

## RM-RT<sup>2</sup>NI:融合评论时效与可信近邻影响力的推荐模型

韩志耕, 周婷, 陈耿, 付纯硕, 陈健

引用本文

韩志耕, 周婷, 陈耿, 付纯硕, 陈健. RM-RT<sup>2</sup>NI:融合评论时效与可信近邻影响力的推荐模型[J]. 计算机科学, 2024, 51(6A): 230800160-7.

HAN Zhigeng, ZHOU Ting, CHEN Geng, FU Chunshuo, CHEN Jian. [RM-RT<sup>2</sup>NI:A Recommendation Model with Review Timeliness and Trusted Neighbor Influence](#) [J]. Computer Science, 2024, 51(6A): 230800160-7.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于YOLOP-L的多特征融合道路全景驾驶检测](#)

Multi Feature Fusion for Road Panoramic Driving Detection Based on YOLOP-L

计算机科学, 2024, 51(6A): 230700185-8. <https://doi.org/10.11896/jsjcx.230700185>

#### [基于多尺度视觉感知特征融合的显著目标检测方法](#)

Salient Object Detection Method Based on Multi-scale Visual Perception Feature Fusion

计算机科学, 2024, 51(5): 143-150. <https://doi.org/10.11896/jsjcx.230100132>

#### [一种基于时效近邻可信选取策略的协同过滤推荐方法](#)

Time-effective Nearest Neighbor Trusted Selection Strategy Based Collaborative Filtering Recommendation Method

计算机科学, 2023, 50(11A): 220800199-11. <https://doi.org/10.11896/jsjcx.220800199>

#### [基于决策树改进深度交叉网络的推荐模型](#)

Recommendation Model Based on Decision Tree and Improved Deep & Cross Network

计算机科学, 2023, 50(6A): 220300084-7. <https://doi.org/10.11896/jsjcx.220300084>

#### [基于自注意力机制和迁移学习的跨领域推荐算法](#)

Cross-domain Recommendation Algorithm Based on Self-attention Mechanism and Transfer Learning

计算机科学, 2022, 49(8): 70-77. <https://doi.org/10.11896/jsjcx.210600011>

# RM-RT<sup>2</sup>NI:融合评论时效与可信近邻影响力的推荐模型

韩志耕<sup>1,2</sup> 周婷<sup>1,2</sup> 陈耿<sup>2,3</sup> 付纯硕<sup>1,2</sup> 陈健<sup>1,2</sup>

1 南京审计大学计算机学院/智能审计学院 南京 211815

2 江苏省审计信息工程与技术协同创新中心 南京 211815

3 南京审计大学会计学院 南京 211815

(hanzgnit@126.com)

**摘要** 基于矩阵分解的推荐模型虽然能够处理高维评分数据,但容易遭受评分数据稀疏性的困扰。基于评分和评论的推荐模型通过外加隐藏在评论中的用户偏好与物品属性信息,缓解了评分数据的稀疏性,但在特征提取时大多没有关注评论时效性和可信近邻影响力,无法获得更丰富的用户和物品特征。为进一步提高推荐精度,提出了融合评论时效与可信近邻影响力的推荐模型 RM-RT<sup>2</sup>NI。基于评分矩阵,该模型使用矩阵分解提取了用户偏好和物品属性的浅层特征,利用云模型和修正的用户相似度评估模型和新构建的信度评估模型提取出可信近邻影响力;基于评论文本,该模型利用 BERT 模型获得每条评论的隐表达,利用双向 GRU 提取评论间的联系,利用新构建的融合时间因子的注意力机制识别各评论的时效贡献度,以获取用户和物品的深层特征。在此基础上,将用户浅层特征、深层特征以及可信近邻影响力特征融合成用户特征,将物品浅层特征和深层特征融合成物品特征,并将它们输入全连接神经网络以预测用户-物品评分。在 5 组公开数据集上对 RM-RT<sup>2</sup>NI 的推荐性能进行了实验评估,结果显示,与 7 个基线模型相比, RM-RT<sup>2</sup>NI 具有更高的评分预测精度,且 RMSE 平均降低了 3.0657%。

**关键词:** 推荐模型;评分矩阵;评论文本;评论时效;可信近邻影响力;多特征融合

**中图分类号** TP391

## RM-RT<sup>2</sup>NI: A Recommendation Model with Review Timeliness and Trusted Neighbor Influence

HAN Zhigeng<sup>1,2</sup>, ZHOU Ting<sup>1,2</sup>, CHEN Geng<sup>2,3</sup>, FU Chunshuo<sup>1,2</sup> and CHEN Jian<sup>1,2</sup>

1 School of Computer Science/School of Intelligence Audit, Nanjing Audit University, Nanjing 211815, China

2 Jiangsu Provincial Collaborative Innovation Center for Audit Information Engineering and Technology, Nanjing 211815, China

3 School of Accounting, Nanjing Audit University, Nanjing 211815, China

**Abstract** While recommendation models based on matrix factorization can handle high-dimensional rating data, they are prone to challenges posed by data sparsity in ratings. Recommendation models that incorporate both ratings and reviews alleviate the sparsity issue by incorporating latent user preferences and item attribute information embedded in reviews. However, these models often neglect the review timeliness and the trusted neighbor influence during feature extraction, resulting in limited acquisition of comprehensive user and item characteristics. In order to enhance accuracy further, a novel recommendation model named RM-RT<sup>2</sup>NI is proposed, which integrates the review timeliness and the trusted neighbor influence. Built upon the rating matrix, this model employs matrix factorization to extract shallow features representing user preferences and item attributes. It employs cloud modeling, a refined user similarity assessment model, and a newly constructed credibility assessment model to capture the trusted neighbor influence. Leveraging the textual content of reviews, BERT is utilized to obtain latent representations of individual reviews. Bi-directional GRU is employed to capture inter-review relationships, while an attention mechanism incorporating timeliness is introduced to evaluate the timeliness contribution of each review, thus deriving deep features for users and items. Subsequently, the shallow and deep user features, along with the credibility-enhanced neighboring influence features, are fused to form comprehensive user representations. Similarly, shallow and deep item features are merged with this fused representation to generate comprehensive item representations. These representations are then fed into a fully connected neural network to predict user-item ratings. Experimental evaluation is conducted on five publicly available datasets. The results demonstrate that, in comparison to seven baseline models, RM-RT<sup>2</sup>NI exhibits superior rating prediction accuracy, yielding an average RMSE reduction of 3.0657%.

基金项目:国家自然科学基金(72072091);江苏省高校自然科学基金(21KJA520002,22KJA520005);江苏省研究生科研与实践创新计划项目(KYCX23\_2345);江苏省审计信息工程与技术协同创新中心项目

This work was supported by the National Natural Science Foundation of China(72072091), Natural Science Foundation of the Higher Education Institutions of Jiangsu Province, China(21KJA520002,22KJA520005), Postgraduate Research & Practice Innovation Program of Jiangsu Province (KYCX23\_2345) and Projects of Jiangsu Provincial Collaborative Innovation Center for Audit Information Engineering and Technology.

通信作者:周婷(1442677601@qq.com)

**Keywords** Recommendation model, Rating matrix, Review text, Review timeliness, Trusted neighbor influence, Multi-feature fusion

## 1 引言

推荐系统通过发掘用户行为,找到用户个性化需求,从而将长尾商品或信息准确地推荐给需要它的用户,以帮助用户发现那些他们感兴趣但却很难发现的商品或信息,有效缓解了信息过载所带来的信息迷航现象<sup>[1]</sup>。当前,推荐系统被广泛应用于电子商务<sup>[2]</sup>、学术网络<sup>[3]</sup>、新闻推荐<sup>[4]</sup>等众多领域,以提升用户粘度、降低服务跳出率、助力用户构建信息茧房。

评分预测是推荐系统的主要任务之一<sup>[5]</sup>。隐语义模型(Latent Factor Model, LFM)<sup>[6]</sup>在此类任务中被广泛讨论,为挖掘用户隐含兴趣和物品隐含特征,LFM将评分矩阵分解成两个隐向量维度相同的低维矩阵,最后通过二者的点积运算来预测用户-物品评分。然而,当用户-物品交互数据稀疏时,LFM的预测偏差通常较大。评论文本富含用户偏好以及物品属性信息,利用评论文本来弥补评分数据的稀疏问题已被DeepCoNN<sup>[7]</sup>, NARRE<sup>[8]</sup>, DeepCLFM<sup>[9]</sup>, RTRM<sup>[10]</sup>等众多推荐模型所采用。然而,上述模型在使用注意力机制度量每条评论的有用性时未曾考虑评论的时效性,无法反映用户在做选择时通常倾向于浏览距离当前时间较近的评论的事实<sup>[11]</sup>;同时,在使用近邻影响力扩充用户特征时未曾考虑近邻的可信性,无法反映用户在做选择时受朋友影响的事实。为提高用户-物品预测评分的精度,受文献<sup>[9-10]</sup>启发,本文提出了一种融合评论时效与可信近邻评分特征的推荐模型 DRM-RT<sup>2</sup>NI。

本文的主要贡献有以下3点:

(1)构建了融合评论时效与可信近邻评分特征的推荐模型,不但能从评分中提取用户偏好和物品属性和用户间信任关系的浅层特征,而且能从评论中提取用户偏好、物品属性的深层时效特征,最后基于多特征融合结果进行评分预测。

(2)提出了基于评分矩阵的浅层特征提取方法。该方法在利用矩阵分解提取出用户物品浅层特征时,还综合利用云模型、修正的用户相似度评估模型,以及新构建的信度评估模型获取表征用户间信任关系的可信近邻评分特征。

(3)提出了基于评论文本的深层时效特征提取方法。为保证特征提取的有效性,在采用预训练的BERT模型表示每条评论,利用双向GRU表示评论间的双向联系的基础上,构造了融合时间因子的注意力机制来度量每条评论的时效贡献度。

## 2 相关工作

在所有基于评分矩阵的推荐模型中,LFM被讨论最多,相较于传统的基于邻域的协同过滤模型,LFM通常可以表现出更好的评分预测效果,但此类模型在数据稀疏时仍存在预测精度不高的问题。近年来,利用信任信息缓解评分数据的稀疏性备受关注。Yuan等<sup>[12]</sup>提出了基于矩阵分解的隐式信任建模方法,依据物品评分数量占比及流行度构建信任矩阵,利用矩阵分解提取出用户物品信任隐向量,并将它们与利用矩阵分解从评分数据中提取出的用户、物品隐向量进行融合,增强了用户、物品隐向量的特征表达能力,提高了基于SVD++模型的评分预测精度。Kashani等<sup>[13]</sup>提出了基于用户直

接信任关系的非负矩阵分解方法,利用信任属性向量对使用非负矩阵分解所得到的用户偏好矩阵和物品属性矩阵进行扩展更新,提高了评分预测的精度。Xu等<sup>[14]</sup>提出了一种基于直接信任的概率矩阵分解算法,通过对用户信任矩阵实施概率矩阵分解,并基于用户信任隐向量和受信隐向量对TrustSVD中的用户隐向量实施扩展,提高了评分预测的精度。

上述模型通过引入信任关系缓解了评分数据的稀疏性,提高了评分预测的精度。然而,由于LFM对评分数据仅进行了线性分析<sup>[15]</sup>,只能提取到用户物品的浅层特征。一般来讲,用户偏好受多重因素制约,它们之间的非线性相互作用会使用户特征呈现出复杂性。为准确预测用户-物品评分,还需利用深度学习等非线性技术提取出用户、物品的深层抽象特征。

评论文本通常含有比评分数据更多的用户、物品描述信息,利用深度学习技术从评论文本中挖掘出用户、物品的深层、非线性特征,是当前推荐模型常采用的特征提取技术<sup>[16-17]</sup>。Zheng等<sup>[7]</sup>基于卷积神经网络CNN提出了深度协作神经网络模型DeepCoNN,用于从评论文本中挖掘用户偏好和物品属性特征;针对该模型在特征提取时仅使用评论信息且忽略了评论贡献度的问题,Chen等<sup>[8]</sup>对DeepCoNN进行了改进,提出了具备评论级解释的神经注意力回归模型NARRE,该模型利用注意力机制学习每条评论的权重,并结合评分矩阵,利用LFM对用户物品评分进行可解释性预测。

Feng等<sup>[9]</sup>针对以上模型采用基于静态词向量进行特征提取,进而导致评论的上下文动态语义无法获取的问题,提出了深度协作隐因子模型DeepCLFM,使用预训练的BERT模型、双向GRU和注意力机制从用户评论和商品评论中提取出用户和商品的深层非线性特征向量;同时,根据用户和商品的编号映射出用户、商品的潜在隐向量;之后,将用户和商品的深层特征向量与潜在隐向量进行多层融合,以一、二阶特征项的方式产生深度特征项,用于用户-物品的评分预测。Li等<sup>[10]</sup>提出了基于评论文本和评分矩阵的深度推荐模型RTRM,该模型使用Electra模型对评论文本进行嵌入表示,利用BiLSTM对其进行深度情感分析,以提取用户、物品的深层特征;同时,利用矩阵分解从评分矩阵中提取出用户、物品浅层特征,最后通过融合用户和物品的浅层、深层特征,以及近邻用户影响力以获得最终的用户、物品特征。

然而,以上模型在从评论文本中提取用户、物品深层特征时未曾关注评论的时效性,且在从评分中提取近邻影响力时也未关注近邻的可信性。

## 3 推荐模型

针对上述问题,本章构建了一种融合评论时效和可信近邻影响力的推荐模型RM-RT<sup>2</sup>NI。

### 3.1 模型介绍

如图1所示,RM-RT<sup>2</sup>NI模型包含3部分:1)基于评论的特征学习,包括两个并行网络结构 $TNet_I$ 和 $TNet_U$ ,分别用于从评论中提取物品特征 $Feature_I$ 和用户偏好特征 $Feature_U$ ;2)基于评分的特征提取,从评分矩阵中分解出物品隐向量 $LFM_I$ 和用户隐向量 $LFM_U$ ,以及表征可信近邻影响力的

可信近邻信任向量  $TRUST_U$ ; 3) 特征融合及评分预测, 对前两个部分提供的特征向量进行多层融合, 获得最终的用户偏好

和物品特征, 利用全连接层进行特征映射, 以得到用户对物品的预测评分  $Y\_predict$ 。

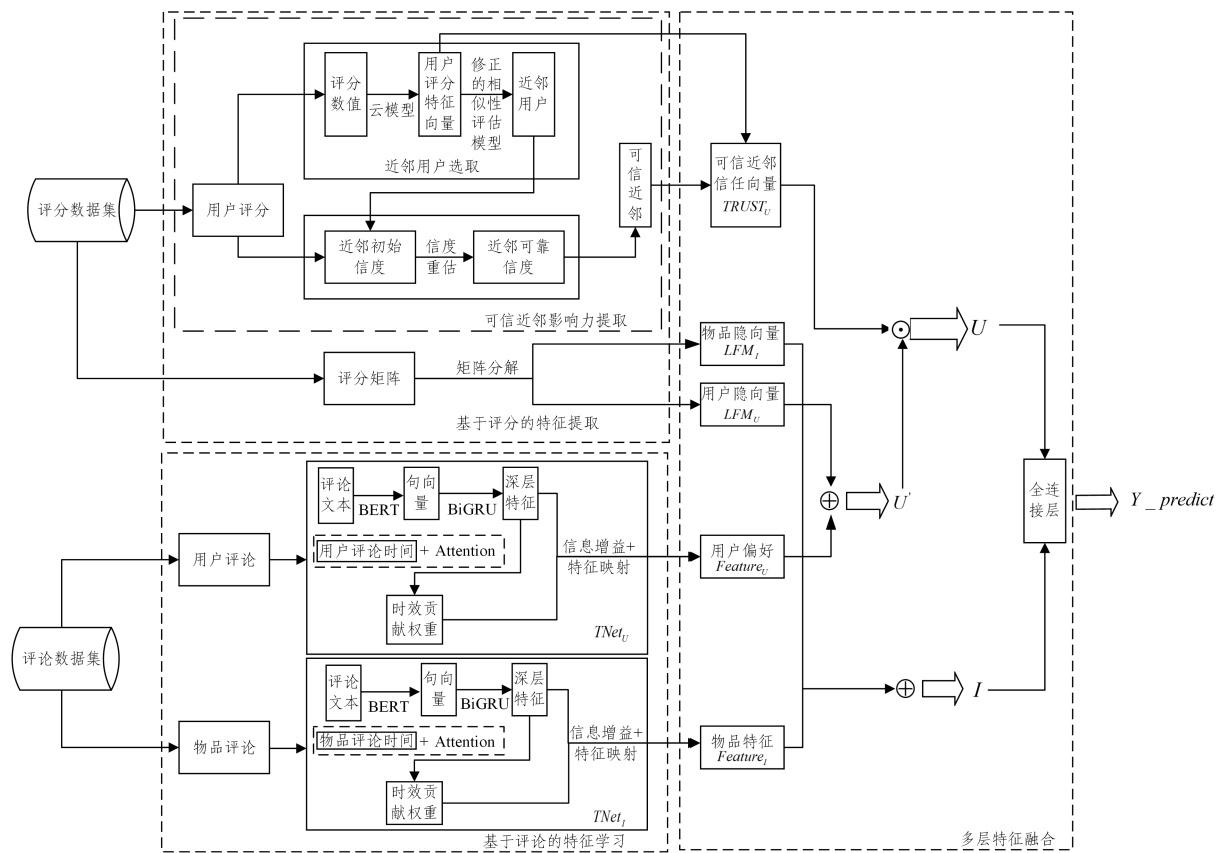


图1 RM-RT<sup>2</sup>NI 深度模型框架结构

Fig. 1 Framework of RM-RT<sup>2</sup>NI

给定用户集  $U = \{u_1, \dots, u_m\}$ , 物品集  $I = \{i_1, \dots, i_n\}$ , 五元组  $o = (u, i, r_{ui}, \omega_{ui}, t_{ui})$  表示用户  $u$  在时刻  $t_{ui}$  对物品  $i$  给出评分  $r_{ui}$  和评论  $\omega_{ui}$ 。模型的任务是利用训练集上来自用户  $u$  的评分  $r_{u*}$  和评论  $\omega_{u*}$ 、针对物品  $i$  的评分  $r_{*i}$  和评论  $\omega_{*i}$ , 及评论时间  $t_{ui}$ , 学习用户偏好和物品特征, 使得  $r_{ui}$  与预测评分  $\tilde{r}_{ui}$  间的误差最小。

### 3.2 基于评论的特征学习

基于评论的特征学习部分由两个结构相似的并行网络  $TNet_u$  和  $TNet_i$  组成, 其中  $TNet_u$  用于从用户评论中学习用户特征,  $TNet_i$  用于从物品评论中学习物品特征。为简单起见, 此处仅对  $TNet_u$  进行介绍。

给定用户  $u$  的评论集  $R = \{R_{u1}, \dots, R_{ud}\}$ ,  $d$  为用户平均评论个数。每条评论经过 BERT 映射成  $n$  维句向量, 即  $R$  句向量量化后得到  $S = \{S_{u1}, \dots, S_{ud}\}$ 。若某用户的评论数大于  $d$ , 则截取前  $d$  条评论; 反之, 若某位用户的评论数小于  $d$ , 则用 [PAD] 字符填充至  $d$  条评论, 以保证每位用户的评论数目为  $d$ 。

在得到用户  $u$  的评论集句向量表示  $S$  后, 经过双向 GRU 获取句子间的相互联系, 得到前后向的上下文信息。第  $k$  条评论对应的前向上下文信息  $\vec{h}_k$  和后向上下文信息  $\overleftarrow{h}_k$  计算式如下:

$$\vec{h}_k = \overrightarrow{GRU}(S_{uk}, \vec{h}_{k-1}) \quad (1)$$

$$\overleftarrow{h}_k = \overleftarrow{GRU}(S_{uk}, \overleftarrow{h}_{k-1}) \quad (2)$$

此处  $\vec{h}_{k-1}$  和  $\overleftarrow{h}_{k-1}$  分别表示第  $k-1$  条评论的前向和后向上

下文信息,  $\overrightarrow{GRU}$  和  $\overleftarrow{GRU}$  分别表示前向和后向 GRU 运算。

将前后向上下文信息  $\vec{h}_k$  和  $\overleftarrow{h}_k$  进行拼接得到  $S_{uk}$  的上下文信息  $h_k$ , 即:

$$h_k = \vec{h}_k \oplus \overleftarrow{h}_k \quad (3)$$

令 GRU 的隐藏单元数为  $l$ , 则  $h_k \in R^{2l}$ 。句向量  $S$  经过双向 GRU 处理后可表示为  $H_u = \{h_1, \dots, h_d\}$ , 其中  $H_u \in R^{d \times 2l}$ 。

在得到句向量  $S$  的上下文信息  $H_u$  后, NARRE, DeepCLFM 和 RTRM 都采用(自)注意力机制来度量每条评论对用户偏好的贡献程度。考虑到用户倾向于浏览距离当前时间较近的评论并据此做出选择, 此处, 本文拟在注意力机制中引入时间因子  $\omega(t)$  来度量评论的时效性, 即:

$$\omega(t) = (1 + e^{-\alpha(t_p - t_k)})^{-1}, \alpha \in (0, 1) \quad (4)$$

此处  $\alpha$  为时间衰变因子;  $t_k$  为第  $k$  条评论的评论时间;  $t_p$  为最近一条评论的评论时间。

所以, 用户  $u$  每条评论的时效权重计算步骤如下:

首先, 使用注意力机制计算用户  $u$  的评论贡献度  $a$ , 即:

$$a = \text{softmax}(\omega_1 \times \text{RELU}(\omega_2 \times H_u^T)) \quad (5)$$

此处 softmax 函数对注意力权重进行归一化处理, 得到  $a = \{a_1, \dots, a_d\}$ ,  $a \in R^{1 \times d}$ ,  $\omega_1 \in R^{1 \times \mu}$ ,  $\omega_2 \in R^{\mu \times 2l}$ 。

其次, 利用时效权重函数  $\omega(t)$  对每条评论的时间戳进行映射, 得到评论的时效权重  $T = \{t_1, \dots, t_d\}$ ,  $T \in R^{1 \times d}$ , 并将其与评论贡献度结合, 得到评论的时效贡献权重  $T\_A$ , 即:

$$T\_A = T * a \quad (6)$$

在获取时效贡献权重  $T\_A \in R^{1 \times d}$  后, 接入全连接层以得到用户  $u$  偏好特征  $Feature_u$ , 即:

$$\mathbf{Feature}_U = \text{Fully\_Connected}(\mathbf{T}_A \times \mathbf{H}_u) \quad (7)$$

同理,使用  $TNet_i$  可从物品评论集中学习到物品  $i$  的物品特征  $\mathbf{Feature}_I$ 。

### 3.3 基于评分的特征提取

该模块任务是从评分数据中提取用户隐向量  $\mathbf{LFM}_U$ 、物品隐向量  $\mathbf{LFM}_I$  和可信近邻信任向量  $\mathbf{TRUST}_U$ 。

对用户隐向量  $\mathbf{LFM}_U$  和物品隐向量  $\mathbf{LFM}_I$  的提取,可利用矩阵分解方法进行,即:

$$R_{m \times n} \approx \mathbf{LFM}_U \mathbf{LFM}_I^T \quad (8)$$

$$\mathbf{LFM}_U = \{\mathbf{LFM}_{u_1}, \dots, \mathbf{LFM}_{u_m}\}^T \quad (9)$$

$$\mathbf{LFM}_I = \{\mathbf{LFM}_{i_1}, \dots, \mathbf{LFM}_{i_n}\}^T \quad (10)$$

此处,  $R_{m \times n}$  为评分矩阵,  $\mathbf{LFM}_{u_i}$  为用户  $u_i$  的隐向量,  $\mathbf{LFM}_{i_j}$  为物品  $i_j$  的隐向量。

对用户可信近邻信任向量  $\mathbf{TRUST}_U$  的提取采用如下步骤:

#### (1) 近邻用户筛选

算法 1 给出了近邻用户筛选过程。其中,第 2-3 行利用逆向云算法<sup>[18]</sup>计算用户评分特征向量  $\vec{U} = (Ex, En, He)$ 。其中,  $Ex$  为期望,用于表示用户评分的平均水平;  $En$  为熵,用于表示用户评分的离散度;  $He$  为超熵,用于表示熵的稳定度。第 4-8 行利用修正的相似性度量方法计算用户  $u_i$  和  $u_j$  之间的相似度  $\text{sim}(\vec{u}_i, \vec{u}_j)$ , 即:

$$\text{sim}(\vec{u}_i, \vec{u}_j) = \frac{\vec{u}_i(Ex, En, He) * \vec{u}_j(Ex, En, He)}{\sqrt{|\vec{u}_i(Ex, En, He)|^2} * \sqrt{|\vec{u}_j(Ex, En, He)|^2}} \quad (11)$$

第 9-11 行选取相似度较高的前  $K$  个用户作为近邻用户。

#### 算法 1 近邻用户筛选

输入: 评分矩阵  $R_{m \times n}(U, I)$ , 近邻用户数  $K$

输出: 近邻用户集  $NS$

1.  $NS \leftarrow \emptyset$ ;
2. for each  $u_i \in U$  do
3.  $\vec{u}_i \leftarrow (Ex, En, He)$ ;
4. for each  $u_j \in U$  do
5.  $\text{simset}(u_i) \leftarrow \emptyset$ ;
6. for each  $u_j \in U (i \neq j)$  do
7. 利用式(11)计算  $\text{sim}(\vec{u}_i, \vec{u}_j)$ ;
8.  $\text{simset}(u_i) \leftarrow \text{simset}(u_i) \cup \{u_j\}$ ;
9. for each  $u_i \in U$  do
10.  $NS(u_i) \leftarrow \text{top}^K(\text{simset}(u_i))$ ;
11.  $NS \leftarrow NS \cup \{NS(u_i)\}$ ;
12. return  $NS$ .

#### (2) 近邻信度计算

针对  $\forall u_a \in U, u_i$  为  $u_a$  的任一近邻用户,  $CRIS(u_a, u_i)$  为  $u_a$  与  $u_i$  的共同评分项目集, 且  $i_j$  为该集中按时间先后排列的第  $j$  个项目。  $u_a$  与  $u_i$  的信度计算过程如下:

Step1 计算  $u_a$  在物品  $i_j$  上的评分  $\hat{r}_{aj}$ , 即:

$$\hat{r}_{aj} = \bar{r}_a + (r_{ij} - \bar{r}_i) \quad (12)$$

其中,  $\bar{r}_a$  和  $\bar{r}_i$  分别为  $u_a$  和  $u_i$  的评分均值。

Step2 利用  $\hat{r}_{aj}$  将  $u_a$  的评分特征向量更新为  $u_a^*$ , 计算  $u_a$  对  $u_i$  的推荐满意度  $SAT^j(u_a, u_i)$ , 即:

$$SAT^j(u_a, u_i) = \begin{cases} 1, & \text{sim}(\vec{u}_a, \vec{u}_i^*) \geq \varepsilon \\ 0, & \text{else} \end{cases} \quad (13)$$

其中,  $\vec{u}_a$  为  $u_a$  的真实评分特征向量,  $\varepsilon$  表示评分特征向量

相似度阈值。

Step3 计算  $u_i$  的初始信度  $IRT^j(u_a, u_i)$ :

$$IRT^j(u_a, u_i) = \frac{\sum_{k=1}^j SAT^k(u_a, u_i)}{j}, 1 \leq j \leq |CRIS(u_a, u_i)| \quad (14)$$

Step4 计算  $u_i$  的可靠信度  $RT^j$ , 即:

$$RT^j(u_a, u_i) = \alpha * IRT^j(u_a, u_i) + \beta * HRT_{i_1}^{j-1}(u_a, u_i) \quad (15)$$

其中,  $\alpha, \beta$  为各部分的权重, 且  $0 < \alpha, \beta < 1$ 。  $HRT_{i_1}^{j-1}$  为  $u_i$  呈现给  $u_a$  的历史信度, 即:

$$HRT_{i_1}^{j-1} = \begin{cases} 0, & j=1 \\ \frac{\sum_{k=1}^{j-1} IRT^k * \rho^{j-(k+1)}}{\sum_{k=1}^{j-1} \rho^{j-(k+1)}}, & j>1 \end{cases} \quad (16)$$

其中,  $\rho (0 < \rho \leq 1)$  为历史信度的关注因子。

Step5 跳转至 Step1 以更新  $RT^j$ , 直至  $j = |CRIS(u_a, u_i)|$  为止, 并最终返回  $u_i$  呈现给  $u_a$  的可靠信度  $RT^j$ 。

针对  $\forall u_i \in NS(u_a)$ , 使用 Step1-Step5 计算可靠信度  $RT(u_i, u_a)$ , 从而获取  $u_a$  的近邻信度集  $RT(u_a)$ 。针对  $\forall u_a \in U$ , 计算其近邻信度集, 最后得到  $U$  的近邻信度集  $RT$ 。

#### (3) 可信近邻信任向量获取

算法 2 给出了可信近邻信任向量获取过程。第 3 行选取  $u_i$  前  $S$  个较高信度的近邻作为其可信近邻  $T_U(u_i)$ , 第 4 行通过聚合得到  $u_i$  的可信近邻信任向量  $\mathbf{TRUST}_U(u_i)$ , 第 6 行返回用户集  $U$  的可信近邻信任向量  $\mathbf{TRUST}_U$ 。

#### 算法 2 可信近邻信任向量计算

输入: 用户集  $U$ , 近邻信度集  $RT$ , 可信近邻数  $S$

输出: 可信近邻信任向量  $\mathbf{TRUST}_U$

1.  $\mathbf{TRUST}_U \leftarrow \emptyset$ ;
2. for each  $u_i \in U$  do
3.  $T_U(u_i) \leftarrow \text{top}^S(RT(u_i))$ ;
4.  $\mathbf{TRUST}_U(u_i) = \sum \vec{u}_j / \sqrt{|T_U(u_i)|}, u_j \in T_U(u_i)$ ;
5.  $\mathbf{TRUST}_U \leftarrow \mathbf{TRUST}_U \cup \{\mathbf{TRUST}_U(u_i)\}$ ;
6. return  $\mathbf{TRUST}_U$ .

### 3.4 特征融合及评分预测

首先, 将从评论中提取到的用户偏好  $\mathbf{Feature}_U$  和物品特征  $\mathbf{Feature}_I$  与从评分中提取到的用户、物品的隐向量  $\mathbf{LFM}_U$  以及  $\mathbf{LFM}_I$  进行拼接运算, 即:

$$\mathbf{I} = \mathbf{Feature}_I \oplus \mathbf{LFM}_I \quad (17)$$

$$\mathbf{U}' = \mathbf{Feature}_U \oplus \mathbf{LFM}_U \quad (18)$$

其次, 对上述得到的用户特征中间向量  $\mathbf{U}'$  与从评分中提取到的可信近邻信任向量  $\mathbf{TRUST}_U$  进行对应维度相加运算, 即:

$$\mathbf{U} = \mathbf{TRUST}_U \odot \mathbf{U}' \quad (19)$$

最后, 将最终获取到的用户偏好特征  $\mathbf{U}$  和物品特征  $\mathbf{I}$  输入全连接层, 通过特征映射得到用户对物品的预测评分, 即:

$$\mathbf{Y}_{\text{Predict}} = \boldsymbol{\mu} + \mathbf{b}_i + \mathbf{b}_u + \mathbf{W} \times \text{multiply}(\mathbf{U}, \mathbf{I}) \quad (20)$$

其中,  $\boldsymbol{\mu}$  为全局平均值偏移,  $\mathbf{b}_i$  为物品偏移,  $\mathbf{b}_u$  为用户偏移,  $\mathbf{W}$  为权重矩阵,  $\text{multiply}$  为内积操作。

此处使用平方损失作为模型训练的损失函数。同时, 为避免训练过程中出现过拟合现象, 在损失函数  $L$  中添加正则项来对参数实施约束, 即:

$$L = \frac{1}{2} \sum_{u \in U, i \in I} (\tilde{r}_{ui} - r_{ui})^2 + \frac{\lambda}{2} (\|\mathbf{W}\|^2 + \|\mathbf{I}\|^2 +$$

$$\|U'\|^2 + \|b_u\|^2 + \|b_i\|^2 \quad (21)$$

其中,参数 $\lambda$ 用于平衡两个损失项的权重。

## 4 实验及分析

### 4.1 评估目标及基线模型

对 RM-RT<sup>2</sup>NI 的性能评估重点回答以下 3 个问题:

- (1)相比于基线模型,该模型是否提高了评分预测精度;
- (2)该模型各超参数对评分预测精度的影响如何;
- (3)单独考虑评论时效和单独考虑可信近邻影响力对模型评分预测精度的提升各自有多大。

本文选取的基线模型如下:

(1)LFM:利用矩阵分解从评分矩阵中提取用户、物品隐特征。

(2)SVD++:基于 LFM 从评分中提取用户、物品隐特征,但较 LFM 而言,添加了用户隐式反馈。

(3)Time-SVD++:将评分时间引入 SVD++,考察了评分时效对用户偏好的影响。

(4)DeepCoNN:利用 CNN 从评论中提取用户、物品特征,未考虑评分信息。

(5)NARRE:在 DeepCoNN 的基础上,利用 LFM 从评分中提取用户物品特征,引入注意力机制度量评论的重要度。

(6)DeepCLFM:在 NARRE 的基础上,将从评论中提取到的用户物品深层特征与从评分中提取到的用户物品浅层特征进行一二阶特征融合。

(7)RTRM:与 NARRE 不同的是,RTRM 在从评分中提取用户物品隐特征时考虑了近邻用户影响力。

表 1 从是否利用评分、评论、深度学习、注意力机制、时效性、近邻影响力这 6 个维度对各模型进行了细粒度比较。

表 1 模型比较

Table 1 Model comparison

	评分	评论	深度学习	注意力机制	时效		近邻影响力	
					评分	评论	相似近邻	可信近邻
LFM	✓	/	/	/	/	/	/	/
SVD++	✓	/	/	/	/	/	✓	/
Time-SVD++	✓	/	/	/	✓	/	✓	/
DeepCoNN	/	✓	✓	/	/	/	/	/
NARRE	✓	✓	✓	✓	/	/	/	/
DeepCLFM	✓	✓	✓	✓	/	/	/	/
RTRM	✓	✓	✓	✓	/	/	✓	/
RM-RT <sup>2</sup> NI	✓	✓	✓	✓	/	✓	✓	✓

### 4.2 数据集与实验设置

实验数据来源于 Amazon 5-core 的 Clothing, Office\_Products(OP), Musical\_Instruments(MI), Sports\_and\_Outdoors(SO)以及 Beauty 数据集。各数据集评分数据都极为稀疏,基本信息统计如表 2 所列。

表 2 数据集统计信息

Table 2 Dataset statistics

数据集	用户数	物品数	评分数	稀疏度/%
Clothing	39 387	23 033	278 677	99.97
OP	4 905	2 420	53 258	99.55
MI	1 429	900	10 261	99.20
SO	35 598	18 357	296 337	99.95
Beauty	22 363	12 101	198 502	99.93

表 3 列出了各数据集的评论信息统计,其中,U-R-

AVG 为每位用户的平均评论数,I-R-AVG 为每件物品的平均评论数,U-W-AVG 为用户评论集的平均单词数,I-W-AVG 为物品评论集的平均单词数。从表中可知,评论信息较为丰富。

表 3 数据集评论信息统计

Table 3 Dataset review information statistics

数据集	U-R-AVG	I-R-AVG	U-W-AVG	I-W-AVG
Clothing	5	9	187.01	262.10
OP	8	17	329.43	380.25
MI	5	9	244.97	338.37
SO	6	12	256.68	347.09
Beauty	7	13	252.32	328.03

实验中,为保持评论长度及数量的一致性,设置评论选取率为 0.85。实验平台采用 CPU(E5-1230V3,2.40 GHz)、内存(32G)、GPU(RTX3090 24GB);深度学习框架采用 PyTorch1.9.0;编程语言采用 python 3.9.7。训练集、验证集和测试集的划分比例为 8:1:1。模型性能评估指标选用均方根误差(RMSE)。

进一步,为了保证评估公平性,7 种基线模型在参数设置上参照了原始文献,并通过微调使其性能最优。

(1)对于 LFM,SVD++ 和 Time-SVD++,拟从[8,16,32,64]中搜索最佳隐因子数量,从[0.0001,0.001,0.01,0.1,1.0]中搜索最佳正则化系数。

(2)对于 DeepCoNN,NARRE,DeepCLFM,RTRM 和 RM-RT<sup>2</sup>NI,在词向量化上,为 DeepCoNN 和 NARRE 选用 300 维的 Glove 预训练模型,为 DeepCLFM,RTRM 和 RM-RT<sup>2</sup>NI 选用 Sentence-BERT 句向量模型;同时,将 DeepCoNN 和 NARRE 中卷积核大小设置为 3、个数设置为 100;DeepCLFM,RTRM 和 RM-RT<sup>2</sup>NI 的 GRU 隐藏单元数设置为 200;RTRM 和 RM-RT<sup>2</sup>NI 的近邻用户数设置为 40,将 RM-RT<sup>2</sup>NI 的可信近邻数初始设置为 10。

### 4.3 评分预测精度对比

表 4 列出了 RM-RT<sup>2</sup>NI 模型与 7 种基线模型的评分预测精度对比,可以看出:

(1)在 LFM,SVD++,Time-SVD++ 这 3 个基于评分数据的模型中,Time-SVD++ 具有最高的评分预测精度。这表明,在特征提取时考虑时效信息能够提高评分预测精度。

(2)仅基于评论的 DeepCoNN 模型在性能上优于基于评分的 LFM,SVD++,Time-SVD++ 模型。这表明,相较于评分数据,评论文本可能含有更多的用户、物品特征信息。

(3)NARRE,DeepCLFM,RTRM 和 RM-RT<sup>2</sup>NI 这 4 个基于评论与评分的模型在性能上优于 LFM,SVD++,Time-SVD++ 和 DeepCoNN。这表明,与单纯从评论或评分中提取特征相比,融合评论与评分可以提取到更为丰富的用户、物品特征。

(4)RTRM 在性能上优于 NARRE 和 DeepCLFM,这表明在特征提取时融合近邻影响力可以提升模型的特征提取效果。

(5)RM-RT<sup>2</sup>NI 较 7 个基线模型在性能上平均提升了 3.0657%。这表明在特征提取过程中,融合评论时效和可信近邻影响力能够改善模型的特征提取效果。

表4 评分预测精度对比

Table 4 Comparison of rating prediction accuracy

模型	Clothing	OP	MI	SO	Beauty	RMSE 均值	RM-RT <sup>2</sup> NI 提升/%
LFM	1.1404	0.8833	0.9845	1.0080	1.1557	1.0344	7.4820
SVD++	1.1064	0.8667	0.9432	0.9705	1.1256	1.0025	4.2920
Time-SVD++	1.0959	0.8582	0.9352	0.9662	1.1220	0.9955	3.5940
DeepCoNN	1.0798	0.8525	0.9309	0.9546	1.1118	0.9859	2.6360
NARRE	1.0702	0.8471	0.9148	0.9478	1.0964	0.9753	1.5700
DeepCLFM	1.0672	0.8410	0.8991	0.9486	1.0965	0.9705	1.0920
RTRM	1.0631	0.8407	0.8920	0.9463	1.0954	0.9675	0.7940
RM-RT <sup>2</sup> NI	1.0569	0.8336	0.8697	0.9435	1.0941	0.9596	3.0657 (avg.)

#### 4.4 调参

本节在 OP, MI 和 SO 的验证集上测试 dropout 比率、隐因子数, 以及可信邻居数对 RM-RT<sup>2</sup>NI 性能的影响程度。

(1) dropout 比率。设置 dropout 比率为 [0.1, 0.3, 0.5, 0.7, 0.9]。从图 2 可以看出, RM-RT<sup>2</sup>NI 的性能随 dropout 比率的不同而有所变化; 对于 OP 验证集而言, 比率为 0.5 时模型性能最好; 对于 MI 验证集, 比率为 0.7 时模型性能最好; 而对于 SO 验证集, 比率为 0.3 时模型性能最好。

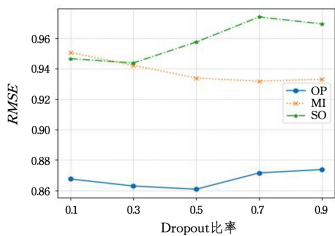


图2 dropout 比率对模型性能的影响

Fig. 2 Effect of dropout ratio on model performance

(2) 隐因子数。设置隐因子数为 [8, 16, 32, 64, 128]。从图 3 可知, 在 OP, MI 和 SO 验证集上, 隐因子数分别为 16, 16 和 32 时模型性能最好。其次, 随着隐因子数的增大, RMSE 也随之升高, 这表明隐因子数的增大, 会导致模型出现过拟合现象。




图3 隐因子数对模型性能的影响

Fig. 3 Effect of hidden factor number on model performance

(3) 可信邻居数。设置可信邻居数为 [10, 15, 20, 25]。从图 4 可知, 在 OP, MI 和 SO 验证集上, 该参数分别为 10, 25 和 15 时模型性能最好。同时, 相较于 OP 和 SO, 该参数在 MI 上对模型性能提升的影响最明显, 这是因为 MI 评分稀疏度最低, 可信邻居数的增多会提升可信邻居影响。

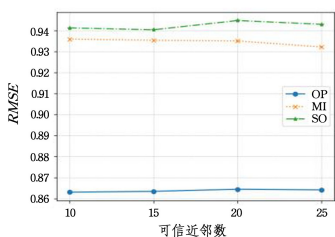


图4 可信邻居数对模型性能的影响

Fig. 4 Effect of trusted neighbor number on model performance

#### 4.5 消融实验

为评估评论时效与可信邻居影响力对 RM-RT<sup>2</sup>NI 模型性能提升的影响程度, 此处通过删除 RM-RT<sup>2</sup>NI 模型注意力机制的评论时效度量功能, 构建对比模型 RM-RTNI<sub>1</sub>; 通过删除 RM-RT<sup>2</sup>NI 模型近邻信度评估功能, 构建对比模型 RM-RTNI<sub>2</sub>。

从图 5 可以看出, RM-RT<sup>2</sup>NI 模型在 OP, MI 和 SO 上的评分预测性能均比 RM-RTNI<sub>1</sub> 模型优秀, 在这 3 个数据集上前者性能比后者分别提升了 0.67%, 1.59% 和 0.14%。这表明, 本文通过在注意力机制中添加评论时效度量功能, 提高了模型的特征提取效果; RM-RT<sup>2</sup>NI 模型的预测精度较 RM-RTNI<sub>2</sub> 模型有所提升, 在 OP, MI 和 SO 数据集上, 前者性能相较于后者分别提升了 0.53%, 1.47% 和 0.22%。这表明, 本文在特征提取中引入可信邻居评分影响力, 提升了评分预测精度。

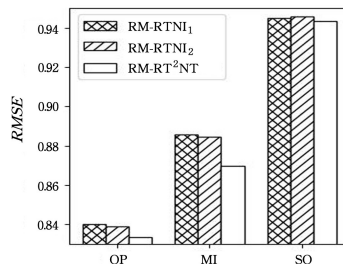


图5 引入模块前后对模型性能的影响

Fig. 5 Effect on model performance before and after introducing modules

**结束语** 本文构建了一种融合评论时效和可信邻居影响力的推荐模型。该模型的特色在于从评论中提取用户物品特征时考虑了评论时间对评论重要度的影响, 从评分中提取用户特征时考虑了可信任的近邻的影响。下一步工作拟利用图神经网络对用户-物品交互关系进行分析, 挖掘评分数据中的用户深层特征和用户间信任关系, 进一步提高预测精度。

#### 参考文献

- [1] KO H, LEE S, PARK Y, et al. A survey of recommendation systems: recommendation models, techniques, and application fields [J]. Electronics, 2022, 11(1): 141-189.
- [2] ZHU Z, WANG S, WANG F, et al. Recommendation networks of homogeneous products on an E-commerce platform: Measurement and competition effects [J]. Expert Systems with Applications, 2022, 201: 117-128.
- [3] DHELMIM S, AUNG N, BOURASM A, et al. A survey on personality-aware recommendation systems [J]. Artificial Intelligence Review, 2022, 55: 2409-2454.
- [4] RAZA S, DING C. News recommender system: a review of re-

- cent progress, challenges, and opportunities[J]. *Artificial Intelligence Review*, 2022, 55: 749-800.
- [5] ALHIJAWI B, AWAJAN A, FRAIHAT S. Survey on the objectives of recommender systems: Measures, solutions, evaluation methodology, and new perspectives[J]. *ACM Computing Surveys*, 2022, 55(5): 1-38.
- [6] TEGENE A, LIU Q, GAN Y, et al. Deep Learning and Embedding Based Latent Factor Model for Collaborative Recommender Systems[J]. *Applied Sciences*, 2023, 13(2): 726.
- [7] 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, USA, 2017: 425-434.
- [8] 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*. Republic and Canton of Geneva, CHE, 2018: 1583-1592.
- [9] 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.
- [10] LI S Z, YU L T, DENG X H. Recommendation Model Combining Deep Sentiment Analysis and Scoring Matrix[J]. *Journal of Electronics & Information Technology*, 2022, 44(1): 245-253.
- [11] ZHAI Y, ZHANG X, DAO R, et al. Research on the usefulness of online reviews in catering trade[C]// *2017 3rd International Conference on Information Management (ICIM)*. Chengdu, China, 2017: 247-251.
- [12] YUAN Y, ZAHIR A, YANG J. Modeling implicit trust in matrix factorization-based collaborative filtering [J]. *Applied Sciences*, 2019, 9(20): 4378-4396.
- [13] KASHANI S M Z, HAMIDZADEH J. Improvement of non-negative matrix-factorization-based and Trust-based approach to collaborative filtering for recommender systems[C]// *2020 6th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)*. Mashhad, Iran, 2020: 1-7.
- [14] XU S, ZHUANG H, SUN F, et al. Recommendation algorithm of probabilistic matrix factorization based on directed trust[J]. *Computers & Electrical Engineering*, 2021, 93: 107-206.
- [15] XI W D, HUANG L, WANG C D, et al. Deep rating and review neural network for item recommendation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(11): 6726-6736.
- [16] WU L, HE X, WANG X, et al. A survey on accuracy-oriented neural recommendation: From collaborative filtering to information-rich recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(5): 4425-4445.
- [17] FANG H, ZHANG D, SHU Y, et al. Deep learning for sequential recommendation: Algorithms, influential factors, and evaluations[J]. *ACM Transactions on Information Systems (TOIS)*, 2020, 39(1): 1-42.
- [18] TANG H, LEI M, GONG Q, et al. A BP neural network recommendation algorithm based on cloud model[J]. *IEEE Access*, 2019, 7: 35898-35907.



**HAN Zhigeng**, born in 1976, Ph.D, associate professor, is a member of CCF (No. 20278M). His main research interests include trustworthy recommendations and intelligent audit.



**ZHOU Ting**, born in 1999, postgraduate. Her main research interests include trustworthy recommendations and intelligent audit.