arXiv:2301.00910v1 [cs.IR] 3 Jan 2023

推荐系统中的因果推断：关于偏差缓解、解释和泛化策略的综述

Yaochen Zhu、Jing Ma 和 Jundong Li

摘要 在信息过载的时代，推荐系统已成为在线服务平台不可或缺的一部分。传统推荐系统利用观测到的用户历史活动、用户画像以及用户交互物品的内容中的相关性，估计用户兴趣并预测其未来行为。然而，由于没有考虑导致所观测用户行为的内在因果原因，生成的推荐中可能存在多种偏差。此外，在这些推荐系统中，驱动用户活动的因果动机通常相互纠缠，因此无法保证推荐结果的可解释性和泛化能力。为解决这些缺点，近年来，人们对运用因果推断技术增强传统推荐系统的兴趣日益高涨。在本综述中，我们系统地概述了因果推荐系统，帮助读者全面了解这一前景广阔的领域。我们首先介绍传统推荐系统的基本概念，以及因果推理能力缺失所带来的局限性。随后，我们讨论如何引入不同的因果推断技术来应对这些挑战，重点关注去偏、提升可解释性和提升泛化能力。此外，我们还全面分析了因果推荐系统的各种评估策略，尤其关注在无法获得兴趣因果效应时，如何利用有偏数据可靠地估计其性能。最后，我们对未来因果推荐系统研究的潜在方向提出见解。

Yaochen Zhu 电气与计算机工程系，弗吉尼亚大学，电子邮件：uqp4qh@virginia.edu Jing Ma 计算机科学系，弗吉尼亚大学，电子邮件：jm3mr@virginia.edu Jundong Li 电气与计算机工程系、计算机科学系和数据科学学院，弗吉尼亚大学，电子邮件：jl6qk@virginia.edu

1 引言

随着网络信息呈指数级增长，推荐系统凭借根据用户的个性化兴趣自动向用户推送物品[1] 的能力，在现代在线服务中发挥着日益关键的作用。传统推荐系统主要分为三类 [9]：基于协同过滤的方法 [10], 基于内容的方法 [11], 和混合方法 [12]。基于协同过滤的推荐系统利用用户过去的活动（如浏览、点击、购买等）来估计用户兴趣并预测其未来行为。另一方面，基于内容的方法通过将用户兴趣与物品内容进行匹配，来预测新的推荐结果。混合方法结合两者的优势，综合考虑协同信息和用户/物品特征信息，从而生成更准确的推荐。

尽管近年来，上文介绍的三类推荐系统都取得了显著进展，但这些方法有一个很大的局限：它们只能根据用户历史观测行为以及用户/物品特征中的相关性来估计用户兴趣并预测未来推荐，而这些相关性并不能保证具有因果含义 [13, 14]。例如，基于协同过滤的推荐系统可能会发现，某一类型的几部电视剧往往会获得一群用户的高评分，并据此得出结论，认为应该继续向这些用户推荐同一类型的电视剧。但这里有一个重要问题：高评分究竟是因为用户确实喜欢这一类型的电视剧，还是因为他们接触到的同类电视剧有限（即曝光偏差），如果有机会，他们会不会更愿意观看一些新内容？此外，基于内容的推荐系统可能会观察到，具有某些特征的微视频与更多点击相关联，并由此认为这些特征可能反映了用户兴趣的当前趋势。但用户点击这些微视频，是因为它们往往采用耸人听闻的标题作为标题党，容易欺骗用户吗？此外，如果将这些微视频的标题改为能够反映其真实内容的标题，用户还会点击它们吗？上述问题本质上都是因果问题，因为它们询问的是干预的效果（例如，如果向用户**展示**一部新电视剧，评分会如何），或反事实结果（例如，如果将微视频的标题**改为**忠实反映其内容的标题，用户是否仍会点击），而非观察数据中的单纯关联。根据 Pearl[15], ，这些问题属于因果阶梯的第 2 级和第 3 级，即干预推理和反事实推理；而仅依据关联进行推理、处于因果阶梯第 1 级的传统推荐系统无法回答这些问题。

为什么这些因果问题对推荐系统如此重要？首先，若未能妥善处理这些问题，推荐中很容易产生偏差，而且这种偏差可能长期不被察觉。如果上述基于协同过滤的推荐系统将曝光偏差误认为用户兴趣，就会不断向兴趣相似的用户推荐相似物品，从而放大这种偏差；最终，推荐将失去意外发现性，

[1] 我们广义地使用“物品”一词，泛指任何可推荐给用户的内容，例如新闻 [1], 工作 [2], 文章 [3], 音乐 [4], 电影 [5], 微视频 [6], 兴趣点 [7], 话题标签 [8], 等。

用户的在线体验也会受到严重影响。同样，对于基于内容的微视频推荐系统，如果无法区分用户因兴趣而点击的微视频和被标题党诱骗而点击的微视频，就可能过度推荐标题耸动的微视频，这对那些投入大量精力设计内容的高质量微视频上传者并不公平。此外，了解用户活动背后的原因有助于提高推荐的可解释性。以一个因果问题为例：用户购买某件物品，是因为它质量好，还是因为价格低？探究用户行为背后的因果解释，有助于服务提供商根据用户的个性化偏好改进推荐系统算法。最后，因果推断使我们能够识别并依据稳定且不变的因果关系进行推荐，同时舍弃其他不理想或易变的相关性。以餐厅推荐为例，用户可能因为方便而选择一家餐馆（例如，去附近的快餐店快速吃点东西，但他们未必喜欢这家店；这是一种不稳定的相关性），也可能因为个人兴趣而选择（例如，远道前往一家火锅店；这是一种稳定的因果关系）。如果推荐系统能够恰当地分辨出对用户过往餐馆到访产生因果影响的意图，那么即使由于用户搬到新地方等各种内部或外部原因，不同餐馆的便利程度发生变化，系统仍能很好地适应新情况。从这个角度来看，因果推荐系统的泛化能力可以得到显著提升。

本综述系统地概述了因果推荐系统研究的最新进展。其组织结构如图1所示。我们首先在第2节介绍传统推荐系统的基本概念，以及其依赖相关性推理的局限性。随后，第3节回顾机器学习和统计学中的两种重要因果推断范式，并阐述它们与推荐任务之间的联系。第4节深入探讨如何引入不同的因果推断技术，以解决传统推荐系统的局限性，重点关注去偏、提升可解释性和提高泛化能力。第5节总结因果推荐系统的一般评估策略。最后，第6节和第7节讨论因果推荐系统未来可能面临的开放问题与发展方向，并对本综述作出总结。

2 推荐系统基础

为使本综述简洁明了，我们将讨论范围限定在仅包含 I个用户和 J 个物品的简单推荐系统中。推荐系统的主要数据，即用户的历史行为，由用户-物品评分矩阵 $\mathbf{R} \in \mathbb{R}^{I\times J}$表示，其中非零元素 r_{ij}表示用户 i对物品 j的评分，而零元素 r_{ik}^0 表示该评分缺失 [2]。为使推荐系统相关讨论与因果推断相兼容，我们从概率视角看待 $\mathbf{R}$ [17], , 其中假定 r_{ij} 是该随机变量的实现值

[2] 我们用“评分”指任何可用数值表示的用户-物品交互。这既包括点赞/点踩等显式反馈，也包括浏览和点击等隐式反馈。当 r_{ij} 表示隐式反馈时，$\mathbf{R}$ 中的缺失元素 r_{ik}^0 可在训练阶段用作弱负反馈 [16]。这可能会使因果问题更加复杂。因此，除非另有说明，为简化讨论，我们假设推荐系统是在观测评分上进行训练的。

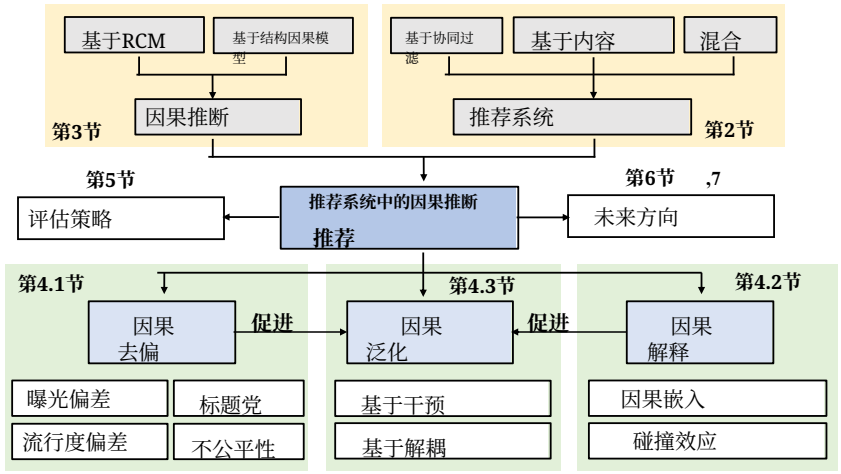


图1：本综述的结构概览及各章节之间的联系。

随机变量 R，它取决于用户 i 和物品 j[3]。除 $\mathbf{R}$ 外，推荐系统通常还可以使用侧信息，例如用户特征 $\mathbf{f}_i^u \in \mathbb{R}^{K_F^u}$，如用户的年龄、性别、位置等，或物品特征 $\mathbf{f}_j^v \in \mathbb{R}^{K_F^v}$，如物品的内容和文本描述。$K_F^u$ 和 K_F^v 分别是用户特征和物品特征的维度。**推荐系统的主要目的**是根据 $\mathbf{R}$ 中的观测评分 r_{ij}，以及可用的用户和物品侧信息（如 $\mathbf{f}_i^u$ 和 $\mathbf{f}_j^v$），预测用户对其尚未交互物品的评分（即 $\mathbf{R}$ 中的缺失值 r_{ik}^0），从而根据用户的个性化兴趣恰当地推荐新的相关物品。

2.1 协同过滤

基于协同过滤的推荐系统通过利用用户过去的评分来推荐新物品。它们通常认为，评分 r_{ij} 由表示用户兴趣的用户潜变量 $\mathbf{u}_i \in \mathbb{R}^K$ 和编码物品属性（即物品潜在语义信息）的物品潜变量 $\mathbf{v}_j \in \mathbb{R}^K$ 生成，其中 K 为潜在空间的维度。下面列出三种广泛使用的基于协同过滤的推荐系统，它们将在本综述中频繁用作示例：

- **矩阵分解 (MF)** [18]。MF 模型 r_{ij} 通过 $\mathbf{u}_i$ 和 $\mathbf{v}_j$ 的内积来建模，其中 $r_{ij} \sim \mathrm{N}(\mathbf{u}_i^T \cdot \mathbf{v}_j, \sigma_{ij}^2)$，且 σ_{ij}^2 为预定方差[4]。

[3] 不过，如果不会引起混淆，我们不会区分随机变量及其具体取值。为简单起见，除非另有说明，我们假设 R 服从高斯分布。[4] 对于未明确将 r_{ij} 视为随机变量的研究，我们假设其服从方差为零的高斯分布。此时，生成过程变为 $r_{ij} = \mathbf{u}_i^T \cdot \mathbf{v}_j$。

- **深度矩阵分解 (DMF) [19]**。DMF 通过对$\mathbf{u}_i$和 $\mathbf{v}_j$应用深度神经网络 (DNNs) [20],（即 f^u_{nn}, f^v_{nn}：$\mathbb{R}^K \to \mathbb{R}^{K'}$）扩展了 MF，其中假设评分的生成方式为 $r_{ij} \sim \mathrm{N}(f^u_{nn}(\mathbf{u}_i)^T \cdot f^v_{nn}(\mathbf{v}_j), \sigma^2_{ij})$。
- **基于自编码器（AE）的推荐系统 [21, 22]** 将用户 i对所有 J 物品的评分建模为$\mathbf{r}_i \sim \mathrm{N}(f^u_{nn}(\mathbf{u}_i), \sigma^2_i \cdot \mathbf{I}_K)$，其中 f^u_{nn}：$\mathbb{R}^K \to \mathbb{R}^J$是一个深度神经网络，所有物品的物品潜变量$\mathbf{v}_j$ 隐含在解码器 [23]最后一层的权重中。

在训练阶段，模型通过拟合**观测评分**r_{ij}（例如，通过最大似然估计；本质上，这是根据观察数据 [24]估计条件分布 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j)$），学习潜变量$\mathbf{u}_i$、$\mathbf{v}_j$ 及相关函数 f_{nn}。之后，我们可以使用它们为此前未交互过的物品 k预测新的评分，例如，MF 的 $\hat{r}^{\mathrm{MF}}_{ik} = \mathbf{u}_i^T \cdot \mathbf{v}_k$，DMF 的 $\hat{r}^{\mathrm{DMF}}_{ik} = f^u_{nn}(\mathbf{u}_i)^T \cdot f^v_{nn}(\mathbf{v}_k)$，以及基于自编码器的推荐系统的 $\hat{r}^{\mathrm{AE}}_{ik} = f^u_{nn}(\mathbf{u}_i)_k$；其中，与用户兴趣最匹配的靠前物品可被选作推荐结果。

传统的基于协同过滤的推荐系统依据相关性进行推理。理想情况下，我们希望$\mathbf{u}_i$、$\mathbf{v}_j$ 和 f_{nn} 能够捕捉用户兴趣和物品属性对评分的因果影响，即当物品j 呈现在用户 i [24]面前时，用户会给出怎样的评分。然而，由于收集到的评分数据是**观察性的**而非实验性的，$\mathbf{u}_i$、$\mathbf{v}_j$和f 实际学到的是用户过去行为中的共现模式，而这些模式并不能保证具有因果含义。因此，模型可能会捕捉到伪相关和偏差，并在未来推荐[25]中将其放大。此外，学到的用户潜变量$\mathbf{u}_i$ 通常会纠缠在因果上决定用户兴趣的不同因素。从这个角度来看，这些方法的可解释性和泛化能力无法得到保证。

2.2 基于内容的推荐系统

个性化基于内容的推荐系统（基于内容的推荐系统）根据用户交互过的物品的特征来估计用户兴趣。这些模型通常将用户兴趣编码为用户潜变量$\mathbf{u}_i \in \mathbb{R}^K$，并假设评分是通过匹配用户兴趣与物品内容生成的，即 $r_{ij} \sim \mathrm{N}(f(\mathbf{u}_i, \mathbf{f}^v_j), \sigma_{ij})$，其中 f是匹配函数。个性化基于内容的推荐系统的训练遵循与协同过滤类似的步骤：通过拟合**观测评分**来学习$\mathbf{u}_i$和 f（本质上是根据观测数据估计条件分布 $p(r_{ij}|\mathbf{u}_i, \mathbf{f}^v_j)$），然后可以通过 $\hat{r}_{ik} = f(\mathbf{u}_i, \mathbf{f}^v_k)$预测新的评分。构建基于内容的推荐系统的关键步骤是创建能够最佳反映用户兴趣的物品特征$\mathbf{f}^v_j$，这在很大程度上取决于待推荐的物品。例如，对于微视频，会综合考虑视觉、音频和文本模态，以便充分捕捉用户对微视频不同方面的兴趣 [26]。

传统的基于内容的推荐系统无法对用户兴趣 $\mathbf{u}_i$ 和物品内容 $\mathbf{f}_j^v$ 对用户评分的因果影响进行建模 。 这是因为，除用户对物品内容的兴趣之外的因素，例如用户被标题党（如微视频耸人听闻的标题）欺骗 [27], 等，会导致物品内容 $\mathbf{f}_j^v$ 与用户评分 r_{ij} 在观测数据集中产生不良关联，其中的偏差可能被用户潜变量 $\mathbf{u}_i$ 和匹配函数 f 捕获，并延续到未来推荐中。

2.3 混合推荐

混合推荐系统将用户/物品侧信息与协同过滤相结合，以提升推荐效果。一种常用的混合策略是：在现有协同过滤方法中，为用户和物品潜变量 u_i 和 $\mathrm{v}j$ 增加用户 / 物品侧信息 f_i^v 和 f_j^v ，在矩阵分解、深度矩阵分解和基于自编码器的推荐系统中，分别用 $\mathrm{u}_i^+ = [\mathrm{u}_i | \mathrm{f}_i^u]$ 和 $\mathrm{v}_j^+ = [\mathrm{v}_j | \mathrm{f}_j^v]$ 替换 u_i 和 $\mathrm{v}j$，其中 $[\cdot||\cdot]$ 表示向量拼接 [28, 29]。相应地调整编码协同信息的 u_i 和 $\mathrm{v}j$ 的维度，使模型中的 u_i^+ 和 v_j^+ 兼容。另一类重要的混合推荐系统是因子分解机（FM） [30] 及其扩展模型（如 [31, 32],），可将其视为学习双线性函数 f_{fm}，其中评分由 $r_{ij} \sim \mathrm{N}(f_{fm}(\mathrm{u}_i, \mathrm{v}j, \mathrm{f}_i^u, \mathrm{f}_j^v), \sigma_{ij}^2)$ 生成。

简单的混合策略无法突破协同过滤和基于内容的推荐系统在相关性推理方面的局限，因为混合的目标仍然是提升模型对观测到的用户历史行为的拟合效果（即根据数据估计条件分布 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}j, \mathbf{f}_i^u, \mathbf{f}_j^v)$），而导致观测到的用户行为的因果原因并未纳入考量。不过，引入额外的用户／物品侧信息这一思路，对于构建因果推荐系统十分重要。其原因在于，结合人类专家的领域知识，侧信息有助于在感兴趣的变量之间建立更全面的因果关系，例如用户兴趣、物品属性、历史评分以及其他可能导致伪相关和偏差的重要协变量；这通常是进行推荐因果推理的关键步骤。

3 因果推荐系统：预备知识

在上一节中，我们讨论了传统推荐系统的推荐策略，以及由于基于观察到的用户行为进行相关性推理而产生的局限性

。本节将介绍两种因果推断框架，即 Rubin 的潜在结果框架（也称为 Rubin 因果模型，RCM）[33] 和 Pearl 的结构因果模型（SCM） [34],在推荐系统中的应用，旨在为推荐中的相关性与因果关系推理提供理论上严谨的依据。我们将说明，RCM 和 SCM 都是构建具备因果推理能力的推荐系统（即因果推荐系统）的强大框架，但它们最适用于不同的任务和问题。本节的讨论为第 4 节对最先进的因果推荐系统模型进行更深入的探讨奠定基础。

3.1 Rubin 潜在结果框架

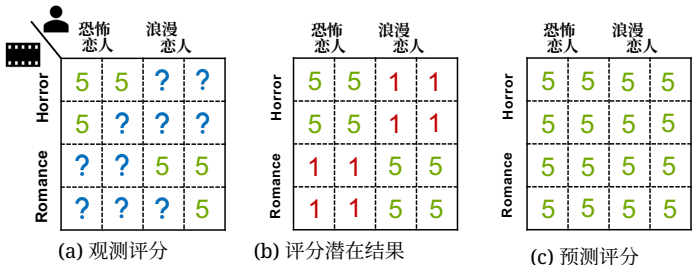
3.1.1 推荐系统中应用的动机

为了理解传统推荐系统的相关性推理本质，我们注意到，直接基于观测评分拟合模型，只能回答这样一个问题：**“如果我们观察到某物品已向用户曝光**，评分会是多少？”由于收集的数据集中的物品曝光并非随机分配 5，“该物品已向用户曝光”这一谓词本身包含了关于用户-物品对的额外信息（例如，该物品可能比其他未曝光的物品更受欢迎），这些信息无法推广到**任意**用户-物品对的评分预测。因此，推荐系统所提出的本质上是一个干预问题（因而也是一个因果推断问题），即，**如果让某物品向用户曝光**，评分会是多少？为了解决这一问题，基于RCM的推荐系统从临床试验中汲取灵感：将向用户曝光某物品类比为对患者施加某种处理，而用户评分则类似于患者接受处理后的结果 [39, 40]。相应地，基于RCM的推荐系统旨在估计处理（向用户曝光某物品）对结果（用户评分）的因果效应，即便处理分配与结果观测之间可能存在相关性 [39]。

3.1.2 定义与目标

我们首先介绍必要的符号和定义，以便将 RCM 与推荐系统联系起来。我们将用户-物品对 $(i,\ j)$ 视为分析单元，它可以接受“向用户 i 曝光物品 j”这一处理；将所有用户-物品对的总体潜在结果 $\mathrm{PO} = \{(i,\ j),\ 1 \le i,\ j \le I,\ J\}$ [41] 视为总体。我们首先使用二元标量 a_{ij} 表示用户 i对物品 j 的曝光状态，即分配的处理。我们进一步将**评分潜在结果** $r_{ij}(a_{ij} = 1)$定义为：若物品向用户曝光，则用户 i对物品 j的评分；将 $r_{ij}(a_{ij} = 0)$定义为物品未曝光时的评分 [42]。对于用户 i，如果她给物品 j评过分，我们就会观测到 $r_{ij}(a_{ij} = 1) = r_{ij}$。否则，我们观测到基线潜在结果 $r_{ij}(a_{ij} = 0) = 0$，而在以消除偏差为导向的

[5] 这可能归因于多种原因，例如用户自主搜索 [35], 先前模型的推荐 [36], 物品的展示位置 [37], 物品流行度 [38], 等。通常，基于 RCM 的因果推荐系统并不关注导致曝光偏差的具体原因。



(a) 观测评分 (b) 评分潜在结果 (c) 预测评分

图 2：推荐系统中的曝光偏差经典示例 [43]。该示例由两位恐怖片爱好者和两位爱情片爱好者组成：前两位总是给恐怖电影打五分，同时讨厌爱情电影；后两位则恰恰相反。(a) 显示观测评分 r_{ij}。(b) 显示评分潜在结果 $r_{ij}(a_{ij}=1)$。(c) 显示了一个推荐系统的评分预测，该系统通过最大化 (a) 中观测评分的似然进行预测，但这个推荐系统表现很差，因为它将所有评分都预测为五分。

因果推荐系统研究 [39, 43][6]中通常会忽略这一结果。与临床试验类似，我们可以将处理组 $\mathrm{T}=\{(i,\ j):\ a_{ij}=1\}$定义为用户 i 曝光于物品 j的用户-物品对集合，并相应地将非处理组 $\mathrm{NT}=\{(i,\ k):\ a_{ik}=0\}$定义为另一组。**在 RCM 框架下，推荐系统的目的**可以表述为：利用处理组 T 中各单元的观测评分，无偏地估计总体 PO 中各单元的评分潜在结果，尽管所收集数据中的物品曝光 a_{ij} 与用户评分 r_{ij} 之间可能存在相关性。

3.1.3 传统推荐系统的因果分析

传统推荐系统会直接训练一个最符合处理组 T 中评分的评分预测模型（例如，通过第2节介绍的最大似然法），以估计 NT 中用户-物品对的未观测评分潜在结果 $r_{ij}(a_{ij}=1)$ [46],，而忽略了曝光偏差可能导致 T 与 NT 中 $r_{ij}(a_{ij}=1)$ 的分布存在系统性差异这一事实。例如，用户往往会给现实中自己喜欢的物品评分，这可能导致物品曝光 a_{ij} 与评分潜在结果 $r_{ij}(a_{ij}=1)$ 之间产生如下伪相关：

$$p(r_{ij}(a_{ij}=1)\text{ is high}|a_{ij}=1)>p(r_{ij}(a_{ij}=1)\text{ is high}|a_{ij}=0), \tag{1}$$

也就是说，给物品 j 打过分的用户，其评分可能系统性地高于尚未给该物品评分的用户。在这种情况下，传统推荐系统可能会倾向于高估 NT 中各个单元的评分（直观示例见图 2）。从理论上讲，RCM 将收集的数据集中的曝光偏差归因于**无混杂假设** [33] 遭到违反，该假设定义如下：

$$r_{ij}(a_{ij}=1)\perp a_{ij}. \tag{2}$$

[6] 在旨在估计推荐如何改变用户行为 [44] 的推荐系统增益评估中，$r_{ij}(a_{ij}=0)$ 可用于表示用户 i 通过自主搜索 [45] 对物品 j 的评分。

其依据是，若式（2）成立，则用户 i对物品 j的曝光（即 a_{ij}）与评分潜在结果 r_{ij}（$a_{ij}=1$）相互独立，这意味着r_{ij}（$a_{ij}=1$）在 T 和 NT 中服从相同的分布。因此，物品的曝光是随机的，式（1）所示的曝光偏差便不会存在 [42]。

3.1.4 基于 RCM 框架的潜在结果估计

基于 RCM 的框架中，一种解决曝光偏差的经典方法是找到用户和物品协变量 C，使得在由$C=\mathbf{c}$所指定的每个数据层中，用户对物品的曝光都是随机的 [33]。协变量C 的这一属性可表述为如下条件无混杂假设：

$$r_{ij}(a_{ij}=1) \perp a_{ij} \mid \mathbf{c}. \tag{3}$$

C 在文献中有时被不严谨地称为**混杂因素**，但我们将在下一小节给出其正式定义。如果式（3）成立，那么在由 $C=\mathbf{c}$指定的每个数据层中，物品曝光与评分潜在结果相互独立，曝光偏差完全源于处理组 T 与总体 PO 中协变量 $C=\mathbf{c}$ 的分布差异，即 $p(\mathbf{c}|a_{ij}=1)$ 和 $p(\mathbf{c})$[7] 。因此，我们可以根据协变量 C 对 T 中的观测评分重新加权，以消除偏差，使其可视为伪随机样本。这便引出了逆倾向加权（IPW），它从数据角度消除了曝光偏差 [39]。此外，我们还可以在推荐系统模型中调整 C 的影响，从模型角度处理曝光偏差 [42]。这两种方法将在第4.1.1节讨论。

●！注意：大多数基于RCM的推荐系统都需要额外的假设

除了无混杂性之外，大多数基于RCM的推荐系统还需要两个额外假设，才能识别物品曝光对评分的因果效应：（1）**稳定单元处理值假设（SUTVA）**，该假设指出，向一位用户曝光的物品不会影响另一位用户的评分。（2）**正值性假设**，该假设指出，每位用户都有正概率接触到每件物品 [33]。对于本综述介绍的基于 RCM 的因果推荐系统，这两个假设都被默认接受。

[7]！我们可以从图 2 中直观地理解这一说法。假设协变量 C表示二维特征（用户类型、电影类型）。给定 $C=\mathrm{c}$，$r_{ij}(a_{ij}=1) \perp a_{ij} \mid \mathrm{c}$ 在式（3）中所述的条件成立，因为在由 $C=\mathrm{c}$ 指定的每个数据层（即图 2-(b) 中的四个 2×2区块）中，$r_{ij}(a_{ij}=1)$ 是常数。图 2-(a) 显示，对于处理组 T，当 $\mathrm{c}\in \mathrm{C}_1=\{$(恐怖片爱好者, 恐怖片), (爱情片爱好者, 爱情片) $\}$ 时，$p(\mathrm{c}|a_{ij}=1)=1/2$；而当 $\mathrm{c}\in \mathrm{C}_2=\{$(恐怖片爱好者, 爱情片), (爱情片爱好者, 恐怖片) $\}$ 时，$p(\mathrm{c}|a_{ij}=1)=0$。相比之下，对于总体 PO，当 $\mathrm{c}\in \mathrm{C}_1\cup \mathrm{C}_2$ 时，$p(\mathrm{c})=1/4$。因此，在处理组 T 中，协变量属于 C_1 的用户-物品对占比过高，而协变量属于 C_2 的用户-物品对占比过低。不过，我们也注意到，这种情况过于极端，RCM 无法处理，因为对于 $C\in \mathrm{C}_2$，$p(\mathrm{c}|a_{ij}=1)=0$，这违反了上述注意框中提到的正值性假设。

3.2 Pearl结构因果模型

3.2.1 推荐系统中的应用动机

与使用评分潜在结果 进行因果推理、并将观测到的用户行为中的偏差归因于非随机化物品曝光的RCM不同，Pearl的结构因果模型（SCM）深入探究生成观测结果 （及偏差）的因果机制，并用因果图$G = (\mathrm{N}, \mathrm{E})$表示该机制。节点N指定感兴趣的变量；在推荐系统的上下文中，这些变量可以是用户兴趣 U、物品属性 V、观测评分 R以及其他重要协变量 C，例如物品流行度、用户特征等[8]。节点之间的有向边E表示由研究人员的领域知识确定的因果关系。每个节点 $X \in \mathrm{N}$都关联一个结构方程$p_G(X|Pa(X))$9，该方程描述父节点 $Pa(X)$如何因果影响 X（即，将 $Pa(X)$中的节点设为特定值时， X 的响应）

尽管人们通常认为 RCM 和结构因果模型在本质上等价[34], ，但二者各有独特优势。与 RCM 相比，结构因果模型的主要优势在于，因果图提供了一种直观而直接的方式，用于编码和传达研究人员的领域知识和实质性假设；这对基于RCM的推荐系统也有益处 [42]。此外，结构因果模型更加灵活，因为它能够表示并推理因果图中任意节点子集之间的因果效应（例如，两个原因之间 U， V 以及一个结果之间 R），也能表示并推理特定路径上的因果效应（例如，$U \to R$和 $U_c \to R$）。因此，结构因果模型广泛适用于推荐系统中的多种问题（不限于曝光偏差），例如标题党偏差、不公平性、纠缠、领域自适应等 [14]。

! 注意：基于结构因果模型的因果推荐系统有两点需要注意。

基于结构因果模型的因果推荐系统有两个需要注意之处。(1) 推荐系统的因果图通常涉及用户和物品的**潜变量**U, V，这些变量编码了用户兴趣和物品属性。大多数研究在估计结构方程的同时推断这些变量，并在分析因果关系时将其视为已观测变量。另一种理解方式是：在因果图中用用户和物品的标识符（即 i 和 j）表示它们，并将嵌入过程纳入结构方程 [47]。(2) 一般而言，因果图应描述**观测数据**的生成机制，因为这有助于我们区分不变的因果关系与不良相关性。例如，我们可以认为物品流行度 C 应由物品属性 V决定，即 $V \to C$。然而，为了描述观测评分的生成过程，通常会假设因果关系 $C \to V$，即物品流行度会因果性地影响每件物品的曝光概率 [48]。

[8] 为简洁起见，因果图中省略了各节点的下标 i、 j。[9] 我们也省略了各节点相互独立的外生变量，并将它们的随机性概括到带有概率分布 [14] 的结构方程中。下标 G 用于区分结构方程与可从 G 推断出的其他条件关系。

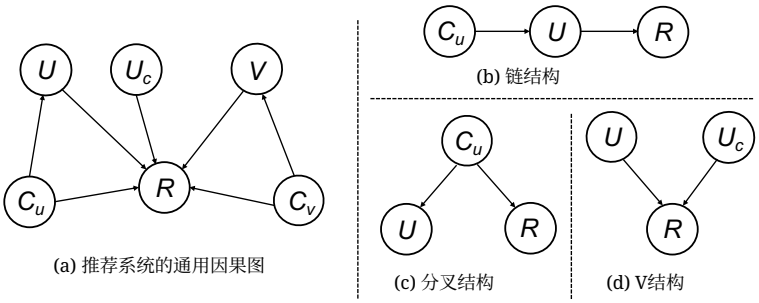


图 3：(a)：推荐系统的通用因果图，展示了用户兴趣 U、用户对流行趋势的从众 U_c 和物品属性 V 对观测评分 R 的因果影响。具体而言，因果路径 $U \to R$ 和 $V \to R$ 受到 C_u 和 C_v 的混杂，二者分别代表用户特征和物品流行度。(b)(c)(d)：从 (a) 中识别出的三种原子结构。

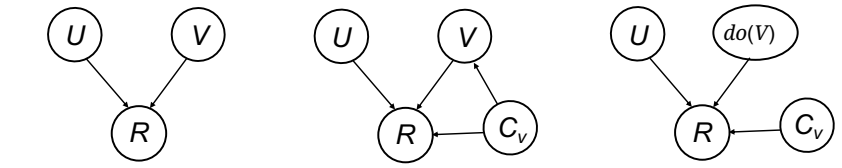
3.2.2 因果图的原子结构

因果图的结构体现了研究人员对观察数据因果生成过程的领域知识，这是区分稳定的因果关系与感兴趣变量之间其他不良相关性的关键。这里，我们以图 3-(a) 中适用于推荐系统的通用因果图为例，说明三种基本图结构：

- **链结构，**例如，$C_u \to U \to R$。在链结构中，假设后继节点受到祖先节点的因果影响。在此例中，U 是R的直接原因，而 C_u 则通过作为中介变量的 U 间接影响 R。
- **分叉结构，**例如，$U \leftarrow C_u \to R$。在分叉结构中，C_u 被称为**混杂因素**，因为它会对两个子节点 U 和 R产生因果影响。从概率视角来看，除非以混杂因素 C_u [49]为条件，否则 U 和 R**并非**独立。这就引出了分叉结构中棘手的一点，即**混杂效应** [34], ：未观测到的 C_u 可能导致 U 与 R之间出现伪相关。

- **V结构**，例如，$U \to R \leftarrow U_c$。在V结构中，R 被称为**碰撞点**，因为它受到两个父节点（即 U 和 U_c）的因果影响。V结构的一个有趣特性是碰撞效应 [34], ：观察到R 会使 U 和 U_c产生依赖关系，即使它们在边际上相互独立。

混杂因素会导致观测数据集中变量之间出现非因果依赖。这可能会给传统推荐系统带来偏差，因为混杂效应会被误认为是因果关系。混杂偏差是推荐系统中普遍存在的问题 [24], ，将在以下小节中进一步分析。此外，抽象化的V结构通常会导致原因纠缠，从而损害推荐系统的可解释性。例如，用户购买某件物品可能是出于兴趣，即 U；也可能是出于对流行趋势的从众性，即 U_c。由于大多数推荐系统会将二者概括为一个用户潜变量 U，V结构 $U \to R \leftarrow U_c$ 便被抽象掉了，因此无法区分促成购买的这两种原因。



(a) 非因果推荐系统所假设的结构因果模型 (b) 存在混杂的真实结构因果模型 (c) 干预下的结构因果模型

图 4：(a)：基于非因果协同过滤的推荐系统所假设的结构因果模型。(b)：描述真实数据生成过程的存在混杂的结构因果模型。(c)：在干预 $do(V)$ 下的结构因果模型。

3.2.3 传统推荐系统的因果分析

本节将探讨传统协同过滤推荐系统对混杂偏差的易感性。如第2.1节所述，这些模型的共同点是根据观测评分估计条件分布 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j)$，并用其预测新的评分。为了将 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j)$表示为用户兴趣$\mathbf{u}_i$和物品属性$\mathbf{v}_j$对评分$r_{ij}$的因果影响（在协同过滤的语境中，指向用户 i [24]展示的任意物品 j 的评分），这些模型默认假设图4-(a)中的因果图 G_1，即因果路径 $U \to R$ 和 $V \to R$[10]上不存在未观测混杂因素。

然而，在现实中，$U \to R$ [25, 51] 和 $V \to R$ [52, 53] 都可能受到混杂因素的影响，这些混杂效应可能被 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j)$隐式捕获，从而使未来推荐产生偏差。为揭示这种偏差，我们考虑因果路径 $V \to R$ 受到 C_v（例如物品流行度）混杂影响的情形。我们假设因果路径 $C_v \to V$ 表示 C_v 对物品 V [48]曝光概率的因果影响。在这种情况下，观测评分是根据图4-(b)中的因果图 G_2 生成的。利用全概率公式，从混杂数据中估计的条件分布 $p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j)$可计算如下：

$$p(r_{ij}|\mathbf{u}_i, \mathbf{v}_j) = \sum_{\mathbf{c}} p(\mathbf{c}|\mathbf{v}_j) \cdot p_{G_2}(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, \mathbf{c}) = \mathbb{E}_{p(C_v|\mathbf{v}_j)}[p_{G_2}(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, C_v)]. \tag{4}$$

式（4）的问题在于，$p(\mathbf{c}|\mathbf{v}_j)$ 项并非因果性的（因为我们在因果图中只有一条边 $C_v \to V$，而没有 $V \to C_v$）。事实上，$p(\mathbf{c}|\mathbf{v}_j)$ 表示溯因推理，因为它根据效应 $\mathbf{c}$（例如，物品流行度）推断原因 $\mathbf{v}_j$（即物品 j 曝光给用户 i），并利用推断出的 $\mathbf{c}$ 来辅助评分 r_{ij}的预测。然而，这种推理无法推广到任意物品 $\mathbf{v}_j$的评分预测，也就是说，无法推广到向用户**进行曝光** 的物品。换言之，未受控制的混杂因素 C_v 留下了一条连接 V 与 R的**后门路径**（即非因果路径），使得数据中存在 R 对 V 的非因果依赖；传统推荐系统可以捕捉这种依赖，并使未来推荐产生偏差。[11]

[10] 这对应于物品曝光经过随机化的情形（参见第3.1.3节中的讨论），因为用户-物品对(U, V)并非由与 R [50]相关的其他因素决定。[11] 本节与第3.1.1节之间的相似性揭示了基于RCM和基于结构因果模型的因果推荐系统之间的联系，其中的论断是：当物品曝光未经过随机化时，

3.2.4 基于结构因果模型的因果推理

要计算 u_i和 v_j对 r_{ij}的因果效应，我们应对 U 和 V实施干预。这意味着，无论它们在因果图中的父节点（包括混杂因素 C_v）取值如何，我们都将 U, V 设为 u_i、v_j（因为这些节点决定了观察数据中物品 j 向用户 i 的曝光情况）。结构因果模型（SCM）用 do 算子将干预表示为 $p(r_{ij}|do(\mathrm{u}_i, \mathrm{v}_j))$，以区别于条件分布 $p(r_{ij}|\mathrm{u}_i, \mathrm{v}_j)$；后者依据观察数据中的相关性进行推断。再次考虑图 4-(b) 所示的因果图 G_2。对节点 V的干预可以通过删除节点V的所有入边，并将结构方程 $p_{G_2}(V|C_v)$确定性地设为 $V = \mathrm{v}_j$来实现，而其他结构方程保持不变（图 4-(c)）。如果能够确定并测量每个物品的混杂因素 C_v，则可通过后门调整 [34]，直接根据混杂数据计算干预分布 $p(r_{ij}|do(\mathrm{u}_i, \mathrm{v}_j))$：

$$p(r_{ij}|do(\mathbf{u}_i, \mathbf{v}_j)) = \sum_{\mathbf{c}} p_{G_2}(\mathbf{c}) \cdot p_{G_2}(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, \mathbf{c}) = \mathbb{E}_{p_{G_2}(C_v)}[p_{G_2}(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, C_v)], \tag{5}$$

与公式（4）相比，该方法阻断了从 $\mathbf{c}$推断 $\mathbf{v}_j$ 的溯因推断，因此能够正确识别$\mathbf{u}_i$、$\mathbf{v}_j$对 r_{ij} 的因果影响。

后门调整要求预先确定并测量所有混杂因素，但还有其他基于结构因果模型的因果推断方法，可以在混杂因素未知的情况下估计因果效应，详情请参阅 [54, 55]。此外，因果图使我们能够基于其中编码的因果知识开展其他类型的因果推理，例如针对非混杂因素引起的偏差（如标题党偏差和不公平性）进行去偏、因果解耦以及因果泛化 [56]。下一节将对此进行深入讨论。

4 因果推荐系统：最新进展

基于前文讨论的推荐系统和因果推断基础知识，我们现在可以介绍因果推荐系统的最新进展。具体而言，我们聚焦于三个重要主题，即偏差缓解、可解释性提升和泛化能力提升，以及它们之间的相互联系；借助这些方法，可以妥善解决传统推荐系统因相关性推理而产生的各种局限。

4.1 推荐中的因果去偏

传统推荐系统的相关性推理可能会承袭观察到的用户行为中的多种偏差，并在未来推荐中放大这些偏差 [46]。

“观察到某个物品曾向用户曝光本身包含了有关用户-物品对的额外信息”，在数学上可转化为通过 p 从$\mathbf{v}_j$ 溯因推断$\mathbf{c}$（$\mathbf{c}|\mathbf{v}_j$）。

这些偏差可能导致各种后果，例如离线评估与在线指标之间的差异、多样性降低、推荐质量下降、冒犯性推荐等。因果推断能够区分稳定的因果关系与伪相关，以及可能对推荐产生负面影响的偏差，从而提升推荐的鲁棒性。

4.1.1 曝光偏差

推荐系统中的曝光偏差，广义而言，是指由非随机物品曝光导致的观测评分偏差。从 RCM 的角度来看，曝光偏差可定义为用户根据对物品评分的预期（即评分潜在结果）而更倾向于接触某些物品所产生的偏差 [43]。曝光偏差的产生有多种原因，例如用户自主搜索或先前的推荐系统所做的推荐 [36], ，这会降低不太可能曝光给用户的物品的权重。由于物品曝光可与临床试验中的处理自然地进行比较，因此我们借助 RCM 框架讨论去偏策略。

逆倾向加权（IPW）。基于逆倾向加权的因果推荐系统旨在对处理组中用户-物品对的有偏观测评分进行重新加权r_{ij}，即 T $=\{(i,\ j):\ a_{ij}=1\}$，从而构造伪随机样本 [57]，用于无偏训练推荐系统模型，以预测总体潜在结果r_{ij}（评分潜在结果）$a_{ij}=1$以及总体潜在结果 $=\{(i,\ j),\ 1\le i,\ j\le I,\ J\}$。直观而言，我们可以将 T 中各单位的权重 r_{ij}设为物品 j对用户 i的曝光概率的倒数，从而提高曝光不足物品的权重，反之亦然。如果每个用户-物品对都有满足式（3）中条件无混杂假设的协变量$\mathbf{c}$，则可以通过$\mathbf{c}$ 对曝光概率e_{ij} 进行无偏估计，方法如下

$$e_{ij}=p(a_{ij}=1|\mathbf{c})=\mathbb{E}[a_{ij}|\mathbf{c}], \tag{6}$$

在因果推断文献中，这被正式称为**倾向得分** [58]。

> **背景：倾向得分的平衡性质。**

倾向得分具有一种称为平衡性的性质 [33, 59],，这是证明基于逆倾向加权的推荐系统无偏性的关键：

$$\begin{aligned}
&\mathbb{E}\left[\frac{r_{ij}}{e_{ij}}\middle|a_{ij}=1\right]=\mathbb{E}\left[\frac{r_{ij}\cdot a_{ij}}{e_{ij}}\right]=\mathbb{E}\left[\mathbb{E}\left[\frac{r_{ij}\cdot a_{ij}}{e_{ij}}\middle|\mathbf{c}\right]\right]\\
&=\mathbb{E}\left[\mathbb{E}\left[\frac{r_{ij}(a_{ij}=1)\cdot a_{ij}}{e_{ij}}\middle|\mathbf{c}\right]\right]\overset{(a)}{=}\mathbb{E}\left[\frac{\mathbb{E}[r_{ij}(a_{ij}=1)\mid\mathbf{c}]\cdot\mathbb{E}[a_{ij}\mid\mathbf{c}]}{e_{ij}}\right]\\
&=\mathbb{E}\left[\frac{\mathbb{E}[r_{ij}(a_{ij}=1)\mid\mathbf{c}]\cdot e_{ij}}{e_{ij}}\right]=\mathbb{E}[r_{ij}(a_{ij}=1)],
\end{aligned} \tag{7}$$

其中，步骤（a）遵循式（3）中的条件无混杂假设。

我们首先讨论基于逆倾向加权的推荐系统的实现及其无偏性，前提是能够获取满足式（3）的用户和物品协变量$\mathbf{c}$，并且能够按照式（6）精确计算倾向得分e_{ij}。我们将旨在预测评分潜在结果$r_{ij}(a_{ij}=1)$的推荐系统的评分预测器记为$\hat{r}_{ij}$，并假设$r_{ij}(a_{ij}=1)$服从单位方差高斯分布。理想情况下，我们希望$\hat{r}_{ij}$能够最大化总体中所有用户-物品对的评分潜在结果$r_{ij}(a_{ij}=1)$的对数似然；这等价于最小化$\hat{r}_{ij}$与$r_{ij}(a_{ij}=1)$之间的均方误差损失，具体如下：

$$\mathcal{L}^{\text{True}} = \frac{1}{I \times J} \sum_{i,j} (\hat{r}_{ij} - r_{ij}(a_{ij}=1))^2. \tag{8}$$

然而，由于非处理组 NT 中用户-物品对的$r_{ij}(a_{ij}=1)$不可观测，因此无法计算L^{True}。所以，传统推荐系统只最大化处理组 T 中用户-物品对观测评分的对数似然，从而得到如下经验均方误差损失：

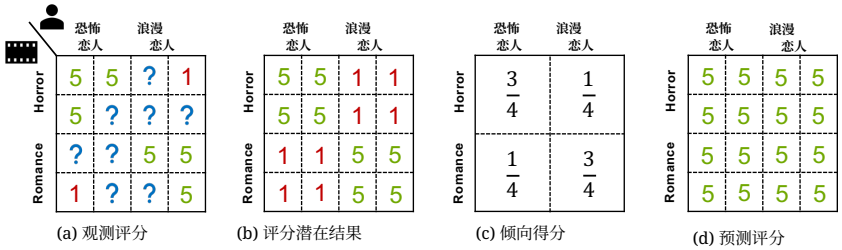
$$\mathcal{L}^{\text{Obs}} = \frac{1}{|(i,j) : a_{ij}=1|} \sum_{(i,j):a_{ij}=1} (\hat{r}_{ij} - r_{ij})^2, \tag{9}$$

其中，$|(i,\ j)\colon\ a_{ij}=1|$是观测评分的数量。当存在曝光偏差时，物品曝光$a_{ij}$取决于评分潜在结果$r_{ij}(a_{ij}=1)$。因此，$\mathrm{L}^{\text{Obs}}$是$\mathrm{L}^{\text{True}}$的有偏估计量，因为处理组 T 中用户-物品对的观测评分是总体 PO 评分潜在结果中的有偏样本（示例见图 5-(a) 和图 5-(b)）。为消除偏差，基于逆倾向加权的因果推荐系统使用倾向得分的倒数对 T 中的观测评分r_{ij}重新加权，即$\frac{1}{e_{ij}}$，由此得到如下新的训练目标：

$$\mathcal{L}^{\text{IPW}} = \frac{1}{I \times J} \sum_{(i,j):a_{ij}=1} \frac{1}{e_{ij}} \cdot (\hat{r}_{ij} - r_{ij})^2. \tag{10}$$

利用式（7）中倾向得分的平衡性质，可以证明L^{IPW}对于L^{True}的无偏性：在式（7）左侧将$(\hat{r}_{ij} - r_{ij})^2$替换为$r_{ij}$，并将评分预测器$\hat{r}_{ij}$视为常数 [39]。我们还在图 5 中提供了一个玩具示例，以直观展示e_{ij}的计算、L^{Obs}的偏差以及L^{IPW}的无偏性。式（10）中定义的基于逆倾向加权的推荐系统的目标具有模型无关性。因此，它适用于我们在第2节中介绍的所有传统推荐系统。例如，对于基于矩阵分解的推荐系统，我们可以代入$\hat{r}_{ij}^{\text{MF}} = \mathbf{u}_i^T \cdot \mathbf{v}_j$；对于基于深度矩阵分解的推荐系统，则代入$\hat{r}_{ij}^{\text{DMF}} = f_{nn}^u(\mathbf{u}_i)^T \cdot f_{nn}^v(\mathbf{v}_j)$，等等。

实际上，由于式 (3) 中的条件无混杂假设无法检验，通常无法根据满足式 (3) 的用户/物品协变量计算出e_{ij}的精确值。不过，我们仍然可以计算近似倾向评分$\tilde{e}_{ij}$，并用$1/\tilde{e}_{ij}$对观测评分进行重新加权，但无法保证重新加权后式 (10) 的无偏性。下面介绍两种近似估计策略。如果可以获得用户/物品特征$\mathbf{f}_i^u$和$\mathbf{f}_j^v$，



(a) 观测评分 (b) 评分潜在结果 (c) 倾向得分 (d) 预测评分

图 5：改编自图 (2) 的一个示例，其中正值性假设成立。再次假设协变量 C 表示二维特征（用户类型、电影类型）。（a）显示观测评分；（b）显示评分潜在结果；（d）显示推荐系统模型预测的评分潜在结果。倾向得分 $e_{ij} = P(a_{ij}|\mathbf{c}) = \mathbb{E}[a_{ij}|\mathbf{c}]$ 显示在（c）中。根据（a）（d）和公式（9），$\mathrm{L}^{\mathrm{Obs}} = (5-1)^2 \times 2/8 = 4$。根据（b）（d）和公式（8），$L^{\mathrm{True}} = (5-1)^2 \times 8/16 = 8$。根据（a）（c）（d）和公式（10），$\mathrm{L}^{\mathrm{IPW}} = {}_1{}^1/_4 (5-1)^2 \times 2/16 = 8$，其对于 L^{True} 是无偏的。

$\tilde{e}_{ij}$ 可以通过 逻辑回归 [39] 估计如下：

$$\tilde{e}_{ij}^{\mathrm{LR}} = \mathrm{Sigmoid}\Big(\Big(\sum_k w_k^u f_{ik}^u\Big) + \Big(\sum_k w_k^v f_{jk}^v\Big) + b_i + b_j\Big), \tag{11}$$

其中，$\mathrm{Sigmoid}(x) = (1+\exp(-x))^{-1}$，$w_k^u$ 和 w_k^v 是回归系数，而 b_i、b_j 分别是用户和物品特定偏置。如果没有用户/物品特征 $\mathbf{f}_i^u$ 和 $\mathbf{f}_j^v$，我们可以仅根据曝光数据粗略估算 e_{ij}。例如，我们可以使用泊松分解 [60] 估算 $\tilde{e}_{ij}$：

$$\tilde{e}_{ij}^{\mathrm{PF}} \approx 1 - \exp\left(-\boldsymbol{\pi}_i^T \cdot \boldsymbol{\gamma}_j\right), \tag{12}$$

其中，$\boldsymbol{\pi}_i$ 和 $\boldsymbol{\gamma}_j$ 是带有伽马先验的可训练用户和物品嵌入，并且可以按照 [61]中的讨论，从曝光数据中推断得出。计算倾向得分的其他策略见 [62, 63, 64, 65]。

逆概率加权的优点在于，如果倾向得分 e_{ij} 估计准确，则可以保证式（10）在评分潜在结果估计中的无偏性。然而，倾向得分估计模型的准确性严重依赖于人类专家的领域知识和专业技能，而这些无法通过实验检验。此外，逆概率加权存在方差较大和数值不稳定的问题，尤其是在估计的倾向得分 e_{ij} 非常小时。因此，通常会采用截断和多任务学习等方差缩减技术，以改善训练动态的稳定性 [66, 67, 68]。

替代混杂因素调整。 基于逆倾向加权的推荐系统从数据角度处理曝光偏差：它们对有偏的观察数据集进行重新加权，生成伪随机数据集，从而实现推荐系统的无偏训练。相比之下，基于混杂因素调整的方法会估计导致曝光偏差的混杂因素 C，并在评分预测模型中调整其影响（一个简单的调整

策略是将其作为额外的协变量进行控制 C [12]）。要使调整无偏，经典因果推断要求式（3）中的条件无混杂假设成立，即不存在未观测混杂因素 [33],，而这在实践中通常难以实现。幸运的是，多原因因果推断 [69]的最新进展表明，我们可以改为控制根据物品共同曝光数据估计出的替代混杂因素，从而在更弱的假设下缓解曝光偏差。

我们用$\mathbf{a}_i = [a_{i1}, \cdots, a_{iJ}]$表示用户 i的所有 J物品的曝光状态，这可以视为临床试验中的捆绑处理 [70]。Wang 等人 [42]指出，如果我们能够估计特定于用户的潜变量 $\boldsymbol{\pi}_i$，使得在给定 $\boldsymbol{\pi}_i$的条件下，不同物品对该用户的曝光相互独立，那么控制 $\boldsymbol{\pi}_i$ 就能消除多原因混杂因素$\mathbf{c}_i^m$的影响（即同时影响多个物品的曝光和评分的混杂因素）。该论断的简单证明如下：如果在给定 $\boldsymbol{\pi}_i$的条件下，$\mathbf{c}_i^m$仍会影响$\mathbf{a}_i$ 和$\mathbf{r}_i$ ，由于$\mathbf{c}_i^m$是不同物品曝光的未观测共同原因，因此a_{ij} 不可能条件独立（参见第3.2.2节关于分叉结构的讨论），这就产生了矛盾。严谨的证明见 [69]。Wang 等人还假设 p（$\mathbf{a}_i|\boldsymbol{\pi}_i$） $= \Pi_j p$（$a_{ij}|\boldsymbol{\pi}_i$） $=\Pi_j$服从 Poisson（$\boldsymbol{\pi}_i^T \cdot \boldsymbol{\gamma}_j$），并使用泊松分解推断 $\boldsymbol{\pi}_i$和$\boldsymbol{\gamma}_j$。随后，在推荐系统模型[33]中将 $\boldsymbol{\pi}_i$ 作为额外协变量进行控制，即可缓解曝光偏差。例如，在基于矩阵分解的推荐系统中控制 $\boldsymbol{\pi}_i$，可得到以下调整：

$$r_{ij}^{\text{adj}}(a_{ij}=1) \sim \mathcal{N}\Big(\underbrace{\mathbf{u}_i^T \cdot \mathbf{v}_j}_{\text{user interests}} + \underbrace{\sum_k w_k \pi_{ik}}_{\text{adj. for expo. bias}}, \sigma_{ij}^2 \Big). \tag{13}$$

倾向得分的性质可用于进一步简化公式 (13)：如果公式 (3) 中的无混杂性对于 $C = \boldsymbol{\pi}_i$成立，那么对于 $C = \tilde{e}_{ij} = p(a_{ij}|\boldsymbol{\pi}_i)$[58]也成立。因此，我们可以控制由 $\boldsymbol{\pi}_i$估计的近似倾向评分，即 $\tilde{e}_{ij} = \boldsymbol{\pi}_i^T \cdot \boldsymbol{\gamma}_j$，从而得到简化后的调整公式：

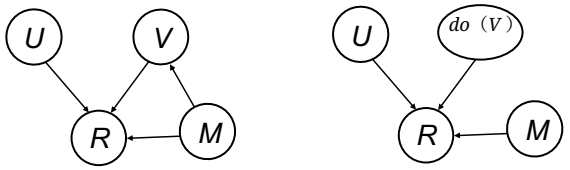
$$r_{ij}^{\text{adj}}(a_{ij}=1) \sim \mathcal{N}\left(\mathbf{u}_i^T \cdot \mathbf{v}_j + w_i \cdot \tilde{e}_{ij}, \sigma_{ij}^2\right), \tag{14}$$

其中， w_i 是一个用户特定系数，用于捕捉 $\tilde{e}_{ij}$ 对评分的影响。

尽管该方法在采用较弱假设处理曝光偏差方面取得了成功，但它仍有一项局限：由于泊松分解是一种浅层模型，可能无法捕捉多原因混杂因素对物品共同曝光的复杂影响。为解决这一问题，近期研究引入深度神经网络 (DNNs)，以从捆绑处理 $\boldsymbol{\pi}_i$ 中推断用户特定的替代混杂因素$\mathbf{a}_i$ [71, 72]。这些方法通常假设$\mathbf{a}_i$ 由 $\boldsymbol{\pi}_i$通过由深度生成网络 $f\text{exp}_{nn}$ 参数化的 $p(\mathbf{a}_i|\boldsymbol{\pi}_i)$生成：

$$p(\mathbf{a}_i|\boldsymbol{\pi}_i) = \Pi_j \text{Bernoulli}(\text{Sigmoid}(f_{nn}^{\text{exp}}(\boldsymbol{\pi}_i)_j)), \tag{15}$$

[12] 再次考虑图 5 中的玩具示例。如果我们准确知道每个用户-物品对的用户类型和项目类型$\mathbf{c}$，那么即使物品曝光不是随机的，预测结果也可以是无偏的。



(a) 考虑物品流行度的结构因果模型　　(b) 干预下的结构因果模型

图 6：(a)：显式建模物品流行度的结构因果模型。(b)：干预 $do(V)$ 下的结构因果模型。

随后，通过变分自编码贝叶斯算法 [73]，使用由深度神经网络参数化的高斯分布来近似 $\boldsymbol{\pi}_i$ 的难以处理的后验分布；即 $q(\boldsymbol{\pi}_i|\mathbf{a}_i) = \mathrm{N}(f_{nn}^{\mu}(\mathbf{a}_i), \mathrm{diag}(f_{nn}^{\sigma^2}(\mathbf{a}_i)))$，其中 f_{nn}^{μ} 和 $f_{nn}^{\sigma^2}$ 是两个深度神经网络，用于计算 $\boldsymbol{\pi}_i$ 的后验均值和方差（对角化前）。借助深度生成模型估计替代混杂因素 $\boldsymbol{\pi}_i$，推荐系统模型能够调整多原因混杂因素对物品曝光的非线性影响，从而在推荐中进一步缓解曝光偏差。

基于替代混杂因素估计的因果推荐系统的关键优势在于，在潜在结果预测模型中控制混杂因素，通常比基于逆概率加权的方法具有更低的方差 [42]。然而，这些模型需要根据物品共同曝光估计替代混杂因素 $\boldsymbol{\pi}_i$，并在推荐系统模型中引入额外参数来调整其影响；如果混杂因素和参数估计不准确，可能会引入额外偏差。此外，这些方法无法解决由单因混杂因素导致的曝光偏差。

4.1.2 流行度偏差

流行度偏差可以视为一种特殊的曝光偏差，即用户过度接触热门物品 [74, 75]。因此，可以采用上一节介绍的技术来应对，尤其是基于逆概率加权的方法 [76]。原因在于，如果我们将物品的流行度定义为其曝光率：

$$m_j = \frac{\sum_i a_{ij}}{\sum_j \sum_i a_{ij}}, \tag{16}$$

我们可以将 m_j 视为伪倾向得分，并使用逆概率加权对观测评分重新加权。或者，我们也可以借助结构因果模型（SCM）分析并应对流行度偏差，深入研究物品流行度影响下生成观测评分的因果机制。

该讨论主要基于 [48] 提出的流行度偏差去混杂（PD）算法。PD 假设，用户兴趣 $\mathbf{u}_i$、物品潜在属性 $\mathbf{v}_j$、物品流行度 m_j 和观测评分 r_{ij} 之间的关系可由图 6 所示的因果图表示。在该图中，物品流行度可明确识别为混杂因素，它会使物品属性与用户

评分产生伪相关。PD 旨在通过后门调整消除这类伪相关，从而正确识别$\mathbf{u}_i$和$\mathbf{v}_j$对r_{ij}（表示用户对物品内在属性的兴趣）的因果影响。回顾一下，基于 SCM 的后门调整包括两个阶段：（1）在训练阶段，根据收集的数据集估计因果图中的相关结构方程。（2）随后，根据公式（5）调整混杂因素的影响，以消除伪相关。因此，我们需要根据观测评分r_{ij}和物品流行度m_j估计$p_G(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, m_j)$，并推断潜变量$\mathbf{u}_i$和$\mathbf{v}_j$。在 PD 中，$p_G(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, m_j)$被建模为 MF 的一种变体，如下所示：

$$p_G(r_{ij}|\mathbf{u}_i, \mathbf{v}_j, m_j) \propto \underbrace{\text{Elu}(\mathbf{u}_i^T \cdot \mathbf{v}_j)}_{\text{user interests}} \times \underbrace{m_j^\lambda}_{\text{pop. bias}}, \tag{17}$$

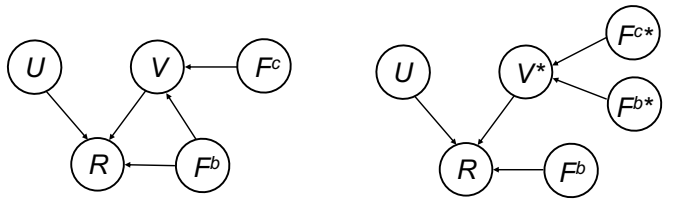
其中λ是一个超参数，表示我们对物品流行度对评分的影响强度的先验判断，而函数 Elu（定义为 $\text{Elu}(x) = e(x) \text{ if } x < 0 \text{else } x + 1$）使公式（17）右侧成为适当的非归一化概率密度函数。在估计出$\mathbf{u}_i$和$\mathbf{v}_j$（使用公式（17）从数据集中估计）后，我们对因果图中的物品节点V进行干预（见公式（5））， 从而通过后门调整消除物品流行度造成的伪相关：

$$p(r_{ij}|do(\mathbf{u}_i, \mathbf{v}_j)) \propto \mathbb{E}_{p(m_j)}[\text{Elu}(\mathbf{u}_i^T \cdot \mathbf{v}_j) \times m_j^\lambda] = \text{Elu}(\mathbf{u}_i^T \cdot \mathbf{v}_j) \times \mathbb{E}_{p(m_j)}[m_j^\lambda]. \tag{18}$$

由于公式（18）中的第二项$\mathbb{E}_{p(m_j)}[m_j^\lambda]$是常数，且 Elu 是单调递增函数，因此它们不会影响预测阶段未交互物品的排序。因此，我们可以将其舍去，并使用$\hat{r}_{ij} = \mathbf{u}_i^T \cdot \mathbf{v}_j$作为无偏评分预测器，以生成未来推荐。

总体而言，PD 的去偏机制非常直观，并且适用于基于后门调整的因果推荐系统 [25, 24]：在有偏训练集上拟合推荐系统模型时，我们在公式（17）中明确引入物品流行度m_j（即混杂因素），以解释物品属性与观测到的用户评分之间的伪相关。因此，用于生成未来推荐的用户/物品潜变量$\mathbf{u}_i$和$\mathbf{v}_j$，即$\hat{r}_{ij} = \mathbf{u}_i^T \cdot \mathbf{v}_j$，可以专注于估计用户对物品内在属性的真实兴趣。

流行度偏差总是有害的吗？ 近来，越来越多的研究者开始认为，流行度偏差对推荐系统而言未必有害，因为有些物品之所以流行，本身是因为其质量优于其他物品，或者契合了用户兴趣的当前趋势，因此，向用户推荐更多这类物品是有充分理由的 [77, 78]。因此，PD 及前文介绍的其他一些方法 [48] 不再将物品流行度的干预分布设为$p(m_j)$，而是进一步提出使其与物品质量相对应，或反映未来流行度预测。我们将在第4.3节介绍推荐系统因果泛化方面的这些策略。



（a）考虑物品内容特征的结构因果模型 F^c 和物品曝光特征 F^b

（b）对物品曝光特征的不良直接效应进行建模的效应，物品曝光特征 F^b

图 7：（a）：同时考虑物品内容特征 F^c 和物品曝光特征 F^b 对物品潜变量 V 的因果影响的结构因果模型。（b）：反事实结构因果模型，其中 V^* 由基线值 F^{b*} 和 F^{c*} 决定，用于对 F^b 的不良直接效应进行建模。

4.1.3 标题党偏差

与前面主要关注基于协同过滤的推荐系统因果去偏策略的小节不同，本节讨论基于内容的推荐。具体而言，我们讨论标题党偏差，其定义为过度推荐具有吸引人的曝光特征（如耸人听闻的标题）但内容质量较低的物品所产生的偏差。讨论主要基于 [27]。我们假设物品特征$\mathbf{f}_j^v$可以进一步分解为用于捕捉物品内容信息的物品内容特征$\mathbf{f}_j^c$，以及主要用于吸引用户注意力的物品曝光特征$\mathbf{f}_j^b$。以微视频为例，物品内容特征$\mathbf{f}_j^c$可以是视频的视听内容，而物品曝光特征$\mathbf{f}_j^b$可以是视频标题，标题并不一定要忠实地描述视频内容。

用户兴趣 $\mathbf{u}_i$、物品曝光特征 $\mathbf{f}_j^b$、物品内容特征 $\mathbf{f}_j^c$、物品融合特征 $\mathbf{v}_j$与观测评分 r_{ij}之间的关系如图 7-(a) 的因果图所示。我们指出，当用户在查看物品内容 $\mathbf{f}_j^c$之前，因受到物品曝光特征 $\mathbf{f}_j^b$ 的误导而记录了对该物品的点击时，就会产生标题党偏差。因此，该偏差可定义为由因果路径 $F^b \rightarrow R$表示的**直接影响**：$\mathbf{f}_j^b$对评分 r_{ij} 的影响。为消除标题党偏差，我们需要阻断 F^b 对评分预测的直接影响，从而在推荐中全面考虑物品内容质量。

与基于结构因果模型的因果推荐系统一样，我们首先估计因果图中感兴趣的结构方程，即 $p_G(\mathrm{v}_j|\mathrm{f}_j^b, \mathrm{f}_j^c)$ 和 $p_G(r_{ij}|\mathrm{u}_i, \mathrm{v}_j, \mathrm{f}_j^b)$。由于 [27] 中的分布是以确定性方式推理的（即具有无限精确率的高斯分布），我们保持讨论与其一致。具体而言，我们使用 $\mathrm{v}_j(\mathrm{f}_j^b, \mathrm{f}_j^c) = f^{ff}(\mathrm{f}_j^b, \mathrm{f}_j^c)$ 表示结构方程 $p_G(\mathrm{v}_j|\mathrm{f}_j^b, \mathrm{f}_j^c)$，其中 f^{ff} 是特征融合函数，它将 f_j^b、f_j^c 聚合为 v_j；并分别使用 $r_{ij}(\mathrm{u}_i, \mathrm{v}_j, \mathrm{f}_j^b)$ 表示结构方程 $p_G(r_{ij}|\mathrm{u}_i, \mathrm{v}_j, \mathrm{f}_j^b)$。为了明确区分物品曝光特征 f_j^b 和物品潜变量 v_j 对观测评分的影响，假设 $r_{ij}(\mathrm{u}_i, \mathrm{v}_j, \mathrm{f}_j^b)$ 可分解如下：

$$r_{ij}(\mathbf{u}_i,\ \mathbf{v}_j,\ \mathbf{f}_j^b) = \underbrace{f_{nn}^{uv}(\mathbf{u}_i,\ \mathbf{v}_j)}_{\text{用户兴趣}} \underbrace{\cdot \text{Sigmoid}\left(f_{nn}^{uf}(\mathbf{u}_i, \mathbf{f}_j^b)\right)}_{\text{潜在的标题党偏差}}, \tag{19}$$

其中，Sigmoid函数在融合过程中提供必要的非线性。本质上，式（19）表示生成观测评分的因果机制，其中交织着用户对物品内容的兴趣和标题党偏差。

然而，通过式（19）学习潜变量 $\mathbf{u}_i$，$\mathbf{v}_j$和函数 f_{nn}^{uf}，f_{nn}^{uv}后，要像使用 PD 算法那样从评分预测中消除标题党偏差并不那么直接，因为我们应该只消除物品曝光特征 $\mathbf{f}_j^b$对评分 r_{ij}的直接影响，同时保留其通过物品潜变量 $\mathbf{v}_j$ 介导的间接影响，从而在推荐中全面考虑所有可用的物品特征。为此，我们首先计算物品曝光特征 $\mathbf{f}_j^b$对评分 r_{ij} 的自然直接效应（NDE） [79]，如下所示：

$$\text{NDE}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^b) = r_{ij}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^b) - r_{ij}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^{b*}), \tag{20}$$

其中 $\mathbf{v}_j^* = f_{nn}^{ff}(\mathbf{f}_j^{b*}, \mathbf{f}_j^{c*})$，基线值 $\mathbf{f}_j^{b*}$、$\mathbf{f}_j^{c*}$被视为相应特征从物品 [27]中缺失。由于式（20）中的第二项$r_{ij}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^{b*})$表示用户对“空”物品的评分，可以视为常数，因此不会影响物品的排序。所以，我们只调整式（20）的第一项，该项基于反事实世界中用户 i对物品 j 的评分进行推理：在这个世界里，式（19）中的物品 j 仅具有曝光特征 $\mathbf{f}_j^b$，而不具有内容特征和融合特征 $\mathbf{f}_j^{c*}$及 $\mathbf{v}_j^*$（图 7-(b)）。这一调整得出以下估计量，

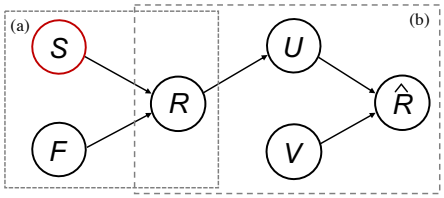
$$\hat{r}_{ij} = r_{ij}(\mathbf{u}_i, \mathbf{v}_j, \mathbf{f}_j^b) - r_{ij}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^b) \triangleq \underbrace{r_{ij}(\mathbf{u}_i, \mathbf{v}_j, \mathbf{f}_j^b)}_{\text{user interests + clickbait}} - \underbrace{r_{ij}(\mathbf{u}_i, \mathbf{v}_j^*, \mathbf{f}_j^b)}_{\text{clickbait bias}}. \tag{21}$$

式（21）消除了$\mathbf{f}_j^b$对评分预测的直接影响，从而能够在未来推荐中全面考虑物品内容质量。

4.1.4 不公平性

近年来，随着人们对算法公平性的日益关注，人们期望推荐系统不会歧视来自某些人口统计群体的用户 [80, 81, 82]。然而，传统推荐系统可能会捕捉用户敏感信息与其历史活动之间的不良关联，从而向用户推荐可能具有冒犯性的内容。因果推断有助于识别并处理此类不公平关联，从而提升未来推荐的公平性。本节重点讨论 [83], 中提到的面向用户的公平性，其定义为推荐系统基于用户的某些敏感属性对其进行差别对待所产生的偏差。

在考虑推荐系统面向用户的公平性时，假设用户特征$\mathbf{f}_i$的一个子集$\mathbf{s}_i$包含用户的敏感信息，



(a) 观察数据集的因果生成过程
观测数据集

(b) 传统推荐系统的因果决策过程
传统推荐系统

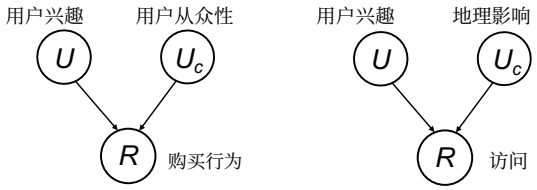
图 8：对传统推荐系统因果决策机制进行推理的结构因果模型。观察到的用户评分 R 可由用户特征 F（包括敏感特征 S）因果驱动，而这些特征可能进而不公平地影响用户潜变量 U 的推断以及新评分预测结果 $\hat{R}$。

例如性别、种族和年龄。特征$\mathbf{s}_i$ 之所以敏感，是因为不恰当地依赖这些特征进行推荐可能会冒犯用户，进而损害他们的在线体验以及对系统的信任。大多数传统推荐系统的因果决策机制所对应的因果图如图 8 [83]所示。从图 8 可以看出，用户历史行为（即观测评分r_{ij}）是由用户特征$\mathbf{f}_i$因果驱动的，其中包括用户敏感特征$\mathbf{s}_i$。因此，根据r_{ij} 推断出的用户潜变量$\mathbf{u}_i$ 可能会捕获$\mathbf{s}_i$ 中的用户敏感信息，从而不公平地影响未来的评分预测$\hat{r}_{ij}$ 。

为了解决这一问题，Li 等人 [83]提出将用户的敏感特征$\mathbf{s}_i$ 与用户潜变量$\mathbf{u}_i$解纠缠，从而在未来推荐中最大限度地抑制由因果链 $S \rightarrow R \rightarrow U$ 所表示的$\mathbf{s}_i$ 对$\mathbf{u}_i$ 的不公平影响。实现解纠缠的一种常见策略是对抗训练 [84],：我们与推荐系统一起训练一个判别器 $f_{nn}^{\text{cls}}(\mathbf{u}_i) \rightarrow \mathbf{s}_i$，使其根据用户潜变量$\mathbf{u}_i$ 预测敏感特征$\mathbf{s}_i$ 。在根据观测评分 r_{ij}拟合推荐系统时，我们约束推断得到的$\mathbf{u}_i$ 去欺骗判别器 $f\text{cls}_{nn}$，使其对$\mathbf{s}_i$作出错误预测，从而避免$\mathbf{u}_i$ 因与$\mathbf{s}_i$存在不公平相关性而捕捉 r_{ij} 中的敏感信息。下面以基于矩阵分解的推荐系统为例说明具体细节。我们用 L^{Rec} 表示基于矩阵分解的推荐系统原始训练目标，即最大化观测评分 r_{ij} 上的对数似然；用 L^{cls} 表示判别器 $f\text{cls}_{nn}$ 的损失函数。加入公平性约束后，调整后的训练目标 L^{Fair} 如下：

$$\mathcal{L}^{\text{Fair}} = \underbrace{\mathcal{L}^{\text{Rec}}(\mathbf{u}_i^T \cdot \mathbf{v}_j, r_{ij})}_{\text{user interests}} - \lambda \cdot \underbrace{\mathcal{L}^{\text{cls}}(f_{nn}^{\text{cls}}(\mathbf{u}_i), \mathbf{s}_i)}_{\text{fairness constraint}}, \tag{22}$$

其中 λ 是一个超参数，用于平衡推荐性能与公平性目标。通常，较高的 λ 会带来更好的公平性，但也会限制用户潜变量$\mathbf{u}_i$的容量，从而可能对推荐性能产生负面影响。尽管这里以基于矩阵分解的推荐系统为例，但只需将式（22）中的$\mathbf{u}_i^T \cdot \mathbf{v}_j$ 项替换为相应的评分估计器，即可轻松将其推广到深度矩阵分解或基于自编码器的推荐系统。



（a）DICE 的因果图　　（b）向兴趣点推荐的泛化

图9：DICE 的因果图（a）及其向兴趣点推荐的泛化（b）。

4.2 推荐中的因果解释

在前面的章节中，我们介绍了因果关系，以解决传统推荐系统中的各种偏差和伪相关问题。本节将利用因果关系来解释用户决策过程。具体而言，我们将探讨一个有趣的问题：如何区分用户的意图——这种意图在因果层面上解释了他们过去的行为——也就是说，用户购买某件物品，是因为她顺应了当前趋势，还是因为她真的喜欢它？这个问题棘手之处在于：现实中，我们只能观察到结果，即购买行为，而这些结果可能由两种原因解释。

4.2.1 利用因果嵌入解耦兴趣与从众性

本讨论基于 [56] 中提出的 DICE。为简化讨论，我们将 r_{ij} 视为隐式反馈，并将用户、正向物品（j: r_{ij} =1）和负向物品（k: $r_{ik} = 0$）组成的三元组集合定义为 $\mathrm{R}^{pn} = \{(i, j, k) | r_{ij} = 1 \wedge r_{ik} = 0\}$。每个物品 j的流行度，即 m_j，反映了当前趋势，可通过公式（16）计算。观察到用户兴趣U、用户从众性 U_c 与观测评分 R 之间的因果关系可表示为图9-(a)中的 V结构，DICE 利用碰撞效应 实现解纠缠，也就是说，无法由一种原因解释的结果更可能由另一种原因导致（参见第3节2.2的讨论）。因此，尽管由于纠缠，无法直接根据用户的评分 r_{ij} 估计其兴趣，但可以通过物品 j的流行度水平估计用户对趋势的从众性；而不太可能由从众性导致的正反馈，更有可能反映用户的真实兴趣。

在实现中，DICE 假设观测评分 r_{ij} 可以分解为从众性部分 $r_{ij}^c = f^c(\mathbf{u}_i^c, \mathbf{v}_j^c)$ 与用户兴趣部分$r_{ij}^i = f^i(\mathbf{u}_i^i, \mathbf{v}_j^i)$ 之和，其中 $\mathbf{u}_i^{c\ i}, , \mathbf{v}_j^{c\ i},$ 分别是可学习的用户和物品嵌入，用于反映用户 i对物品j的兴趣（即上标为 i）和从众性（即上标为 c）。根据因果图中的碰撞效应，我们可以将 R^{pn}中的三元组分为两部分：第一部分 $\mathrm{R}^{(1)pn}$中，三元组里的正向物品 a的流行度水平高于负向物品 b，即 $m_a > m_b$。在这种情况下，我们可以从该三元组得出两个一般性结论：（1）总体而言，用户更喜欢物品a 而非 b；（2）由于物品 a 的流行度更高，她更可能从众于物品 a，而非物品 b a更高

流行度。因此，这些结论可得出以下两个不等式：

$$\forall(i,a,b)\in\mathcal{R}_{pn}^{(1)},\text{we have}\begin{cases} r_{ia}^{c} > r_{ib}^{c}\ \text{(conformity)} \\ r_{ia}^{i}+r_{ia}^{c} > r_{ib}^{i}+r_{ib}^{c}\ \text{(overall preference)}, \end{cases} \tag{23}$$

为简便起见，省略了 $r^{c,i}_{a\{,b\}}$ 对潜变量 $\mathbf{u}_i^{c\ i}$,,$\mathbf{v}^{c,i}_{\{a,b\}}$ 的依赖关系。第二部分，即 $\mathrm{R}_{pn}^{(2)}$，是实现解纠缠的**关键**，因为对于 $\mathrm{R}_{pn}^{(2)}$ 中的每个三元组（i, c, d），负物品 d 比正物品 c 更受欢迎。在这种情况下，用户 i 本可以简单地从众于这一趋势并选择物品 d 进行消费，但她反而主动选择了不那么受欢迎的物品 c。因此，我们可以得出另一个更具体的结论，从而实现用户兴趣与从众性之间的解纠缠：相较于 d，选择物品 c 更可能是由用户兴趣所驱动的。因此，我们可以构造出以下三个不等式：

$$\forall(i,c,d)\in\mathcal{R}_{pn}^{(2)},\text{we have}\begin{cases} r_{ic}^{i} > r_{id}^{i}\ \text{(interests)}, r_{ic}^{c} < r_{id}^{c}\ \text{(conformity)}, \\ r_{ic}^{i}+r_{ic}^{c} > r_{id}^{i}+r_{id}^{c}\ \text{(overall preference)}. \end{cases} \tag{24}$$

公式（23）和（24）中的不等式可以通过推荐系统中的基于排序的损失函数求解，例如贝叶斯个性化排序（BPR） [85], ，其中可以从 $\mathrm{R}_{pn}^{(1)}$ 和 $\mathrm{R}_{pn}^{(2)}$ 中学习解缠结嵌入$\mathbf{u}_i^{c\ i}$,,$\mathbf{v}_j^{c\ i}$,以及匹配函数 $f^{c,i}(\cdot,\cdot)$。最后，我们构造评分预测器 $\hat{r}_{ij}=f^{i}(\mathbf{u}_i^i,\mathbf{v}_j^i)+f^{c}(\mathbf{u}_i^c,\mathbf{v}_j^c)$，用于未来推荐。

4.2.2 DICE 的泛化

DICE 从数据视角解耦用户意图，并提升推荐系统的可解释性：它根据正、负物品的相对流行度，将 R^{pn} 中的三元组（i， j， k）划分为两个互不相交的子集 $\mathrm{R}_{pn}^{(1)}$ 和 $\mathrm{R}^{(2)pn}$，并指出 $\mathrm{R}_{pn}^{(2)}$ 中的三元组有助于区分用户兴趣与其对流行趋势的从众性。如果我们能够找到**替代性因果解释**，以质疑这些任务中观察到的正反馈只能归因于用户兴趣这一假设，那么 DICE 的基本思想也可推广到其他类型的推荐任务，从而提升其可解释性。

例如，在兴趣点（PoI）推荐中，目标物品是用户可能觉得值得或有趣而前往的特定地点，例如餐馆、杂货店和购物中心 [7]。在这项任务中，兴趣点的位置是用户前往该兴趣点的一个重要替代解释因素，而非用户兴趣，因为与偏远的兴趣点相比，附近的兴趣点更方便前往[86]。因此，为了将用户兴趣与可能对用户选择产生因果影响的潜在地理因素解纠缠开来，我们可以采取与 DICE 类似的策略，根据正负兴趣点与用户之间的距离，对用户的历史访问记录进行划分。然后，可以采用相同的基于排序的方法，根据划分后的数据集估计解纠缠后的用户兴趣嵌入。

4.2.3 可解释推荐系统的其他研究

可解释推荐是一个广泛的主题 [87],，基于数据划分来解纠缠用户意图只是其中一小部分。还有许多研究从模型层面着手提升推荐系统的可解释性，它们设计并整合特定的解耦模块，例如原型学习 [88],、上下文建模 [89],和方面建模 [90],，以进一步增强传统推荐系统模型的透明度和可解释性。我们建议感兴趣的读者参阅相关论文以及 [91, 92]，以作进一步探究。

4.3 推荐的因果泛化

从可能存在偏差和纠缠的观察数据集中估计因果关系后，推荐系统的泛化能力可以得到显著提升。因为即使我们进行推荐时所处的上下文（或环境）发生变化（例如物品流行度、用户从众性等），仍然可以基于稳定且不变的因果关系进行推荐，同时舍弃或纠正其他具有暂时性且易于变化的不良相关性 [56, 93]。本节以用于解决流行度偏差的PD算法和用于实现因果可解释性的DICE算法为例，展示如何通过因果干预和解纠缠提升推荐系统的泛化能力。

4.3.1 基于干预的泛化

首先，我们以PD算法为例，说明因果干预如何提升推荐系统在动态环境中的泛化能力。在推荐系统中，通常假设用户兴趣在一段时间内保持不变，即图 (6) 中的因果结构 $U \rightarrow R \leftarrow V$ 表示用户对物品内在属性的稳定兴趣。然而，在同一时期，不同物品的流行度（也就是我们进行推荐时所处的上下文）可能会迅速变化 [78]。回想一下，PD通过两个项的乘积，即 $\mathrm{Elu}(\mathbf{u}_i^T \cdot \mathbf{v}_j)$ 和 m_j^λ，将用户兴趣和物品流行度对评分的因果影响解耦，如公式 (17) 所示。假设 m_j 表示物品 j 当前的流行度水平。如果我们预测物品 j 的流行度未来将变为 m'_j [6],，就可以在结构方程 $p_G(R|U,V,M)$ 中进行干预，将 M 设为预测值 m'_j，并通过以下公式预测未来评分 r'_{ij}：

$$p_G(r'_{ij}|\mathbf{u}_i,\mathbf{v}_j,do(m'_j)) \propto \underbrace{\mathrm{Elu}(\mathbf{u}_i^T \cdot \mathbf{v}_j)}_{\text{stable user interests}} \times \underbrace{(m'_j)^\lambda}_{\text{future popularity}}, \tag{25}$$

其中，从当前时间步学习得到的用户、物品潜变量 $\mathbf{u}_i$ 和 $\mathbf{v}_j$ 保持不变。在预测结果中考虑物品流行度未来变化对评分的影响后，服务提供商可以针对具有不同流行潜力的物品，制定资源分配策略。相比之下，传统推荐系统可能会错误地将物品当前流行度水平对评分的影响捕捉为用户兴趣。因此，当物品流行度 m_j 因时间演变而变为不同水平 m'_j 时，它们的泛化能力将较差。

4.3.2 基于解纠缠的泛化

此外，因果解耦能够通过识别那些对环境潜在变化更具稳健性的原因，并基于这些原因进行推荐，从而促进推荐系统的泛化 [94, 95]。例如，如果根据用户的历史行为将用户的从众性与兴趣解纠缠，那么当用户的从众性因某些原因降至较低水平时，由于假设用户兴趣在一定时期内保持稳定，我们仍可使用学习到的用户/物品兴趣变量 $\mathbf{u}_i^i$、$\mathbf{v}_j^i$，根据用户兴趣进行推荐；此前估计的不可靠用户从众性信息则可以舍弃或降低权重。相比之下，对于传统推荐系统，会将因果影响其历史行为的不同因素纠缠为单个用户潜变量 $\mathbf{u}_i$。因此，即使已知某些不太稳定的用户行为成因发生了变化（例如，在前文介绍的兴趣点推荐系统中，用户可能迁至一个新地点，导致不同兴趣点对该用户的便利程度发生变化），这些模型仍会利用过时的成因进行推荐，从而可能无法泛化到新环境。

5 因果推荐系统的评估策略

在前文各节中，我们讨论了多种有望解决传统推荐系统中多种偏差、纠缠和泛化问题的因果推断技术。然而，如果没有精心设计的模型评估策略，就很难判断所提出的因果推荐系统模型是否确实有效，也无法保证该模型部署到真实世界环境后能否可靠运行。因果模型的评估尤其困难，因为通常无法获得真实值，即我们关注的因果效应。尽管存在这些挑战，仍有若干策略可以利用有偏真实世界数据可靠地评估因果推荐系统，我们将在本节中对此进行全面讨论。此外，我们还整理了现有的、通过随机实验消除曝光偏差的真实世界数据集，以助力未来的因果推荐系统研究。

5.1 传统推荐系统的评估策略

传统推荐系统的评估通常分为三个步骤：首先，将评分矩阵 $\mathbf{R}$ 中的观测评分 r_{ij} 划分为互不重叠的训练集 $\mathbf{R}_{tr}$ 和测试集 $\mathbf{R}_{te}$，通常是从每位用户的观测评分中随机留出一定比例。接着，使用$\mathbf{R}_{tr}$ 中的评分训练所提出的推荐系统，以学习潜变量及相关函数模型（参见第2节）。最后，训练好的推荐系统预测每位用户在$\mathbf{R}_{tr}$ 中的缺失评分，并将预测结果与$\mathbf{R}_{te}$ 中的留出评分进行比较，以评估模型性能。评分预测的质量可通过基于准确率的指标来衡量，例如均方误差（MSE）和平均绝对误差（MAE）；也可通过基于排序的指标来衡量，例如召回率、精确率、归一化折损累计增益（NDCG）等。有关这些评估指标的更多信息，请参见 [96]。

5.2 因果推荐系统评估面临的挑战

然而，上述评估策略并不直接适用于因果推荐系统，因为$\mathbf{R}_{te}$ 中的评分可能与$\mathbf{R}_{tr}$中的评分具有相同的伪相关和偏差，这使得在$\mathbf{R}_{te}$ 上进行的评估无法准确衡量模型的真实性能。因此，为了无偏地评估因果推荐系统的有效性，理想情况下，我们应使用有偏/纠缠的训练集$\mathbf{R}_{tr}^{b}$ 来训练模型，并使用无偏/解缠的测试集$\mathbf{R}_{te}^{ub}$来评估模型，以便通过实验直接验证因果去偏/解缠算法的有效性。然而，这种无偏/解缠的测试集$\mathbf{R}_{te}^{ub}$可能难以获取，且建立成本高昂。因此，我们首先介绍用于评估因果推荐系统的常见数据模拟策略，随后讨论如何直接利用真实世界数据集，进一步提升因果推荐系统研究的可信度。

5.3 基于模拟数据集的评估

用于评估因果推荐系统的良好数据集模拟策略应具备以下特性：（1）明确识别所研究的偏差和纠缠的生成机制，并对其进行可信的设计，且能够灵活调整；（2）尽可能充分地利用现有的真实世界信息。

5.3.1 基于生成模型的模拟

一种满足上述标准的、颇具前景的数据集模拟策略是使用深度生成模型。这里我们以曝光偏差为例，展示如何利用真实世界数据集 [71]模拟该偏差。模拟分为

两个阶段。在训练阶段，使用真实世界数据集（例如 MovieLens 数据集 [5]）中的曝光数据和评分数据，训练两个变分自编码器（VAEs） [22, 73]，由此得到两个解码器网络 f^a_{nn} 和 f^r_{nn}。它们分别根据 K维高斯用户潜变量 $\mathrm{u}^a_i \sim \mathrm{N}(0, \mathrm{I}_K)$ 和 $\mathrm{u}^r_i \sim \mathrm{N}(0, \mathrm{I}_K)$，生成物品曝光 $\mathrm{a}_i \in \{0,1\}^J$ 和用户评分 $\mathrm{r}_i \in \mathbb{R}^J$。解码器根据真实用户的数据，捕捉物品曝光和用户评分的生成分布，从而有效利用可获得的真实世界信息。在生成阶段，对于每个假设用户 i'，我们抽取一个混杂因素 $\mathrm{c}_{i'} \sim \mathrm{N}(0, \mathrm{I}_K)$，使其同时影响 $\mathrm{u}^a_{i'}$和 $\mathrm{u}^r_{i'}$。接着，为模拟曝光偏差，我们设定 $\mathrm{u}^a_{i'} = \mathrm{c}_{i'}$ 和 $\mathrm{u}^r_{i'} = \lambda \cdot \mathrm{c}_{i'} + (1-\lambda)\boldsymbol{\epsilon}_{i'}$，并使用 f^a_{nn}, f^r_{nn} 生成模拟的物品曝光 $\mathrm{a}_{i'}$和评分 $\mathrm{r}_{i'}$，其中 $\boldsymbol{\epsilon}_{i'} \sim \mathrm{N}(0, \mathrm{I}_K)$，超参数 λ 控制混杂偏差的强度。最后，我们用 $\mathrm{a}_{i'}$ 对 $\mathrm{r}_{i'}$ 进行掩码处理，形成有偏训练集 R^b_{tr}；并将生成的评分 $\mathrm{r}_{i'}$ 不加掩码地保留在测试集 R^{ub}_{te}中，以便无偏评估模型性能。

基于生成模型的数据集模拟策略的优势在于，在评估阶段可以获得感兴趣的真实因果机制，例如评分潜在结果，而这对于真实世界数据集而言通常是不可能的。因此，可以根据模拟真实值轻松验证因果推荐系统的有效性。此外，这类模拟具有灵活性，可以将偏差和纠缠的强度设定为不同等级（例如，λ 中的示例），从而深入考察因果推荐系统的敏感性和鲁棒性。

5.3.2 测试集干预

另一种可靠的数据集模拟策略是测试集干预，即从原始测试集中创建一个干预测试集，使其偏差／纠缠分布与训练集不同 [56, 60, 97]。例如，要研究流行度偏差，我们可以先从$\mathbf{R}$ 中选择观测评分，使交互物品中 90% 为热门物品、10% 为冷门物品，以构成训练集$\mathbf{R}_{tr}$ [98]。然后，我们从剩余评分中（即原始测试集 $\mathbf{R}_{te}$）选取一个子集，其中热门物品和冷门物品的比例不同（例如，10% 为热门物品，90% 为冷门物品），以构成干预测试集$\mathbf{R}^{int}_{te}$。如果在$\mathbf{R}_{tr}$ 上训练的因果推荐系统在干预测试集$\mathbf{R}^{int}_{te}$上仍能表现良好，则可证明模型对流行度偏差具有不变性。类似的测试集干预策略也可用于评估 DICE 中用户兴趣的解纠缠以及从众性 [56]。

基于测试集干预的因果推荐系统评估策略的优势在于，它只需尽可能少地引入无法由真实世界信息证实的额外假设，因为干预通常是通过从原始测试集中选择样本来改变数据分布实现的，这不会对生成机制或假设用户、物品和评分引入额外假设。从这一角度来看，与基于生成模型的策略相比，基于测试集干预的评估结果可能更可信。

5.4 基于真实世界数据集的评估

5.4.1 随机实验

在研究曝光偏差时，可以建立无偏差的真实世界数据集，在这些数据集中，从部分用户那里收集其对所有物品或随机选取的物品的评分。这种做法可能成本极高，也不便于用户使用，但近年来，工业界对因果推荐系统研究的兴趣日益浓厚，并建立和发布了更多此类随机数据集，以推动因果推荐系统研究。现有真实世界数据集汇总如下：

- **Coat 数据集**[13] [39] （2016年）。Coat 数据集是一个小规模数据集，通过 Amazon Mechanical Turkers 平台众包收集，包含 300 名用户和 290 件物品。具体而言，首先要求每位 Turker 自行选择 24 件外套进行评分，这些评分构成有偏训练集 $\mathbf{R}_{tr}^{b}$。随后，要求每位 Turker 对 16 件随机抽取的外套进行评分，这些评分构成无偏测试集 $\mathbf{R}_{te}^{ub}$。

- **Yahoo! R3 数据集**[14] [99, 100] （2009年）。Yahoo! R3 数据集收集自 Yahoo! Music 平台。有偏训练集 $\mathbf{R}_{tr}^{b}$ 由 15,400 名用户对 1,000 件物品自行提供的 300,000 条评分组成。此外，还向 5,400 名用户中的一部分展示随机选取的十件物品供其评分，并利用这些评分构建无偏测试集 $\mathbf{R}_{te}^{ub}$。

- **KuaiRec 数据集**[15] [101] (2022)。KuaiRec 数据集基于中国广受欢迎的微视频分享平台快手（国际上称为 Kwai）构建。该数据集记录了 7,176 位用户对 10,728 个物品的自主评分，作为有偏训练集 $\mathbf{R}_{tr}^{b}$。无偏测试集 $\mathbf{R}_{te}^{ub}$由 1,411 位用户和 3,327 个物品的一个子集构成，其中这些用户与物品之间的评分几乎都已完整观测到（密度为 99.6%）。

数据集的统计信息汇总于表 1，供参考。此外，一些相关主题也有随机化数据集，例如点击率预测[102], ，即 Criteo Ads 数据集[16] [103], ，以及基于多臂老虎机的推荐系统 [104],，即 Open Bandit 数据集[17] [105], ；同时也提供了数据来源，以供感兴趣的读者查阅。

从表 1 可以看出，Coat 数据集规模较小。对于 Yahoo! R3 数据集，训练集规模相对较大（15,400 名用户和 1,000 件物品），但为建立无偏测试集而开展的随机实验规模较小（每位用户分别随机曝光 16 件和 10 件物品）。因此，尽管这些评分因随机化而无偏，但可能无法全面反映用户兴趣，进而导致较高的评估方差。

[13] https://www.cs.cornell.edu/~schnabts/mnar/[14] https://webscope.sandbox.yahoo.com/catalog.php?datatype=r&did=3[15] https://github.com/chongminggao/KuaiRec[16] http://cail.criteo.com/criteo-uplift-prediction-dataset/[17] https://research.zozo.com/data.html

数据集	用户数	物品数	项目类型	训练集	测试集
Coat	300	290	Coat	24 i/u（自行提供）	16 位用户（随机）
Yahoo! R3	15,400	1,000	音乐	300,000 条评分（用户自填）	对 5,400 位用户随机选择 10 位用户
KuaiRec	7,176	10,728	视频	16.3%r（自行提供）1,411 位用户和 3,327 件物品对应 99.6%r	

表 1：目前可用的真实世界因果推荐数据集的特征。这些数据集的测试集不存在曝光偏差，原因是物品曝光经过随机化，或评分已被完整观测。表中，24 i/u 等术语表示每位用户对 24 件物品进行评分；300,000 r 表示观测评分的数量；16.3% r 等术语表示交互密度。

对于最近发布的 KuaiRec 数据集，研究人员针对用户开展了大规模实验，以建立无偏测试集；其中，几乎完整收集了 1,411 名用户对 3,327 件物品的评分。因此，它可能成为一个前景广阔的新基准，可用于以较低方差评估更复杂的因果推荐系统模型。

5.4.2 定性评估与案例研究

对于推荐系统中无法归因于非随机化物品曝光的其他类型偏差（例如标题党偏差和不公平性），建立无偏测试集更具挑战性。例如，在研究标题党偏差时，很难确定用户点击某个物品究竟是出于兴趣还是因为标题党。同样，在考察推荐系统面向用户的公平性时，我们无法知道生成的物品是否会冒犯用户。在这种情况下，我们仍然可以通过案例研究进行定性模型评估：从原始测试集中手动选取一些有代表性的样本，并观察训练后的因果推荐系统模型是否会按预期对这些样本作出响应 [106]。

以因果推荐系统对标题党偏差的鲁棒性评估为例。我们可以从原始测试集中选取一些具有代表性的物品：一类是内容质量较低但曝光特征极具吸引力的物品，另一类是内容质量较高但曝光特征正常的物品。然后，我们获取这两组物品的评分预测并进行比较。如果所研究的因果推荐系统确实将第二组物品的排名置于第一组物品之上，那么我们基本可以得出结论：该模型对标题党偏差具有鲁棒性，因为推荐过程中优先考虑的是物品内容的质量，而不是其曝光特征。此外，为了评估因果推荐系统的面向用户的公平性，我们可以分析系统为特定人口群体的用户生成的推荐。如果推荐的物品倾向于体现与用户敏感特征负面相关的社会刻板印象，我们就可以得出结论：该模型仍然歧视用户。

6 未来方向

尽管近年来将因果推断与传统推荐系统相结合，以解决传统推荐系统在用户观测数据上进行相关性推理时存在的各种局限，已经取得了一些成果，但因果推荐系统研究仍处于起步阶段。未来可以探索若干有前景的方向，以进一步推动这一领域的发展。在本节中，我们确定了四个值得未来探索的有趣且重要的开放问题。

首先，现有因果推荐系统所需的假设可能过强，在现实中未必成立。例如，大多数基于 RCM 的因果推荐系统依赖稳定单元处理值假设（SUTVA），以排除不同用户的物品曝光之间的干扰。然而，如果用户通过社交网络相互连接，他们可能会彼此密切互动，或受到网络中影响者的强烈影响 [107]。因此，稳定单元处理值假设可能被违背，因为向一位用户所做的推荐可能会对其他用户的评分产生因果影响（即溢出效应 [108, 109]）。此外，如果某些用户从不点击某些类型的物品，正值性假设也可能被违背（即不依从和反从者 [33]）。因此，进一步放宽因果推荐系统的假设至关重要，这样才能使其更适用于现实应用。

此外，目前还缺乏一种可用于不同因果推理目的的通用推荐系统因果模型。大多数基于结构因果模型的因果推荐系统旨在解决某一种特定类型的偏差或纠缠问题，并默认其他问题不存在，因此未将其纳入因果图。此外，即使是解决同一问题的因果推荐系统，也可能采用多种包含不同变量和关系的因果图，导致不同研究之间不一致。因此，建立一种通用且广受认可的因果模型，将有望全面解决推荐中的多种因果问题，并带来显著益处。

此外，推荐系统中的某些偏差就像双刃剑，其积极的一面鲜少受到研究。以第4.1.1节讨论的物品曝光偏差为例。需要注意的是，有些物品更有可能获得曝光，是因为它们的质量高于其他物品。因此，这些物品较高的曝光率是合理的，也可以加以利用，以进一步提升推荐性能。此外，近期研究还发现，与物品曝光和用户评分存在虚假相关性的混杂因素，也有助于解释不同物品的共现模式 [71]。因此，如何恰当地识别并利用偏差的积极一面，同时最大限度地抑制其负面影响，至关重要，值得未来开展更深入的研究。

最后，尽管近年来工业界为因果推荐系统研究建立并发布了更多真实世界数据集，但许多因果推荐系统模型在评估时仍然严重依赖模拟数据集。模拟可能会导致问题过度简化，而且其设计往往与所提出模型的去偏／解纠缠机制完全吻合。因此，由于缺乏模型部署和在线测试，这些方法在更复杂的现实场景中的有效性仍不确定。为更有说服力地证明因果推荐系统的实际效用，我们非常期待与工业界开展更多合作。

7 总结

在本综述中，我们全面概述了因果推荐系统领域因果推断的最新进展。首先，我们指出传统推荐系统存在的问题：它们依赖于观测到的用户行为以及用户／物品特征之间的相关性。随后，我们介绍两种主流的因果推断框架，即 Rubin 的潜在结果模型和 Pearl 的结构因果模型；这些框架为深入理解上述问题提供了视角，也为推动传统推荐系统迈向因果阶梯的更高层级奠定了基础。具体而言，我们深入讨论了若干最先进的因果推荐系统模型，这些模型能够增强对各种偏差的鲁棒性并提升可解释性。此外，由于因果推荐系统可以依据稳定且不变的因果关系生成推荐，我们还阐明了其泛化能力能够得到显著提升。最后，我们介绍了因果推荐系统的评估策略，重点探讨如何基于有偏真实世界数据可靠地估计模型性能。我们还汇总了在用户身上开展了高成本随机实验的真实世界数据集，这反映出工业界对因果推荐系统日益增长的关注。

总体而言，因果推荐系统仍是一个相对新颖且尚未得到充分探索的研究课题。亟需投入更多努力，对现有研究进行系统化梳理，并开展更深入的研究以进一步改进。因此，我们指出了因果推荐系统中四个有趣且具有重要实践意义的开放问题。我们希望本综述能帮助读者全面理解在推荐系统中应用因果关系的核心思想，并推动这一前景广阔的领域进一步发展。

致谢。 本研究得到国家科学基金会资助，项目编号为 IIS-2006844、IIS-2144209、IIS-2223769、CNS-2154962 和 BCS-2228534；同时还获得摩根大通教职研究奖和思科教职研究奖的资助。

参考文献

1. Jiahui Liu、Peter Dolan 和 Elin Rønby Pedersen。基于点击行为的个性化新闻推荐。载于第*15*届国际智能用户界面会议论文集，第31–40页，2010年。2. Ioannis Paparrizos、B Barla Cambazoglu 和 Aristides Gionis。机器学习驱动的职位推荐。载于第*5*届 *ACM* 推荐系统会议论文集，第325–328页，2011年。3. Chong Wang 和 David M Blei。用于推荐科学文章的协同主题建模。载于第*17*届 *ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，第448–456页，2011年。4. Jing Yi、Yaochen Zhu、Jiayi Xie 和 Zhenzhong Chen。用于基于内容的微视频背景音乐推荐的跨模态变分自编码器。*IEEE* 多媒体汇刊，2021年。5. F Maxwell Harper 和 Joseph A Konstan。MovieLens 数据集：历史与背景。*ACM* 交互式智能系统汇刊，5(4):1–19，2015年。

6. Jiayi Xie、Yaochen Zhu、Zhibin Zhang、Jian Peng、Jing Yi、Yaosi Hu、Hongyi Liu 和 Zhenzhong Chen。用于微视频流行度预测的多模态变分编码器-解码器框架。载于*2020*年万维网大会论文集，第2542–2548页，2020年。7. Mao Ye、Peifeng Yin、Wang-Chien Lee 和 Dik-Lun Lee。利用地理影响进行协同兴趣点推荐。载于第*34*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集，第325–334页，2011年。8. Yuyun Gong 和 Qi Zhang。使用基于注意力机制的卷积神经网络进行话题标签推荐。载于第*25*届国际人工智能联合会议论文集，第2782–2788页，2016年。9. Francesco Ricci、Lior Rokach 和 Bracha Shapira。推荐系统手册导论。载于推荐系统手册，第1–35页。施普林格，2011年。10. Yehuda Koren、Steffen Rendle 和 Robert Bell。协同过滤进展。载于推荐系统手册，第91–142页。施普林格，2022。11. Pasquale Lops、Marco de Gemmis 和 Giovanni Semeraro。基于内容的推荐系统：现状与趋势。载于推荐系统手册，第73–105页。施普林格，2011年。12. Erion Çano 和 Maurizio Morisio。混合推荐系统：系统性文献综述。*Intelligent Data Analysis*，21(6):1487–1524，2017年。13. Liuyi Yao、Zhixuan Chu、Sheng Li、Yaliang Li、Jing Gao 和 Aidong Zhang。因果推断综述。*ACM Transactions on Knowledge Discovery from Data*，15(5):1–46，2021年。14. Chen Gao、Yu Zheng、Wenjie Wang、Fuli Feng、Xiangnan He 和 Yong Li。推荐系统中的因果推断：综述与未来方向。*arXiv* 预印本 *arXiv:2208 12397*，2022。。15. Judea Pearl 和 Dana Mackenzie。为什么之书：因果关系的新科学。Basic Books，2018。16. Yifan Hu、Yehuda Koren 和 Chris Volinsky。面向隐式反馈数据集的协同过滤。载于第*8*届 *IEEE* 国际数据挖掘会议，第263–272页，2008年。17. Andriy Mnih 和 Russ R Salakhutdinov。概率矩阵分解。载于神经信息处理系统进展，2007年。18. Yehuda Koren、Robert Bell 和 Chris Volinsky。推荐系统的矩阵分解技术。*IEEE Computer*，42(8):30–37，2009年。19. Hong-Jian Xue、Xinyu Dai、Jianbing Zhang、Shujian Huang 和 Jiajun Chen。用于推荐系统的深度矩阵分解模型。载于国际人工智能联合会议，第17卷，第3203–3209页，2017年。20. Shuai Zhang、Lina Yao、Aixin Sun 和 Yi Tay。基于深度学习的推荐系统：综述与新视角。*ACM Computing Surveys*，52(1):1–38，2019年。21. Yao Wu、Christopher DuBois、Alice X Zheng 和 Martin Ester。用于 Top-N 推荐系统的协同去噪自编码器。载于第*9*届 *ACM* 国际网络搜索与数据挖掘会议论文集，第153–162页，2016年。22. Dawen Liang、Rahul G Krishnan、Matthew D Hoffman 和 Tony Jebara。用于协同过滤的变分自编码器。载于万维网会议论文集，第689–698页，2018。23. Yaochen Zhu 和 Zhenzhong Chen。用于推荐系统的互正则化双重协同变分自编码器。载于*2022*年 *ACM*网络会议论文集，第2379–2387页，2022。24. Shuyuan Xu、Yingqiang Ge、Yunqi Li、Zuohui Fu、Xu Chen 和 Yongfeng Zhang。因果协同过滤。*arXiv* 预印本 *arXiv:2102.01868*，2021年。25. Wenjie Wang、Fuli Feng、Xiangnan He、Xiang Wang 和 Tat-Seng Chua。用于缓解偏差放大的去混杂推荐。载于第*27*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集，第1717–1725页，2021年。26. Yinwei Wei、Xiang Wang、Liqiang Nie、Xiangnan He、Richang Hong 和 Tat-Seng Chua。MMGCN：用于微视频个性化推荐的多模态图卷积网络。载于第*27*届 *ACM* 国际多媒体会议论文集，第1437–1445页，2019年。

27. Wenjie Wang、Fuli Feng、Xiangnan He、张汉旺和 Tat-Seng Chua。点击可能骗人：用于缓解标题党问题的反事实推荐。载于第*44*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第1288–1297页，2021年。28. Yehuda Koren。因子分解与邻域相遇：一种多面向的协同过滤模型。载于第*14*届 *ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，第426–434页，2008年。29. Yaochen Zhu 和 Zhenzhong Chen。面向混合推荐系统的变分带宽自编码器。*IEEE* 知识与数据工程汇刊，2022年。30. Steffen Rendle。因子分解机。载于*IEEE* 国际数据挖掘大会，第995–1000页。IEEE，2010年。31. Xiangnan He 和 Tat-Seng Chua。面向稀疏预测分析的神经因子分解机。载于第*40*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第355–364页，2017年。32. Yunqi Li、Hanxiong Chen、Juntao Tan 和 Yongfeng Zhang。用于稳健推荐的因果因子分解机。载于第*22*届 *ACM/IEEE* 数字图书馆联合会议论文集，第1–9页，2022年。33. 吉多·W·伊本斯和 Donald B Rubin。统计学、社会科学与生物医学科学中的因果推断。剑桥大学出版社，2015年。34. Judea Pearl。因果关系。剑桥大学出版社，2009年。35. 王晓杰、张瑞、孙宇和齐建中。利用少量无偏评分应对推荐系统中的选择偏差。载于第*14*届 *ACM* 国际网络搜索与数据挖掘会议论文集，第427–435页，2021年。36. 刘都刚、程鹏翔、董振华、何秀强、潘伟科和明忠。通过均匀数据实现反事实推荐的通用知识蒸馏框架。载于第*43*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第831–840页，2020年。37. 王宣辉、Nadav Golbandi、Michael Bendersky、Donald Metzler 和 Marc Najork。个性化搜索中无偏学习排序的位置偏差估计。载于第*11*届 *ACM* 国际网络搜索与数据挖掘会议论文集，第–页，2018年。38. Himan Abdollahpouri、Robin Burke 和 Bamshad Mobasher。控制学习排序推荐中的流行度偏差。载于第*11*届 *ACM* 推荐系统会议论文集，第42–46页，2017年。39. Tobias Schnabel、Adith Swaminathan、Ashudeep Singh、Navin Chandak 和 Thorsten Joachims。作为干预的推荐：学习与评估的去偏。载于国际机器学习会议，第1670–1679页，2016年。40. Peng Wu、李昊轩、邓宇豪、胡文杰、戴全宇、董振华、孙杰、张瑞和周晓华。论推荐系统中因果学习的机遇：基础、估计、预测与挑战。载于国际人工智能联合会议论文集，奥地利维也纳，第23–29页，2022年。41. Stephen Bonner 和 Flavian Vasile。用于推荐的因果嵌入。载于第*12*届 *ACM* 推荐系统会议论文集，第104–112页，2018年。42. Yixin Wang、Dawen Liang、Laurent Charlin 和 David M Blei。推荐系统中的因果推断。载于第*14*届 *ACM* 推荐系统会议论文集，第–页，2020年。43. Harald Steck。基于非随机缺失数据训练和测试推荐系统。载于第*16*届 *ACM SIGKDD* 国际知识发现与数据挖掘会议论文集，第713–722页，2010年。44. Amit Sharma、Jake M Hofman 和 Duncan J Watts。根据观察数据估计推荐系统的因果影响。载于第*16*届 *ACM* 经济学与计算会议论文集，第453–470页，2015年。45. Masahiro Sato、Janmajay Singh、Sho Takemori、Takashi Sonoda、张倩和 Tomoko Ohkuma。基于提升的推荐系统评估与优化。载于第*13*届 *ACM* 推荐系统会议论文集，第296–304页，2019年。

46. Jiawei Chen、Hande Dong、Xiang Wang、Fuli Feng、Meng Wang 和 Xiangnan He。推荐系统中的偏差与去偏：综述与未来方向。*arXiv* 预印本 *arXiv:2010.03240*，2020年。47. Shuyuan Xu、Juntao Tan、Zuohui Fu、Jianchao Ji、Shelby Heinecke 和 Yongfeng Zhang。动态因果协同过滤。载于第*31*届 *ACM* 信息与知识管理国际会议论文集，第2301–2310页，2022年。48. Yang Zhang、Fuli Feng、Xiangnan He、Tianxin Wei、Chonggang Song、Guohui Ling 和 Yongdong Z hang。通过因果干预利用推荐中的流行度偏差。载于第*44*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第11–20页，2021年。49. Daphne Koller 和 Nir Friedman。概率图模型：原理与技术。麻省理工学院出版社，2009年。50. Thomas S Richardson 和 James M Robins。单世界干预图（SWIG）：统一反事实与因果关系图模型方法。华盛顿大学统计与社会科学中心丛书，128(30):2013，2013年。51. Tianxin Wei、Fuli Feng、Jiawei Chen、Ziwei Wu、Jinfeng Yi 和 Xiangnan He。用于消除推荐系统流行度偏差的模型无关反事实推理。载于第*27*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集，第1791–1800页，2021年。52. Aman Agarwal、Kenta Takatsu、Ivan Zaitsev 和 Thorsten Joachims。反事实学习排序的通用框架。载于第*42*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第5–14页，2019年。53. Jiawei Chen、Hande Dong、Yang Qiu、Xiangnan He、Xin Xin、Liang Chen、Guli Lin 和 Keping Yang。Autodebias：学习实现推荐去偏。载于第*44*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第21–30页，2021年。54. Shuyuan Xu、Juntao Tan、Shelby Heinecke、Jia Li 和 Yongfeng Zhang。去混杂因果协同过滤。*arXiv* 预印本 *arXiv:2110.07122*，2021年。55. Xinyuan Zhu、Yang Zhang、Fuli Feng、Xun Yang、Dingxian Wang 和 Xiangnan He。缓解因果推荐中的隐性混杂效应。*arXiv* 预印本 *arXiv:2205 07499*，2022。。56. Yu Zheng、Chen Gao、Xiang Li、Xiangnan He、Yong Li 和 Depeng Jin。通过因果嵌入分离用户兴趣与从众性以实现推荐。载于*2021*年万维网大会论文集，第2980–2991页，2021年。57. Masahiro Sato、Sho Takemori、Janmajay Singh 和 Tomoko Ohkuma。针对推荐因果效应的无偏学习。载于第*14*届 *ACM* 推荐系统会议，第378–387页，2020年。58. Paul R Rosenbaum 和 Donald B Rubin。倾向得分在因果效应观察性研究中的核心作用。*Biometrika*，70(1):41–55，1983年。59. Yang Zhang、Wenjie Wang、Peng Wu、Fuli Feng 和 Xiangnan He。因果推荐：进展与未来方向。2022年万维网大会教程。https: // causalrec.github.io/file/www2022-tutorial-CausalRec.pdf。2022年4月26日。60. Dawen Liang、Laurent Charlin 和 David M Blei。面向推荐的因果推断。载于因果关系：从基础到应用，*UAI* 研讨会。*AUAI*，2016年。61. Prem Gopalan、Jake M Hofman 和 David M Blei。基于分层泊松分解的可扩展推荐。载于第*31*届人工智能不确定性会议论文集，第326–335页，2015年。62. Qingyao Ai、Keping Bi、Cheng Luo、Jiafeng Guo 和 W Bruce Croft。通过无偏倾向度估计实现无偏学习排序。载于第*41*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第385–394页，2018年。63. Wenhao Zhang、Wentian Bao、Xiao-Yang Liu、Keping Yang、Quan Lin、Hong Wen 和 Ramin Ramezani。利用多任务学习，通过大规模因果方法对点击后转化率估计进行去偏。载于*2020*年万维网大会论文集，2781，第–页，2020年。

64. Zhenlei Wang、Shiqi Shen、Zhipeng Wang、Bo Chen、Xu Chen 和 Ji-Rong Wen。利用潜在混杂因素实现无偏序列推荐。载于*ACM Web Conference 2022*论文集，第2195–2204页，2022年。65. Chang Zhou、Jianxin Ma、Jianwei Zhang、Jingren Zhou 和 Hongxia Yang。面向大规模推荐系统中去偏候选生成的对比学习。载于第*27*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集，第 3985–3995 页，2021 年。66. Léon Bottou、Jonas Peters、Joaquin Quiñonero-Candela、Denis X Charles、D Max Chickering、Elon Portugaly、Dipankar Ray、Patrice Simard 和 Ed Snelson。反事实推理与学习系统：以计算广告为例。机器学习研究杂志，14(11)，2013年。67. Yuta Saito、Suguru Yaginuma、Yuta Nishino、Hayato Sakata 和 Kazuhide Nakata。基于非随机缺失隐式反馈的无偏推荐学习。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。68. Ziwei Zhu、Yun He、Yin Zhang 和 James Caverlee。通过组合联合学习实现无偏隐式推荐和倾向度估计。载于第*14*届 *ACM* 推荐系统会议，第551–556页，2020年。69. Yixin Wang 和 David M Blei。多重原因的益处。美国统计学会会刊，114(528):1574–1596，2019年。70. Hao Zou、Peng Cui、Bo Li、Zheyan Shen、Jianxin Ma、Hongxia Yang 和 Yue He。捆绑处理的反事实预测。载于神经信息处理系统进展，第19705–19715页，2020年。71. Yaochen Zhu、Jing Yi、Jiayi Xie 和 Zhenzhong Chen。面向推荐的深度因果推理。*arXiv*预印本 *arXiv:2201.02088*，2022年。72. Jing Ma、Ruocheng Guo、Aidong Zhang 和 Jundong Li。利用解耦混杂因素表示进行多重原因效应估计。载于国际人工智能联合会议，第2790–2796页，2021年。73. Diederik P Kingma 和 Max Welling。自编码变分贝叶斯。载于国际学习表征会议，2014年。74. Harald Steck。物品流行度与推荐准确率。载于第*5*届 *ACM* 推荐系统大会论文集，第125–132页，2011年。75. Himan Abdollahpouri、Masoud Mansoury、Robin Burke 和 Bamshad Mobasher。推荐中的流行度偏差并不公平。载于*RecSys*多利益相关者环境推荐研讨会，2019年。76. Ziwei Zhu、Yun He、Xing Zhao 和 James Caverlee。动态推荐中的流行度偏差。载于第*27*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集，第2439–2449页，2021年。77. Zihao Zhao、Jiawei Chen、Sheng Zhou、Xiangnan He、Xuezhi Cao、Fuzheng Zhang 和 Wei Wu。流行度偏差并非总是有害：解耦推荐中的良性偏差与有害偏差。*IEEE* 知识与数据工程汇刊，2022年。78. Zhihong Chen、Jiawei Wu、Chenliang Li、Jingxu Chen、Rong Xiao 和 Binqiang Zhao。用于在推荐系统中利用流行度偏差的协同训练解耦域适应网络。载于第*45*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第60–69页，2022年。79. Judea Pearl。直接效应与间接效应。载于第*17*届人工智能不确定性大会论文集，*2001*年，第411–420页，2001年。80. Yunqi Li、Hanxiong Chen、Zuohui Fu、Yingqiang Ge 和 Yongfeng Zhang。推荐中的面向用户的公平性。载于*The Web Conference 2021*论文集，632，2021 624页–。81. Yushun Dong、Jing Ma、Chen Chen 和 Jundong Li。图挖掘中的公平性：综述。*arXiv*预印本 *arXiv:2204.09888*，2022年。82. Yunqi Li、Hanxiong Chen、Shuyuan Xu、Yingqiang Ge、Juntao Tan、Shuchang Liu 和 Yongfeng Zhang。推荐中的公平性：综述。*arXiv*预印本 *arXiv:2205 13619*，2022年。。

83. Yunqi Li、Hanxiong Chen、Shuyuan Xu、Yingqiang Ge 和 Yongfeng Zhang。基于因果概念实现个性化公平。载于第*44*届国际 *ACM SIGIR* 信息检索研究与发展大会论文集，第1054 1063页，2021年–。84. Ian Goodfellow、Jean Pouget-Abadie、Mehdi Mirza、Bing Xu、David Warde-Farley、Sherjil Ozair、Aaron Courville 和 Yoshua Bengio。生成对抗网络。*ACM*通讯，63(11):139–144，2020年。85. Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。BPR：基于隐式反馈的贝叶斯个性化排序。载于第*25*届人工智能不确定性大会，第452–461页，2009年。86. Hao Wang、Huawei Shen、Wentao Ouyang 和 Xueqi Cheng。利用兴趣点特定地理影响进行兴趣点推荐。载于第*27*届国际人工智能联合会议论文集，第3877–3883页，2018。87. Yongfeng Zhang、Xu Chen 等。可解释推荐：综述与新视角。信息检索基础与趋势，14(1):1–101，2020年。88. Jianxin Ma、Chang Zhou、Peng Cui、Hongxia Yang 和 Wenwu Zhu。学习用于推荐的解耦表示。载于神经信息处理系统进展，2019年。89. Xiangmeng Wang、Qian Li、Dianer Yu、Peng Cui、Zhichao Wang 和 Guandong Xu。用于语义感知意图学习的因果解耦。*IEEE* 知识与数据工程汇刊，2022年。90. Juntao Tan、Shuyuan Xu、Yingqiang Ge、Yunqi Li、Xu Chen 和 Yongfeng Zhang。反事实可解释推荐。载于第*30*届 *ACM* 国际信息与知识管理会议论文集，第1784–1793页，2021年。91. Shuyuan Xu、Yunqi Li、Shuchang Liu、Zuohui Fu、Yingqiang Ge、Xu Chen 和 Yongfeng Zhang。学习推荐的因果解释。载于第一届搜索与推荐因果性国际研讨会，2021年。92. Paras Sheth、Ruocheng Guo、Kaize Ding、Lu Cheng、K Selçuk Candan 和 Huan Liu。利用网络信息进行因果解耦，实现去偏推荐。载于相似性搜索与应用国际会议，第265–273页，2022年。93. Martin Arjovsky、Léon Bottou、Ishaan Gulrajani 和 David Lopez-Paz。不变风险最小化。*arXiv*预印本 *arXiv:1907.02893*，2019年。94. Raphael Suter、Djordje Miladinovic、Bernhard Schölkopf 和 Stefan Bauer。鲁棒的解耦因果机制：验证深度表示的干预鲁棒性。载于国际机器学习大会，第6056–6065页，2019年。95. Mengyue Yang、Furui Liu、Zhitang Chen、Xinwei Shen、Jianye Hao 和 Jun Wang。Causal-VAE：通过神经结构因果模型进行解耦表示学习。载于 *IEEE/CVF* 计算机视觉与模式识别会议论文集，第9593–9602页，2021年。96. Guy Shani 和 Asela Gunawardana。评估推荐系统。载于推荐系统手册，第257–297页。施普林格，2011年。97. Yaochen Zhu、Xubin Ren、Jing Yi 和 Zhenzhong Chen。利用因果干预，为用户生成内容进行深度去混杂的基于内容标签推荐。*arXiv*预印本 *arXiv:2205 14380*，2022年。。98. Jing Yi 和 Zhenzhong Chen。面向基于内容的微视频背景音乐推荐的去偏跨模态匹配。*arXiv*预印本 *arXiv:2208.03633*，2022年。99. Benjamin M Marlin、Richard S Zemel、Sam Roweis 和 Malcolm Slaney。协同过滤与随机缺失假设。载于第*23*届人工智能不确定性大会论文集，第267–275页，2007年。100. Benjamin M Marlin 和 Richard S Zemel。基于非随机缺失数据的协同预测与排序。载于第*3*届 *ACM* 推荐系统大会论文集，第5–12页，2009年。101. Chongming Gao、Shijun Li、Wenqiang Lei、Jiawei Chen、Biao Li、Peng Jiang、Xiangnan He、Jiaxin Mao 和 Tat-Seng Chua。KuaiRec：一个完全观测的数据集及其洞见，用于

推荐系统评估。载于第*31*届 *ACM* 信息与知识管理国际会议论文集，2022年。102. 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* 国际知识发现与数据挖掘会议论文集，第1059–1068页，2018年。103. Eustache Diemert、Artem Betlei、Christophe Renaudin 和 Massih-Reza Amini。用于增益建模的大规模基准。载于*AdKDD* 和 *TargetAd*研讨会论文集，2018年。104. Djallel Bouneffouf、Amel Bouzeghoub 和 Alda Lopes Gançarski。用于移动上下文感知推荐系统的上下文老虎机算法。载于神经信息处理国际会议，第324–331页。施普林格，2012年。105. Yuta Saito、Shunsuke Aihara、Megumi Matsutani 和 Yusuke Narita。面向老虎机算法的大规模开放数据集、流水线和基准。*arXiv*预印本 *arXiv:2008 07146*，2020年。。106. Wenjie Wang、Xinyu Lin、Fuli Feng、Xiangnan He、Min Lin 和 Tat-Seng Chua。面向分布外推荐的因果表征学习。载于 *ACM Web Conference 2022*论文集，第3562–3571页，2022年。107. Jing Ma 和 Jundong Li。利用图学习因果关系。《*AI Magazine*》，2022年。108. Qian Li、Xiangmeng Wang、Zhichao Wang 和 Guandong Xu。实现因果推荐：消除推荐中的社交网络混杂偏差。*ACM Transactions on Knowledge Discovery from Data*，2022年。109. Jing Ma、Mengting Wan、Longqi Yang、Jundong Li、Brent Hecht 和 Jaime Teevan。学习超图上的因果效应。载于第*28*届 *ACM SIGKDD*知识发现与数据挖掘会议论文集，第1202–1212页，2022年。