

基于 MLP 改进型深度神经网络学习资源推荐算法 *

樊海玮, 史 双[†], 张博敏, 张艳萍, 蔺 琪, 孙 欢

(长安大学 信息工程学院, 西安 710064)

摘要: 针对在线学习过程中出现的知识过载及传统推荐算法中存在的稀疏和冷启动问题, 提出了一种基于多层感知机(MLP)的改进型深度神经网络学习资源推荐算法。该算法利用多层感知机对非线性数据处理的优势, 将学习者特征和学习资源特征进行向量相乘的预测方式转换为输入多层感知机的方式, 改进了 DN-CBR 神经网络推荐模型。为验证模型的有效性, 以爱课程在线学习平台数据为样本构建数据集, 通过对比实验表明, 在该数据集上, 改进后模型相较于 DN-CBR 模型在归一化折损累积增益和命中率指标上分别提升了 1.2% 和 3%, 有效地提高了模型的推荐性能。

关键词: 学习资源推荐; 深度学习; 卷积神经网络; Word2Vec; 多层感知机

中图分类号: TP183 **doi:** 10.19734/j.issn.1001-3695.2019.04.0109

Improved deep neural network of learning resource of recommendation algorithm based on MLP

Fan Haiwei, Shi Shuang[†], Zhang Bomin, Zhang Yanping, Lin Qi, Sun Huan
(Institute of Information Engineering, Chang'an University, Shanxi Xi'an 710064, China)

Abstract: Aiming at the knowledge overload in the process of online learning and the problems of data sparsity and cold start in the traditional recommendation algorithm, this paper proposed an improved learning resource recommendation algorithm based on multi-layer perceptron(MLP). By use of the advantage of multi-layer perceptron in nonlinear data processing, the prediction mode of vector multiplication of learner characteristics and learning resource characteristics is converted into the input mode of multi-layer perceptron, and improves the DN-CBR neural network recommendation model. In order to verify the effectiveness of the model, a data set was built with the online learning platform data of icourse as the sample. Compared with DN-CBR model, the improved model improves the normalized cumulative loss gain and hit rate by 1.2% and 3% respectively on the data set, which effectively improves the recommendation performance of the model.

Key words: recommendation of learning resources; deep learning; convolutional neural network; word2vec; multi-layer perceptron

0 引言

当前在线学习已成为一种普遍的学习方式, 学习者不必受限于实体课堂, 而可以突破传统的时空自由选择学习。在慕课大发展的这几年来, 支持在线学习的平台层出不穷, 为人们带来了很大的便利。与此同时人们注意到在海量学习内容面前出现了知识冗余加剧的新情况。在线学习环境中, 知识供给量空前充足的情况下, 学习者需花费大量时间查找、浏览才能确认是否是自己感兴趣的资源, 因此不可避免出现了知识过载的问题, 而解决知识过载问题的一个有效途径是使用个性化推荐算法^[1]。李嵩^[2]通过矩阵填充和用户聚类改进了协同过滤推荐算法, 降低了用户-物品评分矩阵的数据稀疏性; Chughtai 等人^[3]提出的基于目标导向的在线学习推荐系统着重解决了个性化推荐中的冷启动问题; Ng 等人^[4]在基于内容的推荐算法上, 使用主题分析技术对课程和教授进行打分评级, 并根据评分结果为学习者推荐相关课程。张俊格^[5]通过结合基于用户和基于物品的协同过滤推荐, 将学习风格引入其中, 帮助学习者快速找到感兴趣的学习资源。

综上所述, 协同过滤推荐算法主要依赖用户对物品的评分数据, 而用户和物品内容信息对其影响较小, 当新用户或新物品进入系统后, 由于缺乏评分数据, 会引起冷启动问

题, 降低推荐性能; 基于内容的推荐算法主要依赖物品的内容信息, 能解决新物品的冷启动问题, 但由于物品内容信息既包含结构化的数据又包含非结构化的数据, 故提取物品的特征有一定的难度。目前深度学习在图像处理、语音分析等领域表现出的巨大优势, 使得个性化推荐算法与深度学习的结合成为了可能。许多学者已进行初步探索, 李同欢^[6]将深度学习应用到推荐系统中, 利用其强大的特征提取能力解决系统中存在的数据稀疏问题; 马晓焯^[7]将卷积神经网络融合到传统的协同过滤推荐算法, 提出了深度协同过滤模型, 有效抽取了文本数据的特征。基于此, 文中研究基于深度神经网络的推荐模型 DN-CBR, 分析其优缺点并提出改进之处, 最后通过实验进行对比分析验证改进后模型的有效性。

1 DN-CBR 模型

DN-CBR 是基于深度神经网络实现推荐的模型。该模型充分结合了用户和物品的属性信息及物品的文本信息^[8]。对于用户和物品的属性信息, 模型利用深度神经网络提取用户的属性特征和物品的属性特征。对于物品的文本信息, 模型利用卷积神经网络进行文本向量化表示, 并提取物品的文本特征。通过结合物品的属性特征和文本特征形成最终的物品特征, 最后利用用户特征和物品特征向量相乘的方式预测评

收稿日期: 2019-04-30; 修回日期: 2019-07-02 基金项目: 中央高校教育教学改革专项(300103190639, 300103292405, 300103292403, 300103190605)

作者简介: 樊海玮(1974-), 男, 陕西西安人, 副教授、硕导, 博士, 主要研究方向为软件系统设计、软件复用技术; 史双(1995-), 女(通信作者), 陕西渭南人, 硕士研究生, 主要研究方向为深度学习、智能交通(1580158217@qq.com); 张博敏(1992-), 女, 山西忻州人, 硕士研究生, 主要研究方向为软件系统设计、推荐系统; 张艳萍(1992-), 女, 安徽亳州人, 硕士研究生, 主要研究方向为软件复用技术; 蔺琪(1994-), 女, 陕西渭南人, 硕士研究生, 主要研究方向为计算机视觉; 孙欢(1995-), 男, 陕西咸阳人, 硕士研究生, 主要研究方向为深度学习。

分, 根据评分值的大小为用户提供推荐服务。模型的主要目的是利用深度神经网络提取特征和组合特征的能力, 通过多层网络和多个神经元挖掘用户和物品之间的深层次关系。DN-CBR 模型如图 1 所示。

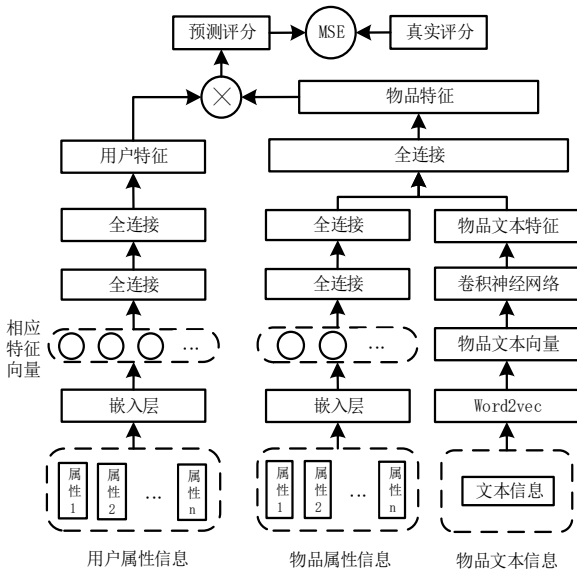


图 1 DN-CBR 模型

Fig. 1 DN-CBR model

1.1 DN-CBR 模型的优缺点

DN-CBR 模型充分依据用户和物品的属性信息、文本信息实现推荐服务。针对新用户, 可以根据用户的属性信息进行推荐; 针对新物品, 可以根据物品的属性和文本信息进行推荐。有效地缓解了传统推荐算法中存在的冷启动和数据稀疏问题。

同时, DN-CBR 模型在评分预测阶段采用向量相乘的方式进行预测评分, 计算复杂度相对较高, 容易消耗大量计算资源, 导致模型速率降低, 一定程度上影响了推荐效果。

1.2 采用 MLP 改进 DN-CBR 模型

多层感知机(multi-layer perceptron, MLP)由感知机发展而来, 其主要特征是有多个神经元层, 能对非线性数据进行处理^[9]。基本的模型结构包含输入层、隐含层和输出层, 其中隐含层的数量可多可少, 输入层到隐含层可看做为一个全连接层, 隐含层到输出层可看做为一个分类器。

从 1.1 节中可知, DN-CBR 模型中的评分预测方式存在缺陷, 有待改进。DN-CBR 模型针对用户特征和物品特征运用向量相乘的方式进行评分预测, 每一用户特征均与每一物品特征一一相乘, 既消耗时间又占据空间。因此, 文中利用多层感知机对非线性数据处理的优势, 将原先的向量相乘的方式转变为通过多层感知机的方式, 将模型得到的用户特征和物品特征输入到多层感知机中, 最终输出的值即为预测的评分值。示意图如图 2 所示。




图 2 基于 MLP 的评分预测方式

Fig. 2 Scoring forecasting method based on MLP

2 改进的学习资源推荐算法

针对在线学习过程中学习资源的推荐, 文中提出了改进 DN-CBR 模型的学习资源推荐算法, 改进后的模型称为 UDN-CBR 模型。算法沿用 DN-CBR 模型的优势, 结合学习者和学习资源的信息, 利用深度神经网络强大的特征提取能力, 充分地学习学习者与学习资源间的非线性关系。UDN-CBR 模型共分为四个阶段, 分别为获取学习者和学习资源的属性特征、卷积神经网络获取学习资源的文本特征、结合学习资源的属性特征和文本特征及 MLP 预测评分并生成推荐。模型框架如图 3 所示。

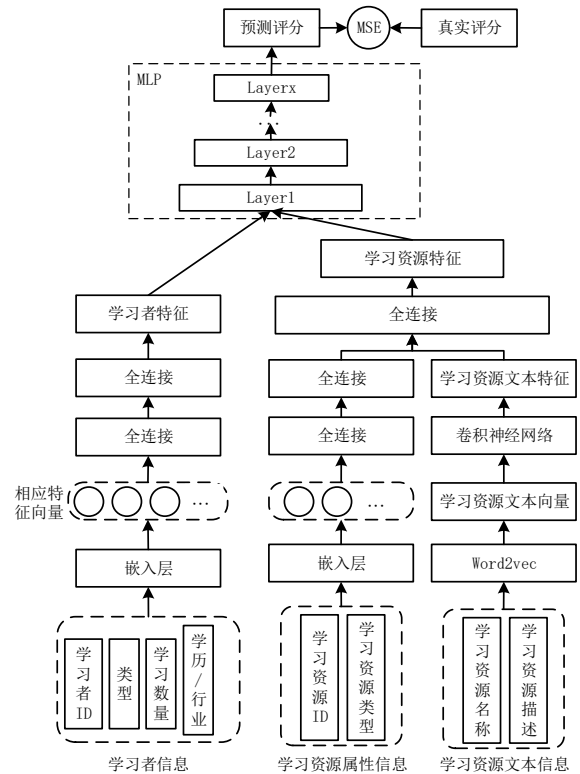


图 3 UDN-CBR 模型

Fig. 3 UDN-CBR model

2.1 获取学习者和学习资源的属性特征

如图 3 所示, 将学习者信息和学习资源属性信息输入到 UDN-CBR 模型中获取学习者和学习资源的属性特征。假设学习者的属性为 $x: \{x_1, x_2, \dots, x_m\}$, x_i 表示其中的一个学习者属性, 例如学习者 ID。学习资源的属性可表示为 $y: \{y_1, y_2, \dots, y_n\}$, y_i 表示其中的一个学习资源属性, 例如学习资源 ID。再将学习者和学习资源的属性输入到嵌入层, 得到学习者和学习资源属性特征向量 \bar{x} 、 \bar{y} , 其公式分别如式(1)(2)所示。

$$\bar{x} = f(w_1x + b_1) \quad (1)$$

$$\bar{y} = f(w_2y + b_2) \quad (2)$$

其中 w_1 和 w_2 表示权重, b_1 和 b_2 表示偏置, $f(\cdot)$ 表示激活函数。

再利用 $concatenate(\cdot)$ 函数将学习者的各个属性特征进行融合得到学习者特征 u_i :

$$u_i = concatenate(\bar{x}) \quad (3)$$

同理得到学习资源的属性特征 s_j :

$$s_j = concatenate(\bar{y}) \quad (4)$$

2.2 卷积神经网络获取学习资源的文本特征

UDN-CBR 模型中的卷积神经网络主要用于从学习资源

文本信息中获取学习资源的文本特征。学习资源文本信息首先经过 word2vec^[10]表示成学习资源文本向量形式,再输入到卷积神经网络中提取特征。卷积神经网络模型的结构包含四层,分别为嵌入层、卷积层、池化层和全连接层^[11],示意图如图 4 所示。

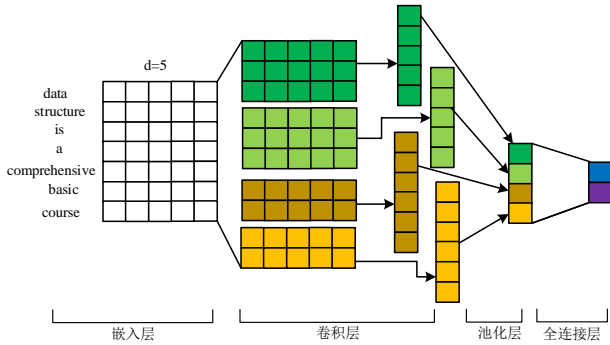


图 4 卷积神经网络模型

Fig. 4 Convolution neural network model

1) 嵌入层

嵌入层用于将学习资源的文本信息转换为嵌入矩阵,矩阵中的每一行为一个分词元素。如图 4 中嵌入层所示,假设一共有 7 个词,每个词都用 5 维向量来表示,那么就可以得到一个 7*5 维的矩阵,这个矩阵就相当于了一幅“图像”,供卷积层进行卷积操作。学习资源的文本矩阵 $D \in R^{n \times m}$ 可表示为

$$\begin{bmatrix} w_{11} & \cdots & w_{1i} & \cdots & w_{1m} \\ w_{21} & \cdots & w_{2i} & \cdots & w_{2m} \\ \vdots & & \vdots & & \vdots \\ w_{n1} & \cdots & w_{ni} & \cdots & w_{nm} \end{bmatrix} \quad (5)$$

其中, m 代表嵌入的维度, n 代表单词的数量, $w_{[i],[m]}$ 代表第 i 个单词的向量形式。

2) 卷积层

卷积层使用多个不同尺寸(窗口大小)的卷积核在嵌入矩阵上做卷积,窗口大小指的是每次卷积覆盖几个单词^[12]。区别于对图像做卷积,图像的卷积核通常采用 3*3、5*5 之类的尺寸,对尺寸大小没有限定,而文本卷积要覆盖整个单词的嵌入向量,所以尺寸大小的格式为:单词数*向量维度。如图 4 中卷积层所示,采用 4 个不同大小的卷积核(2 个 3*5, 2 个 2*5)分别对 7*5 的嵌入矩阵进行卷积操作,尺寸大小为 3*5 的卷积核每次滑动 3 个单词,尺寸大小为 2*5 的卷积核每次滑动 2 个单词,最终形成 4 个不同的特征图。由此可见特征图与卷积核存在一一对应的关系。特征图的计算公式如下:

$$m_i = f(D * F_i + b_i) \quad (6)$$

其中, $*$ 表示卷积计算, b_i 表示偏置项, $f(\cdot)$ 是一个非线性的激活函数,可在模型中引入非线性因素,解决线性模型难以表示的特征向量,本模型中使用 ReLU 函数。

3) 池化层

池化层主要用于卷积层之后,通过下采样操作降低特征图维度,减小网络参数量。常用的池化操作包含均值池化和最大值池化两种。池化操作可以忽略特征图中的微小变化,提高精度,同时可以有效地避免过拟合现象^[13]。假设在第 t 个卷积层中得到的特征图为 $M_t = \{m_1, m_2, \dots, m_s\}$,采用最大池化,提取 M_t 中的最大值, p_t 表示第 t 个卷积层的池化结果,形式化表达为

$$p_t = \max(M_t) = \max\{m_1, m_2, \dots, m_s\} \quad (7)$$

4) 全连接层

通常情况下网络会在池化层后设置全连接层,全连接层的主要作用是将前面所提取的特征值进行综合,输出固定大小的特征向量^[14]。假设全连接层有 m 个神经元,经 ReLU 激活函数后,得到固定大小的向量 s ,即为学习资源的文本特

征向量。计算公式如下:

$$s = \text{ReLU}(w_t p_t + b_t) \quad (8)$$

其中, p_t 表示学习资源文本信息在池化层上的输出, w_t 表示权重, b_t 表示对应的偏置。通过以上描述, CNN 模型构成一个函数,输入数据为学习资源的文本信息,输出结果为每个文本信息的特征向量。

$$t_j = \text{cnn}(W, Y_j) \quad (9)$$

其中, W 表示所有的权重和偏置变量, Y_j 表示学习资源 j 的原始文本信息, t_j 表示学习资源 j 的文本特征向量。

2.3 结合学习资源的属性特征和文本特征

由 2.1 节中的式(4)可知学习资源 j 的属性特征为 s_j , 由 2.2 节中的式(9)可知学习资源 j 的文本特征为 t_j , 故学习资源 j 的特征 v_j 可表示为

$$v_j = s_j + t_j \quad (10)$$

2.4 MLP 预测评分并生成推荐

由 2.1 节中的式(3)得到的学习者特征 u_i 和 2.3 节中的式(10)得到的学习资源特征 v_j , 通过输入多层感知机来预测评分。多层感知机的输入层的输入向量 x_0 是将学习者和学习资源的特征进行融合,其计算公式见式(11)。

$$x_0 = \text{concatenate}(u_i, v_j) \quad (11)$$

其中, $\text{concatenate}(\cdot)$ 函数用于将学习者和学习资源的特征进行串联, x_0 经过第一层的输出值表示为

$$x_1 = f(W_1 x_0 + b_1) \quad (12)$$

其中, W_1 表示输出层与第一个隐藏层间的权重矩阵, b_1 表示偏置向量, $f(\cdot)$ 表示激活函数。最终的输出层计算公式为

$$x_f = f(W_f x_{f-1} + b_f) \quad (13)$$

该模型的预测评分即为

$$\hat{y} = x_f \quad (14)$$

最后根据 UDN-CBR 模型提供的预测评分,为学习者进行推荐,生成推荐列表。

3 实验

3.1 实验环境及数据集

实验在 64 位 Windows 7 系统上的 PyCharm 集成开发环境中展开,使用 Python 语言和 tensorflow 深度学习框架实现。其中 Python 的版本是 3.6.3, tensorflow 的版本是 1.8.0。计算机的 CPU 是频率为 3.60 GHz 的 Intel Core i7-7700,内存为 8 GB。

实验采用的数据来自爱课程在线学习平台,通过收集整理,最终形成 500 个学习者、700 个学习资源及 35000 条评分记录的数据集。该数据集包含三个文档,分别为 resource.dat、learner.dat 和 ratings.dat。部分数据如下图 5 所示。其中 resource.dat 表示学习资源信息,包含学习资源 id、名称、类别、描述信息; learner.dat 表示学习者信息,包含有学习者 id、类型、学历/行业和学习数量; ratings.dat 表示评分信息,记录学习者对学习资源的打分情况,具体包含学习者 id、学习资源 id 和评分值,用于在模型中衡量预测评分与真实评分之间的误差。

由于收集的数据既有结构化的数据又有非结构化的数据,因此,需要对数据进行预处理。首先,将数据进行分类,不同的分类选择不同的处理方式。将学习者 id、学习资源 id、学习数量和评分值归为一类,不需要处理,可直接使用;由于学习者的类型、学历/行业及学习资源的类别均为分类信息,故归为一类,需要将各字段的值数字化;由于学习资源的名称和描述信息均为文本信息,不可量化,故归为一类,需进行文本向量化的表示。例如学历/行业字段,当学习者类型为学时,该字段表示学习者的学历,共有博士、研究生、本科等 7 个分类;当学习者类型为在职时,该字段表示学习者

所在的行业, 共有互联网、教育、电信通信等 28 个分类。通过给每一个分类标号, 即可将该字段数值化。最终将学历/行业字段转换成 35 个连续的数字 1~35。

```
resource.dat
1 1::数据库原理与应用::计算机::数据库课程是高等学校计算机科学与技术专业中的核心课程
2 2::数据库系统概论::计算机|数据库原理与应用::了解数据库管理技术的发展; 掌握数据库的
3 3::数据模型::计算机|数据库原理与应用::理解概念模型的概念; 掌握数据模型的组成要素
4 4::关系数据库标准查询语言SQL::计算机|数据库原理与应用::理解关系数据库模型的组成要素及相关概念;
5 5::关系数据库规范化设计::计算机|数据库原理与应用::掌握SQL的数据定义、查询、
6 6::关系模式的规范化设计::计算机|数据库原理与应用::掌握函数依赖和范式的概念; 了解
7 7::数据库设计::计算机|数据库原理与应用::了解数据库设计步骤; 掌握用E-R模型进行概念
8 8::人工智能导论一面向人文社科专业::计算机::课程以专题形式介绍知识表示、知识图谱、
9 9::知识表示::计算机|人工智能导论::介绍利用计算机表示知识的经典方法。在人工智能研
10 10::自动推理与专家系统::计算机|人工智能导论::利用第二章中的知识表示方法, 实现自
11 11::知识图谱::计算机|人工智能导论::介绍知识图谱的概念、主要研究内容和方法, 发展
12 12::推荐系统::计算机|人工智能导论::推荐系统是建立在非穷举搜索知识表示基础上发展而来的
```

(a) 学习资源数据

```
learner.dat
1 1::学生::本科::10
2 2::在职::信息传媒::16
3 3::学生::本科::36
4 4::学生::研究生::7
5 5::在职::本科::44
6 6::在职::互联网::9
7 7::学生::研究生::25
```

(b) 学习者数据

```
ratings.dat
1 102::65::5
2 45::65::3
3 13::65::3
4 68::65::4
5 147::65::5
6 3::65::3
7 90::65::5
```

(c) 评分数据

图 5 实验数据

Fig. 5 Experimental data

3.2 实验设计与评估指标

根据第 2 节对 UDN-CBR 模型地阐述, 实现推荐需要 3 个阶段: 第一阶段为数据预处理、第二阶段为构建和训练深度神经网络、第三阶段为生成推荐列表。

a) 数据预处理。由于使用的数据并不都是数字形式, 例如学习者的类型、学习资源的类别。这些数据不能直接输入网络中, 需将其转换成向量表示。

b) 构建和训练网络模型。首先要构建深度神经网络, 在此基础上, 将上一步处理后的数据划分为训练集和测试集, 本实验中将 80% 的数据集作为训练集, 20% 的数据集作为测试集。通过训练集对网络进行有监督的训练, 不断地学习学习者和学习资源间的非线性关系。在训练过程中, 通过不断地调整 MLP 中隐含层的层数, 最终确定当层数为 3 时, UDN-CBR 模型的推荐效果最好, 同理, 对 UDN-CBR 模型中学习率、批处理大小、激活函数、推荐列表长度等参数进行了实验, 最终选取学习率为 0.0001, 批处理大小为 256, 激活函数为 ReLU, 推荐列表长度 N 为 10。

c) 生成推荐列表。借助训练好的模型进行评分预测, 再根据评分值的大小排序, 最终为学习者推荐前 top-N 个学习资源。

本实验主要完成两部分内容: 第一, 通过上面地描述, 实现 UDN-CBR 模型, 验证其有效性; 第二, 将 DN-CBR 模型与 UDN-CBR 模型做对比分析, 得出结论。

基于 top-N 推荐算法的评估指标有很多种, 包括 HR、NDCG、MAE、MSE、准确率和召回率等^[15]。在本实验中主要选取两个评价指标命中率(hit radio, HR)和归一化折损累积增益(normalize discount cumulative gain, NDCG)。

HR 的计算公式如下:

$$HR(N) = \frac{|p \in testset \ \& \ p \in R_N|}{|testset|} \quad (15)$$

其中 p 表示在测试集中的学习资源, $p \in testset \ \& \ p \in R_N$ 表示在测试集中的学习资源同时也在 top-N 推荐集合中, $testset$ 表示测试集数量。

NDCG 被广泛运用于推荐排序、信息索引排序的评估任务中, 它是对排序位置敏感的一种评估指标, 越相关的排序越前, 对应的 NDCG 就会越大^[16]。首先引入 DCG, 它的计算公式如下:

$$DCG_n = \sum_{i=1}^n \frac{2^{rel_i} - 1}{\log_2(i+1)} \quad (16)$$

其中, rel_i 是第 i 个学习资源和学习者的相关度。在本实验中,

若学习资源为正样本则相关度为 1, 负样本则相关度为 0。若把相关度越大的学习资源排在后面, 会造成整体的 DCG 变小。

每一个学习者的推荐排序都有一个理想值, 即按照相关度从大到小排序, 那是每个学习者能计算出的最小的 DCG, 称这个 DCG 值为 IDCG(ideal discounted cumulative gain)即理想的 DCG 值, 这样 NDCG 就可以通过如下的公式计算出来。

$$NDCG_n = \frac{DCG_n}{IDCG_n} \quad (17)$$

可以很清楚的看到 NDCG 是一个取值在 0 到 1 之间的值, 且越大说明推荐效果越好。

3.3 实验结果及分析


针对 UDN-CBR 模型, 训练的部分结果如下图 6 所示。实验使用 MAE 函数进行训练, 由图可知随着迭代次数的增加, MAE 的值逐渐下降, 直至 0.70。可见结合学习者属性、学习资源属性及内容描述信息的 UDN-CBR 模型数据更加完整、误差也趋于降低, 表明 UDN-CBR 模型具有一定的有效性。

```
1 av_net=av_network()
2 av_net.train(features, targets_values, epochs=5)
Step #30950 Epoch 4 Batch 2224/3125 Loss: 0.708168 mae: 0.711902 (26.49544044877016 steps/sec)
Step #30940 Epoch 4 Batch 2274/3125 Loss: 0.837604 mae: 0.712273 (26.41265004969173 steps/sec)
Step #30450 Epoch 4 Batch 2324/3125 Loss: 0.688541 mae: 0.721410 (26.17972495429803 steps/sec)
Step #30500 Epoch 4 Batch 2374/3125 Loss: 0.776363 mae: 0.712182 (26.241540313068793 steps/sec)
Step #30950 Epoch 4 Batch 2424/3125 Loss: 0.766122 mae: 0.712354 (26.91214778254048 steps/sec)
Step #30900 Epoch 4 Batch 2474/3125 Loss: 0.890379 mae: 0.706585 (25.19444934018303 steps/sec)
Step #30950 Epoch 4 Batch 2524/3125 Loss: 0.775105 mae: 0.717794 (26.443513209323886 steps/sec)
Step #30700 Epoch 4 Batch 2574/3125 Loss: 0.884859 mae: 0.717794 (26.004620724614533 steps/sec)
Step #30750 Epoch 4 Batch 2624/3125 Loss: 0.944593 mae: 0.715722 (26.23936347442548 steps/sec)
Step #30800 Epoch 4 Batch 2674/3125 Loss: 0.810874 mae: 0.713238 (26.401331941064946 steps/sec)
Step #30850 Epoch 4 Batch 2724/3125 Loss: 0.793636 mae: 0.703970 (26.11104470713855 steps/sec)
Step #30900 Epoch 4 Batch 2774/3125 Loss: 0.763319 mae: 0.712700 (26.108259881647682 steps/sec)
Step #30950 Epoch 4 Batch 2824/3125 Loss: 0.854299 mae: 0.719748 (26.85358414793342 steps/sec)
Step #31000 Epoch 4 Batch 2874/3125 Loss: 0.847386 mae: 0.705366 (26.32883829656205 steps/sec)
Step #31050 Epoch 4 Batch 2924/3125 Loss: 0.849436 mae: 0.711011 (23.70735999390323 steps/sec)
Step #31100 Epoch 4 Batch 2974/3125 Loss: 0.712368 mae: 0.712937 (24.40111078765484 steps/sec)
Step #31150 Epoch 4 Batch 3024/3125 Loss: 0.700126 mae: 0.704626 (26.271120673086134 steps/sec)
Step #31200 Epoch 4 Batch 3074/3125 Loss: 0.829763 mae: 0.704342 (26.289493389023704 steps/sec)
Step #31250 Epoch 4 Batch 3124/3125 Loss: 0.848849 mae: 0.709723 (26.45481474267177 steps/sec)
```


图 6 实验训练结果

Fig. 6 Experimental training results

针对相同的数据集, 分别用 UDN-CBR 模型和 DN-CBR 模型训练网络, 得到的结果如图 7 所示, 图 7(a)为 UDN-CBR 模型训练的结果, 图 7(b)为 DN-CBR 模型训练的结果。由实验训练结果与图 7 可得出, 经过 5 次的迭代, UDN-CBR 模型的 loss 稳定在 0.8 左右, DN-CBR 模型的 loss 稳定在 1.0 左右, 可见 UDN-CBR 模型相比 DN-CBR 模型能更好地拟合评分, 进行评分预测。



(a) UDN-CBR 模型




(b) DN-CBR 模型

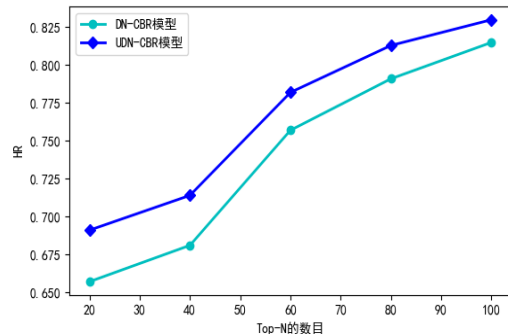
图 7 UDN-CBR 模型和 DN-CBR 模型的 loss 曲线图

Fig. 7 Loss graph of UDN-CBR model and DN-CBR model

为测试 top-N 数目对推荐效果的影响, 实验设置 N 的取值分别为 20、40、60、80、100。并分别从 NDCG 和 HR 两种指标上对 UDN-CBR 模型和 DN-CBR 模型进行分析。实验结果如图 8 所示。可见随着 top-N 数目的增加, 两种模型在 NDCG 和 HR 指标上均不断提高, 且 UDN-CBR 模型比 DN-CBR 模型在 NDCG 指标上平均高出 1.2%, 在 HR 指标上平均高出 3%。这表明 UDN-CBR 模型比 DN-CBR 模型有更好地推荐效果。



(a) NDCG 指标



(b) HR 指标

图 8 不同指标下 UDN-CBR 模型和 DN-CBR 模型在 top-N 上的对比图

Fig. 8 Comparison of UDN-CBR model and

DN-CBR model on top-N under different indicators

4 结束语

通过将深度神经网络引入到推荐算法中, 充分结合学习者和学习资源的数据信息, 利用深度神经网络提取特征和组合特征的能力, 挖掘学习者和学习资源间的深层次关系, 并采用 MLP 改进 DN-CBR 模型中的评分预测方式, 将向量相乘的方式转换为输入多层感知机的方式。解决了在线学习过程中知识过载的问题, 缓解了传统推荐算法中存在的稀疏和冷启动问题。实验结果表明, 改进后的模型加快了运算速度并能更好地优化损失、拟合评分, 提升了推荐效果。

参考文献:

[1] 黄华升. 基于知识图谱的个性化学习资源推荐研究 [J]. 软件工程, 2018, 21 (10): 24-26. (Huang Huasheng. Research on personalized learning resources recommendation based on knowledge graph [J]. Software Engineering, 2018, 21 (10): 24-26.)

[2] 李嵩, 李书琴, 刘斌. 改进的协同过滤算法及其并行化实现 [J]. 计算机工程与设计, 2018, 39 (12): 3853-3859. (Li Song, Li Shuqin, Liu Bin. Improved collaborative filtering algorithm and its parallel implementation [J]. Computer Engineering and Design, 2018, 39 (12): 3853-3859.)

[3] Chughtai M W, Selamat A, Ghani I, *et al.* Retracted: e-learning recommender systems based on goal-based hybrid filtering [J]. International Journal of Distributed Sensor Networks, 2015, 2015 (6): 1-18.

[4] Ng Y K, Linn J. A personalized course recommendation system for college students [C]// Proc of the 8th International Conference on Information, Intelligence, Systems&Applications. Larnaca, Cyprus: IEEE, 2017.

[5] 张俊格. 支持个性化推荐的网络学习平台设计与实现 [D]. 陕西: 陕西师范大学, 2014. (Zhang Junge. Design and implementation of network learning platform supporting personalized recommendation [D]. Shaanxi: Shaanxi normal University, 2014.)

[6] 李同欢, 唐雁, 刘冰. 基于深度学习的多交互混合推荐模型 [J]. 计算机工程与应用, 2019, 55 (01): 135-141. (Li Tonghuan, Tang Yan, Liu Bing. Multi-interactive hybrid recommendation model based on deep learning [J]. Computer Engineering and applications, 2019, 55 (1): 135-141.)

[7] 马晓洋, 张溢. 基于标签卷积神经网络的文本推荐算法 [J]. 计算机系统应用, 2018, 27 (08): 132-137. (Ma Xiaoyang, Zhang Mi. Text recommendation algorithm based on label convolution neural network [J]. Computer system applications, 2018, 27 (8): 132 - 137.)

[8] 江原. 基于图卷积与神经协同过滤的融合信息推荐模型 [D]. 吉林: 吉林大学, 2018. (Jiang Yuan. Fusion information recommendation model based on graph convolution and neural collaborative filtering [D]. Jilin: Jilin University, 2018.)

[9] 张毅锋, 蒋程, 刘袁, 等. 基于基完备化理论和嵌入多层感知机的深度网络结构设计 [J]. 东南大学学报: 自然科学版, 2018, 48 (05): 933-938. (Zhang Yifeng, Jiang Cheng, Liu Yuan, *et al.* Deep network structure design based on base completion theory and embedded multi-layer perceptual machine [J]. Journal of Southeast University: natural Science Edition, 2018, 48 (05): 933-938.)

[10] 王飞, 谭新. 一种基于 Word2Vec 的训练效果优化策略研究 [J]. 计算机应用与软件, 2018, 35 (01): 97-102. (Wang Fei, Tan Xin. Research on an optimization strategy of training effect based on Word2Vec [J]. Computer applications and Software, 2018, 35 (01): 97-102.)

[11] Krizhevsky A, Sutskever I, Hinton G. ImageNet Classification with Deep Convolutional Neural Networks [J]. Advances in neural information processing systems, 2012, 25 (2): 1097-1105.

[12] Szegedy C, Liu Wei, Jia Yangqing, *et al.* Going deeper with convolutions [C]// Proc of IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 1-9.

[13] He K, Zhang X, Ren S, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2014, 37 (9): 1904-1916.

[14] 杨天祺, 黄双喜. 改进卷积神经网络在分类与推荐中的实例应用 [J]. 计算机应用研究, 2018, 35(4): 974-977, 1045. (Yang Tianqi, Huang Shuangxi. Application of improved convolution neural network in classification and recommendation [J]. Application Research of Computers, 2018, 35(4): 974-977, 1045.)

[15] Sun G, Cui T, Beydoun G, *et al.* Tow ards massive data and sparse data in adaptive micro open educational resource recommendation: a study on semantic knowledge base construction and cold start problem [J]. Sustainability, 2017, 9 (6): 1-21.

[16] Chen H. The study on interesting mining based on topic model for web educational resource recommendation [J]. Advances in Information Sciences & Service Sciences, 2012, 4 (2): 275-281.