

主动学习在推荐系统中的应用

赵海燕¹ 汪 静¹ 陈庆奎¹ 曹 健²

(上海理工大学光电信息与计算机工程学院 上海 200093)¹

(上海交通大学计算机科学与技术系 上海 200030)²

摘 要 近年来,推荐技术迅速发展,日趋成熟。但是,多数推荐算法都建立在一个理想的假设下,即有足够多的样本数据供我们训练出成熟的模型用于预测或推荐。在实际工业化生产中,一方面的用户和项目只拥有极少量的标签信息;另一方面,即使依靠历史积累形成的数据集,在分布上也十分不均衡,难以学习出可靠的推荐模型。主动学习的思想认为每个项目给系统带来的“好处”是不等的,因而可以通过特定策略选择某些项目,借助用户与项目之间的交互行为来主动获取相关的偏好信息。应用在推荐系统中的主动学习试图选择数量更少、质量更高的样本来训练模型,既能提高用户体验,又能免受数据集不均衡的束缚。文中综述了近年来主动学习在推荐系统中的应用,并对其发展趋势进行分析。

关键词 推荐系统,主动学习,冷启动,成员查询,基于会话

中图分类号 TP311 文献标识码 A

Application of Active Learning in Recommendation System

ZHAO Hai-yan¹ WANG Jing¹ CHEN Qing-kui¹ CAO Jian²

(School of Optical-Electrical Information & Computer Engineering, University of Shanghai for Science & Technology, Shanghai 200093, China)¹

(Department of Computer Science & Technology, Shanghai Jiao Tong University, Shanghai 200030, China)²

Abstract In recent years, recommender system develops very quickly and is becoming more and more mature. However, many approaches are based on an ideal assumption, i. e., there are plenty of sample data which can help us train a mature model to predict or recommend. In actual industrial production, most users and products lack of rating information or consumption records. And datasets formed by historical accumulation are unevenly distributed, so that it is hard to learn a reliable model. Active learning considers that the benefits of each item to the system is different, so some special items can be selected through specific strategies, and the related preference information can be actively obtained by the interaction between the user and the project. Active learning applied in the recommendation system attempts to training a model with fewer but higher quality samples, which improves the user experience and protects against unbalanced data sets. The applications of active learning in recommendation system in recent years were reviewed and summarized. Future directions were also discussed in this paper.

Keywords Recommendation system, Active learning, Cold start, Query-by-committ, Conversational-based

1 绪论

互联网的快速发展将人们的生活从信息匮乏时代推入了信息过载时代,在不借助工具的情况下,从海量信息中找到所需尤为困难。在分类目录和搜索引擎的时代,用户与信息呈现一种“拉”(pull)的状态,即用户通过搜索引擎输入关键字来主动告诉系统用户的需求,但是对于那些没有明确需求的用户,搜索引擎就会显得力不从心,在这样的背景下,推荐技术应运而生。相较于搜索引擎,推荐系统应用下的用户对信息的获取呈现一种“推”(push)的关系,即用户不需要费力地向系统获取,而是系统主动地为其推送可能需要的信息。当然,推荐技术在迅速发展的同时,也面临着一些“瓶颈”问题,

如冷启动、数据稀疏等等。

主动学习(active learning)技术属人工智能的子领域,主要思想是允许学习算法与人类监督者进行实时交互,有选择地获取数据来训练模型算法。将主动学习运用到推荐系统中,通过向系统中用户询问该用户未曾标记过的物品的标签,来获取用户的偏好信息,为推荐系统在实际工业化应用中出现的诸如数据分布不平衡等问题提供了一种新思路。因此,主动学习在推荐系统中的应用在学术研究和工业化生产中都具有重要的研究价值。

本文对主动学习在推荐系统中的应用进行综述,并指出未来的发展方向。第 2 节简要回顾主要的推荐系统技术;第 3 节简介主动学习的主要思想和过程;第 4 节对主动学习的

本文受国家自然科学基金项目(61272438, 61202376, 61472253),上海市科委项目(14511107702),上海市教委科研创新项目(13ZZ112, 13YZ075)资助。

赵海燕(1975—),女,博士,副教授,CCF 会员,主要研究方向为个性化推荐、数据挖掘;汪 静(1994—),女,硕士生,主要研究方向为数据挖掘, E-mail:jingwang94@outlook.com(通信作者)。

核心策略进行分类比较;第5节着重对主动学习的评估手段进行归纳介绍;最后总结全文并讨论未来的研究方向。

2 推荐系统

推荐系统(recommender systems)通过分析用户及物品的属性,或进一步利用评分、标签等信息,建立模型,向用户推荐其所需的物品。推荐系统在不同的领域中应用,主要通过挖掘并建立用户与物品(或信息)的关系,一方面帮助用户发现对自己有价值的物品,另一方面能让物品主动展现在对它感兴趣的用户面前^[1],实现信息消费者和信息生产者的双赢。目前,基于存储(memory-based)与基于模型(model-based)是推荐系统应用最广的两类方法。

推荐系统中,我们往往通过用户对物品的评分或标注的标签^[2-3]来收集用户的偏好信息。总的来说,推荐系统的性能取决于3个因素:推荐算法的质量、可用数据(评分或标签)的数量以及可用数据的质量。在推荐算法相同的情况下,系统从用户群体获取的数据越多、质量越高,对整个系统的优化提升就越有帮助^[4]。一方面,很多算法的提出都基于有足够多的评分或者标签数据供模型训练的假设^[5-6],而实际生产中往往有标记、有评分的物品数量有限,导致数据集整体稀疏性高,甚至出现用户冷启动(user cold-start)问题,即一个新用户开始使用推荐系统时没有任何的数据。在这样的情况下,基于内存和基于模型的推荐系统都无法得出高质量的结果,而人工标记的方法成本高、质量差且耗时长^[7]。另一方面,实际生产中的数据存在着分布不均衡的问题,即用户在某一方面的兴趣数据很丰富,训练出的模型较为可靠,但在其他方面的兴趣数据很稀少,从而造成对该方面的推荐精度较低。此外,多数推荐系统将推荐的视角局限于拟合用户过去的行为,而不能扩展用户的兴趣,无法提供新颖性体验。

主动学习的应用有助于解决推荐系统面临的问题:1)主动学习重视数据的质量,选择数目更少但质量更高的物品向用户发起询问,从而有助于解决数据稀疏和冷启动等问题;2)主动学习有选择地与用户交互,询问物品的评分等信息,可以对那些数据稀少的兴趣方面进行补充,有助于兴趣模型的全面化;3)主动学习不借助用户或物品之间的相似度,从而使推荐不会被局限在相似的模块,扩大了用户的消费和认知领域,更好地刻画了用户的偏好。因此,主动学习在推荐系统中的应用得到了越来越多的关注。

3 主动学习

主动学习是针对传统的有监督学习过程需要大量带有类别标签的样本构建学习器的弱点而提出的,尤其是在数据量十分巨大的情况下,为每一个样本进行标注的代价十分巨大^[8]。主动学习的目的是在训练数据有限的情况下能够获得较高的分类精度,再对这些样本进行标注,既可以减小训练代价,又可以提高学习器的分类效果。

推荐中的主动学习的典型过程如图1所示。典型的主动学习过程可以分为建立基本分类器以及选择合适样本两个部分。其中,基本分类器是利用有监督学习算法在带有类别标签的样本集合上进行学习和训练,使得分类器模型更趋于成熟;选择样本的过程是通过给定的样本选择算法(策略),从未标注标签的样本中挑选出“最大价值”的样本由专家或用户进

行评价和标定,然后将样本及其标签加入到训练集中。上述两个过程反复迭代,就能使分类器的性能逐步提升,直至符合终止条件。

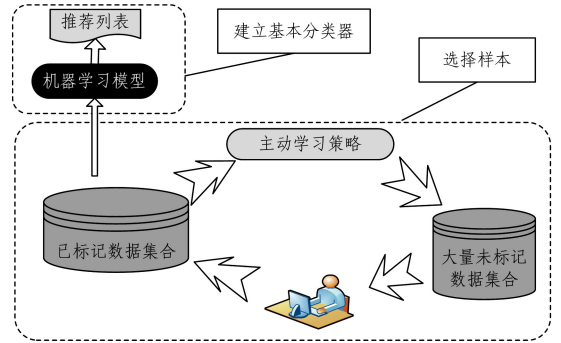


图1 主动学习在推荐中的循环过程

主动学习策略根据未标注样本选择方式的不同,可以分为两种类型^[9]:基于池(pool-based)的主动学习和基于流(stream-based)的主动学习。

基于池的主动学习中会设置一个样本池(pool),它是一个容纳着海量未标注样本的项目集合 P ,主动学习的策略 S 按照一定的规则从 P 中选择一个或多个样本项目组成询问列表 L 让专家做标记^[10]。而基于流的基本思想是从实际分布中采样一部分未标注案例,由学习模型决定是否对其进行标注,决定方式有多种,可以通过“信息量测试”或“询问策略”,也可以对样本实例的信息量设定阈值,大于设定阈值的样本实例被选择标注^[11]。基于池的思想不需要计算并设定阈值,普适性更好,而且能够克服人工标注随意性带来的弊端^[12],但是对机器的内存和处理能力要求较高,算法的耗时较长。基于流的方法能在样本分布未知或不一致时,使得预测结果仍保持合理性,但是存在“信息量测试”等额外计算,并且对于不同的问题需要设定不同的阈值,缺乏普适性。

文献[13-14]提出基于池方法的双标准,旨在选择既富含信息量又具有代表性的未标注的物品进行询问。文献[15]提出CBVR算法,用基于池的思想对网页视频信息检索的模型进行训练。文献[16]采用偏差再取样技术解决了未知密度的问题。文献[17]用基于流的思想对数据流进行分类,通过对实例计算一个最小权重,可以改变分类器的标注意见。文献[18]提出A2ING算法,利用文本类别的不确定性实现文本分类等。

4 主动学习在推荐系统中的应用

在主动学习中,不同的评分或标签对系统的帮助也是不等的^[19],即每一个加入到训练集中的评分数据都会对模型学习用户的偏好信息有着不同的作用。比如,在基于用户的协同过滤推荐中,热门商品是一种流行趋势,不能代表用户喜欢该物品或同样消费了该物品的用户之间具有相似的好,所以热门商品的评分提供给系统的信息量就相对较少。因此,需要利用策略筛选出特定的物品让用户进行评价。我们将应用在推荐系统中的主动学习策略分为单一非个性化策略、单一个性化策略及多策略组合进行讨论,并单独划出一节介绍基于系统与用户之间会话的相关研究工作。

4.1 非个性化策略

非个性化策略对系统中的用户采用统一的策略,呈现相

同的物品,不考虑用户各自的特点,追求整个系统的性能提升。非个性化策略又可以分为基于不确定性和基于误差两类。

4.1.1 基于不确定性

基于不确定性的主动学习试图找到能够降低模型不确定性的训练点,如输出值不确定^[20]、参数不确定^[21]以及决策边界不确定^[22]等。但是,基于不确定的思想有一个弊端,即当模型选择错误时,基于不确定性的主动学习就发挥不了作用,因为降低模型的不确定性始终不是我们的最终目标。

根据文献[21],pLSA(probabilistic latent semantic analysis)算法是基于连续值响应变量的概率潜语义分析的泛化,该方法为每个用户-物品对 (u, i) 引入一个隐藏变量 x 和状态变量 y ,使得用户 u 和物品 i 之间呈现条件独立的关系。根据文献[23],MIU(multiple-instance uncertainty)在多实例的环境下进行主动学习,在选择训练点的标准上不仅考虑到训练点的评分标注的不确定性,还考虑到学习模型能否充分了解训练点适合的用户群体。根据文献[19],PAL(pessimistic active learning)通过计算物品评分的置信区间来衡量候选训练点的不确定性,从而降低模型的输出不确定性。类似地,在文献[20]中,选择物品评分的熵(entropy)或方差(variance)的最大者,希望能最大程度上减小模型的不确定。文献[22,24]用支持向量机(SVM)模型作为底层的技术支持,选择离决策边界越近的未标注样本以获得更精确的分割超平面,或者如果超平面的方向已经确定,可以选择输入点来减小边缘的大小^[25]。

4.1.2 基于误差

基于误差的主动学习思想是降低实验结果的误差,这也是我们的终极目标^[2]。降低预测误差有两种方式,一种是调整训练数据的属性,另一种是调整模型。

根据文献[26],Error-Reduction Sampling是基于池思想的一种实现,选择能使得模型预测误差得到最大程度减小的样本来直接缩减期望误差。使用抽样技术既保证了样本空间的先验分布,又降低了算法的复杂度。文献[27]中,将预测误差 G 表示为: $G=C+B+V$,其中 C 表示模型误差, B 表示当前预测值与最优预测值的偏差, V 表示模型方差。这一想法激发了许多通过该等式来最小化预测误差的方法。文献[28]认为 C 是样本分布中不能左右的噪音,而 B 相较于预测误差可以忽略不计,所以通过最小化模型参数方差 V 来达到最小化预测误差 G 的效果。文献[29]中的ALICE算法在最小化预测误差时,既考虑到方差 V ,还将偏差 B 也考虑进来。

4.1.3 基于隐性特征

基于隐性特征的思想是利用用户与物品之间的关系或对用户物品评分信息进行统计整理,挖掘这些数据背后更深层次的知识,并利用这些知识选择能够给系统带来最有价值的物品,从而实现系统性能的提升。

文献[30]中提到的popularity算法根据物品拥有的非空评分数量进行排列,给用户推荐排列名次靠前的 k 个物品,因为最受欢迎的物品更有可能被用户知晓,也就更有可能获取到用户的评分,从而扩大训练集。根据文献[31],Co-coverage偏向于选择整个数据集中有更高协同覆盖率的物品(物品 i 与物品 j 的协同覆盖率为对 i 和 j 两者都评价过的用户个数,物品 i 的协同覆盖率是 i 与数据集中其他物品的协同覆盖率

之和)。物品的协同覆盖率会受到物品流行度的影响。文献[32]计算目标物品对其他未标注物品的影响力,选择值最大的物品来询问用户获取评分,也就是将选择的物品 i 及其评分加入训练集后,其他未标注物品的预测评分的变化最大。

4.2 个性化策略

个性化策略会为用户量身定制各自的推荐物品,即对不同的用户按其兴趣推荐不同的物品。个性化策略又可以分为基于预测、基于获取概率两类。

4.2.1 基于预测

基于预测的思想使用评分预测模型来预测应该向用户提供哪些物品请求评分。该方法的优点在于所询问的物品都是与该用户相关的,所以一方面用户不会反感所提问题,另一方面用户能顺利给出评分的可能性更大。

文献[33]中的Highest Predicted思想是对未标注的物品预测评分,预测评分最高的物品有可能是用户最喜欢的物品,用户也就能给出评分。而文献[34]提出的Lowest Predicted,与Highest Predicted的思想相似,选取预测评分最低的物品询问用户评分,由此来辨别用户不喜欢的物品。该方法也会暴露模型的预测误差,并对模型的参数有大的影响,同时可能不会获得很多的评分,也会有比较糟糕的用户体验。文献[35]用Aspect Model对属于兴趣组 z 的目标用户 u 对特定物品 i 给出评分 r 的可能性进行预测,其中用户被认为是多个兴趣组的组合。

4.2.2 基于获取概率

在可用数据量极小的情况下,主动学习的第一目标是扩大训练集,获取更多有用的新数据。基于获取概率的思想是按照能够获取到数据的最大可能性选择物品来询问用户,尽可能扩大数据集^[36]。另外,相较于不考虑获取概率的策略,这种思想也能变相地提升用户体验,不至于询问的都是冷门物品,导致用户中途放弃。

文献[37]基于Item-Item计算物品与物品之间的相似度,选择那些与目标用户之前行为具有最大相似度的物品询问用户,既保证了个性化推荐,又避开了用户知识的局限。文献[38]提出Binary Prediction的方法,将用户-物品评分矩阵中的非空值改为1,空值改为0,再对转换过后的矩阵中标为0值的位置进行预测,然后根据预测值的大小来判断用户知道该物品的可能性,最大化用户提供评分的可能。文献[39]在Binary Prediction的基础上加入人格行为调查得到的偏置量,预测目标用户对特定物品给出评分的概率。

4.3 多策略组合

虽然上文提到的策略已经能给出不错的推荐结果,但是单一的选择物品的标准有时无法正确识别那些值得被标注的物品,因此可以将多个策略结合起来,使用多种启发式方法来识别有价值的物品。该思想又可以分为基于集成、部分随机和结合隐性特征的策略组合。

4.3.1 基于集成的策略组合

相较于使用单一模型来预测用户的偏好,使用一组模型的效果可能更好;又或者只使用一个模型,但该模型是从许多候选模型中挑选出来的。基于集成思想的优点在于,能对不同的用户或不同的问题使用不同的模型^[40]。

根据文献[7,41],QBC(query by committee)设置一个模型的成员组 $C=\{\theta(1),\theta(2),\dots,\theta(c)\}$,其表示 C 中有 c 个不

同的学习模型,用这 c 个模型的综合意见来决定物品的去留,当成员组中的成员模型对某物品的标签或评分意见分歧最大时,该物品会呈现给用户请求其评分。构建模型成员组的方式还有很多,可以通过对某些后验分布随机抽样出任意个数的模型来实现,如朴素贝叶斯模型的狄利克雷分布^[42]、隐式马尔科夫模型的正态分布^[43]等;也可以通过其他模型来构建,如文献[45]提出使用 boosting 算法^[44]和 bagging 算法对 QBC 进行修改,让在多次抽样的训练集上训练的多个模型组成 QBC 策略的成员组,从而实现系统性能的优化提升。文献[46]在 Statlog1 数据集上用 Bagging 算法获得了一组分类假设,实验证明该算法对推荐的精度有实质性提升,也避免了模型偏差的影响。文献[47]分析了 KL-d (kullback-leibler divergence)算法和 VE(vote entropy)算法的弊端,提出了将二者结合的想法,提升了推荐系统的推荐精度。

4.3.2 部分随机的策略组合

用户的知识存在局限性,当用户不能给出足够数量的物品评分时,策略也就无法返回指定数量的物品,这种情况下模型不能给出可靠的推荐结果。另一方面,单一策略中仅 random^[37]策略能够将没有评分的新物品呈现给用户,其他的策略都不能克服新物品的冷启动问题。部分随机思想是将选定的策略与 random 策略相结合,通过修改或扩展非 random 策略所返回的物品列表,引入随机物品,能够很好地处理新物品的冷启动问题。

文献[48]在 popularity 策略的结果中加入随机物品,实现 popularity 策略的部分随机。文献[49]在 7 个基础算法(分别为 variance, popularity, lowest predicted, lowest-highest predicted, highest predicted, binary predicted 和 $\log(\text{pop}) * \text{entropy}$)上实现部分随机,并从 MAE, Precisions 以及 NDCG 等各方面对这几个部分随机策略的实验效果进行比较。

4.3.3 结合隐性特征的策略组合

将用户和物品的隐性特征与其他策略相结合,希望收集到更多用户信息的同时也考虑到选择物品的信息量。在两种策略结合使用时,有时会对隐性特征进行预处理,试图避免某些离群点对策略准确度产生负面影响。

文献[37]将 popularity 和基于不确定性思想的策略 entropy 搭配使用,提出了 $\log(\text{popularity}) * \text{entropy}$ 的算法,对物品的流行度取对数是为了克服其与熵之间的差异。popularity 策略能够从用户处获得更多物品的评分,但是这些物品本身携带的信息量不大,所以与 entropy 策略相结合,能获得较多的评分,且这些评分对系统很有用。与之类似,文献[31]用 $\sqrt{\text{popularity}}$ 代替 $\log(\text{popularity})$, variance 代替 entropy,提出 $\sqrt{\text{popularity}} * \text{variance}$ 的算法。文献[50]将物品熵 E 与物品频率的对数形式 $\log(F)$ 相乘后,再用结果来计算调和平均数。算法利用调和平均数的方法,只有当两个操作数都很大的情况下,最后的结果值才会很高,也就是只有物品很流行而又具有高的信息量时,才会被选中。

4.4 基于会话

基于会话的环境能够产生更有效率的主动学习策略^[51],该思想给予用户自由键入某些物品标签或能表达其偏好信息的权利。系统与用户的交互时机可以在用户进入系统的初始阶段,经过多次交互迭代后,逐渐缩小用户偏好的范围,直至获得满意的物品集合;也可以在用户熟悉系统之后^[52],通过

针对性交互更好地挖掘用户的深层兴趣,实现深度精准推荐。下面根据系统与用户之间不同的交互形式进行分类讨论。

4.4.1 评分

直接向用户发起询问,请求用户打分是系统与用户交互最常见的一种方式。评分既有直接量化用户对物品喜爱程度的特点,又有便于统计与分类的优点。比如,MovieLens 数据集利用 1 到 5 分制表达用户对某电影的喜爱程度;另外,通过电影所获得的评分,可统计出电影的受欢迎程度。

根据文献[30]在新用户注册阶段给出一份物品列表,要求用户对列表中的物品打分,粗粒度地掌握用户兴趣方向。文献[52]考虑了以用户为中心的方法,提出了一个基于会话和协同过滤相互作用的模型,利用该模型让用户在特定动机下提供评分等相关信息,这样用户就可以清楚地知道这样做的好处,增加了用户主动提供评级的概率。文献[53]提出的 Information Recommendation 方式研究用户之前的行为,推导出适合不同用户的约束条件并加入到用户模型中,以此预测用户接下来的行为,并诱导用户避开不喜欢的物品。

4.4.2 评论

对于新用户而言,在其进入系统之初,要求用户直接进行评论,如早期的 Last.fm 就要求新用户给出自己感兴趣的音乐类型、歌手等或喜欢的音乐名,通过这些信息简单划分新用户的兴趣范围。对于老用户而言,要求用户对消费过的物品进行评论,从而不断更新系统中用户的兴趣模式。

文献[37]在用户初始进入系统时询问是否愿意让系统用一种新方式提供更好的推荐,如果同意(当然,有的用户会不同意),就要求用户给出之前看过的 10 部电影,最后在相同精确度的前提下通过比较训练集的物品数量来决定优劣。文献[54]提出一种基于评论的移动端推荐方法,先查找与用户的过去行为相似的项目询问用户,引出用户的评论,这样的反馈可以帮助系统纠正对用户偏好的理解,并计算出一个更符合用户需求的新的推荐集。文献[55]对 3 种不同程度地交互解决新用户冷启动问题的方法进行比较,实验结果显示:允许用户自由表达喜好的模型系统中用户具有更高的“忠诚度”;仅由系统提供物品要求用户评论的模型具有更高的精确度;而将前面二者结合的模型不仅“忠诚度”没有提升,精确度也不见提高。文献[39]考虑到现实情况中严重的系统冷启动问题,一改前人给出具体物品向用户寻求评分的做法,利用人格行为调查让用户对自己给出评价(热情、具有批判精神、勇于探险等),建立用户的兴趣模式。

4.4.3 问卷

问卷形式的会话大多与分类器相结合。要求用户回答一份问卷,不同问卷的内容和侧重点不同,但都有一个目的,即通过分类缩小用户的兴趣范围。有的问卷还会根据用户对前一问题的回答结果动态调整下一个问题,以实现用户的个性化推荐。

文献[56]根据用户对节点上物品的评分高低,将用户划分成“喜爱”“不喜爱”和“未知”3 类。文献[48]提出的 IGCN (information gain through clustered neighbors)算法将决策树的中间节点转换成物品集合,利用决策树的结构,根据用户对数节点中物品集的评分选择分支,进行下一轮评分,直到达到树叶节点,实现用户分类,再针对不同的类别实现推荐。而文献[57]利用 FDT(factorized decision trees)以更细粒度地分割

问卷树的节点,不仅提高了准确率,还有效控制了算法计算复杂度的提升。文献[2]将矩阵分解融入到树结构的构造中,加速了树的构造过程。

5 主动学习策略在推荐系统中的性能评估

可以通过实际的实验来评估某一主动学习策略在推荐系统中的效果。在很多时候,实际的实验开展比较困难,因而许多研究是在用户的评分和交互数据的基础上通过模拟用户的行为来进行的。

评价主动学习在推荐系统上的效果经常采取以下的指标。

(1)推荐精度^[33,39,58]。提高系统的推荐精度是推荐系统的最终目标,主动学习的加入应该使推荐算法能在更少数目的评分上获得更高的推荐精度,如准确度、RMSE、MAE等。

(2)获取新数据数目^[7,34,59]。若策略呈现的物品超出用户认知,用户也就不能为其提供评分。主动学习应用在推荐系统中的任务就是解决推荐算法在训练集很少的情况下准确率低的问题,所以在其他条件相同的情况下,能够获取更多数据的学习策略更有优势。另外,可以计算系统询问的失败率,即在所有系统询问的项目中用户不能给出评分的项目比例,可通过失败率对策略进行动态调整。

(3)计算询问列表的时间^[28]。有的主动学习会在新用户(没有任何评分信息或者评分信息很少)进入推荐系统时让用户填写问卷,先对用户的兴趣进行粗粒度的分类或刻画,再根据用户对问卷的回答提出要询问的物品。这种策略虽然考虑到了用户能否给出评分的问题,但是执行过程复杂,计算时间较长,不利于在实际生产中应用。

(4)用户等待时间与付出努力^[35,52],即用户在获得一定精确度的推荐之前等待的时间以及付出的努力,其中涉及到推荐精度与用户付出的平衡问题。一般来说,用户付出努力的越多、等待的时间越久(反馈的越多),推荐系统的精度就越高,但是随着用户付出努力的增多,系统的用户体验就越差,用户也就有可能中途放弃,所以要找到一个相对的平衡,使得用户的等待时间和付出在可以接受的范围内,同时模型的推荐结果也够精确。

(5)NDCG^[60]。NDCG(normalized discounted cumulative gain)原是在信息检索系统中评估系统效率的,主动学习中利用NDCG衡量询问列表的质量,一定程度上体现了系统的性能,计算公式如下:

$$DCG_u = \sum_{i=1}^N \frac{r_u^i}{\log_2^{i+1}} \quad (1)$$

$$NDCG_u = \frac{DCG_u}{IDCG_u} \quad (2)$$

其中, $IDCG$ 表示 DCG 的最大值, N 表示测试集中的所有物品, r_u^i 表示用户 u 对物品 i 的真实评分。

结束语 主动学习被应用到推荐系统领域之后,很好地解决了推荐技术面临的问题。本文先分别介绍了推荐系统和主动学习的一些相关情况,接着又分4个类别综述了近年来主动学习给推荐系统带来的巨大进步及一些代表性的研究成果。

虽然主动学习在推荐领域已经取得了不错的成效,但其理论和实践应用方面仍有许多问题有待进一步研究和探讨。

(1)如何提供更为自然的界面,使得用户能够方便地提供

反馈。现在的主动学习模式使得用户需要付出额外的努力对系统选择的物品进行标记,因此大多是在用户注册时让用户进行标记。如何通过更为自然或者隐性的方式自然地获取用户的反馈,包括将标记过程和推荐过程有机融合起来,是一个需要突破的问题。

(2)尽管主动学习在实际应用中有出色的表现,但是大部分算法局限于具体问题而缺乏一般性的方案,因此需要研究能够自适应选择相应策略的方法。

(3)与强化学习相结合。强化学习提供了一种无模型而直接从系统中学习的方法,因此可以通过强化学习确定在何种情况下采取什么样的方法进行主动学习。

参考文献

- [1] CELMA Ò. Music Recommendation and Discovery in the Long Tail[J]. Ceedings of International Congress on Electron Microscopy Methods Enzymol-89, 2008, 11(1): 7-8.
- [2] KARIMI R, WISTUBA M, NANOPOULOS A, et al. Factorized Decision Trees for Active Learning in Recommender Systems [C]// IEEE International Conference on TOOLS with Artificial Intelligence. IEEE Computer Society, 2013: 404-411.
- [3] ELAHI M, RICCI F, RUBENS N. Active Learning in Collaborative Filtering Recommender Systems[J]. Computer Science Review, 2016, 20(C): 29-50.
- [4] POZO M, CHIKY R, MEZIANE F, et al. Enhancing new user cold-start based on decision trees active learning by using past warm-users predictions[J]. International Conference on Computational Collective Intelligence, 2017, 7(4): 137-147.
- [5] BOUTILIER C, ZEMEL R S, MARLIN B. Active Collaborative Filtering[C]// 19th Conference on Uncertainty in Artificial Intelligence. 2012: 98-106.
- [6] HOFMANN T. Latent semantic models for collaborative filtering[J]. ACM Transactions on Information Systems, 2013, 22(1): 89-115.
- [7] SETTLES B. Active Learning Literature Survey: Computer Science Technical Report 1648[R]. University of Wisconsin, Madison, 2010.
- [8] CASSEL S, HOWAR F, JONSSON B, et al. Active learning for extended finite state machines[J]. Formal Aspects of Computing, 2016, 28(2): 233-263.
- [9] SHARMA M, BILGIC M. Evidence-based uncertainty sampling for active learning[J]. Data Mining & Knowledge Discovery, 2016, 31(1): 1-39.
- [10] HUANG E C, PAO H K, LEE Y J. Big active learning[C]// IEEE International Conference on Big Data. IEEE, 2018: 94-101.
- [11] NARR A, TRIEBEL R, CREMERS D. Stream-based Active Learning for efficient and adaptive classification of 3D objects [C]// IEEE International Conference on Robotics and Automation. IEEE, 2016: 227-233.
- [12] LANG K J, BAUM E B. Query learning can work poorly when a human oracle is used[C]// IEEE Intl. Joint Conference on Neural Networks. 1992: 306-322.
- [13] HOI S C H, JIN R, ZHU J, et al. Semi-supervised SVM batch mode active learning for image retrieval[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2008 (CVPR

- 2008). IEEE, 2008: 1-7.
- [14] XU Z, YU K, TRESP V, et al. Representative Sampling for Text Classification Using Support Vector Machines[C]// European Conference on Ir Research. Springer-Verlag, 2003: 393-407.
- [15] JONES S, SHAO L, DU K. Active learning for human action retrieval using query pool selection[J]. *Neurocomputing*, 2014, 124(2): 89-96.
- [16] SUGIYAMA M, NAKAJIMA S. Pool-based active learning in approximate linear regression[J]. *Machine Learning*, 2009, 75(3): 249-274.
- [17] BOUGUELIA M R. An adaptive streaming active learning strategy based on instance weighting[J]. *Pattern Recognition Letters*, 2016, 70: 38-44.
- [18] BOUGUELIA M R, BELAÏD Y, BELAÏD A. A Stream-Based Semi-supervised Active Learning Approach for Document Classification[C]// International Conference on Document Analysis and Recognition. IEEE, 2013: 611-615.
- [19] ROKACH L, NAAMANI L, SHMILOVICI A. Pessimistic cost-sensitive active learning of decision trees for profit maximizing targeting campaigns[J]. *Data Mining & Knowledge Discovery*, 2008, 17(2): 283-316.
- [20] KOHRS A, BERNARD M. Improving collaborative filtering for new users by smart object selection[C]// Proceedings of International Conference on Media Features, 2001.
- [21] HOFMANN T. Collaborative filtering via gaussian probabilistic latent semantic analysis[C]// ACM SIGIR Conference. 2003: 259-266.
- [22] SCHOHN G, COHN D. Less is More: Active Learning with Support Vector Machines[C]// Seventeenth International Conference on Machine Learning. Morgan Kaufmann Publishers Inc., 2000: 839-846.
- [23] SETTLES B, CRAVEN M, RAY S. Multiple-Instance Active Learning[C]// Conference on Neural Information Processing Systems. DBLP, 2008: 1289-1296.
- [24] TONG S, KOLLER D. Support vector machine active learning with applications to text classification[J]. *Journal of Machine Learning Research*, 2001, 2(1): 999-1006.
- [25] JAN K P S, CHRISTIAN K I. Active learning with support vector machines[J]. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2004, 4(4): 313-326.
- [26] ROY N, MCCALLUM A. Toward optimal active learning through monte carlo estimation of error reduction[C]// ICML. 2001: 441-448.
- [27] GEMAN S, BIENENSTOCK E. Neural networks and the bias/variance dilemma[M]. MIT Press, 1992: 1-58.
- [28] GUAN C, LIU Q, LV J, et al. Consolidation: Metric+ Active Learning and Its Applications for Cross-Domain Recommendation[C]// IEEE/Wic/ACM International Conference on Web Intelligence and Intelligent Agent Technology. IEEE, 2016: 244-251.
- [29] SUGIYAMA M. Active Learning in Approximately Linear Regression Based on Conditional Expectation of Generalization Error[J]. *Journal of Machine Learning Research*, 2006, 7(1): 141-166.
- [30] TEIXEIRA I R, CARVALHO F D A T D, RAMALHO G L, et al. ActiveCP: A Method for Speeding up User Preferences Acquisition in Collaborative Filtering Systems[M]// Advances in Artificial Intelligence. Springer Berlin Heidelberg, 2002: 237-247.
- [31] GOLBANDI N, KOREN Y, LEMPEL R. On bootstrapping recommender systems[C]// ACM International Conference on Information & Knowledge Management. ACM, 2010: 1805-1808.
- [32] ZHAO Y, XU C, CAO Y. Research on query-by-committee method of active learning and application[C]// International Conference on Advanced Data Mining and Applications. Springer-Verlag, 2016: 985-991.
- [33] ELAHI M, RICCI F, RUBENS N. Active learning strategies for rating elicitation in collaborative filtering: A system-wide perspective[J]. *Acm Transactions on Intelligent Systems & Technology*, 2014, 5(1): 1-33.
- [34] ELAHI M, REPSYS V, RICCI F. Rating Elicitation Strategies for Collaborative Filtering[C]// E-Commerce and Web Technologies. 2011, 85: 160-171.
- [35] RASHID A M, ALBERT I, DAN C, et al. Getting to know you: learning new user preferences in recommender systems[C]// International Conference on Intelligent User Interfaces. ACM, 2002: 127-134.
- [36] PAGANO R, QUADRANA M, ELAHI M, et al. Toward Active Learning in Cross-domain Recommender Systems[J]. arXiv: 1701.02021, 2017.
- [37] KOREN Y, BELL R. Advances in Collaborative Filtering [M]// Recommender Systems Handbook. 2011: 145-186.
- [38] ELAHI M, BRAUNHOFER M, RICCI F, et al. Personality-Based Active Learning for Collaborative Filtering Recommender Systems[C]// Congress of the Italian Association for Artificial Intelligence. Cham; Springer, 2013: 360-371.
- [39] SEUNG H, OPPER S. Query by committee[J]. *Proc of the Fifth Workshop on Computational Learning Theory*, 1992, 284: 287-294.
- [40] GEIGER D. Current State of Personalized Task Recommendation[M]// Personalized Task Recommendation in Crowdsourcing Systems. Springer International Publishing, 2016: 15-29.
- [41] KRAWCZYK B, WOŃNIAK M. Online query by committee for active learning from drifting data streams[C]// International Joint Conference on Neural Networks. IEEE, 2017: 38-49.
- [42] PICCHARA K, SOTO A, ARANEDA A. Detection of Anomalies in Large Datasets Using an Active Learning Scheme Based on Dirichlet Distributions[C]// Ibero-American Conference on AI: Advances in Artificial Intelligence. Springer-Verlag, 2008: 163-172.
- [43] NGUYEN T T, PHAM H V, VU P M, et al. Recommending API Usages for Mobile Apps with Hidden Markov Model[C]// IEEE/ACM International Conference on Automated Software Engineering. IEEE, 2016: 795-800.
- [44] SHI S, LIU Y, HUANG Y, et al. Active Learning for kNN Based on Bagging Features[C]// International Conference on Natural Computation. IEEE, 2008: 61-64.
- [45] FATHIAN M, HOSEINPOOR Y, MINAEI-BIDGOLI B. Offering a hybrid approach of data mining to predict the customer churn based on bagging and boosting methods[J]. *Kybernetes*, 2016, 45(5): 732-743.

- IEEE International Conference on Cloud Computing & Big Data Analysis. IEEE, 2017.
- [17] LINGAM G, RANJAN R R, DVLN S. Learning automata-based trust model for user recommendations in online social networks [J]. Computers and Electrical Engineering, 2018, 66.
- [18] AZADJALAL M, MORADI P, ABDOLLAHPOURI A, et al. A trust-aware recommendation method based on Pareto dominance and confidence concepts [J]. Knowledge-Based Systems, 2017 (116): 130-143.
- [19] YIN C Y, WANG J, PARK J H. An Improved Recommendation Algorithm for Big data Cloud Service based on the Trust in Sociology [J]. Neurocomputing, 2017 (256): 49-55.
- [20] GOHARI F S, ALIEE F S, HAGHIGHI H A. A new confidence-based recommendation approach: Combining trust and certainty [J]. Information Sciences, 2018 (422): 21-50.
- [21] MAZUMDER R, HASTIE T, TIBSHIRANI R. Spectral Regularization Algorithms for Learning Large Incomplete Matrices [J]. Journal of Machine Learning Research, 2010, 11(11): 2287-2322.
- [22] 吴宾, 娄铮铮, 叶阳东. 联合正则化的矩阵分解推荐算法 [J]. 软件学报, 2018, 29(9): 2681-2696.
- [23] 傅敏. 基于信任和不信任的协同过滤推荐模型研究 [D]. 燕山: 燕山大学, 2012.
- [24] 王国胤, 于洪, 杨大春. 基于条件信息熵的决策表约简 [J]. 计算机学报, 2002(7): 759-766.
- [25] 毛一凡, 饶世钧. 对修正的 K 近邻域关联算法的仿真与可信性评估 [J]. 计算机仿真, 2004, 21(7): 11-13.
- [26] GOLBECK J. Filmtrust: movie recommendations from semantic web-based social networks [C] // Consumer Communications & Networking Conference. IEEE, 2006.
- [27] SALAKHUTDINOV R, MNIH A. Probabilistic Matrix Factorization [C] // International Conference on Neural Information Processing Systems. Vancouver, Canada, 2007.
- [28] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks [C] // Proceedings of the 2010 ACM Conference on Recommender Systems (RecSys 2010). Barcelona, Spain: ACM, 2010: 26-30.
- [29] 陈婷, 朱青, 周梦溪, 等. 社交网络环境下基于信任的推荐算法 [J]. 软件学报, 2017, 28(3): 721-731.
- [30] ZHANG Z, LIU Y, JIN Z, et al. A Dynamic Trust based two-layer Neighbor Selection Scheme towards Online Recommender Systems [J]. Neurocomputing, 2018, 285: 94-103.

(上接第 158 页)

- [46] ZHAO Y, XU C, CAO Y. Research on query-by-committee method of active learning and application [C] // International Conference on Advanced Data Mining and Applications. Springer-Verlag, 2006: 985-991.
- [47] RASHID A M, KARYPIS G, RIEDL J. Learning preferences of new users in recommender systems: an information theoretic approach [J]. ACM Sigkdd Explorations Newsletter, 2008, 10(2): 90-100.
- [48] CARENINI G, SMITH J, POOLE D. Towards more conversational and collaborative recommender systems [C] // International Conference on Intelligent User Interfaces. ACM, 2003: 12-18.
- [49] PENNOCK D M, HORVITZ E, LAWRENCE S, et al. Collaborative Filtering by Personality Diagnosis: A Hybrid Memory-and Model-Based Approach [C] // Proceedings of IJCAI-99. 2013: 473-480.
- [50] SETTLES B, CRAVEN M. An analysis of active learning strategies for sequence labeling tasks [C] // Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics, 2008: 1070-1079.
- [51] IKHWANTRI F, LOUVAN S, KURNIAWAN K, et al. Multi-Task Active Learning for Neural Semantic Role Labeling on Low Resource Conversational Corpus [C] // Proceedings of the 2007 ACM Conference on Recommender Systems. 2018: 37-49.
- [52] BRIDGE D, RICCI F. Supporting product selection with query editing recommendations [C] // ACM Conference on Recommender Systems. ACM, 2007: 65-72.
- [53] RICCI F, NGUYEN Q N. Acquiring and Revising Preferences in a Critique-Based Mobile Recommender System [J]. IEEE Intelligent Systems, 2007, 22(3): 22-29.
- [54] MCNEE S M, LAM S K, KONSTAN J A, et al. Interfaces for eliciting new user preferences in recommender systems [C] // International Conference on User Modeling. Springer-Verlag, 2003: 178-187.
- [55] GOLBANDI N, KOREN Y, LEMPEL R. Adaptive bootstrapping of recommender systems using decision trees [C] // ACM International Conference on Web Search and Data Mining. ACM, 2011: 595-604.
- [56] KARIMI R, WISTUBA M, NANOPOULOS A, et al. Factorized Decision Trees for Active Learning in Recommender Systems [C] // IEEE, International Conference on TOOLS with Artificial Intelligence. IEEE Computer Society, 2013: 404-411.
- [57] HERLOCKER J L, KONSTAN J A, TERVEEN L G, et al. Evaluating collaborative filtering recommender systems [J]. ACM Transactions on Information Systems, 2004, 22(1): 5-53.
- [58] HARPALE A S, YANG Y. Personalized active learning for collaborative filtering [C] // International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2008: 91-98.
- [59] SHANI G, GUNAWARDANA A. Evaluating Recommendation Systems [M] // Recommender Systems Handbook. Springer, 2011: 257-297.
- [60] LIU N N, YANG Q. EigenRank: a ranking-oriented approach to collaborative filtering [C] // International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2008: 83-90.