

DOI: 10.13718/j.cnki.xdzk.2023.04.019

基于读者兴趣挖掘的深度学习推荐模型

刘园园

武汉轻工大学 图书馆, 武汉 430023

摘要: 传统的推荐算法面临数据稀疏、泛化能力不强等问题, 导致推荐准确率不高. 近 10 年来深度学习由于较强的表达能力以及灵活的模型结构成为了最热门的研究方向. 该文提出一种基于读者兴趣挖掘的深度学习推荐模型 (Deep Reader Preference Mining For Book Recommendation, DRPM), 该算法运用自然语言处理技术提取图书丰富的语义特征, 利用长短时记忆网络模型对读者历史借阅记录进行建模, 分析读者兴趣, 并引入注意力机制使图书与读者进行有效交互, 挖掘读者动态阅读兴趣, 分析读者借阅偏好, 从而提供更加精准的图书推荐服务. 对武汉轻工大学图书馆 5 年真实数据的实验结果表明, 该文所提出的 DRPM 模型比基线模型在命中率(HR)和归一化折损累积增益(NDCG)评价指标上有较大提升.

关键词: 推荐算法; 深度学习; 自然语言处理; 长短时记忆网络; 注意力机制

中图分类号: TP391

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2023)04-0201-09

Deep Learning Recommendation Algorithm Based on Reader Preference Analysis

LIU Yuanyuan

Library, Wuhan Polytechnic University, Wuhan 430023, China

Abstract: Traditional recommendation algorithms face problems such as sparse data and weak generalization ability, resulting in low recommendation accuracy. In the past decade, deep learning has become the most popular research direction due to its strong expression ability and flexible model structure. In this paper, a deep reader preference mining for book recommendation (DRPM) is proposed. Natural language processing technology is used to extract rich semantic features of books. The LSTM is used to model readers' historical borrowing records and analyzes readers' interests. In addition, attention mechanism is introduced to realize the effective interaction between books and readers, excavate readers' dynamic reading interests and analyze readers' borrowing preferences, so as to provide more accurate book recommendation services.

收稿日期: 2022-10-31

基金项目: 国家自然科学基金项目(61906140); 湖北省自然科学基金杰出青年项目(2020CFA063); 武汉轻工大学高等教育研究一般项目(2020GJKT013).

作者简介: 刘园园, 硕士研究生, 主要从事推荐算法及数字图书馆研究.

Result of experiments on dataset of Wuhan Polytechnic University Library shows that the DRPM model proposed in this paper has a greater improvement in the evaluation of HR and NDCG indicators compared to the baseline model.

Key words: recommendation algorithm; deep learning; natural language processing; Long Short-Term Memory; attention

在信息时代,推荐系统作为缓解信息过载的重要手段,已经成为所有新闻、视频、音频、电商、互联网金融等相关平台的标配.目前正处于一个被推荐系统影响的时代,推荐系统已经渗透到我们生活的方方面面.个性化推荐从 1992 年诞生至今,经过 30 年的不断累积和沉淀,受到越来越广泛的关注和重视,已经发展成为了一门独立的学科.

传统的推荐算法,一般根据用户隐向量和物品隐向量的相似度进行物品推荐,虽然简单易懂且计算复杂度低,却十分依赖用户和物品的交互关系,一旦用户和物品的交互关系十分稀疏将会出现物品冷启动问题;同时传统的推荐算法利用的信息一般是单维数据,无法做到多方面、多维度数据的融合.深度学习具有更强的表达能力,无论是对数据的拟合能力或是对数据特征的挖掘能力都要强于传统模型,近 10 年已经成为最热门的研究方向,学者们将深度学习技术引入到推荐算法中,展开了相关研究. Karatzoglou 等^[1]对深度学习技术在推荐算法中的应用进行了详细介绍; Brandão 等^[2]认为协同过滤算法与深度学习相结合,是推荐算法研究的热门方向; Makkar 等^[3]将用户在网页停留时间以及页面点击的次数作为衡量用户对该网页感兴趣的程度; Hao 等^[4]根据用户的滚条拉动次数和用户在网页逗留时间建立线性回归方程来预测用户偏好;谢金峰^[5]、刘丰^[6]、程思等^[7]、汪菁瑶等^[8]研究用户的行为序列来提取用户兴趣,达到提高推荐准确率的目的;段超等^[9]、陶涛等^[10]、任胜兰等^[11]、张若琦等^[12]、刘羽茜等^[13]、于蒙等^[14]尝试在推荐系统中引入注意力机制提升推荐效率.在图书推荐领域,孙守川^[15]将深度学习与协同过滤算法相结合,建立读者检索借阅模型;尹婷婷等^[16]针对读者兴趣,提出了一种基于深度学习的馆藏资源推荐模型;丁永刚等^[17]利用用户学术背景信息,通过 SOM(Self-organizing feature Map)神经网络对读者进行聚类,并融入多种特征信息实现图书资源推荐;沈凌云^[18]利用 Word2vec 提取图书语义特征,采用长短时记忆网络(Long Short-Term Memory, LSTM)对读者借阅行为进行建模;黄禹等^[19]为了计算评分时能够融合更多层的特征,基于深度学习框架改进了矩阵分解算法.然而,目前深度学习技术大多应用在商品、电影、音乐等领域,在图书领域的应用研究较少,且在已开展的图书推荐应用研究中,存在图书特征提取不够充分、忽视读者行为序列与候选图书的关系、未区分读者对不同图书的偏好等问题.为此,本文提出了基于读者兴趣挖掘的深度学习推荐模型.

1) 在标准深度学习推荐模型的基础上,基于图书丰富的文本特征,利用谷歌提供的预训练 BERT(Bi-directional Encoder Representations from Transformers)模型对图书书名、图书内容摘要等语义特征生成向量表示;采用长短时记忆网络(LSTM)模型对读者历史借阅记录进行建模;引入注意力 Attention 机制为不同图书分配不同权重,为读者“下一次借阅”实现更精准的推荐.为了缓解新用户冷启动问题,将教材信息引入了读者借阅记录中,在新读者缺少历史借阅行为时,能根据其专业背景提供相关图书推荐.

2) 为了选择最优模型参数,进行了大量的模型训练实验.通过对不同的负采样比例、隐藏层设置、迭代次数等模型参数进行实验,最终确定正负样本比例为 1 : 5,隐藏层设置为 32 RuLU+16 ReLU+8 ReLU,模型迭代 5 次,推荐长度为 10 的参数设置为最优设置,并与不同算法进行对照实验.

1 相关理论基础

1.1 BERT 预训练模型

BERT 模型由谷歌团队^[20]提出,是一种可适用于多种自然语言处理任务的预训练模型. BERT 模型改进了传统预训练模型学习词向量的表示方法,基于 transformer 网络结构,创新性地提出了通过双向 Multi-

head Self-Attention 模块来学习词汇的词向量表示,从多角度、多方位理解词义,较好地解决了词汇的一词多义问题,一经提出就刷新了 11 项自然语言处理任务的当前最优性能记录,被认为是开创了自然语言处理(NLP)领域的新时代.

BERT 模型结构如图 1 所示,模型的输出代表既有句向量代表,也有每个词汇的词向量代表. Multi-head Self-Attention 层由多个 Self-Attention 模块构成,多个 Self-Attention 模块组成的 Multi-head Self-Attention 层能够将单词在不同模块中获得的词向量进行线性组合,最终生成涵盖多方面语义信息的超强表达能力的词向量;归一化层用来对神经网络的节点做均值为 0,方差为 1 的标准化处理;线性转化层起到增强模型表达能力的作用. 预训练阶段, BERT 模型通过遮盖语言模型(MLM)和下一句预测(NSP)两个目标任务来完成训练.




图 1 BERT 网络结构

1.2 LSTM 网络

LSTM 又称长短时记忆网络,是 Hochreiter 等^[21]提出的基础循环神经网络 RNN(Recurrent Neural Network)的改进模型,它引入了输入门(input gate)、遗忘门(forget gate)和输出门(output gate)3 个“门”单元来决定丢弃或者增加信息.“门”(Gate)由一个 Sigmoid 神经网络层和一个点乘法运算组成, Sigmoid 神经网络层输出 0 和 1 之间的数字,0 表示不通过任何信息,1 表示全部通过,由此来控制信息的通过.

LSTM 网络结构如图 2 所示,信息从输入门 i_t 贯穿到输出门 o_t ,就像传送带一样把信息从前一单元传递到下一个单元,从而实现遗忘或记忆的功能,因此较好地缓解了 RNN 的梯度消失问题. 计算过程如式(1)~式(6).

$$f_t = \text{sigmoid}(\mathbf{W}_{xf}x_t + \mathbf{W}_{hf}h_{t-1} + b_f) \quad (1)$$

$$i_t = \text{sigmoid}(\mathbf{W}_{xi}x_t + \mathbf{W}_{hi}h_{t-1} + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \quad (4)$$

$$o_t = \text{sigmoid}(\mathbf{W}_{xo}x_t + \mathbf{W}_{ho}h_{t-1} + b_o) \quad (5)$$

$$h_t = O_t \circ \tanh(C_t)$$

(6)

式(1)–式(6)中, f_t, i_t, o_t 分别代表遗忘门、输入门, 输出门, sigmoid 和 tanh 代表激活函数, $\circ$ 代表按元素相乘. x_t 是当前时刻的输入, h_{t-1} 是上一时刻的隐藏状态, $\tilde{C}_t$ 是经过 tanh 后获得的新状态, C_{t-1} 是上一次的单元状态, C_t 是更新后的状态, h_t 是最终的输出. W_{xf}, W_{hf} 和 b_f 分别代表遗忘门中 x_t, h_{t-1} 的权重矩阵和偏置项; W_{xi}, W_{hi} 和 b_i 分别代表输入门中 x_t, h_{t-1} 的权重矩阵和偏置项; W_c 和 b_c 代表 $\tilde{C}_t$ 中的权重矩阵和偏置项; W_{xo}, W_{ho} 与 b_o 分别代表输出门中 x_t, h_{t-1} 的权重矩阵和偏置项.




图 2 LSTM 在 t 时刻的网络结构

1.3 Attention 机制

Attention 机制, 即注意力机制, 灵感来源于对人类视觉注意力的模仿. 由于人类眼球的特殊构造, 使我们面对庞大的输入信息时, 视觉关注的重点是我们偏好的信息, 而忽略那些我们不感兴趣的信息. 深度学习中的注意力机制正是利用了人类视觉注意力的原理, 为不同对象赋予注意力权重. Bahdanau 等^[22]最先引入注意力机制应用于 NLP 领域的机器翻译任务, 从 2017 年开始研究者们尝试在推荐模型中引入 Attention 机制^[23-24], 目前注意力机制已成为深度学习推荐技术中的重要技术和研究热点^[25-26]. 注意力机制的计算实际上就是一个检索输入(查询 Query)到目标任务(键-值对 Key-Value)的映射过程. 如图 3 所示, Source 为数据源, 由 Key-Value 键值对组成. 首先通过相关函数计算出输入序列 Key(键)与目标任务 Query(查询)的相关性, 经过归一化处理后得到每个序列的注意力权重系数, 将计算出的权重系数与 Key 相对应的 Value 值加权求和, 得到最终的注意力权重. 值得注意的是, 在某些场景下 Key 与 Value 是同一个值.




图 3 查询及键-值对映射关系

2 基于读者兴趣挖掘的推荐模型

本研究提出的基于读者兴趣挖掘的 DRPM 模型结构如图 4 所示, 主要由输入层、特征提取层、偏好

提取层、MLP(Multi-Layer Perception)层构建而成。首先，将读者借阅历史、候选图书及读者人口统计学特征输入模型；其次，通过特征提取层提取图书文本特征及读者特征；然后，将已提取的读者借阅图书向量输入偏好提取层挖掘读者阅读兴趣；最后，将加权后的历史图书特征、候选图书特征及读者特征拼接后输入多层感知机中得到推荐结果。




图 4 DRPM 模型

2.1 输入层

模型输入层是能够表达读者和图书特征的信息，包含读者证件号、单位、性别、类别等属性，以及图书书名、摘要等内容特征。在图书推荐场景中，借阅记录是读者对图书偏好的重要表达和挖掘读者兴趣偏好的重要信息，因此是模型输入层的重要部分。此外，为了缓解用户冷启动问题，本实验将每学期的教材信息按单位和年级组关联到相关人员的借阅记录中，当新读者缺少历史借阅行为时，模型能根据其专业背景提供相关图书推荐。

2.2 特征提取层

模型的特征提取层是对输入信息进行特征提取。图书推荐与其他推荐的最大不同就在于图书本身含有标题、摘要等大量的文本信息，这些文本信息可以通过 NLP 技术进行特征提取，并生成图书向量表示。目前，在业界流行且效果得到广泛认可的 NLP 技术，大都基于深度学习模型来实现。本实验利用 BERT 模型提取读者的借阅历史与候选图书的语义特征，从而获得读者借阅行为向量和候选图书向量。此外，读者人口统计学特征通过 pytorch 的 embedding 模块获得向量表示。

2.3 偏好提取层

偏好提取层通过分析读者行为挖掘读者兴趣，从而学习读者偏好。首先，将在特征提取层提取的读者借阅图书向量输入 LSTM 网络进行训练，经过训练后的特征向量再与候选图书进行交互，然后计算每本图书不同的注意力权重，得到符合读者兴趣偏好的图书特征向量。

2.3.1 LSTM 兴趣提取

用户的兴趣偏好一般隐藏在用户行为中。读者的历史借阅行为正是其对图书偏好的具体表现，要想得到读者的阅读爱好，就需要从读者的借阅记录中找出读者与图书之间的关联，挖掘出两者更深层次的联

系。同时,由于读者的借阅行为会随着时间的改变而改变,本研究认为读者的借阅偏好受时间序列所影响,因此采用 LSTM 模型初步提取读者偏好特征。

2.3.2 引入注意力机制的偏好提取

由于读者对不同图书的喜好程度不同,在推荐过程中需要更加关注那些能反映读者兴趣的图书,本文引入注意力机制(Attention)来刻画不同图书对读者偏好的影响。对 LSTM 模型提取出的特征,通过增加注意力机制为读者借阅行为赋予不同的权重,越相关的图书分配系数越高,从而区分借阅记录中图书的重要程度,实现借阅行为偏好的动态抽取。计算过程如式(7)–式(9)所示。

$$\text{sim}(q_j, k) = k^T q_j \tag{7}$$

$$a_j = \text{softmax}(\text{sim}(q_j, k)) = \frac{\exp(\text{sim}(q_j, k))}{\sum_{j=1}^n \exp(\text{sim}(q_j, k))} \tag{8}$$

$$c = \sum_{j=1}^n a_j q_j \tag{9}$$

其中, k^T 表示推荐图书的表示向量 k 的转置, q_j 代表读者借阅的第 j 本书的向量表示;两者内积后得到的结果 $\text{sim}(q_j, k)$ 利用 softmax 函数进行指数归一化,计算出与候选图书的注意力权重分数 a_j ; c 表示最终的读者偏好向量; n 代表读者总的借阅数量。

3 推荐模型实验

3.1 实验环境

本研究实验运行的硬件环境为 Intel Corei9-10900X@4.0 GHz CPU, NVIDIA RTX3080Ti GPU, 64 GB RAM; 软件环境基于 Pytorch 框架,采用 Python 3.7 版本以及 Google 提供的 BERT-base(Chinese)预训练模型。

3.2 实验数据与数据预处理

本研究的数据来源于武汉轻工大学图书馆 2017–2021 年的真实借阅数据,以及该馆的馆藏图书信息、读者信息等。对于测试集与训练集的划分,本研究采用留一策略。测试数据正样本选择读者借阅历史中最近那次的借阅记录,其余作为训练数据正样本。负采样率训练集按 1 : 5、测试集按 1 : 50 的比例随机选取。为保证模型训练效果,借阅记录选择 10 本以上的读者进行模型实验,共获得 736 位读者的图书借阅记录。为了保证读者借阅数量的一致性,保留读者最后借阅的 10 条记录,最终得到的训练集为 39 744 条记录,测试集为 37 536 条记录,统计结果如表 1 所示。

表 1 实验数据详情

	读者人数	数据集大小		
		训练集	测试集	合计
正样本	736	6624	736	7 360
负样本	736	33 120	36 800	69 920
总计	736	39 744	37 536	77 280

3.3 目标函数

推荐问题一般可以转化成 1 个二分类问题,常使用交叉熵损失函数作为目标函数,如式(10)所示。

$$\text{loss} = -[y \cdot \log(p) + (1 - y) \cdot \log(1 - p)] \tag{10}$$

式(10)中, y 表示样本的真实标签,1 为正样本,0 为负样本, p 表示模型的预测值。

3.4 评价指标

本研究采用命中率(HR)和归一化折损累积增益(NDCG)两个指标作为评价标准衡量推荐性能,两个指标值高低代表推荐结果的好坏。HR 表示图书推荐列表中至少有一本能够预测正确,如式(11)所示;NDCG 用来评估图书推荐列表中的排序结果,根据图书相关性位置进行评分,评分越高代表推荐效果越

好,反之则推荐效果越差,如式(12)所示.

$$HR = \frac{1}{N} \sum_{i=1}^N hits(i)$$

(11)

式(11)中, N 代表推荐次数, $hits(i)$ 代表推荐列表是否命中第 i 个读者所借阅的图书.

$$NDCG = \frac{1}{N} \sum_{i=1}^N \frac{1}{\log(r_i + 1)}$$

(12)

式(12)中, r_i 代表推荐列表命中第 i 个读者真实借阅图书的位置.

3.5 超参数选择

3.5.1 负采样比例

为了选择最佳负采样比例,本研究分别按 1, 2, ..., 10 等不同数值比例配备负样本数量进行对比实验. 实验结果如图 5 所示, 每个正样本如果仅选择随机采一个负样本, 性能极差; 随着负采样比例增加, 系统性能随之提高. 然而, 当负采样比例达到 5 之后, 推荐模型的评价指标上升趋势逐步放缓, 推荐效果不再明显提升, 证明过度的负采样不仅会增加训练开销, 同时不会明显提升推荐效果. 经综合考虑后, 本研究选择正负样本比例按 1 : 5 进行随机负采样.




图 5 不同负采样率的评价指标

3.5.2 多层感知机隐藏层设置

不同的隐藏层设置会影响推荐效果, 本研究尝试了几种不同的隐藏层设置方案, 当正负样本比例设置为 1 : 5 时, 针对不同的隐藏层方案, HR@10 和 NDCG@10 的值如表 2 所示. 实验结果显示, 当模型不设置隐藏层时模型性能最差; 随着隐藏层宽度和深度增加, 模型性能逐步提升; 隐藏层设置为 32 RuLU+16 ReLU+8 ReLU 时, 模型性能最优, 推荐效果最好.

表 2 不同隐藏层的评价指标

隐藏层	HR@10	NDCG@10
无	0.583	0.352
8 ReLU	0.632	0.413
16 ReLU	0.657	0.433
32 ReLU	0.688	0.452
16 ReLU+8 ReLU	0.723	0.486
32 ReLU+16 ReLU	0.731	0.512
32 ReLU+16 ReLU+8 ReLU	0.743	0.532

3.6 对比实验结果

为了验证本研究提出模型的推荐效果, 选择了以下几种模型进行实验对比: ① 传统的 ItemCF(Item-based Collaborative Filtering)模型^[27]; ② 传统的 PMF(Probabilistic Matrix Factorization)模型^[28]; ③ 深度学习 BERT-MLP 模型; ④ 深度学习 BERT-LSTM-MLP 模型. 上述 4 种推荐算法与本研究提出的 DRPM 模型的实验结果如图 6 所示.

由图 6 可知, 深度学习模型性能要优于传统推荐模型. 相比传统的 ItemCF、PMF 模型仅利用人与物之间的交互行为, 深度学习模型由于融合了更多的特征, 能够挖掘出数据间更多的潜在关系, 因此具

有更强的表达能力和泛化能力. 在深度学习推荐模型中, 加入了 LSTM 的 BERT-LSTM-MLP 模型, 能够捕捉到序列数据特征, 比将 BERT 模型提取的图书特征向量直接输入多层感知机的 BERT-MLP 模型效果更好, 但推荐效果与本研究提出的 DRPM 模型相比仍有差距. DRPM 模型 HR 和 NDCG 指标分别达到 74.3% 和 53.2%, 由此说明循环神经网络 LSTM 处理时序数据能够提升模型性能, 且注意力机制能够进一步提高推荐效果, 同时也说明本研究提出的 DRPM 模型在图书推荐方面性能优于其他模型.

4 结语

本研究基于深度学习技术, 提出了基于读者兴趣挖掘的深度学习推荐模型. 该模型运用自然语言处理技术中的 BERT 模型对图书文本特征进行向量表示; 采用 LSTM 模型学习读者的借阅历史, 分析读者借阅偏好; 引入注意力机制学习读者兴趣演化, 为读者的借阅行为赋予不同的权重, 挖掘读者动态的兴趣向量. 同时将教材信息引入读者借阅记录中, 缓解了读者冷启动问题. 实验结果表明, 该模型在图书推荐上效果好于其他对比模型.

未来的工作将在提高模型可解释性方面进行探索. 可解释性推荐也是目前推荐算法中一个重要的研究方向, 解释性强的推荐会增加用户满意度和信任度, 从而提高推荐说服力和推荐成功率, 未来会尝试在本研究的基础上进行该方面的探索.

参考文献:

[1] KARATZOGLOU A, HIDASI B. Deep Learning for Recommender Systems [C] //Proceedings of the Eleventh ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2017.

[2] BRANDÃO M G, PAULO P J, HOJJAT A. Deep Learning Techniques for Recommender Systems Based on Collaborative Filtering [J]. Expert Systems, 2020, 37(6): 1-21.

[3] MAKKAR A, KUMAR N. User Behavior Analysis-Based Smart Energy Management for Webpage Ranking: Learning Automata-Based Solution [J]. Sustainable Computing: Informatics and Systems, 2018, 20: 174-191.

[4] HAO X, HAN S. An Algorithm for Generating a Recommended Rule Set Based on Learner's Browse Interest [J]. International Journal of Emerging Technologies in Learning, 2018, 13(11): 102-116.

[5] 谢金峰. 基于行为序列的用户兴趣挖掘研究 [D]. 哈尔滨: 哈尔滨工程大学, 2019.

[6] 刘丰. 基于用户行为序列挖掘的个性化推荐方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2021.

[7] 程思, 陶宏才. 一种融合时间权值和用户行为序列的电影推荐模型 [J]. 成都信息工程大学学报, 2022, 37(3): 241-247.

[8] 汪菁瑶, 吴国栋, 范维成, 等. 用户行为序列个性化推荐研究综述 [J]. 小型微型计算机系统, 2022, 43(5): 921-935.

[9] 段超, 张婧, 何彬, 等. 融合注意力机制的深度混合推荐算法 [J]. 计算机应用研究, 2021, 38(9): 2624-2627, 2634.

[10] 陶涛, 郑凯, 王一蕾, 等. 基于翻译结构的相对位置注意力机制推荐模型 [J]. 计算机工程与设计, 2021, 42(10): 2917-2923.

[11] 任胜兰, 郭慧娟, 黄文豪, 等. 基于注意力机制交互卷积神经网络的推荐方法 [J]. 计算机科学, 2022, 49(10): 126-131.




图 6 模型对比结果

- [12] 张若琦, 申建芳, 陈平华. 结合 GNN、Bi-GRU 及注意力机制的会话序列推荐 [J]. 数据分析与知识发现, 2022, 6(6): 46-54.
- [13] 刘羽茜, 刘玉奇, 张宗霖, 等. 注入注意力机制的深度特征融合新闻推荐模型 [J]. 计算机应用, 2022, 42(2): 426-432.
- [14] 于蒙, 蔡利平, 周绪川, 等. 融合注意力机制的深度学习推荐模型 [J]. 西南民族大学学报(自然科学版), 2022, 48(5): 550-560.
- [15] 孙守川. 基于深度学习的读者检索借阅研究 [D]. 兰州: 兰州交通大学, 2015.
- [16] 尹婷婷, 曾宪玉. 深度学习视角下图书馆馆藏资源推荐模型设计与分析 [J]. 现代情报, 2019, 39(4): 103-107, 124.
- [17] 丁永刚, 张雨琴, 付强, 等. 基于 SOM 神经网络和排序因子分解机的图书资源精准推荐 [J]. 情报理论与实践, 2019, 42(9): 133-138, 170.
- [18] 沈凌云. 基于深度学习的图书馆借阅推荐方法研究 [D]. 上海: 上海财经大学, 2020.
- [19] 黄禹, 张文德, 张诗雨. 基于深度距离分解的在线图书资源个性化推荐研究 [J]. 情报科学, 2021, 39(3): 76-81.
- [20] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-Training of Deep Bidirectional Transformers for Language Understanding [C] //Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Minneapolis: Association for Computational Linguistics, 2019.
- [21] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory [J]. Oral Oncology, 1997, 9(8): 1735-1780.
- [22] BAHDANAU D, CHO K, BENGIO Y. Neural Machine Translation by Jointly Learning to Align and Translate [C]. San Diego: Proceedings of the International Conference on Learning Representations, 2015.
- [23] XIAO J, YE H, HE X N, et al. Attentional Factorization Machines: Learning the Weight of Feature Interactions Via Attention Networks [C] //Proceedings of the 26th International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017.
- [24] ZHOU G R, SONG C R, ZHU X Q, et al. Deep Interest Network for Click-Through Rate Prediction [C] //Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018.
- [25] 陈海涵, 吴国栋, 李景霞, 等. 基于注意力机制的深度学习推荐研究进展 [J]. 计算机工程与科学, 2021, 43(2): 370-380.
- [26] 高广尚. 深度学习推荐模型中的注意力机制研究综述 [J]. 计算机工程与应用, 2022, 58(9): 9-18.
- [27] LINDEN G, SMITH B, YORK J. Amazon. com Recommendations: Item-to-Item Collaborative Filtering [J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [28] KOREN Y, BELL R, VOLINSKY C. Matrix Factorization Techniques for Recommender Systems [J]. Computer, 2009, 42(8): 30-37.

责任编辑 夏娟