

基于深度学习的电子商务个性化推荐模型

张泰恒, 谢本亮

贵州大学大数据与信息工程学院, 贵州 贵阳

收稿日期: 2024年3月26日; 录用日期: 2024年4月10日; 发布日期: 2024年5月31日

摘要

智能推荐是电子商务领域的一项重要任务。目前普遍使用关联规则、协同过滤、马尔可夫链、递归神经网络等技术进行购物篮推荐。本文主要研究基于深度学习的电子商务智能推荐系统(IRS)。本文首先进行了电子商务推荐系统的总体设计,提出了电子商务IRS的功能模块和系统架构。然后,讨论了电子商务IRS中的推荐算法,并基于卷积神经网络对电子商务IRS进行了优化。最后,本文比较分析了三种流行的推荐算法在阿里巴巴数据集上的性能。实验结果表明,本模型在不同推荐列表长度下的召回率和NDCG指标上均取得了更高的数值,均明显优于其他两种算法(Item和BPR),在挖掘用户会话序列中的兴趣和行为偏好方面具有很强的价值,能够从大规模数据中学习 to 更丰富和复杂的用户行为和商品信息,这有助于提高推荐的效率和准确性,具有较强的实际意义和推广价值。

关键词

深度学习, 卷积神经网络, 电子商务, 推荐系统

Personalized Recommendation Model of E-Commerce Based on Deep Learning

Taiheng Zhang, Benliang Xie

College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

Received: Mar. 26th, 2024; accepted: Apr. 10th, 2024; published: May 31st, 2024

Abstract

Intelligent recommendation is an important task in the field of electronic commerce. At present, association rules, collaborative filtering, Markov chain and recursive neural network are widely used to recommend shopping baskets. This paper mainly studies the e-commerce intelligent recommendation system (IRS) based on deep learning. In this paper, firstly, the overall design of

e-commerce recommendation system is carried out, and the functional modules and system architecture of e-commerce IRS are put forward. Then, the recommendation algorithm in e-commerce IRS is discussed, and the e-commerce IRS is optimized based on convolutional neural network. Finally, this paper compares and analyzes the performance of three popular recommendation algorithms on Alibaba data sets. The experimental results show that this model achieves higher recall and NDCG index under different recommended list lengths, which are obviously superior to the other two algorithms (Item and BPR). It is of great value in mining users' interests and behavior preferences in conversation sequences, and can learn richer and more complex information about users' behaviors and commodities from large-scale data, which is helpful to improve the efficiency and accuracy of recommendation, and has strong practical significance and promotion value.

Keywords

Deep Learning, Convolutional Neural Network, E-Commerce, Recommendation System

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着互联网技术的迅速发展和普及, 信息资源呈指数级增长。互联网的建设也迎来了电子商务的快速发展, 电子商务已经成为现代商业活动的主要形式之一。电子商务平台如亚马逊、阿里巴巴等巨头已经成为全球消费者进行购物的首选平台, 人们足不出户就可以浏览、挑选和购买各种商品[1] [2]。可以说, 电子商务已经完全融入了人们的生活, 成为生活中不可缺少的一部分。然而, 随着电子商务的迅猛发展, 电子商务数据呈指数级增长, 其增长规模远远超出了人们所能接受的范围。

这个问题被称为“信息过载”。电子商务平台中海量的店铺和商品信息给用户的浏览、选择和决策带来了巨大的挑战。针对日益严重的信息过载问题, 搜索引擎和推荐系统应运而生。搜索引擎更适合于人们需要的明确目的, 通过将人们的信息需求转化为关键词, 提交到后台进行搜索并返回结果信息。然而, 搜索引擎有马太效应的问题[3]。返回的结果容易受到其他用户使用条件的影响, 难以准确获取所需信息。而推荐系统更具个性化和主动性, 会通过个人使用历史向消费者推送更多感兴趣的信息[4] [5], 个性化推荐系统可以帮助用户更快速地找到符合其兴趣和需求的商品, 从而提高信息使用效率, 提升用户体验, 增加销售额。

2. 文献综述

用户喜欢有多种选择, 同时, 当选择的难度增加时, 选择的满意度会降低。也就是说, 为了增加用户对推荐系统服务的满意度, 需要通过推荐模型向用户推荐各种商品, 以拓宽用户的商品选择范围。在过去的几十年里, 出现了许多解决方案来缓解“信息过载”的问题。Yu 等[6]提出了一种概率矩阵分解模型, 该模型仅基于现有的用户 - 物品矩阵评分数据来预测未知物品的用户评分; Liu 等[7] [8] [9]提出了一种基于协同过滤的服装推荐算法, 并将视觉注意模型引入到服装图像中, 解决传统协同过滤算法中的冷启动问题。实验结果表明, 该算法在服装推荐领域的表现优于传统的协同过滤算法[10]。Vellaichamy 等[11] [12]提出的混合推荐方法是由不同类型的推荐方法组成的混合技术推荐。混合推荐是一种常见的基于内容的推荐与协同过滤推荐相结合形成的混合推荐算法, 在电子商务推荐中缺乏针对性, 难以满足用户

需求。Gururaj 等[13]基于知识的推荐算法是利用领域知识根据领域规则进行推理, 然后推荐最终的推理结果, 其核心在于领域规则的获取和知识库的构建。Belkhadir 等[14]通过概率矩阵分解提出了一种通过共享的用户潜在特征空间将社交网络与用户-物品评分矩阵连接起来的推荐算法, 并通过实验证明了该算法在用户评分很少或没有评分的情况下比流行的推荐算法效率更高。

在互联网海量数据的基础上, 将深度学习技术应用于电子商务推荐系统中, 不仅能够提升推荐系统的性能, 还能够推动推荐系统领域的研究和发展。深度学习模型在其他领域取得的成功经验和科技成果, 为推荐系统的创新提供了新的思路和方法。对电子商务 IRS 的深入研究, 相对于其他推荐系统, 在保证算法模型预测精度的前提下, 大大提高了算法模型计算的效率, 不仅对用户和应用提供商业意义重大, 而且对后续推荐系统的研究也有很大的帮助。

3. 基于深度学习算法的电子商务 IRS 设计

3.1. 推荐系统总体设计

推荐系统通常采用两种体系结构, 客户端-服务器和浏览器-服务器。互联网是未来的发展趋势, 通过浏览器进行网站推荐可以提高安全性和操作便利性。本文采用浏览器-服务器(B/S)架构, 可用于挖掘用户的历史行为信息和服务器后端数据库的数据信息, 通过深度协同过滤推荐算法进行分析和预测, 然后为用户推荐相关项目[15][16]。

推荐系统的浏览器-服务器架构见图 1 所示:

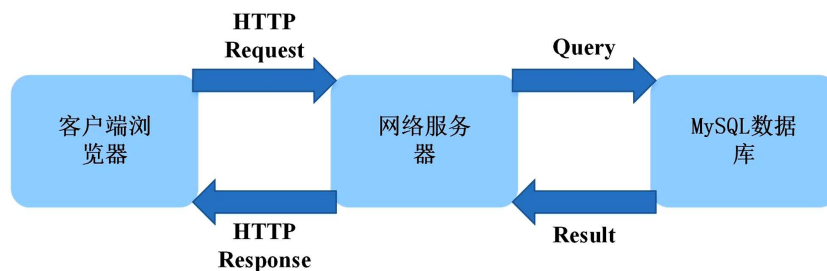


Figure 1. Overall design framework of recommendation system

图 1. 推荐系统总体设计框架

推荐用户通过客户端浏览器进行浏览, 系统自动根据用户注册并向服务器发送电子商务资源请求后, 通过 Web 服务器对浏览信息进行计算分析后进行数据库查询, 当从 MySQL 数据库查询到请求的电子商务资源时, 将结果返回给 Web 服务器, 经过计算分析提出了在服务器架构下的深度协同过滤推荐算法模型; 将从数据库中提取的电子商务信息由高到低进行排序, 并根据排序后的顺序进行相应的推荐, 通过客户端浏览器的推荐系统呈现给用户, 让用户选择自己更喜欢和需要的结果。

功能模块设计: 主要包括用户推荐界面、管理员操作界面、用户与商品特征信息数据库、推荐算法实现流程。特征信息主要分为三个部分: 用户信息、项目信息和浏览信息。数据特征信息主要由用户界面推荐和管理界面双拟合, 该模块主要是根据这些信息进行数据预处理, 预处理主要包括数据清洗、数据集成、数据转换和数据挖掘等步骤, 为了给推荐算法提供准确的数据输入, 数据预处理是关键步骤[17]。个性化推荐功能主要是针对每个用户, 找到彼此接近(即相似)的用户, 为他们推荐最喜欢的商品。这个功能主要是针对那些对商品的需求没有强烈的目的性, 或者徘徊在什么是更好的选择, 或者想知道大家最近在看什么等等。它可以通过深度协同过滤算法挖掘用户的兴趣和偏好, 并通过相应的推荐算法分析和预测用户喜欢的物品。推荐符合用户喜好的项目信息供用户选择[18][19]。

推荐系统架构设计：推荐系统架构主要由三部分组成：第一部分包括用户行为数据库、行为提取、行为特征转换和用户属性数据库。该部分负责从数据库或缓存中检索用户行为数据，生成当前用户的特征向量，并通过分析不同的行为输出。第二部分包括现有的相关数据表和与特征项相关的建议。该部分负责通过属性元素显示表将用户的属性向量转换为原始推荐列表。第三部分包括过滤、排名、推荐、解释和选择、用户行为反馈和项目属性。这个模块负责过滤和排序最初的推荐列表，以产生最终的组合。

3.2. 基于神经网络的电子商务推荐算法

(1) 卷积神经网络：它是深度学习中最成功的形式化算法之一，是一种人工神经网络。人工神经网络类似于生物神经网络，是由神经元连接起来的，每个神经元都可以进行计算[20]。网络后面的神经元从网络前面的神经元接收输入，执行计算并生成输出。在这样的计算之后，网络后面的神经元计算最后一层的结果。

CNN 主要包括以下结构：输入层(Input layer)：输入数据；卷积层(Convolution layer, CONV)：使用卷积核进行特征提取和特征映射；激活层：非线性映射(ReLU)池化层(Pooling layer, POOL)：进行下采样降维；光栅化(Rasterization)：展开像素，与全连接层全连接，某些情况下这一层可以省去；全连接层(Fully Connected layer, FC)：在尾部进行拟合，减少特征信息损失；激活层：非线性映射(ReLU)；输出层(Output layer)：输出结果[21] [22]。其中，卷积层、激活层和池化层可叠加重复使用。卷积神经网络的结构模式见图 2。

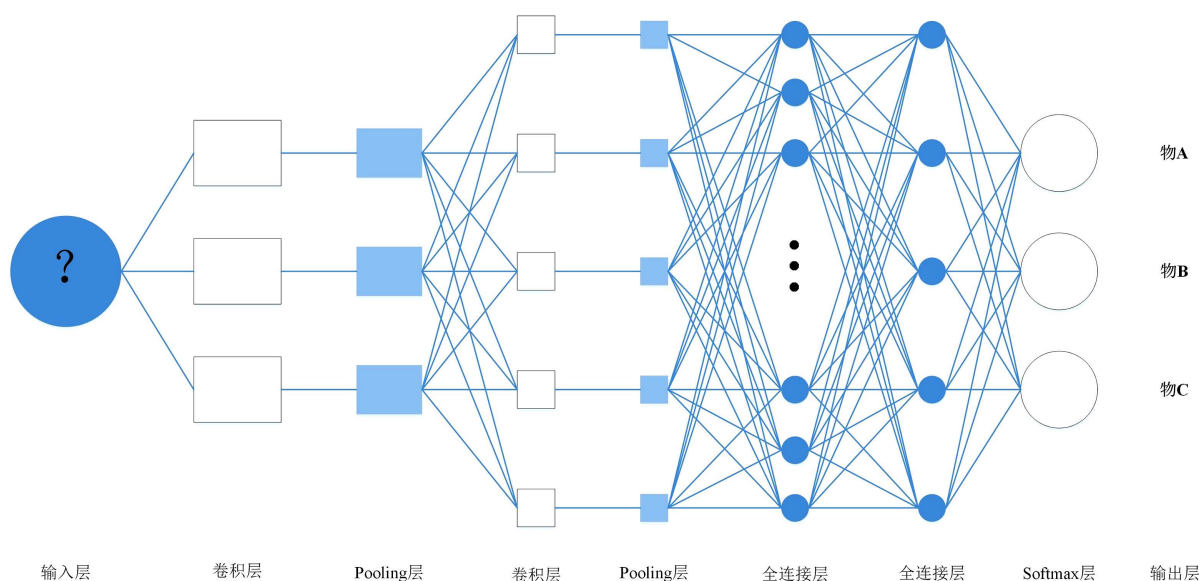


Figure 2. Structural mode of convolutional neural network

图 2. 卷积神经网络的结构模式

(2) 基于卷积神经网络的电子商务推荐算法：本文提出了一种基于卷积神经网络的电子商务推荐方法，该方法利用微调后的 VGG-19 网络加快了网络图像处理的计算速度[23]，并引入空间金字塔池化策略，在不影响识别精度的前提下灵活处理任意大小和尺度的图像问题。结合网络和空间金字塔池策略的优点，在网络之后引入空间金字塔池层。为了使网络更适合电商推荐，在原有网络架构的基础上进行了以下改进：经计算，两个全键合层的参数总数占有所有参数的 85%以上，严重影响了网络的整体运行速度。在神经混淆网络中，混淆层主要负责提取图像特征，全连接层主要负责将混淆层中的局部信息与类别区分相

结合, 对网络没有明显影响。因此, 两个完全键合层将被删除, 只留下最后一个完全键合层。此外, 减少全连接层的数量可以显著降低网络的一般参数, 节省更多的计算机时间和内存空间。

修改最后一个完整连接层的神经元。虽然原始网络的目标是 1000 类 ImageNet 数据集, 但本文推荐 12 类电子商务。因此, 最后一个完整连接层中的神经元数量被修改为 12。改进后的 VGG-19 网络见图 3。

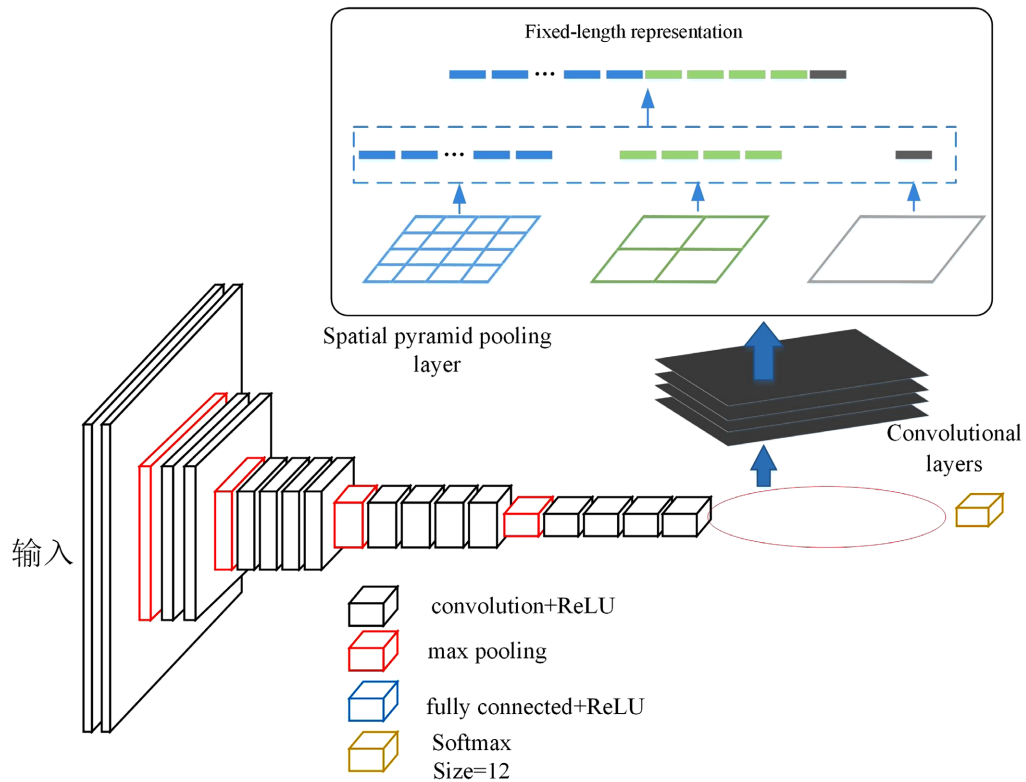


Figure 3. Improved VGG-19 network
图 3. 改进后的 VGG-19 网络

在 VGG-19 网络的最后一个卷积层和全连接层之间引入了空间金字塔池层。对输入图像不做固定大小的处理, 直接使用原始图像作为输入, 去除 VGG-19 网络的前两个完整连接层后, 引入空间金字塔池层, 将固定大小的输出作为连接层的输入, 将最后整个连接层的神经元数量改为 12 个, 得到基于卷积神经网络的推荐模型。整个网络的每个卷积层都使用相同的 6×6 卷积核(Conv3 表示卷积核的大小为 6×6 , Conv6 之后的数字表示卷积核的数量), 池层使用 Max Pooling 方法添加 8 个池层进行 8 级卷积特征提取。FC 代表全连接层, 整个网络结构非常对称。

4. 推荐算法实验比较

4.1. 实验环境与评价指标

本文在一台 Intel(R) Core(TM) i7-11700k CPU、RTX 3080 GPU、Ubuntu18.0 操作系统的计算机上进行实验。本文使用一个真实的数据集阿里巴巴数据集来测试模型的性能[24], 它记录了用户最近一个月的购物记录。每个用户还被划分到一个购物篮中, 用于在一天中添加到购物车或单独放置的每种商品。对数据集进行预处理, 过滤出购买次数少于 10 次的用户或购买次数少于 4 次的商品。

在实验中, 我们使用召回率、NDCG 和 MAE 指标来评价推荐效果[25]。召回率: 所有推荐产品被成

功推荐的百分比称为召回率, 定义如下:

$$Recall@L = \frac{|test \cap Top-L|}{|test|} \quad (1)$$

L 给出了算法的长度, 测试项目是正反馈测试集的用户列表, $|test|$ 表示测试集的大小, $|test \cap Top-L|$ 代表测试集, 建议测试集具有相同的项目集大小。

NDCG 排序评价指标: 归一化折损累计增益。这个指标通常是用来衡量和评价搜索结果算法。DCG 的两个思想: 高关联度的结果比一般关联度的结果更影响最终的指标得分; 高关联度的结果出现在更靠前的位置, 指标得分会更高。当用于推荐结果的评价时, 可以将项目的推荐评分值作为相关水平, 然后计算出 NDCG 的 value。NDCG 计算流程如下:

(1) 计算累计增益 CG, 即 cumulative gain, 是 DCG 的前身。只考虑了相关性的关联程度, 没有考虑到位置前后顺序的因素。所以是一个与搜索结果或分类结果相关分数的总和, 与排序无关。指定位置 p 上的 CG 为:

$$CG_p = \sum_{i=1}^p rel_i \quad (2)$$

其中 rel_i 代表 i 这个位置上的相关度。

(2) 计算折扣累计增益 DCG, 就是在每一个 CG 的结果上除以一个折损值 discounted。目的是为了排名越靠前的结果在最后结果得分上占的比重更大。假设排序越靠后, 对最终结果的影响价值就越低。

公式中定义, 到第 i 个位置时, 它的价值是 $\frac{1}{\log_2(i+1)}$, 那么第 i 个结果产生的效益就是 $\frac{rel_i}{\log_2(i+1)}$ 。所以:

$$DCG_p = \sum_{i=1}^p \frac{rel_i}{\log_2(i+1)} = rel_1 + \sum_{i=2}^p \frac{rel_i}{\log_2(i+1)} \quad (3)$$

(3) 计算归一折损累计增益 NDCG, 由于搜索结果随着检索词的不同, 返回的数量是不一致的, 而 DCG 是一个累加的值, 没法针对两个不同的搜索结果进行比较, 因此需要归一化处理, 这里是除以 IDC:

$$NDCG_p = \frac{DCG_p}{IDCG_p} \quad (4)$$

其中 IDC 为理想情况下最大的 DCG 值:

$$IDCG_p = \sum_{i=1}^{|REL|} \frac{2^{rel_i} - 1}{\log_2(i+1)} \quad (5)$$

其中 $|REL|$ 表示结果按照相关性从大到小的顺序排列, 取前 p 个结果组成的合集。也就是按照最优的方式对结果进行排序。

采用平均绝对偏差 MAE 衡量推荐准确率:

$$MAE = \frac{\sum_{i=1}^W |c_i - c_p|}{W} \quad (6)$$

在公式 6 中 c_p 表示第 i 项的预测评分; c_i 为第 i 项的实际评分, W 是数据集中的评级数。MAE 越小, 推荐准确率越高。

当用召回率和 NDCG 来评价推荐系统的性能时, 指标值越大, 说明推荐系统的推荐性能越好。

4.2. 实验对比结果

在本文的实验中, 将提出的算法与两种不同类型的推荐算法进行了比较: 物品协同过滤推荐算法、贝叶斯个性化排序(BPR)。图 4~7 比较了不同算法在同一个数据集上的性能。

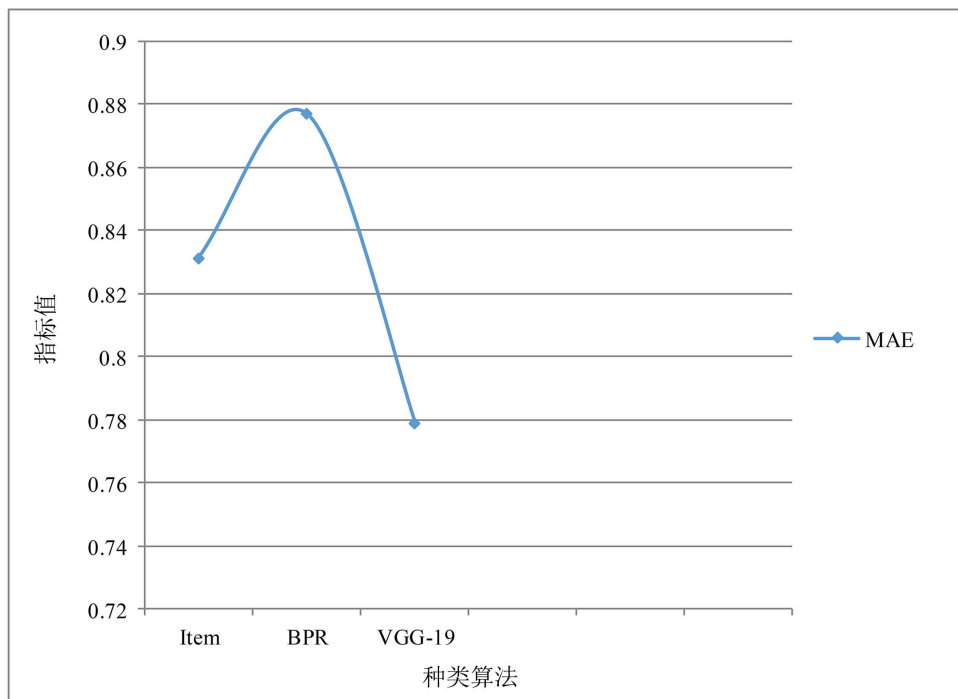


Figure 4. MAEs of different algorithms on dataset

图 4. 不同算法在数据集上的 MAE 值

由图 4 可知, Item method 和 BPR method 的 MAE 值均高于 0.8, 而本文算法的 MAE 值大幅度低于这两种类型的算法, 达到约 0.78。结果表明, 本算法在相同数据集上的推荐准确率高于其他两种类型的推荐算法。相比之下, 基于神经网络的推荐算法优于其他类型的算法。

Table 1. Experimental results of recall rate of three algorithms

表 1. 三种算法召回率实验结果

	Recall@10	Recall@20	Recall@30	Recall@40
Item	0.228	0.346	0.442	0.491
BPR	0.147	0.315	0.387	0.413
VGG-19	0.412	0.519	0.618	0.687

Table 2. Experimental results of three algorithms NDCG

表 2. 三种算法 NDCG 实验结果

	NDCG@10	NDCG@20	NDCG@30	NDCG@40
Item	0.487	0.554	0.622	0.686
BPR	0.415	0.509	0.573	0.623
VGG-19	0.529	0.614	0.695	0.763




Figure 5. Experimental results of Item

图 5. Item 的实验结果




Figure 6. Experimental results of BPR

图 6. BPR 的实验结果




Figure 7. Experimental results of VGG-19

图 7. VGG-19 的实验结果

如表 1、表 2 和三个折线图所示, 随着推荐列表长度 L 的增加, 三种推荐算法的召回率和归一折损累计增益都有一定程度的提高, 其中 BPR method 召回率较低, 在 Recall@10 到 Recall@20 之间增长较快, 然后增长速度趋于平缓, Item method 的召回率在不同的推荐列表长度下虽然稳步上升, 但仍然很低, 而本文提出的算法在 Recall@40 下能达到 0.6 以上; 三种算法归一折损累计增益都能随推荐列表的增加而平稳增加, 但明显本文提出的模型在归一折损累计增益的统计实验中表现更好。

从表中的实验结果对比可以看出, 在相同的硬件条件下, Item method 略优于 BPR method, 这可能是因为 Item method 在电子购物场景中更有效地检验商品的相似性, 改进后的 VGG-19 推荐网络模型相比于以上两种方法召回率都有大幅的提升。由此可见, 卷积神经网络模型对于挖掘用户会话序列中的兴趣和行为偏好是一种有价值的手段。

5. 总结

随着互联网应用的不断发展, 人们接触到的数据越来越多。然而, 面对大量的数据, 人们不知所措, 无法选择对自己真正有用的信息。推荐系统不仅要考虑电子商务网站中不同商品的搭配, 还要考虑用户的整体偏好。结果应以多样性、新颖性和准确性为推荐标准。本文提出了一种基于深度学习的电子商务个性化推荐算法, 通过在一个真实数据集上的实验, 证明了该算法在大小数据集上都优于其他类型的推荐算法。虽然与传统算法相比, 推荐结果有所提高, 但算法的准确率仍然有待提高。如何调整算法结构以进一步提高结果的准确性仍然是一个有待研究的问题, 在未来的研究中, 将更加注重提高推荐的准确性和多样性。

参考文献

- [1] Logesh, R., Subramaniaswamy, V., Vijayakumar, V., *et al.* (2019) Efficient User Profiling Based Intelligent Travel

- Recommender System for Individual and Group of Users. *Mobile Networks & Applications*, **24**, 1018-1033. <https://doi.org/10.1007/s11036-018-1059-2>
- [2] Taneja, A. and Arora, A. (2018) Cross Domain Recommendation Using Multidimensional Tensor Factorization. *Expert Systems with Applications*, **92**, 304-316. <https://doi.org/10.1016/j.eswa.2017.09.042>
 - [3] Peng, M.J., Liu, X.L., Luo, X.M., et al. (2017) Recognizing Intentions of E-Commerce Consumers Based on Ant Colony Optimization Simulation. *Journal of Intelligent & Fuzzy Systems*, **33**, 2687-2697. <https://doi.org/10.3233/JIFS-169318>
 - [4] Zhang, M. AND Liu, Y. (2021) A Commentary of TikTok Recommendation Algorithms in MIT Technology Review 2021. *Fundamental Research*, **1**, 846-847. <https://doi.org/10.1016/j.fmre.2021.11.015>
 - [5] Shen, X. AND Sun, Y. (2023) A Recommendation Algorithm Incorporating Moth-Flame Optimization Algorithm and Fuzzy Clustering. 2023 *IEEE 3rd International Conference on Power, Electronics and Computer Applications (ICPECA)*, Shenyang, 29-31 January 2023, 677-683. <https://doi.org/10.1109/ICPECA56706.2023.10075973>
 - [6] Yu, H., Dou, L. AND Zhang, F. (2015) A Novel Collaborative Recommendation Algorithm Integrating Probabilistic Matrix Factorization and Neighbor Model. *Journal of Information & Computational Science*, **12**, 2011-2019. <https://doi.org/10.12733/jics20105604>
 - [7] Liu, K.H., Chuang, H.L. AND Liu, T.J. (2022) Clothing Recommendation Based on Deep Learning. 2022 *IEEE International Conference on Consumer Electronics-Taiwan*, Taipei, 6-8 July 2022, 281-282. <https://doi.org/10.1109/ICCE-Taiwan53306.2022.9869006>
 - [8] Xhaferra, E., Cina, E. AND Toti, L. (2022) Classification of Standard Fashion MNIST Dataset Using Deep Learning Based CNN Algorithms. 2022 *International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, 20-22 October 2022, 494-498. <https://doi.org/10.1109/ISMSIT56059.2022.9932737>
 - [9] Hu, Z, H., Li, X., Wei, C., et al. (2019) Examining Collaborative Filtering Algorithms for Clothing Recommendation in E-Commerce. *Textile Research Journal*, **89**, 2821-2835. <https://doi.org/10.1177/0040517518801200>
 - [10] Bhoi, A., Nayak, R.P., Bhoi, S.K., et al. (2021) IoT-IIRS: Internet of Things Based Intelligent-Irrigation Recommendation System Using Machine Learning Approach for Efficient Water Usage. *PeerJ Computer Science*, **7**, e578. <https://doi.org/10.7717/peerj-cs.578>
 - [11] Vellaichamy, V. and Kalimuthu, V. (2017) Hybrid Collaborative Movie Recommender System Using Clustering and Bat Optimization. *International Journal of Intelligent Engineering & Systems*, **10**, 38-47. <https://doi.org/10.22266/ijies2017.1031.05>
 - [12] Liu, Y. and Zhang, Q.X. (2022) Research on E-Commerce User Interest Recommendation Method Based on TF-IDF Algorithm. 2022 *2nd Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)*, Shenyang, 25-27 February 2022, 291-295. <https://doi.org/10.1109/ACCTCS53867.2022.00066>
 - [13] Gururaj, P. (2021) Artificial Intelligence-Application in the Field of E-Commerce. *International Journal of Research-GRANTHAALAYAH*, **9**, 170-177. <https://doi.org/10.29121/granthaalayah.v9.i4.2021.3849>
 - [14] Belkhadir, I., Omar, E.D. and Boumhidi, J. (2019) An Intelligent Recommender System Using Social Trust Path for Recommendations in Web-Based Social Networks. *Procedia Computer Science*, **148**, 181-190. <https://doi.org/10.1016/j.procs.2019.01.035>
 - [15] Yadav, V., Shukla, R., Tripathi, A., et al. (2021) A New Approach for Movie Recommender System Using K-Means Clustering and PCA. *Journal of Scientific & Industrial Research*, **80**, 159-165. <https://doi.org/10.56042/jsir.v80i02.40102>
 - [16] Ko, H., Lee, S., Park, Y., et al. (2022) A Survey of Recommendation Systems: Recommendation Models, Techniques, and Application Fields. *Electronics*, **11**, Article 141. <https://doi.org/10.3390/electronics11010141>
 - [17] Thejaswini, N. and Aditya, C.R. (2019) Smart E-Commerce Recommendation System for Handling Limited Resource and Cold Start Problem. *International Journal of Computer Sciences and Engineering*, **7**, 961-964. <https://doi.org/10.26438/ijcse/v7i5.961964>
 - [18] Wadhvani, K. and Jain, V. (2023) Multichannel Consumer Service Integration of Recommendation Systems. In: Sheth, J.N., Jain, V., Mogaji, E. and Ambika, A., Eds., *Customer Centric Support Services in the Digital Age*, Palgrave Macmillan, Cham, 101-129. https://doi.org/10.1007/978-3-031-37097-7_6
 - [19] Wu, W. and Xu, Y. (2022) Information Personalized Recommendation Algorithm of Cross-Border E-Commerce Shopping Guide Platform Based on Multi-Objective Optimization. 2022 *Euro-Asia Conference on Frontiers of Computer Science and Information Technology (FCSIT)*, Beijing, 16-18 December 2022, 198-200. <https://doi.org/10.1109/FCSIT57414.2022.00048>
 - [20] Mi, J.X., Feng, J. and Huang, K.Y. (2022) Designing Efficient Convolutional Neural Network Structure: A Survey. *Neurocomputing*, **489**, 139-156. <https://doi.org/10.1016/j.neucom.2021.08.158>

- [21] Namatēvs, I. (2017) Deep Convolutional Neural Networks: Structure, Feature Extraction and Training. *Information Technology and Management Science*, **20**, 40-47. <https://doi.org/10.1515/itms-2017-0007>
- [22] Li, Z., Liu, F., Yang, W., *et al.* (2021) A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, **33**, 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- [23] Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv: 1409.1556,.
- [24] Zhu, Q., Zhang, S. and Sun, Y. (2022) Recommendation Algorithm Research Based on MPA. 2022 *2nd Asia Conference on Information Engineering (ACIE)*, Haikou, 15-17 January 2022, 24-29. <https://doi.org/10.1109/ACIE55485.2022.00013>
- [25] Balakrishnan, S. and Chopra, S. (2012) Collaborative Ranking. *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining*, Seattle, 8-12 February 2012, 143-152. <https://doi.org/10.1145/2124295.2124314>