

多任务推荐算法研究综述

温民伟,梅红岩⁺,袁凤源,张晓宇,张 兴
辽宁工业大学 电子与信息工程学院,辽宁 锦州 121001
⁺通信作者 E-mail: 715014795@qq.com

摘要:单任务推荐算法存在数据稀疏、冷启动和推荐效果不稳定等问题。多任务推荐算法可以将多种类型的用户行为数据和额外信息进行联合建模,从而更好地挖掘用户的兴趣和需求,以提高推荐效果和用户满意度,为解决单任务推荐算法存在的一系列问题提供了新思路。首先,梳理了多任务推荐算法的发展背景与趋势。其次,介绍了多任务推荐算法的实现步骤以及构建原则,并阐述了多任务学习具有数据增强、特征识别、特征互补和正则化效应等优势。然后,对不同共享模式的多任务学习方法在推荐算法中的应用进行了介绍,并对部分经典模型的优缺点及任务之间的关系进行了归纳总结。接着,介绍了多任务推荐算法常用的数据集和评估指标,并阐述了与其他推荐算法在数据集评估指标方面的区别和联系。最后,指出多任务学习存在负迁移、参数优化冲突、可解释性差等不足,对多任务推荐算法与强化学习、凸函数优化方法、异构信息网络相结合进行了展望。

关键词:推荐系统;多任务学习;多任务推荐

文献标志码:A **中图分类号:**TP391

Survey of Multi-task Recommendation Algorithms

WEN Minwei, MEI Hongyan⁺, YUAN Fengyuan, ZHANG Xiaoyu, ZHANG Xing
School of Electronic and Information Engineering, Liaoning University of Technology, Jinzhou, Liaoning 121001, China

Abstract: Single-task recommendation algorithms have problems such as sparse data, cold start and unstable recommendation effect. Multi-task recommendation algorithms can jointly model multiple types of user behaviour data and additional information, to better explore the user's interests and needs in order to improve the recommendation effect and user satisfaction, which provides a new way of thinking to solve a series of problems existing in single-task recommendation algorithms. Firstly, the development background and trend of multi-task recommendation algorithms are sorted out. Secondly, the implementation steps of the multi-task recommendation algorithm and the construction principle are introduced, and the advantages of multi-task learning with data enhancement, feature identification, feature complementation and regularization effect are elaborated. Then, the application of multi-task learning methods in recommendation algorithms with different sharing models is introduced, and the advantages and disadvantages of some classical models and the relationship between tasks are summarized. Then, the commonly used datasets and evaluation metrics for multi-task recommendation algorithms are introduced, and the differences and connections with other recommendation algorithms in terms of dataset evaluation metrics are elaborated. Finally, it

基金项目:国家自然科学基金面上项目(62273170);辽宁省教育厅面上项目(JYTMS20230869);辽宁省教育厅科学研究项目(JZL202015404,LJKZ0625)。

This work was supported by the National Natural Science Foundation of China (62273170), the General Project of Liaoning Provincial Department of Education (JYTMS20230869), and the Scientific Research Project of Liaoning Provincial Department of Education (JZL202015404, LJKZ0625).

收稿日期:2023-03-06 **修回日期:**2023-07-27

is pointed out that multi-task learning has shortcomings such as negative migration, parameter optimization conflicts, poor interpretability, etc., and an outlook is given to the combination of multi-task recommendation algorithms with reinforcement learning, convex function optimization methods, and heterogeneous information networks.

Key words: recommendation system; multi-task learning; multi-task recommendation

推荐系统(recommendation system, RS)是一种根据物品隐藏模式将不同类型的物品与用户进行个性化匹配的技术^[1]。在短视频、电商、新闻等各种应用场景中,个性化匹配和推荐使用户能够快速发现感兴趣的内容,从而提升用户的在线体验。推荐任务通常可归类为评分预测和生成两种类型。其中,评分预测是一个回归或分类问题,通过用户对物品的评分信息来预测用户对其他物品执行某个操作的可能性。然而,这种方法存在数据稀疏性、冷启动和缺乏上下文等固有限制。生成任务直接生成符合用户兴趣和需求的推荐结果。但存在有限的内容覆盖范围、可扩展性问题和依赖大规模数据集等问题。评分预测和生成等单任务学习(single-task learning, STL)^[2]推荐系统的不足严重影响了推荐性能。此外,RS应具备同时进行多种推荐任务的能力,以满足用户个性化和多样化的需求。如电子商务场景中,用户对单个商品可能进行点击、收藏以及添加购物车等多行为。

为了克服单任务推荐系统的局限性,研究人员将注意力转向了多任务推荐系统(multi-task recommendation system, MTRS)^[3]。MTRS是一种能够同时处理和优化多个相关或独立推荐任务的系统,旨在通过共享特征和优化目标来提高整体推荐性能。对比单任务推荐系统,MTRS可通过任务之间知识共享实现数据增强,此外,还具有特征识别、计算和存储等优势。可提供更准确、更多样化和上下文感知的推荐,有助于提升用户参与度和满意度。然而,MTRS的研究也面临一系列挑战,如对任务之间的相关性比较敏感,必须有效地捕获有用信息和跨任务操作的顺序依赖性等。因此有必要设计新的共享方式,以适应MTRS的应用和发展。

MTRS的研究和应用已非常广泛,但相关方向的综述却极少。本文主要从多任务学习(multi-task learning, MTL)的原理和优势作为切入点,在MTL近些年相关研究进行归纳总结的基础上,从不同共享模式和任务关系的角度对MTRS的研究进展进行了分析总结。此外,对常用数据集以及评价指标进行了整理,并探讨了MTRS未来可研究方向。

1 多任务推荐算法

1.1 多任务推荐算法的实现

MTRS的主要实现步骤是:(1)任务选择。根据问题域和数据域选择相关性高、能够相互促进整体性能提升的推荐任务,这涉及到识别与推荐问题相关并可从共享表示中受益的任务。(2)模型设计。主要包括共享模式和任务专属部分的构建,使模型能够适应多个推荐任务。(3)联合优化。MTRS的优化方法涉及如何联合优化多个推荐任务的目标函数,通常采用端到端联合优化或交替优化策略。

为了有效提升MTRS的性能,实现过程需要遵循五项基本原则:(1)考虑任务之间相关性。MTRS通常假设不同推荐任务之间存在某种形式的关联性,这种关联性可以促进跨多个任务的信息共享和传输效率。(2)整合特定任务信息。每个任务可能具有特定的数据分布、任务特征和目标,加入特定任务信息有助于捕获任务特定要求,使模型更加灵活且能够为每个任务提供个性化推荐。(3)设计灵活的信息共享机制。MTL的有效性基于一个前提,即各个任务能够从共享的信息中获益。因此,需设计合适且高效的共享机制,使得模型能适应特定任务的差异性和不断变化的任务或领域。(4)保持任务平衡。不同任务之间可能存在不同的优先级、目标和要求,需要设计如多目标优化、特定于任务的加权或动态正则化策略来保持冲突目标之间的平衡,避免某些任务被过度偏好而影响整体性能。(5)处理异构数据。MTRS可能涉及不同类型、规模或分布的数据。为了应对数据异构性,需设计相应的技术,如域适应、特定于域的正则化或数据扩充等,以确保跨任务的鲁棒性和有效的推荐性能。

1.2 多任务学习的优势

MTL本质上是迁移学习的一种,目的是通过任务之间的共享和互补学习来提高模型的泛化能力和效率^[4]。MTL在机器学习和深度学习领域中具有多方面的优势:(1)数据增强。缓解数据稀疏问题是MTL最显著的作用之一。MTRS可通过跨多个任务数据共享、知识转移、联合建模、结合辅助信息等方式潜在地解决RS面临的数据稀疏问题。(2)特征互

补。不同任务可能涉及到不同的特征或信息, MTL 可以通过共享模型参数, 将在一个任务中学到的知识和特征转移至其他相关任务, 从而提升这些任务的表征学习能力^[5]。(3)特征识别。当任务之间关系复杂或数据稀疏时, 模型难以区分特征之间的重要程度, 而 MTL 可以利用其他任务对特征的识别作为先验知识, 帮助模型更好地识别并获取关键特征, 从而改善模型整体性能。这实际上是对其他任务进行一种约束。(4)正则化效应。任务之间噪声形式可能存在差异, 而 MTL 采取联合训练机制, 使得模型可以通过平均噪声的方式得到表达能力更一般的特征表示, 从而提高模型的泛化能力和稳健性^[6]。尤其在资源有限、数据稀疏或任务之间有关联性的情况下表现出色。其优势吸引了许多研究者的关注, 逐渐诞生了 ESMM(entire space multi-task model)^[7]、MMOE (multi-gate mixture-of-experts)^[8]、PLE (progressive layered extraction)^[9]等经典多任务推荐算法。此外, 还被广泛运用在自然语言处理^[10]、计算机视觉^[11]、语音识别^[12]、生物信息学^[13]等领域。图 1 为 STL 和 MTL 训练机制对比。




图 1 两种学习范式训练机制对比

Fig.1 Comparison of training mechanisms for two learning paradigms

2 不同共享模式多任务推荐算法

2.1 硬共享模式的研究

硬共享是 MTL 中最基本和最常用的一种共享方

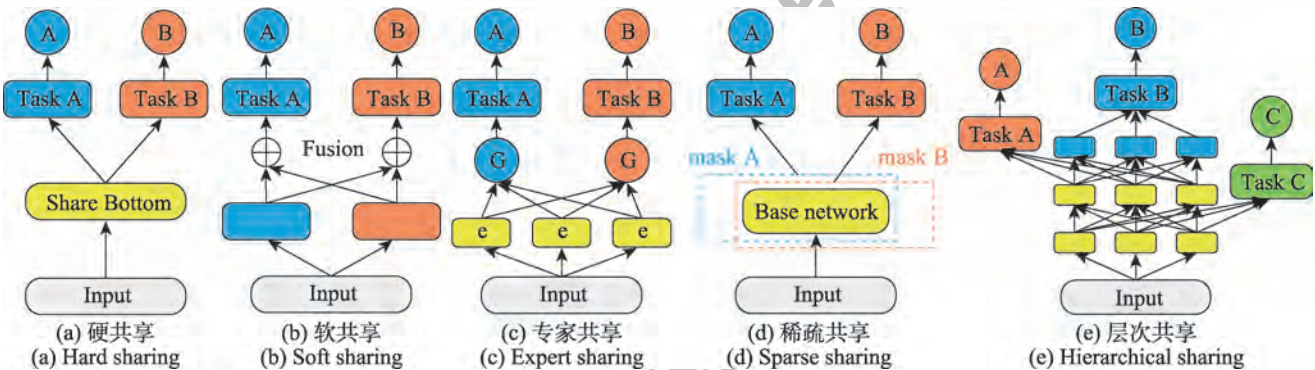


图 2 不同共享模式结构图

Fig.2 Structure diagram of different shared modes

式。任务之间共享相同的底层表示(如权重、特征), 而特定于任务的顶层进行单独训练和优化。它具有提升模型的泛化能力、减少过拟合和节省计算资源的优势, 但也存在任务相互干扰、对任务关系敏感和数据依赖等问题。其结构如图 2(a)所示。其中, 黄色矩形代表共享层, 橘色、绿色和浅蓝色分别代表特定任务层或掩码。

硬共享推荐算法的研究特别广泛, 而任务相关性是决定应用的主要因素。转化率(post-click conversion rate, CVR)的预测被广泛应用于电子商务、广告和金融等领域, 但过去的研究存在样本选择偏差和数据稀疏问题。为此, Ma 等人^[7]在 ESMM 模型中引入了与 CVR 相关性高的两个辅助任务: 点击率预测和点击&转化率预测。利用辅助任务丰富的数据和基于全空间样本数据训练的特点来解决问题。ESMM 在一定程度上解决了样本选择偏差问题, 但并没有从根本上解决数据稀疏问题。其结构如图 3 所示。与 ESMM 采用“浏览→点击→转化”的用户顺序行为路径不同的是, Wen 等人^[4]将用户点击后的动作分解, 得到新的用户行为路径: “浏览→点击→确定性动作(其他动作)→购买”。点击行为分解后带来了丰富数据, 此外, 对全空间下的浏览数据建模, 最终有效地解决了数据稀疏问题。但对分解后动作分别建模会引起误差。然而, 上述两种方法没有考虑点击和转化之间的延迟反馈问题。Wang 等人^[15]提出了一种名为 ESDF 的神经网络模型。先将延迟时间以天为单位进行离散化, 然后利用深度神经网络基于生存分析方法建立概率模型, 以逼近延迟过程。ESDF 模型有效地解决了延迟反馈问题, 并适用于工业场景。但是, 存在可扩展性和效率的问题, 可以探索模型修剪、量化或分布式计算等技术来降低计算复杂度和内存的使用。




图3 ESMM模型结构图

Fig.3 ESMM model structure diagram

最近,许多研究者试图从因果关系的角度来解决CVR预测中存在的问题。Zhang等人^[16]为了解决有偏估计问题,利用Multi-IPW(multi-task inverse propensity weighting estimator)来计算多个因果效应的加权平均值,从而减少有偏估计的影响,但其依赖于预测的准确性。而Multi-DR(multi-task doubly robust estimator)结合了Multi-IPW和计算预测误差的插补模型,通过对Multi-IPW和结果模型之间的差异进行修正,可以减少因模型估计误差而产生的有偏估计。而Wang等人^[17]为了解决固有估计偏差和潜在独立优先级问题,利用逆倾向得分(inverse propensity score, IPS)和双重稳健(doubly robust, DR)两种反事实风险最小化作为正则项,同时考虑两个问题。具体而言,将预测值和真实值之间的差异视为因果关系中的误差,并使用因果推断中的IPS来最小化误差。而DR基于IPS引入了预测误差,以解决IPS可能存在严重高方差问题。但该方法需要进行大量运算,计算和时间成本大。考虑到许多基于MTL方法或因果方法的CVR预测模型无法有效应对非随机性缺失的问题,Zhu等人^[18]提出的DCMT(direct entire-space causal multi-task framework)模型直接使用了因果关系和反事实机制。

用户顺序行为中的上下文依赖和多时间尺度两个关键特征常常被忽略。Jin等人^[19]对此提出了全空间层次循环排序网络(hierarchical recurrent ranking on the whole space, HEROES)。设计了一个分层框

架来分别对用户参与行为和满意行为进行建模,该体系结构可以为每一层学习合适的时间尺度以捕获用户的动态行为特征。并利用Hawkes过程形成一个循环单元来对物品上下文特征进行编码和对用户过去多行为进行激励或抑制。HEROES能有效地结合上下文信息为全空间行为路径学习时间尺度。信用卡申请中存在用户行为路径长和正反馈逐步稀疏的问题。Xi等人^[20]提出了AITM(adaptive information transfer multi-task)框架。主要利用一个自适应信息传输模块对转化之间的顺序依赖行为进行建模并控制信息传输的类型和数量,以实现对用户行为进行精确识别。但该框架没有考虑不同任务之间的时间依赖关系,这可能导致预测时出现偏差。Zhang等人^[21]提出的全局增强多任务模型解决了线上-线下场景中在线转移到离线预测过程中的全局优化问题。

上述方法中,除了文献[20]和文献[21]分别用于金融和外卖领域之外,其他算法主要用于电子商务中的CVR预测。此外,它们都根据用户顺序行为序列建模,并采用底层嵌入共享和全空间模型。总结如表1所示。

除了CVR预测之外,研究者还从其他角度考虑问题:(1)应用角度。Bansal等人^[22]利用深度神经网络将文本序列编码为潜在向量,将捕获的用户-项目交互的潜在模式进行共享,基于此提出了文本推荐模型。(2)参数角度。任务之间许多共享参数通常由一到两个任务控制,导致参数更新严重不平衡。Yang等人^[23]提出了一种自适应学习率方法,该方法将每个任务的学习率和参数的累计梯度实施分离以避免这些任务进行梯度累积。(3)共享效率角度。Liu等人^[24]提出了MFH(multi-faceted hierarchical)多任务模型,主要通过嵌套层次树结构中大量的多维任务关系来进行最大化共享学习,从宏观的角度提升共享效率。而Lin等人^[25]提出了一种基于对比学习的自适应细粒度任务相关性学习方法,可以有效地跨多任务传递知识。

针对以上硬共享推荐算法的性能统计如表2所示(统计数据来源于原文,统计了在两个不同数据集上的实验结果,它们均从淘宝网收集,区别在于收集时间和规模有差异)。以上研究表明,针对硬共享推荐算法的研究主要围绕两方面进行:一方面通过各种策略或结构进行共享特征的语义提取,比如在共享层使用对比学习、嵌套层次结构、注意力机制等进行细粒度特征提取,获取更丰富的共享语义信息;另一方面是将相关任务进行级联,使得不同任务之间

表1 硬共享模型优势及局限性

Table 1 Advantages and limitations of hard sharing models

模型	应用领域	用户行为路径	优势	局限性
ESMM ^[7]	电子商务	浏览→点击→转化	可缓解样本选择偏差和训练数据稀疏的问题	训练样本集的分布与实际数据分布存在偏差
ESM ² ^[14]	电子商务	浏览→点击→确定性动作(其他)→购买	能够更好地利用用户行为信息	模型复杂度较高,训练时间较长
ESDF ^[15]	电子商务	浏览→点击→购买	具有较强的鲁棒性和预测能力	需对时间序列分解和因子提取,计算复杂度高
Multi-IPW Multi-DR ^[16]	电子商务	浏览→点击→购买	可有效地发现和um处理混淆变量,避免偏差出现	当权重偏差较大时,会导致结果的方差增大
ESCM ² ^[17]	电子商务	浏览→点击→购买	可解决固有估计偏差和潜在独立优先级问题	需大量训练数据,否则容易导致欠拟合问题
DCMT ^[18]	电子商务	浏览→点击(非点击)→购买	利用因果推断可消除偏差;利用全局损失优化可寻找更优解决方案	作为一个深度学习模型,可解释性较差,计算复杂
HEROES ^[19]	电子商务	观察→点击→购买	可捕获用户动态行为模式	在循环中加入了Hawkes,导致模型训练非常耗时
AITM ^[20]	金融领域	浏览→点击→申请→审核→激活	可捕获用户转化行为和解决正反馈逐步稀疏问题	模型没有考虑用户行为的时间依赖关系
ECMM ^[21]	外卖领域	浏览→点击→在线订单→离线运输	利用全局优化方法可提高在线和离线CVR预测的精度和稳定性	采用转换和滑动窗口两种注意力机制,模型比较复杂,计算量大

表2 硬共享模型在真实数据集上的性能表现

Table 2 Performance of hard sharing models on real datasets

模型	发表时间	数据集	AUC/%		
			转化率	点击率	点击&转化率
ESMM ^[7]	2018	Ali-CCP	68.56±0.37		65.32±0.49
Multi-IPW ^[16]	2020	Ali-CCP	69.21±0.42		65.30±0.50
Multi-DR ^[16]	2020	Ali-CCP	69.29±0.31		65.43±0.34
AITM ^[20]	2021	Ali-CCP	65.25±0.24	60.43±0.16	
ESCM ² -IPS ^[17]	2022	Ali-CCP	61.63±1.51		61.89
ESCM ² -DR ^[17]	2022	Ali-CCP	61.42±1.33		82.65
ESDF ^[15]	2020	Ali-CCP	78.11		
ESM ² ^[14]	2020	Taobao E-Commerce	84.86		83.71
HEROES ^[19]	2022	Taobao E-Commerce	75.03	59.53	
DCMT ^[18]	2023	Ali-CCP	64.86		64.31
AdaFTR ^[25]	2022	Ali-CCP	61.89		61.93

的计算具有顺序依赖性,模型可以利用其他任务的输出来帮助目标任务训练。

2.2 软共享模式的研究

与硬共享强调完全共享不同,软共享分别为每个任务建立模型,但任务之间可通过对底层特征或参数进行加权共享来实现知识迁移。软共享允许任务之间存在更多的灵活性,以便在保留共享信息的同时,更好地适应每个任务的特定性。然而,它的参数空间大以及使用率低,需要较多的计算资源。其结构如图2(b)所示。

十字绣网络(cross-stitch networks)^[26]和水闸网络(slucice networks)^[27]是经典的软共享模型,比硬共享更灵活。但都使用静态线性权重来融合不同网络的

特征表示,无法有效地捕获任务之间的共性与差异性。为了实现可解释推荐,Chen等人^[28]提出了协同注意多任务学习模型(co-attentive multi-task learning, CAML)。首先,利用分层多指针注意力机制来筛选作为评分预测和解释任务的交叉共享信息。然后,利用因子分解机和门控循环单元分别进行评分预测和生成解释。但CAML采用共享注意力机制来学习用户的多个历史交互,没有考虑不同交互行为之间的相关性,可能会导致过拟合。Xin等人^[29]针对电子商务平台的在线促销模式需要根据应用场景不同而变化的需求提出了一种在线促销物品的网络模型。该模型将用户动态配置文件作为控制器并输入至由目标用户控制的门控循环单元中,目的是生成基于

共享的高效项目特征表示。然后将动态和静态特征融合并传递至基于RNN(recurrent neural network)的注意力机制中,从静态属性和动态时间序列中发现知识。该模型无需重新训练便可在不同应用场景中扩展应用。但是模型具有多个隐藏层,导致参数量较大。为了解决MTL依赖于任务相关联且对特定任务的信息学习不充足的问题,Chen等人^[30]结合剪枝技术和软共享的思想,提出了PBFS(pruning-based feature sharing)模型。利用剪枝技术分别为每个任务进行特征提取,显著提高信息共享效率的同时不受任务相关性影响。但该模型只考虑了任务之间的相似性而忽略了差异性,导致模型可扩展性差。表3对软共享研究模型的应用场景和优缺点进行了总结。

2.3 专家共享模式的研究

专家共享利用专家模块为多个任务提供特定知识,然后通过门控网络为每个任务筛选特定信息。专家共享对缓解负迁移问题具有一定的帮助,但只是软共享模式的一种特殊情况,因为专家网络还是基于共享,只是针对每个特定任务赋予了不同权重。结构如图2(c)所示。

受专家混合模型^[31]的启发, Ma等人^[8]提出MMOE中,每个任务可利用自己的门控网络对基于共享的专家网络进行加权组合,以生成任务特定信息。而专家权重是从输入数据中动态学习得到的,因此,能够更好地捕获任务之间的共性和差异性。但MMOE模型设计时主要考虑了两个任务的情况,当扩展到更多任务时会变得很复杂,此外,还缺乏对长期依赖的建模。其结构如图4所示。Zhao等人^[32]在MMOE模型中引入了Wide & Deep侧网络,可接受有偏输入数据并将生成的标量值作为主模型的偏置项,以消除有偏数据带来的选择偏差问题。为了进一步提升MMOE模型的性能, Ma等人^[33]提出了子网路由(sub-network routing, SNR)机制。首先,将底部共享网络模块化为多层并行的子网络,用于学习更通用的联

合表示以促进模型的可训练性。其次,设计了两种稀疏子网连接路由来代替门控网络,使模型可进行更高效和更灵活的信息共享。但SNR采用静态连接方式难以识别样本依赖性,且需要L0正则化来控制参数稀疏性。上述MMOE模型及其变体存在两个问题:第一,对各专家一视同仁,没有考虑任务的特定性;第二,专家之间没有信息交互,限制了模型的联合优化能力。基于此, Tang等人^[9]提出的PLE模型明确地将底部共享网络划分为共享专家和特定任务专家模块,用以规避有害信息的影响。此外,设计了多层提取网络和渐进分离机制,逐步分离特定任务参数以实现复杂任务关系的有效信息共享。PLE模型有效解决了MTL中常见的跷跷板现象,但采取多层网络可能导致过拟合、收敛性能不稳定的情况。Xu等人^[34]提出了MVKE(mixture of virtual-kernel experts)多任务模型。该模型利用虚拟内核专家针对用户特定方面的偏好进行建模,然后使用虚拟内核门将特定任务层进行关联以进行信息融合。该模型可有效提升推荐性能,但需要大量的计算资源。Wu等人^[35]为了解决产品搜索过程中查询和产品之间词汇不匹配的问题,提出了一个新颖的端到端MTL产品搜索

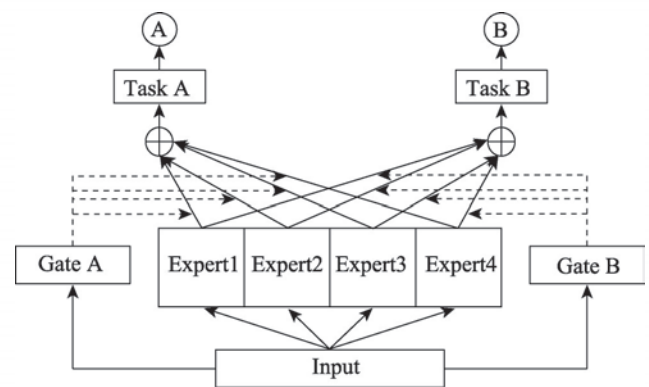


图4 MMOE模型结构图

Fig.4 MMOE model structure diagram

表3 软共享模型优势及局限性

Table 3 Advantages and limitations of soft sharing models

模型	发表时间	应用场景	优势	局限性
Cross-Stitch ^[26]	2016	通用模型	可学习共享知识和任务特定知识的最佳组合	依赖于任务特征,特征过多时容易出现过拟合现象
Sluice ^[27]	2017	通用模型	可有效地处理任务松散相关问题	需手动设计水闸层的大小和位置
CAML ^[28]	2019	可解释推荐	可提高推荐准确性并提供可靠解释	依赖于任务相关性,任务权重分配难
DINOP ^[29]	2019	在线商品推荐	可明确地指出哪些特征对促销效果的影响最大	依赖于序列数据;参数量大,使得模型难以优化
PBFS ^[30]	2022	通用模型	每个任务可动态地选择共享参数,能有效避免任务冲突问题	剪枝操作计算复杂度高;忽略了任务之间的差异性,模型难以扩展

框架。主要利用具有微调功能的特定领域 BERT (bidirectional encoder representations from transformers) 来弥合词汇量差距以进行产品排名。

上述模型是基于非序列化数据建模,然而,现实很多应用场景中的输入数据都是序列化或异构化的。Qin 等人^[36]提出了 MoSE (mixture of sequential experts) 模型,该模型使用长短时记忆网络 (long short-term memory, LSTM) 代替 MMOE 底层和塔层网络中的前馈神经网络,以对序列数据进行显式建模,而混合专家模块可对不同数据源分别进行特征提取。但该模型可解释性较差且泛化能力不足。Wu^[37]提出的多级网络级联模型可分别从任务层面和专家层面自适应地对传递信息进行充分学习,能更有效地对任务之间的顺序依赖关系建模。

MTRS 的性能对任务之间的关系比较敏感,平衡任务关系也是一大研究难点。Xin 等人^[38]将从各个任务中提取到的融合特征作为原型特征引入 MMOE 模型,能有效地学习任务之间的关系,避免了任务之间产生冲突。Tao 等人^[39]表示为每个任务学习对应细粒度特征表示是解决任务之间关系敏感问题的有效方案,因此,提出了 APEM (adaptive pattern extraction multi-task) 多任务框架。通过注意力机制和 Squeeze-and-Excitation 操作来增强特征表达能力,而显式模式选择器基于任务指示向量可自适应地为特定任务选择特征表示。但该模型复杂度高,且收敛速度慢。相比之下, Li 等人^[40]提出的自适应 Task-to-Task 融合网络利用残差网络和门控网络能更有效地为每个任务选择细粒度特征表示。表 4 对专家共享研究模型的应用场景和优缺点进行了总结。

2.4 稀疏共享模式的研究

稀疏共享没有额外的参数空间,而是利用独立参数掩码从基于共享的超参数基网络中为每个任务学习子网。通过这种稀疏约束来限制共享参数的数量,以便在保留任务特定信息的同时,减少过拟合风险。它是硬共享的一种特例,因为是在神经元或层级上进行参数共享。结构如图 2(d) 所示。

硬共享、软共享和专家共享等模式完全共享或按比例共享全部特征,仍然保留了大量共享空间,任务之间容易相互干扰而引起负迁移。为此, Sun 等人^[41]提出了一种可以自动地找到稀疏共享结构的方法。而 Xiao 等人^[42]设计了一种神经元级稀疏掩码,可自动地从超参数空间为每个任务选取更细粒度特征。解决了 CVR 预测中粗粒度共享子网络容易引入冲突而导致推荐模型性能下降的问题。但该模型存在收敛速度慢且对噪声数据敏感的问题。

许多研究者致力于寻找一种更高效的信息共享方法。Ding 等人^[43]提出了两种稀疏连接方法:一种作用在特征层面,在输入层采用稀疏掩码为各个任务选择重要的特征字段组合,以获取更一般的稀疏共享特征表示,这有利于提高模型的泛化能力;另一种作用在隐层层,将一个转换矩阵和二进制编码变量相乘,其结果作为稀疏连接机制来进行子网选择。但所提出的模型并没有进行在线实验,实用性需进一步验证。而 Chen 等人^[44]提出了多任务神经架构搜索 (multi-task neural architecture search, MTNAS) 框架。该框架融合了专家和稀疏共享的思想,将共享部分划分为多层子网络,子网之间采用稀疏连接的方式。与 SNR 静态稀疏子网连接路由不同, MTNAS

表 4 专家共享模型优势及局限性

Table 4 Advantages and limitations of expert sharing models

模型	发表时间	应用场景	优势	局限性
MMOE ^[8]	2018	各种推荐场景	可学习特征交互关系和处理稀疏数据;灵活性和扩展性强	训练复杂度高,可解释性差,依赖大量训练数据
SNR ^[33]	2019	视频推荐	对任务之间的关系不敏感;能够学习任务相关性	使用静态连接方式,难以发现样本依赖性
PLE ^[9]	2020	各种推荐场景	有效地消除了跷跷板现象	对长序列数据处理困难;特征提取过程较为复杂
PFE ^[38]	2022	短视频推荐	可平衡任务特定目标和任务间关系;降低任务间关系敏感性	模型采取并行化计算,计算量大,对硬件要求高
MVKE ^[34]	2022	广告推荐	可进行高效信息融合	需要大量 GPU 计算资源
MoSE ^[36]	2020	邮箱推荐	可有效地处理序列数据、稀疏数据和异构数据	模型可解释性差和泛化能力不足
MNCM ^[37]	2022	电商推荐	可有效地捕获任务之间的顺序依赖关系	采用多层神经网络和级联网络导致模型计算量和参数量较大
APEM ^[39]	2023	金融推荐	可有效解决因任务相关性而导致的负迁移问题	模型复杂度高,收敛速度慢
AdaTT ^[40]	2023	视频推荐	可自适应地学习共享知识和任务特定知识;可扩展性强	模型需要进行复杂的任务权重计算和特征提取

通过神经架构搜索技术可自动地学习子网连接路由。但是,该框架的搜索空间考虑子网的所有连接可能,时间复杂度较大。

针对稀疏共享中子网并行或独立训练存在参数优化冲突问题,Bai等人^[45]提出了对比共享推荐模型(contrastive sharing recommendation model, CSRec)。主要利用一个对比参数掩码来评估参数对任务的重要程度,冲突参数由受参数影响更大的任务进行优化,使模型能够自适应地优化冲突参数。

2.5 层次共享模式的研究

层次共享模式中不同任务被置于不同层,任务之间只能共享一部分参数空间,而特定于任务的参数空间给处理复杂或异构任务留下了选择。这种方法可以在不同层次上平衡任务之间的共享度。但是,设计一个高效的层次结构依赖于专家经验且极其耗时。其结构如图2(e)所示。

基于兴趣点推荐的研究通常存在用户-兴趣点矩阵高度稀疏的问题,严重限制了模型的学习和表达能力。据此,Lim等人^[46]提出了分层多任务图循环神经网络(hierarchical multi-task graph recurrent network, HMT-GRN)。其中,图循环神经网络用于学习兴趣点的顺序依赖关系和兴趣点-兴趣点的全局时空图,以生成基于共享的通用特征表示。而分层MTL模块对用户-兴趣点和用户-区域进行联合建模,并将不同细粒度的任务置于不同层,采用层次结构训练各个任务。训练过程中使用HBS(hierarchical beam search)方法来逐步地缩小兴趣点和区域的搜索空间,以提升推荐效率。但该模型的并行计算能力有限,无法处理大规模数据集。Wen等人^[47]发现用户与项目详情页面特定组件的交互行为可以作为补充CVR预测的细粒度线索,并提出了一个对用户微观和宏观行为进行分层建模的多任务模型。该模型可以丰富CVR预测的监督标签,从而提升预测性能。

2.6 其他共享模式的研究

除了上述五种共享模式之外,在MTRS中较常见的还有元共享和梯度共享。

元共享模式通过元学习(meta-learning)^[48]框架在多个任务间学习一个通用的元模型,该模型可以快速适应新任务,从而实现任务之间的知识共享。共享知识是在训练过程中学习和调整的,对每个任务的特定要求和约束具有更大的灵活性和适应性。这种方式利用了任务之间的结构相似性,而不是直接共享表示。

Yang等人^[49]提出的TAML(task-agnostic meta-learning)模型是典型的元共享模式。该模型侧重于

学习可以针对新任务快速微调的初始化元模型。在训练过程中,模型会暴露在各种任务中,并更新其参数以快速适应新任务。这在少样本学习场景中非常有效。

梯度共享模式不直接共享底层表示,而是在每个任务梯度更新阶段利用其他任务的梯度信息来实现任务间的知识转移。这种方法可以在不显式共享表示的情况下利用任务之间的相关性。

引入辅助任务来帮助目标任务训练是MTL中常用的方式,但通常面临两个问题:第一,辅助任务太强则会控制整个网络权重;第二,辅助任务太弱则无法提供有效帮助。He等人^[50]对此提出了MetaBalance模型,辅助任务梯度大小将依据目标任务梯度大小进行动态变化,二者基于共享参数的子集进行自适应平衡。此外,设计了一个松弛因子来控制辅助任务梯度的变化量,有助于模型适用于不同场景。但是,辅助任务的梯度完全由目标任务提供,这会导致辅助任务的梯度在不同任务之间传递时出现偏差。而Lee和Son将基于梯度的元学习方法应用于MTL,并在共享层进行单梯度步长更新和内/外循环训练,从梯度级别减轻任务之间不平衡问题^[51]。许多研究者将负迁移问题归结为由参数优化冲突时任务间梯度大小和方向差异引起的,并采取均化梯度大小或贪婪地改变梯度方向措施。这忽略了新冲突可能出现的情况。Javaloy和Valera提出的RotoGrad算法联合均匀化梯度大小和方向,可从整体上解决负迁移问题^[52]。

注意,前五种共享模式主要从结构设计的角度来提升共享效率。而元共享从学习策略的角度、梯度共享从梯度的角度来考虑问题,二者没有具体的模型结构,通常会和其他共享模式相结合,共同提升模型的学习效率,解决数据稀疏和参数冲突等问题。表5对层次共享、稀疏共享、梯度共享和元共享的研究模型的优势及局限性进行了对比总结。

从以上的研究可以看出,硬共享和专家共享仍然是研究和应用的热点。硬共享适用于任务相关性较高且负迁移风险小的情形,而专家共享在任务需要不同特征或具有不同类型输出时,可利用专家网络专注于整个需求的特定方面或者子任务,从而对每个任务进行更细粒度的控制。软共享适用场景是:当任务之间存在一定程度的相关性,但又有各自的特异性。但是,需要在灵活性和效率之间进行权衡。稀疏共享中大部分任务是不相关的,主要为各个任务进行特征选择,从而在共享稀疏特征的基础上提高推荐性能。层次共享在RS系统中的应用较少,第一,大部分推荐场景中,所涉及的任务并不是

表5 几种共享模式研究模型的优势及局限性

Table 5 Advantages and limitations of several shared mode research models

分类	模型	发表时间	应用场景	优势	局限性
层次共享	HMT-GRN ^[46]	2022	兴趣点推荐	可有效解决数据稀疏问题	并行计算能力有限,无法处理大规模数据;依赖于序列数据
	HM ^[47]	2021	电商推荐	有效地捕获用户行为之间的复杂关系;解释性和泛化能力强	模型训练依赖于微观和宏观行为的高质量标签
稀疏共享	NCS4CVR ^[42]	2020	视频推荐	可自动地学习共享神经元权重,提升共享效率;可减少任务冲突问题	模型收敛速度较慢;对噪声数据较敏感
	MSSM ^[43]	2021	各种推荐场景	可共享更细粒度的信息和自适应地控制模型稀疏程度	多层结构导致训练时间和成本大;静态连接方式不够灵活
	MTNAS ^[44]	2021	各种推荐场景	可快速找到最佳共享网络结构和任务路由策略	NAS 技术训练非常耗时,且搜索空间考虑了所有连接可能,模型时间复杂度大
	CSRec ^[45]	2022	在线信息推荐	可有效地解决参数优化冲突问题	对比学习方式需要更多计算资源和时间
元共享	TAML ^[49]	2019	个性化推荐	利用元特征和元知识可提高模型泛化能力和性能	依赖大量训练数据来学习推荐策略;易陷入局部最优解
梯度共享	MetaBalance ^[50]	2022	各种推荐场景	可减少任务梯度干扰;可进行动态梯度调整用于不同场景	辅助任务梯度完全由主任务决定,容易产生偏差
	RotoGrad ^[52]	2021		模型解决了任务之间的梯度差异性;可适应不同的数据分布	梯度均化需选择合适的正则化参数,这在实践中具有挑战性

自然地按层次结构组织的;第二,层次结构增加了建模过程的复杂性和扩展性;第三,层次结构依赖于标记数据。元共享和梯度共享较为特殊,通常和其他五种共享模式相结合来提升推荐性能。总而言之,不同共享模式都使用了一定程度的共享信息和归纳偏差来提高跨多个任务的性能。但区别在于它们共享的方式、程度、层次和内容,如可共享参数、梯度或模型的其他方面。选择合适的多任务推荐算法取决于任务之间的关联性、数据的分布以及应用场景的需求。

2.7 任务关系

在MTRS中,任务之间存在潜在的相似性、差异性、关联性和竞争性等固有特性。针对任务之间的不同特性需设计合适的共享策略,否则,容易导致负迁移现象。因此,任务之间就形成了不同的关系:(1)并行。各个任务计算过程中没有明确的交互行为或依赖关系,每个任务被视为一个单独的问题。但模型可在任务之间共享一些共同的表示或特征。目标函数通常以同等加权组合方式来计算整体损失,并对所有任务进行联合优化。(2)级联。任务之间存在数据相关性,即一个任务的学习结果可以对其他任务的学习产生影响,通常任务之间具有顺序依赖关系。(3)辅助与主任务。将目标任务指定为主任务,而其他相关任务被视为辅助任务,主要用于提供额外信息或正则化以帮助提高主任务的性能。(4)层次。任务之间以分层方式共享参数或特征,底

层表示通常用于表示通用知识,而高层表示用于表示任务特定知识。高层任务可为低层任务提供知识或约束以指导其学习。

对上述不同共享模式的研究模型中任务关系进行了归纳总结,如图5所示。不同形状表示关系不同,而颜色代表共享方式。由此可知,任务之间主要以级联和并行关系存在。一方面,相关性高的任务可通过输出共享和共同训练来提升模型泛化能力和效率;另一方面,MTL对任务关系敏感,为了避免相互干扰,对具有不同目标或相关性低的任务进行独立运行。部分模型中任务之间具有混合关系,如ESDF^[15]、Multi-IPW^[16]和Multi-DR^[16]。而文献[24,34-35,52]中任务之间只进行知识共享,而没有形成特定的关系。

3 MTRS常用数据集和评测指标

3.1 常用数据集

MTRS是RS研究中的一种特殊类型,通常会使用包含多种类型数据的数据集(如用户评分数据、标签数据、描述信息等),以同时解决多个推荐任务。而其他类型RS一般只考虑用户评分数据或描述数据等单一类型的数据。但MTRS和其他类型RS一般可使用相同的数据集,因为常用推荐数据集一般包含了多种类型的数据源,这些数据源能在不同推荐任务中被使用。本节依据推荐场景的不同,对常用的公开数据集进行介绍。统计信息如表6所示。

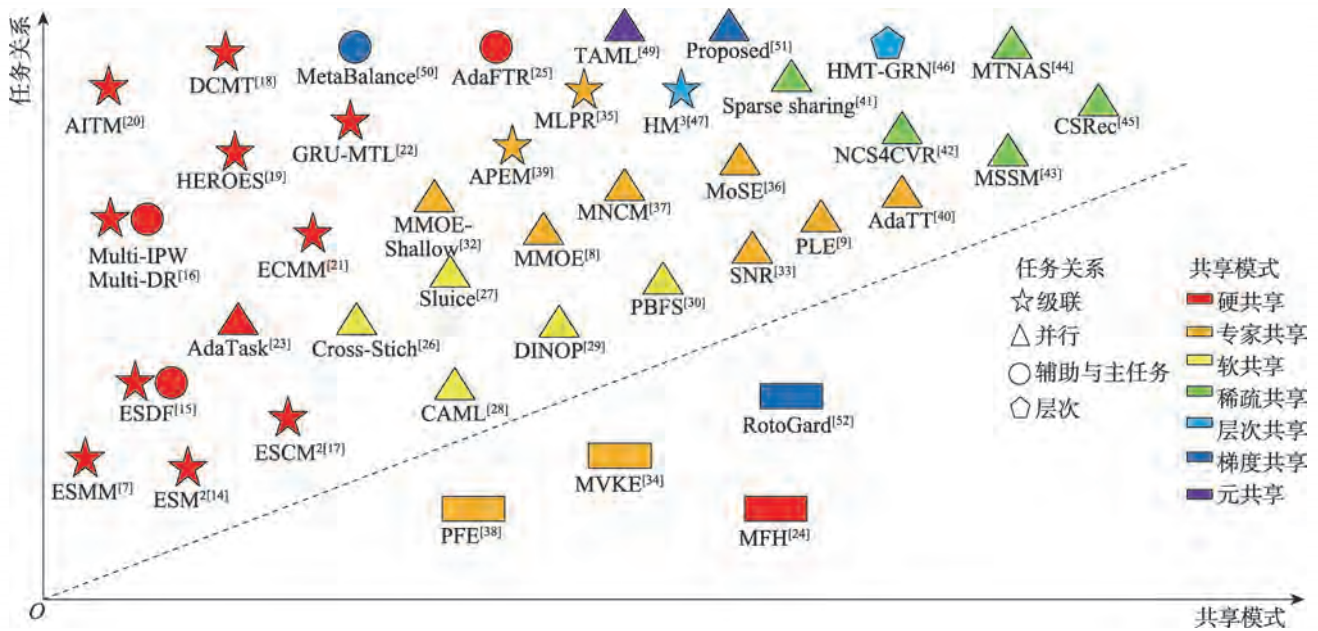


图5 任务关系

Fig.5 Task relationships

表6 数据集统计信息

Table 6 Statistics of datasets

数据集	用户量	项目量	交互量	语言	年份
Amazon	20 980 000	9 350 000	30 330 000	英文	2016
Ali-CCP	32 000 000	3 000 000	400 000 000	中文	2018
MovieLens 1M	6 040	3 952	1 000 209	英文	2003
MovieLens 10M	71 567	10 681	10 000 054	英文	2009
MovieLens 20M	138 493	27 278	20 000 263	英文	2016
Weibo	12 814	126 830	171 268	中文	2017
KGRec-music	5 199	8 640	751 531	英文	2016
LFM-1b	120 322	3 123 496	1 088 161 692	英文	2016
Steam	2 567 538	32 135	7 793 069	英文	2018
Yelp2018	1 326 101	174 567	5 261 669	英文	2018

电商: Amazon产品数据集^[53]包含了大量用户和产品信息,常用于隐式反馈推荐、产品推荐和用户情感分析。Ali-CCP数据集^[7]收集于淘宝移动客户端的推荐系统日志,包含了23个特征域和2个标签域,主要用于点击和与之关联的转化预测。

电影: MovieLens^[54]是一个广泛使用的电影评分数据集,目前常用的有3个版本MovieLens 1M、MovieLens 10M和MovieLens 20M。包括用户对电影的评分、电影的元数据(如类型、导演、演员等)和用户个人信息(如年龄、性别、职业等)。

社交: Weibo数据集^[55]包含了微博、名人、情感3个异构网络,常用于分析用户情感从而进行个性化推荐。

音乐: KGRec-music数据集^[56]携带了大量项目标

签数据。而LFM-1b数据集^[57]是从全球最大在线音乐网站Last.fm中归纳整理得到的,包括了用户、艺术家、歌曲、专辑等信息。

游戏: Steam数据集^[58]是从全球最受欢迎的PC游戏网站Steam中收集得到的,包含了用户对游戏的评论、游戏时间、游戏信息等。

文本: Yelp2018数据集^[59]是从美国最大在线饮食服务平台Yelp收集整理的,该数据集将酒吧和餐馆等本地企业视为物品。

3.2 评估指标

MTRS通过各种推荐算法为用户生成个性化推荐列表,系统使用多种评估指标对算法的性能进行度量和评估,以此来反映算法的可靠性和有效性。对模型进行评估也是推荐工作中的最后一个环节。

需要注意的是,无论 MTRS 还是其他类型 RS,常用的评估指标都是类似的。这些指标主要用于评估推荐项目的相关性和顺序等方面的性能。但在实际应用中,MTRS 有时还需考虑任务之间的平衡性和资源分配问题。通常使用任务相关性或任务优先级等指标来衡量任务之间的关联性和重要性。此外,使用效率或资源利用率等指标评估资源分配效率。常用的评估指标有以下几种:

准确率(Precision):表示 MTRS 预测为正例的样本中,事实上也是正例的样本所占的比例。其值越高,表示推荐的项目越相关。计算公式为:

$$precision = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |R(u)|} \quad (1)$$

其中, U 表示用户集合; $R(u)$ 表示系统为用户 u 生成的推荐列表; $T(u)$ 表示用户 u 的真实偏好列表。

召回率(Recall):表示实际上是正例的样本中,被推荐系统预测为正例的样本所占的比例。其值越高,表示 RS 发现相关项目的能力越强。计算公式为:

$$recall = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |T(u)|} \quad (2)$$

F_1 值:准确率和召回率都关注于某一方面性能的提升,无法做到统筹兼顾,而 F_1 指标可对准确率和召回率进行平衡,同时反映推荐项目的相关性和 RS 发现相关项目的能力。 $t > 1$ 表示模型侧重于召回率, $t < 1$ 表示模型侧重于准确率。计算公式为:

$$F_1 = (1 + t^2) \times \frac{precision \times recall}{precision + recall} \quad (3)$$

AUC(area under curve)^[60]:主要用于衡量模型对正负样本的分类能力,适用于二分类问题。其值越

高,表明 RS 对正负样本的分类能力越强,推荐结果就越符合用户的兴趣。计算公式为:

$$AUC = \int_0^1 TPR(FPR^{-1}(x))dx \quad (4)$$

$$TPR = \frac{TP}{TP + FN} \quad (5)$$

$$FPR = \frac{FP}{FP + TN} \quad (6)$$

其中, TP 表示真正例; FN 表示假负例; FP 表示假正例; TN 表示真负例; TPR 和 FPR 表示分类模型的真阳性率和假阳性率, $FPR^{-1}(x)$ 表示 FPR 逆函数。

GAUC(group AUC)^[61]:该指标的计算是在 AUC 的基础上进行的,它将用户分组,并计算每个用户组内所有任务的平均 AUC 值。主要用于评估多个任务之间的推荐结果相对优劣。计算公式为:

$$GAUC = \frac{1}{|U|} \sum_{u \in U} \frac{1}{|T(u)|} \sum_{t \in T(u)} AUC_t(u) \quad (7)$$

其中, $AUC_t(u)$ 表示用户 u 在项目 t 上的 AUC 值。

MSE(mean squared error)用于衡量预测值和真实值的偏差大小,对异常值极其敏感。其值越小,表示模型预测能力越高。计算公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\tilde{r}_i - r_i)^2 \quad (8)$$

其中, n 表示预测值和对应真实值的数量, \tilde{r}_i 和 r_i 分别表示第 i 个预测值和真实值。

本文对几种代表算法所采用的指标进行了列举。此外,为了更全面地了解算法的性能,根据论文中的描述和公式对时空复杂度进行了总结,如表 7 所示。可知 AUC 指标应用最为广泛,因为在 Top- N 排序推荐背景下,它可以表示随机正例排名高于负例的概率,反映模型在所有阈值下的平均排序能力。当然,为了更全面地度量模型性能,通常需要和其他评估指标结合使用。

表 7 部分代表模型评价指标

Table 7 Evaluation metrics for some representative models

代表模型	precision	recall	F_1	AUC	GAUC	MSE	发表会议/期刊	发表年份	时间复杂度	空间复杂度
ESMM ^[7]				√	√		SIGIR	2018	$O(nk+nm)$	$O(n+m)$
ESCM ^[217]		√	√	√			SIGIR	2022	$O(nk+nm)$	$O(n+m)$
MMOE ^[8]				√			KDD	2018	$O(nkd+nm d)$	$O(kd+md)$
PLE ^[9]				√			RecSys	2020	$O(nLd)$	$O(Ld)$
ESM ^[14]	√	√	√	√			SIGIR	2020	$O(nk+nm)$	$O(n+m)$
AITM ^[20]				√			KDD	2021	$O(nST)$	$O(ST)$
DCMT ^[18]				√			arXiv	2023	$O(nk+nm)$	$O(n+m)$
MoSE ^[36]						√	KDD	2020	$O(nkd+nm d)$	$O(kd+md)$
MSSM ^[43]				√			SIGIR	2021	$O(nS_1S_2d)$	$O(S_1S_2d)$
DINOP ^[29]				√			CIKM	2019	$O(nLd)$	$O(Ld)$

注: n 表示训练样本数量, k 表示任务数量, m 表示特征数量, d 表示隐藏层神经元数量, L 表示层数, S_1 和 S_2 分别表示第一层和第二层的稀疏性参数, T 表示时间步长。

4 未来研究方向

近年来,MTL的研究给推荐系统带来了极大的发展机遇,但同时也面临很多技术难题。比如,因任务相关性引发的负迁移、参数冲突、可解释性问题等。下面将概述4个MTRS未来有潜力的研究方向:

(1)MTL推荐模型的可解释性:过去很多工作致力于提高推荐性能,仅向用户提供推荐结果,但忽略了推荐结果的解释性。提供解释最重要的作用不是促使用户接受推荐结果,而是帮助用户在采纳不同结果时能够做出更理智的决策^[62]。具有两个作用:第一,提升用户对推荐结果的满意度,增强用户对平台的信任度;第二,提高模型的透明度,方便对模型的优化。但大部分MTL方法属于深度学习范畴,而深度学习是一种端到端优化的学习范式,缺乏足够的透明度,难以对推荐结果做出解释。考虑到传统推荐算法实现简单且具有较强的可解释性,将MTL方法与传统推荐方法相结合非常值得探索。虽然目前已存在部分工作,例如,与矩阵分解结合、与因式张量分解结合,但这仍是一个值得继续深入研究的方向。

(2)结合异构信息网络:传统多任务推荐算法任务之间只能基于同质信息共享,这限制了模型对具有复杂任务关系的处理,并且RS常面临冷启动和数据稀疏问题。使用异构数据是解决这些问题的一种有效方法。异构信息网络(heterogeneous information networks, HIN)^[63]能利用高阶图形结构从异构数据中获取更丰富的语义信息。基于此,将HIN引入多任务推荐算法,促使各个任务基于异构数据共享是一个可行的方案。文献[64]利用注意力机制来学习HIN的元路径语义,同时对推荐和链路预测任务进行训练。但如何设计一个高效的基于异构信息网络MTRS需要进一步的研究。

(3)非凸函数优化:目前,大部分多任务推荐算法的目标函数为非凸函数,这就无法避开鞍点问题,导致模型难以在全局范围内寻找最优解,对模型的优化造成很大的困扰。例如,当推荐效果不佳时,无法分辨这是因为模型未能找到最优解而导致的,还是因为任务之间共享信息的组合方式不合理引发的。多任务推荐算法中的非凸优化问题已成为限制推荐系统进一步发展的瓶颈,因此,提出优化方案来解决该问题已经刻不容缓。

(4)结合强化学习:Bandits^[65]等强化学习算法能有效地处理RS中的冷启动和探索开发问题。但过去强化学习大多仅限于和单任务推荐算法相结合,并且在对象关系复杂、数据充足的环境下表现不佳。

而MTL能帮助强化学习的各个代理同时学习,各代理学到的参数将定期与全局网络进行共享,然后全局网络从共享参数中提取一组用于共享的新参数,以达到所有代理整体性能的提升^[66]。强化学习与多任务推荐算法的结合已在不同场景下取得了优异成果^[67-69],证明了这是一个值得探索的方向。

5 结束语

MTL信息共享和联合建模的特点给推荐系统带来了新发展机遇。本文首先对MTRS的研究背景进行了介绍;其次盘点了多任务学习的优势、MTRS的基本原理和创建原则;然后从共享模式的角度对MTRS的研究现状进行了阐述,对研究模型的优势及局限性、任务之间的关系进行了归纳总结;接着对常用的数据集和评估指标进行了总结;最后对该领域未来可研究方向进行了探讨。MTL具有数据增强、提升表征学习和泛化能力等优势。但也面临负迁移、参数冲突、可解释性差、数据异构等挑战。因此,后续将围绕多任务推荐模型存在的问题展开深入研究,促进多任务推荐算法与传统推荐算法、异构信息网络、强化学习范式等相结合。

参考文献:

- [1] DAS D, SAHOO L, DATTA S. A survey on recommendation system[J]. International Journal of Computer Applications, 2017, 160(7): 6-10.
- [2] NUNES M, GERDING E, MCGROARTY F, et al. A comparison of multitask and single task learning with artificial neural networks for yield curve forecasting[J]. Expert Systems with Applications, 2019, 119: 362-375.
- [3] NING X, KARYPIS G. Multi-task learning for recommender system[C]//Proceedings of the 2nd Asian Conference on Machine Learning, Japan, Nov 8-10, 2010: 269-284.
- [4] VILALTA R, CARRIER C G, BRAZDIL P, et al. Inductive transfer[J]. Encyclopedia of Machine Learning, 2017, 1(1): 666-671.
- [5] CARUANA R. Multitask learning[J]. Machine Learning, 1997, 28(1): 41-75.
- [6] RUDER S. An overview of multi-task learning in deep neural networks[J]. arXiv:1706.05098, 2017.
- [7] MA X, ZHAO L, HUANG G, et al. Entire space multi-task model: an effective approach for estimating post-click conversion rate[C]//Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York: ACM, 2018: 1137-1140.
- [8] MA J, ZHAO Z, YI X, et al. Modeling task relationships in

- multi-task learning with multi-gate mixture-of-experts[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2018: 1930-1939.
- [9] TANG H, LIU J, ZHAO M, et al. Progressive layered extraction (PLE): a novel multi-task learning (MTL) model for personalized recommendations[C]//Proceedings of the 14th ACM Conference on Recommender Systems, New York, Sep 10, 2020. New York: ACM, 2020: 269-278.
- [10] HUANG Z, RAO M, RAJU A, et al. MTL-SLT: multi-task learning for spoken language tasks[C]//Proceedings of the 4th Workshop on NLP for Conversational AI. Stroudsburg: ACL, 2022: 120-130.
- [11] SAMPATH V, MAURTUA I, MARTÍN J J A, et al. Attention guided multi-task learning for surface defect identification[J]. IEEE Transactions on Industrial Informatics, 2023, 19(9): 9713-9721.
- [12] HU Y, CHEN C, LI R, et al. Gradient remedy for multi-task learning in end-to-end noise-robust speech recognition[J]. arXiv:2302.11362, 2023.
- [13] SONG Y, WANG Y, WANG X, et al. Multi-task adaptive pooling enabled synergetic learning of RNA modification across tissue, type and species from low-resolution epitranscriptomes[J]. Briefings in Bioinformatics, 2023, 24.
- [14] WEN H, ZHANG J, WANG Y, et al. Entire space multi-task modeling via post-click behavior decomposition for conversion rate prediction[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 2377-2386.
- [15] WANG Y, ZHANG J, DA Q, et al. Delayed feedback modeling for the entire space conversion rate prediction[J]. arXiv: 2011.11826, 2020.
- [16] ZHANG W, BAO W, LIU X Y, et al. Large-scale causal approaches to debiasing post-click conversion rate estimation with multi-task learning[C]//Proceedings of the Web Conference 2020. New York: ACM, 2020: 2775-2781.
- [17] WANG H, CHANG T W, LIU T, et al. ESCM²: entire space counterfactual multi-task model for post-click conversion rate estimation[J]. arXiv:2204.05125, 2022.
- [18] ZHU F, ZHONG M, YANG X, et al. DCMT: a direct entire-space causal multi-task framework for post-click conversion estimation[J]. arXiv:2302.06141, 2023.
- [19] JIN J, CHEN X, ZHANG W, et al. Multi-scale user behavior network for entire space multi-task learning[C]//Proceedings of the 31st ACM International Conference on Information and Knowledge Management, Atlanta, Oct 17, 2022. New York: ACM, 2022: 874-883.
- [20] XI D, CHEN Z, YAN P, et al. Modeling the sequential dependence among audience multi-step conversions with multi-task learning in targeted display advertising[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2021: 3745-3755.
- [21] ZHANG Y, LI X, YU Y, et al. Entire cost enhanced multi-task model for online-to-offline conversion rate prediction [C]//Proceedings of the 2022 Workshop on Deep Learning for Search and Recommendation, co-located with the 31st ACM International Conference on Information and Knowledge Management, Atlanta, Oct 17-21, 2022.
- [22] BANSAL T, BELANGER D, MCCALLUM A. Ask the GRU: multi-task learning for deep text recommendations [C]//Proceedings of the 10th ACM Conference on Recommender Systems, Boston, Sep 7, 2016. New York: ACM, 2016: 107-114.
- [23] YANG E, PAN J, WANG X, et al. AdaTask: a task-aware adaptive learning rate approach to multi-task learning[J]. arXiv:2211.15055, 2022.
- [24] LIU J, LI X, AN B, et al. Multi-faceted hierarchical multi-task learning for recommender systems[C]//Proceedings of the 31st ACM International Conference on Information and Knowledge Management, Atlanta, Oct 17, 2022. New York: ACM, 2022: 3332-3341.
- [25] LIN Z, YANG X, LIU S, et al. Personalized inter-task contrastive learning for CTR&CVR joint estimation[J]. arXiv: 2208.13442, 2022.
- [26] MISRA I, SHRIVASTAVA A, GUPTA A, et al. Cross-stitch networks for multi-task learning[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Washington: IEEE Computer Society, 2016: 3994-4003.
- [27] RUDER S, BINGEL J, AUGENSTEIN I, et al. Sluice networks: learning what to share between loosely related tasks [J]. arXiv:1705.08142, 2017.
- [28] CHEN Z, WANG X, XIE X, et al. Co-attentive multi-task learning for explainable recommendation[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence, Macao, China, Aug 11-19, 2019: 2137-2143.
- [29] XIN S, ESTER M, BU J, et al. Multi-task based sales predictions for online promotions[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 2823-2831.
- [30] CHEN Y, YU J, ZHAO Y, et al. Task's choice: pruning-based feature sharing (PBFS) for multi-task learning[J]. Entropy, 2022, 24(3): 432.
- [31] SHAZEER N, MIRHOSEINI A, MAZIARZ K, et al. Outrageously large neural networks: the sparsely-gated mixture-of-experts layer[J]. arXiv:1701.06538, 2017.

- [32] ZHAO Z, HONG L, WEI L, et al. Recommending what video to watch next: a multitask ranking system[C]//Proceedings of the 13th ACM Conference on Recommender Systems, Copenhagen, Sep 10, 2019. New York: ACM, 2019: 43-51.
- [33] MA J, ZHAO Z, CHEN J, et al. SNR: sub-network routing for flexible parameter sharing in multi-task learning[C]//Proceedings of the 2019 AAAI Conference on Artificial Intelligence, Honolulu, Jan 27-Feb 1, 2019. Menlo Park: AAAI, 2019: 216-223.
- [34] XU Z, ZHAO M, LIU L, et al. Mixture of virtual-kernel experts for multi-objective user profile modeling[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Washington, Aug 14, 2022. New York: ACM, 2022: 4257-4267.
- [35] WU X, MAGNANI A, CHAIDAROON S, et al. A multi-task learning framework for product ranking with BERT [C]//Proceedings of the ACM Web Conference 2022, Lyon, Apr 25, 2022. New York: ACM, 2022: 493-501.
- [36] QIN Z, CHENG Y, ZHAO Z, et al. Multitask mixture of sequential experts for user activity streams[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Aug 20, 2020. New York: ACM, 2020: 3083-3091.
- [37] WU H. MNM: multi-level network cascades model for multi-task learning[C]//Proceedings of the 31st ACM International Conference on Information and Knowledge Management, Atlanta, Oct 17, 2022. New York: ACM, 2022: 4565-4569.
- [38] XIN S, JIAO Y, LONG C, et al. Prototype feature extraction for multi-task learning[C]//Proceedings of the ACM Web Conference 2022, Lyon, Apr 25, 2022. New York: ACM, 2022: 2472-2481.
- [39] TAO X, HA M, GUO X, et al. Task aware feature extraction framework for sequential dependence multi-task learning [J]. arXiv:2301.02494, 2023.
- [40] LI D, ZHANG Z, YUAN S, et al. AdaTT: adaptive task-to-task fusion network for multitask learning in recommendations[J]. arXiv:2304.04959, 2023.
- [41] SUN T, SHAO Y, LI X, et al. Learning sparse sharing architectures for multiple tasks[C]//Proceedings of the 2020 AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2020: 8936-8943.
- [42] XIAO X, CHEN H, LIU Y, et al. LT4REC: a lottery ticket hypothesis based multi-task practice for video recommendation system[J]. arXiv:2008.09872, 2020.
- [43] DING K, DONG X, HE Y, et al. MSSM: a multiple-level sparse sharing model for efficient multi-task learning[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, Canada, Jul 11, 2021. New York: ACM, 2021: 2237-2241.
- [44] CHEN X, GU X, FU L. Boosting share routing for multi-task learning[C]//Proceedings of the Companion of the Web Conference 2021, Ljubljana, Jun 3, 2021: 372-379.
- [45] BAI T, XIAO Y, WU B, et al. A contrastive sharing model for multi-task recommendation[C]//Proceedings of the ACM Web Conference 2022. New York: ACM, 2022: 3239-3247.
- [46] LIM N, HOOI B, NG S K, et al. Hierarchical multi-task graph recurrent network for next POI recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, Madrid, Jul 7, 2022. New York: ACM, 2022: 1133-1143.
- [47] WEN H, ZHANG J, LV F, et al. Hierarchically modeling micro and macro behaviors via multi-task learning for conversion rate prediction[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 2187-2191.
- [48] VANSCHOREN J. Meta-learning[M]//Automated Machine Learning. Cham: Springer, 2019: 35-61.
- [49] YANG K, LI X, LI J, et al. Meta-learning for recommendation system with the multi-tasking learning setting[C]//Proceedings of the 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference, Chengdu, Dec 20-22, 2019. Piscataway: IEEE, 2020: 735-740.
- [50] HE Y, FENG X, CHENG C, et al. MetaBalance: improving multi-task recommendations via adapting gradient magnitudes of auxiliary tasks[C]//Proceedings of the ACM Web Conference 2022. New York: ACM, 2022: 2205-2215.
- [51] LEE S, SON Y. Multitask learning with single gradient step update for task balancing[J]. Neurocomputing, 2022, 467: 442-453.
- [52] JAVALOY A, VALERA I. Rotograd: gradient homogenization in multitask learning[J]. arXiv:2103.02631, 2021.
- [53] HE R, MCAULEY J. Ups and downs: modeling the visual evolution of fashion trends with one-class collaborative filtering[C]//Proceedings of the 25th International Conference on World Wide Web, Montreal, Apr 11-15, 2016: 507-517.
- [54] HARPER F M, KONSTAN J A. The MovieLens datasets: history and context[J]. ACM Transactions on Interactive Intelligent Systems, 2015, 5(4): 1-19.
- [55] CAO Q, SHEN H, CEN K, et al. Deephawkes: bridging the gap between prediction and understanding of information cascades[C]//Proceedings of the 2017 ACM Conference on Information and Knowledge Management. New York: ACM, 2017: 1149-1158.
- [56] ORAMAS S, OSTUNI V C, NOIA T D, et al. Sound and music recommendation with knowledge graphs[J]. ACM

- Transactions on Intelligent Systems and Technology, 2016, 8(2): 1-21.
- [57] SCHEDL M. The LFM-1b dataset for music retrieval and recommendation[C]//Proceedings of the 2016 ACM International Conference on Multimedia Retrieval, New York, Jun 6, 2016. New York: ACM, 2016: 103-110.
- [58] KANG W C, MCAULEY J. Self-attentive sequential recommendation[C]//Proceedings of the 2018 IEEE International Conference on Data Mining. Piscataway: IEEE, 2018: 197-206.
- [59] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, Paris, Jul 18, 2019. New York: ACM, 2019: 165-174.
- [60] FAWCETT T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.
- [61] ZHU H, JIN J, TAN C, et al. Optimized cost per click in tao-bao display advertising[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2017: 2191-2200.
- [62] ZHANG Y, CHEN X. Explainable recommendation: a survey and new perspectives[J]. Foundations and Trends® in Information Retrieval, 2020, 14(1): 1-101.
- [63] LU Y, FANG Y, SHI C. Meta-learning on heterogeneous information networks for cold-start recommendation[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2020: 1563-1573.
- [64] LI H, WANG Y, LYU Z, et al. Multi-task learning for recommendation over heterogeneous information network[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(2): 789-802.
- [65] LI P, WANG Z, REN Z, et al. Neural rating regression with abstractive tips generation for recommendation[C]//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, Tokyo, Aug 7, 2017. New York: ACM, 2017: 345-354.
- [66] VITHAYATHIL VARGHESE N, MAHMOUD Q H. A survey of multi-task deep reinforcement learning[J]. Electronics, 2020, 9(9): 1363.
- [67] ZHANG Q, LIU J, DAI Y, et al. Multi-task fusion via reinforcement learning for long-term user satisfaction in recommender systems[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Washington, Aug 14, 2022. New York: ACM, 2022: 4510-4520.
- [68] ZHANG H, ZHAO P, XIAN X, et al. Click is not equal to purchase: multi-task reinforcement learning for multi-behavior recommendation[C]//Proceedings of the 2022 International Conference on Web Information Systems Engineering. Cham: Springer, 2022: 443-459.
- [69] LIU X, LI L, HSIEH P C, et al. Developing multi-task recommendations with long-term rewards via policy distilled reinforcement learning[J]. arXiv:2001.09595, 2020.



温民伟 (1997—), 男, 江西赣州人, 硕士研究生, CCF 学生会员, 主要研究方向为推荐系统、数据挖掘。

WEN Minwei, born in 1997, M.S. candidate, CCF student member. His research interests include recommendation system and data mining.



梅红岩 (1978—), 女, 辽宁葫芦岛人, 博士, 教授, CCF 专业会员, 主要研究方向为数据挖掘、大数据分析、网络服务。

MEI Hongyan, born in 1978, Ph.D., professor, CCF professional member. Her research interests include data mining, big data analysis and network services.



袁凤源 (1999—), 男, 辽宁沈阳人, 硕士研究生, CCF 学生会员, 主要研究方向为数据挖掘、推荐系统。

YUAN Fengyuan, born in 1999, M.S. candidate, CCF student member. His research interests include data mining and recommendation system.



张晓宇 (2001—), 女, 辽宁大连人, 硕士研究生, 主要研究方向为情感分析、推荐系统。

ZHANG Xiaoyu, born in 2001, M.S. candidate. Her research interests include sentiment analysis and recommender systems.



张兴 (1975—), 男, 辽宁葫芦岛人, 博士, 教授, CCF 专业会员, 主要研究方向为网络体系结构与协议、信息安全。

ZHANG Xing, born in 1975, Ph.D., professor, CCF professional member. His research interests include network architecture and protocol, information security.