多样化推荐的解耦表示

Xiaoying Zhang ZHANGXIAOYING.XY@BYTEDANCE.COM
人工智能实验室，字节跳动

Hongning Wang HW5X@VIRGINIA.EDU
美国弗吉尼亚大学计算机科学系

Hang Li LIHANG.LH@BYTEDANCE.COM
字节跳动人工智能实验室

arXiv:2301.05492v1 [cs.IR] 13 Jan 2023

摘要

长期以来，人们一直认为，准确性与多样性是推荐中的两个相互冲突的目标。然而，我们指出，由于多样性通常是通过某些预先选定的物品属性来衡量的，例如最常用的类别，只要多样化过程尊重用户对这些预先选定属性的偏好，就能在不牺牲推荐准确率的情况下提升多样性。为此，需要细致地理解用户对物品的偏好，并辨别用户的选择究竟是由物品本身的质量驱动，还是由物品的预先选定属性驱动。

在这项工作中，我们聚焦于基于物品类别定义的多样性，并提出一个通用的多样化框架，不受推荐算法选择的限制。我们的方法将推荐模块中学习到的用户表示解耦为类别无关和类别相关组件，从两个正交视角区分用户对物品的偏好。在三个基准数据集上的实验结果以及在线 A/B 测试表明，我们的方法能够有效提升推荐准确率和多样性。深入分析表明，这种提升得益于我们对用户类别偏好的改进建模，以及对物品类别内排序的优化。

关键词： 推荐系统、推荐多样性、解耦的用户表示

1. 引言

推荐系统从用户的历史行为记录（例如点击、收藏或购买的物品等）中学习用户的兴趣，以识别最符合用户偏好的物品。推荐系统在提升用户体验和提高平台效用方面取得了显著成效，应用场景包括电子商务（Zhou 等，2018；He 和 Chua，2017）、在线新闻推荐（Wu等人，2019a）和流媒体服务（Covington 等人，2016）。

推荐准确率衡量推荐模型能否推荐用户喜欢的物品，在以往的大多数研究中，它一直是主要目标，甚至是唯一目标（Zhou 等，2018；Wang 等，2021；He 和 Chua，2017；Guo 等人，2017；Covington 等人，2016）。为了提高准确性，研究者提出了各种复杂的模型（Zhou 等，2018；Guo 等人，2017；Covington 等人，2016）。虽然研究表明，推荐准确率与用户满意度密切相关，但它绝不是

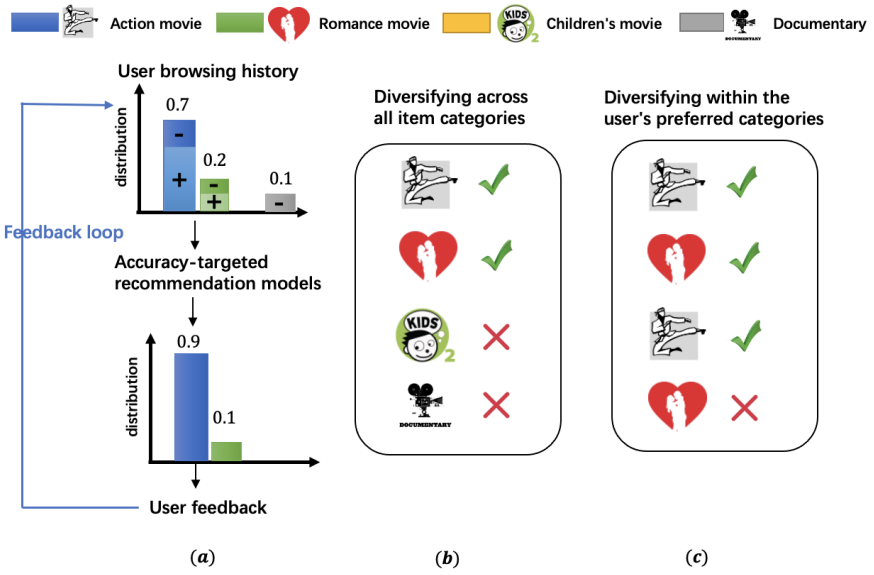


图 1：不同推荐模型中的推荐准确率与多样性优化示意图。

唯一的经验法则。近期研究发现，推荐多样性——衡量推荐物品在某些预先选定的物品属性（例如物品类别）方面的差异程度——对整体用户体验也发挥着重要作用（Wilhelm 等人，2018；Kapoor，2015年；Zhou 等人，2010年）。例如，即使用户是篮球迷，也可能会对只推荐篮球视频或新闻感到厌倦，从而增加用户流失的风险。

遵循以往研究（Steck，2018年；Wang 等，2021；Zheng 等，2021a），本文关注定义在物品类别上的多样性，并旨在解决所谓的准确性与多样性困境（Zheng 等，2021a）。一方面，以准确性为主要目标的推荐模型往往会在一定程度上牺牲多样性，因为它们过度强调用户交互历史中的主导类别物品（Steck，2018年；Wang 等，2021）。图1(a)以电影推荐为例说明了这一问题：用户观看的电影中有70%属于动作片，这导致系统推荐内容中有90%落入动作电影类别。更糟糕的是，由于反馈循环（Chaney 等人，2018年）的存在，当用户遵循这些推荐时，系统推荐中对主导类别的强调会进一步加剧，从而导致推荐多样性进一步降低，并引发过滤气泡（Nguyen 等人，2014年）和回声室（Ge 等人，2020年）等问题。另一方面，在不考虑用户类别偏好的情况下，简单地对所有物品类别进行多样化，会损害生成的推荐的准确性（Wilhelm 等人，2018年；Ziegler 等人，2005年；Qin 和 Zhu，2013年；Zheng 等，2021a）。如图1(b)所示，尽管推荐列表覆盖了全部四个类别，因而具有多样性，但负反馈更有可能出现在用户较少交互或已经以负反馈为主的类别中，例如本例中的儿童电影和纪录片分别属于这两种情况。

儿童电影和纪录片分别属于这两种情况。

显然，不应贸然提升多样性。对于用户不太可能感兴趣的类别，提高多样性所带来的收益不及作出糟糕推荐的风险。因此，本文仅在用户偏好的物品类别中进行多样化，表明在不牺牲推荐准确率的前提下提升推荐多样性是可行的。图 1(c) 展示了采用这一策略生成的推荐列表示例，其中推荐物品主要属于动作片和爱情片，这两种偏好类别是根据用户的交互历史推断得出的。这一策略要求推荐模型能够清楚地区分用户的正向/负向反馈究竟是由物品类别，还是由物品的其他类别无关特征（例如物品本身的质量）所致，而以往的推荐模型忽略了这一点。

本文提出一种通用且与模型无关的框架，旨在解耦用户的类别相关偏好与类别无关偏好，从而构建兼具准确性与多样性的推荐系统（DCRS）。具体而言，DCRS 将用户对物品的偏好表示为以下两者的乘积：（1）用户对物品类别的偏好；（2）用户对物品类别无关特征（例如物品质量）的偏好。这种解耦意味着用户会进行层次化决策：如果用户强烈偏好某一特定物品类别，那么即使该类别中物品的质量并不完美，用户仍可能喜欢它们。然而，如果用户喜欢某个类别的概率较低，那么只有该类别中质量较高的物品才有机会被纳入考虑。通过这种解耦，对于用户偏好程度相近的不同类别，质量相同的物品被推荐的概率也相同。这种方法自然避免了过度推荐用户交互历史中主导类别的物品。因此，主要挑战在于：在无法观测用户对物品类别的偏好的情况下，如何解耦用户在上述两个正交维度上的偏好。这使得一些简单方案难以奏效，例如使用不同的监督信号分别训练用户表示（Zheng 等，2021b），或将物品的特征向量拆分为类别相关与无关部分。

DCRS 不受推荐模块选择的限制，该模块旨在学习用户和物品的有效表示。具体而言，DCRS 使用判别器，将学得的表示分别解耦为类别无关部分和类别相关部分。推荐模块与判别器同时学习，以确保解耦表示学习能够有效实现准确且多样化的推荐。为评估所提出的 DCRS 方案，我们在三个基准数据集上开展离线实验，并在中国最大的新闻推荐平台之一——今日头条应用上进行在线 A/B 测试。实验结果表明，DCRS 能够成功推荐用户偏好的多样化项目，从而提升推荐准确率和多样性。深入分析和案例研究提供了有力证据，表明：（1）DCRS 学得的解耦的类别无关表示能够更准确地辨别用户在类别内的偏好；（2）DCRS 能够更全面地捕捉用户在历史交互中体现的多样化偏好。所有代码和数据均可在 https://github.com/Xiaoyinggit/DCRS.git 获取。

总体而言，本研究的贡献如下：

- 我们证明，只要多样化推荐尊重用户的类别偏好，准确性与多样性就并非相互冲突的目标。

- 为更准确地捕捉用户对物品类别的潜在偏好，我们提出的 DCRS 将用户偏好解耦为类别相关和类别无关的组成部分。

- 在三个基准数据集上的实验和在线 A/B 测试表明，DCRS 能有效提升推荐准确性和多样性。深入分析进一步表明，这种提升源于对用户在类别之间及类别内部偏好的建模更加准确。

2. 框架

本节将介绍所提出的 DCRS 解决方案如何解耦用户对类别相关和类别无关的偏好，从而同时提升推荐准确性和多样性。为便于说明，我们首先简要介绍一种涵盖几乎所有常用推荐模型的通用架构，随后说明如何将 DCRS 平滑地集成到这一通用架构中，以增加其推荐结果的多样性。

2.1 预备知识：通用推荐架构

在推荐任务中，给定一个用户行为数据集 $\boldsymbol{\mathcal{X}}$，其中包含 N 用户与 M 物品之间的交互。用户 u 与物品 i 之间的交互表示为一个元组（$u, i, y_{u,i}$） $\in \boldsymbol{\mathcal{X}}$。其中，$y_{u,i} \in \{0, 1\}$ 表示用户 u 对物品 i 的反馈；$y_{u,i} = 1$ 表示正反馈（例如点击或正面评分），而 $y_{u,i} = 0$ 表示负反馈。一般而言，推荐模型会首先学习用户-物品表示，以捕捉用户对物品的偏好：

$$\boldsymbol{h}_{u,i} = f(u, i, \boldsymbol{\theta}) \in R^d, \tag{1}$$

其中，$\boldsymbol{\theta}$ 表示推荐模型中的一组可训练参数。人们提出了各种架构（Zhou 等，2018；Wang 等，2021；He 和 Chua，2017；Guo 等人，2017）来实现 $f(u, i, \boldsymbol{\theta})$，从简单的矩阵分解算法（Mnih 和 Salakhutdinov，2007）——直接对用户嵌入和物品嵌入进行逐元素乘积以形成表示——到复杂的架构，例如 NFM 中的双交互层（He 和 Chua，2017）。设 $\hat{}p_{u,i}$ 表示用户u 对物品 i给出正反馈的概率。推荐模型的目标是利用学得的用户-物品表示来估计 $\hat{}p_{u,i}$，既可以像矩阵分解那样直接将$\boldsymbol{h}_{u,i}$ 中的元素求和，也可以通过可学习的投影层进行估计，如下所示：

$$\hat{p}_{u,i} = P\left(Y_{u,i} = 1 | u, i\right) = \sigma\left(\boldsymbol{W}^\top \boldsymbol{h}_{u,i}\right), \tag{2}$$

其中，$Y_{u,i}$ 是表示用户 u 对物品 i反馈的随机变量；$\boldsymbol{W} \in R^{d \times 1}$是投影层的可学习权重向量，$\sigma(\cdot)$ 是 Sigmoid 函数。随后，通过最小化以下

损失
函数:

$$\mathcal{L}(\boldsymbol{\mathcal{X}}, \boldsymbol{\theta}, \boldsymbol{W}) = \frac{1}{|\boldsymbol{X}|} \sum_{(u,i,y_{u,i}) \in \boldsymbol{\mathcal{X}}} \mathcal{L}_{rec}(y_{u,i}, \hat{p}_{u,i}), \tag{3}$$

其中， $\mathcal{L}_{rec}(\cdot,\ \cdot)$ 表示所选的损失函数。文献中已探讨了多种损失函数，包括交叉熵损失、均方误差（MSE）和 BPR损失（Rendle 等，2012年）。本文默认使用交叉熵损失。

2.2 解耦类别相关与类别无关表示 s

我们将用户对某个物品的反馈视为一种混合反馈，它反映了用户对该物品所属类别的偏好，以及对类别无关属性（例如物品的内在质量）的评价。如图2所示，用户对第一个动作片给出正反馈，很可能是因为用户强烈偏好动作片这一类别；而用户对第二部爱情电影给出正反馈，则更可能是因为该片质量较高，弥补了用户喜欢爱情片的概率较低这一点。为了根据用户偏好的类别提供更多样化的推荐，推荐模型需要明确区分物品类别及其他类别无关属性对用户决策的影响。为了使对方法的描述足够通用，能够涵盖物品关联多个类别的情况，我们将物品 i 的类别视为该物品所属所有类别构成的集合，并记为 t_i。例如，假设数据集中有三个类别 $\{c_1, c_2, c_3\}$ 。若物品 i 属于第一个类别，则 $t_i = \{c_1\}$。若物品 i 与前两个类别相关联，则 $t_i = \{c_1, c_2\}$。

我们提出将用户对某件物品的偏好解耦为两部分：

- **类别相关偏好**：描述用户对该物品所属类别的偏好；

- **类别无关偏好**：描述类别无关特征如何影响用户对该物品的偏好。

这种解耦可以从概率视角解释用户 u 对物品 i 的反馈生成过程。令 $Y^C_{u,i}$ 表示指示用户 u 对物品 i 所属类别的反馈的二元随机变量。我们有如下结论，

$$\begin{aligned} P(Y_{u,i} = 1|u, i) &= P(Y_{u,i} = 1, Y^C_{u,i} = 1|u, i) && \text{(4a)} \\ &= P(Y_{u,i} = 1|u, i, Y^C_{u,i} = 1)P(Y^C_{u,i} = 1|u, i) && \text{(4b)} \\ &= P(Y_{u,i} = 1|u, i, Y^C_{u,i} = 1)P(Y^C_{u,i} = 1|u, t_i) && \text{(4c)} \end{aligned}$$

具体而言，式 (4a) 源于以下假设：用户 u 只有在喜欢物品 i 所属类别时，才会对物品 i 给出正反馈，即 $P(Y_{u,i} = 1, Y^C_{u,i} = 1|u, i) = 1$ 且 $P(Y_{u,i} = 1, Y^C_{u,i} = 0|u, i) = 0$。式 (4b) 根据链式法则得出。式 (4c) 则是因为 $Y^C_{u,i}$ 仅取决于物品类别，而非具体物品。

式 (4c) 中的第一项描述了当用户 u 对物品 i所属类别感兴趣时，用户 u 对物品i 给出正反馈的可能性；第二项则刻画了用户 u 对物品 i所属类别感兴趣的可能性。已知用户 u 喜欢物品 i所属的类别，

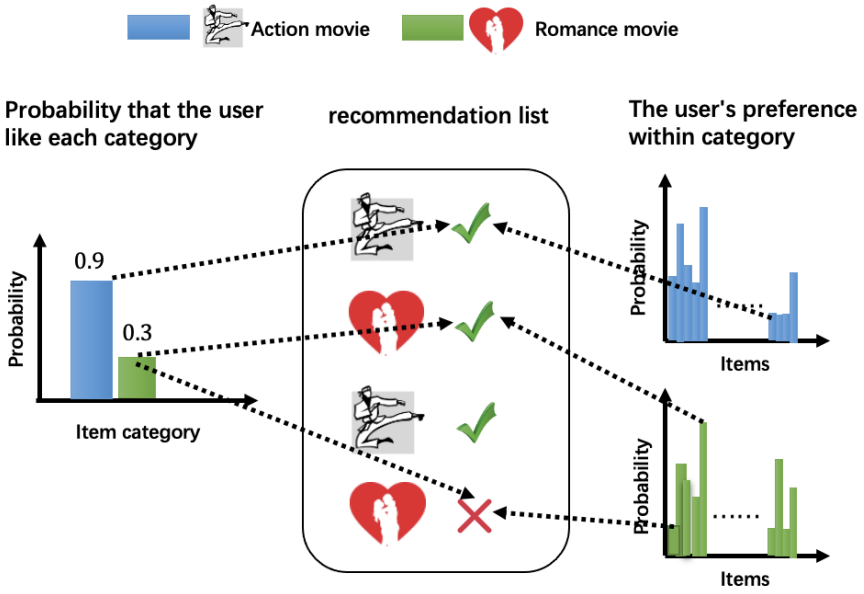


图2：DCRS 框架的层次化决策过程。每次反馈由以下因素决定：(1) 用户对物品类别的偏好；(2) 用户对物品类别无关特征的偏好。

第一项中的概率仅取决于物品 i的类别无关特征，例如物品 i的质量、价格等。因此，在解耦的用户-物品表示下，我们可以通过概率 $P(Y_u^{\perp C}{}_{,i}=1|u,i)$ 计算第一项。该概率描述了由类别无关特征驱动的用户 u对物品 i 的偏好。因此，式 (4c) 可以改写为：

$$P(Y_{u,i}=1|u,i)=P(Y_{u,i}^{\perp C}=1|u,i)P(Y_{u,i}^{C}=1|u,t_i). \tag{5}$$

公式 (5) 描述了图2所示的层次化决策过程。如果用户 u 以较高的概率 $P(Y_u^C{}_{,i}=1|u,t_i)$喜欢物品 i 的类别，那么即使物品 i 的质量并不完美，用户仍可能喜欢物品i，这由较低的 $P(Y_u^{\perp C}{}_{,i}=1|u,i)$ 表示。例如，图2中的第一部动作电影获得正反馈，就是在这种情况下产生的。与此同时，如果用户 u 对物品 i 的类别感兴趣的概率很低（即 $P(Y_u^C{}_{,i}=1|u,t_i)$ 较低），那么物品 i 必须具有较高的质量才能获得正反馈，即 $P(Y_u^{\perp C}{}_{,i}=1|u,i)$ 较高。图2中的第二部爱情电影获得正反馈，就是这种情况的一个例子。

式（5）也说明了解耦为何能在用户偏好的类别内实现多样化推荐。假设存在两个类别 c_1 和 c_2，用户对它们的偏好相似。通过式（5）中的解耦，同等质量的物品在 c_1 和 c_2 中被推荐的机会均等，而不是一味推荐更多来自主导类别（c_1 或 c_2）的物品，从而使推荐更加多样化。

遗憾的是，式（5）中的两个项都无法通过直接监督信号学习，因为既无法观察用户 u 对物品 i所属类别的反馈，也无法观察由物品 i 的类别无关特征驱动的反馈。传统方法通常会采用期望最大化类算法（Dempster 等人，1977）以迭代方式估计这两个项。然而，鉴于现代推荐算法通常由复杂的深度神经网络实现，后验推断会变得繁琐，也会导致收敛缓慢。为此，DCRS 通过同时学习两个解耦表示来分别估计这两个项，从而实现式（5）。具体而言，DCRS 通过以下方式学习两个解耦表示：

$$\left[\left(\boldsymbol{h}_{u,i}^{\perp C}\right)^{\top},\left(\boldsymbol{h}_{u,i}^{C}\right)^{\top}\right]^{\top}=f(u,i,\boldsymbol{\theta})\in R^{2d}, \tag{6}$$

其中，$\boldsymbol{h}_{u,i}^{\perp C}\in R^{d}$ 旨在捕捉用户 u 对类别无关特征的偏好，以估计 $P(Y_{u,i}^{\perp C}=1|u,i)$；而 $\boldsymbol{h}_{u,i}^{C}\in R^{d}$ 描述用户 u 对物品 i 的类别t_i的偏好，旨在估计 $P(Y_{u,i}^{C}=1|u,t_i)$。

仅将物品 i 的特征向量拆分为两部分，即使使用不同的网络，也无法确保完全解耦。相反，除了要求学习到的表示尽可能充分地捕捉用户偏好外，我们还采用对抗判别器，强制学习到的 $\boldsymbol{h}_{ui}^{\perp C}$ 和 $\boldsymbol{h}_{u,i}^{C}$ 分别具有类别无关性和类别相关性。

判别器模块。判别器 $D(\cdot)$ 充当类别分类器，以一段解耦表示（例如 $\boldsymbol{h}_{u,i}^{C}$ 或 $\boldsymbol{h}_{ui}^{\perp C}$）作为输入，并旨在预测物品 i 的类别（即 t_i）。然而，判别器难以直接预测 t_i，因为 t_i 可以取 2^K-1 个值，其中 K 是数据集中可用的不同类别的数量。为便于学习，我们用一个在 K 个不同类别上定义的向量表示 t_i，记作 $\tilde{\boldsymbol{t}}_i$。同样，假设有三个类别 $\{c_1,c_2,c_3\}$，若 $t_1=\{c_1\}$，则$\tilde{\boldsymbol{t}}_i=[1,0,0]^{\top}$。若 $t_1=\{c_1,c_2\}$，则 $\tilde{\boldsymbol{t}}_i=[0.5,0.5,0]^{\top}$。具体而言，当可以衡量物品 i 与各个关联类别之间的相关性时（Pu 等人，2020），通过令 $\boldsymbol{t}_i$ 的第 j 个元素与物品 i 和第 j 个类别之间的相关性~成正比，可以得到更~准确的 $\boldsymbol{t}_i$。否则，可以假设 $\boldsymbol{t}_i$ 在相关类别之间均匀分布，这也是我们实验中的默认设置。随后，判别器以 $\boldsymbol{h}_{u,i}^{C}$ 或 $\boldsymbol{h}_{u,i}^{\perp C}$ 作为输入来预测 $\tilde{\boldsymbol{t}}_i$。在我们的实验中，判别器 $D(\cdot)$ 通过一个全连接层实现，并应满足以下要求：

- 鉴于 $\boldsymbol{h}_{u,i}^{C}$ 与物品 i 的类别密切相关，判别器应基于$\boldsymbol{h}_{u,i}^{C}$准确预测 $\tilde{\boldsymbol{t}}_i$，即应最小化以下损失函数：

$$\min \mathcal{L}_{D}^{C}(u,i)=\mathcal{L}_{CE}\left(D(\boldsymbol{h}_{u,i}^{C}),\tilde{\boldsymbol{t}}_i\right),$$

  其中 $\mathcal{L}_{CE}$ 是交叉熵损失。

- 鉴于$\boldsymbol{h}_{ui}^{\perp C}$ 与物品类别无关，$\boldsymbol{h}_{ui}^{\perp C}$ 应通过最大化分类损失函数来欺骗判别器：

$$\max \mathcal{L}_{D}^{\perp C}(u,i)=\mathcal{L}_{CE}\left(D(\boldsymbol{h}_{u,i}^{\perp C}),\tilde{\boldsymbol{t}}_i\right).$$

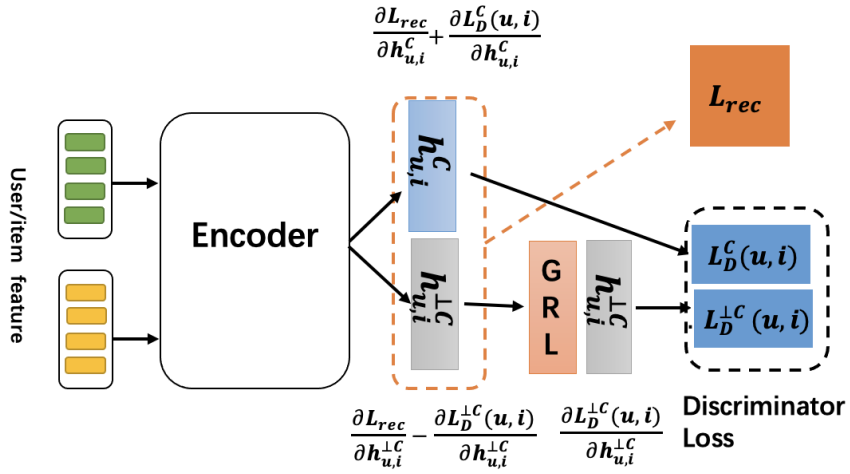


图 3：DCRS 的架构，该架构将用户 u 对物品 i 的偏好解耦为类别相关部分 $\boldsymbol{h}_{u,i}^{C}$ 和类别无关部分 $\boldsymbol{h}_{u\,i}^{\perp C}$，以实现多样且准确的推荐。

由于实现简单，我们利用梯度反转层（GRL）（Ganin 和 Lempitsky，2015年）来实现上述要求。更具体地说，我们在$\boldsymbol{h}_{u\,i}^{\perp C}$、和判别器之间插入一个梯度反转层，如图 3 所示。在反向传播过程中，用于最小化判别器损失函数 $\partial\mathcal{L}_{D}^{\perp C}(u,i)\,\partial\boldsymbol{h}_{u,i}^{\perp C}$ 的梯度会反向流经判别器。经过 GRL 后，梯度将被反转，即变为 $-\partial\mathcal{L}_{D}^{\perp C}(u,i)\,\partial\boldsymbol{h}_{u,i}^{\perp C}$。因此，我们对判别器的参数执行梯度下降，以准确预测物品 i的类别；同时对$\boldsymbol{h}_{u\,i}^{\perp C}$ 执行梯度上升，使得$\boldsymbol{h}_{u,i}^{\perp C}$ 无法预测物品 i的类别。

学习类别无关表示。 $\boldsymbol{h}_{u\,i}^{\perp C}$ 需要在两个目标下进行优化：(1) 它能够通过以下方式准确估计公式 (5) 中的第一项 $P(Y_{u,i}^{\perp C}=1|u,i)$：

$$\hat{p}_{u,i}^{\perp C}=P\left(Y_{u,i}^{\perp C}=1|u,i\right)=\sigma\left(\boldsymbol{W_1}^{\top}\boldsymbol{h}_{u,i}^{\perp C}\right); \tag{7}$$

以及 (2) 它需要与物品类别无关。因此，我们最小化以下损失函数来进行学习：

$$\mathcal{L}_{rec}\left(\hat{p}_{u,i}^{\perp C},y_{u,i}\right)-\lambda\mathcal{L}_{D}^{\perp C}(u,i) \tag{8}$$

其中，两项分别优化两个不同的目标，λ 是一个超参数，用于控制类别无关约束对 $\boldsymbol{h}_{u\,i}^{\perp C}$ 的作用强度。

学习类别相关表示。 虽然用户 u 对物品 i 所属类别的偏好无法观测，但可以通过固定已学习的类别无关表示$\boldsymbol{h}_{u,i}^{\perp C}$ 并估计用户 u 给予

对物品 i 的正反馈:

$$\hat{p}_{u,i} = P(Y_{u,i} = 1|u,i) = \sigma\left(\boldsymbol{W_2}^\top \begin{bmatrix} \text{stop_gradient}(\boldsymbol{h}_{u,i}^{\perp C}) \\ \boldsymbol{h}_{u,i}^{C} \end{bmatrix}\right), \boldsymbol{W_2} \in R^{2d\times 1} \tag{9}$$

其中，停止梯度($\boldsymbol{h}_{u,\ i}^{\perp C}$) 意味着该预测不会更新$\boldsymbol{h}_{u\,i}^{\perp C}$。换言之，给定学习到的用户 u 对物品i的类别无关特征的偏好，只需优化用户 u 对物品 i 所属类别的偏好，通过最小化以下损失函数，准确预测用户 u 对物品 i的整体反馈:

$$\mathcal{L}_{rec}\left(\hat{p}_{u,i}, y_{u,i}\right) + \lambda \mathcal{L}_D^C(u,i), \tag{10}$$

其中，第二个损失函数促使$\boldsymbol{h}_{u,\ i}^{C}$ 准确预测物品 i的类别， λ 表示该约束的强度。

总而言之，结合公式 (8) 和公式 (10)，给定用户行为数据集 $\boldsymbol{\mathcal{X}}$，DCRS 通过最小化以下损失函数，学习公式 (5) 所示的解耦推荐模型:

$$\begin{aligned}\mathcal{L}(\boldsymbol{\mathcal{X}}, \boldsymbol{\theta}, \boldsymbol{W_1}, \boldsymbol{W_2}) = & \frac{1}{|\boldsymbol{X}|} \sum_{(u,i,y_{u,i})\in\boldsymbol{\mathcal{X}}} \mathcal{L}_{rec}\left(\hat{p}_{u,i}, y_{u,i}\right) \\ & + \mathcal{L}_{rec}\left(\hat{p}_{u,i}^{\perp C}, y_{u,i}\right) - \lambda \mathcal{L}_D^{\perp C}(u,i) + \lambda \mathcal{L}_D^C(u,i).\end{aligned}$$

推理。 在推理阶段，我们利用公式 (9) 中的 $\hat{}p_{u,\ i}$ 作为用户 u 对物品 i 的预测偏好，对物品进行排序。我们采用公式 (9) 中的 $\hat{}p_{u,\ i}$，因为它同时考虑了用户对类别相关和类别无关特征的偏好；而公式 (7) 中的 $\hat{}p_{u\,i}^{\perp C}$ 仅捕捉用户对类别无关特征的偏好。

3. 离线实验

本节在若干公开离线数据集上进行实验，以展示 DCRS 的有效性。我们主要从两个角度进行研究:

- 所提出的 DCRS 在推荐准确率和多样性方面表现如何?
- 解耦的类别无关表示能否准确区分用户在不同物品类别中的偏好?

我们还进行了案例研究，以更明确地展示所提出的 DCRS 的有效性。

3.1 实验设置

数据集。 我们使用三个广泛应用于不同推荐场景的数据集进行评估。

- **ML-1M**[1]**:** 该数据集包含来自在线电影推荐服务 MovieLens 的 6040 位用户对 3883 部电影给出的 100 万条评分。它还包含丰富的用户

1. https://grouplens.org/datasets/movielens/1m/

表1：三个数据集的统计信息

数据集	#用户	#物品	#交互	#组
ML-1M	6040	3883	1000209	18
ML-10M	69878	10680	10000047	19
亚马逊图书	22929	33130	1178117	141

特征（例如年龄、性别等）和电影特征（例如标题）。我们按照先前的工作（Zhou 等，2018；Wang 等，2021）对用户和电影特征进行编码。我们取 $y_{u,\ i} = 1$，如果用户 u 给物品 i 的评分高于 3，否则 $y_{u,\ i} = 0$。

• **ML-10M**[2]**：** 该数据集也来自 MovieLens，包含 69878 位用户对 10680 部电影的 1000 万条评分。同样，我们取$y_{u,\ i} = 1$，若用户 u 对物品 i 的评分大于 3，否则取 $y_{u,\ i} = 0$。

• **亚马逊图书**[3]**：** 该数据集包含亚马逊图书的评论和元数据。为确保数据质量，我们仅保留与超过 20 本图书相关联的类别，共 141 个类别，并采用 20核设置（Wang 等，2021），即剔除交互少于 20 次的用户和图书。为使正负样本数量均衡，我们取 $y_{u,\ i} = 1$，若用户 u 对物品 i 的评分大于 4，否则取 $y_{u,\ i} = 0$。

三个数据集的统计信息汇总于表1。

在每个数据集上，我们还随机抽取用户未曾交互过的物品作为负样本。随后，我们按照时间戳对用户-物品交互进行排序，并按 80%、10% 和 10% 的比例将其划分为训练、验证和测试数据集。**基线方法**。 所提出的 DCRS 是一个通用且与模型无关的框架，用于解耦类别相关和类别无关的表示，以实现准确且多样化的推荐。在本文中，我们使用神经分解机（NFM）（He 和 Chua，2017）对其进行了实例化；NFM 是一种具有代表性的推荐模型，已得到广泛应用。在若干与多样化推荐密切相关的工作中，NFM 也被用作骨干模型（Grgic-Hlaca 等，2016；Wang 等，2021）。我们将 DCRS 与以下算法进行了比较，这些算法在推荐多样性和准确性方面各有不同的侧重点。

• **NFM（He 和 Chua，2017）**：作为 DCRS 骨干模型的当前最先进推荐模型。

• **无意识 (Grgic-Hlaca 等，2016年)**：它同样采用 NFM 作为骨干模型，并尝试通过直接从模型输入中移除物品的类别特征来提升多样性。

• **IPS（Saito 等，2020）**：这是一种最先进的提升多样性的技术，通过增强用户较少交互的物品类别，同时抑制用户交互历史中的主导类别来提高多样性。具体而言，它将用户历史交互中的类别分布作为倾向得分，对

2. https://grouplens.org/datasets/movielens/10m/ 3. https://jmcauley.ucsd.edu/data/amazon/

此类别的物品在训练期间重新加权。还采用倾向性剪裁（Saito 等，2020）来降低方差，并在 $\{0.001、0.005、0.01、0.05、0.1\}$ 中搜索剪裁阈值。

• **MMR（Carbonell 和 Goldstein，1998）**：多样化推荐领域最先进的后处理方法之一。它通过贪心策略对 NFM 生成的推荐物品重新排序，以减少冗余。

• **DPP（Chen 等，2018）**：一种有效的多样化推荐后处理方法。它通过平衡物品的相关性及其相似度，从 NFM 生成的推荐物品中选出一组多样化物品。

• **PD GAN（Wu 等，2019c）**：近期的一项工作，利用生成对抗网络（GAN）框架生成多样且相关的推荐。其判别器旨在将生成器生成的多样化物品集合，与从用户观测数据中随机采样的真实集合区分开来。

• **DGCN（Zheng 等，2021a）**：近期的一项工作，在图卷积网络（GCN）基础上，结合再平衡邻居发现、类别增强负采样和对抗学习，实现多样化推荐。

• **DecRS（Wang 等，2021）**：一项近期研究，从因果视角出发，旨在缓解以往推荐模型过度推荐用户交互历史中主导类别物品的偏差。该方法旨在同时提升推荐准确率和多样性。

• **DCRS CI**：DCRS 的一个变体，在物品排序时利用 $\hat{p}_{ui}^{\perp C}$（式（7））， 而不考虑用户对类别的偏好。将其与 DCRS CI 进行比较，可以揭示对用户类别偏好进行建模的重要性。

实现细节。 遵循以往工作（Wang 等，2021；He 和 Chua，2017），我们将用户/物品特征的嵌入维度设为 64（即 $d = 64$），并使用 AdaGrad（Duchi 等，2011）进行优化。我们采用网格搜索，根据模型在验证数据集上的表现来选择超参数：学习率的搜索范围为 $\{0.005、0.01、0.05\}$；归一化系数的搜索范围为 $\{0, 0.1、0.2\}$；丢弃率的搜索范围为 $\{0.2、0.3、...、0.5\}$； λ 用于控制类别无关和类别相关约束强度的参数，搜索范围为 $\{0.01、0.05、0.1、0.5、 1\}$。对于基线算法，如果原论文也在该数据集上进行了评估，我们采用原论文推荐的超参数；否则，我们按照上述方式进行类似的网格搜索，搜索范围则参考原论文。

3.2 推荐准确性与多样性表现

我们首先从推荐准确率和多样性两个方面评估所有算法。

评估指标。 我们从两个方面评估推荐模型的准确性：（1）模型能否在测试数据集中准确地将用户正向交互物品排在负向交互物品之前；（2）模型能否

数据集	方法	AUC	UAUC	RelaImpr	召回率@10	归一化折损累积增益@10	交叉熵@10	点击率@10	R@20	NDCG@20	交叉熵@20	点击率@20
ML 1M	NFM	0.8461	0.8224	0.00%	0.0522	0.0572	1.8056	0.4741	0.0908	0.0681	1.9764	0.6185
	无意识	0.8414^{-}	0.8134^{-}	-2.79%	0.0512^{-}	0.0568^{-}	1.8919^{+}	0.4998^{+}	0.0880^{-}	0.0669^{-}	2.0513^{+}	0.6419^{+}
	IPS	0.8446^{-}	0.8210^{-}	-0.43%	0.0513^{-}	0.0572	1.7929^{-}	0.4713^{-}	0.0890^{-}	0.0681	1.9759^{-}	0.6225^{+}
	MMR	–	0.8194^{-}	-0.93%	0.0501^{-}	0.0545^{-}	2.1279^{+}	0.5886^{+}	0.0902^{-}	0.0670^{-}	2.2224^{+}	0.7244^{+}
	DPP	–	0.6021^{-}	-68.3%	0.0454^{-}	0.0518^{-}	2.4119^{+}	0.7315^{+}	0.0770^{-}	0.0601^{-}	2.5974^{+}	0.9586^{+}
	PD GAN	–	–	–	0.0326^{-}	0.0347^{-}	2.5495^{+}	0.8347^{+}	0.0503^{-}	0.0386^{-}	2.6650^{+}	0.9393^{+}
	DGCN	0.7949^{-}	0.7759^{-}	-14.4%	0.0365^{-}	0.0402^{-}	1.9133^{+}	0.5088^{+}	0.0640^{-}	0.0482^{-}	2.0748^{+}	0.6466^{+}
	DecRS	0.8462^{+}	0.8202^{-}	-0.07%	0.0537^{+}	0.0588^{+}	1.8560^{+}	0.4876^{+}	0.0919^{+}	0.0694^{+}	2.0378^{+}	0.6365^{+}
	DCRS CI	0.8332^{-}	0.8096^{-}	-3.90%	0.0530^{+}	0.0581^{+}	1.7606^{-}	0.4468^{-}	0.0936^{+}	0.0699^{+}	1.9108^{-}	0.5766^{-}
	DCRS	$\mathbf{0.8483}^{+}$	$\mathbf{0.8237}^{+}$	**0.40%**	$\mathbf{0.0551}^{+}$	$\mathbf{0.0602}^{+}$	$\mathbf{1.8877}^{+}$	$\mathbf{0.4909}^{+}$	$\mathbf{0.0960}^{+}$	$\mathbf{0.0722}^{+}$	$\mathbf{2.0620}^{+}$	$\mathbf{0.6368}^{+}$
ML 10M	NFM	0.8346	0.8193	0.00%	0.0474	0.0448	1.9351	0.5127	0.0797	0.0547	2.0877	0.6504
	无意识	0.8274^{-}	0.8078^{-}	-3.60%	0.0394^{-}	0.0363^{-}	2.0308^{+}	0.5410^{+}	0.0659^{-}	0.0446^{-}	2.2036^{+}	0.6891^{+}
	IPS	0.8378^{+}	0.8218^{+}	0.78%	0.0469^{-}	0.0441^{-}	1.9280^{-}	0.5070^{-}	0.0783^{-}	0.0538^{-}	2.0913^{+}	0.6491^{-}
	MMR	–	0.8084^{-}	-3.41%	0.0436^{-}	0.0418^{-}	2.2941^{+}	0.6629^{+}	0.0762^{-}	0.0521^{-}	2.3451^{+}	0.7639^{+}
	DPP	–	0.6459^{-}	-54.3%	0.0390^{-}	0.0392^{-}	2.5014^{+}	0.7740^{+}	0.0629^{-}	0.0459^{-}	2.6248+	0.9376^{+}
	PD GAN	–	–	–	0.0108^{-}	0.0119^{-}	2.3134^{+}	0.7164^{+}	0.0176^{-}	0.0136^{-}	2.4446^{+}	0.8606^{+}
	DGCN	0.8069^{-}	0.8081^{-}	-3.51%	0.0425^{-}	0.0380^{-}	2.0459^{+}	0.5530^{+}	0.0740^{-}	0.0482^{-}	2.1925^{+}	0.6934^{+}
	DecRS	0.8417^{+}	0.8261^{+}	2.12%	0.0477^{+}	0.0445^{-}	1.9401^{+}	0.5048^{-}	0.0814^{+}	0.0551^{+}	2.1181^{+}	0.6480^{-}
	DCRS CI	0.8357^{+}	0.8197^{+}	0.12%	0.0478^{+}	0.0448	1.9810^{+}	0.5269^{+}	0.0813^{+}	0.0554^{+}	2.1322^{+}	0.6635^{+}
	DCRS	$\mathbf{0.8447}^{+}$	$\mathbf{0.8301}^{+}$	**3.38%**	$\mathbf{0.0499}^{+}$	$\mathbf{0.0465}^{+}$	$\mathbf{2.0050}^{+}$	$\mathbf{0.5327}^{+}$	$\mathbf{0.0838}^{+}$	$\mathbf{0.0572}^{+}$	$\mathbf{2.1655}^{+}$	$\mathbf{0.6733}^{+}$
亚马逊图书	NFM	0.6667	0.6289	0.00%	0.0076	0.0052	1.6722	0.0495	0.0118	0.0066	1.9551	0.0740
	无意识	0.6267^{-}	0.5687^{-}	-46.7%	0.0064^{-}	0.0043^{-}	1.6660^{-}	0.0524^{+}	0.0097^{-}	0.0054^{-}	1.8762^{-}	0.0721^{-}
	IPS	0.6650^{-}	0.6269^{-}	-1.55%	0.0078^{+}	0.0053^{+}	1.5969^{-}	0.0453^{-}	0.0115^{-}	0.0066	1.9148−	0.0704^{-}
	MMR	–	0.6096^{-}	-15.0%	0.0067^{-}	0.0045^{-}	2.2899^{+}	0.0864^{+}	0.0109^{-}	0.0060^{-}	2.5119^{+}	0.1278^{+}
	DPP	–	0.5300^{-}	-76.7%	0.0054^{-}	0.0040^{-}	2.5184^{+}	0.1005^{+}	0.0081^{-}	0.0049^{-}	2.8741+	0.1645^{+}
	PD GAN	–	–	–	0.0004^{-}	0.0003^{-}	2.3179^{+}	0.0920^{+}	0.0016^{-}	0.0007^{-}	2.7648^{+}	0.1545^{+}
	DGCN	0.6747^{+}	0.6404^{+}	8.92%	0.0071^{-}	0.0044^{-}	2.0003^{+}	0.0698^{+}	0.0122^{+}	0.0061^{-}	2.2842^{+}	0.1074^{+}
	DecRS	0.6964^{+}	0.6558^{+}	20.8%	0.0074^{-}	0.0051^{-}	1.8207^{+}	0.0601^{+}	0.0111^{-}	0.0063^{-}	2.0973^{+}	0.0918^{+}
	DCRS CI	0.6893^{+}	0.6546^{+}	19.9%	0.0057^{-}	0.0036^{-}	2.0172^{+}	0.0704^{+}	0.0095^{-}	0.0049^{-}	2.2799^{+}	0.1068^{+}
	DCRS	$\mathbf{0.6974}^{+}$	$\mathbf{0.6573}^{+}$	**22.0%**	$\mathbf{0.0079}^{+}$	**0.0052**	$\mathbf{1.8639}^{+}$	$\mathbf{0.0622}^{+}$	$\mathbf{0.0123}^{+}$	$\mathbf{0.0067}^{+}$	$\mathbf{2.1415}^{+}$	$\mathbf{0.0953}^{+}$

表 2：推荐准确率和多样性方面的实验结果。在相同设置下，相较于基础 NFM 模型性能有所提升（或下降）的结果标记为 $+$ （或 $-$）。

		ML-1M				ML-10M				亚马逊图书			
类别	方法	AUC	UAUC	R@20	NDGG@20	AUC	UAUC	R@20	NDGG@20	AUC	UAUC	R@20	NDGG@20
1st 排名类别	NFM	0.8547	0.8180	0.3034	0.1678	0.8498	0.8229	0.2814	0.1453	0.6474	0.5976	0.0679	0.0343
	DecRS	0.8563	0.8135	0.3079	0.1718	0.8545	0.8273	0.3031	0.1572	0.6724	0.6113	0.0698	0.0331
	DCRS 类别无关	0.8606	**0.8241**	**0.3230**	**0.1783**	**0.8608**	**0.8340**	**0.3210**	**0.1659**	**0.6730**	**0.6178**	**0.0730**	**0.0345**
2nd 排名类别	NFM	0.8403	0.8009	0.3820	0.1962	0.8372	0.8078	0.3434	0.1655	0.6637	0.5489	0.0536	0.0302
	DecRS	0.8407	0.8014	0.3817	0.1982	0.8407	0.8088	0.3558	0.1718	0.6978	0.5661	0.0576	0.0310
	DCRS 类别无关	0.8449	**0.8056**	**0.3960**	**0.2078**	**0.8485**	**0.8170**	**0.3861**	**0.1875**	**0.7413**	**0.5709**	**0.0595**	**0.0312**
3rd 排名类别	NFM	0.8344	0.8046	0.6665	0.3350	0.8172	0.7926	0.4156	0.1969	0.6931	0.5910	0.0554	0.0241
	DecRS	0.8381	**0.8062**	0.6743	0.3423	0.8231	0.7968	0.4458	0.2137	0.7044	0.5920	0.0548	0.0233
	DCRS CI	0.8419	0.8055	**0.6873**	**0.3463**	**0.8264**	**0.8014**	**0.4794**	**0.2291**	**0.7176**	**0.6162**	**0.0591**	**0.0245**

表 3：解耦的类别无关表示在类别特定测试数据上的推荐准确率。

从物品池中准确检索出测试数据集中的正向交互物品，其中物品池包含用户在训练数据集中未交互过的所有物品。对于 MMR 和 DPP，由于它们只会对 NFM 生成的推荐物品重新排序，因此我们使用了专门构建的物品池，其中包含 NFM 排名靠前的 200 个物品。我们采用 AUC（Fawcett，2006年）和 UAUC（Zhou 等，2018年）作为评估第一个方面的指标。基本上，UAUC 是 AUC 的微平均版本，通过对各用户的 AUC 取平均来衡量用户内推荐的效果。此外，我们遵循以往研究（Yan 等，2014；Zhou 等，2018年），使用 RelaImpr 指标衡量 UAUC 相较于基础NFM模型的相对提升。对于随机猜测器，AUC 的值为 0.5，因此 RelaImpr 定义为：

$$\text{RelaImpr} = \left(\frac{\text{UAUC(mesured model)} - 0.5}{\text{UAUC(base NFM model)} - 0.5} - 1 \right) \times 100\%.$$

为评估推荐准确率的第二个方面，我们采用 Recall@K 和 NDCG@K 作为评估指标。对于推荐多样性，我们使用了两个广泛采用的指标：(1) 类别覆盖率（CC@K），即前 K 个推荐所覆盖的类别数与数据集中类别总数的比值；(2) 类别熵（CE@K），即前 K 个推荐中类别分布的熵。CC@K 和 CE@K 越高，表明前 K 个推荐越多样化。

表 2 展示了所有算法的实验结果。由于 PD GAN 直接推荐一组物品，因此我们无法报告其 AUC、UAUC 和 RelaImpr。对于 MMR 和 DPP，由于难以找到合适的方法将不同用户重新排序后的列表合并起来以计算 AUC，因此我们只能报告 UAUC 和 RelaImpr。根据这些结果，我们可以观察到：

- 虽然 Unawareness、MMR、DPP、PD GAN 和 DGCN 通过提高 CE@K 和 CC@K 带来了更多样化的推荐，但其推荐准确率却大幅下降，表明它们未能解决准确性与多样性困境。

- 由于倾向得分估计不准确且方差较大，IPS 在推荐多样性和准确性方面并未始终优于基础NFM模型。

- 在大多数情况下，尤其是在 ML 1M 和 ML 10M100K 数据集上，DecRS 提高了推荐准确率和多样性，因为它能够避免推荐来自主导类别的许多相关性较低或低质量物品。不过，其改进幅度不及我们提出的 DCRS。

- 与基础NFM模型相比，我们提出的 DCRS 在三个数据集上都有效提高了推荐准确率和多样性。可以观察到，在所有数据集上，DCRS 在所有指标上都取得了最高的推荐准确率，并且其生成的推荐比基础NFM模型更多样，CC@K 和 CE@K 也更高。这表明，DCRS 倾向于生成用户会偏好的多样化推荐，而不是不顾推荐准确率、一味追求多样性。此外，与 DCRS 相比，DCRS CI 在三个数据集上的推荐准确率均有所下降，这证实了对用户类别偏好进行建模的重要性。

3.3 预测用户的类别内偏好

我们进一步探究 DCRS 为何能够做出准确且多样化的推荐。根据我们的设计，在学习用户-物品表示时，解耦机制将用户对物品类别的偏好与其对类别内物品的偏好区分开来。因此，与未考虑这一方面的方法相比，DCRS 学得的用户-物品表示应能更好地预测用户在某一物品类别中的兴趣。为此，我们考察解耦的类别无关表示（即$\{\boldsymbol{h}_{u,i}^{\perp C}\}$）能否在给定的物品类别中，更准确地区分相关性较低（或质量较差）的物品与相关性较高（或质量较好）的物品。

我们按照物品类别划分测试数据集，并分别在每个类别特定测试数据集上评估所有算法。在我们的三个评估数据集中，物品可能关联多个类别。例如，电影《玩具总动员（1995）》在

ML-1M 数据集关联三个类别：“动画”“儿童”和“喜剧”。在这里，我们按照关联类别的每种唯一组合划分测试数据集。对于给定的一种唯一类别组合，我们遍历测试数据集，只保留交互物品属于相同类别组合的用户-物品交互。为确保评估结果的可靠性，我们仅在每个数据集中最受欢迎的前三个类别上评估算法。

在这一实验设置中，由于所有物品都来自同一类别，我们只需评估 DCRS CI。表 3 展示了实验结果。受篇幅限制，我们仅报告 AUC、UAUC、Recall@20 和 NDCG@20 的结果，并省略表现不如基础NFM模型的基线方法。从表 3 可以看出，DecRS 和 DCRS CI 的表现都优于基础NFM模型，这与第 3.2 节中的结果一致。此外，DCRS CI 大多数时候都取得了最佳表现，这表明解耦表示有助于在类别内进行更准确的偏好建模。

3.4 案例研究

我们还通过案例研究，对所提出的 DCRS 模型的行为进行定性说明。图 4 展示了 ML-1M 数据集中一位用户在训练数据和测试数据中的交互物品类别分布，以及由 NFM、DecRS 和 DCRS 生成的排名前10的推荐项目。从图 4 可以观察到：NFM 和 DecRS 模型给出的排名前10的推荐主要属于“惊悚片”类别，这是该用户训练数据中最受欢迎的类别。我们提出的 DCRS 能够更全面地捕捉用户对不同类别的偏好。如图 4 所示，与其他推荐算法不同，DCRS 推荐的物品并未只集中在主导类别“惊悚片”上，而是成功覆盖了用户测试数据中有非零支持的十个类别中的六个。此外，DCRS 还能识别用户对其此前很少交互过的类别的偏好，例如“纪录片”类别。这解释了它为何能在不牺牲推荐准确率的情况下提升推荐多样性。

4. 在线部署和 A/B 测试

为进一步验证 DCRS 的有效性，我们将其部署在今日头条应用的推荐频道上进行在线 A/B 测试。今日头条应用是中国最大的新闻推荐平台之一。

具体而言，我们基于今日头条的主候选生成器实现了 DCRS。主候选生成器是众多候选生成器之一，用于生成推荐候选项；之后，这些候选项会由独立的排序模型打分并排序，再呈现给用户（Chen 等，2019）。不过，主候选生成器生成的推荐候选项占展示给用户的推荐内容中的最大比例。随后，我们在实验组中用 DCRS 替换主候选生成器，在对照组中则使用原有的主候选生成器。我们采用了两个关键指标来衡量用户对推荐结果的满意度：（1）点击率（*CTR*）；（2）停留时长。为准确评估推荐多样性，我们只将曝光量超过 1000 的物品作为目标物品，因为对于那些

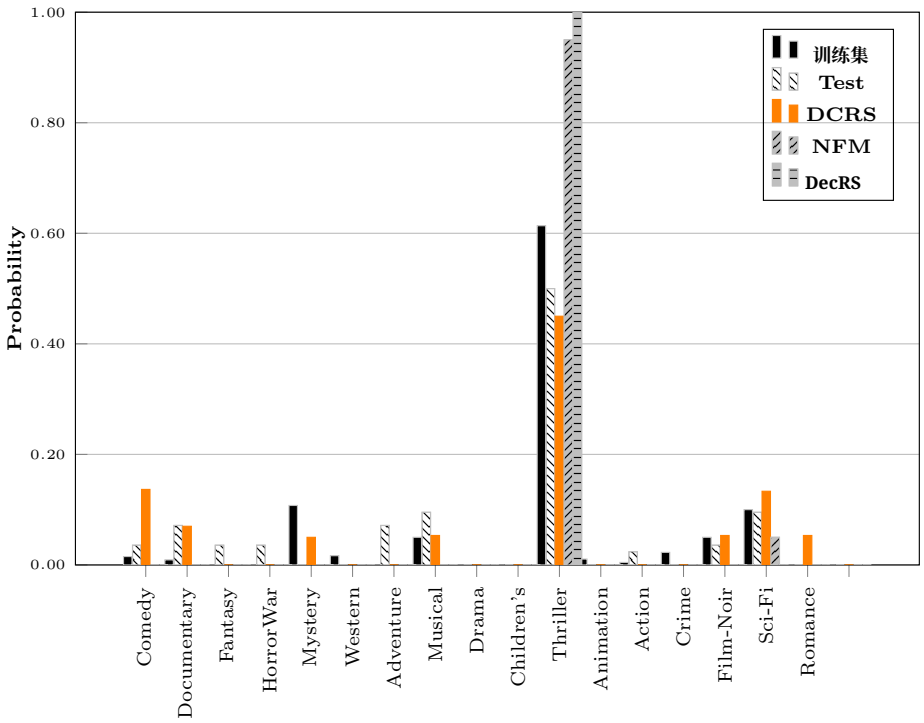


图 4：抽样用户的训练数据、测试数据和排名前10的推荐项目的类别分布。

	Δ点击率	Δ停留时长	ΔE CN	ΔE CE	ΔR CN	ΔR CE
DCRS	+0.973%	+0.062%	+0.197%	+0.111%	+2.372%	+2.276%

表4：今日头条应用在线 A/B 测试结果。

曝光频次较低的物品，可能是通过某些特殊策略而非所比较的方法引入的。随后，我们计算了四项指标：（1）E CN：向用户展示的目标物品所涉及的不同类别数量；（2）E CE：向用户展示的目标物品类别分布的熵；（3）R CN：用户阅读过的目标物品所涉及的不同类别数量；（4）R CE：用户阅读过的目标物品类别分布的熵。A/B 测试连续进行了 17 天，并报告上述指标的平均表现。实验结果见表4。所有报告的结果均具有统计显著性，p 值为 < 0.05。我们可以看到，DCRS 提高了 点击率和停留时长，表明用户满意度有所提升。此外，尽管 E CN 和 E CE 的提升幅度不大，DCRS 却大幅提升了 R CN 和 R CE，这表明 DCRS 能够生成用户更喜欢的多样化推荐。

5. 相关工作

DCRS 与两类现有研究密切相关：（1）解决推荐中的准确性与多样性困境；（2）用于通用用户建模的解耦用户表示学习。

解决推荐中的准确性与多样性困境。除了推荐准确性外，越来越多的研究表明，推荐质量的其他因素也会影响用户对系统的整体满意度。在这些因素中，推荐多样性被证明至关重要（Anderson 等人，2020；Wilhelm 等人，2018），但它也造成了所谓的准确性与多样性困境（Wang 等，2021；Zheng 等，2021a）：更高的准确性往往意味着在一定程度上牺牲多样性，反之亦然。一个主要原因是，过去以准确性为首要目标的解决方案往往侧重于用户交互历史中占主导地位的类别中的物品。为确保用户满意度，研究者提出了三类不同的解决方案，分别是后处理、学习排序和多样化推荐模型。

对于第一类也是最受欢迎的解决方案，会在选定的推荐模型后附加一个重排序或后处理模块。后处理模块以推荐物品为输入，并重新排序，以平衡推荐准确率和多样性。已有研究提出了各种后处理算法（Ziegler等人，2005年；Qin和Zhu，2013年；Ashkan等人，2015年；Chen等人，2018年；Kaya和Bridge，2019年）。例如，Ziegler等人（Ziegler等人，2005年）首次将最大边际相关性（MMR）算法应用于推荐，该算法此前用于搜索引擎中的主题多样化，旨在尽量减少推荐物品之间的冗余。行列式点过程（DPP）被证明是所有后处理算法中效果最好的一种（Chen等人，2018年）；它对整个物品列表进行评分，而不是逐一对每个物品评分，从而更好地建模物品之间的相关性。然而，尽管这些后处理算法的学习效果高度依赖推荐模型的性能，但它们都是与推荐模型分开构建的。如果推荐模型一开始就无法提供多样化的物品列表，或者给多样化项目的评分很低，那么上述后处理算法的效果就会大幅下降。此外，正如第3节的实验结果所示，上述后处理算法通常会严重牺牲推荐准确率。

学习排序类型的解决方案（Cheng等人，2017年；Wu等人，2018a；Liu等人，2022年）旨在直接向用户推荐一个物品列表，而不是根据预测分数逐一选择物品。然而，这类方法通常存在时间复杂度较高的问题，限制了其在现实世界推荐场景中的应用。

最近，有几种方案被提出，用于直接提升推荐模型的多样性。Zheng等人（Zheng 等，2021a）提出了一种基于图卷积网络（GCN）的多样化推荐模型，其唯一目标是提升推荐多样性。Wu等人（Wu 等，2019c）利用GAN框架进行多样化推荐，其中生成器尝试推荐多样化的物品集合，而判别器则旨在区分生成的推荐与从目标用户的观测数据中随机抽取的一组物品。与我们工作最相关的是（Wang 等，2021），作者从因果角度研究了推荐缺乏多样性的问题，并提出DecRS来缓解这一问题。实验表明，我们提出的DCRS在提升推荐准确率和多样性方面优于这些方案。近期的一项工作（Lin 等，2022）也尝试在相关性推荐场景中实现推荐多样化，其做法是针对多个物品方面进行多样化，从而在不同物品方面之间自适应地平衡相关性与多样性

。不过，当只考虑一个物品方面时，例如本文中的物品类别，他们的算法就会退化为MMR算法。

解耦用户表示。近年来，学习解耦用户表示受到越来越多的关注。一类解决方案基于变分自编码器（VAE），旨在使学习到的表示的每个维度分别关注不同的潜在因子（Ma等人，2019年；Xie等人，2021；Nema等人，2021）。然而，这种解耦是隐式的，因此无法将解耦后的表示与感兴趣的特定属性关联起来。Zheng等人（Zheng 等，2021b）提出了DICE，通过特定原因数据的直接监督，学习在结构上将用户兴趣与从众性解耦的表示。然而，在我们的问题中，我们无法显式获取用户对物品类别的偏好，因此无法得到关于该偏好的直接监督。Chen等人（Chen等人，2022年）提出对物品表示进行解耦以解决流行度偏差，方法是要求两个解耦后的物品表示彼此正交。在我们的方案中，我们将用户对某件物品的偏好解耦为类别相关与无关部分。这两部分都与用户相关，因此彼此之间不必正交。

6. 结论

本文提出了一项新原则：推荐多样化应在用户偏好的类别内进行，从而在不牺牲推荐准确率的前提下提升推荐多样性。我们通过一个名为 DCRS 的通用框架实现了这一原则，该框架能够在学习到的表示中解耦用户对类别相关和类别无关的偏好。我们通过三个广泛使用的推荐基准数据集上的离线实验，以及在中国最大新闻推荐平台之一今日头条上开展的在线 A/B 测试，对 DCRS 进行了评估。结果表明，DCRS 能够提供更准确、更多样化的推荐。通过深入分析和案例研究，我们发现 DCRS 带来的优势源于：（1）它能更全面地捕捉用户在历史交互中表现出的多样化偏好；（2）它能更准确地对同一类别中的物品进行排序。

在本研究中，我们以静态视角看待用户对物品和物品类别的偏好。然而，大量研究表明，用户的偏好会随时间演变（Wu等人，2018年b，2019年b）。以交互式方式随时间研究推荐多样化问题很有意义。此外，目前我们每次只向用户推荐一个物品。如何生成多样化推荐列表也值得研究，其中应在单个推荐列表内以及不同推荐列表之间优化多样性。

参考文献

Ashton Anderson、Lucas Maystre、Ian Anderson、Rishabh Mehrotra 和 Mounia Lalmas。算法对 Spotify 消费多样性的影响。载于 *2020*年万维网大会论文集，第 2155–2165 页，2020 年。

Azin Ashkan、Branislav Kveton、Shlomo Berkovsky 和 Zheng Wen。用于推荐的最优贪心多样性。在第二十四届国际人工智能联合会议，2015年。

Jaime Carbonell 和 Jade Goldstein。使用 MMR（一种基于多样性的重排序方法）对文档重新排序并生成摘要。在第*21*届 *ACM SIGIR* 信息检索研究与发展国际会议论文集，第335–336页，1998年。Allison JB Chaney、Brandon M Stewart 和 Barbara E Engelhardt。推荐系统中的算法混杂如何增加同质性并降低效用。在第*12*届 *ACM*推荐系统会议论文集，第224–232页，2018年。Laming Chen、Guoxin Zhang 和 Hanning Zhou。用于行列式点过程的快速贪心最大后验推断，以提升推荐多样性。在第*32*届神经信息处理系统国际会议论文集，第5627–5638页，2018年。Minmin Chen、Alex Beutel、Paul Covington、Sagar Jain、Francois Belletti 和 Ed H Chi。面向 REINFORCE 推荐系统的 top-k离策略校正。在第十二届 *ACM*网络搜索与数据挖掘国际会议论文集，第456–464页，2019年。Zhihong Chen、Jiawei Wu、Chenliang Li、Jingxu Chen、Rong Xiao 和 Binqiang Zhao。协同训练解耦领域自适应网络，以利用推荐系统中的流行度偏差。在第*45*届 *ACM SIGIR*信息检索研究与发展会议论文集，第60–69页，2022年。Peizhe Cheng、Shuaiqiang Wang、Jun Ma、Jiankai Sun 和 Hui Xiong。学习如何推荐准确且多样化的物品。在第*26*届万维网国际会议论文集，第183–192页，2017年。Paul Covington、Jay Adams 和 Emre Sargin。用于 YouTube 推荐的深度神经网络。在第*10*届 *ACM*推荐系统会议论文集，第191–198页，2016年。Arthur P Dempster、Nan M Laird 和 Donald B Rubin。通过期望最大化算法从不完整数据中求最大似然。皇家统计学会杂志：*B*辑（方法论），39(1):1–22，1977年。John Duchi、Elad Hazan 和 Yoram Singer。用于在线学习和随机优化的自适应次梯度方法。机器学习研究杂志，12(7)，2011年。Tom Fawcett。ROC分析简介。模式识别快报，27(8):861–874，2006年。Yaroslav Ganin 和 Victor Lempitsky。通过反向传播实现无监督领域自适应。在国际机器学习会议，第1180–1189页。PMLR，2015年。Yingqiang Ge、Shuya Zhao、Honglu Zhou、Changhua Pei、Fei Sun、Wenwu Ou 和 Yongfeng Zhang。了解电子商务推荐系统中的回声室。在第*43*届 *ACM SIGIR*信息检索研究与发展国际会议论文集，第2261–2270页，2020。

Nina Grgic-Hlaca、Muhammad Bilal Zafar、Krishna P Gummadi 和 Adrian Weller。《论学习中的过程公平性：面向公平决策的特征选择》。发表于*NIPS* 机器学习与法律研讨会，第 1 卷，第 2 页，2016年。Huifeng Guo、Ruiming Tang、Yunming Ye、Zhenguo Li 和 Xiuqiang He。《DeepFM：一种基于因子分解机的神经网络，用于点击率预测》。*arXiv* 预印本 *arXiv:1703.04247*，2017年。Xiangnan He 和 Tat-Seng Chua。《面向稀疏预测分析的神经分解机》。发表于第 *40* 届 *ACM SIGIR*信息检索研究与发展会议论文集，第 355–364 页，2017年。Komal Kapoor、Vikas Kumar、Loren Terveen、Joseph A Konstan 和 Paul Schrater。《"我有时喜欢探索"：适应动态的用户新颖性偏好》。发表于第 *9* 届 *ACM*推荐系统会议论文集，第 19–26 页，2015年。

Mesut Kaya 和 Derek Bridge。校准型推荐与意图感知推荐的比较。载于第*13*届*ACM*推荐系统会议论文集，第151–159页，2019年。

Zihan Lin、Hui Wang、Jingshu Mao、Wayne Xin Zhao、Cheng Wang、Peng Jiang 和 Ji-Rong Wen。面向相关性推荐的特征感知多样化重排序与解耦表示。*arXiv*预印本 *arXiv:2206.05020*，2022年。

Yuli Liu、Christian Walder 和 Lexing Xie。用于序列推荐的行列式点过程似然。*arXiv*预印本 *arXiv:2204.11562*，2022年。

Jianxin Ma、ChangZhou、Peng Cui、Hongxia Yang 和 Wenwu Zhu。学习用于推荐的解耦表示。*arXiv*预印本 *arXiv:1910.14238*，2019年。

Andriy Mnih 和 Russ R Salakhutdinov。概率矩阵分解。神经信息处理系统进展，20，2007年。

Preksha Nema、Alexandros Karatzoglou 和 Filip Radlinski。使用 ß-vae 解耦偏好表示，以便对推荐进行评价。在第 *30* 届 *ACM* 国际信息与知识管理会议论文集中，第 1356–1365 页，2021 年。

Tien T Nguyen、Pik-Mai Hui、F Maxwell Harper、Loren Terveen 和 Joseph A Konstan。探索过滤气泡：使用推荐系统对内容多样性的影响。发表于第 *23* 届万维网国际会议论文集，第 677–686 页，2014 年。Shi Pu、Yijiang He、Zheng Li 和 Mao Zheng。用于视频推荐的多模态主题学习。*arXiv* 预印本 *arXiv:2010.13373*，2020 年。Lijing Qin 和 Xiaoyan Zhu。通过熵正则化器提升推荐多样性。发表于第二十三届国际人工智能联合会议，2013 年。

Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。贝叶斯个性化排序：基于隐式反馈的贝叶斯个性化排序。*arXiv* 预印本 *arXiv:1205.2618*，2012 年。

Yuta Saito、Suguru Yaginuma、Yuta Nishino、Hayato Sakata 和 Kazuhide Nakata。从非随机缺失隐式反馈中进行无偏推荐学习。载于第*13*届国际网络搜索与数据挖掘会议论文集，第501–509页，2020年。

Harald Steck。校准推荐。载于第*12*届*ACM*推荐系统会议论文集，第154–162页，2018年。

Wenjie Wang、Fuli Feng、Xiangnan He、Xiang Wang 和 Tat-Seng Chua。通过消除混杂因素的推荐来减轻偏差放大。*arXiv*预印本 *arXiv:2105.10648*，2021。

Mark Wilhelm、Ajith Ramanathan、Alexander Bonomo、Sagar Jain、Ed H Chi 和 Jennifer Gillenwater。基于行列式点过程的 YouTube 实用多样化推荐。载于第*27*届*ACM*信息与知识管理国际会议论文集，第2165–2173页，2018年。

Chuhan Wu、Fangzhao Wu、Mingxiao An、Jianqiang Huang、Yongfeng Huang 和 Xing Xie。NPA：借助个性化注意力的神经新闻推荐。载于 *ACM SIGKDD* 知识发现与数据挖掘国际会议论文集（第*25*届），第 2576–2584 页，2019a。

Liwei Wu、Cho-Jui Hsieh 和 James Sharpnack。SQL-Rank：一种列表式协同排序方法。载于国际机器学习会议，第 5315–5324 页。PMLR，2018a。

Qingyun Wu、Naveen Iyer 和 Hongning Wang。在非平稳环境中学习上下文老虎机。载于第*41*届 *ACM SIGIR* 信息检索研究与发展大会，第 495–504 页，2018b。

Qingyun Wu、Huazheng Wang、Yanen Li 和 Hongning Wang。动态集成上下文老虎机，以满足用户变化的兴趣。载于万维网大会，第 2080–2090 页，2019b。

Qiong Wu、Yong Liu、Chunyan Miao、Binqiang Zhao、Yin Zhao 和 Lu Guan。PD-GAN：用于个性化多样性促进推荐的对抗学习。载于 国际人工智能联合会议，第 19 卷，第 3870–3876 页，2019年c。

Zhe Xie、Chengxuan Liu、Yichi Zhang、Hongtao Lu、Dong Wang 和 Yue Ding。用于序列推荐的对抗式与对比变分自编码器。载于 *Web Conference 2021* 论文集，第 449–459 页，2021。

Ling Yan、Wu-jun Li、Gui-Rong Xue 和 Dingyi Han。用于展示广告网络规模点击率预测的耦合组套索。载于国际机器学习会议，第 802–810 页。PMLR，2014。

Yu Zheng、Chen Gao、Liang Chen、Depeng Jin 和 Yong Li。DGCN：基于图卷积网络的多样化推荐。载于*2021* 年 *Web Conference* 论文集，第 401–412 页，2021a。

Yu Zheng、Chen Gao、Xiang Li、Xiangnan He、Yong Li 和 Depeng Jin。利用因果嵌入解耦用户兴趣与从众性以进行推荐。载于*Web Conference 2021*论文集，第 2980–2991 页，2021b。

Guorui Zhou、Xiaoqiang Zhu、Chenru Song、Ying Fan、Han Zhu、Xiao Ma、Yanghui Yan、Junqi Jin、Han Li 和 Kun Gai。用于点击率预测的深度兴趣网络。载于第*24*届 *ACM SIGKDD*知识发现与数据挖掘国际会议论文集，第 1059–1068 页，2018年。

Tao Zhou、Zolt´an Kuscsik、Jian-Guo Liu、Mat´uˇs Medo、Joseph Rushton Wakeling 和 Yi- Cheng Zhang。解决推荐系统中表面上的多样性-准确性困境。美国国家科学院院刊，107(10):4511–4515，2010年。

Cai-Nicolas Ziegler、Sean M McNee、Joseph A Konstan 和 Georg Lausen。通过主题多样化改进推荐列表。载于第*14*届万维网国际会议论文集，第22–32页，2005年。