

基于神经网络的用户视频评分自动获取方法

纪淑娟^{1,2,4} 王 理³ 梁永全⁴ 赵建立⁴

(山东科技大学矿山灾害预防控制省部共建国家重点实验室培育基地 青岛 266590)¹

(电子商务江西省高校高水平工程研究中心 南昌 330013)²

(山东商业职业技术学院电子信息学院 济南 250103)³ (山东科技大学信息科学与工程学院 青岛 266590)⁴

摘 要 在未来的智能电视系统中,真正的智能视频推荐应该是不需要用户评分动作就能自动、准确地获得用户兴趣、爱好并做出推荐的系统。研究无评分动作约束下的用户评分(揭示了他们的兴趣和爱好)自动获取技术是真正的智能推荐必须解决的一个关键问题。给出了一种基于神经网络的用户视频隐性评分自动获取方法。基于用户视频观看行为与评分样本的实验结果表明,该方法可以有效地获取用户的隐性评分信息。

关键词 智能视频推荐,个性化推荐,隐性评分信息获取,神经网络

中图分类号 TP183 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.11.020

Neural-network-based Method for Automatic Acquisition of User's Video Rating

Ji Shu-juan^{1,2,4} WANG Li³ LIANG Yong-quan⁴ ZHAO Jian-li⁴

(State Key Laboratory of Mining Disaster Prevention and Control Co-founded by Shandong Province and Ministry of Science and Technology, Shandong University of Science and Technology, Qingdao 266590, China)¹

(High Level Engineering Research Center of Electronic-commerce, Jiangxi Provincial Colleges and Universities, Nanchang 330013, China)²

(College of Electronic and Information, Shandong Institute of Commerce and Technology, Jinan 250103, China)³

(College of Information Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China)⁴

Abstract In future intelligent system, a real intelligent video recommendation system should have the ability of automatically acquiring users' interest and preference without users' rating actions and the ability of accurately recommending videos for them. In implementing a real intelligent video recommendation system, a key problem we must solve is the design of some technologies that can acquire users' ratings (which reveal their interests and preferences) in case of no rating actions. To acquire user's implicit rating on videos automatically, this paper presented a neural-network-based method. Experimental results on samples about users' video-viewing behavior and ratings show that this method is effective in gaining users' implicit rating information.

Keywords Intelligent video recommendation, Personalized recommendation, Implicit rating acquisition, Neural network

1 引言

推荐系统是帮助人们快速发现有用信息的重要工具,它不仅可以给用户推荐符合个人兴趣的内容,还为用户节省了在海量数据中查找信息的时间。当人们面临海量信息时,推荐系统的作用日趋明显。目前大部分的视频推荐算法都是基于用户评分设计的。然而,真正的智能视频推荐系统应该是不需要用户评分动作就能自动、准确地获取用户兴趣、爱好(即评分的隐性表现)的系统。因此,研究无评分动作约束下的用户评分自动获取技术是实现真正智能视频推荐的一个关

键问题。该问题的解决依赖于两点:(1)无评分视频推荐系统中隐性用户兴趣的获取;(2)基于隐性用户兴趣建立的视频推荐算法。第一个问题是难点,也是第二个问题的基础。

已有大量研究者对用户行为量化方法(即将用户显性行为转化为用户兴趣模型或隐性评分的方法)展开研究,其中较为成熟的是基于 Web 日志的用户兴趣获取方法。也有一些学者基于用户行为和行为持续时间、行为次数研究用户对文本、商品等的兴趣。一些电影隐性评分获取方法应用了用户观看视频的时间信息。到目前为止,尚未出现将用户视频观看过程中的行为转化为用户隐性评分的方法研究。本文给出

到稿日期:2014-11-17 返修日期:2014-12-30 本文受国家自然科学基金项目(71403151),中国博士后科学基金(2014M561948),山东省自然科学基金项目(ZR2013FM023,ZR2012FM003),山东省博士后创新项目专项资金(201403007),山东省高等学校科技计划项目(J14LN33),青岛科技计划项目(KJZD-13-29-JCH),青岛市博士后研究人员应用研究项目(2014),青岛经济技术开发区重点科技发展计划(2013-1-25),山东科技大学领军人才培养计划,泰山学者建设工程专项经费,江西省电子商务高水平工程研究中心开放项目资助。

纪淑娟(1977—),女,博士,副教授,主要研究方向为人工智能、电子商务、Petri 网,E-mail:jane_ji2003@aliyun.com;王 理(1989—),女,硕士,助教,主要研究方向为电子商务推荐;梁永全(1968—),男,博士,教授,主要研究方向为分布式人工智能、电子商务、多媒体信息处理;赵建立(1977—),男,博士,副教授,主要研究方向为电子商务推荐。

一种基于神经网络的用户视频评分获取方法,它通过神经网络学习方法将系统记录的用户行为映射到用户评分,实现用户评分的获取。

本文第2节简述了基于用户隐性行为的用户兴趣/评分学习方法及推荐方法的研究现状;第3节给出了基于神经网络的用户视频评分自动获取模型;第4节通过实验对本文给出的获取模型的性能进行了分析;最后对本文的工作进行了总结,并对下一步的工作进行了展望。

2 相关工作

个性化推荐是根据用户的偏好和行为特点向用户推荐感兴趣信息的过程。推荐算法的一个关键步骤就是收集用户对物品的偏好,补全用户-项目评分矩阵中的未知项。获取用户偏好的途径主要包括显性反馈和隐性反馈两种。显性反馈是获取偏好最直接的方式,它通过用户对项目的评分或评论,将用户对项目的兴趣和偏好量化为数值^[1,2]。现有个性化推荐算法大多基于用户显性评分数值建立模型,计算推荐结果。然而,这些算法存在因用户交互界面不够友好、评分操作过于繁琐或用户的分享意愿不高等而导致用户不愿意参与评分活动的情况。因此,大多数情况下用户-项目矩阵都非常稀疏。为了减少用户操作及提高推荐准确度,一个更智能的推荐系统还应该具有挖掘用户行为信息、获取用户隐性评分的能力。以此为出发点,人们已经提出了很多用户隐性评分获取方法。下面简要介绍现有的用户隐性评分获取方法。

(1) 基于行为的隐性评分获取方法

Claypool等^[3]根据用户行为的不同将用户兴趣指标分为7种类型,即显性兴趣指标、标记兴趣指标、操作兴趣指标、导航兴趣指标、外部兴趣指标、重复兴趣指标、负面兴趣指标。根据用户的操作行为(包括鼠标点击、鼠标移动、滚动和停留时间)不同,他们还进一步提出了通过记录页面上用户的操作获取用户隐式评分的方法。同时,他们还探讨了Web浏览器中各种隐式评分与显式评分的相关性。Nichols^[4]分析了过滤信息过程中采用隐性评分的利弊,并基于用户行为对隐式评级进行了分类(如分为检查、收藏等)。Oard和Kim^[5]在Nichols^[4]隐式评级分类的基础上,将用户浏览器端行为分为检查(用户研究一个项目)、保留(用户收藏一个项目以备日后使用)和引用(用户将部分或整个项目与另一个项目关联)等几种,并提出了两种策略来应用隐式评级。基于文献^[5]总结的隐性行为指标,Zemirli^[6]研究了浏览器端的隐性偏好程度衡量方法,他基于阅读、书签、打印3类行为指标分别预测用户对候选项目的评价,以3项预测的平均值作为最终预测评分。

Hu等^[7]根据不同的置信级别将隐性偏好数据分成积极偏好和消极偏好,并结合最近邻模型和因式分解方法为隐性反馈建立抽象模型。此外,他们还在Oard和Kim^[5]成果的基础上总结了隐性反馈的4个特点:(1)没有消极反馈,获取的用户行为可以辅助人们推测出用户喜欢并选择的项目;(2)隐性反馈存在固有的噪音;(3)显性反馈的数值表明了偏好,隐性反馈的数值表明了信任度;(4)评价隐式反馈推荐结果需要适当的方式。

Puolamäki等^[8]把用户的眼动信号作为隐性反馈,通过马尔科夫判别模型预测用户兴趣;此外,他们还进一步将协同

过滤算法、用户评分模型(一个概率隐变量模型)与马尔科夫链蒙特卡理论(MCMC)融合,并通过实验证明把眼动信号和以上融合模型结合起来实现信息检索预测是可行的。

(2) 基于行为与行为时间/次数的隐性评分获取方法

大量研究表明,用户对网页的兴趣度与其在网页上的浏览行为密切相关^[9,10]。由于推荐结果产生过程通常是黑盒操作,因此Herlocker^[11]解释了为什么要利用隐性反馈,以及如何根据隐性反馈产生推荐结果。

Konstan等^[12]认为很多隐性反馈可以体现用户的偏好,比如用户是否阅读了一篇文章,阅读了多长时间等。当然,没有阅读并不能代表用户不喜欢该文章^[13]。实验结果显示,人们可以利用隐性评分进行预测,而且由阅读时长得到的预测结果与由显性评分得到的预测结果几乎一样准确。该结果在更大范围上验证了Morita和Shinoda^[14]的结论,即时间与评分存在关系,而且不需要考虑文章长度。类似地,张岚^[15]根据用户的隐性反馈建立了基于行为分析的网页兴趣度模型。该模型参考Claypool等^[3]划分的兴趣指标,选取用户浏览网页时间与页面中拖动滚动条的次数两个行为特征建立了线性回归模型。为了进一步提高模型的性能,张岚^[15]还利用用户标记、收藏、打印等行为对模型进行改进。

Choi等^[16]认为在购物过程中,一个人买一件商品多于一次,表明该用户喜欢这件商品;一个人比他人更频繁地买一件商品,就表明他比他人更喜欢这件商品。在分析已有相似度方法^[17]局限性的基础上,Lee^[2,3]将隐性评分与相似度方法结合,提出了一种适用于隐性评分的相似度计算方法。Mobasher^[18]和Anderson等^[19]将隐性反馈信息与协同过滤算法^[20]结合,针对电子商务提出了一种基于日志的协同过滤方法,并通过分析网页访问日志获得购买类型、页面访问、页面停留时间、浏览路径等隐性反馈信息得到隐性评分。

Schein等^[21-23]认为预测用户对电影的评价结果与预测用户购买商品的方法相似,他们还在解决推荐系统冷启动问题的过程中利用隐性评分预测结果作为评价算法性能的指标。Da Silva^[24]针对电视推荐系统提出一套基于内容的推荐方法,并将“内容”定义为“人物、时间、地点、做了什么、怎么做等等”。在此基础上,Uluyagmur等^[25]根据用户观看电影的时长产生该用户对该电影的隐性评分。Gantner等^[26]应用张量分解方法实现时间性情境分析,并以贝叶斯个性化排序^[27]作为评价标准研究了基于情景感知的电影推荐问题。Denis^[28]提出将隐性反馈转化为显性反馈,再利用显性数据算法进行推荐的方法,并基于音乐这种音频信息的推荐进行了实验。实验过程中选择“用户播放音乐的次数”、“用户最后听各个专辑是什么时候”、“每张专辑总共有多少人听”作为统计特征,采用混合回归的方法进行预测。与相关直接用隐性数据进行推荐的算法比较,实验结果显示,将隐性反馈转化为显性反馈,再利用显性数据算法进行推荐的方法可以获得更高的性能。

以上研究显示,对隐性评分研究较为成熟的是基于Web日志的用户兴趣获取,也有一些研究者基于用户行为和行为持续时间、行为次数研究用户对文本、商品等的兴趣。少数电影隐性评分获取方法应用了用户观看视频的时间信息,但是尚未发现对用户视频观看过程中其他行为信息的应用。本文提出一种基于神经网络的视频隐式评分学习模型。

3 基于神经网络的用户视频评分自动获取模型

为了能准确获得用户兴趣模型,无评分操作的视频系统中必须能够获取一些用户行为的数据。将这些用户观看行为自动地转换成隐性的兴趣模型或评分,不仅可以直接利用已有的显性评分推荐算法进行推荐,还可以免去用户评分动作,解决用户无评分动机和推荐系统评分稀疏的问题。本节主要介绍与用户兴趣或评分相关的视频操作行为信息和基于用户行为获取用户评分的神经网络学习方法。

3.1 视频播放系统中用户兴趣相关的行为

视频播放系统中用户评分一般受到3个因素影响:(1)视频的质量,即视频内容、适用性、画面质量等;(2)用户的偏好,即用户自身的兴趣、爱好;(3)用户的评价标准,同样一事物、同样感兴趣的人,但是严苛的人给的评分一般要比随和的人给的评分低。固定视频资源的情况下,用户评分与用户的偏好和评价标准密切相关。

一般情况下,用户在观看视频过程中可能涉及的行为有播放、快进、快退、暂停、关闭等。由于暂停和关闭可能与用户的休闲时间长短、其他行为相关,因此本文不考虑这两个动作。本文认为与播放、关闭、快进、快退4个动作相关的用户实际观看累计总时长(L)、用户观影过程中的后退次数(BN)、前进次数(FN)和用户所观看视频的总时长(T)与用

户的评分(R)密切相关。在给定电影总时长的情况下,实际观看累加时间越长,说明用户对该电影越有兴趣;同样,后退次数越多、前进次数越少,也表明用户对该电影的兴趣越大。在这些行为的基础上,本文采用神经网络学习算法学习一个实现 L, T, BN, FN 到 R 映射的模型。

3.2 基于神经网络的用户视频评分自动获取模型

神经网络(Artificial Neural Network, ANN)是由许多被称为神经元的基本计算单元通过广泛链接所组成的自适应非线性动态系统。神经网络通过神经元之间的交互提取数据中的相关特征或内在规律^[29]。神经网络有较强的自适应力,使用学习算法可以自动恢复网络中变化的连接权值;另一方面,神经网络有较强的学习能力,能够通过学习外界环境改进自身功能。

由于神经网络的以上特点,本文采用神经网络作为用户隐性评分的学习方法,其结构如图1所示。该神经网络包含4个输入和1个输出,其中输入包括总时长 T 、实际观看时长 L 、后退次数 BN 、前进次数 FN ;输出为预测评分 R (为 $0 \sim 5$ 的整数值)。式(1)定义了该神经网络模型中输出与输入之间的关系。

$$R = f\left(\sum_{i=1}^4 w_i x_i - \theta\right) \quad (1)$$

其中, x_i 表示第 i 项输入(即 T, L, BN, FN 4个输入之一), w_i 表示该项输入的权值, θ 为偏置。

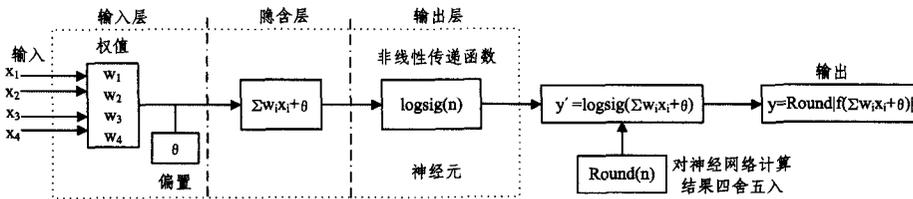


图1 基于神经网络的用户视频评分自动获取模型

神经网络算法的目标是通过大量训练实例学习式(1)中各输入变量的权值 w_i 和偏置 θ 。为了得到 $0 \sim 5$ 的整数输出值,本文应用 logsig 函数(见式(2))作为该神经网络传递函数,并在训练后对结果进行四舍五入。

$$\text{logsig}(n) = \frac{1}{1 + \exp(-n)} \quad (2)$$

4 实验与分析

为了评价第3节给出的神经网络模型的性能,本文应用我们开发的电影推荐系统¹⁾收集了3组样本并设计了3套实验。第一套实验旨在验证模型预测评分的速度和准确性;第二套实验旨在验证模型预测评分的可伸缩性;第三套实验旨在验证模型预测评分的鲁棒性。

4.1 实验设置

如表1所列,第一套实验选取155例随机样本,其中60%作为训练集,40%作为测试集;第二套实验分别选取155例随机样本、465例随机样本两组样本集进行实验,每组样本各取60%作为训练集,40%作为测试集;第三套实验分别选取155例随机样本和155例临界点样本集,通过交叉训练、验证观察模型对边缘数据的处理能力。第三套实验分为两组,第一组首先以随机样本训练集训练神经网络模型,然后对比

随机样本和临界点样本验证集的验证结果;第二组则分别以随机样本和临界点样本训练集对神经网络训练,以随机样本验证集作验证集。这两部分旨在比较训练样本集和验证样本集的不同特点对验证结果的影响。这些实验都设置神经网络学习速率为0.05,动量因子为0.8,最大迭代次数为3000。

表1 实验样本设置

实验	训练样本集	测试样本集
第一套实验	随机样本 155 例 * 60%	随机样本 155 例 * 40%
第二套实验	随机样本 155 例 * 60%	随机样本 155 例 * 40%
	随机样本 465 例 * 60%	随机样本 465 例 * 40%
第三套实验	随机样本 155 例 * 60%	随机样本 155 例 * 40%
	临界点样本 155 例 * 60%	临界点样本 155 例 * 40%

上述实验中涉及的临界点样本是指电影长度、观影累加时长、用户后退次数和快进次数4个变量中的任意3个变量对应相同的情况下,另一变量的少量增加或者少量降低造成 R 值变化的样本。以临界点样本进行实验的意义在于检验模型对预测边缘数据评分的适应能力,以及寻求提高预测评分准确性的方法。

本文样本具有如下特点:电影长度取值为90分钟、100

¹⁾ 国家重点基础研究发展规划项目(973)子课题“基于普适计算环境下的智能推荐算法研究和系统建模”中开发的电影推荐实验平台。

分钟和 120 分钟;观看累加时间为到当前时间为止用户已经观看该电影的总时长(如果看过多次,则为每次时长的累加值);后退次数和前进次数的最小值都为 0,最大值都为 10;真实评分分别是 1、2、3、4、5 级。

4.2 评估标准

本文以预测评分程序运行时长、失误差率、平均绝对误差(MAE)作为评估标准。程序运行时长越短,表示神经网络模型预测评分的速度越快。采用失误差率(即预测错误的比例)作为衡量模型准确性的第二个标准,失误差率越低,表示神经网络模型的命中率越高,准确性也越好。选择它作为评估标准之一的原因是本文构造的神经网络模型每次预测失误差最大为 1 分(估计的用户评分比真实值要么高出 1 分,要么低 1 分),偏差较大,因此传统的计算平均绝对误差的方法不能完全体现模型性能。平均绝对误差是验证模型预测准确率的重要指标,虽然在本文提出的模型中 MAE 由于偏差较大不能完全反映模型的准确性,但是在与失误差率结合分析的过程中可以评估到每次预测失误差产生的偏差范围。当 MAE 与失误差率相等时,说明每次失误差的偏差都为最大值,即 1。

为了验证本文给出的神经网络模型的可伸缩性,第一套实验采用失误差率和平均绝对误差作为评估标准,失误差率和平均绝对误差越小越好;第二套、第三套实验以失误差率为标准验证基于两组样本训练得到的神经网络模型的性能,失误差率越低,表示该模型性能越好。

4.3 实验结果分析

(1)速度和准确性实验结果分析

实验对验证集样本反复预测评分 20 次,速度和准确性的结果如表 2 所列,失误差率和平均绝对误差如图 2 所示。由表 2 可知,实验中对 155 个样本中的 62 个测试样本评分进行预测,最短用时 0.015s,最长用时 0.046s,平均用时 0.024s。实验结果表明程序预测评分用时较短,即神经网络模型预测评分速度较快。模型预测评分的失误差率在 15%上下浮动,且较为稳定,失误差率较低,预测评分的命中率较高。通过对比实验的失误差率与 MAE(见图 2)发现,两曲线趋势大致相同,且两组数字差值较小。由此可以看出,基于随机样本的平均每次预测失误差的偏差较小,且根据观察,大多数实验偏差为最小值 1。

表 2 评分预测速度和准确性

运行时长(s)	误差(个)	失误差率	预测评分 MAE	
1	0.032	9	14.52%	0.1452
2	0.015	9	14.52%	0.1452
3	0.016	10	16.13%	0.1613
4	0.031	9	14.52%	0.1452
5	0.032	10	16.13%	0.1613
6	0.015	10	16.13%	0.1613
7	0.016	8	12.90%	0.1290
8	0.015	9	14.52%	0.1452
9	0.032	10	16.13%	0.1613
10	0.031	9	14.52%	0.1452
11	0.046	10	16.13%	0.1613
12	0.032	8	12.90%	0.1290
13	0.015	9	14.52%	0.1452
14	0.031	9	14.52%	0.1452
15	0.031	10	16.13%	0.1452
16	0.015	8	12.90%	0.1290
17	0.016	10	16.13%	0.1613
18	0.031	11	17.74%	0.1774
19	0.016	9	14.52%	0.1452
20	0.031	9	14.52%	0.1452
平均	0.02495	9.3	15.00%	0.1492

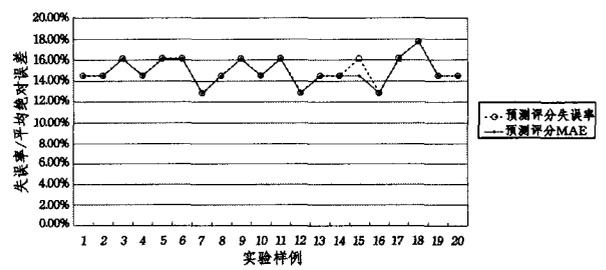
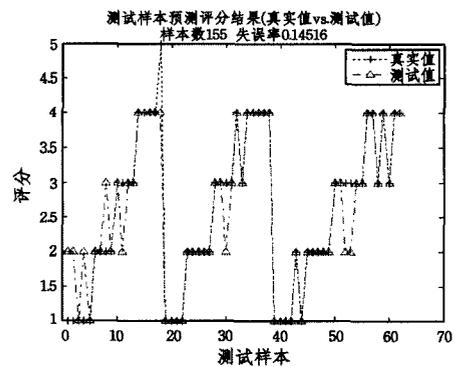


图 2 预测评分失误差率与平均绝对误差的比较

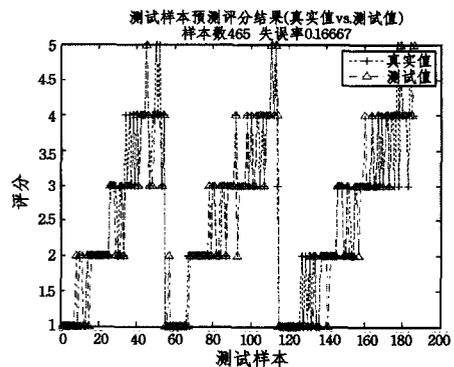
结论 1:模型预测评分的速度较快,准确性较高。

(2)可伸缩性实验结果分析

实验结果如图 3 所示,模型在 155 例样本的实验中失误差率为 0.145(见图 3(a)),在 465 例样本的实验中失误差率为 0.167(见图 3(b))。由该结果可知,模型在加大样本数据量的情况下,失误差率浮动较小,准确性维持在较高水准,证明模型具有较好的可伸缩性。



(a)模型在 155 例样本集上的表现



(b)模型在 465 例样本集上的表现

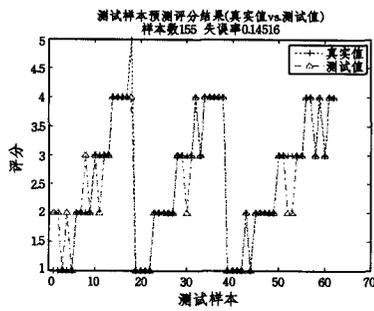
图 3 基于两个样本集的预测结果

结论 2:在加大样本的情况下,模型失误差率浮动较小,准确性维持在较高水平,模型具有较好的可伸缩性。

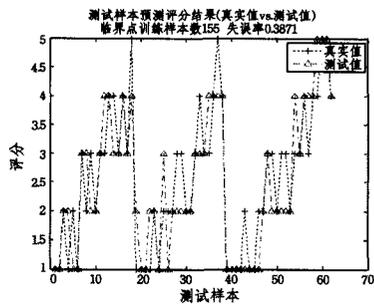
(3)鲁棒性实验结果分析

随机样本和临界点样本验证集上的实验结果如图 4 所示。由该图可知,基于随机样本训练得到的神经网络在随机样本和临界样本验证集上失误差率分别为 0.145(见图 4(a))和 0.387(见图 4(b))。由此可知,临界点样本对模型预测评分准确性的影响较大。分别以随机样本和临界点样本对神经网络进行训练,再以随机样本作为测试集验证训练好的神经网络模型,得到的实验结果如图 5 所示。由该图可知,以随机样本训练神经网络的预测失误差率为 0.145(见图 5(a)),以临界点样本训练神经网络的预测失误差率为 0.097(见图 5(b)),后

者失误率降低了 1/3。由此可知,由临界点样本训练出的神经网络模型的预测准确率更高。

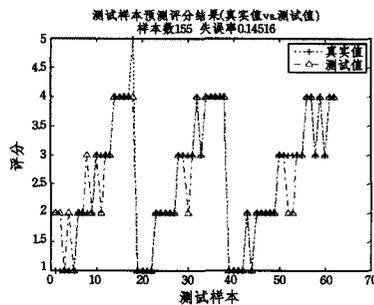


(a) 随机样本的测试结果

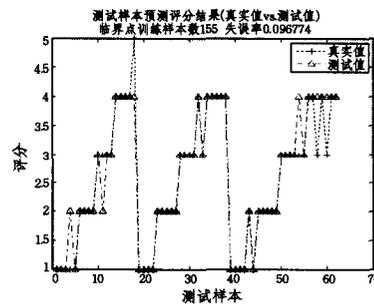


(b) 临界点样本的测试结果

图 4 基于随机训练样本训练得到的预测结果



(a) 基于随机样本训练得到神经网络的测试结果



(b) 基于临界点样本训练得到神经网络的测试结果

图 5 在随机测试样本集上的预测结果

结论 3: 基于随机样本训练得到的神经网络模型预测随机数据时准确率较高,但是预测临界点数据时准确率大大降低。

结论 4: 在对随机数据的预测中,模型的正确率受训练样本的影响比较大;利用临界点样本进行神经网络训练可以提高随机样本预测的准确率。

结束语 现有个性化推荐算法具有如下两个特点:(1)大多基于用户显性评分数值建立模型;(2)推荐算法所依赖的用户-项目矩阵非常稀疏。为了解决用户-项目矩阵非常稀疏的

问题,提出了一种基于神经网络的用户隐性评分自动学习模型。该模型的主要特点是不需要用户执行任何评分动作,基于电影的长度、用户观影时间、观影过程中与兴趣相关的行为次数等信息实现用户隐性评分/兴趣的学习。

为了分析该模型的性能,本文设计了 3 套实验分别验证模型的预测速度、准确性、可伸缩性和鲁棒性。实验结果表明:(1)模型预测评分的速度较快,准确率在 75%左右浮动;(2)在增加样本数目的情况下,模型失误率浮动较小,准确率仍可维持在 74%左右,模型具有较好的可伸缩性;(3)基于随机样本训练得到的神经网络模型预测随机数据时准确率较高(大约为 85%),但在预测临界点数据时,准确率大大降低(大约为 61%);(4)在对临界点数据的预测中,基于随机样本训练的神经网络的预测准确率远远低于基于临界点样本训练的神经网络的预测准确率,利用临界点样本进行神经网络训练可以显著提高随机样本预测准确率(从 75%提高到 81%)。

虽然本文给出的神经网络模型可以有效地实现从用户行为、行为次数等信息中学习用户对视频的兴趣/评分,但是该隐性评分模型预测准确率受训练样本的影响较为严重,整体的预测准确率比较低。这主要是因为该模型中未考虑用户评估标准的偏差性。在以后的工作中,将通过进一步细化用户兴趣的行为因素,考虑用户评估标准的偏差,探索其他机器学习方法(如 logistic 回归等)来提高预测准确率。

参考文献

- [1] Lee T-Q, Park Y, Park Y-T. A similarity measure for collaborative filtering with implicit feedback[M]// With Aspects of Artificial Intelligence. Berlin Heidelberg: Springer-Verlag, 2007: 385-397
- [2] Lee T-Q, Park Y, Park Y-T. An empirical study on effectiveness of temporal information as implicit ratings [J]. Expert systems with Applications, 2009, 36(2): 1315-1321
- [3] Claypool M, Le P, Waseda M, et al. Implicit interest indicators [C]// Proceedings of the 6th International Conference on Intelligent User Interfaces, 2001. New York: ACM, 2001: 33-40
- [4] Nichols D. Implicit Rating and Filtering[C]// Proceedings of the 5th DELOS Workshop on Filtering and Collaborative Filtering, 1998. Budapest: ERCIM, 1998: 31-36
- [5] Douglas O, Jinmook K. Implicit feedback for recommender systems[C]// Proceedings of the AAAI Workshop on Recommender Systems, 1998. AAAI, 1998: 81-83
- [6] Nesrine Z. WebCap: Inferring the user's interests based on a real-time implicit feedback[C]// Seventh International Conference on IEEE Digital Information Management, 2012. IEEE, 2012: 62-67
- [7] Hu Yi-fan, Yehuda K, Chris V. Collaborative filtering for implicit feedback datasets[C]// Eighth IEEE International Conference on Data Mining, 2008. IEEE, 2008: 263-272
- [8] Kai P, Jarkko S, Eerika S, et al. Combining eye movements and collaborative filtering for proactive information retrieval[C]// Proceedings of the 28th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 2005. New York: ACM, 2005: 146-153

(下转第 129 页)

- [17] 许伟涛,徐扬. 语言真值格值命题逻辑系统中广义文字的归结判定[J]. 计算机科学, 2013, 40(2): 208-211
Xu Wei-tao, Xu Yang. Resolution Determination of Generalized Literals in Linguistic Truth-valued Lattice-valued Propositional Logic System[J]. Computer Science, 2013, 40(2): 208-211
- [18] 徐扬,秦克云. 格值命题逻辑(I)[J]. 西南交通大学学报, 1993, 28(1): 123-128
Xu Yang, Qin Ke-yun. Lattice-valued Propositional Logic (I) [J]. Journal of Southwest Jiaotong University, 1993, 28(1): 123-128
- [19] 秦克云,徐扬. 格值命题逻辑(II)[J]. 西南交通大学学报, 1994, 29(2): 22-27
Qin Ke-yun, Xu Yang. Lattice-valued Propositional Logic (II) [J]. Journal of Southwest Jiaotong University, 1994, 29(2): 22-27
- [20] 张家锋,徐扬,何星星. 格值语义归结推理方法[J]. 计算机科学, 2011, 38(9): 201-204
Zhang Jia-feng, Xu Yang, He Xing-xing. Lattice-valued Semantic Resolution Reasoning[J]. Computer Science, 2011, 38(9): 201-204

(上接第 100 页)

- [9] 王继民,彭波. 搜索引擎用户点击行为分析[J]. 情报学报, 2006 (2): 154-162
Wang Ji-min, Peng Bo. User behavior analysis for a large-scale search engine [J]. Journal of the China Society for Scientific and Technical Information, 2006(2): 154-162
- [10] Shen Rui-min, Han Peng, Yang Fan, et al. An open framework for smart and personalized distance learning[M]//Advances in Web-Based Learning. Berlin Heidelberg, Springer-Verlag, 2002: 19-30
- [11] Jonathan H, Joseph K, John R. Explaining collaborative filtering recommendations[C]//Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work, 2000. New York: ACM, 2000: 241-250
- [12] Joseph K, Bradley M, David M, et al. GroupLens: applying collaborative filtering to Usenet news [J]. Communications of the ACM, 1997, 40(3): 77-87
- [13] Zeno G, Steffen R, Christoph F, et al. MyMediaLite: A free recommender system library[C]//Proceedings of the fifth ACM conference on Recommender systems. New York: ACM, 2011: 305-308
- [14] Masahiro M, Yoichi S. Information filtering based on user behavior analysis and best match text retrieval[C]//Proceedings of the 17th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Springer-Verlag, 1994: 272-281
- [15] 张岚. 基于学习行为的用户兴趣建模及应用研究[D]. 济南: 山东大学, 2012
Zhang Lan. Research on user interest model and application based on learning behaviors[D]. Jinan: Shandong University, 2012
- [16] Keunho C, Donghee Y, Gunwoo K, et al. A hybrid online-product recommendation system: Combining implicit rating-based collaborative filtering and sequential pattern analysis [J]. Electronic Commerce Research and Applications, 2012, 11(4): 309-317
- [17] Paul R, Neophytos I, Mitesh S, et al. GroupLens: an open architecture for collaborative filtering of net news[C]//Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work. New York: ACM, 1994: 175-186
- [18] Bamshad M, Robert C, Jaideep S. Automatic personalization based on Web usage mining[J]. Communications of the ACM, 2000, 43(8): 142-151
- [19] Corin A, Pedro D, Daniel W. Personalizing web sites for mobile users[C]//Proceedings of the 10th international conference on World Wide Web, 2001. New York: ACM, 2001: 565-575
- [20] John B, David H, Carl K. Empirical analysis of predictive algorithms for collaborative filtering[C]//Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence, 1998. Burlington: Morgan Kaufmann Publishers, 1998: 43-52
- [21] Andrew S, Alexandrin P, Lyle U. Generative models for cold-start recommendations [C]//Proceedings of the 2001 SIGIR Workshop on Recommender Systems, 2001. 2001
- [22] Alexandrin P, Rin P, Lyle U, et al. Probabilistic models for unified collaborative and content-based recommendation in sparse-data environments[C]//Proceedings of the Seventeenth Conference on Uncertainty in Artificial Intelligence. Burlington: Morgan Kaufmann Publishers, 2001: 437-444
- [23] Andrew S, Alexandrin P, Lyle U. Methods and metrics for cold-start recommendations[C]//Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 2002. New York: ACM, 2002: 253-260
- [24] Fábio S, Luiz A, Graca B. PersonalTVware: A proposal of architecture to support the context-aware personalized recommendation of TV programs [C]//European Interactive TV Conference, 2009. Leuven, Belgium, 2009
- [25] Mahiye U, Zehra C, Esengul T. Content-based movie recommendation using different feature sets [C]//Proceedings of the World Congress on Engineering and Computer Science. San Francisco, 2012: 517-521
- [26] Zeno G, Steffen R, Lars S-T. Factorization models for context-/time-aware movie recommendations [C]//Proceedings of the Workshop on Context-Aware Movie Recommendation, 2010. New York: ACM, 2010: 14-19
- [27] Steffen R, Christoph F, Zeno G, et al. BPR: Bayesian personalized ranking from implicit feedback [C]//Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. Arlington: AUAI Press, 2009: 452-461
- [28] Denis P, Alexandros K, Xavier A, et al. Implicit feedback recommendation via implicit-to-explicit ordinal logistic regression mapping [C]//Proceedings of the 3rd Workshop on Context-Aware Recommender Systems, 2011
- [29] 张立毅. 神经网络盲均衡理论、算法与应用[M]. 北京: 清华大学出版社, 2013
Zhang Li-yi. Blind equalization theory, algorithm and application of neural network [M]. Beijing: Tsinghua university press, 2013