

一种融合混合协同过滤与 CNN 的图书推荐算法

王莎莎¹
WANG Shasha

摘要

随着电子阅读时代的到来, 数字化资源海量涌现。然而, 这也导致读者在寻找感兴趣图书时, 时间成本大幅攀升。如何提升推荐系统的准确性和个性化程度成为学术界亟待解决的问题。传统的推荐算法如基于用户的协同过滤和基于物品的协同过滤针对不同的场景各显优势。但传统的单一协同过滤方法因无法满足用户的复杂要求在解决用户偏好稀疏性、冷启动等问题时存在较大局限性。基于此, 文章提出了一种融合用户协同过滤、物品协同过滤与卷积神经网络的图书推荐算法, 通过结合用户与物品的多层次特征, 提升推荐系统的准确性。为了验证文章所提方法的有效性, 研究团队在 Book-Crossing 数据集上, 将该方法与传统推荐方法展开对比实验。实验结果表明, 相较于传统方法, 所提方法在推荐精度、覆盖率等多个关键指标上均展现出更为良好的推荐性能, 能够显著提升推荐服务的质量。

关键词

图书推荐; 协同过滤; 卷积神经网络; 数据稀疏性; 冷启动问题

doi: 10.3969/j.issn.1672-9528.2025.04.011

0 引言

数字化时代, 各类数据出现快速增长和大量堆积, 在这种情形下用户需要花费大量精力与时间从海量数据中挑选出符合自己需求的图书。图书引擎系统虽可利用关键词信息展开模糊搜索但这种检索信息方式只针对那些有明确需求且主动检索用户, 无法满足那些无明确阅读要求或未进行检索行为的用户^[1]。1992 年, Goldberg 等人^[2]提出减少垃圾邮件推送的协同过滤算法。此后各种推荐系统的出现促进了协同过滤技术的发展。协同过滤算法(collaborative filtering, CF)目前仍被应用于多个领域, 该方法可以通过用户之间或者物品之间的相似度来进行推荐, 虽然能实现一定程度上的推断性, 但仍存在数据稀疏、冷启动等问题。

近年来, 为提高推荐效果, 许多学者提出的深度学习技术模型尤其是卷积神经网络(convolutional neural network, CNN)在多个领域都取得了突破性的进展, 因此面对非结构化数据方面的图书推荐, 有学者提出利用 CNN 提取书籍的文本描述、封面图片、类别标签等非结构化特征。Zheng 等人^[3]提出了一种学习用户行为特征和项目特征的深度学习模型。陈帆等人^[4]提出一种基于图卷积神经网络的捕获用户交互矩阵中的高阶连通性的图

书推荐方法。

然而, 单独依赖神经网络的推荐方法, 难以充分利用用户与物品之间的关系数据, 因此在处理用户—物品之间交互数据时往往不能表现出最佳推荐效果。Ngaffo 等人^[5]提出具有矩阵分解的神经网络过滤方法以准确模拟用户—项目的交互, 该方法使用的深度神经网络有效缓解了矩阵分解过程中设计的线性点积的局限性。高飞等人^[6]提出一种基于自适应的卷积注意力神经协同推荐算法, 该算法通过卷积注意力神经网络完成预测评分实现了推荐预测; 邓存彬等人^[7]提出一种用于电影评分预测的融合动态协同过滤和深度学习的推荐算法。综上所述, 虽然现有的混合神经网络和协同过滤算法都在提升推荐准确度方面有一定的成就, 但是很多算法都忽略了冷启动问题^[8-9]。因此, 本文将在兼顾两种协同过滤算法的基础上对现有算法进行加以完善, 提出一种融合用户的协同过滤、物品的协同过滤以及卷积神经网络的混合推荐模型, 该模型不仅能够有效利用用户行为数据实现推荐性能的优越性, 还可以通过 CNN 模块提取图书内容中的深层特征, 在冷启动和稀疏数据情境下展现出更高的推荐质量。

1 相关工作

1.1 卷积神经网络

神经网络因其特大的特征提取能力广泛应用于图像识别、语义识别等多个应用领域。传统的神经网络各层之间全

1. 信阳师范大学 河南信阳 464000

[基金项目] 河南省哲学社会科学规划项目“河南高校图书馆红色特藏资源建设与开发利用研究”(2023BZH008)

连接的方式使得参数数量呈现指数式的增加,因此在网络训练时会花费很多时间。卷积神经网络具备解决这种问题的能力。卷积神经网络一般由输入层、卷积层、池化层和全连接层堆叠而成。本文在卷积层设计中采用了多层卷积结构逐层去提取特征的复杂关联能有效提取到更深层的用户偏好与图书特征之间的交互关系,并且在每层卷积后都使用最大池化(Max Pooling)操作,缩减特征维度有效提升了模型的泛化能力。CNN 模块的输入由用户特征和图书特征嵌入向量组成,其中图书特征主要包括评分、内容嵌入、图书类别等,而用户特征主要包括兴趣嵌入、历史偏好等方面。卷积神经网络的深层卷积可能带来梯度消失问题,残差连接(Residual Connections)可以缓解该问题,注意力机制(Attention Mechanism)的引入通过给不同特征赋予动态权重,能更好地关注与用户当前兴趣匹配的特征,也使得推荐更加精准。

1.2 矩阵优化

本文综合考虑图书本身语义特征和评论中的关键信息,有效解决了数据源单一带来的信息量不大、数据片面等问题,提升了矩阵填充质量。具体过程大致分为以下步骤:

步骤 1: 初始化用户对图书的原始评分数据表写为用户-图书评分矩阵 $R_{m \times n}$, 读取图书内容相似度矩阵 $S_{n \times n}$ 。

步骤 2: 预测目标用户对未评分图书的评分。预测用户 x 对图书 i 的评分具体为首先在评分矩阵中获取用户 x 已有评分的图书列表, 设置阈值后剔除列表中低于目标图书相似度的阈值的图书, 最后利用用户 x 对图书 i 的预测评分:

$$P(x, i) = \frac{\sum_{j \in L} S_c(i, j) \times R(x, j)}{|L|} \quad (1)$$

式中: $P(x, i)$ 为用户 x 对图书 i 的预测评分; L 为用户 x 有过评分且与目标图书 i 的相似度大于阈值的图书集合; $|L|$ 为集合中元素个数; $R(x, j)$ 为用户 x 对图书 j 的实际评分。

步骤 3: 遍历所有目标用户, 重复步骤 2 对空值填充。

2 融合混合协同过滤与 CNN 的图书推荐算法

在本文提出的图书推荐系统中, 方法部分主要包括基于用户的协同过滤(user-based collaborative filtering, UCF)模块、基于物品的协同过滤(item-based collaborative filtering, ICF)模块和卷积神经网络模块。为实现用户和图书特征的深层次匹配, 本文进一步设计了多层次的特征融合机制。

2.1 基于用户的协同过滤模块

UCF 模块的核心是根据相似度的高低, 找到相邻用户集合, 选择近邻用户感兴趣且与目标用户未产生过交互行为的图书来进行推荐, 具体步骤如下:

(1) 计算用户相似度: 协同过滤算法的关键在于计算出用户相似率性。目前计算用户相似度的方式最常用的方法是皮尔森相关系数或余弦相似度, 即通过用户相似度的算法把用户-项目的共线矩阵转换为用户-项目-用户的相似性矩阵。本文利用皮尔森相关系数围绕用户共同评分图书的评分数值展开, 充分考虑到用户的评分偏好, 计算公式为:

$$s_u(x, y) = \frac{\sum_{i \in B_{xy}} (R_{x,i} - \bar{R}_x) \cdot (R_{y,i} - \bar{R}_y)}{\sqrt{\sum_{i \in B_{xy}} (R_{x,i} - \bar{R}_x)^2} \sqrt{\sum_{i \in B_{xy}} (R_{y,i} - \bar{R}_y)^2}} \quad (2)$$

式中: B_{xy} 为用户 x 与 y 的共同评分图书集合; $R_{x,i}$ 、 $R_{y,i}$ 分别为用户 x 与 y 对图书 i 的评分; $\bar{R}_x$ 、 $\bar{R}_y$ 分别为用户 x 与 y 对所有图书的平均评分。

(2) 建立目标用户近邻集合: 对各用户之间的相似度进行降序排列, 选择与目标用户相似度最高的近邻用户集合。

(3) 预测评分: 式(3)用来预测目标用户对其邻近用户评分过的物品的评分。如出现多个不同的邻近用户对同一本书进行评分情况, 则取预测评分的平均值:

$$P_u(x, i) = \bar{R}_x + \frac{\sum_{y \in K_1} s_u(x, y) \times |R_{y,i} - \bar{R}_y|}{\sum_{y \in K_1} s_u(x, y)} \quad (3)$$

式中: $P_u(x, i)$ 表示基于 UCF 算法预测的用户 x 对图书 i 的评分; K_1 表示用户 x 的最近邻居集合。

2.2 基于物品的协同过滤模块

基于物品的协同过滤(ICF)模块主要是为了通过分析图书之间的相似性来为用户推荐相似度高的图书, 该模块输出的图书候选列表将与基于用户的协同过滤模块的输出进行合并, 并将其作为 CNN 输入的图书特征之一。但其计算相似度的对象是物品, 利用该算法对物品之间的相似度排序之后推荐给用户最高评分的图书, 具体步骤如下:

(1) 构建物品相似度矩阵: 本文利用优化矩阵计算物品之间的余弦相似度, 计算公式为:

$$s_b(i, j) = \frac{\sum_{x=1}^m R_{x,i} \times R_{x,j}}{\sqrt{\sum_{x=1}^m (R_{x,i})^2} \sqrt{\sum_{x=1}^m (R_{x,j})^2}} \quad (4)$$

式中: $R_{x,i}$ 、 $R_{x,j}$ 分别代表用户 x 对图书 i 、 j 的评分。

(2) 建立目标物品的最近邻集合: 对物品之间的相似度进行降序排列, 选取与目标图书相似度最高的近邻图书集合。

(3) 预测评分: 预测目标用户对近邻图书的评分以式(5)计算。

$$P_b(x, i) = \frac{\sum_{j \in K_2} s_b(i, j) \times R_{x,j}}{\sum_{j \in K_2} s_b(i, j)} \quad (5)$$

式中： $P_b(x, i)$ 表示基于 ICF 算法中用户 x 对图书 i 的预测评分； K_2 表示图书 i 的最近邻居集合。

2.3 模型设计

本文所提模型能够在充分利用协同过滤与 CNN 优势的基础上，有效提升图书的推荐精度和用户满意度。CNN 模块主要通过深度学习模型捕捉用户与图书之间的潜在非线性关联，该模块输出的预测得分向量将用户所需图书的可能性进行排序，进而生成个性化推荐列表。通过卷积神经网络和多层感知机可以得到用户的特征隐向量和图书的特征隐向量。将该模块推荐的结果与协同过滤算法的推荐结果合并后，再利用选择排序算法，筛选出与用户偏好最匹配的图书。该方法利用 CNN 模块实现了从浅层特征到深层次隐含关联的特征的逐步提取，3 种模块的融合有效解决了协同过滤在稀疏数据与冷启动上的不足问题，在有效帮助不同用户获取个性化的推荐信息的同时，为图书推荐系统提供了更强的适应能力和准确性。具体的模型设计如图 1 所示。




图 1 模型图

3 实验

3.1 数据预处理

本文使用 Book-Crossing 数据集进行对比实验，实验开始前对数据进行了预处理，主要包括数据清洗、评分标准化与特征提取三个步骤。数据清洗部分的目的是为了过滤掉评分较少的用户和被评分次数较少的图书以提高数据集的代表性，实验部分本文为确保实验具有一定的数据密度仅保留评分次数超过 20 次的用户与被评分超过 10 次的图书。评分标准化部分为了保证与其他推荐模型的评分范围一致对 Book-Crossing 数据集评分进行了归一化处理使其落在 0 到 1 的范围内。特征提取部分对于图书主要是提取文本描述、标题、类别标签等信息，而提取用户特征向量可以基于用户的

年龄、地区等信息。

3.2 评价标准

(1) 平均精度 (mean average precision, MAP)、召回率 (Recall)

MAP 主要用于评估推荐列表的精度，其计算公式为：

$$MAP = \frac{1}{|X|} \sum_x A(x) \quad (6)$$

$$A(x) = \frac{1}{R_x} \sum_{k=1}^N P_x(k) \cdot r_x(k) \quad (7)$$

式中： X 是所有用户集合； $|X|$ 是用户总数； $A(x)$ 是针对用户的平均精度； R_x 是用户 x 的相关项目总数； N 是推荐列表长度； $P_x(k)$ 是用户 x 的推荐列表中第 k 个位置的精度； $r_x(k)$ 的值为 0 与 1，推荐结果若为用户喜欢的书，则取值为 1，若非用户喜欢的书，则取值为 0。

(2) 均方根误差 (RMSE)

RMSE 主要是为了衡量评分预测的准确性，其具体公式为：

$$RMSE = \sqrt{\frac{1}{|N|} \sum (R(x, i) - P(x, i))^2} \quad (8)$$

式中： $R(x, i)$ 表示用户 x 对图书 i 的评分实际值； $P(x, i)$ 表示用户 x 对图书 i 的评分预测值。

3.3 实验结果与分析

为验证本文所提算法，将所提模型与 UCF、ICF、矩阵分解模型 (如 SVD)、神经协同过滤模型 (NCF)、使用 CNN 的内容推荐模型 (不结合协同过滤) 进行对比实验，以验证模型的有效性。为全面评估模型的性能，本文将实验分为基础实验组、数据稀疏性测试组、冷启动实验组。

(1) 基础实验结果

为全面评估模型的推荐系统的整体表现，本文将所提模型与对比方法在完整数据集上进行测试，如表 1 所示。

表 1 模型在完整数据集上的实验结果

方法	MAP/%	Recall/%	RMSE/%
UCF	25.2	51.2	85.0
ICF	24.5	50.5	84.5
SVD	26.8	52.3	82.2
NCF	29.0	56.3	81.0
CNN	27.5	55.0	81.5
本文所提模型	31.2	68.2	78.5

从表 1 实验结果可以看出，所提融合模型的 MAP 能达到 0.312，与 UCF 和 ICF 相比均有所提升，表明多层次特征融合能够使得推荐列表更加精准。本文所提模型的召回率达到 0.682，与单一的协同过滤方法相比提高约 18%，这表明

该模型能够更好地覆盖用户的兴趣范围。融合模型的 RMSE 在评分预测的准确性方面为 0.785，显著低于传统协同过滤方法和单一的 CNN 推荐模型，这表明所提模型在评分预测方面具备优势。

(2) 数据稀疏性测试结果

实验在数据稀疏性测试中通过随机移除 50% 的用户 - 物品交互记录模拟了数据稀疏的场景。从表 2 可以看出，所提模型与对比方法在数据稀疏性水平的数据子集上的对比，展现了较强的鲁棒性，这表明融合模型的多层次特征融合在数据稀疏情况下仍能较好地捕捉用户兴趣。

表 2 模型在数据稀疏性（50%）下的实验结果

方法	MAP/%	Recall/%	RMSE/%
UCF	20.8	47.0	92.0
ICF	21.5	47.8	91.5
SVD	23.0	49.5	89.0
NCF	24.8	51.0	87.5
CNN	24.2	50.0	88.0
本文所提模型	28.2	61.2	81.5

(3) 冷启动测试结果

本文通过引入未被评分的新用户和新图书构建冷启动情境，将提出的融合模型与其他方法对比。通过表 3 可知，在引入新用户后本文模型的 Recall 达到了 0.580，显著优于传统的协同过滤和矩阵分解模型，而引入新图书后实验结果所提融合模型的 MAP 和 Recall 也保持了较好表现，这表明本文提出的模型因 ICF 和 CNN 模块的多层嵌入在新图书信息不足的情况下，仍然能够具备良好的推荐结果。

表 3 模型在冷启动场景下的实验结果

场景	方法	MAP/%	Recall/%	RMSE/%
新用户	UCF	17.8	43.0	95.0
	ICF	18.0	42.5	94.8
	SVD	20.0	44.0	93.5
	NCF	21.5	46.0	91.0
	CNN	21.0	45.5	92.0
	本文所提模型	25.4	58.0	87.5
新图书	UCF	16.5	40.0	96.5
	ICF	17.2	40.5	96.0
	SVD	18.8	41.5	94.0
	NCF	20.0	43.0	92.0
	CNN	19.5	42.5	93.0
	本文所提模型	23.6	55.5	88.5

由表 3 结果可知，本文提出的融合模型在 Book-Crossing 数据集上的表现优于传统的协同过滤、矩阵分解和单一深度学习算法。这种基于 UCF、ICF 和 CNN 的多层次融合模型

通过有效捕捉用户和图书特征的复杂交互关系，不仅提高了推荐的精度，还表现出良好的鲁棒性和个性化特征，尤其在稀疏数据和冷启动情境下，本文模型的性能提升尤为显著，这表明 CNN 模型在捕捉用户深层兴趣上的有效性。

4 结语

本文提出了一种结合基于用户协同过滤、基于物品协同过滤与卷积神经网络的图书推荐算法，旨在通过多层次特征融合去克服单一方法的局限性，在图书推荐系统中实现更精准且个性化推荐的同时有效提升用户体验。本文的研究不仅为图书推荐提供了一种新的解决思路，也为混合推荐系统的设计和 multimodal 特征的融合提供了借鉴。未来工作将进一步优化深度模型结构，以提高计算效率并实现在线实时推荐。

参考文献：

[1] 周万珍, 曹迪, 许云峰, 等. 推荐系统研究综述 [J]. 河北科技大学学报, 2020, 41(1): 76-87.

[2] 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.

[3] ZHENG L, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation[C]// WSDM'17: Proceedings of the Tenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2017: 425-434.

[4] 陈帆, 张文德, 刘田. 基于图卷积神经网络的图书推荐方法研究 [J]. 情报探索, 2022(10):1-5.

[5] NGAFFO A N, CHOUKAIR Z. A deep neural network-based collaborative filtering using a matrix factorization with a twofold regularization[J]. Neural computing and applications, 2022, 34:6991-7003.

[6] 高飞, 林凯杰. 基于图卷积网络的双向协同过滤推荐算法 [J]. 软件, 2021, 42(7):32-38.

[7] 邓存彬, 虞慧群, 范贵生. 融合动态协同过滤和深度学习的推荐算法 [J]. 计算机科学, 2019, 46(8):28-34.

[8] 杨东风, 牛永洁. 基于混合规则的图书推荐模型设计与研究 [J]. 计算机技术与发展, 2011, 21(7):210-213.

[9] 崔家坡. 基于神经协同过滤的图书推荐算法研究 [D]. 上海: 上海第二工业大学, 2022.

【作者简介】

王莎莎 (1993—), 女, 河南驻马店人, 硕士, 教师、助理馆员, 研究方向: 图书馆学、数据检索。

(收稿日期: 2024-11-24)