

基于协同过滤与注意力机制的个性化电影推荐研究

时小芳¹ 向志华¹
SHI Xiaofang XIANG Zhihua

摘要

当前个性化电影推荐方法仅基于用户历史评分的均值进行简单加权推荐,难以捕捉用户偏好的复杂动态变化,导致推荐误差较大。因此,文章提出基于协同过滤与注意力机制的个性化电影推荐研究。通过图数据库导入用户观影行为数据以及电影的相关信息,构建用户-电影关系图,利用机器学习算法分析关系数据,实现对用户未来标注行为的预测。基于用户对电影目标信息的标注行为,建模用户的电影偏好。在此基础上,引入协同过滤模型,并结合注意力机制,生成针对特定用户的个性化偏好模型。借助自然语言处理与机器学习技术构建电影的多维度标签体系,并实现自动标签抽取。结合用户数据,构建偏好矩阵,并通过隐语义分析得到用户的偏好向量,进而生成个性化推荐列表。实验结果表明,所提方法在不同推荐列表长度下,各项关键指标均优于对比方法。特别是在NDCG值方面,随着K值的增大,所提方法仍保持最高的推荐质量,且平均绝对偏差被有效控制在0.3以下,证明该方法具有较高的推荐准确性。

关键词

协同过滤;注意力机制;用户偏好;电影标签;个性化电影推荐

doi: 10.3969/j.issn.1672-9528.2025.10.015

0 引言

随着电影产业的蓬勃发展,电影资源的种类日益丰富、数量持续增多。面对海量电影作品,用户想要精准找到符合自身兴趣的内容,难度越发增大。然而,传统的推荐方法在处理大规模、多维度的数据时效果不佳,难以捕捉用户与电影之间复杂且动态变化的关系,在一定程度上限制了推荐的精准性,进而影响了用户满意度。在电影个性化推荐这一研究领域,已有多种方法被提出并投入实际应用。周晨曦等人^[1]以电影推荐为核心,通过区分用户行为与兴趣的相似性、融合多源数据构建用户画像、优化链路预测,同时改进兴趣相似性的计算方法以及衡量链接作用的方法,实现了个性化推荐。但该方法在捕捉用户动态偏好方面能力有限,难以应对用户兴趣的快速变化。王新武^[2]基于隐马尔可夫模型构建了个性化推荐系统,采用三级递进推荐设计,针对不同用户群体进行推荐。该系统结合兴趣关键词加权以及用户兴趣时间转移阈值,实现了资深用户在线视频内容的推荐。但在处理长序列数据时,容易出现误差累积,从而影响推荐的准确性。刘瑞等人^[3]基于观影心理动机划分用户的长短期兴趣并量化,结合时间权重拟合短期兴趣的演化规律,最终融合评分与兴

趣值构建评分矩阵,以实现电影个性化推荐。但在用户兴趣切换频繁的情况下,推荐误差较大。魏子钦等人^[4]的混合推荐算法结合了多种推荐策略,但在处理极端稀疏数据时,由于数据不足,模型训练不充分,导致推荐效果不理想。针对上述问题,本文提出了一种基于协同过滤与注意力机制的个性化电影推荐方法。通过构建用户-电影图数据库,揭示用户与电影之间的直接关联以及潜在关联,并借助协同过滤算法深入挖掘用户与电影之间的潜在关联。相较于传统方法,该方法能够更精准地捕捉用户与电影之间的复杂关系,有效提升推荐系统的准确性和多样性,为个性化电影推荐提供了新的解决方案。

1 基于协同过滤与注意力机制的个性化电影推荐研究

1.1 预测用户目标信息标注行为

在个性化电影推荐系统中,用户与电影之间的关系复杂且处于动态变化中。传统方法在处理大规模、多维度的数据时表现欠佳,影响推荐的精准性,进而降低了用户满意度^[5]。通过将用户的观影行为数据和电影信息导入图数据库,能够构建用户-电影图。该图不仅能揭示用户与电影之间的直接关联和潜在关联,还能展现社群结构。

以图数据库中的节点数据为基础,计算用户相似度^[6],计算公式为:

$$T(u_i, u_j) = \frac{u_i \cdot u_j}{\|u_i\| \cdot \|u_j\|} \quad (1)$$

1. 广东理工学院 广东肇庆 526100

[基金项目] 广东理工学院科技项目“人工智能”(2024KDZK001)

式中： T 表示用户相似度； u_i 、 u_j 表示用户特征向量。

基于用户观影偏好相似度的计算分析结果，构建精细化的用户画像模型；深入挖掘图数据库中关系边所蕴含的信息，精准识别并详细记录用户的各类标注行为，通过统计分析这些标注行为的出现频次，洞察用户偏好的动态演变趋势以及市场潜在需求的变化方向；同时，借助先进的机器学习算法，对图结构中的关系数据进行深度整合与建模，开展前瞻性的预测分析，提前准确预判用户未来的标注行为模式^[7]。预测公式为：

$$P(A|B) = \frac{P(B|A)}{P(B)} \cdot \frac{1}{T(u_i, u_j)} \quad (2)$$

式中： A 表示用户未来标注行为； B 表示已知用户行为； P 表示用户标注行为的预测结果。

参考预测结果，提前给用户推荐具有高概率标注行为的电影。

1.2 基于协同过滤与注意力机制构建用户偏好模型

为捕捉用户电影偏好，基于用户对电影目标信息的标注行为构建偏好模型。分析用户与电影之间的关联网路以及观影行为数据，提取深层次特征。引入协同过滤模型并融合注意力机制，构建用户电影偏好模型。依据用户偏好搭建综合模型。

该模型训练公式为：

$$M(u_i) = \frac{\sum_j S(i, j)}{P(A|B) \cdot I(m)} \quad (3)$$

式中： m 表示模型训练参数； S 表示用户偏好电影信息集合； I 表示符合用户偏好电影特征相似性标准的其他电影信息集。以训练数据为基础，构建用于刻画用户电影偏好的向量，其表达式为：

$$p(u) = \sum w(i, j) \cdot F_i \cdot M \quad (4)$$

式中： F 表示特征权重向量； p 表示偏好向量； w 表示注意力权重。以偏好向量为基础，构建用户电影偏好模型：

$$f = \min \sum (r_i - \hat{r}(\theta))^2 + p(u) \cdot \lambda \|\theta\|^2 \quad (5)$$

式中： r 表示用户对电影信息的评分数值； $\hat{r}$ 表示 r 的预测值； λ 表示负向激励因子； θ 表示模型训练数据集合； f 表示偏好模型。

将收集到的相关数据导入到模型之中，进而生成针对特定用户的个性化电影偏好模型。遵循此操作流程，为全体用户依次完成偏好模型的构建工作，最终整合形成综合性的电影偏好模型。

1.3 个性化推荐电影资源

搭建涵盖多种维度属性的电影标签系统，并实现标签的自动化提取。整合用户标注操作和偏好模型构建用户-标签

偏好矩阵，利用隐语义分析生成用户标签偏好向量，经算法匹配标签后生成个性化电影推荐列表^[8]。该方案流程如图1所示。




图1 个性化电影资源推荐

依托用户的历史观影行为数据以及标注行为记录，运用数据分析与建模技术，构建能够精准刻画用户与标签之间偏好关系的用户-标签偏好矩阵^[9]。矩阵中的元素反映了用户针对特定标签所表现出的偏好程度差异^[10]。其计算公式为：

$$C = \frac{f(i, t)}{|u(\chi)|} \quad (6)$$

式中： t 表示矩阵项； χ 表示电影资源数据库； C 表示偏好矩阵。

运用隐语义分析方法，确定每位用户针对所有标签的偏好权重，进而构建能够反映用户标签偏好的标签偏好向量。归一化处理标签权重^[11]，即：

$$W = \frac{C}{\sqrt{L^2 + (\beta + 1)^2}} \quad (7)$$

式中： W 表示标签权重数值； β 表示标签集合； L 表示标签名称字节量度。

以电影资源所对应的标签集合为基础，借助通过大量用户行为数据训练得到的用户偏好模型，生成反映用户标签偏好的标签偏好向量，并基于向量相似度计算等算法，获取电影资源与用户之间的匹配程度。生成用户偏好推荐列表，计算公式为：

$$Z = \frac{1}{l \cdot \gamma^2 + h \cdot W} \quad (8)$$

式中： h 表示用户需求频次； l 表示电影数量； γ 表示电影资源覆盖范围； Z 表示电影推荐列表。

通过上述方案，成功实现了个性化电影推荐。

2 实验结果与讨论

2.1 数据集

本文采用 MovieLens-250k、MovieLens-5M 和 Netflix-Small 数据集，对本文模型进行测试。各数据集的基本特征如表1所示。

表1 数据集信息

数据集	交互数	项目	用户	稀疏/%
MovieLens-250k	100 000	1 682	943	93.7
MovieLens-5M	1 000 209	3 706	6 040	95.5
Netflix-Small	270 121	1 000	8 089	96.6

在表1所涉及的数据集中，针对每个用户，随机挑选出

其评分记录的 80% 来构建训练集, 将剩下的 20% 作为测试集。

2.2 评价指标

为科学评估基于协同过滤与注意力机制的个性化电影推荐模型所生成推荐列表的质量, 选用 F_1 值、归一化折损累计增益 NDCG 以及个性化电影推荐中平均绝对偏差作为推荐效果的评价指标。

F_1 值计算公式为:

$$F_1 = \frac{2 \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$\text{Precision} = \frac{1}{N} \sum_{i=1}^N \frac{|I_p(u_i) \cap I_a(u_i)|}{|I_p(u_i)|} \quad (9)$$

$$\text{Recall} = \frac{1}{N} \sum_{i=1}^N \frac{|I_p(u_i) \cap I_a(u_i)|}{|I_a(u_i)|}$$

式中: Precision 表示推荐列表的精度; Recall 表示推荐列表的召回率。

NDCG 计算公式为:

$$\text{NDCG} = \frac{1}{|U|} \sum_{u \in U} \frac{\text{DCG}_u}{\text{idCG}_u} \quad (10)$$

$$\text{DCG}_u = \sum_{id=1}^K \frac{2^{\text{rel}_{id}-1}}{\log_2(id+1)}$$

式中: id 表示电影在推荐列表中的排序位置; DCG_u 表示用户 u 的折损累计增益; rel_{id} 表示排序为 id 的电影是否在用户实际观看或喜欢的电影集合中, 如果在, 则 $\text{rel}_{id}=1$; 如果不在, 则为 $\text{rel}_{id}=0$ 。

平均绝对偏差计算公式为:

$$K = \alpha - \left(1 + \frac{\phi}{\phi \times \sum_{e=1}^e ve + \alpha^2} \right) + \phi \alpha \quad (11)$$

式中: α 表示推荐范围; e 表示预设推荐频次; ϕ 表示推荐均方差值; v 表示等效偏差度量; K 表示平均绝对偏差。

2.3 实验方法

为验证所提方法的有效性, 将其与以下两类具有代表性的方法展开对比实验: 方法 1: 基于用户画像和链路预测的电影个性化推荐研究; 方法 2: 基于混合推荐算法的电影推荐研究。

完成上述设计后, 正式进行实验。

2.4 实验结果分析

结合实验得出的测试结果, 进行对比分析, 其中 F_1 值如图 2 所示。




图 2 F_1 值对比结果

从图 2 中可以看出, 本文所提方法展现出更优的推荐性能。在不同推荐列表长度值的情况下, 该方法的各项关键指标值均显著高于对比方法。这一结果表明, 通过引入注意力机制对用户历史行为进行加权处理, 并结合协同过滤算法挖掘用户与电影之间的潜在关联, 能够有效提升推荐系统的准确性和多样性。

为进一步验证该方法在不同推荐场景下的稳定性与有效性, 对推荐列表长度为 K 时, NDCG 值的变化情况进行了详细分析, 结果如图 3 所示。




图 3 NDCG 值对比结果

从图 3 中可以看出, 随着推荐列表长度 K 值的不断增大, 3 种对比方法的 NDCG 值均呈现下降趋势, 但基于协同过滤与注意力机制的方法始终保持着最高值。这一现象表明, 该方法在处理长列表推荐任务时, 仍能保持较高的推荐质量, 有效避免了推荐结果随列表长度增加而质量下降的问题。

在个性化电影推荐中, 平均绝对偏差 (MAE) 是衡量推荐系统精度的重要指标之一。本文方法在不同实验条件下的 MAE 值如图 4 所示。从图 4 中可以看出, 本文所提方法最终得出的平均绝对偏差被有效控制在 0.3 以下。




图 4 平均绝对偏差对比结果

这一结果表明, 在充分考量用户个性化特征和电影属性差异的基础上, 该方法能够准确预测用户对电影的评分, 推荐方向明确且精准度较高。同时, 较低的 MAE 值也反映出该方法具有较强的稳定性和泛化能力, 能够适应不同用户群体的需求变化, 具有实际的推广应用价值。

3 结语

本文通过构建用户 - 电影图数据库, 深入挖掘用户的潜在偏好, 并引入注意力机制对用户历史行为进行加权处理, 并融合协同过滤算法, 挖掘用户与电影之间的潜在关联, 有效提升了推荐系统的准确性和多样性。面对大规模多维度数据及交互数据稀疏、新用户新电影缺历史数据挑战, 该方法依托结构关联信息推断偏好, 助力个性化推荐。然而, 该方法仍存在一定不足, 如对用户动态偏好的捕捉能力有待进一步提升, 在处理极端稀疏数据时, 性能优化方面也面临挑战。未来, 将探索融合更多元化的用户行为数据, 如社交网络信息、观影评论等, 以更全面地刻画用户偏好。同时, 将研究更高效的模型压缩与加速技术, 提升推荐系统的实时响应能力, 从而更好地满足用户不断增长的个性化需求。

近水面协同对抗博弈模型的构建与实现

邹修玮¹
ZOU Xiuwei

摘要

自主水下航行器 (autonomous underwater vehicle, AUV) 凭借其具备的自主导航、隐蔽性强、可长时间在复杂水下环境执行任务等特点, 在水下对抗中扮演着关键角色, 已成为各国提升水下作战能力的重要装备。在水下多 AUV 对抗场景中, 目标分配问题是决定作战效能的核心因素。合理的目标分配能够优化 AUV 的资源利用, 充分发挥其作战优势, 提高任务完成的成功率。反之, 不合理的目标分配可能导致 AUV 资源浪费、任务冲突, 甚至无法达成作战目标。基于此, 文章构建了基于动态博弈理论的数学模型, 并设计了纳什均衡值求解算法。通过引入混合策略应对不确定性, 适应度函数将求解转化为优化问题。此外, 采用粒子群优化算法迭代搜索最优混合策略, 仿真结果表明: 所提算法能有效找到纳什均衡解, 为制定对抗策略提供了科学依据。

关键词

水下多 AUV 对抗; 纳什均衡; 粒子群优化算法

doi: 10.3969/j.issn.1672-9528.2025.10.016

0 引言

海洋作为连接世界各国的重要纽带, 其战略意义日益凸显, 已成为各国维护国家主权、保障经济发展和提升国际影响力的关键领域。海洋资源的开发利用、海上贸易通道的安全维护以及海洋权益的保护, 都对国家的发展和国家安全至

重要。随着海洋战略地位的提升, 水下作战领域的重要性也愈发显著。自主水下航行器 (autonomous underwater vehicle, AUV) 凭借其具备的自主导航、隐蔽性强、可长时间在复杂水下环境执行任务等特点, 在水下对抗中扮演着关键角色, 已成为各国提升水下作战能力的重要装备^[1]。

在水下多 AUV 对抗场景中, 目标分配问题是决定作战效能的核心因素。合理的目标分配能够优化 AUV 的资源利

1. 扬州大学物理科学与技术学院 江苏扬州 225002

参考文献:

- [1] 周晨曦, 赵天驰, 张玲玲. 基于用户画像和链路预测的电影个性化推荐研究 [J]. 系统科学与数学, 2024, 44(6): 1586-1607.
- [2] 王新武. 基于隐马尔可夫模型的在线视频个性化推荐研究 [J]. 数字通信世界, 2023(9): 1-4.
- [3] 刘瑞, 陈烨. 考虑长短期兴趣及其演化的电影个性化动态推荐研究 [J]. 数据分析与知识发现, 2024, 8(1): 80-89.
- [4] 魏子钦, 单豫洲, 梁艳美. 基于混合推荐算法的电影推荐研究 [J]. 信息与电脑 (理论版), 2022, 34(9): 166-168.
- [5] 李彭. 基于用户特征与信任度的协同过滤推荐算法 [J]. 现代信息科技, 2024, 8(24): 49-53.
- [6] 王锐, 王永, 刘金源, 等. 基于 Rényi 差分隐私的图卷积协同过滤推荐算法 [J]. 软件学报, 2025, 36(3): 1202-1217.
- [7] 王永, 李行健, 邓江洲. 融合注意力机制的残差神经网络协同过滤推荐模型 [J]. 运筹与管理, 2024, 33(10): 201-208.

- [8] 王宁, 李然, 王客程, 等. 基于神经网络和注意力机制的协同过滤推荐算法的研究 [J]. 现代电子技术, 2024, 47(20): 95-100.
- [9] 徐远宏. 基于协同过滤的农业平台学习资源个性化推荐方法探究 [J]. 科技资讯, 2024, 22(16): 174-176.
- [10] 崔春生, 魏盟, 车利斌, 等. 基于概率语言术语集的非个性化推荐算法研究 [J]. 系统科学与数学, 2023, 43(11): 2990-3010.
- [11] 景楠, 周正茜, 袁戟. 基于宽度学习和协同过滤的在线信息推荐算法 [J]. 计算机应用与软件, 2023, 40(5): 279-287.

【作者简介】

时小芳 (1991—), 女, 河南濮阳人, 硕士研究生, 讲师、教研室主任, 研究方向: 计算机视觉、机器学习。

向志华 (1982—), 女, 湖南邵阳人, 硕士, 副教授、教研室主任, 研究方向: 软件工程、机器学习。

(收稿日期: 2025-04-23 修回日期: 2025-10-14)