

# 融合评论文本特征和评分图卷积表示的推荐模型

冯海林, 张潇, 刘同存

(浙江农林大学数学与计算机科学学院, 浙江 杭州 311300)

**摘要:** 为了充分利用评分的有效信息, 并进一步研究评论的重要性, 提出了一种融合评论文本特征和评分图卷积表示的推荐模型, 利用图卷积编码学习用户和商品在评分上的特征表示, 结合文本卷积特征, 使用注意力机制来区分评论的重要性, 然后通过隐因子模型把在评论和评分上学习到的特征表示融合产生推荐。在亚马逊公开数据集上的实验结果表明, 提出的模型显著优于现有的模型, 证明了提出的模型的有效性。

**关键词:** 推荐模型; 图卷积编码; 注意力机制; 隐因子模型

**中图分类号:** TP391

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2022049

## Recommendation model combining review's feature and rating graph convolutional representation

FENG Hailin, ZHANG Xiao, LIU Tongcun

College of Mathematics and Computer Science, Zhejiang A & F University, Hangzhou 311300, China

**Abstract:** In order to fully exploit the effective information of the ratings and further investigate the importance of the review, a recommendation model combining review's feature and rating graph convolutional representation was proposed. Graph convolutional neural network was used to learn the representation of user and item from the ratings data. Combining with text convolutional features, attention mechanism was utilized to distinguish the importance of the review. Finally, the representation learned from the review and the rating data was fused by the hidden factor model. The experimental results on Amazon's public data showed that the proposed model significantly outperformed the traditional approaches, proving the effectiveness of the proposed model.

**Keywords:** recommender model, graph convolutional encoder, attention mechanism, latent factor model

### 0 引言

互联网的迅速发展带来了信息过载问题, 这使用户从海量的信息中获取自己需要的信息极其困难, 推荐系统作为解决信息过载的重要工具, 可以帮助用户发现他们感兴趣的内容。推荐系统的评分预测可看作矩阵补全任务, 即基于矩阵中已有的数据来填补矩阵中缺失的部分, 然而观测到的用户行为数据是极其稀疏的, 如何根据极其稀疏的观测数

据来较准确地预测未观测数据一直以来都是推荐系统研究的关键课题。早期的方法主要是利用矩阵分解技术, 仅仅利用用户对商品的评分来推断<sup>[1-2]</sup>, 但用户的反馈行为不仅有评分, 还包含丰富的评论信息, 这些评论文本能够体现出用户的购物偏好以及商品的属性吸引力, 可以加强对用户和商品的表征学习能力, 从而提高推荐系统的推荐质量<sup>[3]</sup>。

近年来, 深度学习技术所具备的较强特征提取能力<sup>[4-7]</sup>使其在推荐系统中得到了广泛应用, 也在一定

收稿日期: 2021-11-19; 修回日期: 2022-02-14

通信作者: 刘同存, liutongcun@ebupt.com

基金项目: 国家自然科学基金资助项目 (No.U1809208); 浙江省自然科学基金资助项目 (No.LGG22F020010)

**Foundation Items:** The National Natural Science Foundation of China (No.U1809208), The Natural Science Foundation of Zhejiang Province (No.LGG22F020010)

程度上缓解了用户评分的稀疏性问题<sup>[8-9]</sup>。但是现有的基于深度学习的方法仍然存在可以改进的地方,比如在评分数据的处理上,脱离传统的矩阵分解方法,以其他方式学习评分特征可能会提升推荐模型的精准度;另外,不同的评论所包含的语义信息不同,如何对重要的评论进行选取和建模,也需要进行进一步的研究分析。

本文对以上提出的可改进的部分加以研究,提出了融合评论文本和评分图卷积表示(CRRG, combining review's feature and rating graph convolutional representation)的推荐模型。该模型利用图卷积编码学习用户和商品的评分特征表示,首先获取用户-商品评分集(用户对商品的评分数据),根据用户对商品的评分等级,在用户-商品二部图上进行信息传递;然后获取用户评论集(用户对商品的评论信息)和商品评论集(商品中各个用户的评论信息),通过卷积神经网络分别提取用户和商品的文本卷积特征,引入注意力机制,利用用户(商品)在评分上的特征表示区分评论重要性,从而获取更准确的评论文本特征;最后将评论文本特征和评分特征拼接融合,将得到的用户和商品最终特征表示输入隐因子模型中产生推荐结果。本文所提CRRG模型的贡献可以总结为以下3点。

1) 本文提出的模型结合卷积神经网络和图卷积编码器对用户及商品评论文本以及评分数据进行联合建模,学习用户和商品的特征表示。

2) 在评分数据上使用图卷积编码器并结合注意力机制对用户和商品特征进行表示,使模型在评论建模时可以区分评论的重要性,融合用户和商品评分特征及相应的评论文本特征,通过增强用户和商品的信息交互提升模型精度。

3) 在亚马逊公共数据集上进行了对比实验,结果表明本文提出的CRRG模型在评分预测上的均方误差(MSE, mean square error)低于现有的相关模型,证明了本文提出的模型的有效性。

## 1 相关工作

### 1.1 基于主题建模的推荐

早期的研究工作主要使用主题建模技术从用户的评论文本中进行语义分析,提取语义特征,将潜在的语义主题整合到学习模型中进行推荐。文献[10]提出了最早期的基于用户的评论数据进行推荐的方法,分别使用用户和商品的评论数据进行评分的预测;文献[11]使用每个用户对某个具体商品的评

论建模,并且用不同的关联机制将用户和商品的表示和学到的主题模型进行关联;文献[12]将文本信息上的降噪自编码器(SDAE, stacked denoising autoencoder)<sup>[13]</sup>与隐式评分矩阵的概率矩阵分解(PMF, probabilistic matrix factorization)<sup>[1]</sup>紧密耦合,从文本中学习可解释的潜在因素。这些方法都优于仅依赖用户商品评分数据交互的模型,但是都属于词袋模型,忽略了单词顺序和局部上下文信息,导致评论中重要信息的丢失。

### 1.2 基于深度学习的推荐

国内外研究者提出了许多方法对评论的上下文信息进行建模,显著提高了推荐精度。例如, Kim等<sup>[4]</sup>提出了卷积矩阵分解(ConvMF, convolutional matrix factorization)模型,使用卷积神经网络从商品描述中提取商品特征,将上下文信息合成为连续的实值矢量表示;文献[14]模型从用户和商品文档中提取特征,利用该特征来校准学习模型中的潜在因子;深度协同神经网络(DeepCoNN, deep cooperative neural network)<sup>[5]</sup>模型使用并行的卷积神经网络从用户和商品文档中发现语义特征。这些方法的推荐效果优于基于词袋的方法,但它们仅以静态和独立的方式学习用户和商品的潜在特征向量,忽略了不同评论的重要性差异,以及评论内部不同单词的重要性差异。

最近的许多工作利用注意力机制从文本信息中学习上下文感知的潜在表示。例如,文献[15]利用Local和Global这2个注意力机制来识别评论文档中的重要单词;文献[16]利用基于指针的共同注意力方法,选出重要的评论及重要的单词;Chen等<sup>[8]</sup>提出NARRE(neural attentional regression model with review-level explanation)模型,通过评论级别的注意力机制来刻画每一条评论的权重,选择有用的评论进行评分预测;文献[17]应用词注意力机制对商品文本进行编码,从而更好地理解商品的内容;Zhou等<sup>[18]</sup>提出了双头注意力融合自动编码器模型,应用早期融合模块,利用注意力机制选择与推荐任务相关的评论;Liu等<sup>[19]</sup>提出一种个性化的注意力模型NRPA(neural recommendation with personalized attention),为不同的用户或商品选择不同的重要单词和评论;梁顺攀等<sup>[20]</sup>提出SACR(self-attention capsule network rate)模型,通过自注意力胶囊网络来挖掘用户评论文档,对低质量评论进行编号标记。这些基于注意力机制的推荐研究考虑到单词或评论的重要性,更准确地学习到用户或

商品特征表示,取得了较好的推荐效果。另外,还有一些基于深度学习的推荐方法,冯兴杰等<sup>[21]</sup>以及李昆仑等<sup>[22]</sup>提出的推荐算法都使用了预训练的双向编码器表示(BERT, bidirectional encoder representation from transformer)模型提取评论文本信息,构造评论文本的特征表示,提升了模型对同一单词在不同语义环境下具体含义的理解能力。

近年来,多视图的结构也被应用到推荐中,Gao等<sup>[23]</sup>构建了一个深度可解释网络的初始结构,利用注意力多视图学习对深度可解释网络中每层的参数进行优化,通过无监督的方式分析了用户是对低层特征感兴趣还是对高层特征整体感兴趣;图卷积矩阵补全(GC-MC, graph convolutional matrix completion)模型<sup>[24]</sup>设计了一种对矩阵进行补全的图自编码器框架,将评分作为用户-商品图的链接边,通过在用户和商品的交互图上进行信息传递学习节点的嵌入,但是该模型并没有结合评论文本信息;Gao等<sup>[25]</sup>将评论的辅助信息混合,提出了集合-序列-图的多视图方法,采用3种方式编码器架构,共同学习用户和商品的表示形式。虽然这些研究在一定程度上提升了推荐的准确度,但在获取重要性评论方面仍然可以进行进一步的研究,并且可以继续探究融合评论文本和评分数据对推荐模型优化的有用性。

## 2 推荐模型

本文提出的CRRG模型架构如图1所示。CRRG模型共包括4个模块:1)文本向量化,将用户和商品评论集分别通过嵌入层输出评论文本的嵌入向量;2)特征工程,首先将评论文本的嵌入向量通过卷积层利用卷积神经网络获取文本的卷积特征,再将用户-商品评分集通过图卷积编码获取用户和商品在评分上的特征表示;3)特征交互,通过注意力层将用户和商品的文本卷积特征与评分特征进行交互,得到用户和商品最终的评论文本特征,再通过连接操作和内积运算得到融合特征;4)评分预测,利用隐因子模型计算用户对商品的预测评分。

### 2.1 文本向量化

对于用户 $u$ 的评论集,合并所有评论形成用户文档 $D_u = [w_1, w_2, \dots, w_m]$ ,其中 $m$ 表示用户 $u$ 的评论数量,然后将文档中每条评论的单词进行嵌入表示,使用word2vec进行词向量的预训练,得到用户 $u$ 的评论文本向量化表示 $E_u$ 为

$$E_u = [E_{u,1}, E_{u,2}, \dots, E_{u,m}] \quad (1)$$

其中, $E_{u,j} \in \mathbb{R}^{c \times d}$ 表示用户 $u$ 第 $j$ 条评论的嵌入矩

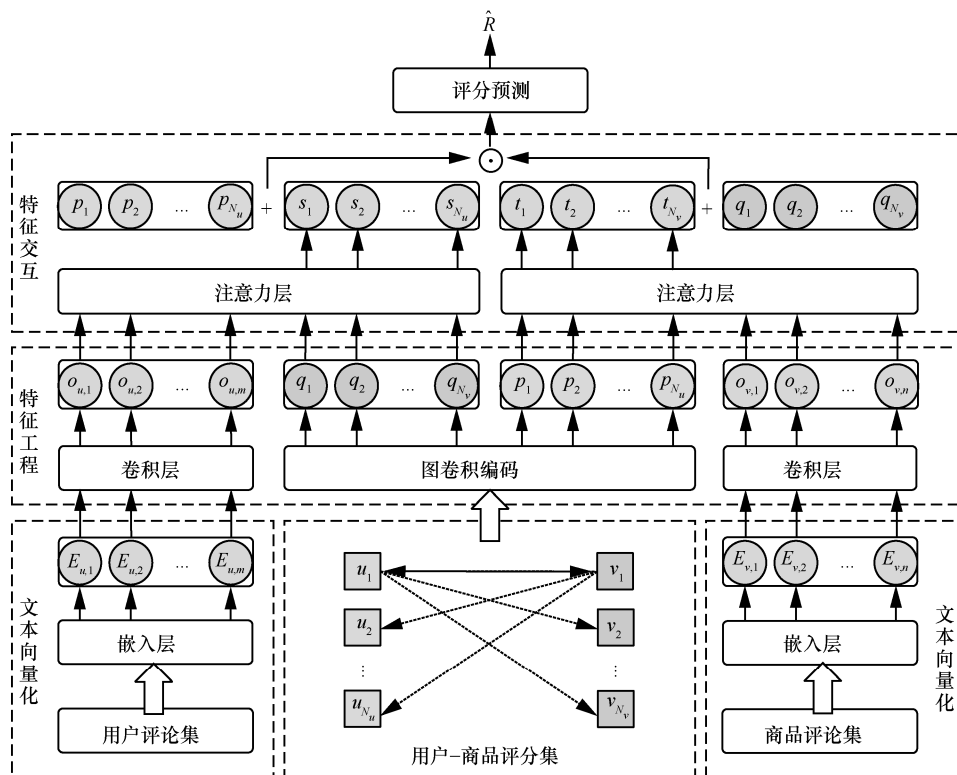


图1 CRRG模型架构

阵,  $c$  表示该条评论的长度,  $d$  表示单词嵌入维度。同样地, 可以用类似的方式获得商品  $v$  的评论文本向量化表示  $\mathbf{E}_v = [\mathbf{E}_{v,1}, \mathbf{E}_{v,2}, \dots, \mathbf{E}_{v,n}]$ , 其中  $n$  表示商品  $v$  的评论数量。

## 2.2 特征工程

### 2.2.1 卷积神经网络

首先, 基于用户和商品的评论文本向量化表示, 利用卷积神经网络提取用户和商品的评论文本卷积特征。卷积层由  $\alpha$  个神经元组成, 每一个神经元与卷积滤波器  $\mathbf{F} \in \mathbb{R}^{h \times d}$  关联, 其中  $h$  表示滑动窗口, 该滤波器通过在嵌入矩阵上应用卷积运算产生卷积特征。第  $k$  个神经元产生的局部特征  $\mathbf{z}_k$  表示为

$$\mathbf{z}_k = \text{ReLU}(\mathbf{E}_{u,j} * \mathbf{F}_k + \mathbf{b}_k) \quad (2)$$

其中,  $\mathbf{b}_k \in \mathbb{R}^h$  表示偏置,  $*$  表示卷积运算符号,  $\text{ReLU}$  表示激活函数。

然后, 执行最大池化操作, 得到第  $k$  个神经元产生的最终特征  $\mathbf{o}_k$ , 把  $\alpha$  个神经元产生的特征根据滑动窗口  $h$  的维度进行连接, 得到用户  $u$  第  $j$  条评论的文本卷积特征  $\mathbf{o}_{u,j} \in \mathbb{R}^h$ , 最后得到用户  $u$  的所有评论文本卷积特征  $\mathbf{O}_u \in \mathbb{R}^{m \times h}$ , 该过程表示为

$$\mathbf{o}_k = \max(\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k^{c-h+1}) \quad (3)$$

$$\mathbf{o}_{u,j} = [\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_\alpha] \quad (4)$$

$$\mathbf{O}_u = [\mathbf{o}_{u,1}, \mathbf{o}_{u,2}, \dots, \mathbf{o}_{u,m}] \quad (5)$$

其中,  $\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k^{c-h+1}$  表示第  $k$  个神经元在滑动窗口  $h$  上产生的特征。同样地, 也可以生成商品  $v$  的所有评论文本卷积特征  $\mathbf{O}_v = [\mathbf{o}_{v,1}, \mathbf{o}_{v,2}, \dots, \mathbf{o}_{v,n}]$ , 其中,  $\mathbf{O}_v \in \mathbb{R}^{n \times h}$ ,  $\mathbf{o}_{v,n} \in \mathbb{R}^h$  表示商品  $v$  第  $n$  条评论的文本卷积特征。

### 2.2.2 图卷积编码

给定用户-商品评分集, 构建图编码模型获取用户和商品的评分特征, 相比于将评分矩阵分解为 2 个低维矩阵的乘积, 只能提取模型的浅层次特征, 构建图编码模型可以在用户-商品二部图上进行信息传递, 用户(商品)节点可以由与其交互过的商品(用户)进行表示。具体来说, 将用户-商品评分集转换为评分矩阵  $\mathbf{M} \in \mathbb{R}^{N_u \times N_v}$ , 其中,  $N_u$  表示用户数量,  $N_v$  表示商品数量,  $M_{ij}$  表示用户  $i$  对商品  $j$  的评分。用户-商品的评分交互数据可以用二部图  $\mathbf{G} = (\mathfrak{U}, \mathfrak{V}, \mathfrak{R})$  表示, 其中,  $\mathfrak{U}$  表示用户节点  $u_i \in \mathfrak{U}$ ,  $i \in \{1, \dots, N_u\}$  和商品节点  $v_j \in \mathfrak{V}$ ,  $j \in \{1, \dots, N_v\}$  的集合,  $(u_i, r, v_j) \in \mathfrak{R}$  表示二

部图的边, 携带表示评分等级的标签, 如  $r \in \{1, \dots, R\} = \mathfrak{R}$ ,  $R$  表示评分等级的最大值。本文借鉴 GC-MC<sup>[24]</sup> 的图编码模型进行编码, 表示为

$$[\mathbf{P}, \mathbf{Q}] = f(\mathbf{X}_u, \mathbf{X}_v, \mathbf{M}_1, \dots, \mathbf{M}_r) \quad (6)$$

其中,  $\mathbf{X}_u \in \mathbb{R}^{N_u \times D_u}$  表示输入用户特征矩阵,  $\mathbf{X}_v \in \mathbb{R}^{N_v \times D_v}$  表示输入商品特征矩阵;  $D_u$  表示输入用户特征的数量;  $D_v$  表示输入商品特征的数量,  $\mathbf{M}_r \in \{0, 1\}^{N_u \times N_v}$  表示与评分类型  $r \in \mathfrak{R}$  相关的邻接矩阵, 交互过的值为 1, 没交互过的值为 0;  $\mathbf{P}$  表示用户的评分特征,  $\mathbf{Q}$  表示商品的评分特征。

图编码模型可以有效利用图形中各个位置之间的权重分配, 并为每种评分类型  $r \in \{1, \dots, R\}$  分配单独的处理通道。局部图卷积可以看作信息传递, 其中特征值的信息被沿着图的边传递和转换, 即用户可以用被它交互过的商品来表示, 因此这里在二部图上进行信息传递, 获取用户节点的评分边类型特征信息, 表示为

$$\mu_{j \rightarrow i, r} = \frac{1}{\sqrt{|A_i| |A_j|}} \mathbf{x}_j^v \sum_{g=1}^r \mathbf{I}_g \quad (7)$$

其中,  $\sqrt{|A_i| |A_j|}$  表示归一化常数,  $A_i$  表示用户节点  $i$  的邻集,  $A_j$  表示商品节点  $j$  的邻集,  $\mathbf{x}_j^v \in \mathbb{R}^{D_v}$  表示商品节点  $j$  的初始特征向量,  $\mathbf{I}_g \in \mathbb{R}^{D_v \times B}$  表示参数矩阵,  $B$  表示嵌入维度。在信息传递步骤之后, 通过对评分边类型  $r$  下的所有邻集  $A_{i,r}$  进行求和, 将每个用户节点的传入信息进行累加, 然后将它们表示成单个向量, 表示为

$$\mathbf{p}'_i = \sigma \left[ \text{accum} \left( \sum_{j \in A_{i,1}} \mu_{j \rightarrow i, 1}, \dots, \sum_{j \in A_{i,R}} \mu_{j \rightarrow i, R} \right) \right] \quad (8)$$

其中,  $\text{accum}(\cdot)$  可以表示为向量总和  $\text{sum}(\cdot)$ , 也可以表示为向量串联  $\text{stack}(\cdot)$ ;  $\sigma$  表示激活函数  $\text{ReLU}$ 。通过一个全连接层获取用户  $i$  的评分特征, 即

$$\mathbf{p}_i = \sigma(\mathbf{W}_p \mathbf{p}'_i) \quad (9)$$

其中,  $\sigma$  表示激活函数  $\text{ReLU}$ ,  $\mathbf{W}_p \in \mathbb{R}^{B \times \beta_1}$  表示参数矩阵,  $\beta_1$  表示隐藏因子。由此, 可以得到用户评分特征表示  $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{N_u}]$ , 其中,  $\mathbf{P} \in \mathbb{R}^{N_u \times \beta_1}$ ,  $\mathbf{p}_{N_u} \in \mathbb{R}^{\beta_1}$  表示第  $N_u$  个用户的评分特征。类似地, 可以得到商品评分特征表示  $\mathbf{Q} = [\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_{N_v}]$ , 其中,  $\mathbf{Q} \in \mathbb{R}^{N_v \times \beta_1}$ ,  $\mathbf{q}_{N_v} \in \mathbb{R}^{\beta_1}$  表示第  $N_v$  个商品的评分特征。

### 2.3 特征交互

用户和商品评分交互数据经过图卷积编码后，能够获取到更准确的用户和商品的评分特征，将其和评论文本卷积特征相交互，对于辨别评论信息的有效性会更有效。因此对于商品建模来说，在输入商品  $v$  的第  $l$  条评论文本卷积特征  $\mathbf{o}_{v,l}$  后，结合该评论的用户评分特征  $\mathbf{p}_{u,l}$ ，计算每条评论的重要性，即

$$\mathbf{a}'_{v,l} = \boldsymbol{\omega}^T \text{ReLU}(\mathbf{W}_1 \mathbf{o}_{v,l} + \mathbf{W}_2 \mathbf{p}_{u,l} + \mathbf{b}_1) + b_2 \quad (10)$$

其中， $\boldsymbol{\omega} \in \mathbb{R}^\beta$ 、 $\mathbf{W}_1 \in \mathbb{R}^{h \times \beta}$ 、 $\mathbf{W}_2 \in \mathbb{R}^{\beta \times \beta}$ 、 $\mathbf{b}_1 \in \mathbb{R}^\beta$ 、 $b_2 \in \mathbb{R}^1$  都是模型参数， $\beta$  是注意力层的隐藏因子。对  $\mathbf{a}'_{v,l}$  执行 softmax 归一化操作，即可得到商品  $v$  第  $l$  条评论最终的注意力权重  $a_{v,l}$  为

$$a_{v,l} = \frac{\exp(\mathbf{a}'_{v,l})}{\sum_{l=0}^n \exp(\mathbf{a}'_{v,l})} \quad (11)$$

在获得每条评论的注意力权重后，将商品  $v$  的特征向量计算为加权总和，通过一个全连接层，则经过注意力操作的商品  $v$  的评论文本特征可表示为

$$\mathbf{t}_v = \mathbf{W}_a \left( \sum_{l=1, \dots, n} a_{v,l} \mathbf{o}_{v,l} \right) + \mathbf{b}_0 \quad (12)$$

其中， $\mathbf{W}_a \in \mathbb{R}^{\beta \times h_1}$  为参数矩阵，偏置  $\mathbf{b}_0 \in \mathbb{R}^{\beta_1}$ 。获取商品最终的评论文本特征表示  $\mathbf{T} = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_{N_v}]$ ，其中， $\mathbf{T} \in \mathbb{R}^{N_v \times \beta_1}$ ， $\mathbf{t}_{N_v} \in \mathbb{R}^{\beta_1}$  表示第  $N_v$  个商品的评论文本特征。类似地，也可以获取用户最终的评论文本特征表示  $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_{N_u}]$ ，其中， $\mathbf{S} \in \mathbb{R}^{N_u \times \beta_1}$ ， $\mathbf{s}_{N_u} \in \mathbb{R}^{\beta_1}$  表示第  $N_u$  个用户的评论文本特征。

对于得到的用户  $u$  的评论文本特征以及评分特征，将 2 个特征相连接，得到用户  $u$  的最终特征表示，类似地，计算获取商品  $v$  的最终特征表示，将用户和商品的最终特征表示通过内积运算进行组合得到  $\mathbf{h}_0 \in \mathbb{R}^{\beta_1}$ ，如式(13)所示。

$$\mathbf{h}_0 = (\mathbf{p}_u + \mathbf{s}_u) \odot (\mathbf{q}_v + \mathbf{t}_v) \quad (13)$$

其中， $\odot$  表示内积符号。

### 2.4 评分预测

在评分预测层利用隐因子模型 (LFM, latent factor model) 来完成最终评分的预测。LFM 是一种基于矩阵分解的算法，可获得用户  $u$  对商品  $v$  的预测评分  $\hat{R}_{u,v}$ ，表示为

$$\hat{R}_{u,v} = \mathbf{W}_0^T \mathbf{h}_0 + b_u + b_v + \gamma \quad (14)$$

其中， $\mathbf{W}_0 \in \mathbb{R}^{\beta_1}$  表示参数， $b_u$ 、 $b_v$ 、 $\gamma$  分别表示用户的偏置、商品偏置、全局偏置，将  $\mathbf{W}_0$  设置为 1 即可恢复标准的隐因子模型。

本文的评分预测可以看作回归任务，使用 MSE 构建损失函数，表示为

$$L_r = \sum_{u,v \in \Gamma} (\hat{R}_{u,v} - R_{u,v})^2 \quad (15)$$

其中， $\Gamma$  表示模型训练数据集， $R_{u,v}$  表示用户  $u$  对商品  $v$  的评分的真实值。为了优化目标函数，本文采用自适应矩估计 (Adam, adaptive moment estimation) 作为优化器，它是一个寻找全局最优优点的优化算法，引入了二次梯度校正，相对于其他算法有一定的优越性。

## 3 实验

### 3.1 数据集和评估方法

本文在亚马逊公开的 5-core 评论数据集上进行实验，选用亚马逊网站的用户 ID、商品 ID、评论信息和评分数据信息，其中评论数据中每个用户和商品至少有 5 条评论，本次实验采用其中 4 种类别的数据集，分别是 Musical Instruments (MI)、Patio Lawn and Garden (PLG)、Automotive (Auto) 以及 Amazon Instant Video (AIV)。表 1 显示了这 4 种数据集的统计信息。

表 1		数据集统计信息	
数据集	用户数	商品数	评分数
MI	1 429	900	10 261
PLG	1 686	962	13 272
Auto	2 928	1 835	20 473
AIV	5 130	1 685	37 126

实验采用 MSE 作为模型的评估方法，这是一种常用的回归算法的评价指标，并且在相关文献中被广泛使用。在获取评分预测结果  $R_{u,v}$  后，求得其与真实值  $R_{u,v}$  误差的平方和再与所有测试实例数目  $N$  的比值，如式(16)所示。在本文实验中，MSE 的值越低，表示模型的预测评分越准确，模型的推荐性能越好；反之，表示模型的推荐性能越差。

$$\text{MSE} = \frac{1}{N} \sum_{u,v} (\hat{R}_{u,v} - R_{u,v})^2 \quad (16)$$

### 3.2 对比模型

本文将提出的 CRRG 模型和以下推荐模型进行比较，检验模型的推荐效果。表 2 展示了实验的对比模型使用的输入数据以及方法类型。

表2 模型比较

推荐模型	评分数据	评论文本	卷积神经网络	注意力机制	图卷积编码
PMF	✓	—	—	—	—
LFM	✓	—	—	—	—
ConvMF	✓	✓	✓	—	—
DeepCoNN	—	✓	✓	—	—
NARRE	—	✓	✓	✓	—
GC-MC	✓	—	—	—	✓
CRRG	✓	✓	✓	✓	✓

1) PMF<sup>[1]</sup>。经典的概率矩阵分解模型，只输入了评分数据。

2) LFM<sup>[2]</sup>。隐因子模型，通过矩阵奇异值分解 (SVD, singular value decomposition) 的方法预测商品评分，同样只输入了评分数据。

3) ConvMF<sup>[4]</sup>。利用卷积神经网络提取商品的评论文本特征，和 PMF 模型相结合完成推荐任务，没有使用用户的评论文本信息。

4) DeepCoNN<sup>[5]</sup>。使用 2 个并行的卷积神经网络，分别从用户和商品的评论文本中提取相应的特征表示来进行推荐。

5) NARRE<sup>[8]</sup>。在 DeepCoNN 模型的基础上，考虑到不同评论的重要性不一致，在对评论文本进行建模的时候，引入了注意力机制，将用户和商品的 ID 嵌入作为注意力分数计算的辅助信息来获取相对重要的评论。

6) GC-MC<sup>[24]</sup>。基于用户-商品的二部图，设计了一种图自编码器框架，从链路预测的角度解决推荐系统中的评分预测问题，仅输入了评分数据。

### 3.3 实验设置

实验在每个数据集上随机选取 80% 作为训练集，10% 作为验证集，10% 作为测试集。对于需要输入评论文本的模型，使用 GoogleNews 预训练的 300 维词向量；对于使用卷积神经网络的模型，本文使用了基准模型 DeepCoNN 和 NARRE 中大部分参数设置，其中 CNN 的卷积核大小在 {3,4,5} 中选取，每种卷积核个数为 100，并对参数进行微调，在 {4,8,16,32} 中遍历寻找最佳的隐因子个数，选取最优结果进行展示。

### 3.4 结果分析

本文提出的 CRRG 推荐模型和现有的几个模型在 4 种数据集上 MSE 的对比实验结果如表 3 所示。

表3 MSE 的对比实验结果

推荐模型	MI	PLG	Auto	AIV
PMF	1.363 6	1.492 3	1.506 4	1.424 5
LFM	1.792 0	1.671 9	1.798 6	1.485 8
ConvMF	1.357 4	1.331 8	1.283 4	1.228 3
DeepCoNN	0.835 7	1.070 9	0.835 5	1.018 8
NARRE	0.804 2	1.025 2	0.788 5	0.961 2
GC-MC	1.129 9	1.292 4	1.024 3	1.151 5
CRRG	0.791 4	1.017 1	0.785 9	0.959 8

通过分析以上对比实验，可以得出以下结论。

- ①只考虑评分数据的推荐模型 (PMF、LFM、GC-MC) 的预测结果不如使用评论文本的推荐模型 (DeepCoNN、NARRE、CRRG) 效果好，因为评论文本中含有丰富的语义信息，可以对评分数据进行补充，更有可能得到相对准确的评分预测结果；
- ②根据 PMF、LFM、ConvMF 模型与 GC-MC 模型的对比实验结果，使用图卷积编码对模型性能可以有实质性的提升，这是因为图卷积编码在用户-商品二部图上让节点进行信息传递，使用户和商品的特征表示更加具体；
- ③使用了注意力机制的模型 (NARRE、CRRG) 比 DeepCoNN 模型的推荐性能更优，因为注意力机制可以区分评论文本的重要性，获取更深层次的语义信息；
- ④本文提出的 CRRG 模型在 NARRE 模型的基础上，使用图卷积编码的方式对评分数据进行特征表示学习，从多维度特征交叉角度学习用户和商品的特征表示，增强了用户和商品的交互，获取了最好的评分预测结果。

### 3.5 模型性能优化

本文在模型的图卷积编码过程中，将式(8)中的函数  $\text{accum}(\cdot)$  设置为向量求和函数  $\text{sum}(\cdot)$  或者向量串联函数  $\text{stack}(\cdot)$ ，以 2 种不同的方式获取用户和商品节点的评分特征表示。实验为了优化模型性能，并且分析模型参数中的隐因子数量给模型带来的影响，分别比较了不同的隐因子个数在 2 个不同的数据集上使用  $\text{sum}(\cdot)$  或  $\text{stack}(\cdot)$  给模型性能带来的影响，结果如图 2 所示，其中 CRRG-ST 表示使用了向量串联函数，CRRG-SU 表示使用了向量求和函数。

通过图 2 可以看出，在不同的隐因子数量下，模型的预测结果有很大的差别。在 PLG 和 MI 这 2 个数据集上，使用 CRRG-ST 和 CRRG-SU 算法的预测结果表现最好时的隐因子数量也是不一样的，但是从 2 种算法最好的表现效果来看，使用

CRRG-SU 算法总体上比 CRRG-ST 算法得到的误差更小, 表明使用向量求和函数比向量串联函数更好, 因此, CRRG 模型在式(8)中最好使用向量求和函数。另外, 随着隐因子数量的增加, 使用 CRRG-SU 算法得到的误差逐步上升, 这可能是由于参数过多导致的过拟合现象。

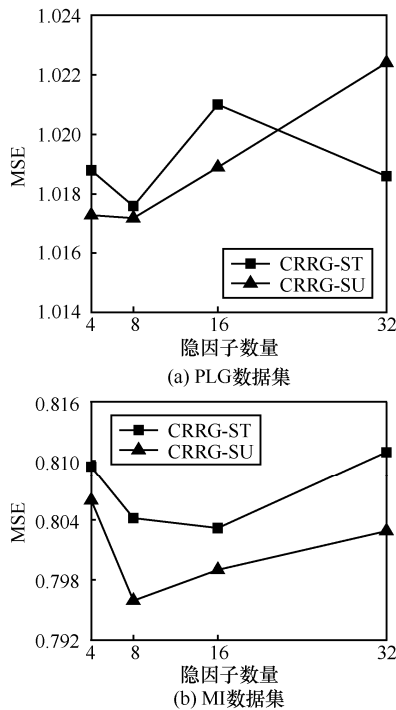


图 2 不同隐因子数量下函数 accum(.)设置对模型性能的影响

### 3.6 消融实验

为了验证图卷积编码在评分特征表示学习上的有效性, 本文在 CRRG 模型基础上进行消融实验, 设计了以下变体算法。

1) CRRG-G1。在注意力层进行注意力分数计算时, 将对应评论的用户或商品特征改为它们的 ID 嵌入特征。

2) CRRG-G2。在最后进行评论文本特征和评分特征的融合时, 将通过图卷积编码获取的评分特征改为相应的用户或商品的 ID 嵌入特征。

在 2 个不同的数据集上对 CRRG-ST、CRRG-SU、CRRG-G1、CRRG-G2 以及没有引入评分图卷积表示的 NARRE 模型进行对比实验, 实验结果如图 3 所示。

通过图 3 可以看出, 虽然在不同的数据集上变体算法的表现不尽相同, 但是总体都比 NARRE 模型效果更好。通过分别比较 CRRG-G1、CRRG-G2 变体算法和 NARRE 的实验结果可知, 图卷积编码获取的评分特征能够提高判断用户和商品重要性

评论的准确性, 对融合评论文本特征的有效性也有所提升。另外, 将通过图卷积得到的评分特征在注意力层和最后的融合部分与评论文本特征都进行交互, 能够最大程度地发挥作用, 提升推荐效果。




图 3 消融实验

### 4 结束语

本文提出了融合评论文本和评分图卷积表示的推荐模型 CRRG, 该模型使用卷积神经网络以及图卷积编码分别学习用户和商品的评论文本与评分的特征表示, 并通过注意力机制结合 2 种特征获取更有效的评论信息, 融合评论文本特征和评分图卷积表示的特征得到了用户和商品更准确的表示。在亚马逊公开数据集上进行对比实验, 实验表明本文提出的推荐模型能够进一步降低评分预测的误差, 提升推荐效果。今后的研究可以探索通过用户和商品的其他交互行为, 比如用户对商品时序偏好、点击率等来提升推荐性能。

### 参考文献:

[1] SALAKHUTDINOV R R, MNH A. Probabilistic matrix factorization[C]//Proceedings of the 20th International Conference on Neural Information Processing Systems. New York: Curran Associates Inc, 2007: 1257-1264.

- [2] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. *Computer*, 2009, 42(8): 30-37.
- [3] 任开旭, 王玉龙, 刘同存, 等. 融合多维语义表示的概率矩阵分解模型[J]. *电子学报*, 2019, 47(9): 1848-1854.  
REN K X, WANG Y L, LIU T C, et al. A probabilistic matrix factorization model based on multidimensional semantic representation learning[J]. *Acta Electronica Sinica*, 2019, 47(9): 1848-1854.
- [4] 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*. New York: ACM Press, 2016: 233-240.
- [5] 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*. New York: ACM Press, 2017: 425-434.
- [6] LIU T C, LIAO J X, WANG Y L, et al. Collaborative tensor-topic factorization model for personalized activity recommendation[J]. *Multimedia Tools and Applications*, 2019, 78(12): 16923-16943.
- [7] 顾亦然, 姚志鹏, 杨海根. 融合注意力胶囊的深度因子分解机模型[J]. *通信学报*, 2021, 42(10): 130-139.  
GU Y R, YAO Z P, YANG H G. Deep factorization machine model based on attention capsule[J]. *Journal on Communications*, 2021, 42(10): 130-139.
- [8] 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 - WWW'18*. New York: ACM Press, 2018: 1583-1592.
- [9] LIAO J X, LIU T C, YIN H Z, et al. An integrated model based on deep multimodal and rank learning for point-of-interest recommendation[J]. *World Wide Web*, 2021, 24(2): 631-655.
- [10] MCAULEY J, LESKOVEC J. Hidden factors and hidden topics: understanding rating dimensions with review text[C]//*Proceedings of the 7th ACM Conference on Recommender Systems*. New York: ACM Press, 2013: 165-172.
- [11] BAO Y, FANG H, ZHANG J. TopicMF: simultaneously exploiting ratings and reviews for recommendation[C]//*Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI Press, 2014: 2-8.
- [12] WANG H, WANG N Y, YEUNG D Y. Collaborative deep learning for recommender systems[C]//*Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2015: 1235-1244.
- [13] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11: 3371-3408.
- [14] LU Y C, DONG R H, SMYTH B. Coevolutionary recommendation model: mutual learning between ratings and reviews[C]//*Proceedings of the 2018 World Wide Web Conference on World Wide Web - WWW'18*. New York: ACM Press, 2018: 773-782.
- [15] 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 Eleventh ACM Conference on Recommender Systems*. New York: ACM Press, 2017: 297-305.
- [16] 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 Press, 2018: 2309-2318.
- [17] MA C, KANG P, WU B, et al. Gated attentive-autoencoder for content-aware recommendation[C]//*Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining*. New York: ACM Press, 2019: 519-527.
- [18] ZHOU J P, CHENG Z Y, PEREZ F, et al. TAFA: two-headed attention fused autoencoder for context-aware recommendations[C]//*Proceedings of the Fourteenth ACM Conference on Recommender Systems*. New York: ACM Press, 2020: 338-347.
- [19] LIU H T, WU F Z, WANG W J, et al. NRPA: neural recommendation with personalized attention[C]//*Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM Press, 2019: 1233-1236.
- [20] 梁顺攀, 刘伟, 尤殿龙, 等. 考虑评论质量的自注意力胶囊网络评分预测模型[J]. *电子与信息学报*, 2021, 43(12): 3451-3458.  
LIANG S P, LIU W, YOU D L, et al. Self-attention capsule network rate prediction with review quality[J]. *Journal of Electronics & Information Technology*, 2021, 43(12): 3451-3458.
- [21] 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.  
FENG X J, ZENG Y Z. Joint deep modeling of rating matrix and reviews for recommendation[J]. *Chinese Journal of Computers*, 2020, 43(5): 884-900.
- [22] 李昆仑, 翟利娜, 赵佳耀, 等. 融合信任关系与评论文本的矩阵分解推荐算法[J]. *小型微型计算机系统*, 2021, 42(2): 285-290.  
LI K L, ZHAI L N, ZHAO J Y, et al. Matrix factorization recommendation algorithms by exploiting trust relationship and review text[J]. *Journal of Chinese Computer Systems*, 2021, 42(2): 285-290.
- [23] GAO J Y, WANG X T, WANG Y S, et al. Explainable recommendation through attentive multi-view learning[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI Press, 2019: 3622-3629.
- [24] BERG R V D, KIPF T N, WELLING M. Graph convolutional matrix completion[J]. *arXiv Preprint, arXiv: 1706.02263*, 2017.
- [25] GAO J Y, LIN Y, WANG Y S, et al. Set-sequence-graph: a multi-view approach towards exploiting reviews for recommendation[C]//*Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. New York: ACM Press, 2020: 395-404.

## [作者简介]



冯海林 (1980- ), 男, 安徽安庆人, 博士, 浙江农林大学教授、博士生导师, 主要研究方向为计算机视觉、智能信息处理和物联网。

张潇 (1997- ), 女, 浙江台州人, 浙江农林大学硕士生, 主要研究方向为深度学习和推荐算法。

刘同存 (1983- ), 男, 山东临沂人, 博士, 浙江农林大学讲师, 主要研究方向为数据挖掘、视频理解、深度学习和推荐算法。