

Review of Classical Recommendation Algorithms

Chunhua Zhou, Jianjing Shen, Yan Li, Xiaofeng Guo

Information Engineering University, Zhengzhou Henan
Email: zchgb@126.com

Received: Sep. 3rd, 2019; accepted: Sep. 18th, 2019; published: Sep. 25th, 2019

Abstract

Recommender systems are effective tools of information filtering that are prevalent due to continuous popularization of the Internet, personalization trends, and changing habits of computer users. Although existing recommender systems are successful in producing decent recommendations, they still suffer from challenges such as cold-start, data sparsity, and user interest drift. This paper summarizes the research status of recommendation system, presents an overview of the field of recommender systems, describes the classical recommendation methods that are usually classified into the following three main categories: content-based, collaborative and hybrid recommendation algorithms, and prospects future research directions.

Keywords

Recommender Systems, Cold-Start, Data Sparsity, Collaborative Filtering

经典推荐算法研究综述

周春华, 沈建京, 李艳, 郭晓峰

信息工程大学, 河南 郑州
Email: zchgb@126.com

收稿日期: 2019年9月3日; 录用日期: 2019年9月18日; 发布日期: 2019年9月25日

摘要

推荐系统作为一种有效的信息过滤工具,由于互联网的不断普及、个性化趋势和计算机用户习惯的改变,将变得更加流行。尽管现有的推荐系统也能成功地进行推荐,但它们仍然面临着冷启动、数据稀疏性和用户兴趣漂移等问题的挑战。本文概述了推荐系统的研究现状,对推荐算法进行了分类,介绍了几种经

经典的推荐算法，主要包括：基于内容的推荐算法、协同过滤推荐算法和混合推荐算法，并对推荐系统未来的研究趋势进行了展望。

关键词

推荐系统，冷启动，数据稀疏，协同过滤

Copyright © 2019 by author(s) and Hans Publishers Inc.

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

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



Open Access

1. 引言

随着信息技术迅速发展和在线服务的普及，人们能够快速获取大量信息，这也使得人们从信息匮乏的时代跨进了“信息过载”的时代。数据的“爆炸式”增长，为人类记忆和处理信息的能力带来了极大的挑战，大量冗余信息严重干扰对有用信息的提取和利用，增加信息处理的成本。个性化和智能化的代理、搜索引擎和推荐系统是被大家广泛使用的克服信息过载的主要工具或技术[1]。然而，与返回与用户查询匹配的相关结果的搜索引擎或检索系统不同，推荐系统根据用户的需求和偏好提供个性化的推荐。

推荐系统通过分析用户的特点、项目(被推荐物品或服务的统称)的特征、用户的历史行为、以及其他一些辅助信息，主动为用户推荐满足他们兴趣和需求的项目，属于主动式提供服务[2]。推荐系统不仅可以根据用户的偏好推荐与用户偏好相似的项目，甚至可以在没有用户偏好的情况下，帮助用户发现他们感兴趣的新内容。推荐系统作为解决信息过载的有效方法，已成为学术界和工业界的关注热点，并在很多领域发挥着重要作用，如：电子商务、电影和视频、音乐、社交网络、阅读、广告、基于位置的服务、新闻和个性化邮件等。

在推荐系统中，典型的推荐问题主要有两种：评分预测和 Top-N 推荐。评分预测一直是推荐系统研究的热点，是指根据用户对项目的历史评分，学习用户的兴趣模型，预测用户对未评分项目的打分；而 Top-N 推荐通常更符合实际的应用需求，是指提供用户可能喜欢的前 N 个项目的有序列表。基于以上推荐问题，学术界和工业界提出了很多推荐理论和技术。经典的推荐算法主要分为三类：基于内容的推荐算法、协同过滤推荐算法和混合推荐算法[3]。

2. 推荐系统存在的问题

目前，很多推荐系统中都综合集成了各种的推荐方法和技术，虽然能提升推荐效果，但仍然面临着很多挑战，其中，冷启动问题、数据稀疏问题和用户兴趣漂移问题是推荐系统面临的三大难题。冷启动问题是指针对新用户、新项目或新系统没有历史评分数据的推荐问题；数据稀疏问题是指在海量的用户和项目信息中评价数据集的稀疏问题；用户兴趣漂移问题是指用户的兴趣随着时间、地点甚至是人物的变化而变化，如何建模用户的兴趣问题也是推荐系统面临的一大难题。

2.1. 冷启动问题

推荐系统需要根据用户的历史行为和兴趣预测用户未来的行为和兴趣，因此大量的用户行为数据就成为推荐系统的重要组成部分和先决条件。当推荐系统积累数据量过少时，如何设计个性化推荐系统且让用户对推荐结果满意从而愿意使用推荐系统，就是冷启动问题，这也是推荐系统面临的一大难题。

冷启动主要分为三类：

- (1) 用户冷启动：如何给新用户做个性化推荐的问题，新用户刚使用网站的时候，系统并没有他的行为数据。
- (2) 项目冷启动：解决如何将新的项目推荐给可能对它感兴趣的用户。
- (3) 系统冷启动：如何在新开发网站设计个性化推荐系统，此时网站上用户很少，用户行为也少，只有一些商品的信息。

2.2. 数据稀疏问题

现在推荐系统处理的数据规模越来越大，用户和物品数目动辄百千万计，用户项目评分矩阵是高维稀疏的，且两个用户之间选择的重叠也会非常少，则传统的基于相似度计算的算法和基于关联分析的算法效果都不会太好。因此评价数据集的稀疏度非常必要。如果以用户 - 项目评分矩阵中已评分数占评分总量的比例来衡量系统的稀疏性，稀疏度越小，传统算法的精度越低。

比如，目前最大规模的电子商务平台淘宝网，其用户和商品数量都非常庞大。截至 2014 年底，淘宝网拥有注册用户近 5 亿，日活跃用户超 1.2 亿，在线商品数量达到 10 亿，假如要用基于用户 - 项目评分矩阵的协同过滤算法，那么用户 - 项目评分矩阵的大小是 $1.2 \text{ 亿} \times 10 \text{ 亿}$ 。而平均每个用户的商品浏览数量可能不超过 20，那么在用户 - 项目评分矩阵中，只有 $1.2 \text{ 亿} \times 20$ 的输入是有值的，稀疏的度达到 $20/10 \text{ 亿} = 2.0 \times 10^{-8}$ ，远远小于百万分之一。在这个规模下，任意两个用户的浏览的商品交集都非常非常小，计算得到的相似度往往近似为 0，那么传统的基于相似度计算的过滤算法将得不到理想的效果。因此，数据稀疏性问题也是过滤算法面临的一大挑战，一般来说，数据规模越大，数据稀疏性会越大，而能够处理稀疏数据的算法将会有更好的应用。

2.3. 用户兴趣漂移问题

随着时间的推移，用户的工作生活会不断变化，用户的兴趣爱好也会发生改变，将导致推荐的准确度逐渐下降，这就是用户兴趣漂移问题，这一问题给推荐系统同样带来了很大的挑战。在信息过载和快速迭代的时代，能够有效地识别出用户所发生的兴趣变化对于推荐系统来说非常重要，而未考虑兴趣漂移的推荐系统将会逐渐失去竞争力。

引起用户兴趣变化的主要原因：(1) 随着科学技术的进步和信息量的不断增长，用户会接触到新的领域信息，兴趣可能会变化到不同的领域。(2) 用户由于年龄增长或受到实际生活中不同情况的影响，用户的自身原有的兴趣和关注点会发生改变。(3) 用户兴趣受新闻事件或项目流行度的影响，会随时间、节日和人物的变化而变化。

3. 推荐算法分类

根据推荐方式的不同，传统的推荐算法主要分为三类：基于内容的推荐算法(Content-Based, CB)、协同过滤推荐算法(Collaborative Filtering, CF)和混合推荐算法。其中，协同过滤算法又可分为基于记忆的协同过滤算法(memory-based)和基于模型的协同过滤算法(model-based)。基于记忆的协同过滤算法包括基于用户的协同过滤算法(User-based Collaborative Filtering, UserCF) [4] 和基于项目的协同过滤算法(Item-based Collaborative Filtering, ItemCF) [5] [6] [7]；基于模型的协同过滤算法包括基于聚类模型的(Clustering Model, CM) [8] [9]、基于贝叶斯模型的(Bayesian Model, BM) [10]、基于概率模型的(Probabilistic Model, PM) [11] [12]、基于最大熵模型的(Maximum Entropy Model, MEM) [13] 和基于矩阵分解的(Matrix Factorization, MF) [14] [15] 等协同过滤算法。混合推荐技术主要分为：加权型(Weighted)、切换型(Switching)、

交叉型(Mixed)、特征组合型(Feature combination)、瀑布型(Cascade)、特征增强型(Feature augmentation)、元层次型(Meta-level) [16]。除了这些经典的推荐算法，还有一些特定的推荐技术，包括基于知识的(Knowledge-Based, KB) [17] [18] [19] [20] [21]、基于上下文感知的(Context-Aware, CA) [22] [23] [24] [25]、基于信任感知的(Trust-Aware, TA) [26] [27]、基于模糊的(Fuzzy-Based, FB) [28]、基于社交网络的(Social network-Based, SB) [29]、基于群组的(Group-Based, GB) [30] [31]和基于深度学习的技术(Deep Learning-Based, DLB) [32] [33] [34] [35]等推荐每种方法都有其优点和局限性。推荐算法的具体分类如图 1 所示。

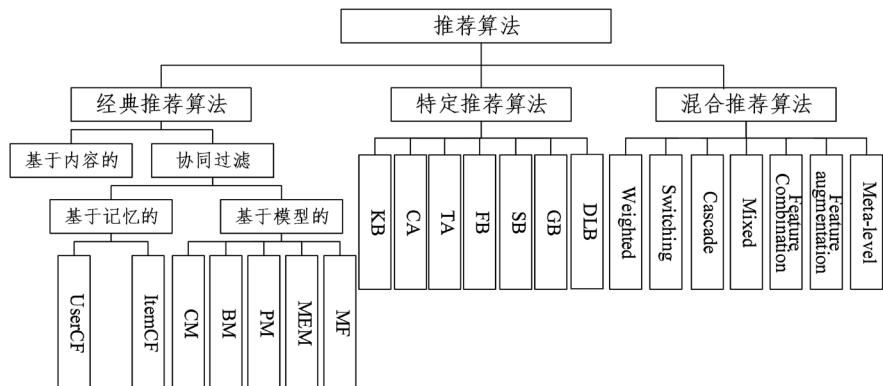


Figure 1. The classification of recommendation algorithms

图 1. 推荐算法分类

4. 经典推荐算法

4.1. 基于内容的推荐算法

基于内容的推荐算法充分利用用户的个人资料和项目的特征来生成推荐项，向目标用户推荐与其过去喜欢的内容特征相似的项目[36]。比如，用户经常阅读包含“推荐”、“协同过滤”和“偏好”关键词的文章，基于内容的推荐系统就会推荐与推荐系统有关的文章。

基于内容推荐算法的步骤主要有三步：第一步：项目表示。提取项目内容特征来表示项目；第二步：学习用户偏好模型。利用用户过去喜欢(及不喜欢)的项目特征数据，学习用户的偏好模型；第三步：产生推荐列表。通过比较用户偏好模型与候选项目的特征，为用户推荐一组相似度最大的项目。具体过程如图 2 所示。基于内容推荐的关键就是计算项目内容特征向量之间的相似度，相似度计算的主要通过向量的余弦相似度来表示[37]。

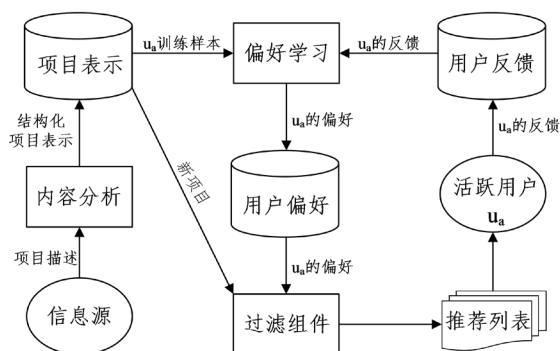


Figure 2. The architecture of content-based recommendation algorithm

图 2. 基于内容的推荐算法架构

基于内容的推荐又可以分为基于案例的推理技术和基于属性的技术[3]。基于案例的推理技术会推荐与用户之前喜欢的项目相关度最高的项目，而基于属性的技术是推荐与用户个人资料属性匹配的项目。

基于内容的推荐系统的主要优点是用户独立性、可解释性，以及可解决项目冷启动问题。然而，随着个人隐私问题越来越受到互联网用户的关注，基于内容的推荐方法收集用户档案变得越来越困难，同时这种方法需要有效的特征提取，传统的浅层模型依赖于人工设计特征，其有效性及可扩展性非常有限，制约了基于内容的推荐方法的性能。由于只依赖于用户过去对某些项目的喜好，所以无法挖掘出用户的潜在兴趣，又新用户没有喜好历史，它还面临着新用户冷启动问题。

4.2. 协同过滤推荐算法

协同过滤推荐算法是推荐系统中最流行的推荐算法，它充分利用用户的历史行为数据来生成推荐项，协同过滤是建立在这样的假设基础上的，如果用户 X 和 Y 对 t 个项目进行相似的评分，或者有相似的行为(例如购买、观看、聆听)，那么用户就会对其他项目进行类似的评分或行为[38]。

通常，基于 CF 推荐系统包含 m 个用户的列表 $U = \{u_1, u_2, \dots, u_m\}$ 和 n 个项目列表 $P = \{p_1, p_2, \dots, p_n\}$ 。系统构造一个 $m \times n$ 的用户 - 项目矩阵，其中包含用户对项目的评分，其中每个元素值 r_{ij} 表示用户 u_i 对项目 p_j 给出的评分。CF 算法要么预测目标用户 a 对某个未评分项目 q 的评分，要么向用户 a 推荐其最喜欢的 Top-N 项目列表。CF 算法的一般过程如图 3 所示。

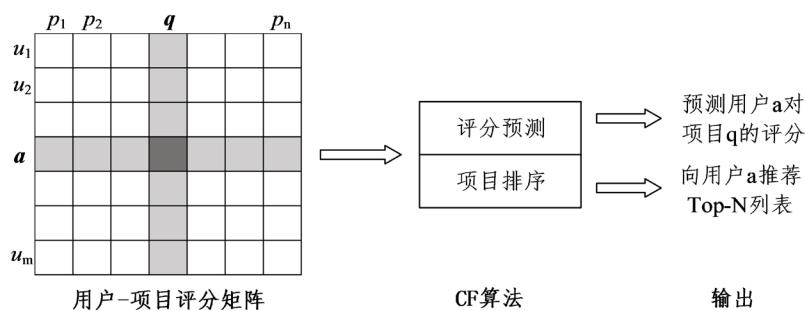


Figure 3. The general process of CF algorithm
图 3. CF 算法的一般过程

CF 算法主要采用两大类方法来解决推荐生成问题：

1. 基于内存的协同过滤算法

基于内存的 CF 算法可以使用所有的用户 - 项目数据或一个样本集来生成预测。每个用户都有一个与其有着相似兴趣的群体，被称为邻居，通过识别新用户(或活动用户)的邻居，可以预测他或她对新项目的偏好。

基于内存的 CF 算法主要采用基于邻域的协同过滤，步骤如下：计算两个用户或两个项目之间的相似度，相似度反映了用户之间或项目之间的距离或相关性；通过将用户对所有项目所有评分加权平均或将所有用户对项目的所有评分加权平均，也可以使用简单的加权平均[5]，为活动用户生成预测。当任务是生成 Top-N 推荐时，需要在计算相似度后找到 N 个最相似的用户或项目(最近邻)，然后将这些邻居聚合起来，得到 Top-N 项目列表作为推荐。基于内存的推荐算法主要有：UserCF、ItemCF 和混合的。UserCF 使用了目标用户 a 最近邻的过去偏好，而 ItemCF 则使用了与某一项目 q 最相似的项目的评分。

UserCF 是推荐系统中最古老的算法，它的诞生标志着推荐系统的诞生。UserCF 向目标用户推荐与其兴趣相似的用户过去喜欢且目标用户不知道的项目。兴趣相似度计算是通过用户的历史行为的相似度

来衡量的。ItemCF 是目前业界应用最多的算法，很多推荐算法的基础都是该算法。ItemCF 给用户推荐那些和他们之前喜欢的项目相似的项目。不同于基于内容的推荐算法，ItemCF 不是利用项目的内容特征计算项目之间的相似度，而是通过分析用户的行为记录计算项目之间的相似度。相似度的计算通常有三种方法：*Pearson* 相关系数、*Jaccard* 相似系数和余弦相似度[39]。而调整余弦相似度是目前效果最好，也是最流行的相似度计算方法。

2. 基于模型的协同过滤算法

不同于基于内存的算法，基于模型的算法是根据已有数据应用统计和机器学习得到模型进行预测。模型的设计和开发(如机器学习、数据挖掘算法等)可以使系统学会根据训练数据识别复杂的模式，然后根据所学习的模型对测试数据或真实数据的协同过滤任务进行智能预测。基于模型的 CF 算法包括聚类模型、贝叶斯模型、概率模型、最大熵模型和矩阵分解等等。

基于聚类模型的推荐算法通常将聚类作为一个中间步骤，利用聚类的结果进行进一步的分析或处理，以执行分类或其他任务。聚类 CF 模型可以有不同方式的应用。比如，O'Connor 和 Herlocker [8] 以及胡蓉等人[9] 使用聚类技术将数据划分为簇，然后在每个簇中使用基于内存的 CF 算法进行预测。Chee 等人[40] 使用 $k = 2$ 的 k -means 方法，提出了 *RecTree* 方法，在递归地构造 *RecTree* 的过程中，将原始的大型评级数据划分为两个子簇。所得到的 *RecTree* 类似于一个不平衡的二叉树，预测是由目标用户所属的叶子节点进行的。基于聚类的推荐算法具有很好的可扩展性，因为它们在更小的集群中进行预测，而不是在整个数据集中进行预测。但其推荐质量普遍较低。

基于矩阵分解的协同过滤算法是近年来协同过滤算法中一种非常著名的方法，是一种基于潜在变量分解和降维的无监督学习方法。矩阵分解模型将用户和项目映射到维数为 d 的联合潜在因子空间，将用户与项目的交互结果建模为该空间的内积[14]。每个项目 i 与一个向量 $q_i \in \mathbb{R}^d$ 相关联，每个用户 u 与一个向量 $p_u \in \mathbb{R}^d$ 相关联。对于给定的项目 i ， q_i 中的元素值表示拥有这些因子的正负程度。对于给定的用户 u ， p_u 中的元素衡量的是用户对相应的正负因子中较高的项目的兴趣程度。内积 $q_i^T p_u$ 表示用户 u 和项目 i 之间的交互，即用户对项目特征的总体兴趣，这近似于用户 u 对项目 i 的打分 r_{ui} ，即：

$$r_{ui} = q_i^T p_u \quad (1)$$

矩阵分解是一种发现数据背后隐藏结构的强大技术，是一种非常精确的降维方法。常用的分解模型主要有：奇异值分解(Singular Value Decomposition, SVD)、主成分分析(Principal Component Analysis, PCA)、概率矩阵分解(Probabilistic Matrix Factorization, PMF)、非负矩阵分解(Non-negative Matrix Factorization, NMF) [41]。矩阵分解能够有效地处理海量数据集、稀疏的评价矩阵、可扩展性以及基于用户/项目的 CF 算法的冷启动问题。

协同过滤算法是目前最流行的推荐技术，不仅可以发现用户潜在的兴趣偏好，具有推荐新信息的能力，还能解决基于内容推荐中一些项目难以进行内容分析的问题，如：电影、音乐、艺术品等。

4.3. 混合推荐算法

每种方法都有各自的局限性，没有一种方法可以独领风骚，它们在各自的领域表现出来的效果也各有千秋，于是在实际的应用中，通常根据实际情况将各种算法混合在一起使用，所以就有了混合推荐技术。混合推荐技术融合了基于内容的过滤和协同过滤算法中两种或两种以上推荐技术的特点，从而利用每种技术的优势，提高性能。混合推荐技术非常有用，因为它可以克服传统推荐方法的大多数限制，将它们组合起来以获得更好的结果。混合推荐技术的方法有很多：加权型、切换型、交叉型、特征组合型、瀑布型、特征递增型、元层次型。

- 加权型：输出是由多种不同推荐方法加权组合而成。
- 切换型：根据问题背景和实际情况采用不同的推荐技术。
- 交叉型：同时采用多种推荐技术给出多种推荐结果，为用户提供参考。
- 瀑布型：后一个推荐方法优化前一个推荐方法：它是一个分阶段的过程，首先用一种推荐技术产生一个较为粗略的候选结果，在此基础上使用第二种推荐技术对其进行进一步精确地推荐。
- 特征组合型：将来自不同推荐数据源的特征组合起来，由另一种推荐技术采用。
- 特征递增型：将一种方法的推荐输出作为另一种方法的输入。
- 元层次型：用一种推荐方法产生的模型作为另一种推荐方法的输入。

5. 推荐系统研究热点和趋势

5.1. 深度学习与现有推荐算法的结合

近年来，随着以深度学习为核心的认知智能技术快速兴起和发展，对深度学习的研究取得爆炸式增长，深度学习已在语音识别、图像处理、自然语言处理等领域取得了突破性的进展和丰富的成果，深度学习在推荐任务中的应用也受到国际学术界和工业界越来越多的关注。推荐系统国际会议(ACM Rec-Sys)自2016年起定期举办基于深度学习的推荐系统研讨会，国内外许多大学和研究机构也对基于深度学习的推荐系统开展了广泛研究。深度学习给推荐体系结构带来了革命性的变化，为提高推荐者的性能带来了更多的机会。基于深度学习的推荐系统克服了传统模型的局限性，实现了高质量推荐，受到了人们的广泛关注。

5.2. 基于强化学习的推荐

大多数推荐模型都将推荐过程看作静态过程，这使得捕获用户的时间意图和及时响应变得困难。近年来，强化学习在个性化推荐方面开始受到关注[42]-[47]。强化学习主要采用试错法，有两个关键概念探索和利用。探索就是把不确定用户喜不喜欢的商品推荐给用户，来探索用户到底喜欢什么；利用就是从用户已知的用户喜欢的东西里找到用户最喜欢的。文献[46]提出了一种基于强化学习的新闻推荐系统，解决以下三个挑战：(1) 新闻内容和用户偏好的动态变化；(2) 纳入用户的退货单(服务)；(3) 增加推荐的多样性。Choi等人[47]提出用RL和双聚类方法解决冷启动问题。强化学习技术，在实际应用中已显示出了优越的推荐性能，尤其是强化学习与深度学习结合的深度强化学习定会在推荐系统领域取得广泛的关注，成为一个新的研究热点。

5.3. 融合注意力机制的推荐

近年来，由于受深度学习研究的影响，注意力机制得到了广泛应用和更深入研究，如在图像处理、语音识别、视频识别、自然语言处理等领域都取得了很好的效果[48][49][50]。在推荐系统领域也取得了不少成果，文献[51]从不同角度将注意力机制应用在电影推荐系统中，学习用户的行为偏好，提高推荐精度。文献[52]利用双层注意力机制分别构建用户特征网络和项目特征网络，预测特定用户可能给出的项目评分；文献[53]考虑用户行为的异构性，通过自我注意对行为之间产生影响，构建基于注意力机制的用户行为模型。可见注意力机制在推荐系统中的应用研究已成为一个热点。

5.4. 推荐结果的可解释性

推荐结果的可解释性是指在为用户提供推荐的同时，给出推荐的理由。推荐系统的目的是为用户推荐其可能会感兴趣的项目，然后通过算法推荐达到节省用户时间、提升用户满意度、为公司创造更多的

商业价值的目的。要想达到这个目的就需要让用户信任推荐系统，只有信任了，用户才会经常使用推荐系统。那么如何让用户信任呢？一种比较好的方法是为用户推荐项目的同时给用户提供推荐的理由，向用户解释清楚是基于什么原因给他推荐的。因此，最近几年越来越多的推荐算法开始注重推荐结果的可解释性，希望能与用户产生沟通交流，直接增强用户体验，间接地增强推荐效果[54] [55] [56]。

学者们已在该领域做了大量工作[57] [58]。文献[57]从用户评论中提取项目细粒度的个性化特征，提出了一个用于可解释推荐任务的多任务学习方法。文献[58]提出了利用结合知识库的记忆网络来增强推荐系统的特征捕获能力与解释性，解决序列化推荐系统不具有解释性，且无法获取用户细粒度特征的不足。

5.5. 推荐结果的多样性和公平性

对于推荐系统来说，推荐准确率是评价推荐质量最重要的指标，并且在 Netflix Prize 大赛中，推荐准确率是作为评价算法优劣的唯一标准[59]。但是，如果只考虑推荐的准确性，很容易陷入一个单一类别的局部最优解，造成用户兴趣的同质性。为了给用户带来更好的体验，获得更好的用户满意度，推荐结果的多样性、新颖性和公平性受到研究人员的重视。推荐结果的多样性能够向用户推荐彼此相似度低的项目，从而开阔用户的视野，发散用户的兴趣[60]，能更好地发现具有“新颖性”的项目[61]，并增加冷门项目被推荐的机会。文献[62] [63] [64] [65]也分别提出了不同的方法来提高推荐结果的多样性和公平性。如何在保证推荐准确率的前提下，有效提高推荐多样性已成为推荐系统研究的热点问题。

6. 结论

推荐系统作为大数据时代信息过载解决的有效手段，受到学术界和工业界的极大关注。本文总结了推荐系统面临的三大挑战，对目前的推荐算法进行了分类，介绍了几类经典的推荐算法，并对推荐系统未来的研究热点做了总结和预测。虽然现有的工作已经为深入地开展推荐系统研究奠定了坚实的基础，仍然还有很多问题没有彻底解决，且这些问题对该领域的发展至关重要。除了本文总结的三大挑战，还有系统的可扩展性、系统的脆弱性、大数据处理与增量计算等。并且随着用户对推荐系统的要求不断提高，个性化推荐系统也需要更加的精确化、智能化和人性化。

基金项目

国家自然科学基金(61773399)。

参考文献

- [1] Montaner, M., López, B. and De La Rosa, J.L. (2003) A Taxonomy of Recommender Agents on the Internet. *Artificial Intelligence Review*, **19**, 285-330. <https://doi.org/10.1023/A:1022850703159>
- [2] 项亮. 推荐系统实践[M]. 北京: 人民邮电出版社, 2019.
- [3] Adomavicius, G. and Tuzhilin, A. (2005) Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. *IEEE Transactions on Knowledge and Data Engineering*, **17**, 734-749. <https://doi.org/10.1109/TKDE.2005.99>
- [4] Resnick, P., Iakovou, N., Sushak, M., Bergstrom, P. and Riedl, J. (1994) GroupLens: An Open Architecture for Collaborative Filtering of Netnews. *Proceedings of the 1994 Computer Supported Cooperative Work Conference*, Chapel Hill, 22-26 October 1994, 175-186. <https://doi.org/10.1145/192844.192905>
- [5] Sarwar, B., Karypis, G., Konstan, J. and Riedl, J. (2001) Item-Based Collaborative Filtering Recommendation Algorithms. *Proceedings of the 10th International WWW Conference*, Hong Kong, 1-5 May 2001, 285-295. <https://doi.org/10.1145/371920.372071>
- [6] Linden, G., Smith, B. and York, J. (2003) Amazon.com Recommendations: Item-to-Item Collaborative Filtering. *IEEE Internet Computing*, **7**, 76-80. <https://doi.org/10.1109/MIC.2003.1167344>
- [7] Deshpande, M. and Karypis, G. (2004) Item-Based Top-N Recommendation Algorithms. *ACM Transactions on In-*

- formation Systems*, **22**, 143-177. <https://doi.org/10.1145/963770.963776>
- [8] Ungar, L.H. and Foster, D.P. (1998) Clustering Methods for Collaborative Filtering. In: *Recommender Systems: Papers from 1998 Workshop*, Technical Report WS-98-08, AAAI Press, Palo Alto, 114-129.
- [9] Hu, R., Dou, W., Liu, J. and Club, C.F. (2014) A Clustering-Based Collaborative Filtering Approach for Big Data Application. *IEEE Transactions on Emerging Topics in Computing*, **2**, 302-313. <https://doi.org/10.1109/TETC.2014.2310485>
- [10] Chien, Y.-H. and George, E.I. (1999) A Bayesian Model for Collaborative Filtering. *Proceedings of the 7th International Workshop on Artificial Intelligence and Statistics*, Lauderdale FL.
- [11] Hofmann, T. (2003) Collaborative Filtering via Gaussian Probabilistic Latent Semantic Analysis. *Proceedings of the 26th Annual International ACM SIGIR Conference*, Toronto, 28 July-1 August 2003, 259-266. <https://doi.org/10.1145/860435.860483>
- [12] Hofmann, T. (2004) Latent Semantic Models for Collaborative Filtering. *ACM Transactions on Information Systems*, **22**, 89-115. <https://doi.org/10.1145/963770.963774>
- [13] Pavlov, D.Y. and Pennock, D.M. (2002) A Maximum Entropy Approach to Collaborative Filtering in Dynamic, Sparse, High-Dimensional Domains. *Proceedings of the 16th Annual Conference on Neural Information Processing Systems*, Vancouver, December 2002, 1465-1472.
- [14] Koren, Y. (2009) Matrix Factorization Techniques for Recommender Systems. IEEE Computer Society, Washington DC, 42-49. <https://doi.org/10.1109/MC.2009.263>
- [15] Li, K.K., Zhou, X.Z., Lin, F., Zeng, W.H. and Alterovitz, G. (2019) Deep Probabilistic Matrix Factorization Framework for Online Collaborative Filtering. *IEEE Access*, **7**, 56117-56128. <https://doi.org/10.1109/ACCESS.2019.2900698>
- [16] Batmaz, Z., Yurekli, A., Bilge, A., et al. (2019) A Review on Deep Learning for Recommender Systems: Challenges and Remedies. *Artificial Intelligence Review*, **52**, 1-37. <https://doi.org/10.1007/s10462-018-9654-y>
- [17] Tarus, J.K., Niu, Z.D. and Mustafa, G. (2017) Knowledge-Based Recommendation: A Review of Ontology-Based Recommender Systems for E-Learning. *Artificial Intelligence Review*, **50**, 21-48. <https://doi.org/10.1007/s10462-017-9539-5>
- [18] Burke, R. (2000) Knowledge-Based Recommender Systems. In: Kent, A., Ed., *Encyclopedia of Library and Information Systems*, Volume 69, Marcel Dekker, New York, Supplement 32.
- [19] Colombo-Mendoza, L.O., Valencia-García, R., Rodríguez-González, A., Alor-Hernández, G. and Samper-Zapater, J.J. (2015) RecomMetz: A Context-Aware Knowledge-Based Mobile Recommender System for Movie Show-Times. *Expert Systems with Applications*, **42**, 1202-1222. <https://doi.org/10.1016/j.eswa.2014.09.016>
- [20] Zhang, F., Yuan, N.J., Lian, D., Xie, X. and Ma, W. (2016) Collaborative Knowledge Base Embedding for Recommender Systems. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, 13-17 August 2016, 353-362. <https://doi.org/10.1145/2939672.2939673>
- [21] Wang, H.W., Zhang, F.Z., Xie, X. and Guo, M.Y. (2018) DKN: Deep Knowledge-Aware Network for News Recommendation. *27th International Conference on World Wide Web*, Lyon, 23-27 April 2018, 1835-1844. <https://doi.org/10.1145/3178876.3186175>
- [22] 孙光浩, 刘丹青, 李梦云. 个性化推荐算法综述[J]. 软件, 2017(7): 70-80.
- [23] Verbert, K., Duval, E., Lindstaedt, S. and Gillet, D. (2010) Context-Aware Recommender Systems. *Journal of Universal Computer Science*, **16**, 2175-2178.
- [24] Adomavicius, G. and Tuzhilin, A. (2011) Context-Aware Recommender Systems. In: Ricci, et al., Eds., *Recommender Systems Handbook*, Springer, Berlin, 217-253. https://doi.org/10.1007/978-0-387-85820-3_7
- [25] Huang, Z., Lu, X. and Duan, H. (2011) Context-Aware Recommendation Using Rough Set Model and Collaborative Filtering. *Artificial Intelligence Review*, **35**, 85-99. <https://doi.org/10.1007/s10462-010-9185-7>
- [26] Bedi, P., Kaur, H. and Marwaha, S. (2007) Trust Based Recommender System for Semantic Web. *Proceedings of the 20th International Joint Conference on Artificial Intelligence*, Hyderabad, Vol.7, 2677-2682.
- [27] Kalaïa, A., Zayani, C.A., Amous, I., Abdelghani, W. and Sèdes, F. (2018) Social Collaborative Service Recommendation Approach Based on User's Trust and Domain-Specific Expertise. *Future Generation Computer Systems*, **80**, 355-367. <https://doi.org/10.1016/j.future.2017.05.036>
- [28] Zhang, Z., Lin, H., Liu, K., Wu, D., Zhang, G. and Lu, J. (2013) A Hybrid Fuzzy-Based Personalized Recommender System for Telecom Products/Services. *Information Sciences*, **235**, 117-129. <https://doi.org/10.1016/j.ins.2013.01.025>
- [29] He, J. and Chu, W. (2010) A Social Network-Based Recommender System (SNRS). In: Memon, N., Xu, J.J., Hicks, D.L. and Chen, H., Eds., *Data Mining for Social Network Data*, Springer, New York, 47-74.

https://doi.org/10.1007/978-1-4419-6287-4_4

- [30] Masthoff, J. (2011) Group Recommender Systems. In: Ricci, F., Rokach, L., Shapira, B. and Kantor, P.B., eds., *Recommender Systems Handbook*, Springer, New York, 677-702. https://doi.org/10.1007/978-0-387-85820-3_21
- [31] Mc Carthy, K., Salamó, M., Coyle, L., Mc Ginty, L., Smyth, B. and Nixon, P. (2006) Group Recommender Systems: A Critiquing Based Approach. *Proceedings of the 11th International Conference on Intelligent User Interfaces*, Sydney, 267-269. <https://doi.org/10.1145/1111449.1111506>
- [32] 黄立威, 江碧涛, 等. 基于深度学习的推荐系统研究综述[J]. 计算机学报, 2018, 41(7): 1619-1647.
- [33] Zhang, S., Yao, L. and Sun, A. (2017) Deep Learning Based Recommender System: A Survey and New Perspectives.
- [34] Sahoo, A.K., Pradhan, C., Barik, R.K. and Dubey, H. (2019) DeepReco: Deep Learning Based Health Recommender System Using Collaborative Filtering. *Computation*, 7, 25. <https://doi.org/10.3390/computation7020025>
- [35] Mu, R.H., Zeng, X.Q. and Han, L.X. (2018) A Survey of Recommender Systems Based on Deep Learning. *IEEE Access*, 6, 69009-69022. <https://doi.org/10.1109/ACCESS.2018.2880197>
- [36] Van Meteren, R. and Van Someren, M. (2000) Using Content-Based Filtering for Recommendation. *Proceedings of the Workshop on Machine Learning in the New Information Age*, Barcelona, 47-56.
- [37] Baeza-Yates, R. and Ribeiro-Neto, B. (1999) Modern Information Retrieval. Addison-Wesley, Boston.
- [38] Goldberg, K., Roeder, T., Gupta, D. and Perkins, C. (2001) Eigen-Taste: A Constant Time Collaborative Filtering Algorithm. *Information Retrieval*, 4, 133-151. <https://doi.org/10.1023/A:1011419012209>
- [39] Su, X.Y. and Khoshgoftaar, T.M. (2009) A Survey of Collaborative Filtering Techniques. *Advances in Artificial Intelligence*, 2009, Article ID: 421425. <https://doi.org/10.1155/2009/421425>
- [40] Chee, S.H.S., Han, J. and Wang, K. (2001) RecTree: An Efficient Collaborative Filtering Method. *Proceedings of the 3rd International Conference on Data Warehousing and Knowledge Discovery*, Munich, 5-7 September 2001, 141-151. https://doi.org/10.1007/3-540-44801-2_15
- [41] 王建芳. 推荐系统的协同过滤理论及其应用[M]. 北京: 清华大学出版社, 2018.
- [42] Zhao, X.Y., Xia, L., Zhang, L., Ding, Z.Y., Yin, D.W. and Tang, J.L. (2018) Deep Reinforcement Learning for Page-Wise Recommendations. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 95-103. <https://doi.org/10.1145/3240323.3240374>
- [43] Zhao, X.Y., Zhang, L., Ding, Z.Y., Xia, L., Tang, J.L. and Yin, D.W. (2018) Recommendations with Negative Feedback via Pairwise Deep Reinforcement Learning. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, London, 19-23 August 2018, 1040-1048. <https://doi.org/10.1145/3219819.3219886>
- [44] Wang, X.X., Wang, Y., Hsu, D. and Wang, Y. (2014) Exploration in Interactive Personalized Music Recommendation: A Reinforcement Learning Approach. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 11, 7. <https://doi.org/10.1145/2623372>
- [45] Munemasa, I., Tomomatsu, Y., Hayashi, K. and Takagi, T. (2018) Deep Reinforcement Learning for Recommender Systems. *International Conference on Information and Communications Technology*, Yogyakarta, 6-7 March 2018, 226-233. <https://doi.org/10.1109/ICOIACT.2018.8350761>
- [46] Zheng, G.J., Zhang, F.Z., Zheng, Z.H., Xiang, Y., Yuan, N.J., Xie, X. and Li, Z.H. (2018) DRN: A Deep Reinforcement Learning Framework for News Recommendation. *Proceedings of the 2018 World Wide Web Conference on World Wide Web*, Lyon, 23-27 April 2018, 167-176. <https://doi.org/10.1145/3178876.3185994>
- [47] Choi, S., Ha, H., Hwang, U., Kim, C., Ha, J.-W. and Yoon, S. (2018) Reinforcement Learning Based Recommender System Using Biclustering Technique.
- [48] Bahdanau, D., Cho, K. and Bengio, Y. (2014) Neural Machine Translation by Jointly Learning to Align and Translate.
- [49] Luong, M.T., Pham, H. and Manning, C.D. (2015) Effective Approaches to Attention-Based Neural Machine Translation. *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, Lisbon, 17-21 September 2015, 1412-1421. <https://doi.org/10.18653/v1/D15-1166>
- [50] Jang, Y., Song, Y., Yu, Y., et al. (2017) TGIF-QA: An Attention-Based User Behavior Modeling Framework for Recommendation.
- [51] 王永贵, 尚庚. 融合注意力机制的深度协同过滤推荐算法[J/OL]. 计算机工程与应用. <http://kns.cnki.net/kcms/detail/11.2127.TP.20190417.1209.018.html>
- [52] Seo, S.Y., Huang, J., Yang, H., et al. (2017) Interpretable Convolutional Neural Networks with Dual Local and Global Attention for Review Rating Prediction. *Proceedings of the 11th ACM Conference on Recommender Systems*, Como, 27-31 August 2017, 297-305. <https://doi.org/10.1145/3109859.3109890>

-
- [53] Zhou, C., Bai, J., Song, J., et al. (2017) ATRank: An Attention-Based User Behavior Modeling Framework for Recommendation.
 - [54] McInerney, J., Lacker, B., Hansen, S., Higley, K., Bouchard, H., Gruson, A. and Mehrotra, R. (2018) Explore, Exploit, and Explain: Personalizing Explainable Recommendations with Bandits. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 31-39. <https://doi.org/10.1145/3240323.3240354>
 - [55] Wan, M.T. and McAuley, J. (2018) Item Recommendation on Monotonic Behavior Chains. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 86-94.
 - [56] Lu, Y.C., Dong, R.H. and Smyth, B. (2018) Why I Like It: Multi-Task Learning for Recommendation and Explanation. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 4-12.
 - [57] Wang, N., Wang, H.N., Jia, Y.L. and Yin, Y. (2018) Explainable Recommendation via Multi-Task Learning in Opinionated Text Data. *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*, Ann Arbor, 8-12 July 2018, 165-174. <https://doi.org/10.1145/3209978.3210010>
 - [58] Huang, J., Zhao, W.X., Dou, H. and Wen, J.R. (2018) Improving Sequential Recommendation with Knowledge-Enhanced Memory Networks. *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*, Ann Arbor, 8-12 July 2018, 505-514. <https://doi.org/10.1145/3209978.3210017>
 - [59] 张骏. 推荐系统多样性的研究及其在就业推荐中的应用[D]: [硕士学位论文]. 济南: 山东师范大学, 2017.
 - [60] 安维, 刘启华, 张李义. 个性化推荐系统的多样性研究进展[J]. 图书情报工作, 2013, 57(20): 127-135.
 - [61] Liu, Y.Z.G, Wang, J.K., Jiang, Y.C., et al. (2016) Utilize Item Correlation to Improve Aggregate Diversity for Recommender Systems. In: *IEEE 1st International Conference on Data Science in Cyberspace*, IEEE Computer Society, Washington DC, 412-417. <https://doi.org/10.1109/DSC.2016.31>
 - [62] Steck, H. (2018) Calibrated Recommendations. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 154-162. <https://doi.org/10.1145/3240323.3240372>
 - [63] Bonner, S. and Vasile, F. (2018) Causal Embeddings for Recommendation. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 104-112. <https://doi.org/10.1145/3240323.3240360>
 - [64] Sanz-Cruzado, J. and Castells, P. (2018) Enhancing Structural Diversity in Social Networks by Recommending Weak Ties. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 233-241. <https://doi.org/10.1145/3240323.3240371>
 - [65] Chaney, A.J.B., Stewart, B.M. and Engelhardt, B.E. (2018) How Algorithmic Confounding in Recommendation Systems Increases Homogeneity and Decreases Utility. *Proceedings of the 12th ACM Conference on Recommender Systems*, Vancouver, 2 October 2018, 224-232. <https://doi.org/10.1145/3240323.3240370>