

基于评论特征提取和隐因子模型的 评分预测推荐系统

罗莘涛¹, 陈黎¹, 伍少梅¹, 王昊²

(1. 四川大学计算机学院, 成都 610065; 2. 西澳大学, 珀斯 6009)

摘要: 评分预测是推荐系统研究的核心问题, 通过用户的历史行为来预测用户对商品的评分, 根据评分高低来推荐用户喜欢的商品. 当前基于评论评分预测推荐系统普遍只使用卷积神经网络捕获局部特征或者循环神经网络捕获全局特征, 忽略了将这两类特征的有效融合. 针对现存问题, 本文提出基于评论特征提取和隐因子模型的评分预测推荐模型, 使用自适应感受野的卷积神经网络(CNN)提取局部特征, 同时使用门控循环单元(GRU)提取全局特征, 将不同特征融合为评论的嵌入表达. 再结合隐因子模型(LFM)对用户的特征偏好和商品的特征属性进行建模. 最后, 通过对用户和商品的嵌入表达进行评分预测. 实验结果表明, 本文模型在5个数据集上均高于现有基线模型.

关键词: 评论; 神经网络; 特征提取; 评分预测

中图分类号: TP391

文献标识码: A

DOI: 10.19907/j.0490-6756.2021.032002

Rating prediction recommendation system based on reviews feature extraction and hidden factor model

LUO Xin-Tao¹, CHEN Li¹, WU Shao-Mei¹, WANG Hao²

(1. College of Computer Science, Sichuan University, Chengdu 610065, China;

2. University of Western Australia, Perth 6009, Australia)

Abstract: Rating prediction is the core issue of the recommendation system research. It predicts the user's rating of the product through the user's historical behavior, and recommends the user's favorite product based on the rating. The current recommendation system based on comment score prediction generally only uses convolutional neural network to capture local features or recurrent neural network to capture global features, ignoring the effective fusion of these two types of features. Aiming at the existing problems, this paper proposes a rating prediction recommendation model based on review feature extraction and hidden factor model, using adaptive receptive field convolutional neural network (CNN) to extract local features, and using gated recurrent unit (GRU) to extract global features. Fusion of different features into embedded representations of reviews. Then combined with the hidden factor model (LFM) to model the user's feature preference and the feature attributes of the product. Finally, the rating prediction is made on the embedded representations of users and commodities. The experimental results show that the model in this paper is higher than the existing baseline model on the five data sets.

Keywords: Reviews; Neural network; Feature extraction; Rating prediction

收稿日期: 2020-11-20

基金项目: 四川省新一代人工智能重大专项(2018GZDZX0039); 四川省重点研发项目(2019YFG0521)

作者简介: 罗莘涛(1994-), 男, 四川泸州人, 硕士研究生, 主要研究领域为推荐系统. E-mail: luoxt520@163.com

通讯作者: 伍少梅. E-mail: wu_scdx@126.com

1 引言

根据 2016 年公布的数据显示, Amazon 35% 的销售额都来自于推荐系统, 良好的推荐系统还能改善用户的购物体验. 提高推荐系统的精度对商家、电商平台和用户具有重要的商业价值和使用价值.

传统的推荐系统^[1]通常利用用户对商品的评分信息, 按照电商平台数以万计甚至上百万计的商品种类和用户群体来计算, 这样的信息十分稀疏. 为此, 越来越多的研究人员开始尝试使用其他信息^[2]来弥补数据稀疏问题. 而用户在购买商品时会选择性地给某些商品进行评论, 这些评论体现了用户购买的商品的某些特征属性. 如“质量很好, 价格适中, 综合性价比高, 值得购买”这条评论包含了对商品质量、价格、性价比方面的特征描述, 并且我们可以推断出用户在购物时对商品质量、价格、性价比等方面的偏好. 而单一的评论不能完整地体现用户的整体偏好和商品完整的特征属性, 为此将用户和商品的所有评论作为额外的信息来弥补数据的稀疏性问题. 最近的一些研究也表明了评论文本对解决推荐系统中数据稀疏性^[3-9]以及提高推荐的准确率有着积极的作用.

由于深度学习^[10-16]的词嵌入表示模型, 能够简单有效地将不同的数据通过深度神经网络表示到同一个向量空间中, 可以同时构建用户和物品的嵌入表示信息, 因此当前基于评论的推荐工作大部分采用深度学习的方法. ConvMF^[3]只使用卷积神经网络提取评论特征来对商品进行建模, 没有考虑用户本身也可以作为对象建模. NARRE^[4]在 DeepCoNN^[5]使用卷积神经网络模型提取特征和用户和商品平行建模的基础上增加了对单个评论的重要性评估. TARMF^[6]和 NARRE 类似, 使用基于注意力机制^[17]的 GRU 模型^[18]对单个评论进行建模之后平均得到用户和商品的特征向量, 提取了全局特征但是忽略了局部特征. 虽然卷积神经网络通过固定感受野对局部特征的提取有很好的效果, 但是对提取文本全局特征却没有循环神经网络有效, 导致评论特征提取不充分. 此外, 固定感受野的卷积神经网络只能关注单一的局部特征, 但是并不是所有的特征都能被一个感受野完全提取出来, 因此只使用单一感受野的卷积神经网络对局部特征的提取也是有限的.

本文提出基于评论特征提取的复合神经网络

模型, 使用自适应感受野的卷积神经网络, 根据模型训练自适应的选择不同感受野下卷积神经网络提取的局部特征. 结合门控循环单元提取全局特征, 解决了局部特征提取单一以及评论特征提取不全面的问题. 实验证明, 该模型可以有效利用评论中的特征信息, 并在 5 个 Amazon 公开的数据集上取得了较好的效果.

本文的主要贡献有以下两点: (1) 提出了自适应感受野的卷积神经网络提取局部特征, 解决了局部特征提取单一问题; (2) 提出了将全局和局部特征融合表示的方法对用户和商品建模, 兼顾局部特征和全局特征, 丰富特征提取方式.

2 相关工作

当前基于评论的推荐系统按照评论使用方式分为两种: (1) 将用户的每条评论首尾拼接形成一个大文档, 使用这个包含了用户所有评论信息的文档进行建模; (2) 基于单个评论的建模方式, 将用户的评论一条一条的单独进行建模, 最后再将特征融合到一起表示.

基于多个评论拼接在一起统一进行建模中具有代表性的工作是 ConvMF、DeepCoNN、D-Attn^[7]. 较早将用户评论信息引入到推荐系统的工作 ConvMF 结合卷积神经网络和概率矩阵分解模型进行用户的评分预测, 但是在建模过程中只使用了用户对物品的评论进行建模. DeepCoNN 设计了经典的双塔模型, 使用卷积神经网络对用户和物品分别进行特征提取. 分别得到用户和商品的特征表示之后使用因子分解机进行评分预测. 该方法中用户和商品平行使用深度学习建模的方式是后面许多工作的基础. D-Attn 在 DeepCoNN 的基础上引入了词级别的注意力机制, 表示评论中不同的单词对于用户和物品建模的重要性是不一样的. 并且引入了局部和全局注意力两种注意力机制来寻找富含更丰富语义信息的单词, 为这些单词赋予更高的权重.

基于单个评论建模的工作有 NARRE, 作者认为用户写的每条评论对用户和商品的特征建模贡献是不一样的, 有的评论具有丰富的语义信息, 有的评论可能只是简单的复制粘贴. 为衡量每条评论对建模的贡献程度, 提出了评论级的注意力机制, 使用用户名和商品名信息嵌入表示来刻画每条评论的权重. 通过 softmax 得到每条评论的不同权重之后聚合在一起对用户和商品进行特征建模, 并在

特征表示层将隐因子模型(LFM)^[19]引入到该模型中,共同学习用户和商品的特征表示之后进行评分预测.类似的工作还有 TARMF, TARMF 使用双向 GRU 来建模单个评论单词的隐藏单元表示,使用注意力机制来计算单词的权重信息,得到 k 个注意力模块的输出.将用户和商品的每个评论使用同样的平行方式建模得到评论的特征信息,通过优化概率矩阵分解评分矩阵来相互学习用户和商品的特征表示.但是单一的 GRU 模型没有充分挖掘评论中存在的局部特征,并且对提取出来的全局特征也没有进行任何处理.

3 本文方法

本文模型采用单个评论建模的方式,首先在嵌入层通过 Embedding 的方式将评论文本表示成向量;再通过特征提取层提取当前评论的局部特征和全局特征,在评论注意力层结合用户名或商品名信息对用户评论进行权重计算,归一化处理之后相加得到用户的特征表示;最后结合隐因子模型预测用户评分.具体模型结构如图 1 所示.

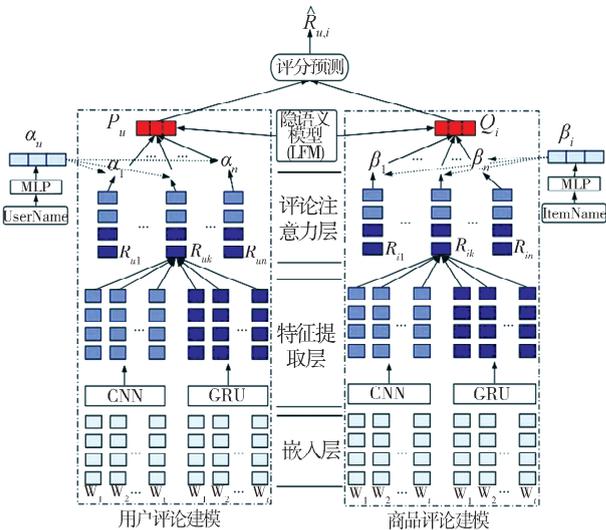


图 1 本文模型结构
Fig. 1 Structure of the model

3.1 嵌入层

嵌入层的功能主要是将用户的评论文本通过词嵌入表示成为可输入神经网络训练的向量.本文采用谷歌公开的 glove 词向量模型,将用户历史评论逐条进行词嵌入表示,得到评论向量 $U_i \in R^{T \times d}$ 和 $I_j \in R^{T \times d}$, U_i 表示用户的第 i 条评论, I_j 表示商品的第 j 条评论,其中, T 为句子填充之后的长度, d 为词嵌入维度.再将评论向量馈入神经网络模型

进行训练.

3.2 特征提取层

特征提取层的主要功能是提取评论的局部特征和全局特征.其中局部特征提取使用 2 个不同感受野的卷积神经网络结合注意力机制自适应选择特征.全局特征提取使用门控神经单元进行.

3.2.1 局部特征提取 局部特征提取模块采用 a, b 两组不同感受野的卷积核提取局部特征,由于不同感受野提取的局部特征不相同,因此通过注意力机制自适应的选择更有用的局部特征来进行建模.整体流程如图 2.

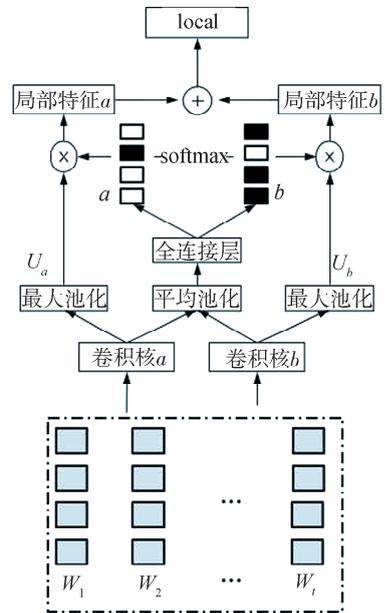


图 2 局部特征提取模型
Fig. 2 Local feature extraction model

$$C_j = \text{ReLU}(U_i * K_j + b_j), 1 \leq j \leq k \quad (1)$$

式(1)中, $*$ 为卷积操作; $K_j \in R^{w \times d}$ 为第 j 个卷积核; w 为卷积核的窗口大小; d 表示嵌入的向量维度. b_j 为第 j 个卷积核的偏置项.采用修正线性单元(ReLU)作为神经网络的激活函数. C_j 表示第 j 个卷积核提取的局部特征.通过最大池化得到第一组卷积核的局部特征信息 U_a .

$$U_a = \max\{0, C\} \quad (2)$$

其中, $C = [C_1 \dots C_j \dots C_k]$, k 为模型中每组卷积核的个数.类似的我们可以得到另外一组卷积核的特征 U_b .这里, $U_a \in R^k, U_b \in R^k$, 在本文模型中,通过平均池化不同卷积核的融合信息,得到评论文本中局部特征关系.类似人眼在阅读时,总是会先关注局部的信息,然而不同的局部特征重要性也是不一样的.因此使用注意力机制来选择不同重要性的特征.首先,将提取的特征 U_a, U_b 融合在一起进行平

均池化得到评论局部融合特征 U , 经过全连接层 $W_a, W_b \in R^k$ 和一层 softmax 得到各组卷积核提取的特征权重. 注意力机制公式如下.

$$U = \text{avg}(U_a \oplus U_b) \quad (3)$$

$$a = U \otimes W_a \quad (4)$$

$$b = U \otimes W_b \quad (5)$$

$$\text{local} = a U_a + b U_b \quad (6)$$

其中, $a \in R^k, b \in R^k, a_i = 1 - b_i, i \in [1, k]$. a, b 的分量 a_i, b_i 表示 a, b 两组卷积核提取的第 i 个局部特征的权重, 通过权重大小自适应的选择局部特征, 最终得到整个评论的局部特征. 模型可以通过训练自适应的选择不同感受野的卷积核提取的局部特征, 不再局限于单一的感受野, 具备很强的可扩展性. 可采用多个不同大小窗口的卷积核来提取特征, 也可以使用不同的卷积方式相互交叉来达到模型增强的效果.

3.2.2 全局特征提取 GRU 和长短期记忆网络 (LSTM) 是循环神经网络的一种, 通过门控机制解决了长期记忆和反向传播中的梯度等问题, 但是 GRU 相比 LSTM 在效果相当的情况下更容易进行训练, 提高了训练的效率. 整个模块流程如图 3 所示.

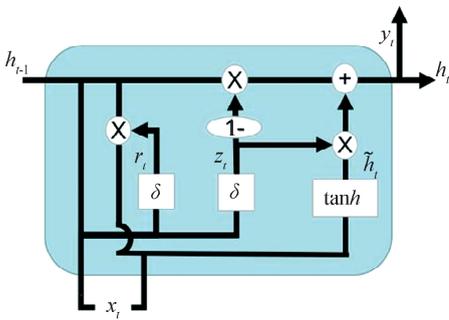


图 3 GRU 模型
Fig. 3 GRU model

本文通过 GRU 提取用户评论的全局特征, r_t, z_t 分别代表重置门和更新门, 计算公式如下.

$$r_t = \sigma W_r[h_{t-1}, x_t], 0 \leq t \leq T \quad (7)$$

$$z_t = \sigma W_z[h_{t-1}, x_t], 0 \leq t \leq T \quad (8)$$

其中, $[h_{t-1}, x_t]$ 表示上一层的状态信息与当前输入向量的拼接, 当前输入向量 x_t 是评论嵌入向量的分量, 表示输入第 t 个单词的向量, W_r, W_z 为待学习的权重参数, σ 表示 sigomoid 激活函数, $r_t, z_t \in (0, 1)$ 表示传入信息重置的门控和更新的门控, 控制前一步状态信息 h_{t-1} 写入到当前状态候选集 \tilde{h}_t 的多少, 门控值越小, 写入信息就越多.

$$\tilde{h}_t = \tan h(W_h[r_t * h_{t-1}, x_t]) \quad (9)$$

$$\text{global} = h_t = (1 - z_t)h_{t-1} + z_t * \tilde{h}_t \quad (10)$$

* 表示矩阵乘法. 整个评论文本经过 GRU 得到的最终状态信息 h_t 作为整个评论文本的全局特征, 与上一个模块提取的局部特征拼接在一起, 作为用户和商品的评论特征提取表示.

$$f_u = [U_{\text{local}}, U_{\text{global}}] \quad (11)$$

$$f_i = [I_{\text{local}}, I_{\text{global}}] \quad (12)$$

由于每个评论对建模的贡献是不同的^[4], 因此使用多层感知机的方式对用户建模嵌入用户名信息来衡量用户评论的重要性, 对商品建模采用嵌入商品名信息来衡量. 具体公式如下.

$$p_k^u = \text{ReLU}(W_u u_{id} + b_u) \quad (13)$$

$$p_j^i = \text{ReLU}(W_i i_{id} + b_i) \quad (14)$$

$p_k^u, p_j^i \in R^D$ 表示用户和商品对第 k, j 个评论的嵌入表示; D 是嵌入表示的维度; W 和 b 是权重和偏置项. 得到嵌入表示后, 我们结合该条评论的提取特征 f_{uk} 计算对应的重要性 α_k^u , 公式如下.

$$e_k = p_k^u A_u f_{u,k} \quad (15)$$

$$\alpha_k^u = \frac{\exp(e_k)}{\sum_{k=1}^N \exp(e_k)}, \alpha_k^u \in (0, 1) \quad (16)$$

同理可以得到 β_j^i , 计算得到评论的重要性之后与对应评论提取特征相乘得到用户和商品的最终评论表示.

$$f_u = \sum_{k=1}^n \alpha_k^u f_{uk} \quad (17)$$

$$f_i = \sum_{j=1}^m \beta_j^i f_{ij} \quad (18)$$

其中, f_u, f_i 表示用户和商品提取的评论文本特征; n, m 是用户和商品的评论数量, 最后结合隐因子模型 (LFM) 学习用户自身的特征偏好和商品的潜在特征. 传统 LFM 模型的公式如下.

$$L(u, i) = p_u q_i^T + b_u + b_i + \mu \quad (19)$$

其中, $p_u, q_i \in R^r$ 表示 LFM 模型中用户的特征偏好和商品的潜在特征属性, b_u, b_i, μ 分别表示用户偏置项, 商品偏置项以及用户对商品的全部评分的平均值, 将该模型需要学习的 p_u, q_i 特征矩阵与上述两个模块提取的特征矩阵融合后得到用户和商品的最终表示 P_u, Q_i , 最后馈入神经网络进行评分预测.

$$P_u = W_m[f_u \oplus p_u] \quad (20)$$

$$Q_i = W_n[f_i \oplus q_i] \quad (21)$$

其中, $W_r \in R^r$ 表示权重参数; t 是根据实验设置的

潜在特征数量.

3.3 评分预测层

评分预测层的工作是将下层模型提取的用户特征偏好和商品特征属性进行交互, 计算预测评分值. 如图 1 所示, 我们得到融合局部和全局特征的用户偏好和商品属性, 通过神经网络计算得到预测评分, 公式如下.

$$\widehat{R}(u, i) = P_u \otimes Q_i + bias \quad (22)$$

其中, $bias$ 表示评分预测计算中用户和商品的偏置项. 模型训练通过反向传播最小化损失函数来学习模型参数, 本文采用平方损失函数进行训练, 公式如下.

$$loss = \sum_{u, i \in \Gamma} (\widehat{R}_{u, i} - R_{u, i})^2 \quad (23)$$

其中, $u, i \in \Gamma$ 表示训练集中所有的用户和商品.

4 实验

4.1 数据集及评价指标

本文采用 Amazon 电商评论数据集^[20] Musical Instruments、Office Products、Grocery and Gourmet Food、Video Games 和 Movies, 所有数据集都包含用户、商品及用户对商品的评论和评分, 数据集中的每个用户都至少在该平台上发表 5 条以上的评论. 数据集详细信息如表 1. 每个数据集按照 8 : 1 : 1 的比例分为训练集、测试集和验证集. 采用平均绝对误差(MAE)作为评价指标, 公式如下.

$$MAE = \frac{1}{N} \sum_{(u, i) \in R} |\widehat{R}_{u, i} - R_{u, i}| \quad (24)$$

其中, N 是测试集中数据的个数. 通过测试集的平均绝对误差来检验模型的效果. 误差越小表示模型效果越好.

表 1 数据集
Tab. 1 Dataset

数据集	用户数量	商品数量	评论数量
Musical Instruments	1 429	900	10 261
Office Products	4 905	2 420	53 228
Grocery and Gourmet Food	14 681	8 713	151 254
Video Games	24 303	10 672	231 780
Sports and Outdoors	35 598	18 357	296 337

4.2 基线模型

为了验证本文模型的有效性, 我们采用了以下

5 个模型作为基线模型进行对比实验.

(1) ConvMF(RecSys'16)^[3]: 该模型将卷积神经网络(CNNs)提取评论特征, 与概率矩阵分解模型(PMF)结合起来进行评分预测;

(2) DeepCoNN(WSDM17)^[5]: 该模型完全使用深度学习的方法进行建模, 采用两个平行的卷积神经网络来分别建模用户和商品的评论, 最后使用因子分解机(FM)进行评分预测;

(3) D-Attn(RecSys'17)^[7]: 该模型在 DeepCoNN 模型的基础上引入了词级别的注意力机制, 表示评论中不同单词对用户和商品的建模作用是不一样的;

(4) NARRE(WWW18)^[4]: 该模型认为, 用户写的每一条评论对用户和商品建模的贡献是不一样的, 有的可能更加有用, 有的可能几乎没有作用, 因此提出了评论级别的注意力机制来衡量每条评论的重要性;

(5) CARL(TOIS19)^[8]: 这篇文章认为同一个用户对不同商品的偏好是不同的. 因此为每个用户和商品的评论文档学习不同的词权重, 用卷积神经网络和多层感知机抽象表示用户和商品特征.

4.3 参数设置

在模型实验中, 本文将评论用 Glove 词向量^[21]对文本中的单词进行初始化, 对没有在 Glove 词向量中的单词进行随机初始化, 整个模型的迭代次数为 40, Batchsize 大小设置为 64, 用户名和商品名嵌入维度为 32, 模型神经网络采用 dropout 方法对神经网络的节点进行随机丢失, 丢失概率为 0.5. 学习率设置为 0.001, 采用 Adam 优化算法进行优化.

在局部特征提取模块中, 卷积神经网络采用的窗口大小分别为 3 和 5, 卷积核个数 k 为 50. 融合信息后卷积窗口为 3, 得到融合的提取特征之后采用两层全连接层的方式对特征先进行缩放然后再还原, 以此来增加融合特征之间的交互. 在全连接层中, 本文使用的神经单元为 50 个. 在全局特征提取模块中, 我们使用的 GRU 单元为 50 维, 长度为评论文本填充后文本长度.

4.4 实验结果

我们对基线模型使用的用户和商品信息以及评论的使用方式进行了分析, 结果如表 2 所示. 其中, ID 嵌入栏表示该模型在训练时是否使用了用户名和商品名信息, 评论处理方式中聚合属性表示该模型将用户和商品下的所有评论信息拼接成一

个大文档进行建模,而单独属性表示将评论逐条进行建模.可以看出,本文模型使用了 ID 嵌入信息,并衡量每条评论对模型建模的贡献.对比 NARRE 模型,本文使用了特征选择注意力机制来选择贡献大的特征,并增加了全局特征提取模块来弥补卷积神经网络无法兼顾整个评论文本特征的缺陷.

表 2 数据使用信息

Tab. 2 Information of data usage

模型	ID 嵌入	评论处理方式
ConvMF	否	聚合
DeepCoNN	否	聚合
D-attn	否	聚合
NARRE	是	单独
CARL	是	聚合
OURs	是	单独

为了验证模型的有效性,我们将从以下两个方面来进行验证,一是对比基线模型在不同数据集上的对比实验;二是本文模型改进部分对实验结果的影响的消融实验.

(1) 对比实验.为验证本文模型的有效性,我们将本文模型与 5 个基线模型进行对比,对比结果如表 3,表中下划线的结果表示基线模型中最好效果.

表 3 对比实验结果

Tab. 3 Result of comparative experiment

模型	Musical Instruments	Office Products	Grocery and Gourmet Food	Video Games	Sports and Outdoors
ConvMF	0.786 0	0.727 9	0.863 4	0.899 3	0.823 5
DeepCoNN	0.759 0	0.710 9	0.801 6	0.875 2	0.719 2
D-attn	0.742 0	0.716 1	0.824 1	0.842 2	0.784 0
NARRE	0.694 9	0.680 7	<u>0.746 7</u>	0.799 1	0.689 7
CARL	<u>0.676 6</u>	<u>0.646 9</u>	0.753 4	<u>0.797 9</u>	<u>0.686 4</u>
OURs	0.637 6	0.635 1	0.729 8	0.774 5	0.658 4

从表 3 对比实验结果可以看出,同时建模用户和商品特征的 DeepCoNN 模型比只建模商品特征的 ConvMF 模型提升较大,提升了 3.56%. DeepCoNN 模型是第一个完全使用深度学习的方法,开创性的设计了端到端的深度学习模型,为基于评论评分预测推荐系统提供了一个经典的基线模型.在 DeepCoNN 的基础上,D-attn, NARRE, CARL 使用不同的注意力方式对 DeepCoNN 进行了改进,

其中,D-attn 使用基于单词级别的注意力机制,给每个用户和商品的评论文档中的单词进行权重评估,找到对特征建模更重要的单词,对比效果提升了 1.70%. CARL 模型在单词级别注意力机制的基础上再使用了一层卷积神经网络提取更高级的特征,对比 DeepCoNN 和 D-attn 效果分别提升了 10.7%和 8.68%.而 NARRE 另辟蹊径,提出了经典的评论有用性机制,引入了基于评论级别的注意力机制来衡量每条评论对用户建模的贡献,效果相较于 DeepCoNN 提升了 8.44%,对比 NARRE 和 CARL 两个模型,NARRE 使用了一层卷积神经网络和基于评论级别的注意力机制,CARL 使用了两层卷积神经网络和基于单词级别注意力机制,对于特征提取的能力更强.通过对比实验也可以发现,CARL 模型的效果普遍比 NARRE 模型更好.而我们的模型在基于评论级别的注意力机制上,提出了自适应感受野的卷积神经网络提取局部特征,并考虑到卷积神经网络在捕捉长距离依赖关系上的不足之处,补充了门控循环单元对全局特征进行提取,弥补了模型的不足之处,在不同数据集上对比效果最好的基线模型均有提升,其中提升最高为 Musical Instruments 数据集,效果对比基线模型提升了 5.76%,效果提升最低的数据集为 Office Products,提升了 1.82%.

(2) 消融实验.为了验证本文模型中改进的各模块对实验的有效性,我们利用消融实验分别验证局部特征提取和全局特征提取的效果,具体如下. Local+Att:只采用局部特征提取模块,使用自适应感受野的卷积神经网络提取特征;Globa:只采用全局特征提取模块;我们在 5 个数据集上将消融实验与最终实验结果进行对比,结果如表 4.

表 4 消融实验结果

Tab. 4 Results of ablation experiment

模型	Musical Instruments	Office Products	Grocery and Gourmet Food	Video Games	Sports and Outdoors
Local+Att	0.645 4	0.638 9	0.734 4	0.790 9	0.661 2
Globa	0.648 5	0.647 0	0.734 5	0.796 2	0.669 1
ours	0.637 6	0.635 1	0.729 8	0.774 5	0.658 4

我们可以从表 4 看出,自适应感受野的卷积神经网络可以根据模型训练自适应的选择特征,对比只使用单一感受野的卷积核 NARRE 效果分别提升了 7.12%,6.14%,1.64%,1.02%,4.13%,对

局部特征建模有比较好的提升作用. 消融实验 Globa 在没有局部特征提取模块时, 模型效果与本文模型相比下降了 2%, 1.87%, 0.6%, 2.8%, 1.62%, 结合消融实验和本文实验结果说明, 全局特征提取模块对本文模型的效果提升是有积极作用的, 从而验证了本文模型的各个模块对模型效果提升均有积极作用. 更直观的结果如图 4 所示.

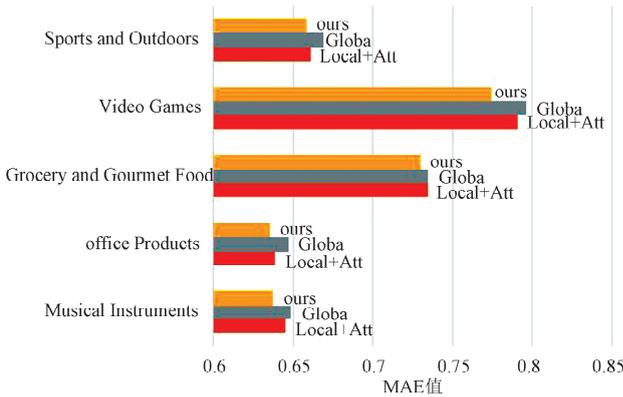


图 4 消融实验结果

Fig. 4 Results of ablation experiment

5 结论

本文在现有模型的基础上提出了自适应感受野的卷积神经网络, 结合局部和全局特征提取对评论文本特征进行了深度挖掘, 结合现有模型使得模型效果得到进一步提升. 在未来的工作中, 我们不应该仅仅关注评分和评论信息, 还应该关注用户的社会性和商品的周期性. 针对多源数据来进行特征融合建模. 此外, 由于神经网络的不可解释性, 对神经网络提取的特征存在更多疑虑. 为了解决这个问题, 可以对神经网络提取的特征进行可视化表达, 使对影响每个用户产生购买行为的偏好特征具有可解释性.

参考文献:

[1] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems [J]. *Computer*, 2009, 42: 30.

[2] Sun Z, Guo Q, Yang J, *et al.* Research commentary on recommendations with side information: a survey and research directions[J]. *Electron Commer R A*, 2019, 37: 100879.

[3] Kim D, Park C, Oh J, *et al.* Convolutional matrix factorization for document context-aware recommen-

dation [C]//Proceedings of the 2016 Acm Conference. [S.l.]: ACM, 2016.

[4] Chen C, Zhang M, Liu Y, *et al.* Neural attentional rating regression with review-level explanations [C]//Proceedings of the 2018 World Wide Web Conference. [S.l. : s. n.], 2018.

[5] Zheng L, Noroozi V, Yu P S. Joint deep modeling of users and items using reviews for recommendation [J]. *arXiv preprint arXiv*, 2017: 1701.04783.

[6] Lu Y, Dong R, Smyth B. Coevolutionary recommendation model: mutual learning between ratings and reviews [C]//Proceedings of the 2018 World Wide Web Conference (WWW 2018), Lyon, France: ACM, 2018.

[7] 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. [S.l. : s. n.], 2017.

[8] Wu L, Quan C, Li C, *et al.* A context-aware user-item representation learning for item recommendation [J]. *ACM T Inform Syst*, 2019, 37: 1.

[9] Chin J Y, Zhao K, Joty S, *et al.* ANR: Aspect-based neural recommender [C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. [S.l. : s. n.], 2018.

[10] Wu S, Ren W, Yu C, *et al.* Personal recommendation using deep recurrent neural networks in NetEase [C]//Proceedings of the 2016 IEEE 32nd international conference on data engineering (ICDE). [S.l.]: IEEE, 2016.

[11] Graves A. Generating sequences with recurrent neural networks [J]. *arXiv preprint arXiv*, 2013: 1308.0850.

[12] Nguyen H T H, Wistuba M, Grabocka J, *et al.* Personalized deep learning for tag recommendation [C]//Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining. Cham: Springer, 2017.

[13] Lei C, Liu D, Li W, *et al.* Comparative deep learning of hybrid representations for image recommendations [C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]: IEEE, 2016.

[14] Cheng H T, Koc L, Harmsen J, *et al.* Wide & deep learning for recommender systems[J]. *arXiv preprint arXiv*, 2016: 1606.07792.

[15] Krizhevsky A, Sutskever I, Hinton G E. Imagenet

- classification with deep convolutional neural networks [J]. *Commun ACM*, 2017, 60: 84.
- [16] 张敏军, 华庆一, 贾伟, 等. 基于深度神经网络的个性化推荐系统研究[J]. *西南大学学报: 自然科学版*, 2019, 41: 104.
- [17] Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need [C]//*Advances in Neural Information Processing Systems*. [S. l. :s. n.], 2017.
- [18] Chung J, Gulcehre C, Cho K H, *et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. *arXiv preprint arXiv*, 2014; 1412. 3555.
- [19] 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*. [S. l. :s. n.], 2013.
- [20] He R, McAuley J. Ups and downs: modeling the visual evolution of fashion trends with one-class collaborative filtering [J]. *arXiv preprint arXiv*, 2016; 1602. 01585.
- [21] Pennington J, Socher R, Manning C D. Glove: Global vectors for word representation [C]//*Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*. [S. l. :s. n.], 2014.

引用本文格式:

中文: 罗莘涛, 陈黎, 伍少梅, 等. 基于评论特征提取和隐因子模型的评分预测推荐系统[J]. *四川大学学报: 自然科学版*, 2021, 58: 032002.

英文: Luo X T, Chen L, Wu S M, *et al.* Rating prediction recommendation system based on reviews feature extraction and hidden factor model [J]. *J Sichuan Univ: Nat Sci Ed*, 2021, 58: 032002.