

基于增量聚类的动态自适应序贯三支协同推荐

彭莉莎¹, 章荣溢¹, 彭娟娟^{2†}, 黄锦涛³

(1. 浙江财经大学 信息技术与人工智能学院, 杭州 310018; 2. 浙江财经大学 管理学院, 杭州 310018;
3. 西北工业大学 网络空间安全学院, 西安 710072)

摘要: 三支协同推荐将三支决策思想引入协同过滤中, 在处理推荐不确定问题上取得了进展, 但现有三支协同过滤方法仍存在两方面不足: 首先, 基于个体邻域相似度的判定往往忽视对象间的群体共性, 导致低频对象被忽略并产生推荐不平衡; 其次, 采用静态阈值或离线调参的策略在持续获得反馈的动态推荐场景中难以及时调整决策边界, 进而增加误推荐率. 针对上述问题, 提出一种基于增量聚类的动态自适应序贯三支协同推荐 (IC-DASTCR), 具体而言, 该模型涵盖两个创新模块: 1) 将增量聚类引入序贯三支推荐, 用于刻画群体共性, 提高推荐准确率并降低决策代价. 2) 基于随机梯度下降算法, 设计了一种动态阈值自适应机制, 以在线更新决策边界并进一步提高推荐准确性. 在多个公开数据集与真实场景上与若干推荐算法进行了实验对比与分析, 结果表明, 本研究构建的模型 IC-DASTCR 具有更优的推荐质量与效率.

关键词: 序贯三支决策; 推荐系统; 协同过滤; 聚类方法; 在线学习; 动态环境; 个性化推荐

中图分类号: TP18 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.1191

引用格式: 彭莉莎, 章荣溢, 彭娟娟, 等. 基于增量聚类的动态自适应序贯三支协同推荐 [J]. 控制与决策, xxxx, x(x): xxxx-xxxx.

Incremental clustering-based dynamic adaptive sequential three-way collaborative recommendation

Peng Li-sha¹, Zhang Rong-yi¹, Peng Juan-juan^{2†}, Huang Jin-tao³

(1. School of Information Technology and Artificial Intelligence, Zhejiang University of Finance and Economics, Hangzhou 310018, China; 2. School of Management, Zhejiang University of Finance and Economics, Hangzhou 310018, China; 3. School of Cybersecurity, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: The three-way collaborative filtering recommendation introduces the decision-making philosophy of three-way thinking into collaborative filtering, achieving success in addressing the uncertainties in recommendations. However, existing three-way collaborative filtering methods still face two challenges: firstly, the determination of individual neighborhood similarity often overlooks the commonality among subjects, leading to the neglect of low-frequency items and resulting in imbalanced recommendation; secondly, using static thresholds or offline parameter tuning strategies in dynamic recommendation scenarios, where continuous feedback is received, makes it difficult to timely adjust decision boundaries, thereby increasing the rate of false recommendations. To address these issues, an incremental clustering-based dynamic adaptive sequential three-way collaborative recommendation (IC-DASTCR) is proposed. Specifically, this model includes two innovative modules: 1) incremental clustering is introduced into sequential three-way recommendation to characterize group commonality, which improves recommendation accuracy and reduces recommendation costs; 2) a dynamic threshold adaptive mechanism is designed based on the stochastic gradient descent algorithm, for online update decision boundaries and further improve the accuracy of recommendations. Experiments and comparisons with several recommendation algorithms on multiple public datasets and real-world scenarios demonstrate that the proposed IC-DASTCR achieves superior recommendation quality and efficiency.

Keywords: sequential three-way decision; recommendation system; collaborative filtering; clustering; online

收稿日期: 2025-11-18; 录用日期: 2026-03-10.

基金项目: 国家自然科学基金青年科学基金项目 (62406278); 浙江省科技厅“尖兵领雁+X”科技计划项目 (2026 C02A2002); 浙江省自然科学基金一般基金项目 (Y24G010019); 浙江省哲学社会科学规划课题重大项目 (26QNYC021ZD).

通信作者. E-mail: pengjj81@zufe.edu.cn.

learning; dynamic environments; personalized recommendation

1 引言

1.1 研究背景和意义

推荐系统^[1]是一种通过挖掘用户历史行为、兴趣特征及对象属性,帮助用户从海量信息中筛选出最相关内容的个性化信息过滤技术,在电子商务、金融投资、视频平台等众多领域发挥着重要作用^[2].因此,构建高质量的推荐系统对于在各类场景中向用户提供准确且具有个性化的建议具有重要意义.

作为推荐系统最常用的方法,协同过滤推荐^[3]是一种基于用户历史行为和物品相似度的推荐模型,具有个性化程度高、推荐领域广的优势.在经典的协同过滤的研究基础上,He等人^[4]构建基于神经网络的协同过滤的框架,通过非线性特征交互提升模型表达能力;Ou等人^[5]融合显式与隐式反馈,有效提升了推荐性能;Zhang等人^[6]提出针对流行度分布漂移的协同过滤框架,在未知目标分布条件下提升推荐系统的性能;He等人^[7]提出轻量化的增强图卷积网络协同推荐模型 LightGCN,在大规模稀疏数据集上有效提升了推荐效果.然而,经典协同过滤算法多采用二值决策框架,在实际推荐过程中,当推荐信息的不足时,容易产生不确定性,导致误推荐或者遗漏潜在推荐对象.

近年来,三支决策^[8]在推荐系统得到广泛研究,涌现出众多三支推荐^[9-10]和三支协同推荐方法.这些方法基于粗糙集的邻域相似关系划分决策边界,有效解决了协同推荐方法存在的推荐不确定问题.例如,Zhang等人^[11]将朴素三支决策和协同过滤算法相结合,构建面向智慧城市的三支朴素贝叶斯协同过滤推荐模型,有效解决了评分数据稀疏的问题.Xie等人^[12]提出考虑用户可变性的混合三支推荐,在交互稀疏场景下提高推荐的鲁棒性与准确性.

面对持续变化的推荐环境,研究者开始关注动态场景下的三支协同推荐方法,序贯三支协同推荐将序贯三支决策^[13]引入协同推荐过程,针对不同推荐场景选择相应决策阈值或调参策略.Liu等人^[14]构建基于矩阵分解的三支决策动态粒度推荐,以解决静态二支推荐的局限性,在保持推荐质量的情况下降低了决策成本.Ye等人^[15]针对推荐信息多层次特性被忽略的问题,提出基于协同深度学习的成本敏感型序贯三支推荐方法,在多步流程中有效降低推荐错误.综合现有研究,将三支推荐与协同过滤结合,有助于提高推荐算法的推荐质量,并且降低了推荐成本^[16].

然而,现有的序贯三支协同推荐方法仍然存在两点不足:一是基于个体邻域相似度的判定往往忽视对象间的群体共性,低频对象在推荐结果中出现率低,容易遗漏潜在的相关推荐项,导致推荐不平衡,使推荐准确率下降与推荐代价增加;二是用户兴趣随着时间变化,但采用静态阈值或离线调参的策略在持续获得反馈的动态推荐场景中无法快速适应用户偏好变化,难以及时调整决策边界,造成误推荐率上升.

已有研究表明,聚类方法能够反应群体特征,然而传统聚类方法面临着动态适应性不足的问题,相较于传统静态聚类,增量聚类能够持续刻画用户兴趣与群体结构的演化过程,更适合动态推荐场景^[17].基于上述特性,在推荐系统中引入增量聚类可以有效缓解推荐对象间群体共性刻画不足的问题^[18].此外,将增量聚类方法融入三支决策框架,有助于在增量数据环境下高效识别相似群体并提升推荐效率^[19].然而,增量聚类侧重数据分布变化,难以利用用户对推荐结果的即时反馈,而在线学习方法能够有效弥补这一不足.Sánchez等人^[20]将增量聚类与在线学习相结合,构建在线增量聚类框架用于提高算法的分类准确率与执行效率.因此,在增量聚类过程中引入在线学习机制,能够将持续到达的二元反馈纳入模型更新过程,增强模型在反馈驱动场景下的自适应能力.

综上,鉴于增量聚类在持续刻画群体共性的独特优势,以及在线学习在自适应更新层面对增量聚类的促进作用.本文针对序贯三支协同推荐方法在低频对象易被忽略与决策边界难以动态调整的不足,提出一种基于增量聚类的动态自适应序贯三支协同推荐 (Incremental clustering-based dynamic adaptive sequential three-way collaborative recommendation, IC-DASTCR),具体过程为:首先,通过 K-means++聚类方法得到对象属性的聚类中心,依据待推荐对象与各聚类中心的相似性进行序贯三支协同推荐,然后结合用户的二元反馈,更新序贯三支阈值和聚类中心,最后重复此过程直至完成对所有对象的动态推荐.与现有三支协同推荐方法相比,IC-DASTCR可有效提升低频对象的推荐覆盖率与准确率,同时在动态反馈环境中快速适应用户偏好变化.实验结果显示,IC-DASTCR在动态与不确定环境下提升了推荐效果,降低了决策成本.表1对比了IC-DASTCR与多种推荐模型在不同问题上的适用性.

表1 IC-DASTCR 与多种推荐模型在不同问题上的适用性

方法	不确定性处理	动态适应性	成本敏感	用户反馈	群体相似性
基于记忆的协同过滤 ^[9]	否	否	否	否	否
Zhang et al.'s model ^[6]	否	否	否	否	否
Zhang et al.'s model ^[9]	是	否	是	否	否
Zhang et al.'s model ^[10]	是	否	是	否	是
Xie et al.'s model ^[12]	是	否	是	否	否
Ye et al.'s model ^[15]	是	是	是	否	否
Ye et al.'s model ^[16]	是	否	是	否	否
Liu et al.'s model ^[17]	否	是	否	是	是
Lee et al.'s model ^[18]	否	是	否	否	是
IC-DASTCR(本文方法)	是	是	是	是	是

1.2 贡献

主要提出基于增量聚类的动态自适应序贯三支协同推荐 IC-DASTCR, 其主要创新点和贡献如下:

1) 针对现有三支协同推荐容易忽视对象间群体共性、低频对象覆盖率低, 导致推荐准确率下降与推荐代价增加的问题, 本文将增量聚类方法引入序贯三支决策过程, 依据对象与各聚类中心的余弦相似度进行三支推荐, 并增量维护簇结构. 从而弥补单一邻域相似度判定的不足和更准确刻画对象间的群体共性, 避免遗失潜在推荐项, 提升推荐准确率并降低推荐代价.

2) 现有序贯三支协同推荐普遍采用静态阈值或离线调参策略, 难以在持续到达的二元反馈中及时调整决策边界, 导致误推荐率上升. 为此, 本文提出结合二元反馈的动态阈值自适应机制, 利用随机梯度下降算法根据用户反馈实时更新决策权重和三支阈值, 以进一步提升动态反馈下的推荐准确率.

2 相关理论

2.1 协同推荐模型

协同过滤是推荐系统领域的基础方法, 其核心思想为通过挖掘用户—对象交互行为中的相似性来推断用户偏好. 经典的基于记忆的协同过滤侧重于利用用户或对象之间的邻域相似度进行直接推荐, 而基于模型的协同过滤通过学习用户与物品的潜在因子以提升稀疏情形下的泛化能力^[21]. 近年来, 随着侧信息技术的发展, 研究者开始将属性特征及其他外部信息与协同信号结合, 以提升推荐的表达能力^[22]. 结合上述研究, 为更准确反映用户偏好, 本文在偏好度量中引入对象特征, 并据此与用户反馈相结合计算相似度以进行推荐.

2.2 三支与序贯三支决策理论

"三域-三策略"是三支决策的主要思想: 通过分析对象的属性值之间的相关性, 将论域中的对象划

分成互不相交的三个域, 然后再针对这三个域中的对象分别制定三种策略(接受策略 P、延迟策略 B 和拒绝策略 N), 下面是三支决策模型.

定义 1 在三支决策中, 将有限非空对象全集(论域) U 划分为三个相对独立的区域: 正域(POS)、边界域(BND)、负域(NEG), 对应地定义三种决策动作: $A = a_P, a_B, a_N$, 分别表示将对象划分到决策属性 D 的正域、边界域或负域. $\{\lambda_{PP}, \lambda_{BP}, \lambda_{NP}\}$ 和 $\{\lambda_{PN}, \lambda_{BN}, \lambda_{NN}\}$ 分别表示当决策对象 x 属于 D 和不属于 D 时分别做出 a_P, a_B, a_N 三种决策的损失函数.

三支决策损失函数的初始值一般由决策专家根据对象耗费的时间、人力资源或经济状况等度量标准给出. 一般情况下, 接受正域中的对象和拒绝负域中的对象损失较小, 而拒绝正域中的对象和接受负域中的对象损失较大.

根据贝叶斯期望损失最小化的决策规则, 三支决策的阈值 α, β 可由决策损失函数计算得出:

$$\begin{cases} \alpha = \frac{\lambda_{PN} - \lambda_{BN}}{(\lambda_{PN} - \lambda_{BN}) + (\lambda_{BP} - \lambda_{PP})}, \\ \beta = \frac{\lambda_{BN} - \lambda_{NN}}{(\lambda_{BN} - \lambda_{NN}) + (\lambda_{NP} - \lambda_{BP})}. \end{cases} \quad (1)$$

定义 2 为适应在线推荐场景, 用 $X = \{x_1, x_2, \dots, x_t\}$ 表示时刻 $1, \dots, t$ 到达的推荐对象序列. 对于 t 时刻到达的对象 x_t , 计算其属于某一决策类 D 的条件概率 $P(x_t | D)$, 得到对应的三支决策规则如下:

- 1) 若 $P(x_t | D) > \alpha$, 则 $x_t \in POS$;
- 2) 若 $\beta \leq P(x_t | D) \leq \alpha$, 则 $x_t \in BND$;
- 3) 若 $P(x_t | D) < \beta$, 则 $x_t \in NEG$.

序贯三支决策是三支决策理论在时间维度上的扩展, 是解决现实决策中动态多步骤问题的有效工具^[23]. 其核心思想是通过渐进更新决策规则, 将决策过程划分为多个阶段, 从而在时间序列中逐步优化决策结果, 实现动态环境下的高效决策^[24]. 具体而言, 首先基于初始阈值将所有对象按后验概率分入正域、边界域和负域, 其中边界域对象因不确定性而被暂时保留; 随后针对边界域对象收集信息重新进行评估, 再重新划分, 将高于或低于新阈值的对象分别归入正域或负域, 其余继续进入下一轮边界域, 直至边界域中没有对象. 在推荐系统中, 序贯三支推荐往往根据不同的序贯阈值来决定对象的推荐决策^[25].

2.3 K-means++ 聚类方法

聚类分析^[26]作为信息粒化策略常被用于辅助决策过程, 是数据挖掘、模式识别等方向的重要研究内容之一. 聚类方法通过数据自身的特征寻找内在规

律,将数据划分为多个簇,能够挖掘数据中潜在的分布和结构,找到数据间的关联.Huang等人^[27]提出的基于主题的长尾产品推荐框架,将基于主题模型的方法与聚类方法相结合,在低频对象推荐的问题上提高了推荐效果.受此启发,本文将聚类方法引入推荐过程,这有助于捕捉对象间的群体共性,为模型提供结构化的先验基础.

K-means是一种经典的划分式聚类算法,其聚类划分的目标是最小化簇内平方误差函数:

$$E = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|^2. \quad (2)$$

其中, k 是簇的数量, C_i 表示第*i*个簇, x 是属于簇 C_i 的对象, μ_i 是簇 C_i 的聚类中心.

K-means++是在K-means基础上延展出的聚类初始化方法,K-means++采用一种基于距离的概率化选择策略来初始化 k 个初始聚类中心,从而显著降低初始化质量差导致陷入坏局部最优的概率,使得同一簇内的对象彼此相似度高,而不同簇之间的对象相似度低.其关键步骤可描述为:第一步,从数据集中均匀随机选取一个对象作为第一个聚类中心 C_1 ;第二步,对于每个对象 x ,计算其到已选质心集合的最小平方距离 $D(x)^2$;第三步,以概率 $p(x) = D(x)^2 / \sum_x D(x)^2$ 选取下一个聚类中心;第四步,重复步骤2-3,直至选取到指定的 k 个聚类中心.基于此,本文在聚类步骤中采用K-means++进行聚类中心初始化,以获得对推荐对象特征更为稳定的划分.

2.4 在线学习模型

在线学习策略^[28]是一种机器学习范式,其特点是数据以流的形式依次到达,模型则根据新到达的数据持续自我更新.在线学习无需一次性加载所有数据,而是逐步处理数据流中的每个对象.Xu等人^[29]提出一个三支决策结合在线流特征选择的模型,降低了特征选择的决策风险.这些研究为兼顾推荐准确率与推荐成本的推荐模型构建奠定技术基础.

随机梯度下降(Stochastic gradient descent, SGD)是在线学习的核心算法之一,其作用原理是基于每个新到对象计算损失函数 L 的随机近似梯度,并沿负梯度方向即时更新模型参数,从而在无需全量数据的情况下,使模型在线逐步逼近损失函数 L 的最小值,以下给出SGD的参数更新公式:

$$\theta_{t+1} = \theta_t - \eta_t \nabla_{\theta} \mathcal{L}((d_t, f(x_t; \theta_t))). \quad (3)$$

其中, θ_t 是第*t*次迭代的模型参数, η_t 是学习率, $\nabla_{\theta} L$ 是损失函数对参数的梯度, x_t 表示输入对象, d_t 表示

x_t 对应的真实标签.

3 基于增量聚类的动态自适应序贯三支协同推荐

为平衡推荐准确性与推荐代价,提出IC-DASTCR,通过对比待推荐对象与模型训练得到的聚类中心的余弦相似度和序贯三支决策阈值大小,做出推荐决策,并增量更新聚类中心与自适应更新决策阈值,直至完成所有对象的动态推荐.

定义3 给定二元信息系统 $I_B = \{U, A \cup D, \mu, \alpha, \beta\}$, U 表示非空有限决策对象全集,将 U 划分为两个互不相交的子集 X 与 Y ,即, $X \cup Y = U$, $X \cap Y = \emptyset$,其中 X 表示已用于模型训练的对象子集(离线训练集),用于模型的参数估计与初始训练; Y 表示训练集中尚未用于训练的对象子集(在线学习集),用于后续的增量训练或在线更新; A 表示属性全集; D 表示二元决策标签; μ 表示聚类过程中得到的聚类中心集合; α, β 为三支决策阈值.

定义4 在二元信息系统 I_B 中,采用K-means++算法,将给定的数据集 $X = \{x_1, x_2, \dots, x_m\}$ 划分为预先指定的 k 个簇 $C = \{C_1, C_2, \dots, C_k\}$,并计算得到对应的聚类中心 $\mu = \{\mu_1, \mu_2, \dots, \mu_k\}$.簇 C_i 对应的聚类中心 μ_i 的计算公式为:

$$\mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x. \quad (4)$$

其中, $|C_i|$ 表示簇 C_i 中对象的数量.

定义5 对于待训练的新对象 $y \in Y$,在协同过滤算法的基础上,参考其常用的相似度量方式,使用余弦相似度计算其与所有聚类中心 $\mu = \{\mu_1, \mu_2, \dots, \mu_k\}$ 的相似度:

$$\text{sim}(y, \mu_i) = \cos(\vec{y}, \vec{\mu}_i) = \frac{\vec{y} \cdot \vec{\mu}_i}{\|\vec{y}\| \|\vec{\mu}_i\|}. \quad (5)$$

其中, \vec{y} 是对象 y 在属性子集上的向量, $\vec{\mu}_i$ 表示聚类中心 μ_i 在同一子空间中的向量.由于本文处理的推荐场景中 \vec{y} 与 $\vec{\mu}_i$ 的各分量均非负,余弦相似度满足非负性,即, $\text{sim}(\vec{y}, \vec{\mu}_i) \geq 0$.

定义索引集合 $\mathcal{I}_{\text{accept}} = \{i \in \{1, \dots, k\} \mid D(\mu_i) = 1\}$,对新对象 y 与各聚类中心的相似度加权求和,计算得到 y 被接受的置信度:

$$p_{\text{accept}}(y) = \frac{\sum_{i \in \mathcal{I}_{\text{accept}}} \text{sim}(y, \mu_i)}{\sum_{j=1}^k \text{sim}(y, \mu_j)}. \quad (6)$$

记 $s_i = \text{sim}(y, \mu_i)$,为明确公式(6)的概率学解

释, 定义归一化权重: $w_i = cs_i / \sum_k s_k$, $\sum_i w_i = 1$. 故公式 (6) 等价于:

$$p_{\text{accept}} = \sum_{i \in \mathcal{I}_{\text{accept}}} w_i. \quad (7)$$

即, 将归一化后的相似度视为离散概率分布上的权重, p_{accept} 等于该分布在接受子集上的总概率.

定义 6 对于三支决策阈值 α, β , 采用随机梯度下降 (SGD) 更新决策规则:

$$\begin{aligned} \lambda_{BP}^{(t+1)} &= \lambda_{BP}^{(t)} - \eta \frac{\partial L}{\partial \lambda_{BP}^{(t)}} = \lambda_{BP}^{(t)} - \eta(1 - \rho), \\ \lambda_{BN}^{(t+1)} &= \lambda_{BN}^{(t)} - \eta \frac{\partial L}{\partial \lambda_{BN}^{(t)}} = \lambda_{BN}^{(t)} - \eta\rho. \end{aligned} \quad (8)$$

为避免在线优化过程中参数 λ 收敛到零值的同时还保持其可解释性, 对 λ 的更新施加下界约束. 设下界为 $\lambda_{\min} > 0$, 每次更新先按梯度下降计算, 随后进行投影: $\lambda_{t+1}^{\text{raw}} = \lambda_t - \eta_t \nabla_{\lambda} L(\lambda_t; \rho_t)$, $\lambda_{t+1} = \max(\lambda_{\min}, \lambda_{t+1}^{\text{raw}})$. 以保证 $\lambda_{t+1} \geq \lambda_{\min}$. λ_{\min} 可取为基准代价 λ^0 的比例 ($\lambda_{\min} = c\lambda^0$, $c \in [0.1, 0.5]$). 然后根据公式 (1) 更新 α, β :

$$\begin{cases} \alpha^{(t+1)} = \frac{\lambda_{PN} - \lambda_{BN}^{(t+1)}}{(\lambda_{PN} - \lambda_{BN}^{(t+1)}) + (\lambda_{BP}^{(t+1)} - \lambda_{PP})}, \\ \beta^{(t+1)} = \frac{\lambda_{BN}^{(t+1)} - \lambda_{NN}}{(\lambda_{BN}^{(t+1)} - \lambda_{NN}) + (\lambda_{NP} - \lambda_{BP}^{(t+1)})}. \end{cases} \quad (9)$$

其中, $\eta > 0$ 是控制更新幅度的学习率, 一般由观察训练损失和验证误差的变化趋势得出; $\rho > 0$ 是用户对于推荐结果的正反馈率. $\lambda_{BP} > 0$, $\lambda_{BN} > 0$ 分别为"延迟决策接受区域的损失函数"和"延迟决策拒绝区域的损失函数". 令 $L(\lambda_{BP}, \lambda_{BN}; \rho)$ 为延迟决策的代价敏感损失函数, 其表达式为:

$$L(\lambda_{BP}, \lambda_{BN}; \rho) = \lambda_{BP}(1 - \rho) + \lambda_{BN}\rho. \quad (10)$$

公式 (10) 为在当前正反馈率 ρ 下, 对两个延迟策略的损失期望加权求和, 其优化目标是 minimized $L(\lambda_{BP}, \lambda_{BN}; \rho)$, 即, 以最优策略平衡"延迟接受"和"延迟拒绝"两类错误, 从而以最小的期望代价确定合适的决策边界. $L(\lambda_{BP}, \lambda_{BN}; \rho)$ 对 λ_{BP} 与 λ_{BN} 的梯度分别为:

$$\frac{\partial L}{\partial \lambda_{BP}} = 1 - \rho, \quad \frac{\partial L}{\partial \lambda_{BN}} = \rho. \quad (11)$$

定理 1 代价敏感损失函数的收敛性. 设 t 时刻的正反馈率为 $\rho_t \in [0, 1]$, 令代价敏感损失函数 $L(\lambda_{BP}, \lambda_{BN}; \rho_t) = \lambda_{BP}(1 - \rho_t) + \lambda_{BN}\rho_t$, 并记 $\lambda = (\lambda_{BP}, \lambda_{BN})$. 设参数更新表达式为: $\lambda^{(t+1)} = \Pi_+(\lambda^{(t)} - \eta_t g_t)$, 其中 Π_+ 表示将向量投影到带下界约束的、有界且凸的可行域 $\mathcal{S} = \{\lambda : \lambda \geq \lambda_{\min} >$

$0\}$ 上. 假设随机梯度估计 g_t 满足下列条件:

(i) (无偏性与有界二阶矩) 对滤子 \mathcal{F}_{\square} 有 $\mathbb{E}[g_t | \mathcal{F}_{\square}] = \nabla_{\lambda} L(\lambda^{(t)}; \rho_t) = (1 - \rho_t, \rho_t)$, $\mathbb{E}[\|g_t\|^2 | \mathcal{F}_{\square}] \leq G^2$ 对常数 $G > 0$ 恒成立;

(ii) (步长条件) 步长序列 $\{\eta_t\}$ 满足 $\sum_{t=1}^{\infty} \eta_t = \infty$, $\sum_{t=1}^{\infty} \eta_t^2 < \infty$;

(iii) 当 $t \rightarrow \infty$, $\rho_t \rightarrow \rho \in [0, 1]$.

则序列 $\{\lambda^{(t)}\}$ 任一极限点都属于集合 $\arg \min_{\lambda \in \mathcal{S}} L(\lambda; \rho)$, 可以得出:

$$L(\lambda^{(t)}; \rho_t) \rightarrow \min_{\lambda \in \mathcal{S}} L(\lambda; \rho). \quad (12)$$

若进一步假设 $L(\cdot; \rho)$ 在 \mathcal{S} 上具有唯一最小点, 则序列 $\{\lambda^{(t)}\}$ 几乎处处收敛到该唯一最小点.

证明 取任意固定的可行点 $\lambda^* \in \mathcal{S}$. 由投影算子的非扩张性可得 $\|\lambda^{(t+1)} - \lambda^*\|^2 = \|\Pi_+(\lambda^{(t)} - \eta_t g_t) - \Pi_+(\lambda^*)\|^2 \leq \|\lambda^{(t)} - \eta_t g_t - \lambda^*\|^2$, 展开 $\|\lambda^{(t)} - \eta_t g_t - \lambda^*\|^2$ 并在条件 \mathcal{F}_{\square} 下取条件期望, 利用无偏性与有界二阶矩假设, 可得到 $\mathbb{E}[\|\lambda^{(t+1)} - \lambda^*\|^2 | \mathcal{F}_{\square}] \leq \|\lambda^{(t)} - \lambda^*\|^2 - 2\eta_t \langle \nabla_{\lambda} L(\lambda^{(t)}; \rho_t), \lambda^{(t)} - \lambda^* \rangle + \eta_t^2 G^2$.

由于 $L(\cdot; \rho_t)$ 关于 λ 为仿射函数, 应用凸函数不等式 $\langle \nabla f(x), x - y \rangle \geq f(x) - f(y)$, 得 $\mathbb{E}[\|\lambda^{(t+1)} - \lambda^*\|^2 | \mathcal{F}_{\square}] \leq \|\lambda^{(t)} - \lambda^*\|^2 - 2\eta_t (L(\lambda^{(t)}; \rho_t) - L(\lambda^*; \rho_t)) + \eta_t^2 G^2$.

记 $X_t = \|\lambda^{(t)} - \lambda^*\|^2$, $A_t = 2\eta_t (L(\lambda^{(t)}; \rho_t) - L(\lambda^*; \rho_t))$, $B_t = \eta_t^2 G^2$, 则不等式可写为条件形式 $\mathbb{E}[X_{t+1} | \mathcal{F}_{\square}] \leq X_t - A_t + B_t$. 注意到 $\sum_{t=1}^{\infty} B_t = \sum_{t=1}^{\infty} \eta_t^2 G^2 < \infty$, 因此条件中以 $O(\eta_t^2)$ 出现的残余项均为可积项, 将不等式 $\mathbb{E}[X_{t+1} | \mathcal{F}_{\square}] \leq X_t - A_t + B_t$ 与 Robbins-Siegmund 引理^[30] 的标准形式对应, 可取 $a_t \equiv 0$, $b_t := A_t$, $c_t := B_t$, 因此引理的可积性条件 $\sum_t c_t < \infty$ 得到满足, 可以得出序列 $\{X_t\}$ 几乎处处收敛, 且有 $\sum_{t=1}^{\infty} A_t < \infty$, 即, $\sum_{t=1}^{\infty} \eta_t (L(\lambda^{(t)}; \rho_t) - L(\lambda^*; \rho_t)) < \infty$.

由 (ii) 中 $\sum_t \eta_t = \infty$ 且 $L(\lambda^{(t)}; \rho_t) - L(\lambda^*; \rho_t) \geq 0$, 可以推出公式 $L(\lambda^{(t)}; \rho_t) - L(\lambda^*; \rho_t) \rightarrow 0$. 结合条件 (iii) 中的 $\rho_t \rightarrow \rho$, 以及 L 关于 (λ, ρ) 的连续性, 对于任一收敛子列 t_j , 若有 $\lambda^{(t_j)} \rightarrow \bar{\lambda}$, 可以得出: $L(\bar{\lambda}; \rho) = \lim_{j \rightarrow \infty} L(\lambda^{(t_j)}; \rho_{t_j}) = L(\lambda^*; \rho)$. 取 $\lambda^* \in \arg \min_{\lambda \in \mathcal{S}} L(\lambda; \rho)$, 由此可知任一极限点 $\bar{\lambda}$ 属于 $\arg \min_{\lambda \in \mathcal{S}} L(\lambda; \rho)$, 进一步可知: $L(\lambda^{(t)}; \rho_t) \rightarrow \min_{\lambda \in \mathcal{S}} L(\lambda; \rho)$. 再结合 $L(\cdot; \rho)$ 在 \mathcal{S} 上的唯一最小性, 则极限点唯一, 故全序列几乎处处收敛到该点. 证明成立. \square

定义 7 给定二元反馈系统 $BF = (Y, \phi)$, 其

中 $Y = \{y_1, y_2, \dots, y_m\}$ 为对象全集; $\phi: Y \rightarrow \{0, 1\}$ 为二元反馈函数, $\phi(y) = 1$ 表示用户对对象 y 的正反馈, $\phi(y) = 0$ 表示负反馈或无反馈. 定义用户正反馈率 ρ_t 为在当前学习批次对象中得到正反馈的比例:

$$\rho_t = \frac{1}{|Y_t|} \sum_{y \in Y_t} \phi(y), \rho_t \in [0, 1]. \quad (13)$$

在实际推荐过程中, 获得正反馈的对象往往远小于全集: $|\{y \in Y_t \mid \phi(y) = 1\}| \ll |Y_t|$.

定义 8 设当前聚类中心为 $\mu = \{\mu_1, \dots, \mu_k\}$, 该在线学习批次记为 $Y = \{y_1, y_2, \dots, y_m\}$, 采用增量更新聚类中心的方法: 对每一到达对象 $y \in Y$, 计算其与各聚类中心的欧氏距离并分配到最近的簇索引: $j = \arg \min_{1 \leq i \leq k} \|y - \mu_i\|$, 其中 $j = \{j_1, \dots, j_k\}$ 表示被分配的簇的索引. 随后按单对象指数移动平均 (Exponential moving average, EMA) 规则^[31]更新对应聚类中心:

$$\mu_j \leftarrow (1 - \tau) \mu_j + \tau y, \tau \in (0, 1]. \quad (14)$$

其中符号 τ 为预先给定的更新系数, 用于控制新对象对聚类中心的影响程度, 通常取值为 0.3–0.6. 若以批量 $Y_j \subset Y$ 同时更新簇 j , 则更新可推广为:

$$\mu_j \leftarrow (1 - \tau) \mu_j + \tau \cdot \frac{1}{|Y_j|} \sum_{y \in Y_j} y. \quad (15)$$

在 IC-DASTCR 中, 增量聚类方法首先影响聚类中心结构, 进而在新对象到来时改变对应的 p_{accept} , 并间接影响正反馈率 ρ_t 的取值, 进一步通过随机梯度下降过程更新参数 $\lambda_{BP}, \lambda_{BN}$, 最终影响三支阈值 α, β 的更新. 当由增量聚类方法所影响的正反馈率

$\{\rho_t\}$ 收敛于某一极限 $\rho \in [0, 1]$, 根据定理 1 可知, 参数序列 $\{\lambda^{(t)}\}$ 几乎处处收敛于集合 $\arg \min_{\lambda \in S} L(\lambda; \rho)$ 中某一极小解. 进一步地, 由于三支阈值 α_t, β_t 由 λ_t 通过连续映射计算得到, 即 $\alpha_t, \beta_t = f(\lambda_t)$, 可得 α_t, β_t 随 λ_t 收敛于相应极值. 因此, 当用户反馈程趋于稳定时, 三支阈值的自适应更新具有收敛性.

3.1 算法描述

在如图 1 所示的 IC-DASTCR 框架中, 首先, 将训练集 U 划分为离线训练集 X 与若干批次的在线学习集 $\{Y_t\}_{t=1}^T, T \in \mathbb{N}$, 利用 K-means++ 聚类方法找到离线训练集 X 的聚类中心 μ , 并初始化三支决策阈值 α, β 和在线学习的学习率 η_t 及梯度 $\nabla_{\theta} L$. 然后, 对于每一到达批次的 Y_t , 根据三支决策规则将其划分为 POS、BND、NEG, 其中, 对 POS 的对象予以推荐, 对 BND 的对象暂时保留, 对 NEG 的对象采取拒绝操作. 之后, 通过随机梯度下降算法, 结合用户的真实反馈, 动态调整损失函数值, 进而更新决策阈值 α, β 和聚类中心 μ , 得到更新后的模型并处理下一批 Y_{t+1} , 上述过程在所有批次处理完毕前循环进行, 当不再有新的在线批次时, 使用训练后的模型对待测集合 Z 进行三支推荐. IC-DASTCR 的算法步骤描述如下所示.

为便于分析 IC-DASTCR 的时间复杂度: 假设离线训练集对象总数为 N , 聚类中心数为 k , 在线学习阶段每次输入在线学习对象数为 n , 特征维度为 d , K-means++ 迭代次数上限为 I , 在线学习梯度更新次数为常数.

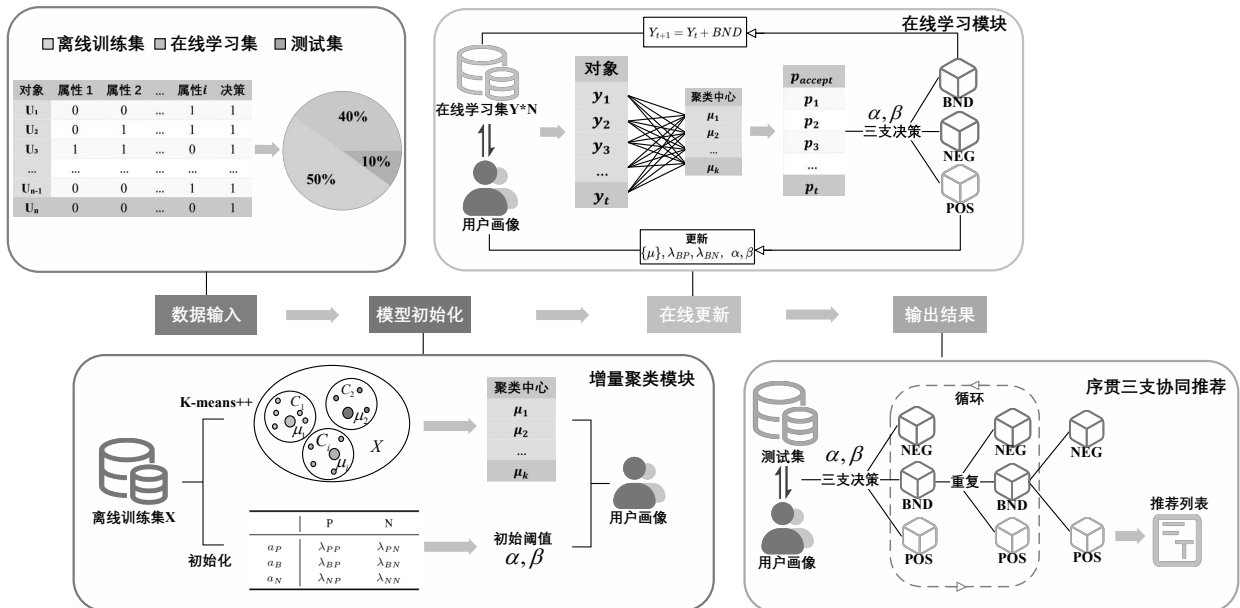


图1 IC-DASTCR 方法流程图

输入: 离线训练集 X , 在线学习集 $\{Y_t\}_{t=1}^T$, 待测集 Z .

输出: 待测集 Z 的推荐列表 Z_{pos} .

step 1: 数据预处理为0/1值的二元信息系统 I_B ;

模型初始化:

step 2: 计算离线训练集 X 的聚类中心 $\mu = \{\mu_1, \mu_2, \dots, \mu_i\}$;

step 3: 初始化阈值 α, β , 学习率 η_t 和损失函数 L ;

在线更新:

step 4: 对于每个待测对象 $y_i \in Y_t$, 计算其被接受的条件概率 $p_{accept}(y_i)$;

step 5: 根据如下规则对 y_i 进行三支划分:

若 $p_{accept}(y_i) > \alpha$, 则 $y_i \in POS$;

若 $\beta \leq p_{accept}(y_i) \leq \alpha$, 则 $y_i \in BND$;

若 $p_{accept}(y_i) < \beta$, 则 $y_i \in NEG$;

step 6: 推荐POS类对象, 待定BND类对象, 拒绝NEG类对象;

step 7: 接收用户反馈, 更新损失函数与聚类中心 μ , 进而更新决策阈值 α, β :

$$\lambda_{BPP}^{(t+1)} = \lambda_{BPP}^{(t)} - \eta_t \nabla_{\lambda_{BPP}} L;$$

$$\lambda_{BNN}^{(t+1)} = \lambda_{BNN}^{(t)} - \eta_t \nabla_{\lambda_{BNN}} L;$$

$$\alpha^{(t+1)} = \frac{\lambda_{PNN} - \lambda_{BNN}^{(t+1)}}{(\lambda_{PNN} - \lambda_{BNN}^{(t+1)}) + (\lambda_{BPP}^{(t+1)} - \lambda_{PPP})};$$

$$\beta^{(t+1)} = \frac{\lambda_{BNN}^{(t+1)} - \lambda_{NNN}}{(\lambda_{BNN}^{(t+1)} - \lambda_{NNN}) + (\lambda_{NPP} - \lambda_{BPP}^{(t+1)})};$$

step 8: 若 $t < T$, 将BND类对象加入 Y_{t+1} : $Y_{t+1} = Y_t + BND$, $t = t + 1$, 跳转至step 4. 否则, 将剩余BND的对象进行二支决策.

输出结果:

step 9: 对待测集 Z 中的对象进行推荐.

根据算法步骤描述 IC-DASTCR 的时间复杂度. step 1-step 3: 基于 K-means++ 对训练集中 N 条对象进行 I 次迭代, 初始化聚类中心时间复杂度为 $\mathcal{O}(NkId)$. step 4: 对于在线学习批内的每个对象, 计算其与 k 个聚类中心的余弦相似度耗时 $\mathcal{O}(kd)$. step 5-step 6: 将其分配至 POS、BND 或 NEG 区域, 耗时 $\mathcal{O}(1)$, 三支协同推荐的复杂度为 $\mathcal{O}(nkd)$. step 7: 进行在线学习参数更新和聚类中心更新, 统计批内正反馈率 ρ 并执行一次随机梯度下降更新参数为常数开销 $\mathcal{O}(1)$; 然后增量更新聚类中心, 聚类中心的更新对被分配到的簇为逐对象的 $\mathcal{O}(d)$ 操作, 因此在采用增量更新聚类中心时单次批处理的总时间复杂度为 $\mathcal{O}(nkd)$. 需要注意的是, I 与 k 通常远小于 n , 且 step 8 中边界域 BND 中的对象会被待定并合并到

下一批决策中. 令第 t 批次实际输入对象数为 $n_t = n + |BND_{t-1}|$, $BND_0 = \emptyset$. 当整个数据流共划分为 T 批时, 若平均每批产生 δ 条延迟对象, 总复杂度约为 $\mathcal{O}(NkId + T(n + \delta)kd)$.

4 实例分析

为验证算法可行性, 本节开展视频推荐案例分析, 视频案例如表 2 所示.

表2 用户视频案例

U	A_1	A_2	A_3	A_4	A_5	A_6	D (反馈)
U_1	1	1	0	0	1	1	1
U_2	1	1	1	0	0	1	1
U_3	0	1	1	0	0	1	0
U_4	0	0	0	1	0	0	0
U_5	1	0	0	0	1	0	1
U_6	0	0	1	1	1	1	0
U_7	1	0	0	0	1	1	1
U_8	1	1	1	1	0	1	1
U_9	1	0	0	1	0	0	1
U_{10}	1	1	1	0	1	0	1
U_{11}	1	0	0	1	0	1	1
U_{12}	1	0	1	1	1	0	1
U_{13}	0	0	1	0	1	1	0
U_{14}	0	0	1	1	0	1	0
U_{15}	1	0	0	1	1	0	1
U_{16}	1	0	1	0	0	0	1
U_{17}	1	1	0	0	1	0	1
U_{18}	0	1	1	0	1	0	0
U_{19}	0	0	1	0	0	0	0
U_{20}	0	1	1	1	0	0	0

步骤一: 对用户视频案例进行数据预处理, 表征为 0/1 属性值的二元信息系统.

表 2 中的视频案例包含 20 个视频对象 U_1-U_{20} , 每个视频对象对应 6 项测评指标 A_1-A_6 : 分别代表"科技"、"娱乐"、"美食"、"运动"、"搞笑"、"知识"六种视频包含的属性, 以及 1 项决策结果 D (D 取值为 1 表示用户"喜欢", 取值为 0 表示用户"不喜欢"). 基于此, 将视频案例划分为离线训练集 X (U_1-U_{10}), 在线学习集 Y ($U_{11}-U_{20}$).

步骤二: 计算 k 个聚类中心.

由于离线训练集对象数量为 10 条, 基于离线训练集规模和聚类结果的可解释性, 在本示例中选取 $k = 3$ 以便于说明算法流程. 根据 K-means++ 算法可得到以下 3 个聚类中心向量: $\mu_1 = [1, 1, 0, 0, 1, 1, \underline{1}]$, $\mu_2 = [0, 1, 1, 0, 0, 1, \underline{0}]$, $\mu_3 = [1, 0, 0, 1, 0, 0, \underline{1}]$. 通过聚类算法得到的聚类中心大致能够反映用户的偏好, A_1 这一指标与聚类的反馈

结果呈现较强的正相关性;而 A_3 则与聚类的反馈结果表现出负相关性.对于科技这一指标,用户表现出较高的兴趣,而对于美食这一指标,则相对兴趣较低.

步骤三:根据损失函数初始化阈值.

假定一组初始的损失函数如下: $\lambda_{PP} = 0.0$, $\lambda_{PN} = 0.7$, $\lambda_{BP} = 0.4$, $\lambda_{BN} = 0.2$, $\lambda_{NP} = 0.8$, $\lambda_{NN} = 0.0$.根据公式(1)计算得到初始化阈值 $\alpha = 0.556$, $\beta = 0.333$.

步骤四:计算视频被推荐的条件概率 p_{accept} .

根据公式(6)计算 $U_{11}-U_{20}$ 的推荐结果,并将推荐结果与用户真实反馈对比,如表3所示.

表3 推荐结果对比

视频	P_{accept}	域	推荐举措	真实反馈	推荐是否准确
U_{11}	0.807	POS	推荐	推荐	是
U_{12}	0.807	POS	推荐	推荐	是
U_{13}	0.464	BND	延迟	拒绝	-
U_{14}	0.511	BND	延迟	拒绝	-
U_{15}	1.000	POS	推荐	推荐	是
U_{16}	0.676	POS	推荐	推荐	是
U_{17}	0.792	POS	推荐	推荐	是
U_{18}	0.464	BND	延迟	拒绝	-
U_{19}	0.000	NEG	拒绝	拒绝	是
U_{20}	0.511	BND	延迟	拒绝	-

步骤五:更新阈值与聚类中心.

由表3可知,在10个待推荐的视频中,系统向用户推荐了5个视频,延迟推荐4个视频,拒绝推荐1个视频.在推荐的5个视频中,用户均表现出正反馈,即,推荐对象的正反馈率为 $\rho = 100\%$.

假设本案例中在线学习的学习率为 $\eta_t = 0.01$,根据随机梯度下降算法可得: $\lambda_{BP}^{(t+1)} = 0.400$, $\lambda_{BN}^{(t+1)} = 0.190$.根据定义6,更新阈值: $\alpha = 0.560$, $\beta = 0.322$.此时,基于反馈后的在线学习集 Y ,使用在线K-Means++方法更新后的聚类中心 μ 如下: $\mu_1 = [1, 0, 0, 0, 1, 1, 1]$, $\mu_2 = [1, 1, 1, 0, 1, 0, 1]$, $\mu_3 = [0, 0, 1, 1, 0, 1, 0]$.

步骤六:接收新的数据并重复上述过程.

根据IC-DASTCR算法,在本轮推荐的10条视频中,共有6条视频($U_{11}, U_{12}, U_{15}, U_{16}, U_{17}, U_{19}$)划入正域、4条($U_{13}, U_{14}, U_{18}, U_{20}$)划入边界域,无视频被划入负域.其中推荐的6条视频全部获得正反馈,正反馈率为 $\rho = 100\%$,模型据此更新聚类中心和三支决策阈值.对于边界域中的四条视频,若有新的在线学习集,则将边界域待定至下一轮推荐中,重复步骤和五.若无后续在线学习批次,则对于边界域中的数据进行一轮二支决策:在本案例中,给定

$p_{\text{accept}} = 0.5$ 为该层级的二支决策阈值,那么边界域中 U_{14}, U_{20} 被推荐; U_{13}, U_{18} 被拒绝.在线学习集 Y 中推荐准确率为80%.

步骤七:根据训练后的模型对待测集中的对象进行推荐.

5 实验与分析

5.1 实验数据集及实验环境

实验运行环境为VSCODE, Python3.9,设备配置为:Windows 11(64位)系统;酷睿i7 13700CPU,主频2.4GHz,16G内存.为验证所提模型的有效性,在7个UCI数据集(<https://archive.ics.uci.edu/>)上进行实验.

为消除数据缺失及属性不一致对实验的影响,对数据集进行下列预处理操作:删除存在缺失数据的数据对象,针对多元的特征属性值进行one-hot编码归一化为二元属性值,对于具有多值取值的决策属性,根据模型需求提取其中2类,将决策属性简化为二元形式,使数据集更符合二元反馈的推荐问题设定.处理后数据集的类别分布和稀疏度等信息如表4所示.

表4 实验数据集描述

数据集名称	对象数	属性数	类别分布 (正:负)	稀疏度	领域
Hepatitis	80	20	67:13	29.25%	健康与医学
Dresses Attribute Sales	99	99	40:59	88.02%	计算机科学
SPECT Heart	267	23	212:55	68.81%	健康与医学
Cylinder Bands	277	506	99:178	94.61%	物理和化学
Car Evaluation	1728	22	518:1210	71.43%	汽车评估
Mushroom	5644	99	3488:2156	77.55%	生物学
Connect4	67557	84	44473:23084	90.48%	游戏

为更好地评估模型的泛化性能,本文对数据集采用十折交叉验证,具体地,将数据集分成十份,轮流将其中9份作为训练数据,1份作为测试数据试验,最终取10次实验的指标均值用于估计模型的总体性能.

5.2 实验设计及结果分析

为评估模型性能,本文使用的评价指标如下:推荐精度通过准确率(ACC),精确率(P),召回率(R)的调和平均数 F_1 值进行衡量;推荐成本使用指标 $Cost$ 评估,在计算推荐成本时,主要考虑错误推荐所产生的成本,正确的推荐决策不产生推荐成本.各指标计算公式如下:

$$ACC = \frac{TP + TN}{TP + FP + FN + TN}, \quad (16)$$

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN}, \quad (17)$$

$$F_1 = \frac{2 \times P \times R}{P + R}, \quad (18)$$

$$Cost = \lambda_{PN} FP + \lambda_{NP} FN. \quad (19)$$

上式中, TP 与 TN 表示推荐正确的对象数, FP 与 FN 表示推荐错误的对象数. 具体而言, TP 表示对象的真实反馈为正, 预测得到的结果也为正的对象数, TN 表示对象的真实反馈为负, 预测得到的结果也为负的对象数, FP 表示对象的真实反馈为负, 预测得到的结果却为正的对象数, FN 表示对象的实际反馈为正, 预测得到的结果却为负的对象数. ACC 和 F_1 值越高, 说明推荐结果越准确、性能越优; $Cost$ 值越低, 说明模型的推荐效果越好.

1) 与其他推荐模型推荐效果对比分析

为验证 IC-DASTCR 的有效性, 选用 6 种基线模型在上述评价指标上进行对比, 各基线模型的关键参数根据其论文中的推荐配置选取, 具体如下: $CF^{[3]}$ 是一种经典的基于记忆的协同过滤推荐模型,

其中对象相似性采用余弦相似度计算; $InvCF^{[6]}$ 是一种基于不变性学习的协同过滤框架, 其中参数 $\eta = 0.01$, 嵌入维度 $emb_dim=64$; $RF-TWR^{[9]}$ 是一种经典的基于随机森林的三支推荐模型, 其中 $random_state=42$, 三支阈值 $\alpha = 0.56, \beta = 0.33$; $HTWR^{[12]}$ 是一种考虑用户可变性的混合三支推荐模型, 其中正则化系数 $\phi = 0.06$; $CFTGR^{[16]}$ 是一种基于协同过滤的三支推荐模型, 其中 $\alpha = 0.56, \beta = 0.33$; $CDL-CS3WR^{[15]}$ 是一种基于协同深度学习的多粒度序贯三支推荐模型, 其中 $\lambda_{PT} = \lambda_{NF} = 0$.

各算法在 7 个真实数据集上的 $ACC(\uparrow)$ 、 $F_1(\uparrow)$ 、 $Cost(\downarrow)$ 的均值及标准差对比分别展示在表 5-7 中. 进一步, 以 Car Evaluation 数据集为例, 以增量序列流输入数据, 改变在线学习数据比例, 比较各方法的运行时间及对应的推荐准确率和标准差, 实验结果展示在图 2 和图 3 中. 由于所选 UCI 数据集不包含时间戳信息, 为模拟在线学习场景, 按数据集中对象的原始输入顺序依次处理, 并对模型进行增量更新.

表 5-7 的实验结果表明, IC-DASTCR 在大多数数

表5 各算法在不同数据集上的 $ACC(\uparrow)$ 对比

数据集	IC-DASTCR	CF	InvCF	RF-TWR	HTWR	CFTGR	CDL-CS3WR
Hepatitis	0.838±0.177	0.838±0.177	0.575±0.115	0.813±0.140	0.813±0.128	0.775±0.156	0.838±0.186
Dresses Attribute Sales	0.636±0.083	0.514±0.155	0.486±0.135	0.606±0.138	0.597±0.116	0.626±0.092	0.566±0.063
SPECT Heart	0.831±0.222	0.307±0.156	0.566±0.066	0.738±0.306	0.786±0.194	0.748±0.155	0.775±0.328
Cylinder Bands	0.643±0.170	0.520±0.060	0.477±0.055	0.581±0.151	0.624±0.103	0.639±0.169	0.555±0.083
Car Evaluation	0.912±0.087	0.585±0.148	0.512±0.038	0.857±0.065	0.914±0.069	0.912±0.087	0.911±0.082
Mushroom	0.929±0.047	0.580±0.031	0.492±0.015	0.896±0.044	0.956±0.044	0.929±0.048	0.883±0.062
Connect+4	0.747±0.061	0.560±0.039	0.528±0.023	0.691±0.076	0.717±0.071	0.745±0.060	0.689±0.057
Avg.	0.791±0.121	0.558±0.109	0.525±0.064	0.740±0.131	0.772±0.104	0.768±0.110	0.744±0.123

表6 各算法在不同数据集上的 $F_1(\uparrow)$ 对比

数据集	IC-DASTCR	CF	InvCF	RF-TWR	HTWR	CFTGR	CDL-CS3WR
Hepatitis	0.901±0.109	0.901±0.109	0.691±0.109	0.879±0.101	0.874±0.096	0.830±0.142	0.897±0.120
Dresses Attribute Sales	0.400±0.236	0.427±0.157	0.443±0.142	0.362±0.242	0.367±0.210	0.385±0.227	0.325±0.183
SPECT Heart	0.830±0.275	0.361±0.168	0.632±0.197	0.801±0.280	0.785±0.263	0.756±0.205	0.820±0.292
Cylinder Bands	0.522±0.198	0.354±0.107	0.401±0.124	0.350±0.208	0.317±0.193	0.519±0.196	0.366±0.169
Car Evaluation	0.785±0.297	0.313±0.238	0.360±0.143	0.641±0.297	0.741±0.304	0.785±0.297	0.803±0.281
Mushroom	0.924±0.089	0.556±0.250	0.483±0.202	0.855±0.159	0.913±0.138	0.924±0.089	0.819±0.165
Connect+4	0.814±0.056	0.662±0.067	0.622±0.042	0.802±0.058	0.777±0.072	0.812±0.055	0.777±0.060
Avg.	0.739±0.180	0.511±0.157	0.519±0.137	0.670±0.192	0.682±0.182	0.716±0.173	0.687±0.181

表7 各算法在不同数据集上的 $Cost(\downarrow)$ 对比

数据集	IC-DASTCR	CF	InvCF	RF-TWR	HTWR	CFTGR	CDL-CS3WR
Hepatitis	0.91±0.99	0.91±0.99	2.65±0.66	1.10±0.80	1.12±0.73	1.39±0.97	0.92±1.06
Dresses	2.76±0.61	3.58±1.17	3.76±1.05	2.98±1.03	3.07±0.90	2.84±0.68	3.29±0.45
SPECT Heart	3.24±4.20	14.46±3.41	8.99±1.26	5.05±5.70	4.30±3.86	5.25±3.26	4.25±6.15
Cylinder Bands	7.37±3.35	9.92±1.27	10.62±1.11	8.78±3.00	8.00±2.05	7.44±3.33	9.22±1.68
Car Evaluation	11.13±10.72	53.50±19.35	61.58±5.17	19.03±8.33	11.16±9.13	11.13±10.72	11.16±9.80
Mushroom	28.17±18.95	179.15±12.87	218.56±13.85	41.16±17.36	17.87±18.19	28.17±18.95	47.17±24.32
Connect+4	1251.20±299.91	2226.73±185.83	2409.71±92.84	1472.63±361.42	1429.14±366.09	1256.34±294.29	1531.73±281.05

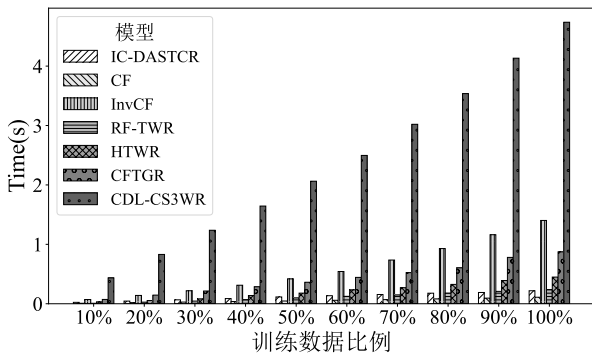


图2 不同在线学习数据比例下各方法推荐时间对比




图3 在线学习设置下各方法ACC均值和标准差

数据集上取得了较高的ACC与 F_1 ，并在Cost指标上表现出优势，验证了本文所提方法 IC-DASTCR 在保证推荐质量的同时对推荐代价的有效控制。具体而言，IC-DASTCR 在数据集 Heart 和 Connect+4 上推荐性能较优，在三个推荐指标上均表现出最佳的性能，这些优势可归因于两方面的设计：一是基于增量聚类的序贯三支推荐将低频对象的推荐依托于簇内群体特征，提高了推荐准确性；二是引入基于在线反馈的动态阈值调整机制降低了误推荐带来的代价。对于数据分布更为复杂的数据集（如 Cylinder Bands），IC-DASTCR 的推荐性能略有下降，这可能是由于“维度灾难”导致分类难度增加，推荐精度下降^[32]。

由图 2-3 可得出三点主要结论：一是随着在线数据比例的增加，IC-DASTCR 的平均耗时始终较少且增长幅度小，表明其在时间效率方面具有优势；二是 IC-DASTCR 的推荐准确率较高且对应的标准差

较小，说明 IC-DASTCR 在准确性与稳定性上均表现良好；三是与若干最新基线方法相比，IC-DASTCR 在时间效率上的优势随数据规模扩大更为明显，因此更能满足实时推荐场景低延迟的需求。

2) 模型消融性分析

为验证模型各个模块的有效性，本节在数据集 Mushroom 上选取参数 $k = 10, \eta = 0.1$ 开展消融实验，模型和各变体的相关实验如表 8 所示，表中共有两个子方法的设计：IC-DASTCR_1(去除增量聚类，保留动态阈值)、IC-DASTCR_2(保留增量聚类，去除动态阈值)。

表8 消融实验结果对比

模型	增量聚类	动态阈值	ACC	F_1	Cost
IC-DASTCR	是	是	0.929	0.924	28.17
IC-DASTCR_1	否	是	0.619	0.693	150.5
IC-DASTCR_2	是	否	0.863	0.882	54.32

由实验结果可见，各个变体模型在推荐准确性和推荐成本的性能上均低于完整模型 IC-DASTCR。具体而言，去除增量聚类模块的 IC-DASTCR_1 相较于完整模型 IC-DASTCR 的 ACC、 F_1 值分别下降 33%、25%，Cost 提高了 4 倍多；去除在线学习模块的 IC-DASTCR_2 则分别在 ACC、 F_1 下降 7%、5%。可见 IC-DASTCR_1 相较于 IC-DASTCR_2 性能退化更明显，说明增量聚类方法对 IC-DASTCR 算法的积极性影响更大，而 IC-DASTCR2 中“动态阈值”的加入则使得 IC-DASTCR 在准确率和决策代价上优化更加明显。

3) 模型参数敏感性分析

为评估 IC-DASTCR 对关键参数的敏感性，以确定参数设置的合理性，在多个数据集上分别考察聚类数 k 、阈值 α, β 及聚类中心更新系数 τ 对模型性能的影响。首先，固定 α, β, τ 值，分析模型在不同聚类数 k 值下的变化情况，如图 4 所示。然后，以 Car 数据集为例，固定 $k = 5, 25, 40$ ， α 和 β 以步长 0.03 递增， τ 以步长 0.1 递增，分析参数 k, α, β, τ 对模型性能指




图4 IC-DASTCR 在不同参数k上的表现




图5 IC-DASTCR 在不同参数组合上的 F_1 表现

标 F_1 的影响, 如图 5 所示. 在其他数据集上的结果类似, 不再赘列.

由图 4 可知, 在聚类数 k 的作用下, ACC 、 F_1 以及 $Cost$ 均呈现出“先波动后趋于稳定”的趋势. 当 k 较小时, 聚类表示不足, 导致模型准确率偏低; 当 k 逐步增加至约 20 至 25 时, 在多数数据集上 ACC 达到较优水平且 $Cost$ 保持在较低区间, 说明适度的聚类规模有助于提升推荐的准确性与稳定性. 而当 k 继续增大时, 簇划分过细导致属性表示稀疏化, 模型的推荐性能略有下降, 个别数据集如 Mushroom 下降明显, 最终趋于稳定, 说明较大的 k 值可能降低模型的推荐准确性.

由图 5 可见, 在参数 α 、 β 、 k 和 τ 的联合影响下, 模型表现出明显差异. 从整体看, 聚类数 k 对模型性能具有显著影响. $k=5$ 时模型性能较为稳定, 但 F_1 的最优水平受限; 当 $k=40$ 时模型能够达到更高的 F_1 峰值, 但不同参数配置下的性能差异更为明显. 因此在模型参数设置中应结合具体应用场景需求考虑 k 值的选取; 从局部看, 随着 α 和 β 的逐级递增, 模型总体性能分别呈现递增和递减的趋势, 且当 α 与 β 取值接近 0.7 和 0.3 时, 模型推荐性能趋于最优, 说明适当的阈值组合能够有效提升模型的 F_1 表现. 同时, 在较大的 τ 值中, 各参数配置表现类似, 而当 τ 取值过低时, 模型性能则出现明显下降. 这说明在 Car 此类特征维度较低、属性类型较为有限的数据集中, 过于保守的聚类中心更新策略不利于模型性能的提升.

4) 模型应用效果

为检验模型在真实场景中的推荐性能, 在真实数据集 MovieLens-1M(<https://grouplens.org/datasets/movielens/1m/>) 上进行实验, 该数据集基于用户对电影的评分行为, 涵盖了 100 万个评分记录, 评分范围为 1-5, 分值高低表示用户的喜好程度. 为便于二值化处理, 将 4-5 分视为推荐类, 将 1-3 分视为拒绝类. 同时为模拟在线处理场景, 将推荐记录按时间戳升序排列, 依据该顺序输入数据以进行增量更新和评

估.

实验在 MovieLens-1M 数据集上, 将 IC-DASTCR 与三种基线模型 (InvCF, HTWR, CDL-CS3WR) 和一种基于图卷积神经网络的深度协同推荐模型 LightGCN^[7] 进行比较. 具体而言, 五者的指标结果为 $ACC = \{0.587, 0.504, 0.561, 0.574, 0.535\}$; $F_1 = \{0.675, 0.545, 0.646, 0.658, 0.654\}$; $Cost = \{60464.9, 74798.3, 61911, 61977.3, 67580.4\}$. 实验结果表明, IC-DASTCR 在三个关键推荐指标上均优于相关模型或接近最优值, 这进一步验证了 IC-DASTCR 在真实数据集上推荐的有效性和优越性.

其次, 在保持测试集不变的前提下, 以步长 12.5% 递增学习数据比例 (50%-100%), 评估 IC-DASTCR 在 MovieLens-1M 数据集上的性能变化. 随着训练程度的增加, 在线 IC-DASTCR 算法性能逐渐提高, 其中, ACC 值从 0.496 增至 0.587; F_1 值从 0.427 增至 0.675; $Cost$ 值从 78089.3 降至 60464.9, 且三个指标均在训练程度到达 75% 后趋于收敛, 显示出模型的稳定性和有效性.

6 结论与展望

针对现有序贯三支协同推荐模型在现实应用场景中遇到的低频对象覆盖不足、数据动态适应性不足等问题, 本文构建了一种基于增量聚类的动态自适应序贯三支协同推荐模型 IC-DASTCR. 该模型通过引入增量聚类方法处理训练对象, 并利用在线学习机制自适应调整决策阈值, 有效应对了低频对象和动态数据的挑战. 在 7 个 UCI 数据集和 1 个真实数据集上的实验结果证明了 IC-DASTCR 的有效性及其优势.

虽然 IC-DASTCR 在多数实验场景下显著改善了推荐性能, 但仍存在以下几点值得进一步研究:

1) IC-DASTCR 模型在应用过程中对于参数 k 值的依赖性较高, 对于如何进一步提高模型对于参数的适应性, 值得深入研究.

2) IC-DASTCR 模型在特征维度较高的数据集

上表现略有下降, 如何进一步提高模型在高维数据集上的性能, 值得深入研究.

参考文献 (References)

- [1] Roy D, Dutta M. A systematic review and research perspective on recommender systems[J]. *Journal of Big Data*, 2022, 9(1): 59.
- [2] Saifudin I, Widiyaningtyas T. Systematic literature review on recommender system: Approach, problem, evaluation techniques, datasets[J]. *IEEE Access*, 2024, 12: 19827-19847.
- [3] Goldberg D, Nichols D, Oki B M, et al. Using collaborative filtering to weave an information tapestry[J]. *Communications of the ACM*, 1992, 35(12): 61-70.
- [4] He X N, Liao L Z, Zhang H W, et al. Neural collaborative filtering[C]. *Proceedings of the 26th International Conference on World Wide Web*. Perth, 2017: 173-182.
- [5] Ou C R, Hu J. A collaborative filtering recommendation model combining explicit and implicit feedback[J]. *Control and Decision*, 2024, 39(3): 1048-1056.
- [6] Zhang A, Zheng J N, Wang X, et al. Invariant collaborative filtering to popularity distribution shift[C]. *Proceedings of the ACM Web Conference 2023*. New York, 2023: 1240-1251.
- [7] He X N, Deng K, Wang X, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York, 2020: 639-648.
- [8] Yao Y Y. Three-way decisions with probabilistic rough sets[J]. *Information Sciences*, 2010, 180(3): 341-353.
- [9] Zhang H R, Min F. Three-way recommender systems based on random forests[J]. *Knowledge-Based Systems*, 2016, 91: 275-286.
- [10] Zhang M, Sun B Z, Wang T, et al. Multi-criteria three-way recommendation of heterogeneous information based on rough set and GRA and its application in medical recommendation[J]. *Control and Decision*, 2022, 37(7): 1883-1893.
- [11] Zhang C Y, Duan X M, Liu F C, et al. Three-way Naive Bayesian collaborative filtering recommendation model for smart city[J]. *Sustainable Cities and Society*, 2022, 76: 103373.
- [12] Xie Y, Yang J L, Meng Y L, et al. A hybrid three-way recommendation considering users variability[J]. *Engineering Applications of Artificial Intelligence*, 2025, 159: 111610.
- [13] Zhang Y J, Zhao T N, Miao D Q, et al. Three-way multi-label classification: A review, a framework, and new challenges[J]. *Applied Soft Computing*, 2025, 171: 112757.
- [14] Liu D, Ye X Q. A matrix factorization based dynamic granularity recommendation with three-way decisions[J]. *Knowledge-Based Systems*, 2020, 191: 105243.
- [15] Ye X Q, Liu D, Li T R. Multi-granularity sequential three-way recommendation based on collaborative deep learning[J]. *International Journal of Approximate Reasoning*, 2023, 152: 434-455.
- [16] Ye X Q, Liu D, Liang D C. Three-way granular recommendation algorithm based on collaborative filtering[J]. *Computer Science*, 2018, 45(1): 90-96.
- [17] Liu P, Wang N, Xu C, et al. Dynamic user interest augmentation via stream clustering and memory networks in large-scale recommender systems[J/OL]. 2024, arXiv: 2405.13238.
- [18] Lee Y H, Chu T H. An incremental clustering approach to personalized tag recommendations[C]. *HCI in Business, Government and Organizations. Information Systems and Analytics*. Cham: Springer, 2019: 209-220.
- [19] Xu Y, Niu G Q. Research on multi-view clustering algorithm based on sequential three-way decision[J]. *Applied Soft Computing*, 2024, 158: 111590.
- [20] Salort Sanchez C, Tudoran R, Al Hajj Hassan M, et al. An online incremental clustering framework for real-time stream analytics[C]. *The 18th IEEE International Conference on Machine Learning and Applications*. Boca Raton, 2020: 1480-1485.
- [21] Koren Y, Rendle S, Bell R. *Advances in collaborative filtering*[M]. Boston: Recommender Systems Handbook. 2021: 91-142.
- [22] Widayanti R. Improving recommender systems using hybrid techniques of collaborative filtering and content-based filtering[J]. *Journal of Applied Data Sciences*, 2023, 4(3): 289-302.
- [23] Qian J, Liu C H, Miao D Q, et al. Sequential three-way decisions via multi-granularity[J]. *Information Sciences*, 2020, 507: 606-629.
- [24] Xiao Y B, Zhan J M, Zhang C, et al. A sequential three-way decision-based group consensus method with regret theory under interval multi-scale decision information systems[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, 8(2): 1670-1686.
- [25] Cheng S H, Wu Y X. Personalized recommendation based on sequential three-way decisions with single feedforward neural network[J]. *Control and Decision*, 2024, 39(3): 1012-1020.
- [26] Dinh T, Wong H, Lisik D, et al. Data clustering: A fundamental method in data science and management[J]. 2024, arXiv: 2412.18760.
- [27] Huang X, Wu F. A novel topic-based framework for recommending long tail products[J]. *Computers & Industrial Engineering*, 2019, 137: 106063.
- [28] Cesa-Bianchi N, Orabona F. Online learning algorithms[J]. *Annual Review of Statistics and Its Application*, 2021, 8: 165-190.
- [29] Xu R Y, Wu D, Wang R F, et al. A highly-accurate three-way decision-incorporated online sparse streaming

- features selection model[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2025, 55(6): 4258-4272.
- [30] Neri M, Powell T. A quantitative Robbins-siegmund theorem[EB/OL]. 2024, arXiv: 2410.15986.
- [31] Morales-Brotons D, Vogels T, Hendrikx H. Exponential moving average of weights in deep learning: Dynamics and benefits[J]. 2024, arXiv: 2411.18704.
- [32] Jain A K, Murty M N, Flynn P J. Data clustering: A review[J]. ACM Computing Surveys, 1999, 31(3): 264-323.

作者简介

彭莉莎 (1994-), 女, 讲师, 博士, 主要研究方向为粒计算与知识发现、三支决策、多属性决策, E-mail: peng_lisha@zufe.edu.cn;

章荣溢 (2005-), 男, 本科生, 主要研究方向为数据挖掘、粒计算与知识发现、智能推荐, E-mail: zry@zufe.edu.cn;

彭娟娟 (1981-), 女, 教授, 博士, 博士生导师, 主要研究方向为决策理论与方法、数据分析与挖掘, E-mail: pengjj81@zufe.edu.cn;

黄锦涛 (1995-), 男, 教授, 博士, 博士生导师, 主要研究方向为弱监督学习、轻量化网络、粒计算与知识发现, E-mail: jthuang@nwpu.edu.cn.