

doi:10.13582/j.cnki.1674-5884.2024.04.008

基于用户影响力感知的 在线学习资源推荐方法

郭飞雁, 贺晶晶

(湖南电气职业技术学院 风能工程学院, 湖南 湘潭 411100)

摘要: 针对在线学习中推荐数据稀疏性和资源多样化需求等问题, 构建了一套在线学习混合推荐策略。该研究提出了一种基于用户相似性、知识可信度和用户影响力评估的在线学习用户模型 LIAM, 以提高推荐效果。同时, 采用动态直觉模糊 DIF 策略对 LIAM 模型进行优化, 以提高模型的推荐准确性和可解释性。最后, 该研究提出了一种基于自组织的推荐方法 SOR, 用于解决推荐结果的多样性和覆盖性问题, 从而形成了一套完整的在线学习混合推荐策略。同时, 采用 Coursera 数据集对推荐方法 SOR 进行性能验证, 实验结果表明, 该方法优于其他两种代表性推荐方法。推荐方法 SOR 有望为在线学习推荐系统提供更加准确和个性化的推荐服务, 提升学习效果 and 用户体验。

关键词: 用户影响力感知; 在线学习; 混合推荐

中图分类号: G642

文献标志码: A

文章编号: 1674-5884(2024)04-0048-07

在线学习已成为全球教育领域的一个热点, 得到了广泛的关注和支持。随着网络技术和云计算技术的不断发展, 在线学习的覆盖面不断扩大, 越来越多的学校和机构开始采用在线学习模式。在线学习平台的内容和形式也不断丰富和创新, 包括 MOOC、微课、直播课程、虚拟实验室等。同时, 个性化推荐、人工智能和数据分析等技术的应用也为在线学习带来了更多的可能性和机遇。

传统的在线学习资源推荐方法, 如基于内容的推荐、协同过滤推荐等需要依赖在线学习用户的历史数据才能进行。但在在线学习平台中的用户和资源数量庞大, 每个用户利用学习资源的历史行为数据通常很少, 导致推荐系统产生数据稀疏性问题。同时, 由于数据的稀疏性, 很多在线学习用户和学习资源之间没有访问交互记录, 传统的推荐方法很难准确地捕捉到用户和学习资源之间的关系。传统的推荐方法只是根据学习用户的历史数据或者学习资源的属

性进行推荐, 缺乏与用户的交互和反馈, 难以对用户兴趣进行深入理解, 面对存在推荐热门资源的现象, 没有针对用户的个性化需求进行推荐, 导致推荐结果缺乏针对性。

在线学习过程中, 由于推荐系统数据极端稀疏性和资源多样化需求, 在为用户个性化推荐时, 遇到了一些亟需解决的问题。例如冷启动问题、多样性和个性化平衡问题、实时性问题等。针对这些问题, 推荐系统需要根据具体情况采取相应的解决方案, 综合考虑个性化、多样性、实时性和计算复杂度等因素, 从而为用户提供更好的学习体验。基于用户影响力感知的在线学习资源推荐方法通过一种自组织混合协同过滤推荐策略, 提高在线学习推荐系统的有效性, 从而提升在线学习质量, 有效缓解在线学习个性化推荐的数据稀疏和冷启动问题, 满足在线学习用户多样性需求。

收稿日期: 2023-06-15

基金项目: 湖南省自然科学基金项目(2022JJ60024)

作者简介: 郭飞雁(1982—), 女, 湖南永州人, 副教授, 博士, 主要从事数据挖掘、教育信息化研究。

1 在线学习资源个性化推荐相关研究

1.1 在线学习推荐系统相关研究

面对推荐系统用户数据稀疏性导致的问题,目前较为通用的解决方式为以下两种:一是基于矩阵分解的推荐算法。矩阵分解模型可以获得数据的基本特征,以更快的速度提取信息和产生预测^[1]。但与基于集群的方法不同,这些模型在捕获强的局部关系方面效果不佳^[2]。另一种是对原始数据存在的缺省值进行相应填充的方法。邓爱林等^[3]提出了一种根据项目进行缺省值填充并针对用户进行预测的改进协同过滤算法,采用一种改进方法计算用户相似度得出最终的预测结果。但是缺省值填充的方法由于不同用户具有不同的兴趣特征会导致填充值存在偏差。另外,研究者们尝试在不改变原始数据稀疏度的情况下通过改变传统协同过滤的推荐模型提升推荐算法的推荐精度。邓晓懿等^[4]提出结合情景信息和社交网络信息对用户评价进行建模,通过建立的模型来预测用户评分。黄大巧等^[5]提出一种基于对抗性训练改进模型鲁棒性的协同过滤推荐算法,通过构建微小扰动对推荐模型进行训练,调整改进网络结构参数,从而提高系统的推荐准确度和抗干扰能力。张新猛等^[6]利用 TF-IDF 和用户对项目不同标签的偏好,基于网络的推荐混合建模后进行推荐。线性组合后的推荐结果在多样性和准确度相较于传统协同过滤算法都有较好的提升。然而,这些研究仍然基于用户评级矩阵,在没有有效评级信息的情况下,如何实现协同过滤推荐仍需进一步研究。

1.2 在线学习用户模型构建相关研究

在线学习环境具有以下特点:时间连续性、知识连续性和在线学习用户对学习资源多样化需求等。为了确保在线学习用户的长期学习经验,在线学习用户模型应该具有很高的准确性,还应该有一定程度的多样性。

增加多样性的一个解决方案是使用多属性在线学习用户模型^[7-8]。在线学习用户模型的类型包括基于规则的模型、基于统计的模型、基于机器学习的模型等。这些模型可以帮助教育者和系统提供个性化的学习支持和建议。在线学习用户模型的研究重点在如何提取和表示在线学习用户的特征。常用的特征包括学习行为、认知风格、学习目标、学习历史等。同时,在线学习用户模型的构

建和训练是一个关键的步骤。研究者使用了各种机器学习算法,如决策树、神经网络、支持向量机等,来构建和训练在线学习用户模型。此外,一些研究者还探索了深度学习和强化学习等新兴技术在在线学习用户模型中的应用。在研究中,发现在线学习用户模型存在一些亟待解决的问题,如数据稀疏性、特征的选择与融合,以及模型的可解释性和解释性问题。Bull 等^[9]设计了协商在线学习用户模型,允许用户直接与在线学习用户模型交互来保持在线学习用户模型的准确性。Suleman 等^[10]开发了协商驱动辅导系统,利用在线学习用户的情感和行为状态、物体和附近环境的情境信息,智能推断用户的行为与目的,提高了在线学习用户模型的准确性。在实践应用方面,武法提等^[11]研究了近年来关于在线学习用户特征的分析模型,并融合在线学习用户所处的场景特性,采用基于频繁序列进行挖掘的算法对场景感知进行建模,构建了个性化在线学习用户模型。

除增加多样性外,另一种方法是引入模糊机制来描述在线学习用户的不确定性行为。模糊理论被广泛应用于多个领域,包括控制系统、决策支持系统、图像处理、模式识别等。模糊机制的核心思想是通过模糊集合和模糊逻辑来处理不确定性和模糊性的问题,从而使系统能够更好地处理模糊的输入和输出^[12]。模糊推理是模糊机制的关键组成部分,用于根据模糊规则和输入变量进行推理和决策。常见的模糊推理方法包括模糊关联、模糊推理机、模糊神经网络等。这些方法可以应用于控制系统中的模糊控制、决策支持系统中的模糊决策等。模糊集合和隶属函数的设计是模糊机制研究的重要内容。研究者通过定义隶属函数的形状和参数,来刻画模糊集合的隶属度。常见的隶属函数包括三角形函数、梯形函数、高斯函数等。此外,一些研究者还探索了基于数据驱动的方法,如聚类和优化算法,用于自动设计隶属函数。模糊机制在控制系统和优化问题中的应用也受到广泛关注。模糊控制利用模糊规则和反馈机制来实现对复杂系统的控制。模糊优化则结合了模糊集合和优化算法,用于解决具有不确定性和模糊目标的优化问题。在线学习中,模糊理论被用来处理在线学习用户的不确定性,如在线学习用户的不确定反应^[13]、学习资源与在线学习用户需求的模糊匹配^[14-15]。由于在线学习用户的复

杂和多样化需求,作者将基于直觉模糊理论进行在线学习用户模型优化,以满足用户多样化需求。

2 一种基于用户影响力感知的在线学习混合式推荐方法

在线学习是一种以数字化技术为基础的学习模式,但是在线学习面临着过度数据稀缺性的问题,主要是因为在线学习用户在线学习过程中的行为记录往往是间断的,导致了学习数据的不完整和稀疏。这阻碍了推荐技术在在线学习中的应用发展,传统的推荐方法往往不能准确地捕捉到在线学习用户的兴趣和需求。

同时,在线学习过程具有时间连续性特点,在线学习用户的兴趣和需求也随时间的推移而发生变化。因此,在保证长期学习经验和提高在线学习用户满意度方面,多样性在推荐系统中发挥着重要作用。基于自组织理论的用户影响力感知的混合式在线学习资源推荐方法,能够充分利用在线学习用户的历史行为数据和社交网络信息,为在线学习用户提供个性化和多样化的学习资源推荐服务。这种方法不仅能够减轻数据稀疏性对推荐结果的影响,还能够提高推荐系统的精度和多样性。同时,该方法还能够感知在线学习用户的影响力和社交关系,为推荐结果提供更加合理的解释,提高在线学习用户对推荐结果的信任度。

2.1 基于用户影响力感知的在线学习用户模型 LIAM 的构建

基于用户影响力感知的在线学习用户模型 LIAM 是一种能够自适应地评估在线学习用户影响力的模型,能够更好地支持在线学习推荐系统的个性化推荐和社交化推荐。该模型能够根据在线学习用户的影响力自适应地调整个性化推荐和社交化推荐的比重,从而更好地满足在线学习用户的学习需求和偏好。

2.1.1 LIAM 模型构建流程

构建用户影响力感知的在线学习用户模型 LIAM 涉及多个步骤和元素,包括特征提取、影响力指标选择、模型选择和评估等,基本的构建流程如下。

(1)数据收集和处理。通过在线学习平台收集在线学习用户的行为数据和社交网络数据,包括学习行为、课程评价、社交网络关系等。从数据中提取与用户影响力相关的特征。这些特征包括

用户的活跃度、贡献度、社交互动、学习历史等。同时还考虑用户的社交网络信息,如粉丝数量、关注者数量等。

(2)用户影响力评估指标的选择。基于数据收集和处理,选择适合在线学习场景的影响力评估指标。如:学生在学习平台上活跃程度,包括登录频率、学习时长、参与讨论和提交作业的频率;学生对学习平台的贡献,包括回答问题、发表评论、分享资源、创建课程内容;学生在社交网络中的影响力,包括粉丝数量、关注者数量、社交分享的频率;评估学生对课程的评价和反馈,包括评分、评论内容和课程推荐;学生分享自己的学习成果、笔记、教程或学习资源的频率和质量;等等。

(3)数据归一化处理。确定要使用的影响力评估指标,收集并选定与指标相关的用户数据。对于每个指标,计算每个用户的具体数值。对每个指标的数值进行归一化处理即将数值缩放到 0 到 1 之间,以确保它们具有相似的尺度和权重。

(4)影响力得分计算。根据指标的重要性,基于领域知识、数据分析或专家意见为每个指标分配权重。使用所分配的权重,将归一化后的指标数值加权求和,得到每个用户的综合影响力得分。根据综合得分,对用户进行排名,以确定他们

的影响力水平,排名主要用于识别高影响力用户。

(5)模型选择。选择用于构建用户影响力感知模型的方法,包括传统的线性模型、基于规则的方法、机器学习模型或深度学习模型等。

(6)模型训练和调优。使用训练数据集对选择的模型进行训练,并根据评估指标如模型的准确率、召回率、均方误差等对模型进行调优。

2.1.2 LIAM 模型的组成

LIAM 模型的建立可以促进在线学习平台的个性化推荐和社交化推荐,提高在线学习用户的学习效果和满意度,同时也有助于促进在线学习用户之间的互动和交流。基于用户影响力感知的在线学习用户模型 LIAM 由 3 部分组成:用户相似性、知识可信度和用户影响力评估。

(1)用户相似性

以在线学习用户的个体偏好即学习风格和学习目标为指标来衡量在线学习用户相似性。学习风格以数字或数字序列表示,根据在线学习用户的配置文件进行更新。由于在线学习用户具有离散值、有序序列和集合多种异构属性,因此,采用余弦

相似性、汉明距离和 Jaccard 系数 3 种方法来计算在线学习用户的个性相似度。详细内容如表 1 所示。

表 1 在线学习用户个性偏好属性及计算方法

属性	符号	计算方法	说明
资源类型偏好	RP	余弦相似性	视频、图片、文字等资源类型
学习内容偏好	TP	汉明距离	计算机、人工智能、经济学、医学等主题
学习目的	SG	汉明距离	考级、兴趣爱好、专业学习等
学习态度	ST	余弦相似性	严谨、懒散、随意、主动等
学习情感	SL	余弦相似性	被吸引、不耐烦或感觉难以遵循等
学习适应性	AD	余弦相似性	在线学习用户对匹配程度较低推荐目标的接受程度
学习能力水平	AL	余弦相似性	学习内容的吸引速度
推荐接受度	RT	余弦相似性	在线学习用户对反复推荐学习目标的容忍度
优先级	PP	汉明距离	某一在线学习用户的上述偏好序列
学习目标	SG	Jaccard 系数	在线学习用户学习的目标序列, $SG = \{G_1, G_2, \dots, G_i, \dots, G_n\}$

在线学习用户 u_a 表示如式(1)所示。 u_a^i 表示 u_a 中的第 i 个属性值。

$$u_a = (RP, TP, SG, ST, SL, AD, AL, RT, PP, SG) \quad (1)$$

在线学习用户 u_a 和 u_b 的个性相似性 US_{ab} 计算如式(2)所示。 $\alpha_1, \alpha_2, \alpha_3$ 为权重系数, $\alpha_1 + \alpha_2 + \alpha_3 = 1$ 。其中, $sim_{ab}, sim'_{ab}, sim''_{ab}$ 计算方法如式(3)、(4)、(5)。

$$US_{ab} = \alpha_1 norm(sim_{ab}) + \alpha_2 norm(sim'_{ab}) + \alpha_3 norm(sim''_{ab}) \quad (2)$$

$$sim_{ab} = \frac{\sum_{i=1,4,5,6,7,8} (u_a^i u_b^i)}{\sqrt{\sum_{i=1,4,5,6,7,8} (u_a^i)^2} \sqrt{\sum_{i=1,4,5,6,7,8} (u_b^i)^2}} \quad (3)$$

$$sim'_{ab} = \sum_{j=2,3,9} HamDis(u_a^j, u_b^j) \quad (4)$$

$$sim''_{ab} = \sum_{k=10} (u_a^k \cap u_b^k) / (u_a^k \cup u_b^k) \quad (5)$$

(2) 知识可信度

知识可信度用于评估目标在线学习用户可被其他主动在线学习用户信任程度。根据在线学习用户的学习概况来评估学习用户知识可信度。知识可信度包括分数、时间效率、排名信息、解决难题的能力等。知识可信度组成如表 2 所示。

表 2 知识可信度组成

序号	符号	说明
1	LR	所有学习模块中在线学习用户学习平均分数所处等级
2	PR	指定模块中在线学习用户学习平均分数所处等级
3	SR	整个模块中学习分数或时间所占比例
4	AR	指定模块回答问题的首次正确率
5	DR	高难度测试中在线学习用户成绩等级
6	NL	单元时间内学习的目标个数

知识可信度用 KC 表示, 在线学习用户 u_a 的可信用度 KC_a 表示, 计算式如(6)所示。

$$KC_a = \beta_1 LR' + \beta_2 PR' + \beta_3 SR' + \beta_4 AR' + \beta_5 DR' + \beta_6 NL' \quad (6)$$

其中, $LR', PR', SR', AR', DR', NL'$ 是 LR, PR, SR, AR, DR, NL 的标准值, 范围为 $[0, 1]$ 。 β_i 为权重系数, 根据专家建议和经验值设置。 KC_{ab} 表示主动在线学习用户 u_b 对目标在线学习用户 u_a 的可信用度值, 计算公式如(7)所示。

$$KC_{ab} = (KC_b - KC_a) (1 + |Rank_{u_a} - Rank_{u_b}| / N) \quad (7)$$

式(7)中, $Rank_{u_a}$ 表示用户 U_a 按 KC 的排序结果, N 表示与 U_b 已学习或正学习同一模块的在线学习用户数量。

(3) 用户影响力评估

为了避免在线学习用户的无目的和无效的跟随行为, 需要评估目标用户对其追随者所施加的影响。用户影响力评估 IA 是为了描述用户被他人认可的程度大小。 IA 组成表示如表 3 所示。

表 3 IA 组成

序号	符号	说明
1	NF	在所有模块的跟随者数量
2	OF	在交叉模块的跟随者数量
3	OP	学习目标中交叉项目的重叠比例
4	OM	在线学习用户通过重叠模块被访问的次数
5	TM	在线学习用户通过重叠模块被访问的时间
6	EF	重叠模块中有效追随者的数量
7	TF	重叠模块中的真正追随者的数量

重叠模块指主动在线学习用户和目标在线学习用户所学习的相同内容模块。在线学习用户 U_a 影响力计算方法如式(8)所示。

$$IA_a = \chi_1 NF' + \chi_2 OF' + \chi_3 OP' + \chi_4 OM' + \chi_5 TM'$$

$$+ \chi_6 EF' + \chi_7 TF' \quad (8)$$

目标在线学习用户 U_b 对 U_a 的影响力 IA_{ab} 表示如式(9)所示,其中,式中 $Rank_{u_a}$ 表示按 IA 排序的 U_a 的位置。

$$IA_{ab} = (LGB - LGA) (1 + |Rank_{u_a} - Rank_{u_b}| / N) \quad (9)$$

2.2 基于动态直觉模糊集理论的 LIAM 模型优化

如果 X 是给定域,则 X 中的动态直觉模糊 FT 计算如式(10)。

$$FT = \{ \langle x, \varepsilon_{FT}(x), \delta_{FT}(x) \rangle \mid x \in X \} \quad (10)$$

式(10)中, $\varepsilon_{FT}(x)$ 表示 x 属于模糊集 FT 的程度, $\delta_A(x)$ 表示 x 不属于 FT 的程度,取值范围均在 $[0,1]$ 。对于 x 中的每个模糊集 A , $o_A(x)$ 被定义为 A 中 x 的直觉指数,计算公式如式(11)。

$$o_A(x) = 1 - \varepsilon_{FT}(x) - \delta_{FT}(x) \quad (11)$$

通过设置学习需求(SR)、学习阶段(LS)和学习能力(LA)三个直觉模糊逻辑系数表示在线学习用户对用户相似性(US)、知识可信度(KC)和用户影响力评估(IA)三个影响因素的态度。

采用 PrefixSpan 频繁序列模式挖掘算法,应用直觉模糊逻辑系数 $\langle \varepsilon_i, \delta_i, o_i \rangle$, 计算在线学习用户在 US、KC 和 IA 三个领域的相关性,通过捕获序列数据的实时变化对 LIAM 模型进行优化。

2.3 基于自组织行为理论的推荐方法 SOR

在推荐系统中,主动在线学习用户更愿意接近高影响力的目标在线学习用户,这种自组织过程可以促进团体内部的有效学习和知识传递。当在线学习用户结构稳定时,可以通过设置最小团内距离来构建有序有效的团体,团中的在线学习用户可以互相支持和帮助。在这样的团体中,每个在线学习用户都被邻居包围着,都形成自己的有效用户,这些用户在信息传播过程中能够直接与主动在线学习用户进行交流,提供建议和支持。此外,有效在线学习用户之间也可以相互传递运动信息,将主动在线学习用户的需求和偏好传达给其他有效在线学习用户和邻居,从而形成一种基于信息传播的在线学习用户自组织行为。具体流程描述如图1所示。




图1 基于信息传播的在线学习用户自组织行为形成过程

在线学习具有时间和空间复杂性特点,推荐算法需要考虑到这些特点。基于协同过滤和启发式算法的混合式推荐策略可以解决在线学习过程中出现的多样性和数据稀缺性问题。首先利用在线学习用户自组织行为生成稳定的在线学习用户群体,然后利用协同过滤和启发式算法对在线学习用户群体进行推荐。这种推荐策略是一种自下而上、分布式、基于概率的方法,可以实现在线学习的个性化和多样化需求,并提高在线学习用户的满意度和学习效果。

3 基于用户影响力感知的在线学习混合式推荐方法验证

3.1 数据集

研究中使用 Coursera 数据集评估基于自组织行为理论的推荐方法 SOR。Coursera 是全球知名的在线学习平台,合作伙伴包括全球领先的大学和机构,提供来自各个领域的高质量课程。

Coursera 数据集为研究者和数据科学家提供了机会,深入了解在线学习的模式、在线学习用户行为和学习成果,以及评估教学方法和个性化学习策略的效果。Coursera 数据集主要包含以下类型的信息。

(1)在线学习用户个人信息。在线学习用户在 Coursera 平台上个人信息包括在线学习用户的年龄、性别、国籍等基本信息,以及学历、职业等背景信息。

(2)注册信息。在线学习用户在 Coursera 平台上注册课程的信息,包括注册时间、注册课程、课程属性等。

(3)课程交互数据。在线学习用户与课程内容的交互数据,如观看视频、完成测验、参与讨论等。

(4)学习行为数据。在线学习用户在课程中的学习行为数据,如访问频率、学习时长、重复观看视频的次數等。

(5)作业和测验数据。在线学习用户提交的作业和测验的数据,包括作业得分、测验结果等。

(6)讨论参与数据。在线学习用户在课程讨论区的参与情况,包括提问、回答问题、点赞等。

(7)学习成果数据。在线学习用户在课程中的学习成果,如最终得分、证书颁发情况等。

随机选择 100 个用户数据,将数据划分为训练集和测试集,其中 80% 的数据作为训练集,用于模型的训练和参数优化,20% 的数据作为测试集用于模型性能的评估和预测结果的验证。

3.2 对比方法

在研究中,采用基于项目的协同过滤(item-based CF)和基于用户的协同过滤(user-based CF)两种方法与研究中提出的基于用户影响力感知的在线学习混合推荐方法 SOR 进行对比。

3.2.1 基于项目的推荐方法 item-based CF

基于项目的推荐方法是根据用户先前对在线学习资源的评分或者对该资源的描述信息,对学习资源进行分析,通过识别相似的特征或属性,为在线学习用户推荐具有相似特征或属性的其他学习资源。例如,当用户搜索一个学习资源时,系统会分析该资源的类型、时长等信息,并根据这些信息为用户推荐具有类似特征的其他在线学习资源。

3.2.2 基于用户的推荐方法 user-based CF

基于用户的推荐方法是根据用户的行为历史数据,如浏览历史、购买历史或评分历史,来预测他们对其他学习资源的偏好,从而为用户推荐他们可能感兴趣的产品。该系统使用用户行为数据来计算用户之间的相似度,然后将相似用户之间的喜好进行比较,以预测用户对其他学习资源的喜好。例如,如果两个用户经常浏览或学习相似的在线学习资源,则他们在一定程度上具有相似的品味和偏好,系统会为其中一个用户推荐另一个用户学习过的资源。

3.3 结果分析

随机选择 100 个用户记录评价,采用三种推荐方法进行推荐准确度对比:基于项目的 item-based CF 方法,基于用户的推荐 user-based CF 方法和基于用户影响力感知的在线学习混合推荐方法 SOR。实验结果如图 2 所示。




图 2 三种方法推荐准确度对比

从图中可以得出,基于项目的 item-based CF、基于用户的推荐 user-based CF 和基于用户影响力感知的在线学习混合推荐方法 SOR 的推荐准确度分别为 56.58%、54.27%、78.65%。SOR 的推荐准确度相较 item-based CF 和 user-based CF 推荐方法准确度分别提高了 22.07%、24.38%。基于用户影响力感知的在线学习混合推荐方法 SOR 在预测精度方面优于其他两种推荐代表方法。此外,该方法还可以通过不断学习用户的行为来不断改进推荐结果,具有良好的实时性和适应性。因此,SOR 可应用于在线学习推荐系统中,提高用户的满意度和推荐效果。

4 结语

基于推荐系统的现有成果,针对目前在线学习资源推荐存在的瓶颈问题,探索适合在线学习用户个性化和多样性需求的推荐新方法和新模式。设计一个基于用户影响力感知的在线学习用户模型 LIAM,解决在线学习中的人际信息稀疏和冷启动问题,为在线学习资源推荐策略提供数据结构支撑。采用动态直觉模糊策略优化在线学习用户模型,解决在线学习用户学习过程中存在的主观和不确定因素,进一步优化在线学习资源推荐策略的数据结构模型。提出一种基于自组织理论的在线学习资源推荐方法 SOR,研究在线学习用户之间的协作行为,提供最优在线学习用户群体,从而提高推荐精度,满足用户对推荐资源的多样化需求。最后采用 Coursera 数据集对推荐方法 SOR 进行性能验证,实验结果表明,该方法优于其他两种代表性推荐方法。

参考文献:

- [1] CACHED A F, CARNEIRO V, FERNÁNDEZ D, et al. Comparison of Collaborative Filtering Algorithms: Limitations of Current Techniques and Proposals for Scalable,

- High-Performance Recommender Systems [J]. ACM Transactions on the Web, 2011(1):2.
- [2] KOREN Y. Factorization Meets the Neighborhood: A Multifaceted Collaborative Filtering Model [C]//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2008:426-434.
- [3] 邓爱林, 朱扬勇, 施伯乐. 基于项目评分预测的协同过滤推荐算法[J]. 软件学报, 2003(9):1621-1628.
- [4] 邓晓懿, 金淳, 韩庆平, 等. 基于情境聚类 and 用户评级的协同过滤推荐模型[J]. 系统工程理论与实践, 2013(11):2945-2953.
- [5] 黄大巧, 朱健军, 曹俊卓. 基于对抗性训练的动态协同过滤推荐算法[J]. 软件工程, 2022(12):50-53.
- [6] 张新猛, 蒋盛益, 李霞, 等. 基于网络和标签的混合推荐算法[J]. 计算机工程与应用, 2015(1):119-124.
- [7] DI NOIA T, ROSATI J, TOMEIO P, et al. Adaptive multi-attribute diversity for recommender systems [J]. Information Sciences, 2017: 234-253.
- [8] WAN S S, NIU Z D. A Learner Oriented Learning Recommendation Approach Based on Mixed Concept Mapping and Immune Algorithm [J]. Knowledge-Based Systems, 2016: 28-40.
- [9] BULL S. Negotiated Learner Modelling to Maintain Today's Learner Models [J]. Research and Practice in Technology Enhanced Learning, 2016(1): 10.
- [10] SULEMAN R M, MIZOGUCHI R, IKEDA M. A New Perspective of Negotiation-based Dialog to Enhance Metacognitive Skills in the Context of Open Learner Models [J]. International Journal of Artificial Intelligence in Education, 2016(4): 1069-1115.
- [11] 武法提, 黄石华, 殷宝媛. 基于场景感知的学习者建模研究[J]. 电化教育研究, 2019(3):68-74.
- [12] KUO Y L, YEH C H, CHAU R. A Validation Procedure for Fuzzy Multiattribute Decision Making [C]//The 12th IEEE International Conference on Fuzzy Systems, 2003. FUZZ'03. IEEE, 2003: 1080-1085.
- [13] CHEN C, DUH L. Personalized Web-based Tutoring System Based on Fuzzy Item Response Theory [J]. Expert Systems with Applications, 2008(4): 2298-2315.
- [14] WU D S, ZHANG G Q, LU J. A Fuzzy Tree Similarity Measure and its Application in Telecom Product Recommendation [C]//2013 IEEE International Conference on Systems, Man, and Cybernetics. IEEE, 2013:3483-3488.
- [15] Lu J. Personalized E-learning Material Recommender System [J]. Macquarie Scientific Publishing, 2004: 374-379.

Online Learning Resource Recommendation Approach Based on User Influence Perception

GUO Feiyan, HE Jingjing

(Wind Energy Engineering College, Hunan Vocational and Technical College of Electric Appliances, Xiangtan 411100, China)

Abstract: To address the issues of data sparsity in online learning and diverse resource demands, researchers have developed a hybrid recommendation strategy for online learning. This study introduces an online learning user model called LIAM, which is based on user similarity, knowledge credibility, and user influence assessment to enhance recommendation effectiveness. Additionally, the LIAM model is optimized by using a dynamic intuition fuzzy (DIF) strategy to improve recommendation accuracy and interpretability. Finally, a self-organizing recommendation method, SOR, is proposed to address the diversity and coverage of recommendation results, forming a comprehensive hybrid recommendation strategy for online learning. By using the Coursera dataset for performance validation, experimental results show that the SOR method outperforms two other representative recommendation methods. The SOR recommendation method is expected to provide more accurate and personalized recommendation services for online learning recommendation systems, thus enhancing learning outcomes and user experiences.

Key words: user influence perception; online learning; hybrid recommendation

(责任校对 王小飞)