN (c) DGRec (d) DRGNN

図 3: Comparison of the category distribution for the user with the lowest entropy on Beauty across different methods.



(a) Categ. dist. (b) LightGCN (c) DGRec (d) DRGNN

図 4: Comparison of the category distribution for the user with the highest entropy on Beauty across different methods.

ション研究を行った。LightGCN, DRGNN, DCP を除いた DRGNN (すなわち、式 (16) の第一項のみで訓練されたもの)、および CPS を除いた DRGNN を比較した。アブレーション研究の結果は、表 4 および 5 に示す。DCP は精度をわずかに低下させるが、多様性を大幅に向上させ、特に多くのカテゴリを持つ Taobao データセットでの有効性が顕著であることがわかった。CPS は多様性の向上に顕著に寄与し、相互作用の少ないカテゴリの表現を改善する。さらに、DRGNN は、DCP と CPS の両方を組み合わせることで、最も高い多様性を示した。

#### 4.5.4 定性的分析

本節では、推薦リストにおけるカテゴリ分布を調査することにより、DRGNN の特性を定性的に分析する。Beauty データセットを使用し、特定のユーザの学習データと、LightGCN, DGRec, DRGNN によって生成された推薦リストのカテゴリ分布と比較した。学習データの中で 50 回以上の相互作用を持つユーザに焦点を当て、特に Entropy が最も低いユーザおよび最も高いユーザについて考察した。この結果を図 3 および図 4 に示す。各図の (a) は、ユーザが相互作用したアイテムのカテゴリ分布を示している。(b) から (d) は、(a) のカテゴリ分布を持つユーザに対して、各手法が生成した推薦リストのカテゴリ分布を示している。

図 3 は最も低い Entropy のユーザに対する結果であり、偏っ

た相互作用を持っていることが図からもわかる。LightGCN は正確な好みを学習するため、学習データに依存して特定の カテゴリに強く偏った推薦を行うことが分かる。DGRec は、LightGCN によって提供されないカテゴリからアイテムを推薦するが、依然として特定のカテゴリが突出している。一方、提案された DRGNN は、特定の カテゴリに大きく影響されることなく、幅広いカテゴリのアイテムを網羅した推薦が可能であることを示す。


図 4 は、多様なカテゴリとの相互作用を示す高い Entropy の ユーザである。このユーザに対しても同様の効果が確認でき、提案手法が学習データに含まれるカテゴリの偏りに関係なく、多様な相互作用パターンを持つさまざまなユーザに対して多様な推薦を提供することを確認できる。

#### 4.5.5 提案手法の限界点

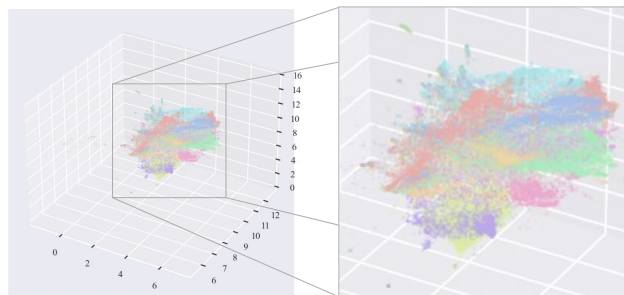
4.5.1 節で示されている通り、DRGNN は、精度をわずかに犠牲にして多様性を向上させる。さらに、DRGNN と CPS なしの DRGNN を比較すると、Taobao データセットでは LightGCN と比べて 9.6% から 14.5%、Beauty データセットでは 1.6% から 5.4% の多様性の増加が見られる (表 4 および 5 参照)。2 つのモジュールの組み合わせが多様性の増加に寄与していることを示しているが、これは、学習サンプルの偏りを緩和することがカテゴリの好みの推定に良好な影響を与えることを示唆している。また、DCP によって達成される 2 つのデータセット間の改善の大きさの相違は、各データセットのカテゴリの数の顕著な違いに起因する可能性がある。これは、カテゴリの数が少ないデータセットで DCP の適用が困難である可能性を示唆している。

#### 4.5.6 埋め込み表現の可視化

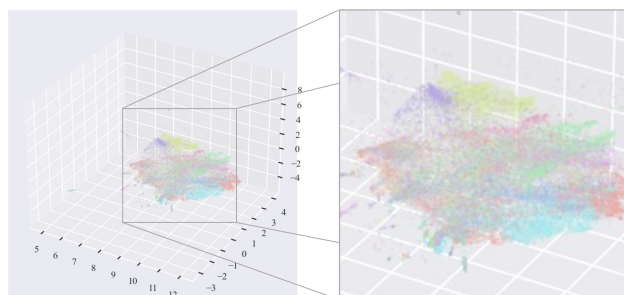
本節では、提案するモジュールの適用による埋め込み表現の変化を確認するため、可視化を行った。予測への影響を確認するため、予測に用いる埋め込み同士を比較する。具体的には、LightGCN はエンコーダの出力の  $d (= 32)$  次元の埋め込み、DCP を用いる際はアイテム嗜好を推定するエンコーダの出力の  $d (= 32)$  次元埋め込みである。まず、それぞれの手法ごとに全てのアイテムの埋め込みを Uniform Manifold Approximation and Projection (UMAP) [32] を用いて 3 次元に次元削減し、そのうちアイテム数が多い上位 10 件のカテゴリのアイテムを描画した。ここで、異なる色は異なるカテゴリであることを示している。LightGCN とパラメータを変化させた 2 種類の DCP の適用 ( $\lambda_1 = 1$  と  $\lambda_1 = 10$  とした)、そして提案手法の埋め込みの分布の結果を図 5 に示す。(a) より LightGCN によって得られる埋め込みは同じカテゴリのアイテム同士は大まかに固まって分布していることが確認できる。DCP の導入によってカテゴリに対する表現を分離することで、(b) より同カテゴリのアイテムは分布として広がる傾向が見られ、(c) よりパラメータを強くすることで分離が進み、カテゴリごとに固まるのが緩和されていることが確認できる。一方、水色や黄緑色のよう固まった表現が残されている点は今後の課題である。また、(d) より提案手法は CPS との組み合わせによって最もカテゴリに影響されない、分離された表現を獲得していることが分かる。



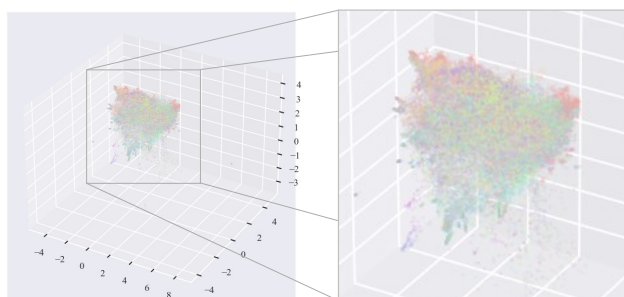
(a) LightGCN



(b) LightGCN+DCP( $\lambda_1 = 1$ )



(c) LightGCN+DCP( $\lambda_1 = 10$ )



(d) DRGNN

図 5: Visualization results of embedding representations on Taobao.

## 5 まとめ

本稿では、GNN ベースの推薦システムの多様性向上のための新しいアプローチである DRGNN を提案した。DRGNN は、DCP および CPS という 2 つのモジュールによって実現される。これらのモジュールは、精度を損なうことなく推薦の多様性を高めるために、GNN アーキテクチャに統合される。DRGNN は、多様性の面で最先端の多様化推薦手法を上回るだけでなく、精度においても精度のみを考慮したモデルに匹敵する。ま

た、精度と多様性の調整が可能なハイパーパラメータにより、DRGNN は多様なユーザのニーズに合わせてトレードオフを調整することができる。

今後の研究では、異なるデータセットにわたる  $\alpha$  および  $\beta$  パラメータの決定のための体系的な方法の開発、カテゴリ嗜好表現の類似性を考慮した推論について調査する予定である。

**謝辞** 本研究の一部は JSPS 科学研究費補助金 (若手研究: 22K18007), および関西大学先端科学推進機構 (近未来 ICT の社会実装研究グループ) の助成を受けて行われた。ここに謝意を表す。

## 文 献

- [1] G. Linden, B. Smith, and J. York, “Amazon. com recommendations: Item-to-item collaborative filtering,” *IEEE Internet Comput.*, vol.7, no.1, pp.76–80, 2003.
- [2] P. Covington, J. Adams, and E. Sargin, “Deep neural networks for youtube recommendations,” *Proc. of the 10th ACM Conf. on Recomm. Syst.*, pp.191–198, 2016.
- [3] D. Goldberg, D. Nichols, B.M. Oki, and D. Terry, “Using collaborative filtering to weave an information tapestry,” *Commun. of the ACM*, vol.35, no.12, pp.61–70, 1992.
- [4] Y. Koren, R. Bell, and C. Volinsky, “Matrix factorization techniques for recommender systems,” *Comput.*, vol.42, no.8, pp.30–37, 2009.
- [5] H.-J. Xue, X. Dai, J. Zhang, S. Huang, and J. Chen, “Deep matrix factorization models for recommender systems,” *Proc. of the 26th Int. Jt. Conf. on Artif. Intell.*, vol.17, pp.3203–3209, 2017.
- [6] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T.-S. Chua, “Neural collaborative filtering,” *Proc. of the 26th Int. Conf. on World Wide Web*, pp.173–182, 2017.
- [7] X. Wang, X. He, M. Wang, F. Feng, and T.-S. Chua, “Neural graph collaborative filtering,” *Proc. of the 42nd Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.165–174, 2019.
- [8] X. He, K. Deng, X. Wang, Y. Li, Y. Zhang, and M. Wang, “Lightgcn: Simplifying and powering graph convolution network for recommendation,” *Proc. of the 43rd Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.639–648, 2020.
- [9] H. Wu, Y. Zhang, C. Ma, F. Lyu, F. Diaz, and X. Liu, “A survey of diversification techniques in search and recommendation,” *arXiv prepr. arXiv:2212.14464*, 2022.
- [10] M. Wilhelm, A. Ramanathan, A. Bonomo, S. Jain, E.H. Chi, and J. Gillenwater, “Practical diversified recommendations on youtube with determinantal point processes,” *Proceedings of the 27th ACM Int. Conf. on Inf. and Knowl. Manag.*, pp.2165–2173, 2018.
- [11] J. Carbonell and J. Goldstein, “The use of mmr, diversity-based reranking for reordering documents and producing summaries,” *Proc. of the 21st Annu. Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.335–336, 1998.
- [12] L. Chen, G. Zhang, and E. Zhou, “Fast greedy map inference for determinantal point process to improve recommendation diversity,” *Adv. in Neural Inf. Proc. Syst.*, vol.31, pp.5627–5638, 2018.
- [13] A. Ashkan, B. Kveton, S. Berkovsky, and Z. Wen, “Optimal greedy diversity for recommendation,” *Proc. of the 14th Int. Jt. Conf. on Artif. Intell.*, vol.15, pp.1742–1748, 2015.
- [14] Y. Zheng, C. Gao, L. Chen, D. Jin, and Y. Li, “Dgcn: Diversified recommendation with graph convolutional networks,” *Proc. of the ACM Web Conf. 2021*, pp.401–412, 2021.
- [15] L. Yang, S. Wang, Y. Tao, J. Sun, X. Liu, P.S. Yu, and T. Wang, “Dgrec: Graph neural network for recommendation with diversified embedding generation,” *Proc. of the 16th ACM Int. Conf. on Web Search and Data Min.*, pp.661–669, 2023.
- [16] T.N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” *arXiv prepr. arXiv:1609.02907*, 2016.
- [17] W. Hamilton, Z. Ying, and J. Leskovec, “Inductive representation learning on large graphs,” *Adv. in Neural Inf. Proc. Syst.*, vol.30, pp.1024–1034, 2017.
- [18] Z. Wu, S. Pan, F. Chen, G. Long, C. Zhang, and S.Y. Philip, “A comprehensive survey on graph neural networks,” *IEEE Trans. on Neural Netw. and Learn. Syst.*, vol.32, no.1, pp.4–24, 2020.
- [19] C. Wang, Y. Yu, W. Ma, M. Zhang, C. Chen, Y. Liu, and S. Ma, “Towards representation alignment and uniformity in collaborative filtering,” *Proc. of the 28th ACM SIGKDD Conf. on Knowl. Discov. and Data Min.*, pp.1816–1825, 2022.
- [20] K. Mao, J. Zhu, J. Wang, Q. Dai, Z. Dong, X. Xiao, and X. He, “Simplex: A simple and strong baseline for collaborative filtering,” *Proc. of the 30th ACM Int. Conf. on Inf. & Knowl. Manag.*, pp.1243–1252, 2021.
- [21] H. Tang, G. Zhao, Y. Wu, and X. Qian, “Multisample-based contrastive loss for top-k recommendation,” *IEEE Trans. on Multimed.*, 2021.
- [22] J. Yu, H. Yin, X. Xia, T. Chen, L. Cui, and Q.V.H. Nguyen, “Are graph augmentations necessary? simple graph contrastive learning for recommendation,” *Proc. of the 45th Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.1294–1303, 2022.
- [23] J. Ma, C. Zhou, P. Cui, H. Yang, and W. Zhu, “Learning disentangled representations for recommendation,” *Adv. in Neural Inf. Proc. Syst.*, vol.32, pp.1–12, 2019.
- [24] X. Wang, H. Jin, A. Zhang, X. He, T. Xu, and T.-S. Chua, “Disentangled graph collaborative filtering,” *Proc. of the 43rd Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.1001–1010, 2020.
- [25] Y. Zheng, C. Gao, X. Li, X. He, Y. Li, and D. Jin, “Disentangling user interest and conformity for recommendation with causal embedding,” *Proc. of the Web Conf. 2021*, pp.2980–2991, 2021.
- [26] A. Zhang, J. Zheng, X. Wang, Y. Yuan, and T.-S. Chua, “Invariant collaborative filtering to popularity distribution shift,” *Proc. of the ACM Web Conf. 2023*, pp.1240–1251, 2023.
- [27] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme, “Bpr: Bayesian personalized ranking from implicit feedback,” *arXiv prepr. arXiv:1205.2618*, 2012.
- [28] G.J. Székely, M.L. Rizzo, and N.K. Bakirov, “Measuring and testing dependence by correlation of distances,” *The Ann. of Stat.*, vol.35, no.6, pp.2769–2794, 2007.
- [29] H. Zhu, X. Li, P. Zhang, G. Li, J. He, H. Li, and K. Gai, “Learning tree-based deep model for recommender systems,” *Proc. of the 24th ACM SIGKDD Int. Conf. on Knowl. Discov. & Data Min.*, pp.1079–1088, 2018.
- [30] Y. Liang, T. Qian, Q. Li, and H. Yin, “Enhancing domain-level and user-level adaptivity in diversified recommendation,” *Proc. of the 44th Int. ACM SIGIR Conf. on Res. and Dev. in Inf. Retr.*, pp.747–756, 2021.
- [31] D.P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv prepr. arXiv:1412.6980*, 2014.
- [32] L. McInnes, J. Healy, and J. Melville, “Umap: Uniform manifold approximation and projection for dimension reduction,” *arXiv prepr. arXiv:1802.03426*, 2018.