

# 基于深度受限玻尔兹曼机的个性化推荐算法

谢 妙<sup>1</sup>, 邓育林<sup>2</sup>, 吕 洁<sup>1</sup>

(1. 玉林师范学院计算机科学与工程学院, 玉林 537000; 2. 南宁师范大学计算机与信息工程学院, 南宁 530299)

**摘 要:** 为了提高个性化推荐系统性能, 提出了一种基于深度受限玻尔兹曼机的个性化推荐方法。首先通过提取推荐系统的用户和资源特征构建多层受限玻尔兹曼机(Restricted Boltzmann machine, RBM)网络, 从而形成深度受限玻尔兹曼机个性化推荐模型; 其次通过可视和隐藏层的边缘概率分布求解待推荐训练样本的最大似然度; 然后结合对比散度(Contrast divergence, CD)重构来获得RBM主要参数更新方式, 并通过可视和隐藏层的正反向更新, 来获得稳定的RBM结构; 最后利用计算用户资源评分值实现个性化推荐。实验结果表明, 在训练样本稀疏度合理范围内, 与常用个性化推荐算法比较, 所提方法通过合理控制RBM深度和设置合适的隐藏层节点数, 能够获得更优的均方根误差(Root mean squared error, RMSE)性能。

**关键词:** 个性化推荐; 深度受限玻尔兹曼机; 对比散度; 边缘概率; 均方根误差

**中图分类号:** TP311.5      **文献标志码:** A

## Personalized Recommendation Algorithm Based on Depth-Restricted Boltzmann Machine

XIE Miao<sup>1</sup>, DENG Yulin<sup>2</sup>, LYU Jie<sup>1</sup>

(1. School of Computer Science and Engineering, Yulin Normal University, Yulin 537000, China; 2. College of Computer and Information Engineering, Nanning Normal University, Nanning 530299, China)

**Abstract:** To improve the performance of personalized recommendation system, a personalized recommendation method based on depth-restricted Boltzmann machine is proposed. Firstly, by extracting the characteristics of users and resources of the recommendation system, a multi-layer restricted Boltzmann machine (RBM) network is constructed, thus forming a personalized recommendation model of depth-restricted Boltzmann machine. Secondly, the maximum likelihood of the training samples to be recommended is calculated by the marginal probability distribution of visible and hidden layers. Then, combined with contrastive divergence (CD) reconstruction, the main parameter updating mode of RBM is obtained, and the stable RBM structure is obtained by updating the visible and hidden layers in both directions. Finally, the personalized recommendation is realized by calculating the user resource score. Experimental results show that, within the reasonable range of sparsity of training samples, compared with the commonly used personalized recommendation algorithms, the proposed method can obtain better root mean squared error (RMSE) performance by reasonably controlling the depth of RBM and setting the appropriate number of hidden layer nodes.

**Key words:** personalized recommendation; depth-restricted Boltzmann machine; contrast divergence; marginal probability; root mean squared error (RMSE)

## 引 言

互联网数据日益增长,用户从网络中获取有效数据的难度提升。从用户端来讲,用户需要花费更多的时间来完成有价值数据的全网检索,资源获取的便捷度难以改进,因此主流方法是从服务端改进,通过服务端的记录、统计和计算来实现用户的个性化资源推荐,以解决用户从海量数据快速获取价值数据的问题。当前,个性化推荐的方法广泛用于各个行业<sup>[1-3]</sup>。电商行业将商品的个性化推荐应用到了极致,为顾客提供便利;在线社交网络根据用户的访问习惯为用户推荐兴趣相近的资源及好友;网络学习平台根据学员的学习习惯为其推荐学习资源,以解决学员挑选学习资源的盲目性。

当前,关于个性化推荐的研究较多。邵英玮等<sup>[4]</sup>对电商平台的商品推荐进行互补性研究,可根据用户购物习惯推荐未来可能需要的物品;Zhang等<sup>[5]</sup>采用图像处理算法对旅游景点进行位置识别,利用旅游图片为用户进行个性化旅游推荐;Gu等<sup>[6]</sup>详细阐述了知识图学习算法在不同推荐场景中的运用优势。这些研究都采用了合适的推荐方法用于不同领域的个性化推荐,但是主要的训练对象大多为自有数据集,可迁移性较差,且推荐准确度仍有一定提升空间。作为一种在实际应用中使用最多的神经网络模型,基于概率无向图的受限玻尔兹曼机(Restricted Boltzmann machine, RBM)已广泛应用于图像和语音处理等领域。近期,人们开始尝试将RBM应用于个性化推荐领域,并已成为一个很有意义的研究方向。例如杨宇环等<sup>[7]</sup>提出了融合关联规则FP-Growth和RBM的混合推荐算法并用于图书推荐,解决了推荐效率不高的问题。

但是,目前大多数将RBM模型应用于推荐领域的研究都是采用算法结合方式,且侧重于提升推荐效率,推荐准确性不高。为了进一步提升推荐的准确率,本文尝试构建多层RBM网络,来生成深度RBM个性化推荐模型。所提方法根据用户和资源的特征,以及用户对以往资源的评分,并结合RBM的多次正反向更新,来最终获得稳定的RBM模型。常用公共数据集上的测试结果表明,通过合理提取输入用户和资源特征,并利用用户对资源的评分结果,多层RBM网络可以有效提高系统推荐性能。

## 1 个性化推荐模型

### 1.1 深度受限玻尔兹曼机

如图1所示,受限玻尔兹曼机为两层网络结构,主要由可见层(Visual layer, VL)与隐藏层(Hidden layer, HL)构成<sup>[8]</sup>, $W$ 为可见层与隐藏层之间的连接权重。单个RBM可以多个级联,组成深度RBM网络结构,也就是说通过多层RBM来构建深度RBM模型。RBM网络结构主要参数如表1所示。

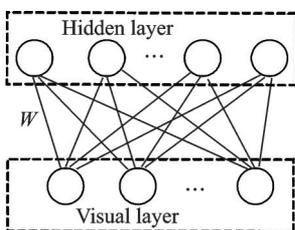


图1 RBM结构  
Fig.1 RBM structure

表1 RBM结构参数  
Table 1 Structural parameters of RBM

参数	数学表示
$a_i$	VL第 <i>i</i> 个神经元偏置
$v_i$	VL第 <i>i</i> 个神经元期望
$b_j$	HL第 <i>j</i> 个神经元偏置
$h_j$	HL第 <i>j</i> 个神经元期望
$W_{ij}$	VL第 <i>i</i> 个神经元与HL第 <i>j</i> 个神经元连接权重

设  $n$  和  $m$  分别表示 VL 与 HL 节点个数, 那么网络能量值为

$$E(v, h) = - \sum_{i=1}^n \sum_{j=1}^m v_i W_{ij} h_j - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n a_i v_i \quad (1)$$

VL 与 HL 之间的联合密度概率函数为<sup>[9]</sup>

$$p(v, h) = \frac{1}{Z} E(v, h) \quad (2)$$

由于自身层节点无连接, 因此 VL 与 HL 之间的条件概率分布分别为

$$p(h|v) = \prod_{i=1}^n p(h_i|v) \quad (3)$$

$$p(v|h) = \prod_{j=1}^m p(v_j|h) \quad (4)$$

式中  $Z = \sum_{v, h} e^{-E(v, h)}$  为归一化因子。

在 RBM 训练时, VL 边缘概率为

$$p(v) = \sum_h p(v, h) = \frac{1}{Z} \sum_h e^{-E(v, h)} \quad (5)$$

那么 HL 边缘概率为

$$p(h) = \sum_v p(v, h) = \frac{1}{Z} \sum_v e^{-E(v, h)} \quad (6)$$

根据 RBM 结构特点, VL 与 HL 已知其一, 便可以根据条件概率求取另外一个, 求解方法为<sup>[10]</sup>

$$p(h_j = 1|v) = \sigma \left( b_j + \sum_{i=1}^n v_i W_{ij} \right) \quad (7)$$

$$p(v_i = 1|h) = \sigma \left( a_i + \sum_{j=1}^m h_j W_{ij} \right) \quad (8)$$

式中  $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 。

因此, 若要求出  $p(v)$  和  $p(h)$ , 需要先求出  $Z$  的值, 根据  $Z = \sum_{v, h} e^{-E(v, h)}$ , 则需要计算隐藏层和可见层所有节点的概率分布, 计算量较大。常用方法为采用 CD 快速方法, 经过 CD 重构, 可以得到  $\langle v_i h_j \rangle_{\text{model}}$ 、 $\langle v_i \rangle_{\text{model}}$  和  $\langle h_j \rangle_{\text{model}}$ ; 然后结合式 (2, 7, 8) 分别计算出  $\langle v_i h_j \rangle_{\text{data}}$ 、 $\langle v_i \rangle_{\text{data}}$  和  $\langle h_j \rangle_{\text{data}}$ ; 最后采用以下方法计算  $a_i$ 、 $b_j$  和  $W_{ij}$  的更新方法<sup>[11]</sup>。

$$\Delta W_{ij} = \epsilon \cdot (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}}) \quad (9)$$

$$\Delta a_i = \epsilon \cdot (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{model}}) \quad (10)$$

$$\Delta b_j = \epsilon \cdot (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{model}}) \quad (11)$$

式中  $\epsilon$  表示学习率。

## 1.2 用户-资源的 RBM 建模

在用户对资源评分时, 考虑到用户对资源的评分为整数, 而 RBM 运算权重一般是经过归一化的值, 因此可以采用编码对评分值  $k$  进行编码运算, 因此  $W_{ij}$  变为  $W_{ij}^k$ , 则有

$$E(v, h) = - \sum_{i=1}^n \sum_{j=1}^m v_i W_{ij}^k h_j - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n a_i v_i \quad (12)$$

将 1.1 节的边缘概率求解及主要参数更新的  $W_{ij}$  均替换为  $W_{ij}^k$ , 进行常规 RBM 运算。

最后,求解用户  $u$  对资源  $i$  的评分为<sup>[12]</sup>

$$r_{u,i} = \sum_{l=1}^K l \cdot p(v_i^k = 1|h) \tag{13}$$

式中  $K$  表示评分的最大值。

### 1.3 个性化推荐流程

首先,输入用户和资源的特征变量并进行初始化。资源特征是指推荐系统目标优化时所涉及的主要属性,例如电影推荐系统中用户考虑的离家距离、大众评分数值和影院设施等。然后将特征变量输入RBM网络,根据需要可构建多层RBM网络,分别计算VL和HL所有节点的激活概率,然后利用快速CD法进行RBM主要参数更新,最后通过多次训练,获得稳定RBM推荐结构,主要流程如图2所示。

## 2 实验仿真

为了验证深度RBM在个性化推荐中的性能,进行实例仿真。本文采用的仿真数据样本均为公共数据集,具体如表2所示。

表 2 仿真样本  
Table 2 Simulation samples

数据集名称	用户数	资源数
Movie Lens100K	943	1 682
Movie Lens1M	6 040	3 900
Yahoo Webscope	7 642	11 915
Netflix	5 128	4 361

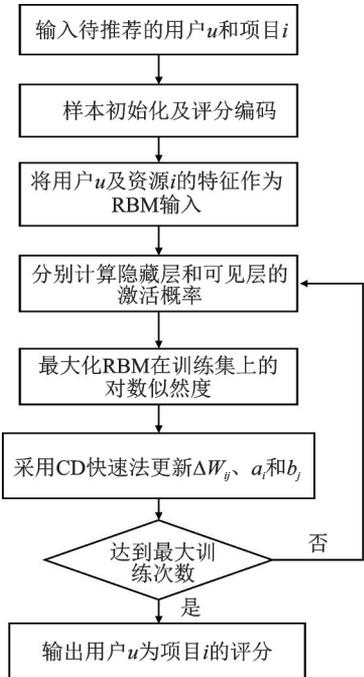


图 2 基于RBM的个性化推荐流程  
Fig.2 Personalized recommendation process based on RBM

深度RBM层数对RBM规模及训练效果均有着重要影响,而层数最终会表现在HL节点数目上,因此本文首先针对不同HL节点数进行仿真,找出最适合于本文样本的HL节点数;然后对参与训练的节点数,即不同样本稀疏度情况下进行推荐性能仿真;最后将常用算法和本文算法分别对表2中的样本集进行性能仿真,比较其推荐RMSE性能优劣。

### 2.1 不同HL节点数的均方根误差

分别设置不同的HL节点数,验证不同节点数情况下的均方根误差(Root mean squared error, RMSE)性能,结果如图3所示。

从图3可以看出, RMSE值均随着节点数的增加先降后升,表明个性化推荐的RMSE值受HL节点数影响敏感度高。对比发现Movie Lens和Netflix数据集和最佳节点数为100个,而数据集Yahoo Webscope在节点数为140时获得最优RMSE性能,这表明训练Yahoo Webscope数据集比其他3种数据集需要更大的深度RBM网络。从图3也可以看出,本文算法对Movie Lens100K的

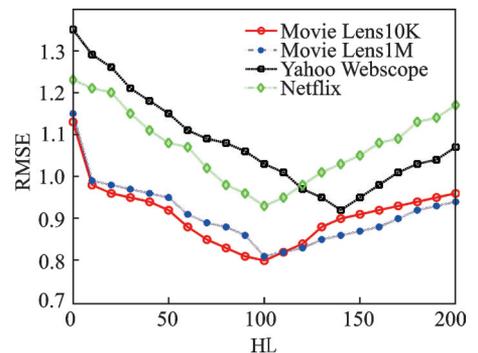


图 3 4种样本的RMSE  
Fig.3 RMSE of four samples

推荐性能最优,获得 RMSE 约为 0.8,对 Netflix 的推荐效果最差, RMSE 值约为 0.95。因此,本文针对 Netflix 集训练时选择的 HL 节点数为 140,其他 3 种数据集均选择 100 个 HL 节点参与运算。

### 2.2 不同样本稀疏度的 RMSE

深度 RBM 网络个性化推荐的性能除了与 RBM 结构规模相关,对训练样本量依赖性也较高,因此差异化设置参与训练的样本量,验证其推荐性能,结果如表 3 所示。初始状态的训练和测试样本比例为 8:2。

从表 3 可知,当参与训练的样本变少,4 种数据集的推荐 RMSE 值均上升。当训练集占比从 80% 降至 20% 时,Movie Lens100K 集、Movie Lens1M 集、Yahoo Webscope 集和 Netflix 集的 RMSE 性能分别下降了 34.02%、36.66%、30.25% 和 42.82%。对比发现,Netflix 集的个性化推荐对训练样本集的稀疏度最敏感,其次是 Movie Lens 集,样本集稀疏度对 Yahoo Webscope 集影响最小。总之,当训练集占比为 80% 时,可获得最优的个性化推荐性能。

### 2.3 不同算法的推荐性能

为了验证不同算法对表 2 中 4 种数据集的个性化推荐性能,分别采用协同过滤<sup>[13]</sup>、典型 RBM<sup>[14]</sup>、深度神经网络<sup>[15]</sup>和深度 RBM 算法对 4 种数据集进行训练,结果如图 4~7 所示。RBM 的节点数选择参照根据表 3 结果,4 种算法参与训练的节点数均为总样本数的 80%。

从图 4~7 可得,对于表 2 中 4 种数据集的个性化推荐,深度 RBM 的 RMSE 均是最低数值,这说明深度 RBM 对这 4 种数据集具有最高的推荐准确率。个性化推荐的准确率高低排序为深度 RBM 表现最优,深度神经网络次之,协同过滤和典型 RBM 的 RMSE 性能最差。从运行时间来看,协同过滤和典型 RBM 最好,深度 RBM 和深度神经网络表现较差,主要原因是深度学习框架的运行需要多次正反向更新,导致运算步骤耗时较高。此外,Yahoo Webscope 集的运行时间最长,主要是因为该样本集所包含的样本量最大。

表 3 不同训练样本量的 RMSE

Table 3 RMSE of different training sample sizes

数据集	训练集占比/%	RMSE
Movie Lens100K	80	0.812 5
	60	0.884 6
	40	0.913 2
	20	1.152 7
Movie Lens1M	80	0.826 7
	60	0.907 1
	40	0.926 8
	20	1.193 3
Yahoo Webscope	80	0.939 1
	60	0.954 9
	40	1.098 2
	20	1.241 6
Netflix	80	0.956 2
	60	0.987 7
	40	1.138 3
	20	1.384 4

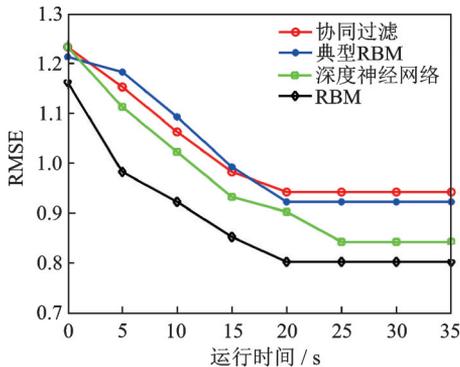


图 4 4 种算法的 RMSE(Movie Lens100K)

Fig.4 RMSE of four algorithms (Movie Lens100K)

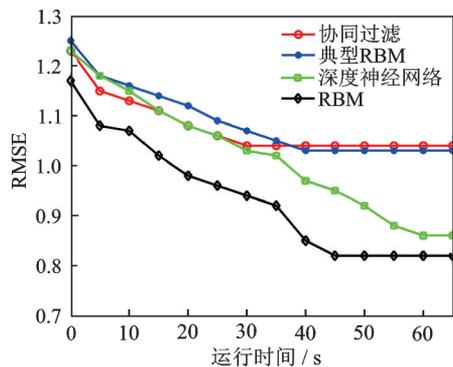


图 5 4 种算法的 RMSE(Movie Lens1M)

Fig.5 RMSE of four algorithms(Movie Lens1M)

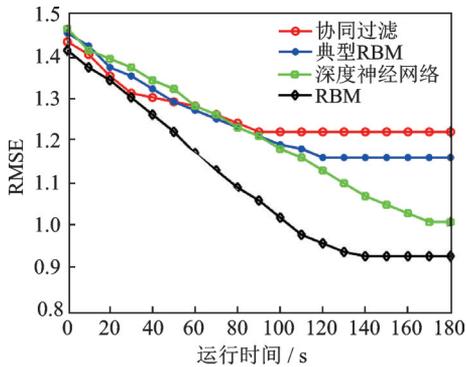


图6 4种算法的RMSE(Yahoo Webscope)

Fig.6 RMSE of four algorithms (Yahoo Webscope)

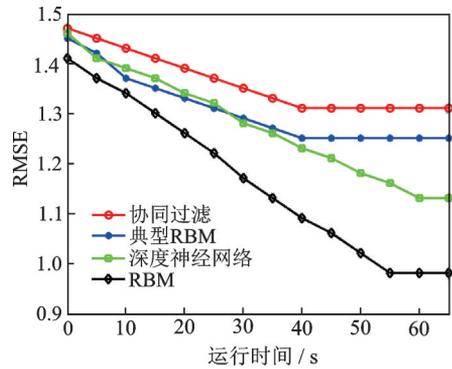


图7 4种算法的RMSE(Netflix)

Fig.7 RMSE of four algorithms(Netflix)

### 3 结束语

将深度RBM应用于个性化推荐系统,根据用户和资源的特征,以及用户对以往资源的评分,并结合多次正反向更新,来最终获得稳定的深度RBM模型。实验结果表明,在训练样本量充足时,合理设置深度RBM的规模及隐藏层节点数,相比于常见个性化推荐算法,本文算法能够获得更好的推荐RMSE性能。后续研究将进一步对深度RBM的主要参数更新进行优化计算,以提高推荐效率,提高该算法在个性化推荐中的适用度。

#### 参考文献:

- [1] CHEN X, XUE Y, SHIUE Y. Rule based semantic reasoning for personalized recommendation in indoor O2O e-commerce[J]. International Core Journal of Engineering, 2020, 6(1): 309-318.
- [2] 蔡永嘉, 李冠宇, 关皓元. 信任社交网络中基于图熵的个性化推荐算[J]. 计算机应用, 2019, 39(1): 182-186.  
CAI Yongjia, LI Guanyu, GUAN Haoyuan. Personalized recommendation algorithm based on graph entropy in trust social network[J]. Computer Applications, 2019, 39(1): 182-186.
- [3] CHAABI Y, NDIYAE N M, LEKDIOUI K. Personalized recommendation of educational resources in a MOOC using a combination of collaborative filtering and semantic content analysis[J]. International Journal of Scientific & Technology Research, 2020, 9(2): 3243-3248.
- [4] 邵英玮, 张敏, 马为之, 等. 融合商品潜在互补性发现的个性化推荐方法[J]. 软件学报, 2020, 31(4): 1090-1100.  
SHAO Yingwei, ZHANG Min, MA Weizhi, et al. A personalized recommendation method integrating commodity potential complementarity discovery[J]. Journal of Software, 2020, 31(4): 1090-1100.
- [5] ZHANG Q, LIU Y, LIU L, et al. Location identification and personalized recommendation of tourist attractions based on image processing[J]. Traitement du Signal, 2021, 38(1): 197-205.
- [6] GU T, LIANG H, BIN C, et al. Combining user-end and item-end knowledge graph learning for personalized recommendation [J]. Journal of Intelligent and Fuzzy Systems, 2021, 40(12): 1-13.
- [7] 杨宇环, 张开生. 融合FP-Growth和RBM的图书推荐算法研究[J]. 陕西科技大学学报, 2021, 39(4): 156-160.  
YANG Yuhuan, ZHANG Kaisheng. Research on book recommendation algorithm integrating FP-Growth and RBM[J]. Journal of Shaanxi University of Science & Technology, 2021, 39(4): 156-160.
- [8] TORU N. Direct representation of complex-valued data using complex extension of restricted Boltzmann machine and its application to speech signal processing[J]. The Journal of the Acoustical Society of Japan, 2019, 75(3): 164-172.
- [9] DONG K K. Generalized kernel restricted Boltzmann machine[J]. The Journal of Korean Institute of Communications and

Information Sciences, 2020, 45(5): 783-789.

- [10] BISWAL A, BORAH M D, HUSSAIN Z. Music recommender system using restricted Boltzmann machine with implicit feedback[J]. *Advances in Computers*, 2021, 122: 367-402.
- [11] FAKHARI A, KIANI K. A new restricted Boltzmann machine training algorithm for image restoration[J]. *Multimedia Tools and Applications*, 2020, 80(2): 2047-2062.
- [12] LÜ X, MENG L, CHEN C, et al. Fuzzy removing redundancy restricted Boltzmann machine: Improving learning speed and classification accuracy[J]. *IEEE Transactions on Fuzzy Systems*, 2020, 28(10): 2495-2509.
- [13] 李广丽, 朱涛, 袁天, 等. 混合分层抽样与协同过滤的旅游景点推荐模型研究[J]. *数据采集与处理*, 2019, 34(3): 566-576.  
LI Guangli, ZHU Tao, YUAN Tian, et al. Recommendation model of tourist attraction by fusing hierarchical sampling and collaborative filtering[J]. *Journal of Data Acquisition and Processing*, 2019, 34(3): 566-576.
- [14] CHOPRA P, YADAV S K. Restricted Boltzmann machine and softmax regression for fault detection and classification[J]. *Complex & Intelligent Systems*, 2018, 4(1): 67-77.
- [15] 郭旭, 朱敬华. 基于用户向量化表示和注意力机制的神经网络推荐模型[J]. *计算机科学*, 2019, 46(8): 118-122.  
GUO Xu, ZHU Jinghua. Deep neural network recommendation model based on user vectorization representation and attention mechanism[J]. *Computer Science*, 2019, 46(8): 118-122.

#### 作者简介:



谢妙(1976-),女,副教授,  
研究方向:机器学习、大数  
据分析,E-mail: x-m@yly.  
edu.cn。



邓育林(1975-),女,讲师,  
研究方向:人工智能。



吕洁(1979-),通信作者,  
女,副教授,研究方向:  
图像处理、大数据分析,  
E-mail: lvjie@yly.edu.cn。

(编辑:王静)