# 推荐中的因果推断：基础、方法与应用

Shuyuan Xu、Jianchao Ji、Yunqi Li、Yingqiang Ge、Juntao Tan、Yongfeng Zhang

**摘要**——推荐系统是各种个性化服务中重要而强大的工具。传统上，这些系统利用数据挖掘和机器学习技术，根据数据中发现的相关性进行推荐。然而，如果仅仅依赖相关性而不考虑其潜在的因果机制，可能会导致各种实际问题，例如公平性、可解释性、鲁棒性、偏差、回音室以及可控性问题。因此，相关领域的研究人员开始将因果关系引入推荐系统，以解决这些问题。本文综述了推荐系统中因果推断的现有文献。我们讨论了推荐系统和因果推断的基本概念及其相互关系，并回顾了针对推荐系统中不同问题的因果方法相关研究。最后，我们探讨了推荐领域因果推断的开放问题和未来方向。

**索引词**——推荐系统、因果推断

arXiv:2301.04016v1 [cs.IR] 8 Jan 2023

## 1 引言

推荐系统已被公认为缓解信息过载最有效的工具之一，并已广泛应用于许多现实世界的系统中，例如电子商务平台（如 Amazon、eBay）、社交网络（如 Facebook、Twitter）、视频分享平台（如 YouTube、TikTok）以及流媒体服务（如 Netflix、Hulu）。通常，这些系统利用先进技术，根据历史数据以及收集到的用户、物品和内容信息来学习用户偏好。近年来，这些技术发展迅速。

一般来说，推荐算法可分为三大类：协同过滤、基于内容的推荐和混合方法[1, 2, 3]。协同过滤（CF）模型基于一个核心思想：相似用户可能有相似的兴趣，而相似物品可能会被相似用户喜欢。早期基于记忆的 CF 模型，例如基于用户的协同过滤 [4, 5] 和基于物品的 CF [6, 7]，，将用户-物品评分矩阵的行向量或列向量作为用户和物品的向量表示，并基于预定义的相似度函数（如余弦相似度和皮尔逊相关系数）计算用户或物品之间的相似度，用于推荐。为了从矩阵中提取潜在语义，研究人员随后开始探索学习得到的用户和物品向量表示。这一研究始于潜因子模型（LFM），例如矩阵分解 [8], 、概率矩阵分解 [9]和分解机 [10],，这些模型在实践中得到了广泛采用。在这些模型中，每个用户和物品都被学习为潜在表示，通常基于内积计算每个用户-物品对的匹配分数。深度学习和神经网络的发展进一步拓展了 CF 模型。例如， [11, 12, 13, 14] 采用简单的用户和物品表示（如独热向量），并学习复杂的匹配函数。 [15, 16, 17, 18, 19] 学习复杂的用户和物品表示，并采用简单的匹配函数（如内积）。用户表示也可以直接根据历史交互计算，例如序列推荐 [20, 21]。基于内容的推荐会利用有关用户和物品的丰富信息，甚至上下文信息，以增强推荐效果。为了基于辅助信息学习物品之间的相似度，基于内容的推荐所采用的表示方法已从 TF-IDF 等简单模型 [22] 发展到 DNN [23], 、卷积神经网络 [24], 等基于深度学习的模型。混合方法将协同过滤与基于内容的方法相结合，既发挥两种方法的优势，又避免其各自的局限 [1, 2, 25]。

传统推荐算法的基础是从数据中挖掘或学习相关模式。例如，许多协同过滤模型旨在学习用户与物品之间的相关模式，而一些基于内容的推荐模型旨在学习特征之间的相关模式。然而，现实世界中的应用受潜在因果机制驱动；如果只进行相关性学习而不考虑因果关系，就会导致一些实际问题。我们以经典的“啤酒与尿布”问题为例。单纯的相关性学习会学到啤酒与尿布之间的强相关模式，因此会向购买尿布的客户推荐啤酒，反之亦然。然而，背后的机制是年轻父亲通常会同时购买啤酒和尿布；若不考虑这一潜在机制就推荐啤酒或尿布，会令人困惑，进而损害用户的满意度。因此，从相关性学习转向因果学习至关重要。

严格来说，因果推断研究的是因与果之间的因果关系，其中原因负责产生结果。两种著名且广为采用的框架是潜在结果框架（也称为 Neyman–Rubin 潜在结果或鲁宾因果模型） [26]和结构因果模型（SCM） [27, 28]。

作者供职于美国罗格斯大学计算机科学系。邮箱： {*shuyuan.xu, jianchao.ji, yunqi.li, yingqiang.ge, juntao.tan, yongfeng.zhang*}*@rutgers.edu*

这两种因果框架都推动了因果推荐的发展。通过利用推荐系统中的底层因果机制，因果推荐能够应对各种实际问题，包括可解释性、公平性、鲁棒性、增益和无偏性。

**本综述的贡献**。 本综述旨在全面回顾推荐中的因果推断。我们首先介绍推荐系统的基础知识，然后探讨推荐中的因果推断相关现有研究。具体而言，我们从两个维度探讨推荐系统中的因果推断。第一个维度遵循因果推断的流程，涵盖因果推断的概念、符号表示和技术，以及因果推断与推荐系统之间的联系。第二个维度围绕推荐中的实际问题展开，包括问题介绍、因果方法和开放问题。更具体地说，我们涵盖推荐中的可解释性、公平性、鲁棒性、基于增益的方法和无偏性。最后，我们指出了推荐中的因果推断领域仍有待解决的若干开放问题。

**与现有综述的区别**。 近年来，推荐系统或因果推断领域发表了多篇综述。例如，Zhang 等人 [29]和 Chen 等人 [30]回顾了可解释推荐，Li 等人[31] 和 Wang 等人 [32]回顾了推荐公平性，Ge 等人 [33], 、Wang 等人 [34] 和 Fan 等人 [35]总结了可信推荐系统，Chen 等人 [36] 回顾了推荐中的偏差，Zhang 等人 [2] 回顾了基于深度学习的推荐算法，Ko 等人 [37]全面回顾了推荐系统，Yao 等人 [38] 全面回顾了因果推断方法，Guo 等人 [39] 和 Vowels 等人 [40]总结了因果结构学习和因果发现方面的现有方法。Gao 等人 [41]总结了推荐系统中因果推断的现有研究。与 Gao 等人 [41] 主要从推荐系统的视角介绍现有研究不同，我们的综述从因果推断和推荐系统两个视角对相关工作进行了系统回顾。

**组织结构**。本文综述的结构如下：第2节介绍推荐系统的基础知识。第3节至第7节介绍因果推断的基本知识及其与推荐系统的联系。第8节至第12节分别介绍现有的因果方法在可解释推荐、推荐中的公平性、基于增益的推荐、鲁棒推荐和无偏推荐中的应用。第13节讨论推荐中的因果推断所面临的一些开放问题和未来方向。第14节总结本文综述。

## 2 推荐系统基础

一般而言，推荐系统旨在根据收集到的信息对用户偏好进行建模，这些信息包括用户资料、物品档案和用户-物品交互，并进一步预测用户未来的交互。用户资料代表用户注册的信息，可能包括用户 ID、用户年龄、用户性别、用户收入等。推荐系统可能仅使用部分信息进行推荐（例如，仅使用用户 ID）。“物品”一词在不同的推荐系统中代表不同的对象（例如，电子商务中的商品、社交网络中的其他用户、在线视频平台中的视频等）。根据“物品”的不同定义，物品档案可能包含不同的物品特征。例如，电子商务中的商品，其物品档案可能包含品牌、类别、价格、图像等；在视频推荐中，在线视频平台上的视频，其物品档案可能包含视频时长、内容描述等；社交网络中的其他用户，则可能以相应的用户资料作为物品档案。同样，推荐系统可能仅使用物品档案中的部分信息进行推荐。交互是指根据所定义的任务，用户对物品可能产生的行为（例如，电子商务推荐中的点击、购买、评分、加入购物车、评论，以及视频推荐中的点赞、点踩、分享等）。一般而言，推荐系统中的交互通常有两种表示方式：一种是显式反馈，另一种是隐式反馈。显式反馈（如评分和评论）是用户偏好的明确表达（例如，评分为 5 表示用户喜欢该物品）；而隐式反馈（如点击）是在用户与系统的交互过程中收集的，并隐含地反映用户偏好（例如，用户的点击行为意味着用户很可能喜欢相应的物品）。

传统推荐算法大致可分为协同过滤、基于内容的推荐和混合模型。协同过滤（CF）的基本思想是，相似的用户可能有相似的兴趣，而相似的物品可能会被相似的用户点赞。CF 方法还可进一步分为基于记忆的协同过滤和基于模型的协同过滤。基于记忆的协同过滤通过对历史数据进行简单的相似度度量来进行预测。例如，基于用户的协同过滤 [4, 5] 或基于物品的协同过滤 [6, 7] 会将用户-物品评分矩阵的行向量或列向量作为每个用户或物品的表示，并通过余弦相似度等简单度量计算相似度。基于模型的协同过滤则利用模型学习用户和物品的表示，以进行预测。它始于潜因子模型，例如矩阵分解 [8],概率矩阵分解[9], 张量分解 [42], 等。深度学习和神经网络进一步拓展了 CF 模型。深度协同过滤方法还可进一步分为相似度学习方法和表示学习方法。相似度学习方法 [15, 16, 17, 18, 19]使用用户和物品的简单表示（例如独热向量），并学习复杂的匹配函数，从而对每个用户-物品对进行预测。表示学习方法则学习用户和物品的复杂表示，然后应用简单的匹配函数（例如内积）计算预测分数。另一方面，基于内容的推荐[23, 24, 43, 44, 45, 46, 47], 依赖丰富的用户和物品档案，向用户推荐与其过去偏好的物品相似的物品。例如，在电影推荐系统中，模型会尝试理解用户过去评分较高的电影所具有的特征（例如演员、导演、类型、标签等）。随后，只推荐符合用户偏好特征的电影

混合模型结合协同过滤和基于内容的方法，兼取两种方法的优势并避免其某些局限性[1, 2, 25, 48, 49]。此外，若干研究（如 [50, 51],）通过实证证明，与单纯使用协同过滤或基于内容的方法相比，混合方法能够实现更准确的推荐。

除上述传统推荐算法外，还有其他一些推荐算法。序列推荐 [52] （也与基于会话或会话感知推荐有关）利用交互的时间戳信息来推荐物品，近年来在学术研究和工业应用中越来越受欢迎。传统的序列推荐模型采用简单的机器学习方法对序列数据进行建模，例如马尔可夫链 [53],、基于会话的 KNN [54]。随着深度学习技术的发展，许多深度模型在序列推荐中取得了显著成果，包括循环神经网络 [55],、长短期记忆网络 [56],、卷积神经网络 [57, 58], 、注意力模型 [59] 和记忆网络[60]。此外，随着基础模型（例如，大语言模型）在自然语言任务（例如，T5 [61], GPT-3 [62], OPT [63], PaLM [64]）上取得越来越大的成功，推荐系统领域利用推荐系统的独特特点，开展了个性化基础模型研究。例如，P 5 [65],作为一种用于推荐的预训练、个性化提示和预测范式，将推荐表述为一项语言理解与生成任务，从而为多种推荐任务提供基础模型。

推荐模型基于收集到的信息学习用户的偏好，并根据学到的偏好进行推荐。具体而言，推荐系统会向特定用户提供个性化推荐列表，并可能附上解释。推荐系统首先预测用户对一组候选物品的偏好，然后对候选物品进行排序，以提供个性化推荐列表。值得一提的是，排序过程不一定完全依据推荐算法提供的预测分数。系统也可能根据多样性、公平性或某些商业目的等不同需求，对列表重新排序。生成个性化推荐列表后，一些推荐系统可能会在推荐内容旁附上解释。根据推荐模型是可解释的还是黑箱，解释可以与推荐同时生成，也可以在推荐之后生成。

为了评估推荐系统的性能，定义优秀推荐系统的特征并量化这些特征至关重要。对于能够预测评分的推荐模型，优秀的模型应能够准确预测评分。因此，通常使用均方根误差或均方误差来评估推荐性能。考虑到排序列表的准确性，以及列表是否推荐了用户偏好的物品，一些常用指标包括精确率、召回率、F度量、归一化折损累计增益、ROC曲线、曲线下面积、平均倒数排名等。除了上述用于评估推荐性能的指标外，还有一些指标用于从其他目的的角度评估推荐模型。例如，绝对差值（AD） [66] 用于评估推荐系统的公平性。

## 3 推荐中的因果记法

因果推断是源自统计学的一项重要研究课题 [28, 67, 68],，数十年来已广泛应用于计算机科学、公共政策、经济学等诸多领域。本节将介绍因果记法，并说明如何将其应用于推荐。

### 3.1 什么是因果关系

因果关系（也称为因果性）是一个术语，通常会与相关性进行比较和讨论。尽管相关性和因果关系都探讨变量之间的关系，但众所周知，“相关性并不意味着因果关系” [68]。因果关系比相关性更进一步。直观来说，因果关系明确适用于事件 $A$ 导致事件 $B$发生的情形。另一方面，相关性是一种简单得多的关系，表示事件 $A$ 与事件 $B$相关，但一个事件不一定会导致另一个事件发生。例如，一项研究表明，美国每月冰淇淋销售额的数据与每月鲨鱼袭击次数高度相关。尽管这两个变量高度相关，但不能据此得出结论，认为吃冰淇淋会导致鲨鱼袭击（反之亦然）。更可能的情况是，由于天气暖和等其他因素，冰淇淋销售额和鲨鱼袭击事件都会在夏季增加，从而导致这两个变量相关。在推荐中也能找到类似的例子。啤酒与尿布故事很好地说明了推荐中因果关系与相关性的区别。有人观察到啤酒和尿布经常一起热销。基于纯粹的相关性学习，对于购买尿布的客户，应该推荐啤酒，反之亦然，因为啤酒和尿布之间存在很强的相关模式。然而，其背后的因果机制是，年轻的父亲可能会在买啤酒时顺便买些尿布。因此，若不考虑潜在的因果关系就直接推荐物品，可能会令人困惑，并降低推荐效果。总的来说，理解因果关系有助于我们更好地了解世界的运作方式，并提升推荐系统的性能。

要从理论上研究因果关系，就需要理解因果关系的数学表示。通常，因果推断有两种常用框架：一种是潜在结果框架（也称为 Neyman–Rubin 潜在结果或鲁宾因果模型） [26] ，另一种是 Pearl 提出的结构因果模型框架 [27, 28]。现有研究通常分别介绍这两种框架；然而，我们认为这两种框架在逻辑上等价 [28], 并遵循相似的直觉。接下来的章节将围绕因果关系的直观概念介绍这两种框架，包括它们之间的联系与区别。

### 3.2 因果关系的关键数学符号表示。

因果推断是指得出某项处理 是结果 的“原因”的过程，而该结果

已被观察到 [69]。在这种情况下，核心目标是估计应用了某项特定处理时的结果。这两种框架都使用数学符号表示来表述所需的值。对于鲁宾因果模型，其基本元素称为潜在结果。

**定义 1.** *(潜在结果)* 潜在结果是指个体在接受某种可能的处理时所产生的结果

令 $X(X \in \{x_1, x_2, \cdots, x_n\})$ 表示处理，其中 $n$ 为可能处理的总数。大多数文献研究二元处理，例如，服药记为 $X = 1$，不服药记为 $X = 0$。在二元处理下，接受处理 $X = 1$ 的个体群体称为处理组，接受处理 $X = 0$ 的个体群体称为对照组。通常，处理取值为 $x_i$ 时的潜在结果记为 $Y(X = x_i)$，可简写为 $Y(x_i)$。处理取值为 $x_i$ 时的平均潜在结果可记为 $\mathbb{E}[Y(x_i)]$。对于任何个体，在保持其他变量不变的情况下，只能施加一种处理，因此只能观测到一个潜在结果。因此，潜在结果可进一步分为两类：观测到的潜在结果称为观测结果，其余未观测到的潜在结果称为反事实结果。

在推荐中，结果通常定义为用户行为（例如点击、购买）或用户偏好（例如评分）。无偏推荐模型将处理定义为曝光，其中观测反馈 $Y$（即观测结果）可以建模为两个未观测变量曝光 $O$ 和相关性 $R$ （即$Y = O \cdot R$） [70, 71, 72, 73, 74]的乘积。更具体地说，在推荐系统中，$Y = 0$可以是负样本（即$R = 0$）或潜在正样本（即 $R = 1$, $O = 0$），这会导致推荐中的数据偏差。为了实现个性化推荐，模型通常会估计特定用户-物品对（$u, v$）的潜在结果 $Y_{u,v}$（即$Y_{u,v} = O_{u,v} \cdot R_{u,v}$）。通过正确估计潜在结果 $Y_{u,v}$（$O_{u,v} = 1$）（即$R_{u,v} = Y_{u,v}$ ($O_{u,v} = 1$)），所设计的模型能够实现无偏推荐。基于增益的推荐模型将处理定义为推荐（即，推荐时为 1，不推荐时为 0） [75]。对于每个观测到的用户-物品对，只能观测到一种处理（即推荐或不推荐）。因此，估计反事实结果以计算推荐的增益值是一项挑战。为了实现公平性，处理也可以定义为敏感属性 [76]（例如，特权组为 1，弱势组为 0）。

除了处理变量和结果变量之外，还可以观察到其他一些变量，这些变量又可进一步分为处理前变量和处理后变量 [38]。

**定义 2.** （处理前变量）处理前变量是不受处理影响的变量，也称为背景变量。

**定义 3.** （处理后变量）处理后变量是指受到处理影响的变量。

不同的推荐场景可能包含不同的信息和因果机制，因此处理前变量和处理后变量的具体定义可能有所不同。

除了潜在结果之外，Pearl 还使用另一种常见表示法，从概率的角度通过 $do$-运算 [27, 68] 来区分相关性与因果关系。假设 $X$ 表示处理，$Y$ 表示结果，那么相关性与因果关系关注的是不同的概率。具体而言，相关性根据观察数据估计条件概率 $P(Y|X)$，以确定 $X$ 与 $Y$之间的相关关系。相比之下，因果推断估计 $P(Y|do(X = x_i))$，表示在可能的处理 $x_i$下的结果；其中，$do$-运算直观地表示施加处理，而不是观察处理。施加处理 $x_i$ 的平均结果可表示为 $\mathbb{E}[Y|do(X = x_i)]$。特定概率 $P(Y = y|do(X = x))$可简化为 $P(y|do(x))$。正如前文所述，现有因果框架遵循相同的直觉，因此，在大多数情况下， $do$-运算和潜在结果的数学符号表示可以相互转换。例如，在无偏推荐模型中，处理通常定义为曝光。用户-物品对（$u, v$）在曝光下的结果可表示为$P(Y|u, v, do(X = 1))$，其中 $Y$是结果， $X$是曝光变量。如果将变量 $V$定义为曝光物品，那么也可以表示为 $P(Y|u, do(V = v))$。同样，基于增益的推荐和推荐公平性中的因果记法也可以用 $do$-运算表示。

通过定义 $do$-操作，干预作为因果推断中的一个基本概念，可以得到形式化定义。如上所述， $do$-操作表示应用处理，也可以定义为对处理变量的干预。我们将在第6节中介绍更多细节。反事实是潜在结果框架和结构因果模型中的一个重要概念，表示与事实的差异。更具体地说，反事实表示处理变量的取值与事实世界中观测到的取值不同的情形。例如，假设处理是服用药物，结果是康复，那么一位服药后康复的患者可能会想，如果自己没有服药，是否也能康复。在这种情况下，在事实世界中，患者服用了药物并康复；而在反事实世界中，患者没有服用药物，我们想知道他是否会康复。推荐系统中也有类似的例子：对于基于增益的推荐，处理被定义为推荐，结果被定义为用户行为，系统旨在最大化推荐所带来的用户行为增量。然而，在事实世界中，物品不可能既被推荐又未被推荐，因此有必要将反事实应用于推荐。反事实已广泛应用于推荐系统，以解决实际问题，并取得了巨大成功。我们将在本综述中详细介绍。

**4 推荐中的因果假设**

本节将介绍因果推断中常用的假设 [38]。

**定义 4.**（稳定单元处理值假设（***SUTVA***））任何个体的潜在结果都不会因分配给其他个体的处理而改变；并且对每个个体而言，每个处理水平都不存在会导致不同潜在结果的不同形式或版本。

这一假设强调每个个体的独立性，即个体之间不存在相互联系。在推荐中，个体通常指用户。传统推荐隐含地假设用户之间相互独立，因此满足 SUTVA 假设。然而，在实际的推荐系统中，这一假设并非总是成立。例如，在社交网络推荐中，用户可能通过网络结构彼此连接。有些推荐模型不包含显式用户，例如基于会话的推荐。在这种情况下，个体可以视为会话，而会话之间存在时间上的联系。

**定义 5.**（可忽略性）给定变量 $W$（这些变量不受处理影响），处理分配 $X$ 与潜在结果相互独立，即 $Y(1)\ Y(0) \perp\!\!\!\perp X|W$。

可忽略性假设也称为无混杂假设。该假设在一定条件下定义了处理分配。具体而言，对于具有相同变量 $W$ 的个体，处理分配是随机的。许多推荐算法都接受这一假设；然而，在现实世界的推荐系统中，可能存在未观测到的变量，同时影响处理和结果，已有研究对此进行了探讨 [77, 78]。

**定义 6.**（正值性）对于变量 $W$ 的任意取值（这些变量不受处理影响），处理分配不是确定性的：

$$P(X = x|W = w) > 0, \quad \forall x \text{ and } w. \tag{1}$$

这一假设保证了估计处理效应的可行性和意义。如果 $W$ 的某些取值对应的处理分配是确定性的，那么对于这些取值，至少一种处理的结果将永远无法观测。在这种情况下，估计处理效应既不切实际，也没有意义。在推荐算法设计中，这些假设成立。对于每个用户，每一种

物品有机会展示给用户。无法展示的物品不属于推荐系统的研究范围。

基于上述三个假设，可以建立观测结果与潜在结果之间的联系。

$$\begin{aligned}\mathbb{E}[Y(x)|W = w] =& \mathbb{E}[Y(x)|W = w, X = x] \\ =& \mathbb{E}[Y|W = w, X = x]\end{aligned} \tag{2}$$

除了上述三种常用假设外，还有另一种表示假定机制的方式。

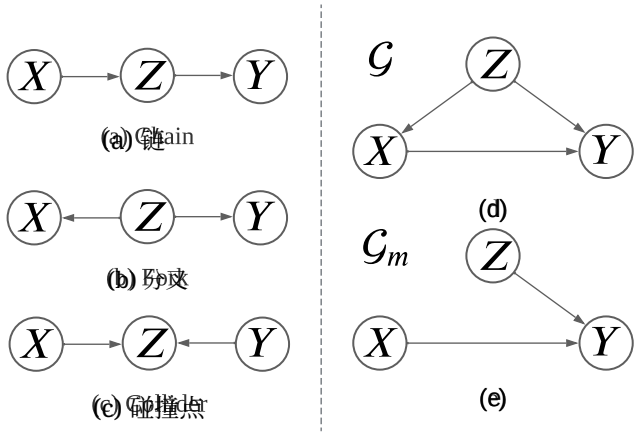



图 1. $X$、 $Y$、 $Z$ 代表三个变量。(a)-(c)展示了三种基本因果图。(d)展示了一个因果图示例，(e)则表示对变量 $X$进行干预时，(d)对应的干预图。

**定义 7.** **(**结构因果模型 **(**结构因果模型**))**结构因果模型由一组内生变量 $(V)$ 和一组外生变量 $(U)$ 构成，它们通过一组函数 $(F)$ 相连接，这些函数根据 $U$ 中变量的取值来确定 $V$ 中变量的取值。

SCM是Pearl因果框架中的核心概念，它对情境背后的机制提出了更强的假设（相比潜在结果框架），这些机制描述了处理和结果以外的变量之间的关系。每个SCM都与一个图模型 $\mathcal{G}$相关联，该模型表示为有向无环图（DAG），其中每个节点都是 $U$或 $V$中的一个变量，每条边都是一个函数 $f$。每条边都对应一个因果假设：如果变量 $Y$ 是变量 $X$的子节点，则假设 $X$ 是$Y$的直接原因；如果变量 $Y$ 是变量 $X$的后代节点，则假设 $X$ 是 $Y$的潜在原因。因果图是潜在结果框架与结构因果模型框架之间的关键区别：潜在结果框架不考虑用因果图来描绘因果关系。不过，我们认为这两种框架都建立在一些假设之上，而因果图只是更强的一项假设，因此无法将这两种框架完全区分开来。我们在图1中介绍了三种基本因果图。

因果图是表示推荐系统底层机制的一种直观方式，图1中的三种典型因果图也经常出现在推荐系统的机制中。例如，图1(a)中的链式结构出现在 [77], 中，其中物品决定物品固有特征，而物品固有特征进一步决定用户偏好；图1(b)中的分叉结构出现在 [79], 中，其中物品流行度被视为物品曝光和交互概率的共同原因；图1(c)中的碰撞结构出现在 [80], 中，其中用户点击是用户兴趣和从众性的共同结果。对于SCM，一项已有研究[81] 表明，传统推荐与因果推荐可以通过因果视角实现统一，在这种视角下，推荐模型旨在估计

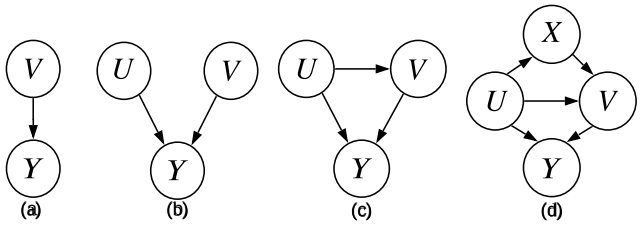



图2. 许多传统推荐方法和因果推荐方法都可以在不同的因果图框架下统一起来。在图中，$U$ 是用户，$V$ 是物品，$X$ 是用户交互历史，$Y$ 是偏好分数。(a) 非个性化模型的因果图。(b) 基于相似度匹配的协同过滤模型的因果图。(c) 考虑从用户到物品 [82]的因果关系的因果图。(d) [81]中使用的因果图。

$P$（$Y|U$，$do$（$X$））（即，$Y$表示用户偏好，$U$表示用户，$V$ 表示物品），但所采用的因果图不同。更多细节请参见图2。

如前所述，对处理变量进行干预 可以解释为对处理变量执行 $do$操作。直观而言，$do$操作意味着直接进行干预，从而切断其他变量对处理变量的影响。因此，考虑两个变量 $X$ 和 $Y$，所需的干预概率 $P(y|do(x))$ 可以直观地计算为 $P_m(y|x)$，即干预图上的观测概率。具体来说，干预图会移除所有指向处理变量的入边。例如，考虑图1(d)所示的简单因果图，其中 $X$ 是处理变量，$Y$是结果，$Z$ 是混杂因素。在原始因果图 $\mathcal{G}$ 上，$P(y|do(x))$与图1(e)所示的干预图 $\mathcal{G}_m$ 上的 $P_m(y|x)$ 相同。在推荐中，一个例子是对物品曝光进行干预，从而生成随机实验的数据（即数据生成过程遵循干预后的因果图）。我们将在第6节进一步介绍随机实验。与对因果图进行干预类似，对结构方程进行干预时，会将干预值作为输入，用于计算结构方程的输出。

引入的假设弥合了观测相关性与估计出的因果关系之间的差距。我们将介绍一些基于这些假设的常用方法。

## 5 推荐中的因果效应

介绍因果表示的基本表示后，可以用这些基本表示定义多种不同类型的因果效应。

一种基本的因果效应称为处理效应（即应用另一种处理时结果的变化）。更具体地说，处理效应可以在总体、处理组、亚组和个体层面进行测量。这里我们定义二元处理下的处理效应以便说明，并且可以通过比较不同处理的潜在结果将其扩展到多重处理 [38]。我们以潜在结果为例，$do$- 运算也可以采用类似方式应用。

总体层面的处理效应称为**平均处理效应（ATE）**（有些文献也将其称为**平均因果效应** [68] 或**总效应**[83]），其定义为：

$$ATE = \mathbb{E}[Y(1)] - \mathbb{E}[Y(0)] \tag{3}$$

处理组层面的处理效应称为**处理组平均处理效应（ATT）**（有些文献也将其称为**对处理组的处理效应（ETT）** [27, 68]），其定义如下：

$$ATT = \mathbb{E}[Y(1)|X = 1] - \mathbb{E}[Y(0)|X = 1] \tag{4}$$

其中，$Y(1)|X = 1$ 和 $Y(0)|X = 1$ 分别表示处理组在两种处理下的潜在结果。

在亚组层面，处理效应称为**条件平均处理效应（CATE）**，其定义如下：

$$CATE = \mathbb{E}[Y(1)|W = w] - \mathbb{E}[Y(0)|W = w] \tag{5}$$

其中，$W$ 表示定义亚组的变量（即按多个变量进行分组），这些变量不受处理影响；$Y(1)|W = w$ 和 $Y(0)|W = w$ 分别表示该亚组在两种处理下的潜在结果，其中 $W = w$。

在个体层面，处理效应称为**个体处理效应（ITE）**，可表示为：

$$ITE = Y_i(1) - Y_i(0) \tag{6}$$

其中，$Y_i(1)$ 和 $Y_i(0)$ 分别表示个体 $i$ 接受处理 $X = 1$ 和 $X = 0$ 时的潜在结果。如果每个亚组都代表一个个体，则ITE被认为等同于CATE [84, 85] 。

不同层面的处理效应已被用作推荐系统中的定量评估，以解决许多问题。例如，ITE用于估计推荐的增益值 [75, 86, 87, 88]；ATE可用于评估解释 [89] 并估计无偏偏好 [90]；ATT用于评估反事实公平性 [91]；等等。

除了上文介绍的不同层次的处理效应外，进行中介分析时还会涉及一些因果效应。中介模型通过引入第三个变量（称为中介变量），旨在解释处理与结果之间因果关系的形成过程。令 $X$、$Y$ 和$M$ 分别表示处理、结果和中介变量。下面介绍二元处理中介分析的三种效应。

首先，控制直接效应（CDE）衡量处理发生变化时 $Y$ 的预期增幅，同时将整个总体中的中介变量设定为特定值 $m$，其定义如下：

$$CDE(m) = \mathbb{E}[Y|do(X = 1, M = m)] - \mathbb{E}[Y|do(X = 0, M = m)] \tag{7}$$

其次，自然直接效应（NDE）衡量的是处理发生变化时结果的预期增幅，同时将中介变量设为其在变化发生前本来会达到的值，

即 $X = 0$，其定义如下：

$$NDE = \mathbb{E}[Y|do(X = 1, M = M_0)] - \mathbb{E}[Y|do(X = 0, M = M_0)] \tag{8}$$

其中， $M_0$ 表示处理为 0 时中介变量的取值。

最后，自然间接效应（NIE）衡量的是：当处理固定为 $X = 0$，而 $M$ 变为其在 $X = 1$下本会达到的取值时，结果的预期增幅，可定义为：

$$NIE = \mathbb{E}[Y|do(X = 0, M = M_1)] - \mathbb{E}[Y|do(X = 0, M = M_0)] \tag{9}$$

其中， $M_1$ 表示处理为 1 时中介变量的取值。NIE 刻画了仅由中介作用解释的效应部分。

上述直接效应与间接效应在推荐中也发挥着重要作用。直接效应与间接效应有助于模型定量评估路径特定效应，从而检测并消除不希望出现的效应。例如，它们可用于识别直接和间接歧视，以实现或解释公平性 [92, 93]，；也可用于识别并消除某些偏差 [94, 95],等。

## 6 推荐中的因果估计方法

定义因果效应后，接下来顺理成章要问的是：如何估计这些效应？一种方法是进行随机实验。

### 6.1 随机实验。

要衡量平均处理效应，理想的方法是对同一组个体施加不同的处理。然而，在现实情境中，这种理想方案并不切实际，只能通过随机实验来近似实现。具体而言，随机实验会将个体随机分配到处理组或对照组。两组平均结果之差即可用于估计平均处理效应。要理解为什么随机实验是估计平均处理效应的黄金标准，就有必要了解相关性与因果关系有何不同。

$$\begin{aligned}
&\mathbb{E}[Y|X = 1] - \mathbb{E}[Y|X = 0] \\
\overset{1}{=}&\mathbb{E}[Y(1)|X = 1] - \mathbb{E}[Y(0)|X = 0] \\
\overset{2}{=}&\underbrace{\mathbb{E}[Y(1)|X = 1] - \mathbb{E}[Y(0)|X = 1]}_{\text{ATT}} \\
&+\underbrace{\mathbb{E}[Y(0)|X = 1] - \mathbb{E}[Y(0)|X = 0]}_{\text{bias}}
\end{aligned} \tag{10}$$

这里，步骤 1 基于以下事实： $Y$（1）是在给定 $X = 1$ 时观测到的结果，而 $Y$（0）是在给定 $X = 0$时观测到的结果；步骤 2 通过加上再减去 $\mathbb{E}[Y$（0）$|X = 1]$，构造出平均处理效应（ATT）项和偏差项。公式（10）中的偏差项造成了.....之间的差距相关性与因果关系。随机实验通过将个体随机分配到处理组或对照组来消除偏差项。更具体地说，随机分配使潜在结果与处理 $Y$（1） $Y$（0） $\perp\!\!\!\perp$ $X$相互独立（这并不意味着结果与处理相互独立），因此 $\mathbb{E}[Y$（0）$|X = 1] = \mathbb{E}[Y$（0）$|X = 0]$。给定$Y$（1） $Y$（0） $\perp\!\!\!\perp$ $X$后，公式（10）可改写为：

$$\mathbb{E}[Y|X = 1] - \mathbb{E}[Y|X = 0] = \mathbb{E}[Y(1)] - \mathbb{E}[Y(0)] \tag{11}$$

因此，随机实验可以直接将处理组与对照组的平均结果之差作为平均处理效应的估计值。在推荐中，随机实验通常用于处理偏差[82, 96, 97, 98, 99, 100, 101, 102]。具体而言，将物品曝光作为处理后，随机实验会采用随机推荐策略，而非已部署策略，从而获得用于推荐的无偏数据（也称为均匀数据）。

随机实验并非适用于所有情况的因果推断解决方案。实际上，随机实验总是耗时且昂贵，因此研究通常只涉及少量个体，这些个体可能无法代表总体。同时，伦理方面的顾虑极大地限制了随机实验的应用，例如环境健康研究。此外，随机实验无法解释个体层面的因果关系。因此，鉴于观察数据广泛可得，观察性研究是进行因果推断的一条捷径。

### 6.2 观察数据

尽管观察性研究可能是进行因果推断的一条捷径，但在设计因果模型时，仍需仔细考虑观察数据存在的一些问题。混杂因素的存在是观察数据中的一个关键问题。

**定义 8.** *(*混杂因素*)* 混杂因素是指会同时影响处理分配和结果的变量。

由于混杂因素的存在，我们可能会观察到一些虚假效应（例如冰淇淋消费与鲨鱼袭击之间的关系）。混杂因素在推荐系统中广泛存在。混杂因素的存在往往会导致不同的偏差，这取决于对混杂因素的定义。例如，将物品流行度视为混杂因素，会导致流行度偏差 [79]。除了物品流行度等一些可观察、可测量的混杂因素外，现实世界推荐中还存在一些不可观察或不可测量的混杂因素（即违反第 4 节中的可忽略性假设的因素），且学界已对此进行了广泛研究 [74, 78, 81]。

观察数据中还可能出现另一种现象，即辛普森悖论。从表1可以看出，在男性组和女性组中，服用药物的康复率都更高；但在总体中，不服用药物的康复率更高。这种现象通常由混杂因素导致。在推荐系统中也可以观察到辛普森悖论 [103]。

表1 考虑性别因素的新药研究结果 [68]。a/b 表示 b 人中有 a 人康复。

| | Drug | 未用药 |
|---|---|---|
| Male | 81/87 (93%) | 234/270 (87%) |
| 女性 | 192/263 (73%) | 55/80（69%） |
| 总计 | 273/350（78%） | 289/350（83%） |

Macdonald [103] 在推荐的离线评估中观察到了辛普森悖论，并提出了一种缓解离线评估中这一悖论的方法。

与实验数据相比，观察数据仅提供已发生事件的信息，却无法说明为何会采用特定处理。由于处理分配机制未知，公式（10）中的偏差项无法消除或进行定量测量。因此，未知处理分配造成的偏差也是模型设计中必须谨慎处理的关键问题。

### 6.3 依赖假设的方法

在一些复杂场景中，根据先验知识假设因果机制存在风险。在这种情况下，稳定单元处理值假设、可忽略性和正值性假设为一些估计潜在结果的方法提供了依据。

一种常用方法基于重新加权的思想。如前所述，由于处理分配机制未知，可能会出现偏差问题。通过为观察数据中的每个样本分配适当的权重，可以创建一个伪总体，使处理组和对照组的分布相似。常用的重新加权方法有两种：逆倾向评分和混杂因素平衡。

**定义 9.**（倾向得分）倾向得分定义为给定背景变量时处理的条件概率：

$$e(w) = P(X = 1|W = w) \tag{12}$$

根据上述定义的倾向得分，逆倾向评分方法 [104, 105] 根据倾向得分为每个观测样本分配权重。因此，基于观测样本估计的平均处理效应可改写为：

$$ATE_{IPS} = \frac{1}{n_1} \sum_{i,x_i=1} \frac{y_i}{e(w_i)} - \frac{1}{n_0} \sum_{j,x_j=0} \frac{y_j}{1 - e(w_j)} \tag{13}$$

逆倾向评分（IPS）常用于为推荐系统 [90, 106],设计无偏估计量，其中倾向得分可以预先定义，也可以从数据中学习。

尽管使用倾向得分能有效降低偏差，但在实践中应用逆倾向评分时仍存在一些问题。首先，逆倾向评分估计器的正确性高度依赖于倾向评分估计量的正确性。为解决这一两难问题，研究者提出了一些增强型逆倾向评分方法，例如双重稳健估计量 [107]。另一个缺点是，逆倾向评分估计器存在方差问题，当估计的倾向得分较小时，估计量会变得不稳定。为克服这一缺点，一些方法提出对倾向得分进行截断 [70] ，或剔除倾向得分较小的样本 [108]。

另一种重新加权方法是混杂因素平衡[109, 110, 111]。其原理是，矩可以唯一确定变量分布，因此可以通过矩来平衡混杂因素。由此可以学习样本权重，通过重新加权来估计因果效应。基于混杂因素平衡的方法可用于稳定学习 [112] 和稳健推荐 [113]。

除了重新加权方法，分层也是一种有代表性的方法。分层的思路是将总体划分为同质子群，使每个子群中的处理组和对照组相似。理想情况下，同一子群中的样本可视为来自随机实验条件下的数据。Macdonald [103]采用这一思路，以缓解推荐离线评估中的辛普森悖论。

在某些应用中，可以基于先验知识或专家知识，可靠地假设因果机制。在这种情况下，因果机制可以表示为我们之前介绍过的结构因果模型（SCM）。尽管结构因果模型框架所需的假设比潜在结果框架更强，但它也能通过图进行推理。使用结构因果模型时，因果关系与相关性的关键区别在于 $do$ 操作，这是估计因果效应的基本要素。正如我们提到的， $do$ 操作可以通过干预图来估计。然而，干预图中的数据是通过随机实验生成的。基于原始因果图生成的数据所采用的方法在实践中很有用。后门调整是一种常用方法。

**定义 10**。（后门准则）变量集合 $Z$ 满足因果图 $\mathcal{G}$ 中有序变量对（$X$，$Y$）的后门准则，当且仅当 $Z$ 同时满足：（*1*）$Z$ 中没有节点是 $X$ 的后代节点；（*2*）$Z$ 阻断了 $X$ 与 $Y$ 之间所有包含指向 $X$ 的箭头的路径。

通过识别满足后门准则的变量集合，可以使用后门调整公式估计因果效应。

**定义 11**。（后门调整）如果变量集合 $Z$ 满足有序变量对（$X$，$Y$）的后门准则，并且 $P$（$x$，$z$） $> 0$，那么 $X$ 对 $Y$ 的因果效应是可识别的，其表达式为

$$P(y|do(x)) = \sum_z P(y|x, z)P(z) \tag{14}$$

对于观测数据的总体，如果我们根据 $Z$ 的取值划分亚组，式（14）可以看作是通过对各亚组的因果效应求加权和来进行计算，这与分层方法非常相似。此外，式（14）可以改写为：

$$P(y|do(x)) = \sum_z \frac{P(y, x, z)}{P(x|z)} \tag{15}$$

其中， $P$（$x|z$）被称为“倾向得分”，因此，后门调整也是逆倾向评分方法的另一种表示形式。后门调整被广泛

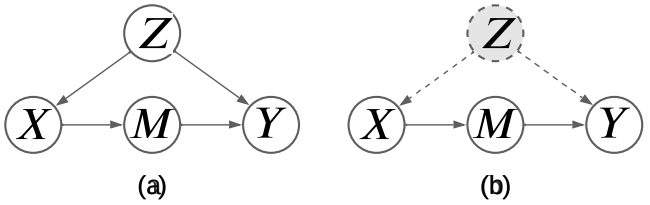



图 3。（a）在因果图上应用后门调整的示例。（b）含有未观测混杂因素的因果图示例，其中因果效应值可以通过前门调整进行估计。

用于解决推荐系统中的问题，例如偏差问题 [79, 114], 回音室 [115], 等。

考虑 *do*-操作时，干预并不限于强制某个变量或一组变量取特定值的操作。一般而言，干预可能涉及动态策略，即使处理变量 $X$ 按照指定方式对某个变量集合 $Z$ 作出响应，这记作 $x = g(z)$。在这种情况下，估计的因果效应 $P(Y = y|do(X = g(Z))$ 可计算如下:

$$\begin{aligned} &P(Y = y|do(X = g(Z))) \\ =&\sum_z P(Y = y|do(X = g(Z)), Z = z)P(Z = z|do(X = g(Z))) \\ =&\sum_z P(Y = y|do(X = g(Z)), Z = z)P(Z = z) \\ =&\sum_z P(Y = y|do(X = x), Z = z)|_{x=g(z)}P(Z = z) \end{aligned} \tag{16}$$

在推荐中，反馈数据是从已部署的推荐算法中收集的，因此数据生成过程中存在推荐策略。将动态策略视为推荐策略时，也可以应用条件干预来设计因果推荐模型 [81]。在推荐场景中，观察到反馈数据中的一次交互，并不意味着该交互注定会发生，因此有时会结合反事实推理应用因果调整方法 [77, 81, 115]。

除了上述调整公式外，还有一些适用于干预概率的规则，称为 *do*-演算规则。在介绍具体规则之前，我们先介绍一些符号表示。设 $X$、$Y$、$Z$ 和 $W$ 是因果有向无环图 $\mathcal{G}$ 中任意互不相交的节点集。$\mathcal{G}_X$ 表示从 $\mathcal{G}$ 中删除所有指向 $X$ 中节点的箭头后得到的图。同理，$\mathcal{G}_X$ 表示从 $\mathcal{G}$ 中删除所有从 $X$ 中节点出发的箭头后得到的图。*do*-演算规则可以用上述符号表示。

**定义 12**。（*do*-演算规则）以下三条规则适用于与因果图 $\mathcal{G}$ 相容的所有干预分布

**规则 1**（观测的插入/删除）:

$$\begin{aligned} &P(y|do(x), z, w) = P(y|do(x), w) \\ &if \quad (Y \perp\!\!\!\perp Z|X, W)_{\mathcal{G}_{\overline{X}}} \end{aligned} \tag{17}$$

**规则 2**（干预与观察互换）:

$$\begin{aligned} &P(y|do(x), do(z), w) = P(y|do(x), z, w) \\ &if \quad (Y \perp\!\!\!\perp Z|X, W)_{\mathcal{G}_{\overline{X}\underline{Z}}} \end{aligned} \tag{18}$$

**规则 3**（行动的插入/删除）:

$$\begin{aligned} &P(y|do(x), do(z), w) = P(y|do(x), w) \\ &if \quad (Y \perp\!\!\!\perp Z|X, W)_{\mathcal{G}_{\overline{X}\overline{Z(W)}}} \end{aligned} \tag{19}$$

其中 $Z(W)$ 是 $Z$ 中不属于任何 $W$ 节点祖先节点的节点集。

借助 *do*-演算规则和前述调整公式，可以根据观察数据估计干预概率。

### 6.4 宽松假设下的方法

尽管上述依赖所引入假设的方法基本上满足了从观察数据中估计因果效应的要求，但在实践中，对于某些特定应用，这些假设未必总是成立。因此，有一些方法尝试在更宽松的假设下估计因果效应。

稳定单元处理值假设认为个体之间相互独立且同分布。然而，在一些现实世界的应用中，例如社交网络，由于个体通过网络结构彼此紧密相连，稳定单元处理值假设不再成立。为了解决实际应用中的这一问题，一种常用方法是将能够捕捉这种相互关联的模型引入因果推断模型。例如，将图卷积网络引入因果推断模型，以处理网络数据 [116]。

可忽略性假设认为，在给定背景变量的条件下，处理分配与潜在结果相互独立。然而，在现实世界中，不可能识别并收集所有背景变量，因此很难满足可忽略性假设。换言之，可能存在我们之前提到的未观测混杂因素。仅使用观察数据估计因果效应很困难，另一种方法是结合有限的实验数据和观察数据 [117]。在推荐中，通过随机实验收集无偏数据；利用少量无偏数据和大量观测反馈，是设计无偏推荐模型的一种常见方法。

另一种解决方案基于假设的结构因果模型，该模型将未观测混杂因素纳入因果图中（示例见图 3(c)）。与应用后门调整类似，我们首先确定一组满足前门准则的变量。

**定义 13.** *(*前门准则*)* 给定因果图 $\mathcal{G}$ 中的一对有序变量 $(X, Y)$，变量集合 $Z$ 关于 $(X, Y)$ 满足前门准则，当且仅当 $Z$ 满足以下条件:

– $Z$ 截断了从 $X$ 到 $Y$的所有有向路径。– 从 $X$ 到 $Z$不存在未阻断的后门路径。– $X$ 阻断了从 $Z$ 到 $Y$的所有后门路径。

给定一组满足前门准则的变量，我们可以在存在未观测混杂因素的情况下识别因果效应 [68]。

**定义 14.** *(*前门调整*)* 如果一组变量$Z$ 满足与有序变量对$(X, Y)$相关的前门准则，并且 $P(x, z) > 0$，那么 $X$对 $Y$ 的因果效应是可识别的，且其表达式为

$$P(y|do(x)) = \sum_{z} P(z|x) \sum_{x'} P(y|x', z)P(x') \qquad (20)$$

社区普遍认识到未观测混杂因素的存在 [74, 77, 78, 118], 也有一些研究 [77, 118] 尝试在推荐中应用前门调整。

使用工具变量是绕过可忽略性假设并进行因果推断的一种可行方法。工具变量定义为仅通过处理变量影响结果的变量。典型的工具变量方法 [119, 120] 采用两阶段模型：第一阶段根据工具变量重构处理变量，第二阶段根据第一阶段得到的处理变量重构结果。在推荐系统中，Si 等人 [121]采用工具变量，利用搜索数据设计了一个模型无关的推荐框架。

## 7 C推荐中的因果发现 ATION

上述方法旨在学习因果效应；另有一类因果模型旨在学习因果关系，这也称为因果发现。除少数仅旨在识别处理变量和结果的研究外[122],大多数研究旨在发现因果图。沿用 [39, 123], 传统方法，可将其分为三类：基于约束的方法、基于评分的方法，以及基于函数因果模型的方法。

基于约束的算法会学习一组满足数据中蕴含的条件独立性的因果图，并利用统计检验来验证候选图是否满足独立性。基于评分的算法通过最大化评分函数$S$（$\mathbf{X}$ $\mathcal{G}$）来学习因果图，该函数会返回给定数据$\mathbf{X}$时因果图 $\mathcal{G}$ 的评分。基于函数因果模型（FCM）的算法通常将变量定义为其直接原因与某个噪声项的函数（例如，由因果图 [124]的邻接矩阵线性加权）并优化所设计的目标来学习函数参数。我们仅简要介绍因果发现方法，感兴趣的读者可参阅 [39, 123] 了解更多详情。

大多数现有的因果推荐研究都基于预先定义的因果图来表示潜在的因果机制。这些预先定义的因果图通常依据专家知识构建，因此可能不够准确且过于简单（即只涉及少数变量）。在推荐中运用因果发现有助于解决这些问题。目前只有少数研究 [125, 126] 采用基于连续优化 [127]的因果发现技术来设计推荐系统。学习得到的因果机制将提升推荐系统的可解释性，并为公平性、无偏性等其他方面的模型设计提供指导。

## 8 推荐中的因果可解释性

随着机器学习的发展，准确性不再是唯一的追求。此外，透明度和可信度也日益受到关注。例如，医疗 AI 不仅需要提供准确的诊断，还需要提供相应的解释来说服患者。推荐系统有人类参与其中，因此也需要具备透明度。可解释推荐随着对推荐系统透明度和可信度的追求而兴起并发展，如今在学术界和工业界都日益普及。它旨在为推荐的物品提供解释，并以多种方式惠及相关群体。对于消费者而言，可解释推荐能够帮助他们做出更好的决策。对于平台而言，它可能提升系统的透明度、说服力、可信度和用户满意度。对于模型开发者而言，它是理解所设计模型并加快设计周期的重要工具。本节将首先概述可解释推荐，然后总结现有的因果方法以及一些与因果推断相关的开放问题。

### 8.1 问题介绍

作为可解释人工智能的一个分支，可解释推荐研究由 [128] 提出并定义。随着深度神经网络的快速发展，最先进的推荐系统广泛采用深度模型来提升推荐性能。然而，这些深度模型过于复杂，用户难以理解智能系统作出的决策，因此深度模型通常被视为黑箱。推荐系统是日常生活中至关重要的决策系统，既需要提供准确的决策结果，也需要说明其背后的原因。例如，股票投资者在作出最终决策前，需要了解哪些特征促成了这项推荐。消费者在付款前则希望知道为什么值得购买所推荐的物品。

可解释模型可以分为模型内在型和模型无关型。前者是,指在生成推荐结果的同时生成解释，后者是指在提供推荐结果后生成解释。模型内在型（也称特设型）可解释模型通常将解释生成机制设计为决策过程的一部分，而模型无关型（也称事后型）可解释模型通常会设计独立的机制来生成解释。

解释可以通过多种不同方式呈现，通常取决于所采用的信息来源。通常，解释可以呈现为相关用户或物品 [89, 129], 用户或物品的特征 [128, 130],生成的文本句子 [131, 132], 可视化解释 [133],图 [134],等。现有研究利用不同的信息来源，在可解释推荐方面取得了许多成果。例如，张等人 [128] 提出了显式因子模型（EFM），该模型提取显式物品特征和用户

从用户评论中获取的意见，以提供特征级解释。Peake 和 Wang [129] 提取关联规则，以与模型无关的方式将已购买物品作为解释。Xian 等人 [134] 利用知识图谱执行显式推理路径，以提供推荐和解释。此外，现有研究还将可解释性引入对话式推荐。Chen 等人 [135]开发了一种可解释对话推荐（ECR）模型，通过多轮对话提供准确的推荐和高质量的解释。融入因果推断的理念和技术，为可解释推荐带来了新的机遇。接下来，我们将重点关注因果相关方法。感兴趣的读者可参阅其他综述 [29, 30] ，了解更多可解释推荐方法。

### 8.2 因果方法

#### *8.2.1* 反事实

近年来，反事实推理在可解释人工智能领域越来越受到关注。对于任何基于机器学习模型进行预测的人工智能系统，无论是白盒还是黑箱，反事实推理都会探究应改变哪些输入（例如方面、特征），以及改变多少，才能获得不同的预测结果。随后，经过修改的输入将构成解释。例如，在为一份被拒绝的贷款申请生成解释时，可能会是这样的：如果您的年收入是 50，000，而不是 30，000，您的申请就不会被拒绝。一些已有研究将反事实推理引入推荐场景以生成解释，通过寻找推荐系统中的最小改动（例如物品特征、历史记录中的物品、用户行为等），使预测结果发生变化，从而确定最关键的部分（例如物品特征、历史记录中的物品、用户行为等）作为解释。Ghaz- imatin 等人 [136] 基于用户在历史记录中的行为，为推荐系统生成解释。更具体地说，该研究在知识图谱上引入了一种搜索算法，用于寻找需要删除的最小用户历史记录集合，使用户能够获得不同的推荐结果。Tan 等人 [130]提出了一个用于生成特征级解释的反事实解释框架。该框架引入了两个新概念：解释复杂度和解释强度。这两个概念用于构建反事实优化问题，以及用于评估所生成解释的评估指标。之后， [137], 中的一项研究也采用了类似的反事实解释框架，用于解释哪些特征导致了推荐系统中的公平性问题。Tran 等人 [138]利用影响函数分析训练数据。随后，使用一组反事实训练数据来生成解释。

#### *8.2.2* 因果发现

基于因果发现的可解释推荐模型仍处于起步阶段。因果发现方法旨在从数据中提取变量之间的因果关系。现有基于因果发现的推荐方法能够提供模型内在解释。更具体而言，基于提取出的因果关系，基于因果发现的推荐模型能够在提供推荐的同时，给出相应的因果关系作为解释。正如我们所提到的，因果发现方法通常试图学习因果图。在推荐场景中，考虑到物品数量极其庞大，学到的因果图通常基于物品组级别。例如，Wang 等人 [125] 提出学习簇级因果图，以指导序列推荐。基于学到的簇级因果图以及每个物品的簇分配，模型能够计算物品之间的因果关系。交互历史中与推荐物品具有最强因果关系的物品会被确定为解释。Xu 等人 [126] 旨在学习产品类型（PT）级别的因果图，用于 PT 级别的推荐。具体而言，该模型将收集的反馈数据视为两种相互竞争机制共同作用的结果：一种是基于用户意图的因果机制，另一种是基于已部署推荐算法的干预机制。推荐及相应解释通过学到的 PT 级别因果图生成。

### 8.3 开放问题

尽管上述方法已成功应用于因果可解释推荐领域，但仍有一些有待未来解决的开放问题。首先，基于因果发现的可解释推荐模型能够生成模型内在解释，值得进一步探索。其次，目前的反事实解释算法被认为是模型无关的，因为它们能够应用于任何推荐模型（或至少适用于广泛的推荐模型）。然而，算法用户必须能够访问模型本身。对于算法用户无法访问的推荐模型，如何应用反事实解释算法，目前尚不明确。最后，目前还没有方法能够利用其他因果推理方法（如 do-演算）来生成解释。

## 9 推荐中的因果公平性

推荐系统作为一种强大的商业工具，已被广泛用于提升用户参与度，进而创造更高的利润。传统推荐系统主要关注如何精准估计用户偏好。然而，近年来，推荐公平性问题引起了业界和学术界的广泛关注 [31, 32, 139, 140, 141]。随着推荐技术的发展，推荐系统已广泛应用于多个领域，用于辅助甚至取代人类决策。多项研究表明，不公平性可能导致负面后果 [142, 143, 144], , 进而产生重大的社会影响。例如，在电子商务中，物品曝光的不公平性可能长期损害平台和提供方的利益 [145]；在教育推荐中 [146], , 由性别失衡[147] 导致的不公平系统可能会打击女性选择科学、技术、工程和数学（即

科学、技术、工程和数学）相关主题的积极性，这可能影响几代人；不公平的广告推荐甚至可能导致种族歧视 [148]。因此，为了扩大推荐系统的应用并维护其对社会的积极影响，至关重要的是考虑推荐公平性，并构建可靠的决策系统。

### 9.1 问题介绍

要实现推荐系统中的公平性，首先应了解不公平性的成因。偏差和歧视是公认的两种常见成因 [31, 32, 33, 149]。推荐系统中的偏差主要包括数据偏差和算法偏差。数据偏差可能源于数据生成、收集、采样和存储。例如，在推荐系统中，训练数据采集自已部署的系统；如果该系统所使用的算法会产生有偏预测，那么生成的数据就可能包含偏差。数据偏差可能会影响算法，因为大多数机器学习算法都依赖数据进行训练，并在训练后做出预测。如果训练数据包含偏差，那么基于这些数据训练的算法就会从中学习到有偏知识，进而导致不公平性。例如，如果训练数据中多数用户/项目群体与少数用户/项目群体之间存在显著失衡，推荐算法很可能在多数群体上的学习效果更好，从而导致对少数群体的歧视。除了数据偏差，推荐算法本身也可能加剧已有偏差并造成不公平性，这称为算法偏差。例如，某些推荐算法可能会加剧流行度偏差，即质量相同或相近的热门物品会比不那么热门的物品获得更多推荐。歧视也是导致不公平性的原因之一，它是一个多学科问题 [150, 151, 152],，指因人类偏见和刻板印象，基于某种生理或文化特征（如种族、性别等）而造成的不合理处理差异。值得一提的是，不公平性并非仅由偏差和歧视导致。例如，不同类型的公平性之间可能存在冲突或权衡 [31, 33, 153], ，实现一种公平性可能会损害另一种公平性。

为了应对不公平性，明确公平性的定义非常重要。在一般的机器学习中，可以根据目标层面定义公平性（即实现群体层面或个体层面的公平性）。具体而言，公平性可分为群体公平性和个体公平性。

- **群体公平性**：群体公平性定义的是群体层面的公平性，其理念是不同群体应受到平等对待。群体可以通过多种方式划分，其中最常见的方式是依据某些明确的敏感属性对群体进行划分。

- **个体公平性**：个体公平性定义了个体层面的公平，其理念是相似的个体应获得相似的预测结果。此外，从理论上讲，个体公平性可以视为一种非常特殊的群体公平性，即将每个个体分别划分为不同的群体。

由于推荐系统中的公平性涉及多个利益相关者的利益，[144, 154, 155, 156, 157],对公平性的诉求可能来自不同方面。因此，推荐公平性的定义也可分为用户侧公平性和物品侧公平性。

- **用户侧公平性**：用户侧公平性旨在满足用户（消费者）的公平性要求。用户侧的需求主要关注推荐质量（即推荐性能）。用户侧公平性可以在群体层面和个体层面实现。群体层面的用户侧公平性旨在减少不同用户群体之间推荐质量的差异，其中用户群体根据敏感特征（如种族或性别） [142, 158], 或指定特征（例如，冷启动用户与重度用户、 [159], 活跃用户与非活跃用户[140, 160]）进行划分。对于个体层面的用户侧公平性，即使某个用户的敏感特征发生变化，推荐质量也应保持不变。例如，Li 等人 [139] 将反事实公平性的理念 [91] 融入推荐模型设计，使得即使用户的敏感特征在反事实世界中发生翻转，推荐性能仍保持不变。

- **物品侧公平性**：物品侧公平性旨在满足物品侧的公平性需求，主要关注为物品争取平等的曝光机会，以维护市场公平性。这里的物品是指待排序或待推荐的“物品”。例如，在电子商务中，物品指待售商品；在招聘系统中，物品指求职者（物品提供者）。现有研究的一个分支侧重于根据物品属性实现公平性。例如，一些研究 [145, 161, 162, 163, 164, 165] 致力于实现热门物品与非热门物品之间的公平曝光，避免非热门物品曝光不足。此外，另一类研究主要关注根据物品提供者的敏感属性实现公平性，例如性别、 [166, 167, 168], 地理来源[169, 170, 171], 等。

值得注意的是，用户侧公平性与物品侧公平性并非相互排斥，因此有人提出双侧公平性 [172, 173, 174, 175, 176] 方法，以满足两侧的公平性需求。除了上述分类法之外，还有一些分类法 [31, 33] 从其他角度对推荐公平性进行分类。例如，静态公平性与动态公平性 [143, 143, 177, 178]；短期公平性与长期公平性 [145, 179]；群体公平性与个性化公平性 [139, 180, 181]；黑箱公平性与可解释公平性 [137],；集中式公平性与去中心化公平性 [182, 183]。

通常，旨在实现推荐公平性的方案大致可分为三类：预处理方法、处理中方法和后处理方法 [31, 33, 149, 184]。预处理方法通常旨在模型训练前，通过尽量减少数据中的偏差来实现公平性。与其他类型的方法相比，关于预处理方法的研究较少。一些具有代表性的方法包括

覆盖所有群体物品的公平性感知数据采样方法、用于提高少数群体覆盖率的数据平衡方法 [185] ，以及用于确保标签正确性并消除差别影响的数据修复方法[186]。处理中方法则提出将公平性要求纳入目标函数，以在训练过程中实现公平性。通常，公平性要求作为正则项或约束发挥作用 [66, 140, 145, 158, 162, 187, 188, 189, 190, 191]。为了在最小化原始损失函数（即推荐准确率损失）的同时尽量减少不公平性，同样重要的是在推荐准确率与公平性之间找到权衡 [145, 192], ；有时，这也会被表述为一个多目标学习问题 [192]。后处理方法旨在训练完成后，在推理阶段通过重排序 [140, 193, 194,195]或多臂老虎机 [196, 197, 198]等技术实现公平性。为了衡量不公平性，研究者提出了许多不同的公平性指标。例如，绝对差值（AD） [66]用于衡量受保护群体与非受保护群体之间的表现绝对差异；归一化折扣KL散度 [199] 则计算各位置KL散度的归一化折扣累积值，等等。更多可用的公平性指标见 [32]。

最近，研究人员注意到，仅凭相关性或关联性无法很好地检测公平性。具体而言，公平性标准仅基于随机变量的联合分布 [200], ，例如结果、特征、敏感属性等。然而，近期研究 [201] 表明，任何仅依赖联合概率分布的公平性定义，都未必能够检测出歧视。因此，许多方法 [91, 93, 200, 202, 203]从因果关系的角度提出，以解决不公平性问题。

在一般的机器学习中，基于因果的公平性符号表示大多基于干预或反事实来定义。要衡量基于因果的公平性中的不公平性，一个挑战是理解导致不同结果的因果关系。因果图是进行因果推理的有力工具，通常用于表示变量之间的因果关系。给定能够捕捉因果关系的因果图，许多因果效应可用于衡量不公平性。例如，ATE（如式（3）所示，也称为总效应 [27]）用于衡量改变敏感属性对结果的影响。Kilbertus 等人 [204] 衡量从敏感属性到结果的间接因果效应[205] , 并消除从敏感属性到结果的有向路径，但经由解决变量的路径除外。解决变量是指因果图中受敏感属性影响、但影响方式不具歧视性的任何变量。有关基于因果的公平性符号表示的更多细节，请参见[76]。反事实公平性是基于因果的公平性中一种常用的公平性定义。反事实公平性是一种个体层面的基于因果的公平性概念，要求对于任何个体，其预测结果在反事实世界中应与现实世界中相同 [91]。其基本思想是，在给定所有特征的条件下，最小化 ATT（如式（4）所示，一些文献也将其称为 ETT [27, 68, 132]），使事实世界和反事实世界中的概率分布相同。对于推荐中的反事实公平性，其定义如下 [139]:

**定义 15.** （推荐中的反事实公平性）如果对于任何具有敏感属性 $Z = z$ 和其余特征 $X = x$的用户 $u$ ，推荐模型满足以下条件，则该模型满足反事实公平性:

$$P(L_z|X = x, Z = z) = P(L_{z'}|X = x, Z = z) \qquad (21)$$

对于所有 $L$以及 $Z$可取的任意值 $z'$ ，其中 $L$ 表示面向用户 $u$ 的前$k$ 个推荐列表。

下一节将介绍一些用于推荐公平性的因果方法。

## 9.2 因果方法

### *9.2.1* 重新加权

如前文所述，偏差被广泛认为是不公平性的成因之一，因此现有的一些工作采用逆倾向评分（IPS）方法来解决推荐中的偏差。例如，流行度偏差会导致物品侧不公平性，使热门物品获得更多曝光机会。IPS方法认为，这些偏差是由非随机分配的处理造成的，因此使用逆倾向对样本进行重新加权，以消除偏差。例如，Schnabel等人 [90]将推荐视为处理，并在经验风险最小化框架中应用IPS估计器进行学习，以解决推荐中的偏差。Saito等人 [70] 设计了一种基于IPS的估计器，用于无偏成对学习。Wang 等人 [106]使用一小部分无偏数据训练倾向模型，并使用有偏数据训练基于逆倾向评分的评分模型。基于IPS的方法易于实现，但需要准确的倾向估计器，并且会受到高方差的影响 [206, 207]。

尽管人们普遍认为数据中的偏差是导致推荐不公平性的主要原因，但偏差与公平性之间的关系尚未得到清晰的理解或讨论。更具体地说，去偏方法通常旨在通过消除偏差来提升推荐性能，因此模型采用推荐指标而非公平性指标进行评估。许多关于公平性的研究并未采用去偏方法，而是直接根据公平性要求进行设计，这可能导致准确性与公平性之间的权衡。下文将重点讨论公平性方法。关于去偏方法的更多讨论，请参见第12节。

### *9.2.2* 反事实

作为一种基于因果关系的公平性定义，反事实公平性要求预测结果在反事实世界中与事实世界中相同。为了实现反事实公平性，公平模型需要预测反事实世界中的结果（即敏感属性已发生改变），这既重要又具有挑战性。Ma 等人 [208] 提出了一种反事实数据增强模块，该模块基于带有公平性约束的变分自编码器进行训练，以生成具有不同敏感属性的反事实数据。通过最大化从原始数据和不同反事实数据中学到的表示之间的相似度，

该模型能够实现反事实公平性。Mehrotra 等人 [209] 使用反事实估计，从相关性与公平性之间的权衡角度评估推荐策略，并提出了一种考虑用户对公平性的容忍度的推荐模型。反事实的思想不仅用于公平性模型设计，也用于公平性诊断。具体而言，公平性诊断旨在找出导致模型不公平的原因。受反事实解释[130, 210], 的启发，Ge 等人 [137] 提出了一种反事实推理方法，用于学习对公平性—效用权衡有显著影响的关键特征，并将其用作基于特征的推荐的公平性解释。

*9.2.3* 结构方程

结构因果模型由因果图和一组结构方程构成。因果图刻画变量之间的直接因果关系，而结构方程则建立变量之间的定量关系。正如我们在第6节中介绍的，如果已知结构方程，就可以通过替换结构方程中变量的取值，得到干预结果或反事实结果。受这一思路启发，一些公平性研究采用学习得到或预先定义的结构方程。例如，一些研究
[92, 211, 212, 213, 214, 215]根据学习得到的结构方程对不同因果效应进行建模，以发现歧视并进一步消除歧视。
Kilbertus 等人 [204] 提出了一种实用流程，可在给定结构方程模型的情况下消除歧视。

*9.2.4* 因果图

其他一些基于因果关系的方法利用因果图刻画潜在的数据生成机制，并应用其他技术来实现公平性。例如，Huang 等人 [216] 利用从因果图中识别出的 d- 分离集，设计了一种用于在线推荐的公平上置信界赌博机算法。Li 等人 [139]设计了一种基于因果图的模型，通过对抗学习生成与特征无关的用户表征。具体而言，该模型同时训练预测器和对抗分类器：预测器学习用于推荐的表征，而分类器则尽可能削弱预测器预测敏感特征的能力。

### 9.3 开放问题

如上文所述，研究人员开始意识到在推荐中考虑基于因果关系的公平性的重要性 [76, 201]。然而，推荐中的因果公平性基础尚未得到充分确立。具体而言，公平性技术在分类任务中已得到充分探索，但即使在某些情况下推荐可以被视为分类任务，这些技术也未必能直接迁移到推荐问题中。例如，在分类中实现反事实公平性的一种直接方法[91] 是从输入中移除敏感属性，以确保结果与敏感特征相互独立。然而，在推荐系统中，一些现有方法并不使用特征进行推荐，例如大多数基于协同过滤的模型 [217],，但仍然存在不公平性。原因在于，交互信息包含敏感特征与用户-物品交互之间的隐藏关系，而这种潜在关系会在协同学习过程中被模型捕获，从而导致不公平性。因此，深入探索不公平性的潜在因果机制至关重要。此外，这也有助于学界建立偏差与公平性之间的联系。

## 10 推荐中的因果鲁棒性

近年来，机器学习的鲁棒性日益重要。由于模型训练非常耗时，实际应用中推荐系统模型不会频繁重新训练。传统上，推荐系统假设训练数据集和测试数据集的模式相同。然而，训练数据集与真实世界数据之间存在差异。这种差异可能由自然分布偏移或蓄意攻击造成 [218]。在这样的训练数据集上进行训练，会导致模型应用于真实世界数据时性能下降。在这种情况下，如何构建鲁棒模型至关重要。

### 10.1 问题引言

首先，我们需要了解哪些方面会损害推荐系统的鲁棒性。一般来说，在训练过程中，数据集会被划分为三个子集（训练集、验证集和测试集）。大多数鲁棒性问题出现在训练集和测试集上。例如，如果训练数据集规模不足，可能会导致过拟合或欠拟合问题。在这种情况下，我们可能会在测试集上得到较差的结果。具体而言，鲁棒性问题可分为以下几类：

- **分布偏移**许多现有的推荐系统都假设训练集和测试集的数据分布相同。然而，这一假设并不符合真实世界场景，因此许多现有推荐模型在上线部署时无法达到预期的性能[219]。目前，许多推荐系统模型都是基于已收集的数据集进行训练的。部署新模型时，数据的分布可能会有所不同 [220]。即使数据是新收集的，仍然存在变换风险 [218]。这是因为从模型训练到部署之间存在一段时间，足以让已收集的信息因处理错误而遭到攻击或发生改变。

- **转换**大多数推荐系统都使用用户和物品特征进行训练。推荐系统可以根据这些特征，向用户提供一组推荐物品。然而，用户和物品特征可能会被篡改或误导。例如，用户购买物品时使用虚拟专用网络（VPN），其位置信息就可能不准确。基于此类数据，推荐系统可能会向用户推荐错误的物品。

•**攻击**除了转换之外，攻击也可能改变训练数据的准确性。随着电子商务的发展，越来越多的人开始在网上购买物品。这带来了巨大的收益。因此，系统极有可能遭受攻击，攻击者旨在提高或降低某些物品的排名。例如，用户可能会在不情愿的情况下更改已购买商品的评分和评论。

• **稀疏性** 与数量庞大的用户和物品相比，大多数序列推荐训练集都具有稀疏性。如上所述，这可能导致过拟合或欠拟合问题，并使模型在测试集上的表现不佳。

## 10.2 鲁棒性方法

### *10.2.1* 反事实

推荐模型面临数据稀疏性问题。例如，在电子商务应用中，与数量庞大的用户和物品相比，用户的购买历史非常稀疏。因此，模型无法获得足够的训练数据，导致预测性能低下。解决这一问题的一种方法是反事实数据增强。通过使用反事实推理生成新的训练数据，并将其与原始数据结合，可以提升推荐模型的性能。反事实数据增强序列推荐（CASR）为解决这一问题提供了一个框架 [221]。对于一个训练样本 ($\{u, t^1, t^2, ...t^l\}$, $t^{l+1}$)，模型将首先指定一个索引 d，并将一个 $t^d$ 替换为一个物品 $t^a$。假设$\mathbf{e}_t \in R^D$ 是物品 t 的嵌入，D 是物品的嵌入维度。对于给定的样本 ($\{u, t^1, t^2, ...t^l\}$, $t^{l+1}$)，模型将优化以下目标：

$$\begin{aligned} &\min_{t^a \in C} \|\mathbf{e}_{t^a} - \mathbf{e}_{t^d}\|_2^2 \\ s.t.\ &t^{l+1} \neq arg\max_{t \in I} \mathcal{S}(t|u, t_1, ..., t^{d-1}, t^a, t^{d+1}, ..., t^l) \end{aligned} \tag{22}$$

其中，$\mathcal{I}$ 是所有物品的集合。$\mathcal{C}$ 是用于替换的物品集，可以指定为 $\mathcal{I}$ 或其他集合，以纳入一些先验知识。 $\mathcal{S}$ 是用于生成新序列数据的采样器。在该函数中，目标是尽量缩小原始物品与替换物品之间的距离。约束确保替换后的物品不是原始物品。这样，我们就能生成与原始数据不同但相似的数据。

### *10.2.2* 因果图

一些已有研究引入了因果表示学习的思想，以缓解分布偏移问题。该模型将用户特征划分为已观测组和未观测组，并根据偏好是否受到已观测特征影响，设定两类偏好 [222]。根据因果图，研究人员构建了一个框架，用于建模交互生成过程。为处理未观测特征，他们设计了一种新的变分自编码器（VAE），从历史交互和已观测特征中推断未观测特征。

### *10.2.3* 重新加权

此外，研究人员还引入了重新加权方法，以提升推荐的鲁棒性。例如，Li 等人[113] 考虑在训练数据与测试数据之间存在未知分布偏移时增强推荐的鲁棒性。为此，该论文借鉴混杂因素平衡方法，提出了一种面向因子分解机（FMs）的个性化特征选择方法，通过平衡每个特征的混杂因素来实现这一目标。具体而言，鉴于通常缺乏关于 FMs 中输入变量因果结构的先验知识，该论文将每个特征视为一个处理变量，并旨在估计其对结果的因果效应。当某个特征被视为处理变量时，其他特征则被视为混杂因素。该论文借鉴混杂因素平衡的思想 [223, 224] 学习一个权重矩阵，通过平衡不同处理特征之间混杂因素的分布来对每个样本重新加权，使 FMs 能够为每个特征分配一个表示其对目标变量因果效应的权重，从而有助于选择因果特征，以实现稳健推荐。

## 10.3 开放问题

现有关于鲁棒性问题的研究只能聚焦于某些特定问题。例如，使用反事实数据增强来缓解稀疏性问题，以及使用因果表征学习来解决分布偏移问题。如果将这些方法应用于其他鲁棒性问题，实验性能可能会大幅下降。此外，目前大多数已有研究都缺乏解释。它们或许能有效解决某些问题，但无法说明模型的哪些部分提升了性能，以及哪些部分还有进一步改进的空间。如何提出一种可应用于多个问题且具有可解释性的鲁棒性方法，是一项巨大的挑战。

# 11 基于增益的推荐

现代推荐系统通常旨在推荐用户最有可能交互的物品（例如点击、购买等）。然而，即使没有推荐，用户也可能会与某些物品发生交互。基于这一事实，一些现有研究提出，应推荐交互概率增益较高的物品，而不是仅推荐交互概率值较高的物品。

一个密切相关的领域是增益建模，指用于估计处理对结果的增量影响的技术。增益建模既是因果推断问题，也是机器学习问题 [225]。它属于因果推断问题，因为对于计算增量影响所需的两种结果（即接受处理或不接受处理），对同一个体而言二者互斥。它也属于机器学习问题，因为需要借助模型预测可靠的增益值，以支持决策。从理论上说，增益建模旨在估计处理对结果的处理效应 [225]。现有文献中主要有三种方法：双模型方法分别使用处理组数据和对照组数据训练两个模型，并利用

两个预测值之差来计算增益值 [226]；类别转换方法基于某些假设建立处理组与对照组之间的联系 [227]；直接估计方法则设计一个模型，直接估计增益值 [228, 229]。

## 11.1 问题介绍

推荐系统已应用于多个工业领域，以提高企业利润并提升用户参与度。为实现这一目标，大多数推荐模型都旨在通过推荐交互概率最高的物品来增加用户行为（例如点击、购买等）。然而，大多数推荐系统忽略了一个事实：无论系统是否推荐某些物品，用户都可能会采取行动 [75, 230]。例如，如果系统推荐瓶装水和能量饮料，用户购买瓶装水的概率为 95%，购买能量饮料的概率为 50% 。在大多数传统推荐系统看来，推荐瓶装水会更好，因为用户更有可能购买它。然而，即使系统不推荐瓶装水，作为日常用品，它仍有 90% 的购买概率；而能量饮料的购买概率可能只有 20% 。推荐能量饮料似乎是更好的选择，因为它带来的购买概率增幅更高（即 30% ，而非 5%），进而有望带来更多利润。基于这一动机，人们开始设计基于增益的推荐系统，旨在推荐增幅较高的物品。

一些已有研究已经意识到推荐的影响，但尚未从因果视角解决这一问题。例如，Bodapati [231] 提出了一个两阶段模型，分别训练物品的认知阶段和满意度阶段。通过基于企业发起的购买数据（即作为推荐结果的购买）和自主发起的购买数据（即企业发起购买以外的购买）训练模型，该模型旨在推荐能够最大化由推荐带来的预期增量购买数量的物品。Sato 等人 [230]提出了一种购买预测模型，将个体在推荐响应度方面的差异纳入其中。更具体地说，该模型包含用户特定的响应度和物品特定响应度，以最大化推荐的影响。

推荐系统中的增益定义为推荐所带来的用户行为（如点击、购买、点赞等）增加量。鉴于增益被定义为有推荐和无推荐两种情形下的差异，从因果推断的角度来看，增益可以用潜在结果进行数学表示。具体而言，将推荐视为处理，令 $Y(1)$ 表示有推荐时的潜在结果，$Y(0)$ 表示没有推荐时的潜在结果。在二元情形下，$Y(1) = 1$ 和 $Y(0) = 1$分别表示用户在有推荐和无推荐时是否会对该物品采取行为。用户对某物品的增益为 $Y(1) - Y(0)$。在下一小节中，我们将介绍一些现有的结合因果推断的基于增益的推荐模型研究。

## 11.2 因果方法

### *11.2.1* 数据处理

估计增益值的一项挑战在于，无法观察到每个个体的事实结果和反事实结果（即有推荐和无推荐时的结果）。因此，增益值（即推荐的因果效应）没有可观测的真实值。解决这一问题的一种可能方案是利用训练数据。Sato 等人 [75] 针对观察数据提出了一种用于基于增益的优化的采样方法。具体而言，通过观察购买记录和推荐日志，对于给定用户，某物品可能被购买或未被购买，也可能被推荐或未被推荐。该优化方法从四类物品中采样出专用于增益任务的正样本和负样本（即已推荐且已购买、已推荐但未购买、未推荐但已购买、未推荐且未购买）。因此，将采样得到的增益任务标签作为真实值后，该优化方法便能够学习用户-物品对的增益值。除了基于观察数据的采样方法外，使用实验数据进行训练也是一种可行方案。Shang 等人 [86]提出了一种基于强化学习的方法，该方法结合深度增益网络，将不同用户行为的因果效应作为奖励函数进行学习。该增益网络从随机实验中收集的训练数据中学习。

### *11.2.2* 反事实

根据增益值的计算，一种直接的方法是估计反事实结果。尽管随机实验是估计因果效应的理想方法，但由于耗时且成本高昂，不可能在所有推荐场景中都开展随机实验。因此，仅基于观测数据估计反事实结果至关重要。受协同过滤思想的启发，Xie 等人 [87]认为，相似用户不仅对物品具有相似的偏好，而且在推荐处理下也具有相似的处理效应。所提出的方法基于张量分解构建，张量的三个维度分别为用户、物品和处理。更具体地说，对于一个包含 $m$ 个用户、 $n$ 个物品和 $l$ 个处理的三维张量，其元素 $y_{u,\ i,\ t}$可以预测如下。

$$\hat{y}_{u,i,t} = p_u^T q_i + p_u^T d_t + q_i^T d_t \tag{23}$$

其中， $p_u$、 $q_i$、 $d_t$ 分别是用户 $u$、物品 $i$和处理 $t$的潜在表示。预测值$\hat{}y_{u,i,t}$用于推断处理 $t$下用户-物品对$(u,i)$ 的潜在结果。以二元处理设定为例，用户-物品对$(u,i)$ 的增益值可通过$\hat{}y_{u,i,t=1} - \hat{}y_{u,i,t=0}$估计。Sato 等人 [88] 采用匹配估计量 [232] 估计未观测到的反事实结果，并进一步估计推荐中的因果效应。具体而言，遵循推荐系统中的邻域方法，该方法用一组邻居的观测结果加权平均值替代潜在结果，以计算因果效应；这些邻居可以是邻近用户，也可以是邻近物品。

*11.2.3* 重新加权

仅凭观察数据估计因果效应颇具挑战，因为真实值无法观测，而且估计容易受到观察数据中偏差的影响。为解决这一问题，一些已有研究设计了基于IPS的方法，以估计推荐或评估中的无偏因果效应。增益值（即因果效应）的无偏估计可由IPS [233]表示。实际应用中，IPS容易产生高方差问题。为解决这一问题，Sato 等人 [233]采用截断逆倾向评分（CIPS）训练无偏的基于增益的模型；Sato 等人 [75] 提出了一种使用自归一化逆倾向评分（SNIPS） [234]进行基于增益的评估的无偏估计量；Xiao和Wang [235] 采用双重稳健技术 [107, 236]训练用于基于增益的推荐的无偏鲁棒模型。

**11.3 开放问题**

现有关于基于增益的推荐的研究主要关注如何表示增益值，以及如何利用潜在结果框架估计因果效应。结构因果模型是因果推断的强大工具，但很少被用于基于增益的推荐。采用结构因果模型的现有研究试图估计系统推荐某个物品时用户的偏好，这可以通过对所设计的因果图执行 $do$-操作来估计。然而，如何通过 $do$-操作估计没有推荐时的偏好，目前仍不清楚。首先，结构因果模型需要设计因果图。采用结构因果模型进行因果推荐的现有研究很少明确将推荐的影响纳入因果图；然而，对于基于增益的推荐，是否需要一个明确描绘推荐影响的特定因果图，仍有待讨论。其次，如何通过 $do$-操作对没有推荐时的偏好进行数学表示，也是一项挑战。最后，对于基于增益的推荐，如果已经确定了所设计的因果图以及没有推荐时偏好的数学表示，那么将因果技术应用于没有推荐时的偏好，可能会与现有研究有所不同。

**12 推荐中的因果无偏性**

如今，推荐算法已广泛应用于多个领域，以缓解日常生活中的信息过载。尽管推荐系统（RS）已对众多现实应用产生了巨大影响，但仍面临许多棘手的偏差问题；若对此置之不理，将影响推荐系统的长期效益。偏差问题在推荐系统中十分常见，因为推荐系统的一个固有特征就是反馈回路。按照普遍接受的理解 [35, 36],，从宏观视角来看，推荐系统中的反馈回路可分为三个部分：1）数据收集部分（用户 $\rightarrow$ 数据）；2）模型训练部分（数据 $\rightarrow$ 模型）；3）模型服务部分（模型 $\rightarrow$ 用户）。不同的偏差定义存在于各个部分以及整个反馈回路中。我们将在下文详细介绍。

**12.1 问题介绍**

正如我们所提到的，偏差问题存在于反馈回路的各个部分以及整体之中。下面我们将介绍 RS 反馈回路中不同的偏差定义：

- **数据偏差**指用于训练的已收集数据与理想测试数据之间的分布差异。通常，RS 的训练数据是观察性数据，而非实验性数据。用户决策可能受到多种因素影响，例如 RS 的曝光机制，因此训练分布与测试分布不同。此外，训练数据可能无法真实反映用户偏好，从而误导推荐模型，导致预测不准确。下面我们将介绍四种数据偏差：

  – 选择偏差：选择偏差源于用户的显式反馈（即评分）。选择偏差是指由于用户的选择，观察到的评分无法代表所有评分。它也被称为随机缺失（MNAR）。

  – 曝光偏差：曝光偏差通常出现在采用隐式反馈的推荐中。由于观测数据中没有用户点踩某个物品的信息，学习过程会用未观测交互来表示负向偏好。曝光偏差意味着未观测交互不一定代表用户的负向偏好，因为用户只接触到了少部分物品。

  – 从众偏差：从众偏差是指用户倾向于表现得与群体中的其他人相似，即使这种行为违背了自己的判断，因此反馈可能无法代表用户的真实偏好。

  – 位置偏差：位置偏差在推荐中很常见，尤其是在结果以排序列表形式呈现时。位置偏差是指用户倾向于与推荐列表中排名较高的物品交互，即使这些物品可能与用户的相关性并不高。

- **模型中的偏差**指模型设计中的偏差。偏差并非总是有害的。事实上，模型中的偏差使模型能够将预测泛化到未观测样本。

  –归纳偏差：归纳偏差是模型设计者为帮助模型更好地学习目标并泛化到训练数据之外而做出的假设。

- **结果偏差**指推荐算法倾向于在向用户呈现的推荐结果中表现出偏差这一现象。通常，从两个角度研究推荐结果中的偏差：一是流行度偏差，二是不公平性。第 9 节已介绍公平性及相关方法，因此本节将结果偏差限定为流行度偏差。

  –流行度偏差：流行度偏差是指热门物品获得的推荐频率超出其流行度所应有水平的现象。

• **反馈回路偏差** 是指由整个推荐系统反馈回路机制引入并放大的偏差。数据偏差会导致数据不平衡，进而造成推荐结果中的偏差问题；而有偏的推荐又会反过来影响用户行为，并进一步放大未来推荐中的偏差。以流行度偏差为例，热门物品在观测数据中获得更多曝光，进而拥有更多被推荐的机会，导致偏差加剧：热门物品变得更热门，而非热门物品则变得更加冷门[237, 238, 239]。若不加以处理，这些由反馈回路造成的偏差会导致回音室[115, 240]或过滤气泡 [241, 242, 243, 244],，降低多样性并加剧同质化。

一般而言，推荐系统中的去偏有两种方式：一种是在训练过程中去偏，另一种是在评估过程中去偏。近年来，将因果推断引入去偏推荐取得了巨大成功。接下来，我们将介绍基于因果推断的去偏推荐模型相关研究。

## 12.2 因果方法

### *12.2.1* 数据处理

为了解决推荐系统中的偏差问题，一个直接的方案是利用无偏数据[82, 96, 97, 98, 99, 100, 101, 102]。正如我们在本节中提到的，在放宽可忽略性假设的前提下，将有限的实验数据与观察数据结合起来是一种可行的方案。在推荐系统中，实验数据也称为无偏数据，它通过使用随机推荐策略而非常规推荐策略来干预系统。具体而言，对于每位用户，系统不使用推荐模型展示物品，而是随机选择一些物品进行展示。利用无偏数据有助于实现去偏预测，因为采用随机推荐会打破反馈回路。关键挑战在于如何将少量无偏数据纳入模型设计。例如，Rosenfeld 等人 [96]以及 Bonner 和 Vasile [82] 分别为有偏数据和无偏数据使用两个推荐模型，并通过正则化将这两个模型连接起来。Yuan 等人 [97]利用无偏数据为广告点击预测训练插补模型。Chen 等人 [101] 通过元学习利用无偏数据。尽管利用无偏数据能够有效处理偏差，但收集无偏数据时会向用户随机推荐物品，而不是使用个性化推荐模型，这不可避免地会损害用户体验和平台收入。

### *12.2.2* 重新加权

另一种常用方法基于重新加权，使用逆倾向得分对数据样本重新加权，以应对不同的偏差问题，例如选择偏差 [90, 106], 曝光偏差 [70, 72, 73, 245], 位置偏差 [246, 247, 248, 249, 250, 251], 等。关键挑战在于如何估计倾向得分，以及如何将其应用于优化中。一些研究 [70, 252] 使用基于流行度的倾向估计器。一些研究 [73, 248, 250, 251]提出对偶问题，同时优化倾向估计器和推荐模型。一些研究 [249]提出从观察数据中学习倾向得分。一些研究 [207, 235] 使用双重稳健模型来处理不准确的倾向估计器。逆倾向评分方法存在一些局限，例如倾向得分不准确，以及面临高方差问题[206]。

### *12.2.3* 因果调整

因果调整是解决偏差问题的另一项有前景的方向 [77, 79, 81, 114, 115]。借助 do 运算符，所设计的模型旨在估计因果偏好 $P(Y|U,\ do(V))$，即在干预物品曝光的情况下得到的偏好，而非传统推荐模型估计的纯关联偏好 $P(Y|U,\ V)$。直观地说，这可以理解为回答一个反事实问题：如果我们干预并将物品曝光给用户，用户会有什么偏好？因果调整利用观察数据来估计因果偏好。具体而言，因果调整包括后门调整[68], 前门调整 [68], 等。根据所设计的因果图（该图表示推荐系统中数据生成的底层机制），首先要找出一组满足相应准则的变量（例如，后门调整所需的后门准则、前门调整所需的前门准则），然后对已识别的变量集进行因果调整，以估计因果偏好。例如，张等人 [79] 采用后门调整来缓解物品流行度造成的曝光偏差；Xu 等人 [77] 利用前门调整消除未观测混杂因素的影响；Wang 等人 [114] 利用后门调整来缓解流行度偏差的影响。因果调整要求找出一组满足相应准则的变量，但对于推荐系统的一个合理因果图而言，并不总能找到满足此类准则的变量集。不过，所设计的因果图仍能从其他方面为模型设计提供指导。

### *12.2.4* 因果图

因果图是因果建模中一种有效且强大的工具，用于描绘推荐系统中的数据生成过程。研究人员以设计好的因果图为指导，设计用于去偏的因果模型 [80, 253]。例如，Zhao 等人 [253] 和 Zheng 等人 [80]基于设计好的因果图，将偏差的影响与用户偏好区分开来，并仅根据用户偏好推荐物品；Wei 等人 [95] 和 Wang 等人 [94] 则基于设计好的因果图表示反事实世界，并通过反事实推理进行推荐。

## 12.3 开放问题

逆倾向评分（IPS）是一种有价值的去偏方法。然而，逆倾向评分方法的有效性在很大程度上取决于倾向得分是否正确。如何获得正确的倾向得分仍然是一个重要

但尚未解决的问题。现有研究通常根据物品的一些特征设计简单的倾向估计器，例如基于流行度的倾向性 [70]，，或从数据中学习倾向得分 [73, 248, 249, 250, 251]。倾向得分是否正确，通常只能通过推荐性能的提升间接估计。因此，如何定量评估倾向得分的正确性仍是一个开放问题，有待进一步探索。

## 13 开放问题与未来方向

### 13.1 底层因果机制

回顾上文介绍的现有研究，其中大多数基于推荐系统的底层因果机制，并通过预先定义的因果关系来表示这些机制。一般而言，预先定义的因果关系可分为三个层级。第一个层级仅识别因与果。例如，逆倾向评分方法只研究两个变量之间的定量关系，一个是原因，另一个是结果。例如，在一些用于推荐去偏的基于逆倾向评分的模型中，原因是物品曝光，结果是交互概率。第二个层级是定义因果图，即识别所有变量对之间的因果关系（也就是说，因果关系是否存在，以及若存在，其方向如何）。通过预先定义因果图，一些现有研究在因果图的指导下设计模型。例如，一些研究 [80, 253]基于定义好的因果图，分离多个原因对结果的影响，以实现无偏性。最后一个层级是结构因果模型，它不仅定义因果关系，也定义定量关系（即结构方程以原因作为输入，并返回结果的值）。所提出模型的有效性与底层因果机制的正确性密切相关。目前，大多数现有研究通过专家知识来定义底层因果机制。预先定义的因果机制是否正确，只能通过推荐性能间接反映。因此，值得进一步探索如何直接、定量地评估所定义的因果机制。另一个观察是，即使在相同的实际场景下，不同模型也可能采用不同的预先定义因果机制。因此，我们认为应当提出一种通用的因果机制。

### 13.2 因果发现

除了对预定义因果机制准确性的担忧之外，预定义因果机制的另一个局限在于，基于专家知识构建的预定义因果机制通常相当简单，只考虑了少数因素。然而，在真实世界场景中，决策过程（即推荐系统潜在的因果机制）可能涉及更多因素，超出领域专家的理解范围。因此，从数据中学习因果关系是推荐系统中一个重要但尚未解决的问题。目前只有少量工作 [125, 126] 基于连续优化设计了用于 [127, 254]推荐的因果发现方法。所学习到的因果机制可以用于可解释推荐，或被用于改进推荐。因此，提出面向推荐的因果发现方法是一个很有前景的方向。如何评估所提出的面向推荐的因果发现方法同样是一个挑战。由于真实世界数据中不存在真实因果机制，推荐中的因果发现方法通常通过推荐性能进行间接评估。为了直接评估面向推荐的因果发现方法，一种可能的解决方案是使用模拟（我们将在下一节介绍）。

### 13.3 因果驱动模拟

模拟是构建环境的最强大方法之一，可用于测量和分析推荐系统。构建用于推荐的模拟环境将使业界和学术界都受益。例如，对于业界而言，模拟为从业者提供了可控的环境，使其能够分析所关注的目标（例如某些业务目的），在规避伦理风险的同时加快应用开发进程。对于学术界的研究人员而言，由于现实世界中的推荐系统存在可访问性限制，一些提出的方法无法得到评估。使用模拟可以解决这一问题。现有模拟利用强化学习技术，在设计好的环境中模拟决策过程。然而，缺乏底层因果机制的现有模拟可能导致决策不准确且不稳定。将因果机制融入模拟，能够实现更稳定的系统，以便进行长期分析和因果关系相关分析。例如，因果驱动模拟可用于评估推荐中的因果发现方法。因此，因果驱动模拟将在推荐系统中发挥重要作用，值得进一步探索。

## 14 结论

在这篇综述中，我们全面回顾了推荐中的因果推断方法。首先，我们介绍推荐系统的基础知识；随后，从因果推断和推荐系统两个视角介绍现有研究。具体而言，一方面，我们介绍因果推断相关知识，并阐述其与推荐系统之间的联系；另一方面，我们介绍推荐系统中的不同问题，以及因果推断的应用方式。最后，我们进一步列出一些开放问题和未来方向。我们希望这篇综述能为该领域的研究人员和从业者带来帮助，并激发更多关于推荐中的因果推断的研究。

## 参考文献

[1] D. Jannach、M. Zanker、A. Felfernig 和 G. Friedrich，推荐系统：入门。剑桥大学出版社，2010年。

[2] S. Zhang、L. Yao、A. Sun 和 Y. Tay，“基于深度学习的推荐系统：综述与新视角”，*ACM* 计算调查 *(CSUR)*，第52卷，第1期，第1–38页，2019。

[3] G. Adomavicius 和 A. Tuzhilin，“迈向新一代推荐系统：现状综述与可能的扩展”，*IEEE*知识与数据工程汇刊，第17卷，第6期，第734–749页，2005年。[4] P. Resnick、N. Iacovou、M. Suchak、P. Bergstrom 和 J. Riedl，“Grouplens：用于网络新闻协同过滤的开放式架构”，载于*CSCW*，1994年，第175–186页。[5] J. A. Konstan、B. N. Miller、D. Maltz、J. L. Herlocker、L. R. Gordon 和 J. Riedl，“Grouplens：将协同过滤应用于Usenet新闻”，*ACM*通讯，第40卷，第3期，第77–87页，1997年。[6] B. Sarwar、G. Karypis、J. Konstan 和 J. Riedl，“基于物品的协同过滤推荐算法”，载于*WWW*，2001年，第285–295页。[7] G. Linden、B. Smith 和 J. York，“Amazon.com推荐：物品到物品协同过滤”，*IEEE互*联网计算，第7卷，第1期，2003年。[8] Y. Koren、R. Bell 和 C. Volinsky，“推荐系统的矩阵分解技术”，*Computer*，第42卷，第8期，第30–37页，2009年。[9] A. Mnih 和 R. R. Salakhutdinov，“概率矩阵分解”，载于神经信息处理系统进展，2008年，第1257–1264页。[10] S. Rendle，“分解机”，载于*2010*年 *IEEE*国际数据挖掘会议。IEEE，2010年，第995–1000页。[11] H.-T. Cheng、L. Koc、J. Harmsen、T. Shaked、T. Chandra、H. Aradhye、G. Anderson、G. Corrado、W. Chai、M. Ispir等，“推荐系统的宽度与深度学习”，载于第一届推荐系统深度学习研讨会论文集，2016年，第7–10页。[12] H.-J. Xue、X. Dai、J. Zhang、S. Huang 和 J. Chen，“面向推荐系统的深度矩阵分解模型”，载于*IJCAI*，第17卷。澳大利亚墨尔本，2017年，第3203–3209页。[13] X. He、L. Liao、H. Zhang、L. Nie、X. Hu 和 T.-S. Chua，“神经协同过滤”，载于*WWW*，2017年，第173–182页。[14] C.-K. Hsieh、L. Yang、Y. Cui、T.-Y. Lin、S. Belongie 和 D. Estrin，“协同度量学习”，载于*InWWW*，2017年，第193–201页。[15] L. Zheng、V. Noroozi 和 P. S. Yu，“利用评论联合深度建模用户与物品以实现推荐”，载于*WSDM*，2017年。[16] Y. Zhang、Q. Ai、X. Chen 和 W. B. Croft，“利用异构信息源进行Top-N推荐的联合表示学习”，载于*CIKM*，2017年，第1449–1458页。[17] F. Zhang、N. J. Yuan、D. Lian、X. Xie 和 W.-Y. Ma，“面向推荐系统的协同知识库嵌入”，载于*KDD*，2016年，第353–362页。[18] Q. Ai、V. Azizi、X. Chen 和 Y. Zhang，“用于可解释推荐的异构知识库嵌入学习”，*Algorithms*，第11卷，第9期，第137页，2018年。[19] J. McAuley、C. Targett、Q. Shi 和 A. van den Hengel，“基于风格和替代品的图像推荐”，载于*SIGIR*。ACM，2015年。[20] B. Hidasi、A. Karatzoglou、L. Baltrunas 和 D. Tikk，“基于循环神经网络的会话推荐”，载于*ICLR*，2016年。[21] W.-C. Kang 和 J. McAuley，“自注意力序列推荐”，载于 *2018*年 *IEEE* 数据挖掘国际会议（*ICDM*）。IEEE，2018年。[22] M. Kompan 和 M. Bielikov´a，“基于内容的新闻推荐”，载于国际电子商务与网络技术会议。Springer，2010年，第61–72页。[23] P. Covington、J. Adams 和 E. Sargin，“用于 YouTube 推荐的深度神经网络”，载于第十届*ACM*推荐系统会议论文集，2016年，第191–198页。[24] Q. Liu、S. Wu 和 L. Wang，“DeepStyle：学习用户对视觉推荐的偏好”，载于第*40*届*ACM SIGIR*国际信息检索研究与发展会议论文集，2017年，第841–844页。[25] R. Burke，“混合推荐系统：综述与实验”，用户建模与用户自适应交互，第12卷，第4期，第331–370页，2002年。[26] D. B. Rubin，“在随机和非随机研究中估计处理的因果效应。”《教育心理学杂志》，第66卷，第5期，第688页，1974年。[27] J. Pearl，《因果关系》。剑桥大学出版社，2009年。[28] ——，“统计学中的因果推断：概述”，《统计调查》，第3卷，第96–146页，2009年。[29] Y. Zhang、X. Chen 等，“可解释推荐：综述与新视角”，《信息检索基础与趋势》，第14卷，第1期，第1–101页，2020年。[30] X. Chen、Y. Zhang 和 J.-R. Wen，“衡量推荐系统中的‘解释’：关于可解释推荐评估的综合综述”，*arXiv*预印本 *arXiv:2202.06466*，2022年。[31] Y. Li、H. Chen、S. Xu、Y. Ge、J. Tan、S. Liu 和 Y. Zhang，“推荐公平性：综述”，*arXiv*预印本 *arXiv:2205.13619*，2022年。[32] Y. Wang、W. Ma、M. Zhang*、Y. Liu 和 S. Ma，“推荐系统公平性综述”，《*ACM*计算机学会会刊》（*JACM*），2022年。[33] Y. Ge、S. Liu、Z. Fu、J. Tan、Z. Li、S. Xu、Y. Li、Y. Xian 和 Y. Zhang，“可信推荐系统综述”，*arXiv*预印本 *arXiv:2207.12515*，2022年。[34] S. Wang、X. Zhang、Y. Wang、H. Liu 和 F. Ricci，“可信推荐系统”，*arXiv*预印本 *arXiv:2208.06265*，2022年。[35] W. Fan、X. Zhao、X. Chen、J. Su、J. Gao、L. Wang、Q. Liu、Y. Wang、H. Xu、L. Chen 等，“可信推荐系统综合综述”，*arXiv*预印本 *arXiv:2209.10117*，2022年。[36] J. Chen、H. Dong、X. Wang、F. Feng、M. Wang 和 X. He，“推荐系统中的偏差与去偏：综述及未来方向”，*arXiv*预印本 *arXiv:2010.03240*，2020年。[37] H. Ko、S. Lee、Y. Park 和 A. Choi，“推荐系统综述：推荐模型、技术与应用领域”，《电子学》，第11卷，第1期，第141页，2022年。[38] L. Yao、Z. Chu、S. Li、Y. Li、J. Gao 和 A. Zhang，

“因果推断综述 ,” *ACM Transactions on* 从数据中发现知识 *(TKDD)*，第 15 卷，第 5 期，第 1–46 页，2021年。[39] R. Guo、L. Cheng、J. Li、P. R. Hahn 和 H. Liu，“利用数据学习因果关系的综述：问题与方法”，*ACM* 计算调查 *(CSUR)*，第 53 卷，第 4 期，第 1–37 页，2020年。[40] M. J. Vowels、N. C. Camgoz 和 R. Bowden，“你喜欢有向无环图吗？结构学习与因果发现综述”，*ACM* 计算调查 *(CSUR)*，2021年。[41] C. Gao、Y. Zheng、W. Wang、F. Feng、X. He 和 Y. 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年。[42]A. Karatzoglou、X. Amatriain、L. Baltrunas 和 N. Oliver，“多元推荐：面向上下文感知协同过滤的 n 维张量分解”，载于第四届 *ACM* 推荐系统会议论文集，2010年，第 79–86 页。[43] R. Van Meteren 和 M. Van Someren，“使用基于内容的过滤进行推荐”，载于新时代信息领域的机器学习：*ML-net/ECML2000* 研讨会论文集，第 30 卷，2000年，第 47–56 页。[44] M. J. Pazzani 和 D. Billsus，“基于内容的推荐系统”，载于《自适应网络》。Springer，2007年，第 325–341 页。[45] J. Bobadilla、F. Ortega、A. Hernando 和 A. Guti´errez，“推荐系统综述”，基于知识的系统，第 46 卷，第 109–132 页，2013年。[46] T. Alashkar、S. Jiang、S. Wang 和 Y. Fu，“示例规则引导的深度神经网络用于化妆推荐”，载于*AAAI*人工智能会议论文集，第 31 卷，第 1 期，2017。[47] D. Liang、M. Zhan 和 D. P. Ellis，“利用预训练神经网络进行内容感知协同音乐推荐”，载于*ISMIR*，2015年，第 295–301 页。[48] R. Burke，“混合型网络推荐系统”，载于《自适应网络》。Springer，2007年，第 377–408 页。[49] E. C¸ano 和 M. Morisio，“混合推荐系统：系统性文献综述”，《智能数据分析》，第 21 卷，第 6 期，第 1487–1524 页，2017。[50] M. Balabanovi´c 和 Y. Shoham，“Fab：基于内容的协同推荐”，*ACM*通讯，第 40 卷，第 3 期，第 66–72 页，1997。[51] P. Melville、R. J. Mooney、R. Nagarajan等，“用于改进推荐的内容增强型协同过滤”，*AAAI/IAAI*，第 23 卷，第 187–192 页，2002年。[52] H. Fang、D. Zhang、Y. Shu 和 G. Guo，“序列推荐中的深度学习：算法、影响因素与评估”，*ACM*信息系统汇刊 *(TOIS)*，第 39 卷，第 1 期，第 1–42 页，2020年。[53] S. Rendle、C. Freudenthaler 和 L. Schmidt-Thieme，“用于下一篮子推荐的个性化马尔可夫链分解”，载于第 *19* 届万维网国际会议论文集，2010年，第 811–820 页。[54] H. Hu、X. He、J. Gao 和 Z.-L. Zhang，“为下一篮子推荐建模个性化物品频率信息”，载于第 43 届国际*ACM SIGIR*信息检索研究与发展会议，2020年，第 1071–1080页。[55] B. Hidasi、A. Karatzoglou、L. Baltrunas和D. Tikk，“基于会话的推荐与循环神经网络”，*arXiv*预印本 *arXiv:1511.06939*，2015年。[56] C.-Y. Wu、A. Ahmed、A. Beutel、A. J. Smola和H. Jing，“循环推荐网络”，载于第十届*ACM*国际网络搜索与数据挖掘会议论文集，2017年，第495–503页。[57] J. Tang和K. Wang，“通过卷积序列嵌入实现个性化 Top-N 序列推荐”，载于第十一届*ACM*国际网络搜索与数据挖掘会议论文集，2018年，第565–573页。[58] F. Yuan、A. Karatzoglou、I. Arapakis、J. M. Jose和X. He，“用于下一物品推荐的简单卷积生成网络”，载于第*12*届*ACM*国际网络搜索与数据挖掘会议论文集，2019年，第582–590页。[59] S. Wang、L. Hu、L. Cao、X. Huang、D. Lian和W. Liu，“用于下一物品推荐的基于注意力的交易上下文嵌入”，载于*AAAI*人工智能会议论文集，第32卷，第1期，2018年。[60] X. Chen、H. Xu、Y. Zhang、J. Tang、Y. Cao、Z. Qin和H. Zha，“基于用户记忆网络的序列推荐”，载于第十一届*ACM*国际网络搜索与数据挖掘会议论文集，2018年，第108–116页。[61] C. Raffel、N. Shazeer、A. Roberts、K. Lee、S. Narang、M. Matena、Y. Zhou、W. Li、P. J. Liu 等，“探索统一文本到文本转换器的迁移学习极限。”机器学习研究期刊，第21卷，第140期，第1–67页，2020年。[62] T. Brown、B.Mann、N. Ryder、M. Subbiah、J. D. Kaplan、P. Dhariwal、A. Neelakantan、P. Shyam、G. Sastry、A. Askell 等，“语言模型是少样本学习器”，神经信息处理系统进展，第33卷，第1877–1901页，2020年。[63] S. Zhang、S. Roller、N. Goyal、M. Artetxe、M. Chen、S. Chen、C. Dewan、M. Diab、X. Li、X. V. Lin等，“OPT：开放预训练Transformer语言模型”，*arXiv*预印本 *arXiv:2205.01068*，2022年。[64] A. Chowdhery、S. Narang、J. Devlin、M. Bosma、G. Mishra、A. Roberts、P. Barham、H. W. Chung、C. Sutton、S. Gehrmann等，“PaLM：利用Pathways扩展语言建模”，*arXiv*预印本 *arXiv:2204.02311*，2022年。[65] S. Geng、S. Liu、Z. Fu、Y. Ge和Y. Zhang，“将推荐视为语言处理（RLP）：统一的预训练、个性化提示与预测范式（P5）”，载于第*16*届*ACM*推荐系统会议论文集，2022年。[66] Z. Zhu、X. Hu和J. Caverlee，“公平性感知的张量推荐”，载于第*27*届*ACM*信息与知识管理国际会议论文集，2018年，第1153–1162页。[67] P. W. Holland，“统计学与因果推断”，美国统计学会期刊，第81卷，第396期，第945–960页，1986年。

[68] M. Glymour、J. Pearl和N. P. Jewell，《统计学中的因果推断：入门》。John Wiley & Sons，2016年。[69] B. B. Frey，《*SAGE*教育研究、测量与评估百科全书》。Sage Publications，2018年。[70] Y. Saito、S. Yaginuma、Y. Nishino、H. Sakata和K. 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，2020年，第501–509页。[71] Y. Saito，“从隐式反馈中进行无偏成对学习”，载于*NeurIPS 2019*因果机器学习研讨会，2019年。[72] L. Yang、Y. Cui、Y. Xuan、C. Wang、S. Belongie和D. Estrin，“针对非随机缺失隐式反馈的无偏离线推荐系统评估”，载于第*12*届*ACM*推荐系统会议论文集，2018年，第279–287页。[73] Z. Zhu、Y. He、Y. Zhang和J. Caverlee，“通过组合联合学习实现无偏隐式推荐与倾向得分估计”，载于第*14*届*ACM*推荐系统会议，2020年，第551–556页。[74] S. Ding、P. Wu、F. Feng、Y. Wang、X. He、Y. Liao和Y. Zhang，“通过敏感性分析解决推荐中的未测量混杂因素问题”，载于第*28*届*ACM SIGKDD*知识发现与数据挖掘会议论文集，2022年，第305–315页。[75] M. Sato、J. Singh、S. Takemori、T. Sonoda、Q. Zhang和T. Ohkuma，“推荐系统的基于增益的评估与优化”，载于第*13*届*ACM*推荐系统会议论文集，2019年，第296–304页。[76] K. Makhlouf、S. Zhioua和C. Palamidessi，“基于因果的机器学习公平性概念综述”，*arXiv*预印本 *arXiv:2010.09553*，2020年。[77] S. Xu、J. Tan、S. Heinecke、J. Li和Y. Zhang，“去混杂因果协同过滤”，*arXiv*预印本 *arXiv:2110.07122*，2021年。[78] Y. Wang、D. Liang、L. Charlin和D. M. Blei，“推荐系统的因果推断”，载于第*14*届*ACM*推荐系统会议，2020年，第426–431页。[79] Y. Zhang、F. Feng、X. He、T. Wei、C. Song、G. Ling和Y. Zhang，“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会议论文集，2021年，第11–20页。[80] Y. Zheng、C. Gao、X. Li、X. He、Y. Li和D. Jin，“利用因果嵌入解耦用户兴趣与从众性以进行推荐”，载于*2021*年网络会议论文集，2021年，第2980–2991页。[81] S. Xu、Y. Ge、Y. Li、Z. Fu、X. Chen和Y. Zhang，“因果协同过滤”，*arXiv*预印本 *arXiv:2102.01868*，2021年。[82] S. Bonner和F. 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，2018年，第104–112页。[83] J. Pearl，“因果推断数学”，即将出版，*IMS*，2013年。[84] U. Shalit、F. D. Johansson和D. Sontag，“估计个体处理效应：泛化界和算法”，载于国际机器学习会议。PMLR，2017年，第3076–3085页。[85] F. Johansson、U. Shalit 和 D. Sontag，“学习用于反事实推断的表示”，载于国际机器学习会议。PMLR，2016年，第3020–3029页。[86] W. Shang、Q. Li、Z. Qin、Y. Yu、Y. Meng 和 J. Ye，“利用提升推断估计强化学习推荐中的部分可观测环境”，《机器学习》，第110卷，第9期，第2603–2640页，2021年。[87] X. Xie、Z. Liu、S. Wu、F. Sun、C. Liu、J. Chen、J. Gao、B. Cui 和 B. Ding，“CausCF：用于推荐效果估计的因果协同过滤”，载于第*30*届*ACM*信息与知识管理国际会议论文集，2021年，第4253–4263页。[88] M. Sato、J. Singh、S. Takemori 和 Q. Zhang，“ 面向推荐系统的因果感知邻域方法 ”，载于欧洲信息检索会议。Springer，2021年，第603–618页。[89] S. Xu、Y. Li、S. Liu、Z. Fu、Y. Ge、X. Chen 和 Y. Zhang，“学习推荐的因果解释”，载于第一届搜索与推荐因果关系国际研讨会，2021年。[90] T. Schnabel、A. Swaminathan、A. Singh、N. Chandak 和 T. Joachims，“将推荐视为处理：去偏学习与评估”，载于国际机器学习会议。PMLR，2016年，第1670–1679页。[91] M. J. Kusner、J. Loftus、C. Russell 和 R. Silva，“反事实公平性”，《神经信息处理系统进展》，第30卷，2017年。[92] Y. Wu、L. Zhang 和 X. Wu，“利用因果图发现并消除排序数据中的歧视”，载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2018年，第2536–2544页。[93] J. Zhang 和 E. Bareinboim，“决策中的公平性——因果解释公式”，载于*AAAI*人工智能会议论文集，第32卷，第1期，2018年。[94] W. Wang、F. Feng、X. He、H. Zhang 和 T.-S. Chua，“点击可能具有欺骗性：通过反事实推荐缓解标题党问题”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第1288–1297页。[95] T. Wei、F. Feng、J. Chen、Z. Wu、J. Yi 和 X. 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，2021年，第1791–1800页。[96] N. Rosenfeld、Y. Mansour 和 E. Yom-Tov，“从大规模历史数据和小规模随机试验中预测反事实”，载于第*26*届万维网国际会议伴会论文集，2017年，第602–609页。[97] B. Yuan、J.-Y. Hsia、M.-Y. Yang、H. Zhu、C.-Y. Chang、Z. Dong 和 C.-J. Lin，“通过考虑未展示事件改进广告点击预测

”，载于第*28*届*ACM*信息与知识管理国际会议论文集，2019年，第329–338页。[98] D. Liu、P. Cheng、Z. Dong、X. He、W. Pan 和 Z. Ming，“一种利用均匀数据进行反事实推荐的通用知识蒸馏框架”，载于第*43*届*ACM SIGIR*信息检索研究与发展国际会议论文集，2020年，第831–840页。[99] R. Jiang、S. Chiappa、T. Lattimore、A. Gy¨orgy 和 P. Kohli，“推荐系统中的退化反馈回路”，载于*2019*年*AAAI/ACM*人工智能、伦理与社会会议论文集，2019年，第383–390页。[100] J. Yu、H. Zhu、C.-Y. Chang、X. Feng、B. Yuan、X. He 和 Z. Dong，“用于无偏推荐的影响函数”，载于第*43*届*ACM SIGIR*信息检索研究与发展国际会议论文集，2020年，第1929–1932页。[101] J. Chen、H. Dong、Y. Qiu、X. He、X. Xin、L. Chen、G. Lin 和 K. Yang，“Autodebias：学习去偏以实现推荐”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第21–30页。[102] Z. Lin、D. Liu、W. Pan 和 Z. Ming，“协同推荐中的迁移学习与偏差消除”，载于第*15*届*ACM*推荐系统会议，2021年，第736–740页。[103] C. Macdonald，“推荐系统离线评估中的辛普森悖论”，《*ACM*信息系统汇刊》，2021年。[104] J. K. Lunceford 和 M. Davidian，“通过倾向得分进行分层与加权以估计因果处理效应：一项比较研究”，《医学统计学》，第23卷，第19期，第2937–2960页，2004年。[105] K. Hirano、G. W. Imbens 和 G. Ridder，“使用估计倾向得分有效估计平均处理效应”，《计量经济学》，第71卷，第4期，第1161–1189页，2003年。[106] X. Wang、R. Zhang、Y. Sun 和 J. Qi，“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*网页搜索与数据挖掘国际会议论文集，2021年，第427–435页。[107] H. Bang 和 J. M. Robins，“缺失数据与因果推断模型中的双重稳健估计”，《生物统计学》，第61卷，第4期，第962–973页，2005年。[108]B. K. Lee、J. Lessler 和 E. A. Stuart，“权重截尾与倾向得分加权”，《*PLOS ONE*》，第6卷，第3期，文章编号e18174，2011年。[109] J. Hainmueller，“因果效应的熵平衡：一种用于在观察性研究中生成平衡样本的多变量重新加权方法”，《政治分析》，第20卷，第1期，第25–46页，2012年。[110]S. Athey、G. W. Imbens 和 S. Wager，“近似残差平衡：高维平均处理效应的去偏推断”，《英国皇家统计学会杂志：*B*辑（统计方法）》，第80卷，第4期，第597–623页，2018年。[111] K. Kuang、P. Cui、B. Li、M. Jiang、Y. Wang、F. Wu 和 S. Yang，“通过差异化混杂因素平衡与回归估计处理效应”，《ACM汇刊《知识发现汇刊》（*TKDD*），第14卷，第1期，第1–25页，2019年。[112]Z. Shen、P. Cui、T. Zhang 和 K. Kunag，《通过样本重加权实现稳定学习》，载于*AAAI*人工智能会议论文集，第34卷，第04期，2020年，第5692–5699页。[113]Y. Li、H. Chen、J. Tan 和 Y. Zhang，《面向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，2022年，第1–9页。[114] W. Wang、F. Feng、X. He、X. Wang 和 T.-S. 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，2021年，第1717–1725页。[115] S. Xu、J. Tan、Z. Fu、J. Ji、S. Heinecke 和 Y. 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，2022年，第2301–2310页。[116] R. Guo、J. Li 和 H. Liu，《从网络化观察数据中学习个体因果效应》，载于第*13*届国际网络搜索与数据挖掘会议论文集，2020年，第232–240页。[117]N. Kallus、A. M. Puli 和 U. Shalit，《通过实验锚定消除隐藏混杂》，载于神经信息处理系统进展，第31卷，2018年。[118]X. Zhu、Y. Zhang、F. Feng、X. Yang、D. Wang 和 X. He，《缓解因果推荐中的隐藏混杂效应》，*arXiv*预印本 *arXiv:2205.07499*，2022年。[119] J. D. Angrist 和 J.-S. Pischke，《基本无害的计量经济学：经验主义者的指南》。普林斯顿大学出版社，2009年。[120] J. Hartford、G. Lewis、K. Leyton-Brown 和 M. Taddy，《深度工具变量：一种用于反事实预测的灵活方法》，载于国际机器学习会议。PMLR，2017年，第1414–1423页。[121] Z. Si、X. Han、X. Zhang、J. Xu、Y. Yin、Y. Song 和 J.-R. Wen，《一种利用搜索数据进行推荐的模型无关因果学习框架》，载于*2022*年*ACM*网络会议论文集，2022年，第224–233页。[122] Y. Bengio、T. Deleu、N. Rahaman、R. Ke、S. Lachapelle、O. Bilaniuk、A. Goyal 和 C. Pal，《用于学习解耦因果机制的元迁移目标》，*arXiv*预印本 *arXiv:1901.10912*，2019年。[123] D. Malinsky 和 D. Danks，《因果发现算法：实用指南》，哲学指南，第13卷，第1期，文章编号e12470，2018年。[124] S. Shimizu、P. O. Hoyer、A. Hyv¨arinen、A. Kerminen 和 M. Jordan，《用于因果发现的线性非高斯无环模型》。机器学习研究期刊，第7卷，第10期，2006年。[125] Z. Wang、X. Chen、Z. Dong、Q. Dai 和 J.-R. Wen，《结合因果行为发现的序列推荐》，*arXiv*预印本 *arXiv:2204.00216*，2022年。[126]S. Xu、D. Xu、E. Korpeoglu、S. Kumar、S. Guo、K. Achan 和 Y. Zhang，《推荐系统中的因果结构学习》，*arXiv*预印本 *arXiv:2210.10256*，2022年。[127]X. Zheng、B. Aragam、P. K. Ravikumar 和 E. P.

Xing, 《无撕裂的有向无环图：用于结构学习的连续优化》，载于神经信息处理系统进展，第31卷，2018年。[128] Y. Zhang、G. Lai、M. Zhang、Y. Zhang、Y. Liu 和 S. Ma, 《基于短语级情感分析的显式因子模型与可解释推荐》，载于第*37*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2014年，第83–92页。[129]G. Peake 和 J. Wang, 《解释挖掘：推荐系统潜因子模型的事后可解释性》，载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2018年，第2060–2069页。[130] J. Tan、S. Xu、Y. Ge、Y. Li、X. Chen 和 Y. Zhang, 《反事实可解释推荐》，载于第*30*届*ACM*信息与知识管理国际会议论文集，2021年，第1784–1793页。[131] X. Wang、Y. Chen、J. Yang、L. Wu、Z. Wu 和 X. Xie, 《一种用于可解释推荐的强化学习框架》，载于*2018*年*IEEE*数据挖掘国际会议（*ICDM*）。IEEE，2018年，第587–596页。[132] L. Li、Y. Zhang 和 L. Chen, 《用于可解释推荐的个性化Transformer》，2021年。[133]S. Geng、Z. Fu、Y. Ge、L. Li、G. de Melo 和 Y. Zhang, 《通过可视化改进个性化解释生成》，载于第*60*届计算语言学协会年会论文集（第*1*卷：长篇论文），2022年，第244–255页。[134] Y. Xian、Z. Fu、S. Muthukrishnan、G. De Melo 和 Y. Zhang, 《用于可解释推荐的强化知识图谱推理》，载于第*42*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2019年，第285–294页。[135] Z. Chen、X. Wang、X. Xie、M. Parsana、A. Soni、X. Ao 和 E. Chen, 《迈向可解释对话推荐》，载于第二十九届国际人工智能联合会议论文集，2021年，第2994–3000页。[136]A. Ghazimatin、O. Balalau、R. Saha Roy 和 G. Weikum, 《Prince：通过反事实解释实现推荐系统的提供方可解释性》，载于*WSDM*，2020年，第196–204页。[137] Y. Ge、J. Tan、Y. Zhu、Y. Xia、J. Luo、S. Liu、Z. Fu、S. Geng、Z. Li 和 Y. Zhang, 《推荐中的可解释公平性》，载于第*45*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2022年。[138] K. H. Tran、A. Ghazimatin 和 R. Saha Roy, 《神经推荐系统的反事实解释》，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第1627–1631页。[139] Y. Li、H. Chen、S. Xu、Y. Ge 和 Y. Zhang, 《基于因果概念的个性化公平性探索》，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第1054–1063页。[140] Y. Li、H. Chen、Z. Fu、Y. Ge 和 Y. Zhang, 《用户

oriented fai性 i荐中 dation," in *P过程di*网络会议*2021*论文集, 2021, 第624–632页。[141] Y. Li、Y. Ge 和 Y. Zhang, "推荐系统中机器学习公平性教程", 载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第2654–2657页。[142] M. Mansoury、H. Abdollahpouri、J. Smith、A. Dehpanah、M. Pechenizkiy 和 B. Mobasher, "探究协同推荐系统中与性别歧视相关的潜在因素", 载于第三十三届国际 *FLairs* 会议，2020年。[143] A. D'Amour、H. Srinivasan、J. Atwood、P. Baljekar、D. Sculley 和 Y. Halpern, "公平性并非静态：通过仿真研究深入理解长期公平性", 载于*2020*年公平性、问责制与透明度会议论文集，2020年，第525–534页。[144] H. Abdollahpouri 和 R. Burke, "多利益相关方推荐及其与多边公平性的联系", 载于第*13*届*ACM*推荐系统会议期间举办的 *RMSE* 研讨会论文集，2019年。[145] Y. Ge、S. Liu、R. Gao、Y. Xian、Y. Li、X. Zhao、C. Pei、F. Sun、J. Ge、W. Ou 等, "迈向推荐中的长期公平性", 载于第*14*届*ACM*网页搜索与数据挖掘国际会议论文集，2021年，第445–453页。[146] M.-I. Dascalu、C.-N. Bodea、M. N. Mihailescu、E. A. Tanase 和 P. Ordo˜nez de Pablos, "教育推荐系统及其在终身学习中的应用", *Behaviour & informationtechnology*，第35卷，第4期，第290–297页，2016年。[147] D. N. Beede、T. A. Julian、D. Langdon、G. McKittrick、B. Khan 和 M. E. Doms, "科学、技术、工程和数学领域的女性：通往创新的性别差距", 经济与统计管理局问题简报，第04-11号，2011年。[148] L. Sweeney, "在线广告投放中的歧视", *ACM*通讯，第56卷，第5期，第44–54页，2013年。[149]N. Mehrabi、F. Morstatter、N. Saxena、K. Lerman 和 A. Galstyan, "机器学习中的偏差与公平性综述", *ACM* 计算调查（*CSUR*），第54卷，第6期，第1–35页，2021年。[150] R. Marshall, "种族歧视的经济学：综述", 经济文献杂志，第12卷，第3期，第849–871页，1974年。[151] S. L. Willborn, "歧视的差别影响模型：理论与局限", *Am. UL Rev.*，第34卷，第799页，1984年。[152] A. Romei 和 S. Ruggieri, "歧视分析的多学科综述", 知识工程评论，第29卷，第5期，第582–638页，2014年。[153] J. Kleinberg、S. Mullainathan 和 M. Raghavan, "风险评分公平判定中固有的权衡", *arXiv* 预印本 *arXiv:1609.05807*，2016年。[154]M. Mansoury, "多边平台中的公平性感知推荐", 载于第*14*届*ACM*网页搜索与数据挖掘国际会议论文集，2021年，第1117–1118页。[155] R. Burke, "推荐中的多侧公平性",

*arXiv* 预印本 *arXiv:1707.00093*，2017年。[156] A. Gharahighehi、C. Vens 和 K. Pliakos，“采用超图排名的公平多利益相关方新闻推荐系统”，*InformationProcessing & Management*，第58卷，第5期，第102663页，2021年。[157] H. Wu、B. Mitra、C. Ma、F. Diaz 和 X. Liu，“面向推荐的联合多侧曝光公平性”，载于第*45*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2022年。[158] S. Yao 和 B. Huang，“超越均等：协同过滤的公平性目标”，神经信息处理系统进展，第30卷，2017年。[159] C. Wu、F. Wu、T. Qi 和 Y. Huang，“大型推荐模型对冷启动用户公平吗？”，*arXiv* 预印本 *arXiv:2202.13607*，2022年。[160]Z. Fu、Y. Xian、R. Gao、J. Zhao、Q. Huang、Y. Ge、S. Xu、S. Geng、C. Shah、Y. Zhang 等，“知识图谱上的公平性感知可解释推荐”，载于第*43*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2020年，第69–78页。[161] T. Kamishima、S. Akaho、H. Asoh 和 J. Sakuma，“通过增强推荐中立性来纠正流行度偏差。”载于*RecSys*，2014年。[162] H. Abdollahpouri、R. Burke 和 B. Mobasher，“控制学习排序推荐中的流行度偏差”，载于第十一届*ACM*推荐系统会议论文集，2017年，第42–46页。[163] A. Ferraro，“音乐冷启动与长尾推荐：深度表示中的偏差”，载于第*13*届*ACM*推荐系统会议论文集，2019年，第586–590页。[164] H. Abdollahpouri、M. Mansoury、R. Burke 和 B. Mobasher，“推荐中流行度偏差的不公平性”，多利益相关方环境中的推荐研讨会，2019年。[165] H. Abdollahpouri、R. Burke 和 B. Mobasher，“利用个性化重排序管理推荐系统中的流行度偏差”，载于第三十二届国际 *FLairs* 会议，2019年。[166] L. Boratto、G. Fenu 和 M. Marras，“上采样与正则化对推荐系统提供方公平性的相互作用”，*User Modeling andUser-Adapted Interaction*，第31卷，第3期，第421–455页，2021年。[167] F. Fabbri、F. Bonchi、L. Boratto 和 C. Castillo，“同质性对人物推荐系统中少数群体可见性差异的影响”，载于国际*AAAI*网络与社交媒体会议论文集，第14卷，2020年，第165–175页。[168]M. D. Ekstrand、M. Tian、M. R. I. Kazi、H. Mehrpouyan 和 D. Kluver，“探究图书评分与推荐中的作者性别”，载于第*12*届*ACM*推荐系统会议论文集，2018年，第242–250页。[169]E. G ´omez、C. Shui Zhang、L. Boratto、M. Sala m´o 和 M. Marras，“赢家通吃：教育推荐系统中的地理不平衡与提供方（不）公平性”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集

信息检索的发展 , 2021, pp 1808 1812 . – .[170]E. G´omez、L. Boratto 和 M. Salam ´o，《物品推荐中的差别影响：地理不平衡案例》，载于欧洲信息检索会议。Springer，2021年，页码 190–206。[171] ——，《协同推荐系统中的跨大陆提供方公平性》，*InformationProcessing&Management*，第 59 卷，第 1 期，文章编号 102719，2022年。[172] Y. Wu、J. Cao、G. Xu 和 Y. Tan，《Tfrom：面向客户和提供方的双边公平性感知推荐模型》，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，页码 1013–1022。[173] A. Chakraborty、A. Hannak、A. J. Biega 和 K. Gummadi，《共享经济平台的公平共享》，载于推荐系统中的公平性、问责制与透明度——负责任推荐专题研讨会，2017。[174] G. K. Patro、A. Biswas、N. Ganguly、K. P. Gummadi 和 A. Chakraborty，《Fairrec：双边平台个性化推荐中的双边公平性》，载于*2020*年万维网会议论文集，2020年，页码 1194–1204。[175] T. S¨uhr、A. J. Biega、M. Zehlike、K. P. Gummadi 和 A. Chakraborty，《双边市场中重复匹配的双边公平性：网约车平台案例研究》，载于第*25*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2019年，页码 3082–3092。[176] L. Wang 和 T. Joachims，《双边市场排名中的用户公平性、物品公平性与多样性》，载于*2021*年*ACM SIGIR*信息检索理论国际会议论文集，2021年，页码 23–41。[177]E. Creager、D. Madras、T. Pitassi 和 R. Zemel，《动力系统公平性的因果建模》，载于国际机器学习会议。PMLR，2020年，页码 2185–2195。[178] J. Williams 和 J. Z. Kolter，《公平决策中的动态建模与均衡》，*arXiv*预印本 *arXiv:1911.06837*，2019。[179] X. Zhang、R. Tu、Y. Liu、M. Liu、H. Kjellstrom、K. Zhang 和 C. Zhang，《公平决策的长期资格认定效果如何？》，神经信息处理系统进展，第 33 卷，页码 18457–18469，2020年。[180] Y. Wu、R. Xie、Y. Zhu、F. Zhuang、A. Xiang、X. Zhang、L. Lin 和 Q. He，《通过提示实现推荐中的选择性公平性》，载于第*45*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2022年，页码 2657–2662。[181] A. Bose 和 W. Hamilton，《图嵌入的组合公平性约束》，载于国际机器学习会议。PMLR，2019年，页码 715–724。[182]S. Liu、Y. Ge、S. Xu、Y. Zhang 和 A. Marian，《公平性感知的联邦矩阵分解》，载于第*16*届*ACM*推荐系统会议论文集，2022年，页码 168–178。[183] K. Maeng、H. Lu、L. Melis、J. Nguyen、M. Rabbat 和 C.-J. Wu，《迈向公平的联邦推荐

学习：刻画系统异质性与数据异质性之间的相互依赖关系》，载于第*16*届*ACM*推荐系统会议论文集，2022年。[184] S. Caton 和 C. Haas，《机器学习中的公平性：综述》，*arXiv*预印本 *arXiv:2010.04053*，2020年。[185] M. D. Ekstrand、M. Tian、I. M. Azpiazu、J. D. Ekstrand、O. Anuyah、D. McNeill 和 M. S. Pera，《所有酷孩子都如何融入其中？推荐系统评估与有效性中的流行度和人口统计偏差》，载于公平性、问责制与透明度会议。PMLR，2018年，页码 172–186。[186] R. Gao 和 C. Shah，《应对搜索系统中的偏差与公平性》，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，页码 2643–2646。[187] A. Beutel、J. Chen、T. Doshi、H. Qian、L. Wei、Y. Wu、L. Heldt、Z. Zhao、L. Hong、E. H. Chi等，《通过成对比较实现推荐排序公平性》，载于第*25*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2019年，页码 2212–2220。[188] R. Burke、N. Sonboli、M. Mansoury 和 A. Ordo˜nez-Gauger，《面向公平性感知协同推荐的平衡邻域》，2017。[189]G. Farnadi、P. Kouki、S. K. Thompson、S. Srinivasan 和 L. Getoor，《公平性感知混合推荐系统》，*arXiv*预印本 *arXiv:1809.09030*，2018年。[190] L. Xiao、Z. Min、Z. Yongfeng、G. Zhaoquan、L. Yiqun 和 M. Shaoping，《兼顾帕累托效率的公平性感知群组推荐》，载于第十一届*ACM*推荐系统会议论文集，2017年，页码 107–115。[191] S. Yao 和 B. Huang，《体现差异的新型推荐公平性指标》，*arXiv*预印本 *arXiv:1706.09838*，2017。[192] Y. Ge、X. Zhao、L. Yu、S. Paul、D. Hu、C.-C. Hsieh 和 Y. Zhang，《通过强化学习实现推荐中帕累托有效的公平性—效用权衡》，载于第十五届*ACM*国际网络搜索与数据挖掘会议论文集，2022年，页码 316–324。[193] A. Singh 和 T. Joachims，《排名中的曝光公平性》，载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2018年，页码 2219–2228。[194] T. Yang 和 Q. Ai，《动态学习排序中的边际公平性最大化》，载于*2021*年网络会议论文集，2021年，页码 137–145。[195] M. Zehlike、F. Bonchi、C. Castillo、S. Hajian、M. Megahed 和 R. Baeza-Yates，《Fa* ir：一种公平的 top-k 排序算法》，载于*2017*年*ACM*信息与知识管理会议论文集，2017年，页码 1569–1578。[196]L. E. Celis、S. Kapoor、F. Salehi 和 N. Vishnoi，《个性化中的极化控制：算法框架》，载于公平性、问责制与透明度会议论文集，2019年，页码 160–169。[197] M. Joseph、M. Kearns、J. Morgenstern、S. Neel 和 A. Roth，《面向无限与上下文环境的公平算法

老虎机，”*arXiv*预印本 *arXiv:1610.09559*，2016年。[198] Y. Chen、A. Cuellar、H.Luo、J. Modi、H. Nemlekar 和 S. Nikolaidis，“公平上下文多臂老虎机：理论与实验”，载于人工智能不确定性会议。PMLR，2020年，第181–190页。[199] S. C. Geyik、S. Ambler 和 K. Kenthapadi，“搜索与推荐系统中的公平性感知排名及其在LinkedIn人才搜索中的应用”，载于第*25*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2019年，第2221–2231页。[200] A. Khademi、S. Lee、D. Foley 和 V. Honavar，“算法决策中的公平性：因果关系视角下的探索”，载于万维网大会，2019年，第2907–2914页。[201] M. Hardt、E. Price 和 N. Srebro，“监督学习中的机会均等”，神经信息处理系统进展，第29卷，2016年。[202] C. Barabas、M. Virza、K. Dinakar、J. Ito 和 J. Zittrain，“干预优于预测：重新审视精算风险评估的伦理争论”，载于公平性、问责制与透明度会议。PMLR，2018年，第62–76页。[203] J. Zhang 和 E. Bareinboim，“分类中的机会均等：一种因果方法”，神经信息处理系统进展，第31卷，2018年。[204]N. Kilbertus、M. Rojas Carulla、G. Parascandolo、M. Hardt、D. Janzing 和 B. Sch¨olkopf，“通过因果推理避免歧视”，神经信息处理系统进展，第30卷，2017年。[205] J. Pearl，“直接效应与间接效应”，载于概率与因果推断：*Judea Pearl*文集，2022年，第373–392页。[206]Y. Saito，“用于非随机缺失显式反馈去偏的非对称三元训练”，载于第*43*届*ACM SIGIR*信息检索研究与发展国际会议论文集，2020年。[207] X. Wang、R. Zhang、Y. Sun 和 J. Qi，“针对非随机缺失数据推荐的双重稳健联合学习”，载于国际机器学习会议。PMLR，2019年，第6638–6647页。[208]J. Ma、R. Guo、M. Wan、L. Yang、A. Zhang 和 J. Li，“利用图反事实公平性学习公平节点表示”，载于第*15*届*ACM*网络搜索与数据挖掘国际会议论文集，2022年，第695–703页。[209] R. Mehrotra、J. McInerney、H. Bouchard、M. Lalmas 和 F. Diaz，“迈向公平市场：对推荐系统中相关性、公平性与满意度之间权衡的反事实评估”，载于第*27*届*ACM*信息与知识管理国际会议论文集，2018年，第2243–2251页。[210] Y. Goyal、Z. Wu、J. Ernst、D. Batra、D. Parikh 和 S. Lee，“反事实视觉解释”，载于国际机器学习会议。PMLR，2019年，第2376–2384页。[211] L. Zhang、Y. Wu 和 X. Wu，“用于发现和消除直接与间接歧视的因果框架”，载于第*26*届人工智能国际联合会议论文集，系列IJCAI’17，2017年。[212] ——，“基于因果建模的歧视发现——

查询与移除：标准 ，界限 ，和算法 ，” *IEEE*知识与数据工程汇刊，第31卷，第11期，第2035–2050页，2018年。[213] ——，“利用因果网络发现歧视”，载于社会计算、行为—文化建模与预测及行为表征建模与模拟国际会议。Springer，2016年，第83–93页。[214] ——，“基于情境测试的歧视发现：一种因果推断方法。”载于*IJCAI*，第16卷，2016年，第2718–2724页。[215] L. Zhang和X. Wu，“反歧视学习：一种基于因果建模的框架”，国际数据科学与分析期刊，第4卷，第1期，第1–16页，2017。[216] W. Huang、L. Zhang和X. Wu，“实现因果老虎机的反事实公平性”，载于*AAAI*人工智能会议论文集，第36卷，第6期，2022年，第6952–6959页。[217] M. D. Ekstrand、J. T. Riedl、J. A. Konstan 等，“协同过滤推荐系统”，《人机交互基础与趋势》，第4卷，第2期，第81–173页，2011年。[218] Z. Ovaisi、S. Heinecke、J. Li、Y. Zhang、E. Zheleva和C. Xiong，“Rgrecsys：用于推荐系统鲁棒性评估的工具包”，载于第十五届*ACM*国际网络搜索与数据挖掘会议论文集，2022年，第1597–1600页。[219] Z. Shen、J. Liu、Y. He、X. Zhang、R. Xu、H. Yu和P. Cui，“迈向分布外泛化：一项综述”，*arXiv*预印本 *arXiv:2108.13624*，2021年。[220] L. Cao，“非独立同分布推荐系统：推荐范式转变的综述与框架”，工程，第2卷，第2期，第212–224页，2016年。[221] Z. Wang、J. Zhang、H. Xu、X. Chen、Y. Zhang、W. X. Zhao和J.-R. Wen，“反事实数据增强序列推荐”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第347–356页。[222] W. Wang、X. Lin、F. Feng、X. He、M. Lin和T.-S. Chua，“用于分布外推荐的因果表征学习”，载于*2022*年*ACM*网络会议论文集，2022年，第3562–3571页。[223]Z. Shen、P. Cui、K. Kuang、B. Li和P. Chen，“针对不可知数据选择偏差的因果正则化学习”，载于第*26*届*ACM*国际多媒体会议论文集，2018年，第411–419页。[224] K. Kuang、P. Cui、S. Athey、R. Xiong和B. Li，“未知环境下的稳定预测”，载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，2018年，第1617–1626页。[225] P. Gutierrez和J.-Y. G´ erardy，“因果推断与提升建模：文献综述”，载于预测应用与*API*国际会议。PMLR，2017年，第1–13页。[226] N. Radcliffe，“利用对照组锁定预测增益目标：构建和评估提升模型”，直销分析期刊，第14–21页，2007年。[227] M. Jaskowski和S. Jaroszewicz，“临床试验数据的增益建模”，载于*ICML*临床数据分析研讨会，第46卷，2012年，第79–95页。

[228] [illegible]基于反事件的增益树在现实世界中的增益建模，” 白皮书 *TR-2011-1*，*Stochastic Solutions*，第 1–33 页，2011年。[229] P. Rzepakowski 和 S. Jaroszewicz，“针对单一和多重处理的增益建模决策树”，*Knowledge and Information Systems*，第 32 卷，第 2 期，第 303–327 页，2012年。[230] M. Sato、H. Izumo 和 T. Sonoda，“对单个用户的响应度进行建模，以最大化推荐效果”，载于*2016*年用户建模、自适应与个性化会议论文集，2016年，第 259–267 页。[231] A. V. Bodapati，“基于购买数据的推荐系统”，*Journal of Marketing Research*，第 45 卷，第 1 期，第 77–93 页，2008年。[232] E. A. Stuart，“用于因果推断的匹配方法：回顾与展望”，统计科学：*Institute of Mathematical Statistics* 评论期刊，第 25 卷，第 1 期，第 1 页，2010年。[233] M. Sato、S. Takemori、J. Singh 和 T. 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，2020年，第 378–387 页。[234]A. Swaminathan 和 T. Joachims，“用于反事实学习的自归一化估计量”，神经信息处理系统进展，第 28 卷，2015年。[235] T. Xiao 和 S. Wang，“迈向推荐系统的无偏稳健因果排序”，载于第*15*届*ACM*国际网络搜索与数据挖掘会议论文集，2022年，第 1158–1167 页。[236] M. J. Funk、D. Westreich、C. Wiesen、T. St¨urmer、M. A. Brookhart 和 M. Davidian，“因果效应的双重稳健估计”，*American Journal of Epidemiology*，第 173 卷，第 7 期，第 761–767 页，2011年。[237] A. J. Chaney、B. M. Stewart 和 B. E. Engelhardt，“推荐系统中的算法混杂如何增加同质性并降低效用”，载于第*12*届*ACM*推荐系统会议论文集，2018年，第 224–232 页。[238]D. Jannach、L. Lerche、I. Kamehkhosh 和 M. Ju-govac，“推荐系统推荐什么：推荐偏差分析及可能的应对措施”，*User Modeling and User-Adapted Interaction*，第 25 卷，第 5 期，第 427–491 页，2015年。[239]M. Mansoury、H. Abdollahpouri、M. Pechenizkiy、B. Mobasher 和 R. Burke，“推荐系统中的反馈回路与偏差放大”，载于第*29*届*ACM*国际信息与知识管理会议论文集，2020年，第 2145–2148 页。[240]Y. Ge、S. Zhao、H. Zhou、C. Pei、F. Sun、W. Ou 和 Y. Zhang，“理解电子商务推荐系统中的回音室”，载于第*43*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2020年，第 2261–2270 页。[241] D. P. Allen、H. J. Wheeler-Mackta 和 J. R. Campo，“音乐推荐引擎对过滤气泡现象的影响”，*InteractiveQualifyingProjects*，2017年。[242] U. Chitra 和 C. Musco，“分析……的影响

过滤气泡对社交网络极化的影响”，载于第*13*届国际网络搜索与数据挖掘会议论文集，2020年，第 115–123 页。[243] C. Gao、W. Lei、J. Chen、S. Wang、X. He、S. Li、B. Li、Y. Zhang 和 P. Jiang，“Cirs：利用反事实交互式推荐系统打破过滤气泡”，*arXiv* 预印本 *arXiv:2204.01266*，2022年。[244] T. T. Nguyen、P.-M. Hui、F. M. Harper、L. Terveen 和 J. A. Konstan，“探索过滤气泡：使用推荐系统对内容多样性的影响”，载于第*23*届国际万维网会议论文集，2014年，第 677–686 页。[245] J. McInerney、B. Brost、P. Chandar、R. Mehrotra 和 B. Carterette，“基于序列奖励交互的推荐列表反事实评估”，载于第*26*届*ACM SIGKDD*国际知识发现与数据挖掘会议，2020年，第 1779–1788 页。[246] A. Agarwal、K. Takatsu、I. Zaitsev 和 T. 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会议论文集，2019年，第 5–14 页。[247] A. Agarwal、I. Zaitsev、X. Wang、C. Li、M. Najork 和 T. Joachims，“无需侵入式干预即可估计位置偏差”，载于第*12*届*ACM*国际网络搜索与数据挖掘会议，2019年，第 474–482 页。[248] Q. Ai、K. Bi、C. Luo、J. Guo 和 W. B. Croft，“通过无偏倾向得分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会议，2018年，第 385–394 页。[249] M. Chen、C. Liu、J. Sun 和 S. C. Hoi，“调整交互观测嵌入以用于反事实学习排序”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第 285–294 页。[250] T. Joachims、A. Swaminathan 和 T. Schnabel，“利用有偏反馈进行无偏学习排序”，载于第*10*届*ACM*国际网络搜索与数据挖掘会议论文集，2017年，第 781–789 页。[251] Z. Qin、S. J. Chen、D. Metzler、Y. Noh、J. Qin 和 X. Wang，“推荐系统无偏学习的基于属性的倾向得分：算法与案例研究”，载于第*26*届*ACM SIGKDD*国际知识发现与数据挖掘会议，2020年，第 2359–2367 页。[252] J.-w. Lee、S. Park 和 J. Lee，“针对隐式反馈的双重无偏推荐学习”，载于第*44*届国际*ACM SIGIR*信息检索研究与发展会议论文集，2021年，第 1647–1651 页。[253] Z. Zhao、J. Chen、S. Zhou、X. He、X. Cao、F. Zhang 和 W. Wu，“流行度偏差并非总是有害：区分推荐中的良性偏差与有害偏差”，*arXiv* 预印本 *arXiv:2109.07946*，2021年。[254]P. Brouillard、S. Lachapelle、A. Lacoste、S. Lacoste-Julien 和 A. Drouin，“从干预数据中进行可微因果发现”，神经信息处理系统进展，第 33 卷，第 21865–21877 页，2020年。