

文章编号:1671-6833(2022)02-0044-07

# 基于评论文本情感注意力的推荐方法研究

郑建兴<sup>1</sup>, 郭彤彤<sup>1</sup>, 申利华<sup>2</sup>, 李德玉<sup>1</sup>

(1.山西大学 计算机与信息技术学院,山西 太原 030006; 2.山西省信息产业技术研究院有限公司,山西 太原 030012)

**摘要:** 基于评论文本的深度学习推荐方法主要利用评论文本刻画用户和项目的特征信息,学习用户对项目的评分关系,提升推荐的性能。现有研究工作在提高推荐系统精度质量的同时,忽略了情感特征在评分预测中的可解释性贡献。针对此问题,考虑了评论文本以及情感倾向分别在用户和项目嵌入中的作用,提出了一种基于评论文本情感注意力的推荐方法(IncorRAS-Rec)。首先,通过卷积神经网络(CNN)处理用户和项目的评论集,对用户和项目的评论文本进行评论特征表示,并提取相关的用户特征信息和项目特征信息,进而结合用户对项目的评分偏好,学习用户和项目的评论情感特征表示;其次,基于注意力机制为用户和项目聚合了相关的评论情感特征信息,学习用户和项目的嵌入表示;最后,结合偏置信息,基于用户和项目的嵌入预测了用户对项目的评分。在亚马逊公开数据集上进行了实验比较和分析,对模型性能进行了有效性评估。实验结果表明:所提 IncorRAS-Rec 模型不仅在均方根误差(RMSE)和平均绝对误差(MAE)评价指标上的性能要优于其他传统方法,而且能够实现基于情感特征在评分预测方面的解释性作用。

**关键词:** 评论文本; 情感特征; 注意力机制; 推荐

**中图分类号:** TP301

**文献标志码:** A

**doi:**10.13705/j.issn.1671-6833.2022.02.007

## 0 引言

推荐系统作为一种为用户提供感兴趣产品和服务的技术,已经在社交媒体、电子商务、广告营销中得到了广泛的应用。已有的推荐系统算法主要是基于用户对项目的交互历史记录,学习用户与项目的特征表示,预测用户对项目的评分。比较典型的方法是矩阵分解(MF)<sup>[1]</sup>,即根据用户和物品的评分矩阵 $A \in \mathbf{R}^{l \times q}$ ,学习 $l$ 个用户, $q$ 个物品的潜在表示,预测用户对物品的评分。传统的矩阵分解主要利用了评分交互信息,但是忽略了用户和项目在节点表示中的作用。随着电子商务的发展,用户对购买的产品或服务会进行评论,大量的评论反映了用户的兴趣,能够揭示用户的喜好以及产品的属性特征。基于评论文本内容对用户和项目建模,获取用户和项目的语义表示,也逐渐引起许多学者的关注。柴玉梅等<sup>[2]</sup>利用

CNN(convolutional neural network)对评论文本建模,获取用户和项目特征,并通过迁移学习提取面向领域的特征和领域间的共享特征进行评分预测。Zheng等<sup>[3]</sup>利用2个并行的卷积结构分别对用户和商品的评论文档建模,提出了DeepCoNN(deep cooperative neural networks)模型。

基于评论文本内容的推荐方法取得了一定成效,忽略了评论文本中与评分相关的情感特征信息。这些情感特征对学习用户和项目的表示具有重要的作用,能够提升用户对项目的评分预测精度。如何获取评论中与评分相关的评论情感特征引起了许多学者的注意。Chen等<sup>[4]</sup>考虑到评论中词汇的重要性不同,基于注意力机制选择了重要的评论信息,提升了评分预测的性能。李勇等<sup>[5]</sup>提出了位置感知的注意力机制,获取评论文本中与距离相关的序列语义特征。受到Fan等<sup>[6]</sup>启发,本文提出了一种基于评论文本情感注意力

收稿日期:2021-09-23;修订日期:2021-11-16

基金项目:国家自然科学基金资助项目(61603229, 62072294);山西省重点研发计划(国际科技合作)项目(201803D421024, 201803D421004);山西省应用基础研究计划项目(20210302123468);山西省高等学校科技创新项目(2020L0001)

作者简介:郑建兴(1985—),男,山西忻州人,山西大学副教授,博士,主要从事自然语言处理、个性化推荐等研究,  
E-mail:jxzheng@sxu.edu.cn。

的推荐方法。首先,基于 CNN 对用户和项目的评论文本进行评论特征表示,进而融合用户对项目的评分学习了用户和项目的评论情感特征表示;其次,考虑到每条评论情感特征信息对用户和项目嵌入的不同作用,基于注意力机制聚合了所有评论情感特征,学习用户和项目的嵌入;最后,结合偏置信息,预测了用户对项目的评分,在亚马逊评论数据集上验证了方法的有效性。

## 1 相关工作

传统推荐方法主要有协同过滤方法和基于内容方法。协同过滤主要包括基于用户的协同过滤和基于项目的协同过滤。基于用户的协同过滤是发现相似用户,根据相似用户的兴趣为目标用户进行推荐;基于项目的协同过滤是根据用户对项目的评论或评分,发现相似项目,进而将相似项目推荐给目标用户。矩阵分解是协同过滤中应用较广的算法。Rendle 等<sup>[7]</sup>提出的因子分解机 FM (factorization machines),结合矩阵分解和广义线性模型,解决了二阶特征组合的稀疏性问题。He 等<sup>[8]</sup>、Xin 等<sup>[9]</sup>基于深度学习的思想对 FM 进行了改进,提出了 NFM<sup>[8]</sup> (neural factorization machines) 模型和 CFM<sup>[9]</sup> (convolutional factorization machines) 模型;NFM 模型利用神经网络代替了 FM 的二阶特征交互的部分,提高了模型的性能;CFM 模型通过外积建模二阶交互,捕捉嵌入层之间的相关性。Guo 等<sup>[10]</sup>提出的 MBCN (multi-branch convolutional network) 模型利用标准一维卷积和扩张卷积,实现对相邻特征以及非相邻特征的交互建模,提升推荐的性能。

协同过滤方法在面对推荐系统冷启动和评分数据稀疏问题时性能较差,有学者开始从评论文本中获取项目的一些基本特征(如包装、功能和质量等)和用户的兴趣偏好,以刻画用户和项目的表示。Wu 等<sup>[11]</sup>提出的 CARL (context-aware user-item representation learning) 模型,以用户和项目的评论文档以及初始 ID 作为输入,学习用户和项目间的交互关系获取具有上下文的语义表示。Chin 等<sup>[12]</sup>提出的 ANR (aspect-based neural recommender) 模型将用户和项目的所有评论组成文档,实现用户对项目的评分预测。也有学者对每条评论内容进行建模,进而聚合每条评论的特征学习文档的表示。Tay 等<sup>[13]</sup>提出了一种协同关注的多指针学习推荐框架。冯兴杰

等<sup>[14]</sup>提出将评论文本与评分矩阵融合,预测用户对项目的评分。

上述研究大多没有同时考虑评论中的特征与情感倾向在用户和项目语义表示中的作用。本文通过融合评论文本的特征信息与用户评分的情感倾向信息,基于注意力机制聚合所有评论情感特征信息对用户和项目表示的影响,学习用户和项目的嵌入,提升评分预测的精度。

## 2 基于评论文本情感注意力的评分预测框架

本节介绍基于评论文本情感注意力的评分预测框架 IncorRAS-Rec,如图 1 所示。在图 1 中,框架包括评论情感特征建模、用户和项目嵌入、评分预测 3 个模块。在评论情感特征建模部分,通过 CNN 对用户和项目的评论文本进行卷积得到用户和项目评论特征表示,并与用户对项目的情感倾向融合;在用户和项目嵌入部分,通过注意力对融合情感倾向后的每条评论情感特征进行聚合,完成对用户和项目的嵌入;在评分预测部分,将得到的用户嵌入与项目嵌入进行内积计算,结合偏置项,预测用户对项目的评分。

## 3 IncorRAS-Rec 模型构建

### 3.1 融合情感倾向的评论情感特征建模

#### 3.1.1 基于 CNN 的评论特征表示

基于评论文本的语义特征可以提升推荐系统评分预测的精度。本文采用 DeepCoNN<sup>[3]</sup>中评论文本语义特征的建模方法,建立评论文本的初始特征表示。以用户的评论特征表示为例,其卷积运算主要有嵌入层、卷积层、池化层和全连接层 4 个部分。

(1) 嵌入层。将用户  $u$  的评论  $j$  中单词的序列映射成  $d$  维向量,形成嵌入向量  $\mathbf{r}_{uj}$ ;考虑到用户  $u$  所有的评论,构成嵌入矩阵  $\mathbf{V} = [\mathbf{r}_{u1}, \mathbf{r}_{u2}, \dots, \mathbf{r}_{un}]$ ,其中  $n$  为用户  $u$  设置的评论总数。

(2) 卷积层。卷积的每个神经元对应过滤器  $\mathbf{F} \in \mathbf{R}^{d \times t}$ ,  $t$  为滑动窗口大小,在嵌入矩阵  $\mathbf{V}$  上执行卷积操作获得评论的语义特征:

$$\mathbf{x} = \sigma(\mathbf{V} * \mathbf{F} + \text{bias}). \quad (1)$$

式中:  $\sigma$  为 Relu 激活函数;  $*$  表示卷积操作;  $\text{bias}$  为偏置项。

(3) 池化层。对过滤器通过滑动窗口产生的语义特征  $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{d-t+1}\}$  采用最大池化操作,选取最具有价值的特征,最大池化之后为一个固

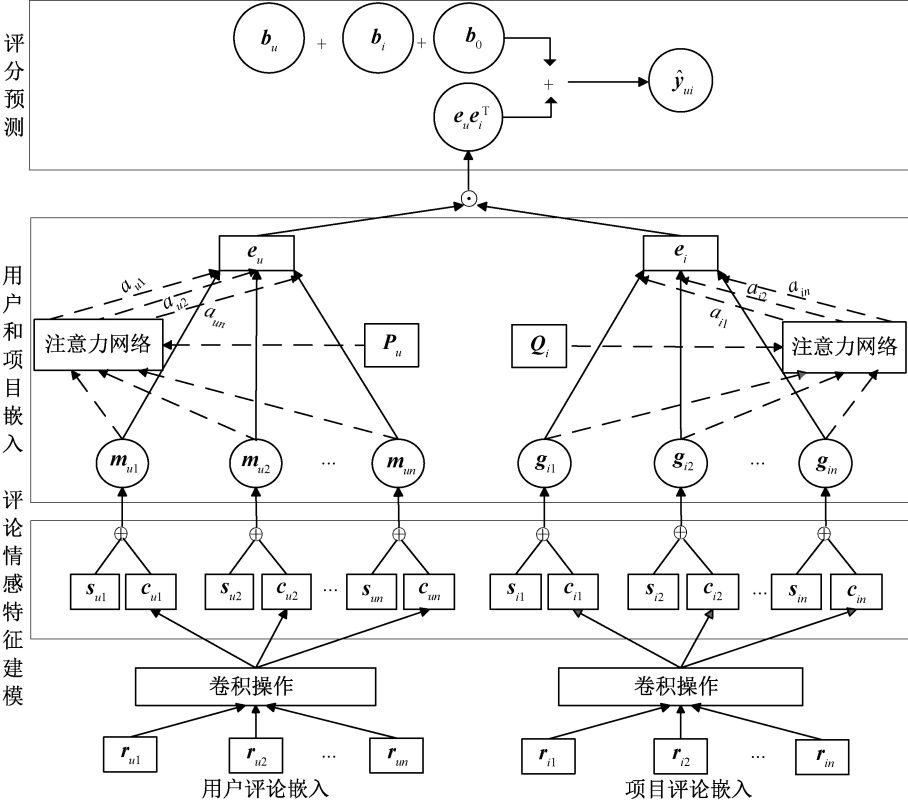


图 1 基于评论文本情感注意力的评分预测框架

Figure 1 Rating prediction framework based on sentimental attention of review text

定向量  $h$ , 定义如下:

$$h = \max \{x_1, x_2, \dots, x_{d-i+1}\}。 \tag{2}$$

卷积层最终的输出是多个过滤器获得的特征进行拼接:

$$k = h_1 \oplus h_2 \oplus \dots \oplus h_{n_1}。 \tag{3}$$

式中:  $n_1$  表示过滤器个数;  $\oplus$  表示拼接运算。

(4)全连接层。将卷积层中的结果送入权重为  $W$ , 偏置为  $b$  的全连接层中, 得到用户  $u$  的评论特征矩阵  $O_u = [c_{u1}, c_{u2}, \dots, c_{un}]$ 。

于是, 基于 CNN 的用户评论特征表示如下:

$$O_u = W \cdot k + b。 \tag{4}$$

项目的评论特征表示与用户的评论特征表示方法类似, 本小节只对用户的评论特征表示进行说明。基于 CNN 的评论特征表示利用了评论中丰富的语义信息, 有利于提高推荐算法的精度。

3.1.2 融合情感倾向的评论情感特征表示

用户对项目的评论不仅刻画了项目的特征, 还描述了用户的兴趣爱好, 同时用户对项目的评分也代表了用户对该项目的情感倾向, 这些情感倾向对于用户对项目的选择有着至关重要的影响。设用户的评分范围为 1~5 分, 本文将用户的情感倾向分为两类, 一类是积极: 4~5 分(用 1 表示); 另一类是消极: 1~3 分(用 0 表示)。对于每

个评论的情感倾向  $e \in \{0, 1\}$ , 将其进行初始嵌入  $s \in \mathbf{R}^d$ , 并将用户的评论特征表示和情感极性嵌入进行联合, 获得用户  $u$  的融合情感极性的评论特征表示  $m_{uj}$ , 定义如下:

$$m_{uj} = \text{MLP}(c_{uj} \oplus s_{uj})。 \tag{5}$$

式中:  $c_{uj}$  为用户  $u$  的第  $j$  条评论特征嵌入;  $s_{uj}$  为第  $j$  条评论的情感倾向嵌入。

项目  $i$  的融合情感倾向的评论特征表示  $g_{ij}$  与用户的融合情感倾向的评论特征表示方法类似, 本小节只对用户的评论情感特征表示  $m_{uj}$  进行说明。

3.2 基于评论情感特征注意力的用户嵌入

在图 1 中, 用户和项目嵌入旨在将融合了情感倾向的评论特征进行聚合, 学习基于评论情感特征注意力的用户和项目表示。本小节对用户嵌入进行介绍。

考虑到用户交互的多条评论信息, 将用户  $u$  的所有评论情感特征信息聚合, 得到用户嵌入  $e_u$ , 定义如下:

$$e_u = f\{m_{uj}, \forall j \in Z(u)\}。 \tag{6}$$

式中:  $f$  为聚合函数;  $Z(u)$  为用户  $u$  所有的评论集合。聚合运算有均值、最大化注意力机制等多种方法, 这里采用注意力机制学习每条评论情感

特征信息对评分预测的重要性。

给定用户  $u$  的融合情感倾向的评论特征表示  $m_{uj}$ , 以及用户 ID 的初始嵌入  $P_u$ , 计算评论情感特征信息对用户  $u$  的注意力分数, 定义如下:

$$\alpha_{uj} = \mathbf{h}^T \sigma[\mathbf{W}_a(m_{uj} \oplus P_u) + \mathbf{b}_a]. \quad (7)$$

式中:  $\sigma$  为 Relu 激活函数;  $\mathbf{W}_a$  和  $\mathbf{b}_a$  为神经网络的权重和偏置。于是, 归一化的注意力权重:

$$a_{uj} = \frac{\exp \alpha_{uj}}{\sum_{j \in Z(u)} \exp \alpha_{uj}}. \quad (8)$$

基于用户  $u$  的每条评论情感特征的注意力权重, 将用户  $u$  所有的评论进行聚合, 得到用户嵌入  $e_u$ :

$$e_u = \mathbf{W}_1 \left\{ \sum_{j \in Z(u)} a_{uj} m_{uj} \right\} + \mathbf{b}_1. \quad (9)$$

基于评论情感特征注意力的用户嵌入充分考虑了不同评论中用户的兴趣语义和情感对用户行为的影响程度, 有助于提升评分预测的精度。

### 3.3 基于评论情感特征注意力的项目嵌入

类似地, 将项目  $i$  的每条评论情感特征  $g_{ij}$  聚合, 可以学习项目的嵌入。本文将项目  $i$  的 ID 初始嵌入表示为  $Q_i$ ,  $B(i)$  是项目  $i$  的所有评论集合, 采用注意力机制计算评论情感特征信息对项目  $i$  的注意力权重  $a_{ij}$ :

$$a_{ij} = \frac{\exp \beta_{ij}}{\sum_{j \in B(i)} \exp \beta_{ij}}; \quad (10)$$

$$\beta_{ij} = \mathbf{h}^T \sigma[\mathbf{W}_s(g_{ij} \oplus Q_i) + \mathbf{b}_s]. \quad (11)$$

式中:  $\mathbf{W}_s$  和  $\mathbf{b}_s$  为神经网络的权重和偏置。通过融合评论情感特征信息  $g_{ij}$  和项目 ID 的初始嵌入  $Q_i$ , 可以提取与项目  $i$  的评分相关的重要情感特征信息。

在获得了每条评论情感特征信息的注意力权重之后, 根据注意力权重将项目  $i$  的所有评论进行聚合, 得到项目嵌入  $e_i$ :

$$e_i = \mathbf{W}_2 \left\{ \sum_{j \in B(i)} a_{ij} g_{ij} \right\} + \mathbf{b}_2. \quad (12)$$

式(12)表示对项目  $i$  的所有评论的情感特征进行加权求和, 实现了基于评论情感特征注意力的项目建模。

### 3.4 评分预测

根据用户嵌入  $e_u$  和项目嵌入  $e_i$ , 定义用户  $u$  对项目  $i$  的偏好预测分数  $\hat{y}_{ui}$ :

$$\hat{y}_{ui} = e_u^T e_i + \mathbf{b}_u + \mathbf{b}_i + \mathbf{b}_0. \quad (13)$$

式中:  $\mathbf{b}_u$ 、 $\mathbf{b}_i$  分别表示用户  $u$  和项目  $i$  的偏置;  $\mathbf{b}_0$  表示全局偏置项。偏置项能够进一步提高推荐算法的预测精度。

### 3.5 模型优化

在训练模型时, 选择平方损失函数进行优化, 定义如下:

$$Loss = \sum_{\langle u, i \rangle \in T} (\hat{y}_{ui} - y_{ui})^2 + \frac{\lambda}{2} \sum \|\mathbf{W}_0\|^2. \quad (14)$$

式中:  $\sum_{\langle u, i \rangle \in T} (\hat{y}_{ui} - y_{ui})^2$  为预测误差;  $\frac{\lambda}{2} \sum \|\mathbf{W}_0\|^2$  为  $L_2$  正则化项;  $T$  表示训练集中的用户项目对集合;  $\hat{y}_{ui}$  和  $y_{ui}$  分别表示用户  $u$  对项目  $i$  的预测值和真实值;  $\mathbf{W}_0 = [\mathbf{W}_a, \mathbf{W}_s]$  为模型中注意力神经网络的学习参数;  $\lambda$  用于控制均方误差和正则项  $\|\mathbf{W}_0\|^2$  之间的关系, 通过调整  $\lambda$  的取值, 对正则项进行约束, 使得正则项中的每个权重元素都很小, 降低模型复杂度, 防止训练过程中出现过拟合。

## 4 实验与分析

### 4.1 数据集

本文在亚马逊公开的 5-core 商品评论数据集 Musical\_Instruments 和 Amazon\_Instaant\_Video 上验证 IncorRAS-Rec 方法的有效性。数据集包含了用户对项目的评论以及评分信息, 评分取值为 1~5 分。实验数据集统计信息如表 1 所示。

表 1 实验数据集统计信息

Table 1 Statistical information of experimental dataset

数据集	用户数	项目数	评论数
Musical_Instruments	1 429	900	10 261
Amazon_Instaant_Video	5 130	1 685	37 126

在实验过程中, 采用 MAE 和 RMSE 指标来比较不同模型在评分预测方面的性能。

### 4.2 对比算法

本文选取了几种传统模型和基于评论文本的模型与 IncorRAS-Rec 模型进行性能比较。

(1) PMF<sup>[15]</sup>: 基于用户项目的评分矩阵, 采用概率矩阵分解实现了用户和项目的潜在表示, 预测了用户对项目的评分。

(2) BPMF<sup>[16]</sup>: 在 PMF 模型基础上, 将超参数的先验置为 Gaussian-Wishart 分布, 进行评分预测。

(3) SVD++<sup>[17]</sup>: 结合了用户对项目的显式反馈和隐式反馈信息, 学习用户和项目的潜在表示, 实现评分预测。

(4) DeepCoNN<sup>[3]</sup>: 通过 2 个并行的 CNN 结构学习了评论文本中用户和项目的特征, 实现评分预测。

(5) NARRE<sup>[4]</sup>: 在 DeepCoNN 模型基础上, 使

用注意力机制识别评论文本在评分预测中的作用,提升了评分预测的性能。

4.3 实验设置

在实验过程中,对于 IncorRAS-Rec 模型采用网格搜索法,从 {16,32,64,128} 寻找最佳嵌入维度。为防止过拟合, $L_2$  正则化参数  $\lambda$  在 {0,0.001,0.01,0.1} 中查找。实验过程中选择 Relu 作为隐藏层的激活函数,选择 Adam 对模型进行优化,学习率设置为 0.001,脱落率设置为 0.5。

对于评论文本数据,本文使用了 word2vec 在 GoogleNews 谷歌新闻语料库上的预训练嵌入,获取词向量的表示。为确保实验的公平性,本文参照 NARRE 模型<sup>[4]</sup>的实验设置,将当前数据集中每个用户(项目)的评论文本长度按照从小到大排序,对应 90%分位点的评论文本长度作为该数据集的用户(项目)评论文本长度,每个用户(项目)评论集中评论条数的选取方法与截取评论文本长度类似。

4.4 实验结果与分析

本文在亚马逊数据集上对 IncorRAS-Rec 模型和对比方法进行了性能比较,实验结果如表 2 所示。通过对实验结果分析,可以得出如下结果:

(1)在 Musical\_Instruments 和 Amazon\_Instant\_Video 数据集上,只考虑了评论文本的模型 DeepCoNN,其 MAE 和 RMSE 结果要低于仅利用评分信息的协同过滤模型,如 PMF、BPMF、SVD++,这表明评论文本比评分信息更有助于获取用户和项目的语义信息,学习用户和项目的特征,提升推荐性能。

(2)同时考虑评论文本和评分信息的模型,如 NARRE 和 IncorRAS-Rec,比仅利用评论文本的模型 DeepCoNN 和仅利用评分信息的 PMF、BPMF 和 SVD++模型,性能更优,表明了融合评论文本以及评分信息能够更好地学习用户和项目的潜在表示,提升评分预测精度。

(3)本文提出的 IncorRAS-Rec 模型在 2 种数据集上的实验结果都优于其他模型。在 Musical\_Instruments 数据集上,IncorRAS-Rec 模型的 MAE 相比 NARRE 和 BPMF 分别降低了 3.6% 和 13.8%,RMSE 相比于 NARRE 和 BPMF 分别降低了 0.9% 和 4.9%。在 Amazon\_Instant\_Video 数据集上,IncorRAS-Rec 模型的 MAE 相比 NARRE 和 BPMF 分别降低了 2.1% 和 11.6%,RMSE 相比于 BPMF 降低了 3.9%。在 NARRE 数据集上的提升效果并不明显。

以上结果表明,相比基于传统协同过滤的 BPMF 模型,本文提出的 IncorRAS-Rec 模型充分利用了评论文本中的语义信息,深入挖掘了用户的兴趣偏好和项目的特征,增强了推荐结果的可解释性。此外,与同时结合评论文本和评分数据的 NARRE 模型相比,IncorRAS-Rec 使用 MLP 提取用户和项目融合情感倾向的评论特征表示,并基于注意力机制,聚合了用户和项目的全部评论情感特征信息,提升了预测结果的精确度,验证了 IncorRAS-Rec 模型的有效性。

表 2 不同算法在 2 种数据集上的性能比较

Table 2 Performance comparison of different algorithms on two datasets

算法	Musical_Instruments		Amazon_Instant_Video	
	MAE	RMSE	MAE	RMSE
PMF	0.743 9	1.018 6	0.754 9	1.028 2
SVD++	0.740 2	0.970 1	0.779 5	1.012 1
BPMF	0.738 3	0.976 1	0.774 4	0.996 2
DeepCoNN	0.653 7	0.952 9	0.690 2	0.968 3
NARRE	0.660 1	0.936 6	0.698 3	0.959 8
IncorRAS-Rec	0.636 6	0.928 6	0.683 4	0.956 9

4.5 参数敏感度分析

本小节在 Musical\_Instruments 和 Amazon\_Instant\_Video 2 个数据集上分析嵌入维度和正则化参数对 IncorRAS-Rec 模型性能的影响。

4.5.1 嵌入维度

嵌入维度是影响模型性能的关键因素。本文选择在 {16,32,64,128} 维度上对 IncorRAS-Rec 模型进行 MAE、RMSE 指标分析,实验结果如图 2 所示。

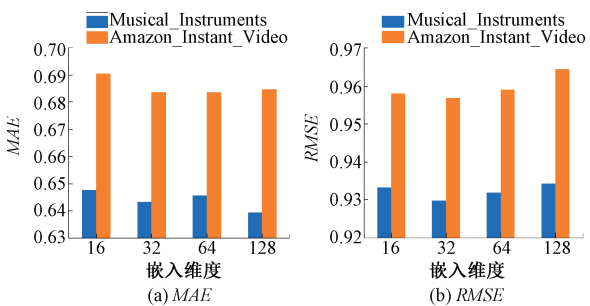


图 2 嵌入维度对 MAE 和 RMSE 的影响

Figure 2 Effect of embedding dimension on MAE and RMSE

在 Amazon\_Instant\_Video 数据集上,随着嵌入维度的增加,IncorRAS-Rec 模型的 MAE 和 RMSE 值呈现先下降后上升的趋势。因此,实验过程中选择 32 作为模型在该数据集上的嵌入维度。

在 Musical\_Instruments 数据集上,当嵌入维度为 32 时,IncorRAS-Rec 模型不仅在  $RMSE$  指标下表现优异,同时在  $MAE$  上的结果也相对较好。因此,实验过程中选择 32 作为模型在该数据集上的嵌入维度。

4.5.2 正则化参数  $\lambda$

正则化项通常是机器学习中避免模型过拟合的有效手段之一。图 3 展示了正则化参数  $\lambda$  对 IncorRAS-Rec 模型在 2 种数据集上结果的影响。

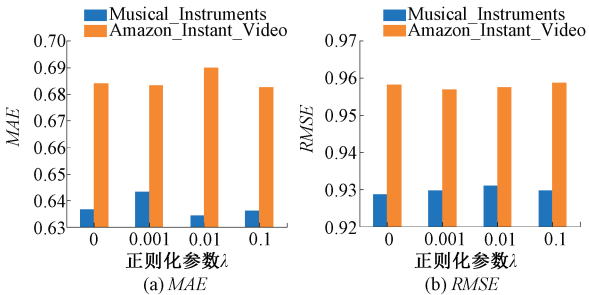


图 3 正则化参数对  $MAE$  和  $RMSE$  的影响  
Figure 3 Effect of regularization parameters on  $MAE$  and  $RMSE$

在 Musical\_Instrument 数据集上,当  $\lambda = 0.01$  时,IncorRAS-Rec 模型在  $MAE$  指标下取得了较好的效果, $RMSE$  指标下性能一般。当  $\lambda = 0$  时,模型不仅在  $RMSE$  下表现优异, $MAE$  结果也相对较好。因此,本文在 Musical\_Instruments 数据集上选择正则化参数  $\lambda = 0$  进行实验比较。

在 Amazon\_Instant\_Video 数据集上,当  $\lambda = 0.001$  或  $0.1$  时,IncorRAS-Rec 模型在  $MAE$  指标的性能较好。在  $RMSE$  指标方面,当  $\lambda = 0.1$  时,IncorRAS-Rec 模型的性能不太理想,而当  $\lambda = 0.001$  时模型的结果相对较好。因此,本文在 Amazon\_Instant\_Video 数据集上选择正则化参数  $\lambda = 0.001$  进行实验比较。

4.6 注意力机制有效性分析

为了验证注意力机制对模型性能的影响,对 IncorRAS-Rec 模型中每条评论情感特征信息的注意力机制用均值聚合进行替换,学习用户和项目的表示,比较模型记为 IncorRAS-A。图 4 展示了注意力机制与均值聚合方法在 2 种数据集下的推荐性能实验对比结果。

由图 4 可知,在 2 种数据集上,IncorRAS-Rec 的评分预测性能相比 IncorRAS-A 都有显著优势。这表明不同评论情感特征信息的有效性不同。与均值聚合方法相比,基于注意力机制的方法可以有效学习不同评论情感特征信息在用户和项目表

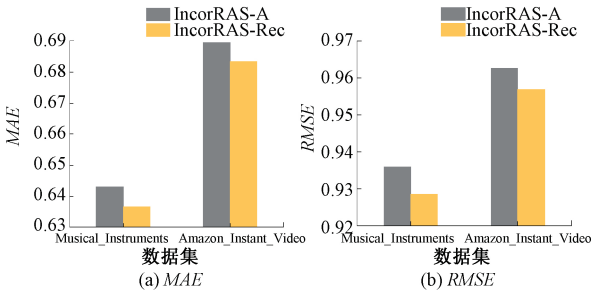


图 4 注意力机制与均值聚合方法的评分预测结果比较  
Figure 4 Comparison of score prediction results between attention mechanism and mean aggregation method

示中的贡献,进而在评分预测准确性方面表现了较好的性能,提升了推荐系统的质量。

4.7 可视化分析

为了进一步解释情感特征对于节点嵌入的有效性,实验过程中,随机从 Musical\_Instruments 数据集中选取了 4 个用户 (User) 对 2 个项目 (Item) 的评论语句,通过可视化的方式解释评论情感特征信息在用户评分过程中的影响,如图 5 所示。在图 5 中,五角星的个数表示用户对项目的评分,红色部分表示了与评分信息相关的评论情感特征词。

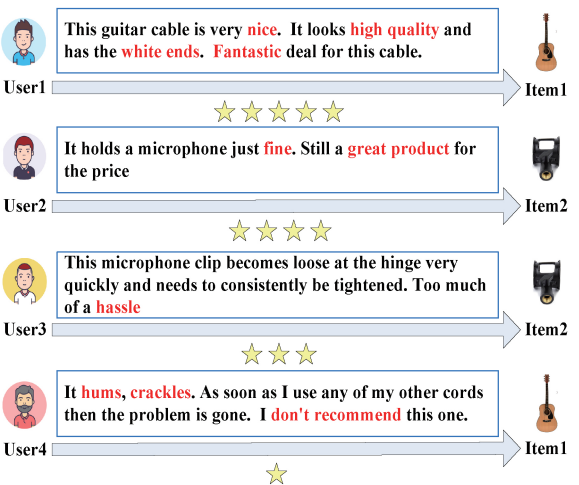


图 5 案例可视化分析  
Figure 5 Case visual analysis

在图 5 中,第 1 条评论是 User1 对 Item1 (吉他线) 购买后的评价。“white ends”体现了 Item1 的特征,“nice”、“high quality”和“Fantastic”表达了 User1 对 Item1 的积极情感,认为它质量很好,很满意。因此,User1 对 Item1 给出了 5 分评价。

第 4 条评论是 User4 对 Item1 的使用感受评价。“hums”和“crackles”描述了 User4 对 Item1 的特征感受,认为它发出嗡嗡的响声,并且“don't recommend”。因此,User4 对 Item1 评价较低,评分为 1。

上述可视化案例说明了 IncorRAS-Rec 模型能够很好地学习评论中与评分相关的情感特征,这些情感特征在提升评分预测精度的同时,可以使预测结果更具有解释性。

5 结论

本文提出了基于评论文本情感注意力的推荐方法。首先,基于 CNN 结构学习了用户和项目的每条评论的特征表示;其次,将每条评论的特征表示与情感倾向表示融合,通过注意力机制计算了每条评论的情感特征信息对于用户和项目嵌入的重要性,进而聚合了所有评论的情感特征信息,学习用户和项目的嵌入;最后,基于用户和项目的嵌入实现了评分预测,并在亚马逊公开数据集上进行了实验验证。实验结果表明,本文提出的 IncorRAS-Rec 模型在 RMSE 和 MAE 指标上均有显著改善。

参考文献:

[1] KOREN Y,BELL R,VOLINSKY C.Matrix factorization techniques for recommender systems[J]. Computer, 2009,42(8):30-37.

[2] 柴玉梅,员武莲,王黎明,等. 基于双注意力机制和迁移学习的跨领域推荐模型[J]. 计算机学报, 2020, 43(10):1924-1942.

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

[4] CHEN C,ZHANG M,LIU Y Q,et al.Neural attentional rating regression with review-level explanations[C]// Proceedings of the 2018 World Wide Web Conference on World Wide Web. New York: ACM, 2018: 1583-1592.

[5] 李勇,金庆雨,张青川.融合位置注意力机制和改进 BLSTM 的食品评论情感分析[J].郑州大学学报(工学版),2020,41(1):58-62.

[6] FAN W Q,MA Y,LI Q,et al.Graph neural networks for social recommendation[C]//The World Wide Web Conference. New York: ACM, 2019:417-426.

[7] RENDLE S. Factorization machines [C]//2010 IEEE International Conference on Data Mining. Piscataway: IEEE, 2010:995-1000.

[8] HE X N,CHUA T S.Neural factorization machines for sparse predictive analytics [C]//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2017:355-364.

[9] XIN X,CHEN B,HE X N,et al.CFM:convolutional factorization machines for context-aware recommendation [C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI 2019). New York: ACM, 2019:3926-3932.

[10] GUO W,ZHANG C,GUO H F,et al.Multi-branch convolutional network for context-aware recommendation[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020:1709-1712.

[11] WU L B,QUAN C,LI C L,et al.A context-aware user-item representation learning for item recommendation [J]. ACM transactions on information systems, 2019, 37(2):1-29.

[12] CHIN J Y,ZHAO K Q,JOTY S,et al.ANR: aspect-based neural recommender [C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. New York: ACM, 2018: 147-156.

[13] TAY Y,LUU A T,HUI S C.Multi-pointer co-attention networks for recommendation[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018:2309-2318.

[14] 冯兴杰,曾云泽.基于评分矩阵与评论文本的深度推荐模型[J].计算机学报,2020,43(5):884-900.

[15] MNIH A, SALAKHUTDINOV R. Probabilistic matrix factorization [C]//Proceedings of the 20th International Conference on Neural Information Processing Systems. New York: ACM, 2007:1257-1264.

[16] SALAKHUTDINOV R,MNIH A.Bayesian probabilistic matrix factorization using Markov chain Monte Carlo [C]//Proceedings of the 25th International Conference On Machine Learning. New York: ACM, 2008:880-887.

[17] KOREN Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model [C]//Proceeding of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008:426-434.

(下转第 57 页)

crack stress intensity factor was formed, and the general program suitable for general finite element method was written to analyze the unidirectional tensile model of an infinite plate with a central crack. By changing the mesh size and crack angle to analyze the influence of crack stress intensity factor, the stress intensity factor values of type I, type II and type I, II composite cracks obtained by the algorithm were compared with the theoretical values. With the decrease of mesh size, the stress intensity factor values of type I and type II obtained by S-XFEM approached to the exact solution continuously. With the increase of crack degree, the stress intensity factor value of type I increased continuously, and the stress intensity factor of type II increased first and then decreased with the angle. The larger the angle was, the closer the crack was to the type I crack. Therefore, the stress intensity factor calculated by the S-XFEM had high accuracy and good adaptability. Secondly, on this basis, the crack propagation criterion was introduced, and the MATLAB programming was used to study the crack propagation path of four-point bending experimental model of the plate with side cracks and the beam with holes. The results showed that the crack propagation path obtained by this example was consistent with that obtained by references. Finally, in this paper, S-XFEM was used to study the crack propagation, compared to using other methods for crack propagation research, it was not necessary to re-divide or encrypt the grid in the area near the crack, which would make the analysis process more simple, improve the computational efficiency.

**Keywords:** smooth-extended finite element method; stress intensity factor; crack propagation; numerical simulation; MATLAB programming

(上接第 50 页)

## Research on Recommendation Method Based on Sentimental Attention of Review Text

ZHENG Jianxing<sup>1</sup>, GUO Tongtong<sup>1</sup>, SHEN Lihua<sup>2</sup>, LI Deyu<sup>1</sup>

(1.College of Computer and Information Technology, Shanxi University, Taiyuan 030006, China; 2.Shanxi Information Industry Technology Research Institute Co., Ltd., Taiyuan 030012, China)

**Abstract:** Recommendation methods of deep learning-based on review text mainly means to describe the feature information of users and items by terms of review texts, by rating relationship between users and items to improve the recommendation performance. Existing studies ignore the interpretable contribution of sentimental features on the rating prediction. To solve this problem, by incorporating the roles of review text and sentimental polarity orientation in the embeddings of users and items, respectively, a sentimental attention recommendation method was proposed based on review text (IncorRAS-Rec); Firstly, CNN (convolutional neural network) was used to handle review sets for users and items, represent the review features of users and items, and obtain relevant users features and items features; Then, by combining users' rating preference for items, users and items embedding with reviews' sentimental features were learned. Secondly, by aggregating reviews' relevant sentimental feature information for users and items in terms of attention mechanism, the embeddings of users and items were learned; Finally, the users ratings on the items were predicted based on users and items embeddings together with their bias information. The experimental comparison and analysis were carried out on public Amazon datasets, to evaluates the effectiveness of the model performance. Experimental results showed that the proposed IncorRAS-Rec model not only could outperform other traditional methods in terms of *RMSE* (Root mean square error) and *MAE*(Mean absolute error) metrics, but also implement the explanatory role of sentimental features in rating prediction.

**Keywords:** review text; sentimental features; attention mechanism; recommendation