

双目标跨领域推荐前沿研究综述*

任婕妤 甘明鑫 王纯华

(北京科技大学 经济管理学院, 北京 100083)

摘要 智能信息时代,为打造全方位商业生态,电子商务平台已从单一服务向多元化服务方向发展。双目标跨领域推荐系统利用用户在两个领域的行为信息捕捉其偏好特征,旨在同时提升两个领域的推荐性能与服务水平。本文首先介绍双目标跨领域推荐的研究背景和基本概念,然后将研究的核心问题归纳为各领域特征表示学习、跨领域迁移丰富信息和跨领域迁移有效信息。之后分类回顾双目标跨领域推荐方法的最新研究成果。最后展望研究的未来发展方向。

关键词 跨领域推荐, 双目标跨领域推荐, 机器学习, 跨领域信息迁移

中图分类号 C931; TP315

1 引言

数字经济的技术革新为国内外电子商务平台开拓了广阔的发展前景。随着近年来数字化需求的激增,电子商务平台为用户提供了更加丰富的信息资源,并从单一服务向多元化服务方向发展^[1]。与此同时,用户面临的信息过载和信息迷航问题日益凸显。如何精准地为用户筛选有价值信息、提升用户满意度与忠诚度,成为电子商务平台提升核心竞争力的关键。研究表明^[2,3],智能推荐系统依靠数据驱动实现深度个性化,能够促进消费者的价值感知和购买意愿。为此,各大平台纷纷为用户提供个性化的信息推荐服务,以提升用户体验与平台效益^[4,5]。

虽然推荐系统能够从用户与待推荐物品或信息^①的交互关系、用户特征、待推荐物品或信息的属性等多种辅助信息中挖掘用户的偏好,但在实际开发与运行过程中,推荐系统受到多方面限制^[6]。一方面,单个领域中用户交互行为的稀疏性限制了推荐系统对用户偏好特征的全面刻画^[7];另一方面,用户年龄、职业等辅助信息在实际系统中难以获得^[8,9]。因此,从稀疏交互行为中充分挖掘用户偏好特征成为新的研究重点。近年来,电子商务平台通过开发多领域服务,构建全方位、多元化的商业生态,由此形成的跨领域信息共享,为跨领域推荐系统提供了重要的现实条件^[10-12]。一方面,由于用户在不同领域的行为反映其不同侧面的偏好和需求,辅助域中的交互信息经过迁移之后能够为目标域中用户偏好预测与推荐提供有价值的依据。另一方面,不同电子商务平台可能提供相同的产品和服务,已形成的知识图谱也往往涉及多个领域^[13],基于此可以建立项目侧的跨领域关联。

在这样的背景下,跨领域推荐系统应运而生并逐渐发展起来,其主要目标是利用辅助域中的有价值信息提升目标域的推荐性能^[14]。双目标跨领域推荐方法是跨领域推荐研究中的重要内容。相比于传统的单目标跨领域推荐方法,双目标跨领域推荐方法旨在双向迁移跨领域信息,以同时提升两个领域的推荐

* 基金项目:国家自然科学基金面上项目(72271024, 71871019)。

通信作者:甘明鑫,北京科技大学经济管理学院,教授,博士生导师, E-mail: ganmx@ustb.edu.cn。

① 在推荐系统中,待推荐物品或信息通常被简称为项目。本文在之后的论述中将采用项目一词进行表述。

性能。一方面,双目标跨领域推荐系统能够利用有限的数据提供更加全面的推荐服务,进而提升推荐系统的高效性;另一方面,双目标跨领域推荐可以扩展到面向多个领域的多目标跨领域推荐,其方法设计通常具有良好的泛化性。因此,双目标跨领域推荐方法成为当前研究的热点问题。

作为平台经济时代的一项核心技术,双目标跨领域推荐系统为赋能和影响管理决策开拓了新的方向^[15,16]。在赋能客户关系管理层面,双目标跨领域推荐系统为用户提供更加满足其复杂需求和偏好的项目推送服务,极大地丰富了用户的交互体验,提升了用户的满意度与忠诚度,从而帮助构建起稳定且长期的客户关系网络^[17,18]。在赋能平台运营管理层面^[19,20],双目标跨领域推荐系统同样展现出巨大潜力。在当前电子商务平台的商业版图日趋扩大的现实背景下,双目标跨领域推荐系统通过技术创新实现全平台内数据资源的统一调度与利用,有效降低推荐系统训练和推理需要消耗的计算资源,推动了平台运营管理策略中的技术更新和功能优化^[16]。由此可知,双目标跨领域推荐系统对提升客户关系管理和平台运营管理的效率和质量,具有显著的推动作用和重要的现实意义。

双目标跨领域推荐研究着重考虑三个关键科学问题。第一,各领域内的特征表示学习问题。跨领域迁移的信息来源于各个领域中用户和项目的特征表示,因此,各领域内的信息来源和建模方法等表示学习问题是双目标跨领域推荐研究中的基础工作。第二,跨领域迁移丰富信息的问题。仅仅跨领域迁移重叠实体(实体为用户和项目的统称)的显式交互信息是远远不够的。在有限的重叠实体的显式交互信息基础上,尽可能挖掘并迁移丰富的潜在信息,是提升跨领域信息迁移质量的关键之一。第三,跨领域迁移有效信息的问题。领域的异质性意味着用户在不同领域的偏好及行为存在差异,因此,辅助域中的一部分信息对目标域而言是没有价值的。尤其是对于双目标跨领域推荐,应保证从两个领域向彼此迁移的信息都是有效的,任何一个领域的推荐性能提升都不能以另一个领域的推荐性能下降为代价。

已有文献^[21,22]将跨领域推荐研究的核心问题归纳为迁移什么和如何迁移。本质上,各领域特征表示学习对应于迁移什么的问题,跨领域迁移丰富信息和跨领域迁移有效信息则共同对应于如何迁移的问题。由此可知,本文识别的三个核心研究问题涵盖了双目标跨领域推荐研究的主要内容,综述框架具备充分性。本文进一步聚焦于双目标跨领域推荐,考虑跨领域双向信息迁移机制需要满足的本质要求,创新性地如何将如何迁移的问题分解为迁移丰富信息和迁移有效信息两个方面。虽然跨领域偏好迁移的稳定性和领域间的协同赋能等问题也被视为双目标跨领域推荐研究的重点^[23,24],但是这些问题属于较高水平的概念,其最终也将落实到跨领域迁移信息的丰富性和有效性上。由此可得,本文提出的综述框架具备合理性。

综上所述,各领域特征表示学习、跨领域迁移丰富信息和跨领域迁移有效信息是双目标跨领域推荐研究的重点和难点。为此,本文从以上核心问题出发,分析总结近些年国内外双目标跨领域推荐方法的前沿研究成果,进而深化研究者对双目标跨领域推荐的理解,促进跨领域推荐系统的持续改进。本文综述的创新性和研究价值总结如下。第一,相比于现有综述论文重点关注的单目标跨领域推荐^[21]和自监督学习推荐^[25],本文强调双目标跨领域推荐研究的跨领域知识互通和跨领域统一的训练、推理架构,响应了平台对于高效、准确和全面的多领域服务的独特研究需求。第二,本文提出基于核心研究问题的综述框架,该框架逻辑性强且子类内容之间不存在重叠,还为研究者提供了清晰的领域研究脉络。第三,本文紧跟生成式人工智能的时代发展趋势并遵循信息系统领域的主流研究范式,前瞻性地提出大语言模型赋能、用户心理因素和行为模式感知、面向具体应用场景的双目标跨领域推荐等方向。这些研究方向已受到信息系统领域的高度认可^[26-28]。

本文的内容结构安排如下:第二节阐明双目标跨领域推荐的基本概念、商业应用和本文综述框架;第三节到第五节对核心研究问题对应的双目标跨领域推荐方法分别综述;最后对未来研究趋势进行展望。

2 跨领域推荐的概念、商业应用及本文综述框架

2.1 跨领域推荐的概念和商业应用

对于跨领域推荐这一研究问题,当前研究主要从研究动机、核心假设和隐私保护三个视角展开探讨。首先,为缓解推荐系统面临的数据稀疏问题,研究者已提出自监督学习推荐、跨领域推荐和融合知识图谱的推荐等多种方案。其中,跨领域推荐系统充分利用辅助域中的用户交互数据来缓解目标域的数据稀疏问题,提供了一种直接且有效的解决方案。其次,跨领域推荐系统都有相同的核心假设,即不同领域之间存在某些共享的信息^[29]。基于此,如何识别并跨领域利用这部分共享信息成为跨领域推荐系统成功的关键。最后,大多数跨领域推荐系统在领域之间共享用户行为信息,这些系统常常面临着用户隐私保护的挑战。为此,现有研究采用局部差分隐私(local differential privacy)等技术以实现隐私保护的跨领域推荐^[23,30]。

以推荐目标为划分依据,可以将跨领域推荐分为单目标跨领域推荐和双(多)目标跨领域推荐^[21]。单目标跨领域推荐单向地将有价值信息从辅助域迁移至目标域,进而提升目标域的推荐性能。双目标跨领域推荐旨在实现信息的跨领域双向迁移,以同时提升两个领域的推荐性能^[31]。表1总结了双目标跨领域推荐研究中的关键概念、概念的内涵及相关文献。

表1 双目标跨领域推荐研究中的关键概念汇总表

关键概念	英文表述	概念的内涵	文献
实体	Entity	推荐系统中用户和项目的统称	[32]
知识图谱实体	Entity in knowledge graph	知识图谱中的核心元素,代表真实世界中的人物、物品和地点等各种类型的对象	[23]
跨领域重叠实体	Overlapping entity	同时在两个领域中拥有交互记录的用户或项目	[33]
领域特有实体	Domain-specific entity	仅在一个领域中拥有交互记录而在另一个领域没有交互记录的实体	[34]
完全重叠的跨领域推荐	Fully overlapped cross-domain recommendation	在该推荐场景下,两个领域中的所有用户或所有项目完全相同	[21]
部分重叠的跨领域推荐	Partially overlapped cross-domain recommendation	在该推荐场景下,两个领域中既存在跨领域重叠用户或项目,也存在领域特有用户或项目	[35]
无重叠跨领域推荐	Non-overlapping cross-domain recommendation	在该推荐场景下,两个领域中仅存在领域特有用户或项目,而不存在跨领域重叠用户或项目	[29]
领域的异质性	Domain heterogeneity	领域的异质性主要包括偏好异质性(用户偏好的跨领域差异)、特征异质性(用户或项目代表性特征的差异)和评分偏差(评分量级等)	[29]
跨领域统一图	Unified cross-domain graph	假设存在跨领域重叠实体。图中的节点包括两个领域中的所有用户和项目,连边代表用户-项目交互关系、项目-项目转换关系等。跨领域重叠实体能够同时与两个领域中的项目建立连边	[36]
协同知识图	Collaborative knowledge graph	用户-项目交互图与知识图谱的结合。图中的节点包括推荐系统中的用户、项目和知识图谱实体,连边代表用户-项目交互关系和知识图谱实体间的关系。项目与知识图谱实体能够对应起来	[33]

续表

关键概念	英文表述	概念的内涵	文献
单领域交互序列	Single-domain interaction sequence	用户在某一领域内按照交互时间顺序排列的一组交互项目（序列中的项目属于同一个领域）	[7]
跨领域交互序列	Cross-domain interaction sequence	用户在两个领域内按照交互时间顺序排列的一组交互项目（序列中的项目涉及两个领域）	[7]
跨领域桥梁/跨领域关联	Bridges between domains/trans-domain relationships	使得两个领域产生联系的对象，如跨领域重叠实体、知识图谱实体、项目标签等	[37][38]

凭借算法的高效性与良好的泛化能力，双目标跨领域推荐方法不仅成为学术界的研究热点，其在实际商业应用中也展现出巨大优势。例如，微信和优酷等在线内容平台已经成功部署了双目标和多目标跨领域推荐系统。这些推荐系统能够为文章和视频等多个领域提供更加精准的内容推送服务，结果表明用户在多个领域的内容消费量有显著增长^[39, 40]。在亚马逊和淘宝等电子商务平台，双目标和多目标跨领域推荐系统同样发挥着重要作用。它们提升了各个商品领域下的用户点击率，改善了用户的交互体验，也为平台带来利润的增长^[1, 35]。这些商业应用证明了双目标跨领域推荐系统的应用潜力和商业价值。

2.2 双目标跨领域推荐的综述框架

一些研究认为^[41, 42]，如何将用户偏好从辅助域迁移至目标域是跨领域推荐研究的核心问题。随着辅助信息的持续积累和神经网络模型的快速发展，各个领域内的信息来源和建模方法也对跨领域推荐的性能产生重要影响^[43]。为此，相关研究^[21, 22]将跨领域推荐研究的核心问题总结为迁移什么和如何迁移。然而，对于如何迁移的问题，现有研究尚未深入探讨跨领域信息迁移机制需满足的具体要求，这在一定程度上限制了跨领域信息迁移质量的持续提升。为此，本文重新审视和定义双目标跨领域推荐研究的核心问题，并基于核心问题对双目标跨领域推荐的研究方法进行分类综述。本文分类综述的具体标准如下。

首先，与迁移什么的研究问题保持一致，本文首先考虑双目标跨领域推荐中各个领域的信息建模问题。本文将在第三节总结各个领域内特征表示学习的常用方法。其中，用户-项目交互数据是推荐系统中使用最广泛的数据类型之一，因此，本文首先总结静态交互信息建模和动态交互信息建模的相关研究。此外，由于一些研究强调对各个领域评论和标签等辅助信息的建模，本文单独总结辅助信息的建模方法。

其次，对于如何迁移的问题，本文认为跨领域信息迁移机制应该满足两点要求。第一，应该尽可能将大量、丰富和潜在的辅助域信息迁移至目标域，最大限度地增强目标域中用户和项目的特征表示。在极端情况下，如果从辅助域迁移到目标域的信息量为 0，跨领域推荐便退化为单领域推荐，此时目标域中的数据稀疏问题得不到任何缓解。第二，应该有选择地迁移辅助域中有价值的部分信息，而消除对目标域而言没有价值的噪声信息。特别是在双目标跨领域推荐系统中，两个领域可能无法有效地协同合作，甚至产生冲突。此时可能为特定领域引入噪声信号，一个领域的性能提升可能以牺牲另一个领域的推荐性能为代价^[44]。现有研究着重考虑两点要求之一，并产生出大量前沿研究成果。

一方面，为了保证迁移信息的丰富性，已有研究采用跨领域统一图构建、跨领域特征对齐和跨领域桥梁扩充等方法，促使两个领域向彼此迁移大量信息。基于跨领域统一图的研究构建起整合两个领域交互数据的跨领域统一图，然后利用图神经网络的优势融合来自跨领域高阶邻居的丰富信息。基于跨领域特征对齐的研究着重考虑领域之间的共性，约束两个领域间的重叠实体特征或领域的整体特征具有高度

相似性。基于跨领域桥梁扩充的研究通过利用外部的知识图谱、挖掘潜在信任关系等方法，将大量潜在信息融入各个领域的表示学习中。

另一方面，为了保证迁移信息的有效性，已有研究采用注意力机制、信息解耦和强化学习去噪等前沿方法，尽可能避免迁移辅助域中的噪声信息。注意力机制及其衍生出的门控机制能够自动为不同信息分配不同的权重，成为跨领域信息迁移机制中的常见方法。为了更彻底地消除噪声信息，大量研究将各个领域内的特征信息解耦为跨领域共享信息和领域特有信息，进而只迁移跨领域共享信息。也有研究从单个项目的细粒度视角出发，衡量辅助域中的各个项目对目标域推荐的价值，进而采用强化学习方法实现单个项目水平的去噪。

综上所述，如图 1 所示，本文将双目标跨领域推荐的核心研究问题归纳为：各领域特征表示学习、跨领域迁移丰富信息和跨领域迁移有效信息。这三个核心问题涵盖了已有跨领域推荐研究总结的迁移什么和如何迁移的问题^[21, 22]，综述框架具备充分性。相比于已有研究，本文进一步聚焦于跨领域双向信息迁移过程，将如何迁移的问题分解为跨领域迁移丰富信息和迁移有效信息两个方面。从用户视角来看，用户偏好信息迁移的稳定性意味着，当面对存在显著特征差异的辅助域和目标域时，跨领域迁移的用户偏好信息能够恒定地改善目标域的推荐性能^[43]。这在本质上要求跨领域迁移的用户偏好信息足够丰富且有效。确保两个领域之间的协同合作也是双目标跨领域推荐需要考虑的关键问题^[23]。如果两个领域无法有效地协作，两个领域为彼此贡献的价值将显著降低，甚至为彼此引入噪声信号而损害推荐性能^[44]。然而，领域间的协同合作是较高水平的概念，其在本质上要求跨领域迁移丰富且有效的信息。因此，本文的综述框架具备合理性。三个核心研究问题之间的内在联系为：各领域特征表示学习提供基础的实体特征编码方法，为跨领域信息迁移机制奠定基础。跨领域迁移丰富信息和跨领域迁移有效信息属于跨领域信息迁移机制中需要兼顾的两个重要方面。三个核心研究问题缺一不可，共同实现了高质量的双目标跨领域推荐。

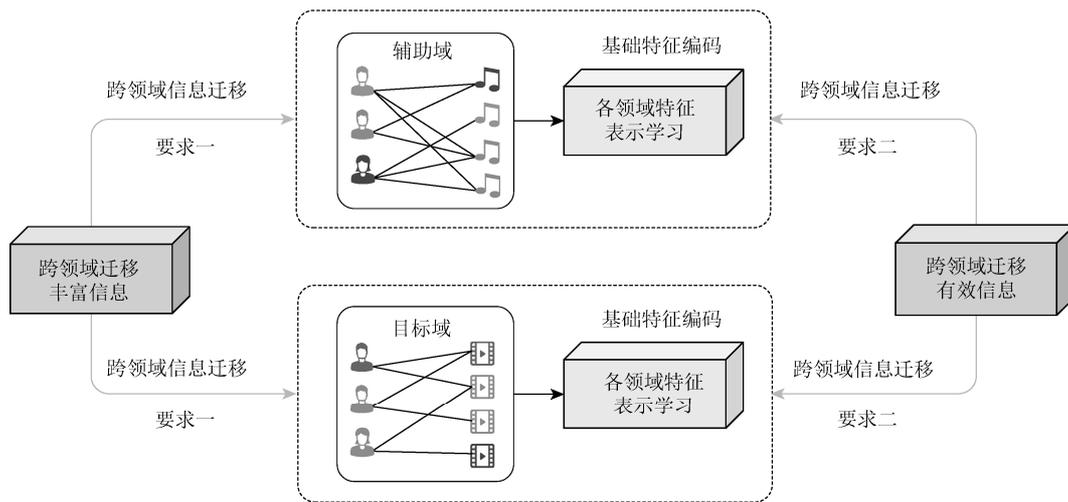


图 1 双目标跨领域推荐中的三个核心研究问题及其关系

近年来已发表两篇跨领域推荐研究综述。综述^[21]构建了基于推荐场景和推荐任务的两级分类系统，并在各个推荐场景下对研究方法进行详细的分类综述。然而，部分方法可以适用于多种推荐场景和任务，导致这些方法在不同子类中重复出现。更重要的是，跨领域推荐研究的研究动机往往是从特定研究问题出发，而非从推荐场景和推荐任务出发。综述^[45]从推荐任务的角度综述了单目标跨领域推荐和双目标跨

领域推荐等任务的核心研究内容。然而,该综述缺乏对双目标跨领域推荐研究的深入探讨,未能将跨领域特征对齐、强化学习去噪等前沿研究成果融入综述框架。因此,相比于已有综述,本文融入了最新研究成果,并且从核心研究问题的视角展开综述,使读者深入且系统地了解双目标跨领域推荐的研究现状。

3 各领域特征表示学习

跨领域推荐是单领域推荐的延伸和发展,双目标跨领域推荐研究利用和改进单领域推荐方法,实现各个领域内基础的实体特征表示。各领域特征表示学习研究主要集中在三个方面:①静态交互信息的建模方法,这类研究从静态的历史交互行为中提取用户和项目的静态特征;②动态交互信息的建模方法,这类研究从时序交互行为中提取用户的动态偏好;③辅助信息的建模方法,这类研究利用评论和标签等辅助信息,增强用户和项目的表示并建立丰富的跨领域关联。表 2 对各领域特征表示学习的主要方法进行了总结与比较。

表 2 面向各领域特征表示学习的相关研究总结

研究类别		数据类型	主要优点	主要难点	相关文献
静态交互信息的建模方法	矩阵分解	交互数据	结构简单;容易训练	捕捉高阶协同信号问题;数据稀疏问题	[31][46][47]
	图神经网络	交互数据	捕捉到实体间的高阶协同信号	数据稀疏问题	[38][48][49][50][51][52]
动态交互信息的建模方法	循环/卷积神经网络	交互数据	有效建模若干邻近项目的序列影响	并行运行问题;处理长序列问题	[53][54][55]
	Transformer	交互数据	高效并行化;建模长范围序列依赖性	捕捉跨序列项目间相关性问题	[39][56][57]
	图神经网络	交互数据	捕捉到跨序列项目间的相关性	融合行为时序信息的问题	[51][58][59]
辅助信息的建模方法	预训练语言模型	用户评论;实体描述	提取并表示文本中蕴含的语义信息	融合多个文本表示的问题	[43]
	去噪自动编码器	用户评论;实体描述	提取并表示文本中蕴含的语义信息	融合多个文本表示的问题	[31]
	大语言模型	实体描述	在项目表示中注入丰富的世界知识	大语言模型与推荐系统的语义对齐	[60][61]

3.1 静态交互信息的建模方法

静态交互信息中不包含用户行为的时序特征,反映用户与项目的内在相关性^[62]。双目标跨领域推荐研究利用矩阵分解和图神经网络等方法得到用户和项目的静态特征表示,进而将其应用于单领域内推荐任务和跨领域双向信息迁移过程。

矩阵分解是推荐系统中的经典方法,具有结构简单与容易训练的优势^[63, 29, 46]。在单领域推荐系统中,矩阵分解方法将用户-项目评分矩阵分解为用户表示矩阵和项目表示矩阵。基于此,代表性双目标跨领域推荐研究^[47]提出协同矩阵分解方法,同时将两个领域的评分矩阵分解为各个领域内的用户表示矩阵和项目表示矩阵,并且使得跨领域重叠用户或项目在两个领域中共享完全相同的特征表示。也有研究利用矩阵分解来预训练各个领域中的实体特征表示,之后进行跨领域知识迁移和模型训练^[31]。图神经网络近

年来在推荐系统中获得巨大成功^[64-66]。双目标跨领域推荐研究开始在各个领域中采用图神经网络方法,通过信息传播和信息聚合机制捕捉领域内和跨领域实体间的高阶协同信号,从而得到高质量的中心节点的特征表示^[38, 48, 67-69]。具体来说,大部分研究采用图卷积网络建模单域内的交互数据^[48, 69, 70],此类方法为邻居节点分配同等的重要度。也有研究采用图注意力网络^[33]和异质图注意力网络^[38],依据中心节点与邻居节点表示的相似度计算邻居的重要性,根据重要性对邻居节点的表示进行加权求和得到精炼的节点表示。为了描述输入数据的不确定性,研究^[71, 72]利用变分图自动编码器,采用服从多元高斯分布的潜在变量表示用户和项目。

3.2 动态交互信息的建模方法

用户的偏好往往随着时间推移发生动态改变^[73]。现有研究采用卷积神经网络、循环神经网络和图神经网络等方法在各个领域内建模用户偏好演化规律,进而为各个领域聚合对方领域中的用户动态偏好,同时提升两个领域的序列推荐性能。

基于卷积神经网络的方法将用户的历史交互序列视为图片,采用卷积滤波器抽取序列模式^[74]。循环神经网络在建模用户行为序列中具有广泛应用,它通过将用户历史交互序列视为句子,依次得到循环单元的输出结果,这些输出结果即可作为用户在各个时刻的偏好表示^[73, 75-77]。然而,基于循环神经网络的序列推荐方法面临时间复杂度高和难以并行运行等问题^[74]。为此,研究者将 Transformer 应用于序列推荐,这类研究基于自注意力机制捕捉序列内任意一对项目间的相关性,具有建模长范围序列依赖性和并行运行的优势^[78]。近几年发表的双目标跨领域序列推荐研究^[39, 56, 57]均将 Transformer 作为序列编码器。具体来说,这些研究将 Transformer 应用于单领域交互序列或者跨领域交互序列之后,通常选取 Transformer 输出的最后一个时刻的表示作为用户的单领域动态偏好或者跨领域动态偏好。为了融合其他用户的历史交互序列中潜在的有价值信息,相关研究构建跨领域统一图,采用图神经网络捕捉用户-项目交互关系、项目-项目转换关系中蕴含的高阶协同信号,进而得到高质量的实体特征表示和行为序列表示^[7, 51, 58]。

3.3 辅助信息的建模方法

为了挖掘领域之间的潜在关联,双目标跨领域推荐研究对各个领域用户评论、项目标签等辅助信息进行编码^[43, 79, 80],从而丰富实体的特征表示,并通过利用文本中蕴含的跨领域通用信息来提升跨领域知识通信质量。

大量研究采用预训练语言模型和卷积神经网络等方法对用户评论进行特征表示^[81, 82]。对于各领域而言,评论数据是交互数据的有效补充,可以更加全面地刻画用户对项目的偏好。同时,评论以自然语言的形式呈现,而自然语言具有跨领域和跨场景的通用性,其语义在不同应用背景中保持相对稳定^[83]。因此,评论中蕴含的丰富语义在两个推荐领域中都是通用的。通过融合评论信息,推荐系统可以在具有较强异质性、跨领域重叠实体较少的两个领域之间更好地理解 and 捕捉跨领域的用户行为和偏好^[84]。大多数研究^[43, 85]采用 BERT^①预训练语言模型等方法生成词嵌入向量,然后采用卷积神经网络和均值池化等方法聚合评论中所有词的表示,进而得到各个评论的综合表示。接下来,提取用户和项目的所有历史评论的表示,采用拼接和均值池化等方法得到用户偏好特征和项目特征。去噪自动编码器在自动编码器基础上,向输入数据中添加噪声,使学习到的低维特征表示更具鲁棒性^[31]。跨领域推荐研究^[31]采用去噪自动

① bidirectional encoder representations from transformers。

编码器将用户属性、项目属性和评论信息映射到低维特征空间。此外,研究^[86]利用项目标签信息来捕捉异质领域之间潜在的语义相关性。

以 ChatGPT 为代表的大语言模型凭借其世界知识理解能力和内容生成能力得到了研究者的广泛关注^[87,88]。大语言模型开始被应用于跨领域推荐系统的文本信息编码中,以提取丰富的跨领域通用信息^[60,61]。基于大语言模型的跨领域推荐成为新兴研究方向。

4 跨领域迁移丰富信息

如何充分挖掘和利用各个领域中的丰富信息,是双目标跨领域推荐的第二个核心研究问题。跨领域迁移丰富信息的研究主要集中在三个方面:①基于跨领域统一图的研究,这类研究构建跨领域统一图,应用图神经网络提取并迁移大量高阶协同信号;②基于跨领域特征对齐的研究,这类研究从领域间共性的视角出发,约束跨领域重叠实体在两个领域的特征表示之间、两个领域整体特征之间具有高度相似性;③基于跨领域桥梁扩充的研究,这类研究利用知识图谱和信任关系等,扩充跨领域信息迁移桥梁。表 3 对跨领域迁移丰富信息的代表文献进行了总结与比较。

表 3 面向跨领域迁移丰富信息的相关研究总结

研究类别		基本思想	主要优点	方法不足	相关文献
基于跨领域统一图的研究	基于跨领域统一图的方法	直接构建跨领域统一图,采用图表示学习方法实现跨领域高阶信息传播	挖掘出潜在的、丰富的跨领域高阶协同信号	跨领域高阶协同信号蕴含的噪声问题	[41][51] [58][89]
基于跨领域特征对齐的研究	基于对比学习的方法	将不同领域视为对比学习中的不同视图,捕捉重叠实体等的跨视图关联	简单高效地实现跨领域双向信息迁移	难以捕捉复杂的跨领域关联	[7][55][56] [90][91]
	基于最优传输的方法	约束两个领域内的实体特征分布尽可能接近	捕捉复杂、多元的跨领域特征关联;普适性强	算法复杂度较高	[35][92] [93][94]
	基于正交变换的方法	对两个领域中的特征学习进行双向的约束	简化并稳定模型的学习过程	难以捕捉复杂的跨领域关联	[40][95][96]
基于跨领域桥梁扩充的研究	融合知识图谱的方法	利用知识图谱中丰富的实体和关系,挖掘潜在的跨领域共享信息	扩充的跨领域关联有充分的事实依据	知识图谱与各个领域内项目的匹配问题	[33][59]
	基于信任关系的方法	挖掘跨领域场景下潜在用户信任关系,进而转化为跨领域偏好相似关系	基于显式的跨领域用户行为数据挖掘出潜在信息	难以保证潜在信息的有效性和真实性	[46]

4.1 基于跨领域统一图的研究

为了实现两个领域之间更充分的信息迁移,相关研究直接构建跨领域统一图,采用图表示学习方法实现跨领域高阶信息传播,进而丰富两个领域中所有用户和项目的特征表示。此方法能够挖掘出潜在的、丰富的跨领域高阶协同信号,同时对两个领域的表示学习发挥促进作用。然而,这类研究假设跨领域重叠实体在辅助域中的所有交互行为对目标域而言都是有价值的,忽略了领域的异质性,导致跨领域高阶协同信号中可能存在与目标域无关的噪声信息^[90]。以跨领域信息迁移桥梁是重叠用户为例,大多数研究在构建跨领域统一图时不区分项目所属的领域,假设所有领域中的项目是同质的,用户和任意领域中的项目之间的交互边也是同质的^[51,89]。由于建模项目转换关系对挖掘用户动态偏好具有重要作用,一些双目标跨领域序列推荐研究构建跨领域项目转换图,在受到用户连续交互的两个项目之间建立连边,而对

项目所在的领域不予区分^[7, 89]。为了建模领域的异质性, 前沿研究^[37]构建跨领域统一异质图, 将用户与不同领域中的项目之间的交互关系抽象为不同类型的连边, 并在信息传播中为两种类型的交互边分配不同的特征转换参数。

4.2 基于跨领域特征对齐的研究

这类研究采用对比学习、最优传输和正交变换等方法, 约束跨领域重叠实体在两个领域的特征表示之间、两个领域整体特征之间具有高度相似性。该特征对齐机制同时作用于两个领域, 使得两个领域都能充分感知到彼此的特征信息, 进而跨领域双向迁移丰富的信息。

4.2.1 基于对比学习的方法

对比学习通过设计数据扩充方法, 建立并捕捉实体在不同视图间的特征相关性, 进而构建对比损失辅助模型的学习^[97]。如图 2 所示, 现有研究将不同的领域视为对比学习中的不同视图, 采用对比学习捕捉跨领域重叠实体等信息的跨视图关联。推荐任务与对比学习任务联合学习, 实现有效的跨领域双向信息迁移和各领域的实体表示学习^[7, 55, 56, 90]。该方法的优势在于简单高效, 但相对于最优传输方法, 该方法难以捕捉复杂的跨领域关联。代表性研究^[7]构建各个领域的交互序列和跨领域交互序列, 然后采用对比学习方法, 分别约束两个领域的交互序列表示, 跨领域交互序列表示之间具有较高的相关性。最终的损失函数由两个对比损失和三个推荐损失构成, 实现了以跨领域交互序列为纽带间接传递跨领域信息。为了提升跨领域信息迁移质量, 捕捉跨领域重叠实体之外的更多跨领域关联成为基于对比学习的跨领域推荐研究的重点。例如, 研究^[91]考虑实体部分重叠的推荐场景, 首先基于用户特征的相似性找出领域特有用户在对方领域的最相似用户, 然后采用对比学习方法最大化两个领域中重叠用户或者相似用户的特征表示的相似性。

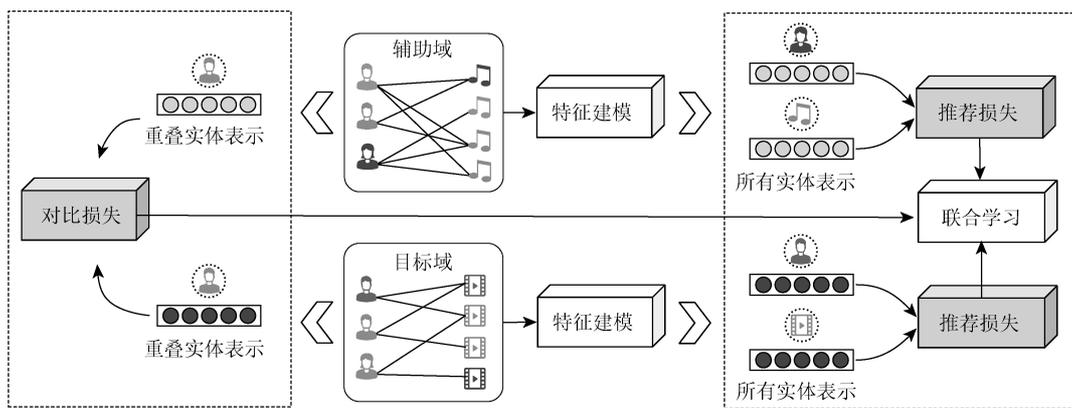


图 2 基于对比学习的跨领域特征对齐架构

4.2.2 基于最优传输的方法

最优传输 (optimal transport) 是一个寻找两个分布之间最优的数据传输方式的过程^[92]。已有研究采用高斯分布来刻画各个领域内用户和项目的特征, 并设计基于最优传输的对齐方法, 即最小化两个分布互换的成本, 约束两个领域中的特征分布尽可能接近^[35, 92-94]。这类研究利用高斯分布进行实体表征和跨领域特征对齐, 能够捕捉复杂、多元的跨领域特征关联; 同时, 这些研究可以应用于实体部分重叠的跨领域推荐场景, 具有良好的普适性。然而, 这类研究的算法复杂度较高。代表性研究^[35]设计局部对齐和

全局对齐策略。局部对齐使得跨领域重叠实体在两个领域中的分布均值和分布方差分别尽可能接近；全局对齐策略将各个领域内的所有实体聚类为若干簇，然后采用最优传输方法，使得所有跨领域实体簇的特征分布之间距离的加权和最小化，进而实现全局层面的跨领域特征对齐。

4.2.3 基于正交变换的方法

基于正交变换（orthogonal mapping）的研究能够对两个领域中的特征学习进行双向的约束，同时为两个领域提供精确的推荐^[40, 95, 96]。由于在正交变换中矩阵的转置矩阵即为它的逆矩阵，此类方法在双向约束过程中能够简化对跨领域特征映射矩阵的学习过程；同时，这类方法对跨领域特征映射矩阵的参数空间进行限制，进而稳定模型的训练过程。代表性研究^[40]设计双向嵌入模块，该模块使得任意一个领域中的用户偏好表示在经过正交映射矩阵的转换后，与对方领域中的偏好表示尽可能相似。该方法拉近了两个领域中实体特征空间的距离，进而利用跨领域信息增强各个领域内的实体表示学习质量。

4.3 基于跨领域桥梁扩充的研究

这类研究融合外部的知识图谱，挖掘潜在信任关系，或依据特定规则增加跨领域实体间的联系，以扩充跨领域信息迁移的桥梁。扩充的跨领域信息迁移桥梁使得两个领域都能为彼此传递更多的信息，从而显著缓解两个领域的数据稀疏问题、提升双目标跨领域推荐性能。

4.3.1 融合知识图谱的方法

研究表明^[59, 98]，项目属性的相通性有助于理解和推断用户偏好的确切含义。利用知识图谱中丰富的实体和关系、挖掘潜在的跨领域共享信息，能够更好地理解并融合辅助域中用户或项目的潜在特征^[99]。如图 3 所示，现有研究依据项目与知识图谱实体的对应关系，将跨领域交互数据和知识图谱整合起来，设计基于图神经网络的特征融合机制，将丰富的知识融入各领域实体的表示中^[33, 59]。由于知识图谱包含真实可靠的实体及关系，这类研究的跨领域关联扩充过程具有充分的事实依据，从而显著提升跨领域信息迁移质量。然而，现已积累的知识图谱中的实体可能难以与各个领域中的项目相匹配，这在一定程度上限制了方法的适用性。考虑动态特征的研究^[59]构建知识图谱，并将跨领域交互序列中的项目与知识图谱中的实体对应起来。然后，该研究采用图卷积网络更新知识图谱实体的表示。特别地，在表示更新过程中，该研究判断目标实体的邻居实体是否与其属于同一个领域，进而分别聚合属于和不属于同一领域的邻居实体的表示并将聚合结果相加。考虑静态特征的研究^[33]构建协同知识图，然后在协同知识图上应用偏好感知的图注意力网络来聚合知识图谱实体的特征。

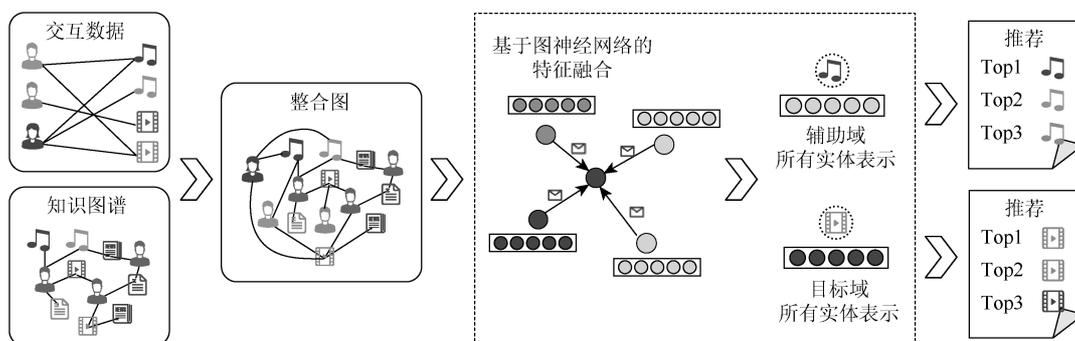


图 3 基于知识图谱的跨领域桥梁扩充架构

4.3.2 基于信任关系的方法

社交同质性理论表明，社会好友通常具有相似的偏好^[100-102]。相关研究从两个领域的用户交互行为中挖掘跨领域场景下潜在的用户信任关系，将潜在信任关系转化为跨领域偏好相似关系，以丰富对用户偏好特征的表达^[46, 103]。这类研究的优势在于其充分挖掘了跨领域交互行为背后的信息。然而，挖掘出的信任关系只是机器学习模型的预测结果，保证其有效性和真实性是一个挑战性强的问题^[104]。代表性研究^[46]首先采用协同矩阵分解方法学习各个领域用户和项目的表示，通过计算特征表示的相似性得到两个领域中用户之间的信任强度，进而构建跨领域信任关系的无向加权二部图。在此基础上，该研究采用蚁群算法生成各个用户与其最为信任的若干邻居的信任度，然后将该信任度整合到评分预测和损失函数中。

此外，研究^[38]面向用户部分重叠的推荐场景，在基于重叠用户构建的跨领域统一图上，为预训练特征表示相似性高的节点对建立连边，进而在扩充的跨领域统一图上运用图神经网络，将大量跨领域高阶协同信号整合到各个领域的实体表示中。面向用户无重叠的推荐场景，研究^[34]首先将各个领域内的用户划分为潜在重叠用户和领域特有用户，然后设计一种新颖的相似性度量方法，将潜在重叠用户在两个领域之间对应起来。

5 跨领域迁移有效信息

领域的异质性意味着用户在不同领域的偏好及行为存在较大差异^[1]，这为跨领域信息迁移机制的设计带来挑战。尤其是在双目标跨领域推荐中，两个领域都需要从对方领域的行为信息中获益。因此，如何保证跨领域双向迁移信息的有效性以避免负迁移问题，是双目标跨领域推荐的第三个核心研究问题。跨领域迁移有效信息的研究主要集中在三个方面：①基于注意力机制的研究，这类研究采用注意力机制有选择地融合来自辅助域的信息；②基于跨领域信息解耦的研究，这类研究将各个领域内的信息解耦为跨领域共享信息和领域特有信息，进而只迁移跨领域共享信息；③基于强化学习去噪的研究，这类研究评估辅助域中每一个项目对目标域推荐性能的作用，识别起到负面作用的噪声项目，进而通过强化学习方法去除噪声项目的信息或降低其训练权重。表 4 对跨领域迁移有效信息的代表文献进行了总结与比较。

表 4 面向跨领域迁移有效信息的相关研究总结

研究类别		基本思想	主要优点	方法不足	相关文献
基于注意力机制的研究	基于注意力机制的方法	有选择地为各个领域聚合对方领域中有价值的信息	方法简单有效	无法彻底消除辅助域中的噪声信息	[31][40][67][53][54]
基于跨领域信息解耦的研究	基于对抗学习的方法	设计跨领域共享特征提取器和领域判别器，对两者对抗训练，最终提取跨领域共享特征	适用于实体部分重叠和无重叠等多种场景	训练过程不稳定，模型难以收敛	[39][43][105][106]
	基于概率图模型的方法	基于概率图模型得到实体特征分布，约束对跨领域共享特征分布的学习	精准迁移跨领域共享信息；训练过程稳定	算法复杂度相对较高	[71][72][107][108]
基于强化学习去噪的研究	基于强化学习去噪的方法	衡量辅助域中各个项目对目标域推荐的作用，消除有负面作用的单个项目信息或降低其训练权重	从根源上消除辅助域中的噪声交互信息	训练难度大，模型难以收敛；奖励函数难以定义	[109]

5.1 基于注意力机制的研究

如图 4 所示, 现有研究采用注意力机制为各个领域有选择地聚合对方领域中的实体特征表示^[31, 40, 67]。这类方法简单有效, 能够借助注意力双向聚合来同时改善两个领域中的特征表示质量。然而, 注意力机制只能尽可能降低跨领域噪声信息的重要性权重, 而不能彻底消除跨领域噪声信息^[110]。代表性研究^[31]面向实体部分重叠场景设计了双注意力机制, 以跨领域重叠实体为纽带同时提升两个领域的全局推荐性能。一方面, 该研究通过领域内的注意力机制, 在各个领域内部为目标实体有选择地聚合相似实体的特征; 另一方面, 该研究设计跨领域注意力机制, 基于重叠实体的跨领域特征相似性, 为各个领域内的所有实体聚合跨领域相似实体的信息。研究^[67]对跨领域重叠用户在两个领域中的特征向量应用逐元素的注意力机制, 能够细粒度地聚合有价值的跨领域信息。此外, 相关研究设计基于注意力机制的门控机制, 对跨领域迁移的信息进行控制和过滤。例如, 基于共享账户的跨领域序列推荐研究^[53, 54]在对各个领域内的交互序列进行序列编码后, 将每一个项目的表示输入基于门控机制的跨领域特征过滤模块, 以单个项目为单位细粒度地对用户动态偏好表示进行过滤和迁移。

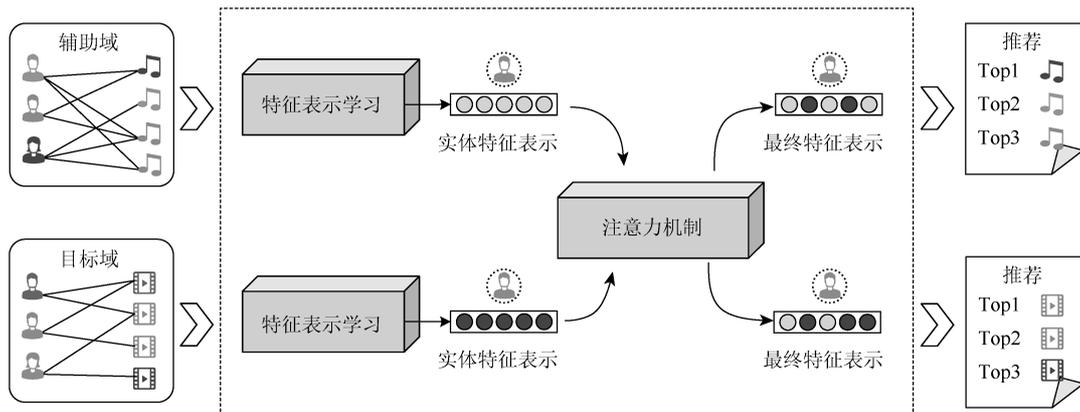


图 4 基于注意力机制的有效信息迁移架构

5.2 基于跨领域信息解耦的研究

注意力机制只能为噪声信号分配较低的权重, 而不能彻底消除噪声信息的影响。为此, 研究^[111]认为应该只迁移跨领域共享信息, 而领域特有信息则应该只应用于领域内的推荐。现有研究通常采用对抗学习和概率图模型等方法, 同等地考虑两个领域并且同等地建模两个领域的相互作用, 将各个领域内的实体特征解耦为跨领域共享特征和领域特有特征, 进而仅将各个领域的跨领域共享特征迁移至对方领域并应用于对方领域的推荐过程。

5.2.1 基于对抗学习的方法

生成对抗网络中, 生成器和判别器进行极大极小博弈, 当模型训练至收敛状态时, 判别器难以分辨生成器所生成内容和真实内容, 此时能够保证生成内容的质量^[112]。如图 5 所示, 基于对抗学习的双目标跨领域推荐研究的主要思路为: 基于矩阵分解、深度神经网络等方法, 设计跨领域共享特征提取器和领域特有特征提取器。跨领域共享特征提取器和领域判别器分别作为生成对抗网络中的生成器和判别器, 通过对抗训练来学习跨领域共享特征。接着基于注意力机制、线性组合等方法, 融合各个领域内的

跨领域共享特征和领域特有特征，得到实体最终特征表示并实现推荐任务^[39, 43, 105, 106]。具体来说，领域判别器的判别样本为两个领域中的跨领域共享特征提取器输出的实体特征，判别结果为这些实体特征所属的领域。在实体完全重叠场景中，接受判别的特征通常来自跨领域重叠实体，以学习同一实体的跨领域共享信息；而在实体部分重叠和无重叠场景中，接受判别的特征通常来自不同领域中的不同实体，这意味着两个领域的全局特征空间得以最大限度地匹配。此类方法的优势在于其适用于实体完全重叠、部分重叠以及无重叠场景。然而，由于生成器和判别器之间的“抗衡”状态较难维持，这类研究也具有训练过程不稳定、模型难以收敛等不足^[39]。

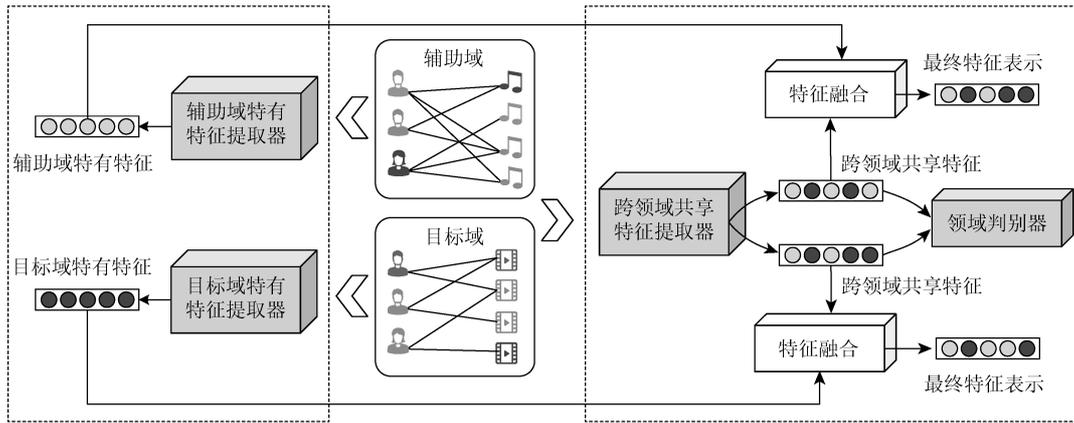


图5 基于对抗学习的跨领域信息解耦架构

5.2.2 基于概率图模型的方法

近年来，基于概率图模型的特征解耦方法得到深入探索^[113-115]。如图6所示，代表性研究 DisenCDR^[71]构建跨领域行为概率图。其中， X, Y 分别代表 X, Y 领域中的交互信息， Z_v^X, Z_v^Y 分别为 X, Y 领域中的项目特征， Z_u^X, Z_u^Y 分别为用户 X, Y 领域的领域特有特征， Z_u^S 为用户的跨领域共享特征。生成过程基于两个领域中的各个潜在特征重构可观测交互数据；推断过程基于可观测交互数据得到每个潜在因子的后验特征分布。为实现有效的特征解耦，DisenCDR 基于互信息理论构建两个正则化器，学习适用于两

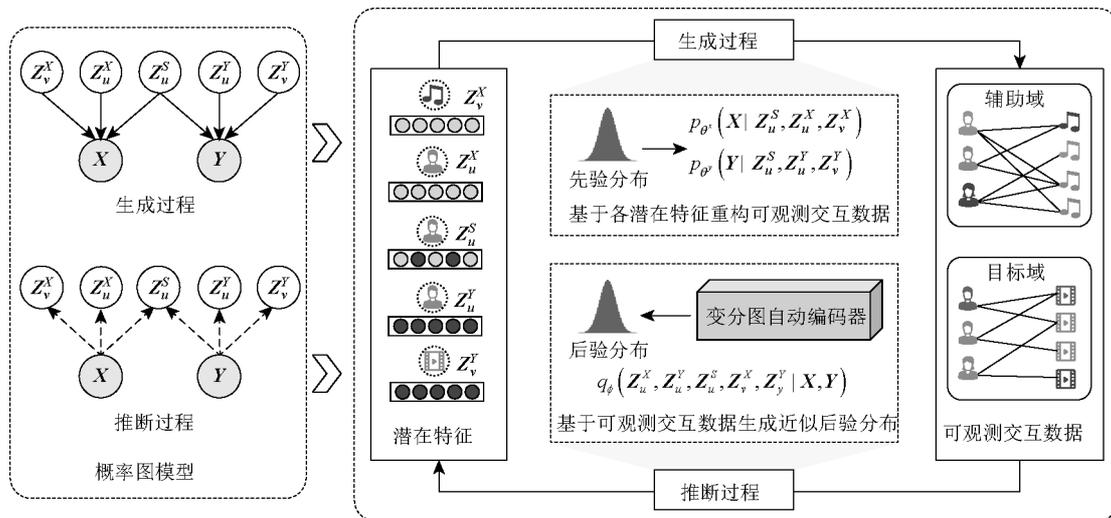


图6 基于概率图模型的跨领域信息解耦架构^[71]

个领域推荐任务的跨领域共享特征，并最大化跨领域共享特征和领域特有特征的差异。在 DisenCDR 基础上，研究^[107]将各个领域内的领域特有特征融入对方领域中的跨领域共享特征的学习过程，从而更精确地学习跨领域共享特征。也有研究只显式地提取跨领域共享特征，而不对领域特有特征进行约束^[39, 72]。例如，研究^[72]基于信息瓶颈理论，设计跨领域和领域内的信息瓶颈正则化器，共同约束跨领域共享特征的学习。总体来看，这类研究显式地划分跨领域共享特征和领域特有特征，能够精准迁移有价值的跨领域共享信息；相比于基于对抗学习的方法，这类方法的训练过程也更为稳定。与此同时，这类方法也具有算法复杂度较高的不足。

5.3 基于强化学习去噪的研究

大多数基于注意力机制和信息解耦的研究首先基于用户交互行为得到用户偏好表示，然后有选择地提取该偏好表示中有价值的信息。这意味着可能无法完全消除用户交互的单个噪声项目的影响。为此，近期研究提出在单个项目水平上，评估用户在辅助域中交互的每个项目对目标域推荐性能的作用，然后采用强化学习方法，去除起到负面作用的单个项目的信息或者降低其在模型优化中的权重^[109]。该机制能够应用于任意一个领域向对方领域的信息迁移过程，从而提升跨领域双向迁移信息的有效性。代表性研究^[109]面向双目标跨领域序列推荐问题，设计层次强化学习方法。高水平强化学习确定是否修正辅助域的整体交互序列。当判断得出需要对辅助域的整体交互序列做出修正时，低水平强化学习将进一步确定是否删除该交互序列中的每个项目。总结来看，这类研究细粒度地消除了噪声信息，显著提升推荐准确性。然而，这类研究面临训练难度大，难以收敛的瓶颈。此外，强化学习中的奖励函数也难以确定，往往存在稀疏奖励的问题，进一步阻碍模型的有效训练和快速收敛^[116]。因此，未来应该深入探索更加简单高效的跨领域信息去噪机制。

6 未来研究趋势

双目标跨领域推荐近年来积累了丰富的研究成果，这些研究成果已被广泛部署和应用到各大电子商务平台^[1, 11, 40]。然而，未来仍需要对双目标跨领域推荐系统展开深入研究。本文主要围绕双目标跨领域推荐的三个核心研究问题，对未来研究趋势进行展望。首先，针对各领域特征表示学习问题，本文认为大语言模型中蕴含的世界知识有助于领域内的表示学习和跨领域的知识理解，因此提出基于大语言模型的项目通用表示学习的未来方向。其次，跨领域迁移丰富信息和有效信息是对跨领域信息迁移机制提出的具体要求。为进一步提升跨领域迁移信息的有效性，本文提出跨领域迁移有效信息的模型架构优化。为兼具迁移信息的丰富性和有效性并实现两者间的权衡，本文提出考虑用户心理因素及行为模式的信息迁移机制。最后，在建模三个核心研究问题基础之上，本文进一步考虑实际应用场景中特有的特征因素，提出面向具体推荐场景的双目标跨领域推荐这一未来研究方向。

6.1 基于大语言模型的项目通用表示学习

为了进一步提取并迁移丰富的跨领域共享知识，越来越多的研究者致力于利用外部知识构建项目通用表征，然后将这些通用表征直接或微调后应用于推荐任务^[117]。现有研究开始将大语言模型应用于跨领域推荐系统，利用大语言模型蕴含的通用知识来增强跨领域共享特征的学习。相比于基于用户/项目标识符 (identifier, ID) 的方法和基于 BERT 等预训练语言模型的方法，大语言模型将更加丰富的信息融

入用户或项目的表示中,进而深化推荐系统对项目特征和用户跨领域偏好的理解。然而,当前基于大语言模型的双目标跨领域推荐研究还处于初步发展阶段。首先,大语言模型旨在理解文本语义而推荐系统旨在捕捉协同信号,两者之间存在语义鸿沟。如何对齐大语言模型和跨领域推荐系统的语义空间、充分发挥大语言模型的优势,是未来需要探索的重要科学问题。其次,大语言模型提取的跨领域通用表示中没有融入特定领域所独有的特点,无法适配于两个特定领域而实现精确的双目标跨领域推荐。因此,设计基于大语言模型的领域自适应机制成为双目标跨领域推荐系统中有前景的研究方向。

6.2 跨领域迁移有效信息的模型架构优化

保证迁移信息的有效性是跨领域信息迁移机制必须满足的重要方面。现有研究通常应用人工智能领域中经典的多任务学习、对抗学习等方法,而没有基于跨领域推荐场景来优化信息迁移的模型架构。首先,多任务学习在双目标跨领域推荐系统中有广泛应用,然而,多任务学习方法容易产生跷跷板现象而导致信息负迁移问题^[118]。因此,在两个领域具有较强异质性的背景下,应探讨跷跷板现象在双目标跨领域推荐模型中的产生原因,改进传统的多任务学习范式。例如,可以将特定领域信息注入模型原有的参数共享层,或者对优化过程中各个领域的学习率及损失函数的权重进行灵活调整等。其次,生成对抗网络是跨领域信息解耦机制研究中的典型方法,但是传统的生成对抗网络面临训练不稳定和难以收敛等问题,致使无法精确地提取并迁移跨领域共享信息。已有研究对传统的生成对抗网络架构进行改进^[119, 120],然而,这些先进方法在双目标跨领域推荐系统中少有应用。因此,改进生成对抗机制或设计其他简单高效的信息解耦方法依然是当前的研究重点。

6.3 考虑心理因素及行为模式的信息迁移机制

跨领域信息迁移机制研究已经取得了丰富的成果,现有研究所使用的门控机制和信息解耦等方法能够较为有效地跨领域迁移有价值信息。然而,现有研究没有考虑用户内在心理因素及分析用户行为模式,难以提供用户友好的双目标跨领域推荐。未来研究可以借助相关心理学理论,深入分析用户在电子商务平台多个领域中的心理因素和行为模式,然后基于用户的个性化行为模式设计跨领域信息迁移机制。首先,用户在不同领域之间的切换可能是由用户特定的心理因素驱动的。例如,当用户对当前领域中项目的形式和风格感到厌倦时,用户可能会切换到对方领域。在这种情况下,可以推荐与用户此前交互的项目本质特征相同、但外在形式不同的项目。因此,用户心理因素的识别对优化跨领域信息迁移策略具有重要作用。其次,已有研究考虑到用户的个性化行为模式,为不同用户设计个性化的跨领域信息迁移桥梁^[41]。在此基础上,双目标跨领域推荐研究可以考虑不同用户之间细粒度的跨领域行为模式的共性及差异,利用用户所在群组的行为信息帮助构建跨领域信息迁移方法。

6.4 面向具体推荐场景的双目标跨领域推荐

现有研究通常设计场景无关的推荐方法,即没有指定“领域”的具体含义。这些方法的优势在于可以将同一模型架构应用于不同的推荐场景,与此同时,这些方法也忽略了对推荐性能至关重要的领域特征。因此,未来研究可以针对具体的领域设计跨领域推荐算法,进而在实际应用中达到更优的推荐性能。例如,异地地点推荐旨在基于用户的本地签到行为和少量的异地签到行为,为用户推荐其在异地可能喜欢的地点。异地地点推荐是一种特殊的跨领域推荐,但是异地地点推荐方法还需要考虑地点间的地理邻近性和用户受到的时空约束等信息。此外,面向图书、电影领域的跨领域推荐与面向运动、服装领域的

跨领域推荐具有明显差异。图书和电影具有其想要表达的主题,而这些主题可以通过潜在狄利克雷分配(latent Dirichlet allocation, LDA)主题模型等文本分析方法从文本描述中挖掘出来。在面向内容平台的跨领域推荐系统中,深入挖掘项目的文本描述能够帮助理解用户在多个领域真正感兴趣的主体,进而推荐符合特定主题的内容。

双目标跨领域推荐研究为平台提供了有益的管理启示与应用价值。首先,随着平台规模的不断扩大,平台应从全局视角出发分析所有领域的特点和运营目标,制定跨领域综合策略,以确保在资源有限的条件下最大化平台整体效益。其次,跨领域知识互通的巨大成功启示我们,对平台内多种资源进行互换与整合有助于充分发挥资源的整体价值。不同领域中商品的营销模式或者内容的展示方式都可以借鉴对方的成功案例进行优化。随着越来越多的平台开始提供功能丰富的多领域服务,双(多)目标跨领域推荐系统将被广泛地开发与应用,进而在更大范围内创造更高的经济价值。最后,基于双目标跨领域推荐研究所依托的知识整合与知识互通思想,能够构建更为全面和精确的用户画像。这有助于精准识别目标客户群体以及提升平台的定向营销能力^[121, 122],对增强客户满意度与平台的市场竞争力具有重要意义。

7 结语

随着多元化服务的普及和跨系统知识互联的高速发展,双目标跨领域推荐成为提升推荐质量的重要研究方向。双目标跨领域推荐系统对当前电子商务平台具有重要的商业价值,是充分利用平台数据资源、全方位提升平台服务水平的关键技术。本文通过梳理双目标跨领域推荐文献,提炼双目标跨领域推荐研究中的三个核心问题。一,将跨领域场景的单个领域建模的问题抽象为对单域内静态交互数据、动态交互数据和多种辅助数据的信息编码问题。二,从跨领域迁移丰富信息的视角,将跨领域信息迁移机制总结为跨领域统一图构建、跨领域特征对齐和跨领域桥梁扩充三个方面。三,从跨领域迁移有效信息的视角,将最新研究成果总结为基于注意力机制的信息聚合、跨领域信息解耦和基于强化学习去噪的研究。之后,针对各个研究问题对双目标跨领域推荐前沿研究进行综述。最后,展望双目标跨领域推荐的未来研究方向。未来研究应借助大语言模型、文本分析方法和相关心理学理论,从三个核心研究问题以及推荐系统实际应用场景的视角出发,对双目标跨领域推荐系统进行持续改进。

参 考 文 献

- [1] Li S Q, Yao L Y, Mu S L, et al. Debiasing learning based cross-domain recommendation[C]//Zhu F D, Ooi B C, Miao C Y. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2021: 3190-3199.
- [2] 范文芳, 王千. 个性化智能推荐对消费者在线冲动购买意愿的影响研究[J]. 管理评论, 2022, 34(12): 146-156, 194.
- [3] 吕巍, 杨颖, 张雁冰. AI个性化推荐下消费者感知个性化对其点击意愿的影响[J]. 管理科学, 2020, 33(5): 44-57.
- [4] Jozani M, Liu C Z C, Choo K K R. An empirical study of content-based recommendation systems in mobile app markets[J]. Decision Support Systems, 2023, 169: 113954.
- [5] 刘世峰, 康来松, 宫大庆. 面向群组的事件兴趣点推荐算法研究[J]. 中国管理科学, 2023, 31(12): 301-310.
- [6] Zhang Y, Li C Y, Tsang I W, et al. Diverse preference augmentation with multiple domains for cold-start recommendations[C]//2022 IEEE 38th International Conference on Data Engineering. Washington, DC: IEEE Computer Society, 2022: 2942-2955.
- [7] Cao J X, Cong X, Sheng J W, et al. Contrastive cross-domain sequential recommendation[C]//Al Hasan M, Li X.

- Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York: Association for Computing Machinery, 2022: 138-147.
- [8] 李延晖, 廖康, 徐璐. 电商平台与服务提供商的用户隐私信息管理策略研究[J]. 中国管理科学, 2022, 30(6): 157-166.
- [9] 王利娥, 李东城, 李先贤. 基于跨域关联与隐私保护的深度推荐模型[J]. 软件学报, 2023, 34(7): 3365-3384.
- [10] Lei C Y, Liu Y, Zhang L Z, et al. SEMI: a sequential multi-modal information transfer network for e-commerce micro-video recommendations[C]//Zhu F D, Ooi B C, Miao C Y. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2021: 3161-3171.
- [11] Hao X B, Liu Y D, Xie R B, et al. Adversarial feature translation for multi-domain recommendation[C]//Zhu F D, Ooi B C, Miao C Y. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2021: 2964-2973.
- [12] Yang J, Zhu J X, Ding X F, et al. A memory pool variational autoencoder framework for cross-domain recommendation[J]. Expert Systems with Applications, 2024, 241: 122771.
- [13] 曹宗胜, 许倩倩, 李朝鹏, 等. 基于对偶四元数的协同知识图谱推荐模型[J]. 计算机学报, 2022, 45(10): 2221-2242.
- [14] Li Y K, Ren J D, Liu J M, et al. Deep sparse autoencoder prediction model based on adversarial learning for cross-domain recommendations[J]. Knowledge-Based Systems, 2021, 220: 106948.
- [15] Ivens B, Kasper-Brauer K, Leischnig A, et al. Implementing customer relationship management successfully: a configurational perspective[J]. Technological Forecasting and Social Change, 2024, 199: 123083.
- [16] Siqin T, Choi T M, Chung S H, et al. Platform operations in the industry 4.0 era: recent advances and the 3As framework[J]. IEEE Transactions on Engineering Management, 2024, 71: 1145-1162.
- [17] Li F Y, Xu G H. AI-driven customer relationship management for sustainable enterprise performance[J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102103.
- [18] Rostamzadeh R, Bakhnoo M, Strielkowski W, et al. Providing an innovative model for social customer relationship management: meta synthesis approach[J]. Journal of Innovation and Knowledge, 2024, 9(3): 100506.
- [19] Li P, Wu B. The diffusion of platform self-operation on reputation-based two-layer network[J]. Industrial Management and Data Systems, 2024, 124(3): 949-977.
- [20] Gao Q Y, Wang Q, Wu C S. Construction of enterprise digital service and operation platform based on internet of things technology[J]. Journal of Innovation and Knowledge, 2023, 8(4): 100433.
- [21] Zang T Z, Zhu Y M, Liu H B, et al. A survey on cross-domain recommendation: taxonomies, methods, and future directions[J]. ACM Transactions on Information Systems, 2023, 41(2): 1-39.
- [22] Xu J, Wang X, Zhang H M, et al. Heterogeneous and clustering-enhanced personalized preference transfer for cross-domain recommendation[J]. Information Fusion, 2023, 99: 101892.
- [23] Wang L, E, Qi Y L, Bai Y, et al. MuKGB-CRS: guarantee privacy and authenticity of cross-domain recommendation via multi-feature knowledge graph integrated blockchain[J]. Information Sciences, 2023, 638: 118915.
- [24] Hu Z, Nakagawa S, Cai S M, et al. Enhancing cross-market recommendations by addressing negative transfer and leveraging item co-occurrences[J]. Information Systems, 2024, 124: 102388.
- [25] Yu J L, Yin H Z, Xia X, et al. Self-supervised learning for recommender systems: a survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(1): 335-355.
- [26] Goli A, Singh A. Frontiers: can large language models capture human preferences? [J]. Marketing Science, 2024, 43(4): 697-923.
- [27] Gao G, Liu H Y, Zhao K. Live streaming recommendations based on dynamic representation learning[J]. Decision Support Systems, 2023, 169: 113957.
- [28] Wei Q, Mu Y, Guo X H, et al. Dynamic Bayesian network-based product recommendation considering consumers' multistage shopping journeys: a marketing funnel perspective[J]. Information Systems Research, 2023, 35(3): 1-18.
- [29] Yu T, Guo J P, Li W H, et al. A mixed heterogeneous factorization model for non-overlapping cross-domain recommendation[J]. Decision Support Systems, 2021, 151: 113625.
- [30] Tian C X, Xie Y X, Chen X, et al. Privacy-preserving cross-domain recommendation with federated graph learning[J].

- ACM Transactions on Information Systems, 2024, 42(5): 1-29.
- [31] Li Y K, Wu Q, Hou L, et al. Entity knowledge transfer-oriented dual-target cross-domain recommendations[J]. Expert Systems with Applications, 2022, 195: 116591.
- [32] Zheng J X, Li Q W, Liao J. Heterogeneous type-specific entity representation learning for recommendations in e-commerce network[J]. Information Processing and Management, 2021, 58(5): 102629.
- [33] Li Y K, Hou L, Li J Z. Preference-aware graph attention networks for cross-domain recommendations with collaborative knowledge graph[J]. ACM Transactions on Information Systems, 2023, 41(3): 1-26.
- [34] Liu M, Li J J, Guo Z Q, et al. Extracting latently overlapping users by graph neural network for non-overlapping cross-domain recommendation[J]. Knowledge-Based Systems, 2024, 290: 111508.
- [35] Liu W M, Zheng X L, Su J J, et al. Exploiting variational domain-invariant user embedding for partially overlapped cross domain recommendation[C]//Amigo E, Castells P, Gonzalo J. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2022: 312-321.
- [36] Zhao C, Zhao H K, He M, et al. Cross-domain recommendation via user interest alignment[C]//Ding Y, Tang J, Sequeda J. Proceedings of the ACM Web Conference 2023. New York: Association for Computing Machinery, 2023: 887-896.
- [37] Shi Y, Larson M, Hanjalic A. Tags as bridges between domains: improving recommendation with tag-induced cross-domain collaborative filtering[C]//Konstan J A, Conejo R, Marzo J L, et al. Proceedings of the 19th International Conference on User Modeling, Adaption, and Personalization. Berlin: Springer-Verlag, 2011: 305-316.
- [38] Xu K, Xie Y Z, Chen L, et al. Expanding relationship for cross domain recommendation[C]//Demartini G, Zuccon G, Culpepper L S. Proceedings of the 30th ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2021: 2251-2260.
- [39] Li C L, Zhao M J, Zhang H M, et al. RecGURU: adversarial learning of generalized user representations for cross-domain recommendation[C]//Candan K S, Liu H. Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York: Association for Computing Machinery, 2022: 571-581.
- [40] Li P, Jiang Z C, Que M F, et al. Dual attentive sequential learning for cross-domain click-through rate prediction[C]//Zhu F D, Ooi B C, Miao C Y. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2021: 3172-3180.
- [41] Zhu Y C, Tang Z W, Liu Y D, et al. Personalized transfer of user preferences for cross-domain recommendation[C]//Candan K S, Liu H. Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York: Association for Computing Machinery, 2022: 1507-1515.
- [42] Zhao C, Li C L, Xiao R, et al. CATN: cross-domain recommendation for cold-start users via aspect transfer network[C]//Huang J, Chang Y, Cheng X Q. Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2020: 229-238.
- [43] Choi Y, Choi J, Ko T, et al. Review-based domain disentanglement without duplicate users or contexts for cross-domain recommendation[C]//Al Hasan M, Li X. Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York: Association for Computing Machinery, 2022: 293-303.
- [44] Park C, Kim T, Hong J, et al. Cracking the code of negative transfer: a cooperative game theoretic approach for cross-domain sequential recommendation[C]//Frommholz I, Hopfgartner F, Lee M, et al. Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2023: 2024-2033.
- [45] Zhu F, Wang Y, Chen C C, et al. Cross-domain recommendation: challenges, progress, and prospects[C]//Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence(IJCAI-21). Freiburg: International Joint Conferences on Artificial Intelligence, 2021: 4721-4728.
- [46] Ahmed A, Saleem K, Khalid O, et al. On deep neural network for trust aware cross domain recommendations in E-commerce[J]. Expert Systems with Applications, 2021, 174: 114757.
- [47] Singh A P, Gordon G J. Relational learning via collective matrix factorization[C]//Li Y, Liu B, Sarawagi S. Proceedings of

- the 14th ACM SIGKDD international conference on Knowledge discovery and data mining. New York: Association for Computing Machinery, 2008: 650-658.
- [48] Liu M, Li J J, Li G H, et al. Cross domain recommendation via bi-directional transfer graph collaborative filtering networks[C]//D'Aquin M, Dietze S, Hauff C, et al. Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: Association for Computing Machinery, 2020: 885-894.
- [49] Nie J, Zhao Z, Huang L, et al. Cross-domain recommendation via user-clustering and multi-dimensional information fusion[J]. IEEE Transactions on Multimedia, 2023, 25: 868-880.
- [50] Mukande T. Heterogeneous graph representation learning for multi-target cross-domain recommendation[C]//Golbeck J, Harper F M, Murdock V, et al. Proceedings of the 16th ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2022: 730-734.
- [51] Guo L, Zhang J Y, Tang L, et al. Time interval-enhanced graph neural network for shared-account cross-domain sequential recommendation[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(3): 4002-4016.
- [52] 易明, 刘明, 冯翠翠. 融合异质信息网络表示学习的跨领域推荐研究[J]. 情报学报, 2022, 41(4): 337-349.
- [53] Ma M Y, Chen Z M, Ren P J, et al. Pi-Net: a parallel information-sharing network for shared-account cross-domain sequential recommendations[C]//Piwowarski B, Chevalier M, Gaussier E, et al. Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2019: 685-694.
- [54] Sun W C, Ma M Y, Ren P J, et al. Parallel split-join networks for shared account cross-domain sequential recommendations[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(4): 4106-4123.
- [55] Zang T Z, Zhu Y M, Zhang R H, et al. Contrastive multi-view interest learning for cross-domain sequential recommendation[J]. ACM Transactions on Information Systems, 2024, 42(3): 1-30.
- [56] Ni R X, Cai W S, Jiang Y C. Contrastive cross-domain sequential recommendation via emphasized intention features[J]. Neural Networks, 2024, 179: 106488.
- [57] Ye X X, Li Y, Yao L N. DREAM: decoupled representation via extraction attention module and supervised contrastive learning for cross-domain sequential recommender[C]//Zhang J, Chen L, Berkovsky S, et al. Proceedings of the 17th ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2023: 479-490.
- [58] Guo L, Tang L, Chen T, et al. DA-GCN: a domain-aware attentive graph convolution network for shared-account cross-domain sequential recommendation[C]//The 30th International Joint Conference on Artificial Intelligence. New York: Curran Associates, Inc., 2021: 2483-2489.
- [59] Ma M Y, Ren P J, Chen Z M, et al. Mixed information flow for cross-domain sequential recommendations[J]. ACM Transactions on Knowledge Discovery from Data, 2022, 16(4): 1-32.
- [60] Tang Z L, Huan Z X, Li Z H, et al. One model for all: large language models are domain-agnostic recommendation systems[J]. ACM Transactions on Information Systems, 2025, 43(5): 1-27.
- [61] Fu Z C, Li X Y, Wu C H, et al. A unified framework for multi-domain CTR prediction via large language models[J]. ACM Transactions on Information Systems, 2025, 43(5): 1-33.
- [62] 陈碧毅, 黄玲, 王昌栋, 等. 融合显式反馈与隐式反馈的协同过滤推荐算法[J]. 软件学报, 2020, 31(3): 794-805.
- [63] Zhang Q, Lu J, Wu D S, et al. A cross-domain recommender system with kernel-induced knowledge transfer for overlapping entities[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(7): 1998-2012.
- [64] Gan M X, Xu G X, Ma Y X. A multi-behavior recommendation method exploring the preference differences among various behaviors[J]. Expert Systems with Applications, 2023, 228: 120316.
- [65] 胡春华, 邓奥, 童小芹, 等. 社交电商中融合信任和声誉的图神经网络推荐研究[J]. 中国管理科学, 2021, 29(10): 202-212.
- [66] Gan M X, Wang C H, Yi L L, et al. Exploiting dynamic social feedback for session-based recommendation[J]. Information Processing and Management, 2024, 61(3): 103632.
- [67] Zhu F, Wang Y, Zhou J, et al. A unified framework for cross-domain and cross-system recommendations[J]. IEEE

- Transactions on Knowledge and Data Engineering, 2023, 35(2): 1171-1184.
- [68] Han Z X, Zheng X L, Chen C C, et al. Intra and inter domain hypergraph convolutional network for cross-domain recommendation[C]//Ding Y, Tang J, Sequeda J. Proceedings of the ACM Web Conference 2023. New York: Association for Computing Machinery, 2023: 449-459.
- [69] Mao Q Y, Liu Q, Li Z, et al. Cross-reconstructed augmentation for dual-target cross-domain recommendation[C]//Yang G H, Wang H N, Han S. Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2024: 2352-2356.
- [70] Zhao C, Li C L, Fu C. Cross-domain recommendation via preference propagation graphnet[C]//Zhu W W, Tao D C, Cheng X Q, et al. Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2019: 2165-2168.
- [71] Cao J X, Lin X X, Cong X, et al. DisenCDR: learning disentangled representations for cross-domain recommendation [C]//Amigo E, Castells P, Gonzalo J, et al. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2022: 267-277.
- [72] Cao J X, Sheng J W, Cong X, et al. Cross-domain recommendation to cold-start users via variational information bottleneck[C]//2022 IEEE 38th International Conference on Data Engineering. Washington, DC: IEEE Computer Society, 2022: 2209-2223.
- [73] Ma Y X, Gan M X. DeepAssociate: a deep learning model exploring sequential influence and history-candidate association for sequence recommendation[J]. Expert Systems with Applications, 2021, 185: 115587.
- [74] Yang Z X, Dong S B, Hu J L. GFE: general knowledge enhanced framework for explainable sequential recommendation[J]. Knowledge-Based Systems, 2021, 230: 107375.
- [75] Wang Y Q, Guo C L, Chu Y F, et al. A cross-domain hierarchical recurrent model for personalized session-based recommendations[J]. Neurocomputing, 2020, 380: 271-284.
- [76] Gan M X, Ma Y X. DeepInteract: multi-view features interactive learning for sequential recommendation[J]. Expert Systems with Applications, 2022, 204: 117305.
- [77] Gan M X, Ma Y X. Mapping user interest into hyper-spherical space: a novel POI recommendation method[J]. Information Processing and Management, 2023, 60(2): 103169.
- [78] 陈聪, 张伟, 王骏. 带有时间预测辅助任务的会话式序列推荐[J]. 计算机学报, 2021, 44(9): 1841-1853.
- [79] 张宜浩, 朱小飞, 徐传运, 等. 基于用户评论的深度情感分析和多视图协同融合的混合推荐方法[J]. 计算机学报, 2019, 42(6): 1316-1333.
- [80] 徐鹏宇, 刘华锋, 刘冰, 等. 标签推荐方法研究综述[J]. 软件学报, 2022, 33(4): 1244-1266.
- [81] 李琳, 朱阁, 解庆, 等. 一种潜在特征同步学习和偏好引导的推荐方法[J]. 软件学报, 2019, 30(11): 3382-3396.
- [82] Liu Y H, Chen Y L, Chang P Y. A deep multi-embedding model for mobile application recommendation[J]. Decision Support Systems, 2023, 173: 114011.
- [83] Liu W M, Zheng X L, Hu M L, et al. Collaborative filtering with attribution alignment for review-based non-overlapped cross domain recommendation[C]//Laforest F, Troncy R, Simperl E, et al. Proceedings of the ACM Web Conference 2022. New York: Association for Computing Machinery, 2022: 1181-1190.
- [84] Ni X, Nie J, Zuo Z J, et al. DITN: user's indirect side-information involved domain-invariant feature transfer network for cross-domain recommendation[J]. Information Processing and Management, 2023, 60(6): 103494.
- [85] Elahi M, Kholgh D K, Kiarostami M S, et al. Hybrid recommendation by incorporating the sentiment of product reviews[J]. Information Sciences, 2023, 625: 738-756.
- [86] Wang J Q, Lv J. Tag-informed collaborative topic modeling for cross domain recommendations[J]. Knowledge-Based Systems, 2020, 203: 106119.
- [87] Bao K Q, Zhang J Z, Zhang Y, et al. TALLRec: an effective and efficient tuning framework to align large language model with recommendation[C]//Zhang J, Chen L, Berkovsky S, et al. Proceedings of the 17th ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2023: 1007-1014.

- [88] Wei W, Ren X B, Tang J B, et al. LLMRec: large language models with graph augmentation for recommendation [C]//WSDM Angélica L, Lattanzi S, Medina A M, et al. Proceedings of the 17th ACM International Conference on Web Search and Data Mining. New York: Association for Computing Machinery, 2024: 806-815.
- [89] Zheng X L, Su J J, Liu W M, et al. DDGHM: dual dynamic graph with hybrid metric training for cross-domain sequential recommendation[C]//Magalhães J, del Bimbo A, Satoh S, et al. Proceedings of the 30th ACM International Conference on Multimedia. New York: Association for Computing Machinery, 2022: 471-481.
- [90] Hsu C W, Chen C T, Huang S H. Adaptive adversarial contrastive learning for cross-domain recommendation[J]. ACM Transactions on Knowledge Discovery from Data, 2023, 18(3): 1-34.
- [91] Lu J H, Sun G H, Fang X, et al. A contrastive learning framework for dual-target cross-domain recommendation[C]//El Saddik A, Mei T, Cucchiara R, et al. Proceedings of the 31st ACM International Conference on Multimedia. New York: Association for Computing Machinery, 2023: 6332-6339.
- [92] Li X H, Qiu Z P, Zhao X Y, et al. Gromov-Wasserstein guided representation learning for cross-domain recommendation[C]//AI Hasan M, Xiong L. Proceedings of the 31st ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2022: 1199-1208.
- [93] Liu W M, Zheng X L, Chen C C, et al. Joint internal multi-interest exploration and external domain alignment for cross domain sequential recommendation[C]//Ding Y, Tang J, Sequeda J. Proceedings of the ACM Web Conference 2023. New York: Association for Computing Machinery, 2023: 383-394.
- [94] Liu W M, Chen C C, Liao X T, et al. User distribution mapping modelling with collaborative filtering for cross domain recommendation[C]//Chuna T-S, Ngo C-W, Lee R K-W, et al. Proceedings of the ACM Web Conference 2024. New York: Association for Computing Machinery, 2024: 334-343.
- [95] Li P, Tuzhilin A. DDTCDR: deep dual transfer cross domain recommendation[C]//Carverlee J, Hu X B, Lalmas M, et al. Proceedings of the 13th International Conference on Web Search and Data Mining. New York: Association for Computing Machinery, 2020: 331-339.
- [96] Li P, Tuzhilin A. Dual metric learning for effective and efficient cross-domain recommendations[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(1): 321-334.
- [97] 张北辰, 李亮, 查正军, 等. 基于跨模态对比学习的视觉问答主动学习方法[J]. 计算机学报, 2022, 45(8): 1730-1745.
- [98] Gao J L, Peng P, Lu F, et al. Towards travel recommendation interpretability: disentangling tourist decision-making process via knowledge graph[J]. Information Processing and Management, 2023, 60(4): 103369.
- [99] Gan M X, Kwon O C. A knowledge-enhanced contextual bandit approach for personalized recommendation in dynamic domains[J]. Knowledge-Based Systems, 2022, 251: 109158.
- [100] 张青博, 王斌, 崔宁宁, 等. 基于注意力机制的规范化矩阵分解推荐算法[J]. 软件学报, 2020, 31(3): 778-793.
- [101] 刘华锋, 景丽萍, 于剑. 融合社交信息的矩阵分解推荐方法研究综述[J]. 软件学报, 2018, 29(2): 340-362.
- [102] Guo T L, Peng S S, Li Y, et al. Community-based social recommendation under local differential privacy protection[J]. Information Sciences, 2023, 639: 119002.
- [103] Ahmed A, Saleem K, Khalid O, et al. Trust-aware denoising autoencoder with spatial-temporal activity for cross-domain personalized recommendations[J]. Neurocomputing, 2022, 511: 477-494.
- [104] Quan Y H, Ding J T, Gao C, et al. Robust preference-guided denoising for graph based social recommendation[C]//Ding Y, Tang J, Sequeda J. Proceedings of the ACM Web Conference 2023. New York: Association for Computing Machinery, 2023: 1097-1108.
- [105] Zhang Q, Liao W H, Zhang G Q, et al. A deep dual adversarial network for cross-domain recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(4): 3266-3278.
- [106] Li P, Brost B, Tuzhilin A. Adversarial learning for cross domain recommendations[J]. ACM Transactions on Intelligent Systems and Technology, 2022, 14(1): 1-25.
- [107] Zhang Y, Cheng Z Y, Liu F, et al. Decoupled domain-specific and domain-conditional representation learning for cross-domain recommendation[J]. Information Processing and Management, 2024, 61(3): 103689.

- [108] Zhang T, Chen C, Wang D, et al. A VAE-based user preference learning and transfer framework for cross-domain recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(10): 10383-10396.
- [109] Guo L, Zhang J Y, Chen T, et al. Reinforcement learning-enhanced shared-account cross-domain sequential recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(7): 7397-7411.
- [110] Zhang X K, Lin H F, Xu B, et al. Dynamic intent-aware iterative denoising network for session-based recommendation[J]. Information Processing and Management, 2022, 59(3): 102936.
- [111] Cao J X, Li S S, Yu B W, et al. Towards universal cross-domain recommendation[C]//Chua T-S, Lauw H, Si Luo, et al. Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: Association for Computing Machinery, 2023: 78-86.
- [112] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [113] Liang D W, Krishnan R G, Hoffman M D, et al. Variational autoencoders for collaborative filtering[C]//Champin P-A, Gandon F, Médini L, et al. Proceedings of the 2018 World Wide Web Conference. Geneva: International World Wide Web Conferences Steering Committee, 2018: 689-698.
- [114] Zhao Z, Nie J, Wang C L, et al. Sliced Wasserstein based canonical correlation analysis for cross-domain recommendation[J]. Pattern Recognition Letters, 2021, 150: 33-39.
- [115] Blei D M, Kucukelbir A, McAuliffe J D. Variational inference: a review for statisticians[J]. Journal of the American statistical Association, 2018, 112(518): 859-877.
- [116] Chen X C, Yao L N, McAuley J L, et al. Deep reinforcement learning in recommender systems: a survey and new perspectives[J]. Knowledge-Based Systems, 2023, 264: 110335.
- [117] Hou Y P, Mu S L, Zhao W X, et al. Towards universal sequence representation learning for recommender systems [C]//Zhang A D, Rangwala H. Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2022: 585-593.
- [118] Liu Q, Zhou Z L, Jiang G W, et al. Deep task-specific bottom representation network for multi-task recommendation [C]//Frommholz P, Hopfgartner F, Lee M, et al. Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2023: 1637-1646.
- [119] Li Z H, Zhou Y, Wang Z Y, et al. Swarm GAN: stabilizing training of generative adversarial networks via swarm intelligence[C]//Proceedings of the 6th International Conference on Machine Learning and Machine Intelligence. New York: Association for Computing Machinery, 2023: 171-177.
- [120] Roy A, Dasgupta D. A distributed conditional Wasserstein deep convolutional relativistic loss generative adversarial network with improved convergence[J]. IEEE Transactions on Artificial Intelligence, 2024, 5(9): 4344-4353.
- [121] 彭宇泓, 赵娜亨. 直播电商服务失败与顾客流失: 基于消费者思维认知方式和直播平台类型的调节[J]. 信息系统学报, 2024, (2): 56-68.
- [122] Kasem M S E, Hamada M, Taj-Eddin I. Customer profiling, segmentation, and sales prediction using AI in direct marketing[J]. Neural Computing and Applications, 2024, 36(8): 4995-5005.

A Review of Frontier Research on Dual-target Cross-domain Recommendation

REN Jieyu, GAN Mingxin, WANG Chunhua

(School of Economics and Management, University of Science and Technology Beijing, Beijing 100083, China)

Abstract In the intelligent information era, in order to create a comprehensive business ecosystem, e-commerce platforms have developed from providing single services to providing diversified services.

Dual-target cross-domain recommender systems utilize users' behavioral information in two domains to capture their preference characteristics, so as to improve the recommendation performance and service level in both domains simultaneously. In this paper, we first introduce the research background and basic concepts. Then, we summarize three essential research issues, i.e., feature representation learning in each domain, cross-domain transfer of abundant information, and cross-domain transfer of valuable information. We survey the latest research findings on dual-target cross-domain recommendation methods. Finally, we state insights into future research.

Key words Cross-domain recommendation, Dual-target cross-domain recommendation, Machine learning, Cross-domain information transfer

作者简介

任婕妤(1999—),女,北京科技大学经济管理学院2022级博士研究生,研究方向为跨领域推荐方法、大数据分析、机器学习。E-mail: d202210493@xs.ustb.edu.cn。

甘明鑫(1978—),女,北京科技大学经济管理学院教授、博士生导师,研究方向为智能推荐系统、社交媒体分析与计算、大数据挖掘与知识发现。E-mail: ganmx@ustb.edu.cn。

王纯华(1999—),男,北京科技大学经济管理学院2021级博士研究生,研究方向为推荐系统、人工智能、知识管理。E-mail: d202110476@xs.ustb.edu.cn。