

融合评论与评分的个性化推荐方法

杜文娜,王乐,陈泽华

(太原理工大学 计算机科学与技术学院(大数据学院),太原 030024)

E-mail:chenzehua@tyut.edu.cn

摘要: 现有的基于评论与评分的方法通常使用相同的模型分别对用户和项目进行建模,但其局限在浅层特征层面,如果能够充分挖掘用户个性化偏好与项目深层特征,则会促进模型学习两种表示之间更深层次的关系从而提升预测结果.因此,本文提出一种融合评论与评分的个性化推荐方法,用于深度挖掘用户偏好与项目特征.在对评论文本进行处理的过程中,首先通过ALBERT获得评论文本中单词的向量表示.其次,提出的个性化注意模块将用户的个性化偏好信息与评论文本向量结合,得到深层的基于评论的用户表示.在Amazon Digital Music、Grocery and Gourmet Food、Video Games数据集上进行实验,本文方法较基准方法在NDCG指标上分别提升了5%、11%、8%.代码已在<https://github.com/ZehuaChenLab/paperCode/tree/main/DuWenNa/PRM-RR>公开.

关键词: 推荐算法;评分矩阵;评论文本;个性化注意力机制

中图分类号: TP391

文献标识码: A

文章编号: 1000-1220(2025)07-1562-09

Personalized Recommendation Method Combining Rating and Review

DU Wenna, WANG Le, CHEN Zehua

(College of Computer Science and Technology (College of Data Science), Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: The existing review-based and rating-based methods usually use the same model to model users and projects respectively, but they are limited to the shallow feature level, and if we can fully explore the user's personalized preferences and the deep characteristics of the project, it will promote the model to learn the deeper relationship between the two representations and improve the prediction results. Consequently, we propose a personalized recommendation method that combines rating and review, which is used to deeply mine user preferences and project features. In the process of processing the comment text, the vector representation of the words in the comment text is obtained through ALBERT. Secondly, the proposed personalized attention module combines the user's personalized preference information with the comment text vector to get a deep comment-based user representation. Experiments are carried out on Amazon Digital Music, Grocery and Gourmet Food and Video Games data sets, and the NDCG index of this method is improved by 5%, 11% and 8% respectively compared with the benchmark method. The code is publicly available on <https://github.com/ZehuaChenLab/paperCode/tree/main/DuWenNa/PRM-RR>.

Keywords: recommendation algorithm; rating matrix; review text; personalized attention mechanism

0 引言

随着互联网和信息技术的飞速发展,社会步入了信息过载的时代,推荐系统应运而生^[1].推荐算法可以大致分为3类:基于内容的推荐、基于协同过滤的推荐^[2-5]以及混合推荐方法.混合推荐方法是指将多种推荐技术融合,从而互相弥补缺点,是目前推荐的主流方向.由于协同过滤存在稀疏性的问题,Sun等人总结了推荐系统可以利用的诸多辅助信息,用以提升推荐质量^[6].许多方法尝试利用了不同类型的辅助信息,如项目描述^[7]、用户配置文件^[8]、社交网络^[9,10]和图结构^[11,12]等.

作为一种辅助信息,评论文本可以被推荐系统利用来模拟用户偏好和项目特征可以有效缓解上述问题^[13,14].然而,基于评论和评分的个性化推荐方法在实际应用中还存在一些

挑战.首先,评分矩阵往往存在稀疏性和冷启动问题,导致难以准确地推荐给用户感兴趣的物品.其次,评论文本的挖掘和分析需要解决文本表示、情感分析和语义理解等复杂任务,对算法的效率和准确性提出了要求.因此,如何融合评分矩阵和评论文本,提高个性化推荐的准确性和效果成为了一个重要的研究方向.

近年来,基于神经网络的方法也在推荐系统中得到广泛应用.其中,一种重要的模型是神经协同过滤(NCF, Neural Collaborative Filtering),NCF结合了深度学习的优势和协同过滤的思想,通过神经网络模型来学习用户和项目之间的非线性关系,进而进行评分预测.然而NCF模型仅仅使用了用户和物品的编号信息进行推荐,存在一定的局限性.

基于以上分析,本文提出一种融合评论与评分的个性化推荐方法(PRM-RR, Personalized recommendation method

combining rating and review). 通过个性化注意模块挖掘用户偏好和项目属性的深层特征,进一步提升推荐模型的效果. 在 Amazon 数据集上的广泛实验验证了该方法的有效性.

该方法包含 4 个模块:评分特征提取模块(RFEM, Rating feature extraction module)提取评分特征,文本特征提取模块(TFEM, Text feature extraction module)对评论文本进行处理,特征融合模块(FFM, Feature fusion module)通过多模态注意将用户的评论表示与评分表示融合得到最终用户表示,改进的神经协同过滤模型预测(MNCF, Modified neural collaborative filtering)评分进行推荐. 本文的主要工作如下:

1) 以预训练的 ALBERT 模型取代以往方法的静态编码模型,直接将每条评论送入 ALBERT 模型得到各评论的单词向量表示,采用双向 GRU 结合注意力机制度量单词、评论对用户特征的贡献程度,有效构建评分、用户、项目的潜在关系,进一步提高推荐效果.

2) 提出两种个性化注意力机制,考虑到重要的单词、评论不仅与评论文本有关,还与用户的个性化偏好有关. 因此,文本特征提取模块中词级、评论个性化注意力机制融合了两个来源的信息,通过评论文本中的上下文信息与用户个性化偏好信息衡量单词、评论的重要性,由此获得深层的个性化用户表示,增加推荐的精度.

3) 改进 NCF 模型,增加了用户评论文本与项目评论文本信息对用户和项目进行建模,提升推荐效果.

1 相关工作

1.1 基于评分矩阵的推荐方法

基于评分矩阵的推荐方法主要有两种:基于邻域的方法和基于模型的方法.

基于邻域的方法根据相似用户或相似项目的评分预测目标用户的评分. 常用的算法有基于用户的协同过滤(User CF, User-Based Collaborative Filtering)和基于项目的协同过滤(Item CF, Item-Based Collaborative Filtering). 这类方法简单易于实现,但是严重依赖于数据的稠密性和稳定性.

基于模型的方法根据用户和物品的潜在因子之间的相似度或者内积计算评分预测值. 常用的算法有矩阵分解(MF, Matrix Factorization)^[15-17]、隐语义模型(LFM, Latent Factor Model)^[18]等. 这类方法虽然可以缓解数据的稀疏性和噪声,但是模型往往需要大量的计算资源和时间,同时模型的泛化能力也需要进行验证.

尽管基于评分矩阵的方法推荐效果良好,但由于评分数据的稀疏性,该类方法的发展仍存在瓶颈. 近年来,越来越多的方法致力于利用其他的辅助信息配合矩阵分解缓解此类问题,从而提高模型预测精度.

1.2 基于评论文本的推荐方法

基于文本的推荐算法可以大致分为两种:基于主题建模的方法和基于深度学习的方法.

基于主题建模的方法主要应用主题建模技术,旨在提取用户或项目整个评论文档的主题分布学习用户和项目的表征. 为了挖掘隐藏在文本数据中的语义信息,Landauer 等人提出了潜在语义分析(LSA, Latent Semantic Analysis)实现文本

聚类任务^[19]. Blei 等人提出的狄利克雷分布(LDA, Latent Dirichlet Allocation)模型对文本数据进行语义建模^[20]. DA^[21]等人提出的 Top2Vec 模型、MG^[22]等人提出的 BER-Topic 模型都实现了文本主题提取.

基于深度学习的方法旨在利用深度神经网络中的模型结构和学习算法为用户提供更加精准的推荐服务^[23]. Zheng 等人提出 DeepCoNN(Deep Cooperative Neural Network),其使用两个并行的卷积结构分别对用户合商品的评论文档建模,最后使用矩阵分解进行评分预测^[24]. Seo 等人引入了注意力机制,提出了 D-Attn(Dual Local and Global Attention)模型更好的学习用户兴趣,从而提升推荐效果^[25]. Liu 等人提出的个性化关注模型 NRPA(Neural Recommendation with Personalized Attention)为不同的用户或项目选择不同的重要的单词或评论,有效的提高了神经推荐的性能^[26]. Zhou 等人提出的 TAFE(Two-headed Attention fused Autoencoder)模型是一种双头注意融合自动编码器模型,通过联合学习用户评论和隐反馈表示进行推荐,其中提出的早晚期融合模块与 NCE 损失能够有效的提高预测精度与“去流行化”^[27]. 但 TAFE 在提取评论特征时,仍采取静态词向量,而本文则采取较为轻量的 ALBERT 并且加入用户个性化的信息融合. 不同于 NRPA 与 TAFE,本文将评论文本与评分矩阵同时作为输入;同时,本文在处理评论文本时还考虑了用户的个性化偏好信息.

2 方法

本文提出的模型整体结构如图 1 所示. 首先,使用文本特征提取模块获得用户评论特征表示,使用评分特征提取模块获得用户评分特征表示. 再通过特征融合模块获得最终用户表示. 最后改进的神经协同过滤^[28]模型处理用户项目交互信息实现推荐.

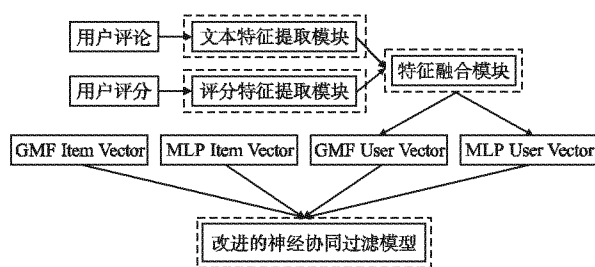


图 1 模型整体结构

Fig. 1 Overall structure of model

文本特征提取模块、评分特征提取模块、特征融合模块具体结构如图 2 所示.

2.1 评分特征提取模块

LFM(Latent Factor Model)是一种经典的矩阵分解方法,其核心思想是将评分矩阵分解成两个低维度的因子矩阵,分别表示用户和项目在潜在空间中的向量表示,如公式(1)所示:

$$R_{m,n} = P_{m,k} \times Q_{n,k}^T \quad (1)$$

其中, R 表示 $m \times n$ 的原始评分矩阵, P 表示 $m \times k$ 的用户潜在

兴趣矩阵, Q 表示 $n \times k$ 项目潜在特征矩阵, m 表示用户数量, n 表示项目数量, k 表示潜在向量维度, 即隐含特征的个数。

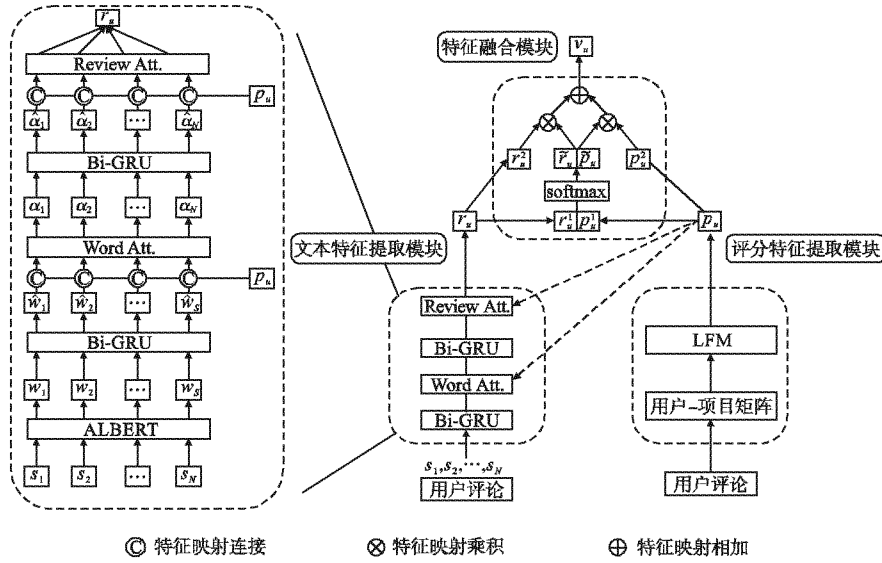


图2 3个模块具体结构

Fig. 2 Concrete structure of three modules

对于用户 u 和项目 i , LFM 可以根据其在潜在主题空间中的向量表示来预测用户对项目的评分 \hat{r}_{ui} , 如公式(2)所示:

$$\hat{r}_{ui} = p_u q_i^T = \sum_{k=1}^k p_{uk} \times q_{ik}^T \quad (2)$$

其中, p_u 表示用户 u 的潜在向量, q_i 表示项目 i 的潜在向量, p_{uk} 与 q_{ik} 为模型参数, 分别表示用户 u 、项目 i 与第 k 项潜在因素的关系。

损失函数使用均方误差 (MSE, Mean Square Error), 如公式(3)所示:

$$\begin{aligned} loss = \sum_{(u,k)} (r_{ui} - \hat{r}_{ui})^2 = \\ \sum_{(u,k)} (r_{ui} - \sum_{k=1}^k p_{uk} \times q_{ik}^T)^2 + \\ \lambda \|p_u\|^2 + \lambda \|q_i\|^2 \end{aligned} \quad (3)$$

其中, r_{ui} 为真实值, $\lambda \|p_u\|^2 + \lambda \|q_i\|^2$ 是用来防止过拟合的正则化项, λ 为正则化参数. 通过优化误差总和, 学习出最优的潜在特征矩阵 P 和 Q , 在训练过程中, 通过 Adam (Adaptive Moment Estimation) 对损失函数进行优化, 逐步更新 P 和 Q 中的参数。

对于 P 中的每个用户, 都可以用 k 维用户兴趣向量 p_{uk} 来表示, 同样的, Q 中的每个项目也都可以用 k 维项目特征向量 q_{ik} 进行表示. 以用户模块建模为例, p_{uk} 将在后续文本特征提取模块中作为用户偏好表示对评论文本进行个性化的特征提取, 在特征融合模块作为评分特征与文本特征进行融合, 得到最终的用户表示. 下文都以用户模块建模为例进行阐述。

2.2 文本特征提取模块

2.2.1 预训练 ALBERT 模型

现有的许多文本推荐系统在处理自然语言理解任务获取单词向量表示时仍采用 word2vec^[29] 或 Glove^[30] 等静态编码模型, 静态编码模型只能将每个单词映射为一个固定的向量表示, 而无法表达该词在不同上下文中的不同含义. 本文使用预训练 ALBERT (A Lite BERT) 模型获取评论中单词的向量表示, 相比于静态编码模型, 有效的解决了 NLP 中两个问题: 长文本处理与上下文理解; 相比于 BERT (Bidirectional En-

coder Representations from Transformers), ALBERT 通过参数共享和重用减少模型大小, 并且使用词片段嵌入方式进一步减少参数数量, 从而显著提高了预训练和微调效率^[31].

具体表示为:

$$\{w_1, w_2, \dots, w_S\} = ALBERT(S) \quad (4)$$

其中, $S = \{S_1, S_2, \dots, S_N\}$ 表示用户评论文本, $\{w_1, w_2, \dots, w_S\}$ 表示评论中每个单词的向量表示。

2.2.2 词级个性化注意力机制

为了进一步捕获上下文信息, 利用双向 GRU (Gated Recurrent Unit) 对评论中的单词向量表示进行编码, 捕捉评论文本中单词间的语义关系。

将每个单词的两个方向上的隐藏状态连接, 生成上下文单词嵌入 $\{\hat{w}_1, \hat{w}_2, \dots, \hat{w}_S\}$ 。

如何为用户 u 生成个性化注意力向量是本文的重点, NRPA^[26] 中使用的是用户 id, 因为每个用户都具有唯一的 id 特征. 本文认为 id 包含的信息量不够多, 不足以支撑生成用户的个性化注意力向量. 因此, 本文采用评分矩阵分解得到的 p_u 作为用户偏好向量表示, p_u 包含了用户与潜在因素之间的关系, 可以更好的建模用户的个性化偏好。

同时, 为了捕捉评论文本中蕴含重要信息的单词, 本文采用单词级别的注意力机制. 同时, 在其中融合用户偏好向量, 因为重要单词的选择不仅与评论文本信息有关, 还与用户的偏好有关. 为了融合来自两个来源的信息, 在应用注意力之前对 p_u 与单词向量进行拼接. 接着, 再使用注意力权重组合所有单词, 得到评论语句 $a = \{a_1, a_2, \dots, a_N\}$ 的表示. 具体表示为:

$$\omega_i = W_2 \tanh(W_1 [\hat{w}_i; p_u] + b_1) + b_2 \quad (5)$$

$$\alpha_i = \frac{\exp(\omega_i)}{\sum_r \exp(\omega_r)} \quad (6)$$

$$a = \sum_{i=1}^S \alpha_i \cdot \hat{w}_i \quad (7)$$

其中, $[x; y]$ 表示连接操作, W_1, W_2 为要学习的权重, b_1, b_2 为

要学习的偏差, α_i 表示每个单词的重要性权重.

2.2.3 评论级个性化注意力机制

与单词向量的处理方法一致, 本文在注意向量上应用另一个双向 GRU, 将每条评论两个方向上的隐藏状态连接起来, 生成上下文评论语句嵌入 $\{\hat{a}_1, \hat{a}_2, \dots, \hat{a}_N\}$.

同样的, 并不是所有的评论语句对于评论的意义都是同样重要的, 因此, 为了突出重要的评论语句, 本文采用评论级别的注意力机制. 同时也融合用户偏好向量 p_u , 在应用注意力之前, 对 p_u 与评论语句向量进行拼接. 接着, 在使用注意力权重组合所有评论语句, 得到用户评论表示 r_u . 具体表示为:

$$\varphi_i = W_4 \tanh(W_3 [\hat{a}_i; p_u] + b_3) + b_4 \quad (8)$$

$$\beta_i = \frac{\exp(\omega_i)}{\sum_{i=1}^N \exp(\omega_i)} \quad (9)$$

$$r_u = \sum_{i=1}^N \beta_i \cdot \hat{a}_i \quad (10)$$

其中, $[x; y]$ 表示连接操作, W_3, W_4 为要学习的权重, b_3, b_4 为要学习的偏差, β_i 表示每个评论语句的重要性权重.

2.3 特征融合模块

通过矩阵分解, 得到用户评分特征表示 p_u . 通过对评论文本的处理, 得到用户评论表示 r_u . 偏好与评论的潜在空间可能不同, 它们对最终预测的贡献可能不同, 因此简单的将两种表示连接在一起而不进行深层次的交互是不够的. 对于特征融合模块, 本文采用与 TAFA^[27] 相同的方法, 首先, 使用交叉模态注意, 将每个表示映射到一个共同的潜在空间, 再在这个空间中应用注意力来融合两种表示:

$$p_u^1 = W_m \tanh(W_5 p_u + b_5) + b_m \quad (11)$$

$$r_u^1 = W_n \tanh(W_6 r_u + b_6) + b_n \quad (12)$$

$$\tilde{p}_u, \tilde{r}_u = \text{softmax}(p_u^1, r_u^1) \quad (13)$$

$$p_u^2 = W_v \tanh(W_5 p_u + b_5) + b_v \quad (14)$$

$$r_u^2 = W_w \tanh(W_6 r_u + b_6) + b_w \quad (15)$$

$$v_u = \tilde{p}_u \cdot p_u^2 + \tilde{r}_u \cdot r_u^2 \quad (16)$$

其中, v_u 为结合了两种模式的最终用户表示, W_5, W_6, W_m, W_n 为要学习的权重, b_5, b_6, b_m, b_n 为要学习的偏差, 通过共享注意力权重 W_m , 确保在 softmax 归一化之前, 注意力系数被映射到相同的空间. 同样, 共享权重 W_v , 确保两个向量表示在融合之前被映射到相同的空间. 与连接相比, 使用 softmax 注意力的融合有一个明显的优势, 因为模型可以明确地决定给每个表示赋予多少权重.

2.4 改进的神经协同过滤模型

传统神经协同过滤模型结构如图 3 所示, 该模型架构由广义矩阵分解 (GMF, Generalized Matrix Factorization) 模块和多层感知机 (MLP, Multi-Layer Perceptron) 模块构成, 他们共同构成了模型的核心. 但 NCF 模型只利用用户和物品的编号信息来进行推荐, 仍存在一些限制. 本文对 NCF 模型进行了改进, 增加用户评论文本与项目评论文本信息对用户和项目进行建模, 提升推荐效果.

具体而言, 去掉 NCF 模型中原始的用户嵌入和项目嵌入模块. 在特征融合模块后, 得到的最终用户向量 v_u 被分别用于广义矩阵分解模块的用户向量表示 (GMF User Vector) 和多层感知机模块的用户向量 (MLP User Vector) 表示. 同样地, 融合后的最终项目模块 v_i 被分别用于广义矩阵分解模块

的项目向量表示 (GMF Item Vector) 和多层感知机模块的项目向量表示 (MLP Item Vector). 再通过 GMF 和 MLP 模块处理广义矩阵模块和多层感知机模块的用户项目信息并融合得到预测分数 \hat{r}_{ui} :

$$\Phi^{GMF} = p^G \odot q^G \quad (17)$$

$$\Phi^{MLP} = a_L (W_L^T (a_{L-1} (\dots a_2 (W_2^T [p^M] + b_2) \dots)) + b_L) \quad (18)$$

$$\hat{r}_{ui} = \sigma (h^T [\Phi^{GMF} \Phi^{MLP}]) \quad (19)$$

其中, p^G 和 p^M 分别表示项目 GMF 向量与 MLP 向量, q^G 和 q^M 表示用户 GMF 向量与 MLP 向量.

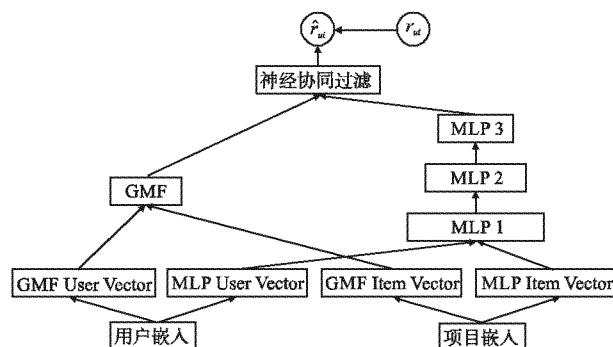


图 3 神经协同过滤模型结构

Fig. 3 Structure of neural collaborative filtering model

传统的 NCF 模型主要依赖于用户和物品的 id 信息来进行推荐, 这种方法存在一定的局限. 为了克服这些限制, 本文对 NCF 模型进行了改进, 通过整合用户的评论文本和项目的评论文本信息, 对用户和项目进行了更为细致的建模, 从而有效提高了推荐的准确性和效果.

3 实验

本文的实验旨在回答以下研究问题:

- RQ1: 与各种基线模型相比, PRM-RR 的性能如何?
- RQ2: PRM-RR 框架中的词级和评论级个性化注意力模块对推荐性能有何贡献?
- RQ3: 融合维度如何影响 PRM-RR 的性能?

在下文中, 本文将首先介绍实验设置, 然后回答以上 3 个研究问题.

3.1 数据集和实验设置

本文的实验在从 Amazon dataset 中选择的 Digital Music、Grocery and Gourmet Food、Video Games3 个基准数据集上进行. 所有的数据集都包含评分 (从 1 到 5) 与评论, 并且在大小、稀疏性方面各不相同. 数据集的详细信息如表 1 所示. 对于所有数据集, 我们按照 80%、10% 和 10% 的比例随机分成训练集、验证集和测试集.

本文在验证集上对所有方法的超参数进行调优, 并通过计算 3 个标准评估指标: 归一化折损累计增益 NDCG, 准确率 Precision@K 和召回率 Recall@K ($K \in \{5, 20, 50\}$) 来评估在测试集上的最终性能. 所有结果报告的置信区间为 95%.

NDCG 不仅考虑了推荐物品的准确性, 还考虑了它们在

推荐列表中的排名.

$$NDCG = \frac{1}{N} \sum_{i=1}^N \frac{1}{\log_2(p_i + 1)} \quad (20)$$

其中, N 表示用户总数量, p_i 表示第 i 个用户真实值在推荐列表的位置, 若推荐列表不存在该值, 则 $p_i \rightarrow \infty$. NDCG 值越高, 模型推荐效果越好.

表1 数据集统计数据

Table 1 Dataset statistics

Dataset	# Users	# Items	# Ratings	# Review Words	# Density
Amazon Digital Music	5,541	3,568	64,706	2,561,491	3.27×10^{-3}
Amazon Grocery and Gourmet Food	14,681	8,713	151,254	3,074,602	1.18×10^{-3}
Amazon Video Games	24,383	18,672	231,780	8,385,355	5.09×10^{-4}

Precision@K 只考虑了推荐列表中与用户实际感兴趣物品相同的物品数目的占比, 如式(21)所示:

$$Precision@k = \frac{TP@k}{TP@k + FP@k} \quad (21)$$

其中, $TP@k$ 表示前 k 个推荐列表中被正确推荐的数量, $FP@k$ 表示前 k 个推荐列表中错误推荐的数量. Precision@k 值越高, 模型推荐效果越好.

Recall@K 表示在所有正样本中, 模型正确预测出的数量占总正样本的比例, 如式(22)所示:

$$Recall@k = \frac{TP@k}{TP@k + FN@k} \quad (22)$$

其中, $FN@k$ 表示不在前 k 个推荐列表中但真实值为正确的数量. Recall@k 值越高, 模型推荐效果越好.

3.2 基线模型

本文采用4种类型共8种基线模型进行比较, 包括基于矩阵分解的方法、融合评论文本的方法、融合注意力机制的方法和自编码器模型.

基于矩阵分解的方法:

1) PMF^[32] (Probabilistic Matrix Factorization, 2007) 通过引入高斯分布对用户和项目的潜在因素进行建模.

2) CML^[33] (Collaborative Metric Learning, 2017) 将传统的CF与矩阵分解相结合对用户偏好与用户-用户、用户-物品相似度进行编码进行推荐.

融合评论文本的方法:

1) ConvMF^[13] (Convolutional Matrix Factorization, 2016) 将卷积神经网络与矩阵分解相结合, 从项目评论文档中学习项目特征. 但对用户的建模只有评分数据.

2) DeepCoNN^[24] (Deep Cooperative Neural Networks, 2017) 用两个平行的卷积结构对用户和项目的评论文档进行建模, 使用FM做评分预测.

融合注意力机制的方法:

1) NARRE^[34] (Neural Attentional Regression with Reviews Explanations, 2018) 引入神经注意机制对评论进行聚焦和划分, 生成不同的权重表示, 用两个并列的神经网络学习用户和项目之间的隐含因子特征.

2) TARMF^[14] (Topical Attention Regularized Matrix Factorization, 2018) 是一种利用基于注意力的循环神经网络从评论文档中提取主题信息的推荐模型.

3) DeepUCF^[35] (Deep attention user-based collaborative filtering, 2020) 通过注意力机制来改进用户协同过滤的性能, 捕捉用户的个性化偏好和兴趣.

4) ADRS^[36] (Adaptive Deep learning-based method for Recommendation System, 2021) 通过卷积神经网络学习用户和项目的自适应潜在特征并用注意力机制捕捉用户项目间的交互进行推荐.

5) LinRec^[37] (Linear Attention Mechanism for Long-term Sequential Recommender Systems, 2023) 设计了一种新型的线性复杂度注意力机制处理长期序列推荐问题.

自编码器模型:

1) GATE^[38] (Gated Attentive-Autoencoder, 2019) 是一种基于自编码器和注意力机制的神经网络模型, 结合了自动编码器对评论文本向量表示进行重构, 并利用门控机制来筛选有用信息进行建模.

2) TAFA^[28] (Two-headed Attention Fused Autoencoder, 2020) 是一种联合学习用户评论和隐式反馈的表示以进行推荐的双头注意融合自动编码器.

3) GIANT^[39] (Geometric InformAtIoN bottleneck, 2024) 是一种结合了几何先验和变分自编码器, 通过引入几何信息瓶颈的概念, 分析用户和项目之间的几何关系(如距离、角度等)进行推荐.

3.3 性能评估 (RQ1)

表2~表4总结了所有基线和本文算法在3个数据集上的整体性能. 整体最好和以前最好的结果分别用粗体和下划线标出.

观察表2~表4, 得出以下结果:

首先, 所有融合了评论文本信息作为辅助信息的推荐方法(第3~13行)始终优于单纯的基于矩阵分解的方法(第1~2行). 这是因为基于矩阵分解的方法只能利用用户-项目评分矩阵来预测用户对未知项目的评分, 而融合评论文本信息的推荐方法可以利用用户和项目的评论信息, 进一步挖掘用户的偏好和需求, 比单纯的矩阵分解方法更能够捕捉用户的兴趣和喜好, 同时融合评论文本的推荐方法可以利用文本信息弥补评分矩阵数据稀疏的缺陷, 从而提高推荐的准确度.

其次, 融合注意力机制的方法(第5~13行)性能优于没有使用注意力机制的方法(第1~4行). 这是因为注意力机制可以体现不同特征对模型输出的重要性, 从而提高模型的可解释性, 同时通过融合评论文本信息, 可以更好的建模用户兴趣.

第三, 基于自编码器的方法(第10~12行)性能与融合注意力机制的方法(第5~9行)相比, 也表现出一定的优势. 对比NARRE、TARMF等早期利用注意力机制处理评论的方

表 2 Amazon Digital Music 实验结果
Table 2 Experimental results of Amazon Digital Music

	model	NDCG	Precision@ 5	Precision@ 20	Precision@ 50	Recall@ 5	Recall@ 20	Recall@ 50
1	PMF	0.0277	0.0064	0.0039	0.0029	0.0108	0.0146	0.0721
2	CML	0.0379	0.0085	0.0050	0.0035	0.0259	0.0570	0.0950
3	ConvMF	0.0654	0.0203	0.0103	0.0072	0.0494	0.1529	0.1193
4	DeepCoNN	0.0798	0.0287	0.0127	0.0093	0.0727	0.1694	0.1298
5	NARRE	0.0924	0.0312	0.0142	0.0105	0.0869	0.1704	0.2834
6	TARMF	0.1215	0.0320	0.0159	0.0103	0.0947	0.1865	0.2861
7	DeepUCF	0.1583	0.0398	0.0212	0.0126	0.1234	0.2435	0.3590
8	ADRS	0.1768	0.0470	0.0227	0.0127	0.1320	0.2676	0.3649
9	LinRec	0.1793	0.0431	0.0220	0.0128	0.1315	0.2574	0.3602
10	GATE	0.1577	0.0395	0.0213	0.0126	0.1230	0.2420	0.3585
11	TAFA	0.1764	0.0478	0.0228	0.0128	0.1370	0.2670	0.3786
12	GIANT	<u>0.1892</u>	<u>0.0511</u>	<u>0.0245</u>	<u>0.0137</u>	<u>0.1421</u>	<u>0.2916</u>	<u>0.3990</u>
13	PRM-RR	0.1987	0.0535	0.0261	0.0149	0.1542	0.2948	0.4059

表 3 Amazon Grocery and Gourmet Food 实验结果
Table 3 Experimental results of Amazon Grocery and Gourmet Food

	model	NDCG	Precision@ 5	Precision@ 20	Precision@ 50	Recall@ 5	Recall@ 20	Recall@ 50
1	PMF	0.0330	0.0056	0.0046	0.0036	0.0146	0.0480	0.0987
2	CML	0.0415	0.0089	0.0054	0.0039	0.0259	0.0631	0.1120
3	ConvMF	0.0534	0.0117	0.0078	0.0053	0.0338	0.0877	0.1449
4	DeepCoNN	0.0587	0.0138	0.0067	0.0053	0.0342	0.0896	0.1402
5	NARRE	0.0589	0.0144	0.0076	0.0046	0.0354	0.0906	0.1346
6	TARMF	0.0596	0.0126	0.0082	0.0052	0.0377	0.0962	0.1567
7	DeepUCF	0.0665	0.0154	0.0092	0.0063	0.0510	0.1182	0.1904
8	ADRS	0.0772	0.0169	0.0118	0.0064	0.0507	0.1227	0.1917
9	LinRec	0.0733	0.0164	0.0096	0.0062	0.0506	0.1223	0.1903
10	GATE	0.0658	0.0156	0.0087	0.0064	0.0515	0.1174	0.1916
11	TAFA	0.0762	0.0166	0.0102	0.0063	0.0508	0.1225	0.1900
12	GIANT	<u>0.0836</u>	<u>0.0213</u>	<u>0.0120</u>	<u>0.0066</u>	<u>0.0598</u>	<u>0.1321</u>	<u>0.1997</u>
13	PRM-RR	0.0928	0.0230	0.0128	0.0078	0.0630	0.1363	0.2047

表 4 Amazon Video Games 实验结果
Table 4 Experimental results of Amazon Video Games

	model	NDCG	Precision@ 5	Precision@ 20	Precision@ 50	Recall@ 5	Recall@ 20	Recall@ 50
1	PMF	0.0051	0.0034	0.0024	0.0164	0.0425	0.0790	0.0272
2	CML	0.0070	0.0041	0.0033	0.0228	0.0523	0.1062	0.0392
3	ConvMF	0.0136	0.0060	0.0046	0.0406	0.1032	0.1664	0.0610
4	DeepCoNN	0.0138	0.0072	0.0050	0.0473	0.1052	0.1680	0.0698
5	NARRE	0.0140	0.0075	0.0056	0.0492	0.1098	0.1687	0.0695
6	TARMF	0.0141	0.0079	0.0052	0.0462	0.1024	0.1637	0.0655
7	DeepUCF	0.0167	0.0092	0.0060	0.0558	0.1269	0.1956	0.0764
8	ADRS	0.0203	0.0108	0.0070	0.0661	0.1456	0.2183	0.0910
9	LinRec	0.1968	0.0106	0.0062	0.0607	0.1398	0.2077	0.0903
10	GATE	0.0150	0.0087	0.0059	0.0511	0.1174	0.1885	0.0741
11	TAFA	0.0201	0.0109	0.0068	0.0665	0.1435	0.2178	0.0897
12	GIANT	<u>0.0225</u>	<u>0.0130</u>	<u>0.0079</u>	<u>0.0732</u>	<u>0.1572</u>	<u>0.2308</u>	<u>0.1087</u>
13	PRM-RR	0.0243	0.0134	0.0082	0.0750	0.1619	0.2450	0.1172

法,基于自编码器的方法表现出较大的优势。DeepUCF 性能优于 GATE 但低于 TAFA,因其注意力机制可以捕捉用户间的复杂高阶关系从而提高了推荐到准确性,但 TAFA 模型利用隐式反馈数据进行建模,同时通过重构误差来训练模型,可以有效地对输入数据进行噪声和异常值的过滤和处理,因此

表现出更为良好的性能。ADRS 模型在 3 个数据集中的结果与 TAFA 相比表现出微弱的优势,因其自适应机制学习用户项目的特征向量能较好的捕捉用户偏好和项目特性,但对比 GIANT 模型却略显不足,GIANT 模型利用从用户-项目交互图中学习到的几何先验知识编码用户项目特征,提升了推荐

性能. 而 LinRec 基于 Transformer 进行设计, 旨在提高处理长序列数据时的效率和性能, 将计算复杂度从二次降低到线性但对推荐的其他性能影响不大. 在实验过程中, 将其集成到原文中表现最好的传统 Transformer 模型 SASRec^[40] 上表现出的效果也比较一般.

最后, PRM-RR 在 3 个数据集的所有指标方面明显优于其他基线方法. 重大改进可归功于用户个性化偏好融合(文本特征提取)与特征融合模块. 用户个性化偏好融合中利用词级、评论级个性化注意力机制, 并充分利用评分矩阵信息, 利用矩阵分解得到用户潜在向量, 在文本特征提取模块中作为用户偏好表示对评论文本进行个性化的特征提取, 在特征融合模块作为评分特征与文本特征进行融合, 更好的建模用户个性化偏好, 得到最终的用户表示. 比起 GATE、TAFA、GLANT 中将评分矩阵二值化作为隐反馈信息进行建模, 本文直接利用评分矩阵, 可以更加准确地描述用户行为特征, 明确的评分信息可以直接的反映用户的偏好, 有助于推荐系统更加准确的预测用户的行为并提供相应的推荐结果.

3.4 消融实验(RQ2)

为了量化模型中每个模块的贡献, 本文进行了大量的消融实验. BASE 模型没有词级、评论级注意力机制, 只有普通的文本特征提取与评分矩阵分解结合, 模型类似于 DeepCoNN, 输入部分除了文本向量还有矩阵分解得到的潜在向量. BASE + WA 中, 只融入词级注意力机制, 并将用户潜在向量作为个性化偏好向量与单词向量拼接得到评论语句向量表示. 而在 BASE + RA 模型中, 只融入评论级注意力机制.

图 4 显示了每个模型在 3 个数据集上的 NDCG 结果. 可以看到, 在 BASE + WA 模型中添加的词级注意力机制显著改善了所有数据集的 NDCG, 将性能提高了 1~6 个百分点, 尤其是在数据量较小较为稀疏的 Amazon Digital Music 数据集上, 证明了词级注意力机制与潜在向量作为个性化偏好向量进行特征融合的有效性. BASE + RA 模型的结果也证明了评论级注意力机制的有效性.

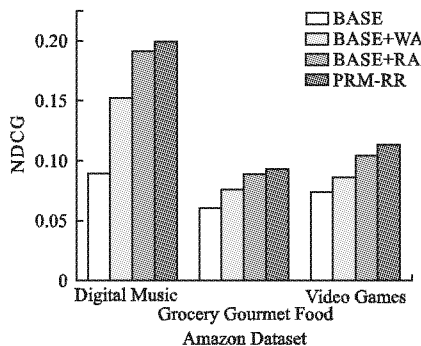


图 4 消融实验结果图

Fig. 4 PRM-RR ablation NDCG results on three datasets

实验结果证明, 不论是缺乏词级还是评论级注意力机制, 都会导致性能的下降. 这是因为词级注意力机制可以为用户识别重要的单词, 评论级注意力有助于在对用户偏好建模时对重要的评论赋予更好的权重. 证明了个性化注意力机制的有效性.

3.5 融合维度(RQ3)

由于本文最终的用户表示向量 v_u 是由用户评论表示向量与矩阵分解潜在向量融合得到的, 因此本节探讨融合维度的影响. Amazon Digital Music 和 Amazon Video Games 数据集在融合维度在 {32, 64, 128, 256, 512} 时 Recall@5、Recall@20、Recall@50 的变化.

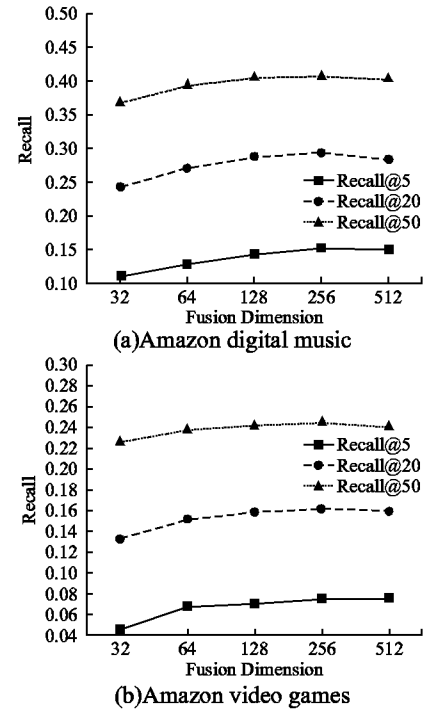


图 5 融合维度结果图

Fig. 5 Recall Plots for PRM-RR on two datasets as dimension of v_u is varied from 32 to 512

从图 5 结果可以看出, 随着维度的增加, Recall 先增加后下降, 在 256 维时效果最好. 当维度太小时, 融合向量可能无法充分了解用户和项目的多样性. 但当维度太大时, 模型可能会过拟合. 无论哪个数据集, 融合维度的最佳值为 256 维.

4 结论

本文提出了一种融合评分与评论的个性化推荐方法, 从评论中学习个性化的用户和项目表示. 利用评分特征提取模块提取评分特征, 文本特征提取模块对评论文本进行处理, 特征融合模块获得最终用户表示. 提出的个性化注意力模型, 从文本中提取特征并将矩阵分解得到的潜在向量作为个性化向量表示融合进来. 本文将注意力模型应用于用户评论与项目评论, 为不同的用户和项目选择不同的重要单词和评论, 更好的捕捉用户的不同偏好和项目的不同特征. 几组消融实验表明, 每个添加的组件都提高了性能. 在 3 个基准数据集上的实验表明, 本文的方法可以有效地提升推荐质量.

在未来的研究中, 将进一步考虑使用除评论文本外其他的辅助信息来更准确地建立用户偏好和项目特征分布, 探索利用图神经网络进行用户和文本处理, 从而提高推荐准确性.

References:

- [1] Liu X, Wu S, Zhang Z, et al. Unify local and global information for Top-N recommendation [C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2022; 1262-1272.
- [2] He X, Liao L, Zhang H, et al. Neural collaborative filtering [C] // Proceedings of the 26th International Conference on World Wide Web, 2017; 173-182.
- [3] Xia L, Huang C, Xu Y, et al. Hypergraph contrastive collaborative filtering [C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2022; 70-79.
- [4] Xue H J, Dai X, Zhang J, et al. Deep matrix factorization models for recommender systems [C] // Proceedings of the International Joint Conference on Artificial Intelligence, 2017; 3203-3209.
- [5] LI K L, SU H D, RONG J Y. Personalized recommendation system incorporated with the implicit feedback of projects and users [J]. Journal of Chinese Computer Systems, 2020, 41 (3) : 519-525.
- [6] Sun Z, Guo Q, Yang J, et al. Research commentary on recommendations with side information: a survey and research directions [J]. Electronic Commerce Research and Applications, 2019, 37, doi: 10.1016/j.elerap.2019.100879.
- [7] CHEN Y M, LI D X, YAN Y F, et al. Method for recommending academic papers combining text and implicit feedback [J]. Journal of Chinese Computer Systems, 2023, 44 (11) : 2471-2476.
- [8] Zhao H, Rui P, Chen J, et al. HINChip: heterogeneous information network representation with community hierarchy preserving [J]. Knowledge-Based Systems, 2023, 264; 110343, doi: 10.1016/j.knsys.2023.110343.
- [9] YANG B, LIANG J, ZHOU J W, et al. Study on interpretable click-through rate prediction based on attention mechanism [J]. Computer Science, 2023, 50 (5) : 12-20.
- [10] Gao C, Zheng Y, Li N, et al. A survey of graph neural networks for recommender systems: challenges, methods, and directions [J]. ACM Transactions on Recommender Systems, 2023, 1 (1) : 1-51.
- [11] Huang C, Chen J, Xia L, et al. Graph-enhanced multi-task learning of multi-level transition dynamics for session-based recommendation [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2021; 4123-4130.
- [12] Zhao S, Du Z, Chen J, et al. Hierarchical representation learning for attributed networks [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35 (3) : 2641-2656.
- [13] Kim D, Park C, Oh J, et al. Convolutional matrix factorization for document context-aware recommendation [C] // Proceedings of the 10th ACM Conference on Recommender Systems, 2016; 233-240.
- [14] Lu Y, Dong R, Smyth B. Coevolutionary recommendation model: mutual learning between ratings and reviews [C] // Proceedings of the World Wide Web Conference, 2018; 773-782.
- [15] HE Y C, MAO Y J, XIE X F, et al. Matrix transformation and factorization based on graph partitioning by vertex separator for recommendation [J]. Computer Science, 2022, 49 (S1) : 272-279.
- [16] JIANG B Z, DENG X, DU Y L, et al. Next-basket recommendation algorithm based on correlation between items collaborative filtering [J]. Computer Science, 2023, 50 (S2) : 486-491.
- [17] Liu S, Ge Y, Xu S, et al. Fairness-aware federated matrix factorization [C] // Proceedings of the 16th ACM Conference on Recommender Systems, 2022; 168-178.
- [18] Tran V, Salha Galvan G, Hennequin R, et al. Hierarchical latent relation modeling for collaborative metric learning [C] // Proceedings of the 15th ACM Conference on Recommender Systems, 2021; 302-309.
- [19] Landauer T K, Foltz P W, Laham D. An introduction to latent semantic analysis [J]. Discourse Process, 1998, 25 (2-3) : 259-284.
- [20] Blei D M, Ng A Y, Jordan M I. Latent dirichlet allocation [J]. Journal of Machine Learning Research, 2003, 3 (1) : 993-1022.
- [21] Zhao J, Huang J X, Deng H, et al. Are topics interesting or not? An LDA-based topic-graph probabilistic model for web search personalization [J]. ACM Transactions on Information Systems, 2022, 40 (3) : 1-24.
- [22] Devlin J, Chang M W, Lee K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [C] // North American Chapter of the Association for Computational Linguistics, 2019; 4171-4186.
- [23] Tal O, Liu Y, Huang J, et al. Neural attention frameworks for explainable recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 33 (5) : 2137-2150.
- [24] Zheng L, Noroozi V, Yu P S. Joint deep modeling of users and items using reviews for recommendation [C] // Proceedings of the 10th ACM International Conference on Web Search and Data Mining, 2017; 425-434.
- [25] Seo S, Huang J, Yang H, et al. Interpretable convolutional neural networks with dual local and global attention for review rating prediction [C] // Proceedings of the 12th ACM Conference on Recommender Systems, 2017; 297-305.
- [26] Liu H, Wu F, Wang W, et al. NRPA: neural recommendation with personalized attention [C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019; 1233-1236.
- [27] Zhou, Cheng Z, Pérez F, et al. TAFA: two-headed attention fused autoencoder for context-aware recommendations [C] // Proceedings of the 14th ACM Conference on Recommender Systems, 2020; 338-347.
- [28] DUAN Z, YU H, ZHAO S, et al. Citation recommendation method based on heterogeneous information network representation learning [J]. Journal of Chinese Computer Systems, 2021, 42 (8) : 1591-1597.
- [29] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality [C] // Proceedings of the 27th Neural Information Processing Systems, 2013.
- [30] Pennington J, Socher R, Manning C D. Glove: global vectors for word representation [C] // Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2014; 1532-1543.
- [31] Lan Z, Chen M, Goodman S, et al. ALBERT: a lite BERT for self-supervised learning of language representations [C] // International Conference on Learning Representations, 2020.
- [32] Jaekels J M, Min Suk B, James J, et al. Positive matrix factorization (PMF) analysis of molecular marker measurements to quantify the sources of organic aerosols [J]. Environmental Science and Technology, 2007, 41 (16) : 5763-5769.
- [33] Hsieh C, Yang L, Cui Y, et al. Collaborative metric learning [C] // Proceedings of the 26th International Conference on World Wide Web, 2017; 193-201.
- [34] Chen C, Zhang M, Liu Y, et al. Neural attentional rating regression with review-level explanations [C] // Proceedings of the World Wide Web Conference, 2018; 1583-1592.
- [35] Chen J, Wang X, Zhao S, et al. Deep attention user-based collaborative filtering for recommendation [J]. Neurocomputing, 2020,

383;57-68.

[36] Da'u A, Salim N, Idris R. An adaptive deep learning method for item recommendation system [J]. Knowledge-Based Systems, 2021, 213:106681.

[37] Liu L, Cai L, Zhang C, et al. Linrec: linear attention mechanism for long-term sequential recommender systems [C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2023:289-299.

[38] Ma C, Kang P, Wu B, et al. Gated attentive-autoencoder for content-aware recommendation [C]//Proceedings of the 12th ACM International Conference on Web Search and Data Mining, 2019: 519-527.

[39] Yan H Q, Gui L, Wang M H, et al. Explainable recommender with geometric information bottleneck [J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(7):3036-3046.

[40] Kang W C, McAuley J. Self-attentive sequential recommendation

[C]//Proceedings of the IEEE International Conference on Data Mining, 2018:197-206.

附中文参考文献:

[5] 李昆仑, 苏华汀, 戎静月. 融合项目和用户隐式反馈的个性化推荐系统[J]. 小型微型计算机系统, 2020, 41(3):519-525.


[7] 陈雨民, 李东喜, 闫一帆, 等. 结合文本与隐反馈信息的学术论文推荐方法[J]. 小型微型计算机系统, 2023, 44(11):2471-2476.

[9] 杨斌, 梁婧, 周佳薇, 等. 基于注意力机制的可解释点击率预估模型研究[J]. 计算机科学, 2023, 50(5):12-20.

[15] 何亦琛, 毛宜军, 谢贤芬, 等. 基于点割集图分割的矩阵变换与分解的推荐算法[J]. 计算机科学, 2022, 49(S1):272-279.

[16] 蒋滨泽, 邓欣, 杜雨露, 等. 基于物品关联协同过滤的下一购物篮推荐算法[J]. 计算机科学, 2023, 50(S2):486-491.

[28] 段震, 余豪, 赵妹, 等. 基于异质信息网络表示学习的引文推荐方法[J]. 小型微型计算机系统, 2021, 42(8):1591-1597.



征稿简则

一、征稿范围:《小型微型计算机系统》杂志所刊登的文章内容涵盖了计算机学科各个领域(计算数学除外). 包括计算机科学理论、体系结构、软件、数据库、网络与通讯、人工智能、网络与信息安全、多媒体、计算机图形与图像等.

二、稿件类型:

1. 学术论文:科研成果有创新、有见解的完整论述. 对该领域的研究与发展有促进意义.
2. 技术报告:在国内具有影响的重大科研项目技术总结.
3. 热点论文:目前国内外计算机前沿热点研究领域的文章.
4. 综述:对新兴活跃的学术领域或技术开发的现状及发展趋势全面、客观的综合评述(各类综述稿件一经录用三个月见刊).
5. 论文字数在 10000 字以上(含图、表、参考文献),参考文献数量不低于 15 条.

三、注意事项:

1. 来稿务求做到论点明确、条理清晰、数据可靠,符合本期刊论文模板要求(模板详见本刊网站),并无学术不端问题.
2. 来稿必须是作者自己的科研成果,无署名和版权争议. 引用他人成果必须注明出处.
3. 本刊采用在线投稿方式(投稿时请在作者留言中注明投稿方向),可登陆 <http://xwxt.sict.ac.cn/> 进行在线投稿.
4. 作者联系方式有变化时请及时通知编辑部. 录用稿、修改稿超过 60 天不回应 E-mail 联络,将视为作者放弃稿件(即弃稿).
5. 格式要求:题目(中、英文)、摘要(中、英文)、作者的真实姓名(中、英文)、作者的单位、城市(中、英文)、邮政编码、E-mail(便于联系的)、关键词(中、英文 4~7 个)、中图分类号(必填)、作者简介、基金项目(省部级以上基金项目或攻关项目支持,并注明类别及项目编号).
 - (1)英文部分的作者姓名使用汉语拼音,单位英文名称须给出英文全称,不要使用缩略语;
 - (2)作者简介包含所有作者姓名、性别、出生年、最高学历、技术职称、研究方向(若作者中有中国计算机学会(CCF)会员,请注明,并给出会员号). 凡第一作者为 CCF 会员/高级会员/学生会员者,并在初次上传稿件中注明的,将享受 8.5 折的版面费优惠;
 6. 中、英摘要:文章摘要要具有独立性和自明性,含正文等量的主要信息,一般为 250~300 字,采用第三人称表述.
 7. 参考文献:未公开发表的文献不得列入. 文后所列参考文献统一排序,且必须在正文中全部引用. 中文参考文献应给出对应的英文译文. 其具体书写格式为:
 - (1)专著:作者姓名(姓在前,名在后). 书名[M]. 出版社所在城市:出版社,出版年.
 - (2)期刊:作者姓名. 文章题目[J]. 刊物名称,出版年,卷号(期号):起止页码.
 - (3)会议论文:作者姓名. 文章题目[C]//会议名全称,出版年:起止页码.
 - (4)网络文献:作者或单位名. 文章题目[EB/OL]. 网址,发布日期.
 - (5)学位论文:作者姓名. 文章题目[D]. 城市:单位,出版年.
 - (6)如无卷期号及页码的文献,应注明 doi 号.
 - (7)参考文献的期刊名称和会议名称要写全称,有缩写的同时提供缩写.

8. 插图和表:插图必须精绘并用计算机激光打印,一般不超过 7 幅. 图应结构紧凑,不加底纹,因本刊为黑白印刷,所以图不要给出彩色的(正文中也不要出现颜色的说明),图宽最好不超过 8 厘米,图内字号统一使用 6 号宋体,字迹、曲线清晰,必要时给出坐标名称和单位. 每个图、表均给出中英文图注(如:“图 1 * * * 图”“Fig. 1 * * *”)和表注(如:“表 1 * * * 表”,“Table 1 * * *”).
9. 计量单位:稿件中一律使用《中华人民共和国法定计量单位》. 外文和公式中应分清大、小写和正、斜体,上、下角的字母、数码位置准确. 易混淆的字母或符号,请在第一次出现时标注清楚.

10. 本刊在收到作者稿件经初审后立即给作者电子邮箱发“稿件收稿回执通知”. 除作者另有明确要求外,本刊原则上只与通信作者联系,作者投稿后若 4 个月无消息,可自行改投它刊. 通过初审的稿件将收到本刊给予的编号,并需邮寄审稿费.

11. 本刊对不拟录用的稿件只发给“退稿通知”,恕不退回原稿,请自留底稿. 录用后的定稿不允许修改作者姓名等涉及著作权的内容,以避免不必要的纠纷.

12. 稿件一经发表,将酌致稿酬,并寄送样刊.

本刊文章现被国内外多家数据库收录,作者著作权使用费与本刊稿酬一并给付,作者若不同意将文章收录,请在投稿时说明.

编辑部地址:辽宁省沈阳市浑南区南屏东路 16 号《小型微型计算机系统》编辑部 邮政编码:110168
 电话:024-24696120 E-mail:xwjxt@sict.ac.cn 网址: <http://xwxt.sict.ac.cn>