



引用格式:赵丽坤,王于可. 基于人工智能的社交网络用户行为数据周期推荐算法[J]. 科学技术与工程, 2020, 20(28): 11647-11652

Zhao Likun, Wang Yuke. The recommendation algorithm of social network user behavior data cycle based on artificial intelligence[J]. Science Technology and Engineering, 2020, 20(28): 11647-11652

基于人工智能的社交网络用户行为数据周期推荐算法

赵丽坤¹, 王于可²

(1. 长春医学高等专科学校计算机教研室, 长春 130000; 2. 吉林大学计算机学院, 长春 130012)

摘要 为提高社交网络个性化服务质量,研究数据周期推荐算法的重大意义,针对传统推荐算法相似度计算准确率不高,导致推荐结果精度低、召回率低和耗时长等问题,提出一种基于人工智能的社交网络用户行为数据周期推荐算法。首先依据用户行为建立评分矩阵,利用皮尔逊相关系数计算评分矩阵评分值与网络行为数据相似度,依据计算得出的相似度以协同过滤为核心来检出需要推荐的社交网络用户数据内容,其次利用Top-N法生成用户邻居集,最后实现社交网络用户行为数据内容周期推荐。实验测试结果表明,所提算法的相似度计算准确率较高,网络用户行为数据周期推荐结果精度可高达97.2%,且推荐结果召回率高、耗时低,提高了社交网络个性化服务质量。

关键词 协同过滤; 社交网络; 用户行为; 相似度; 数据推荐

中图法分类号 TP391; 文献标志码 A

The Recommendation Algorithm of Social Network User Behavior Data Cycle Based on Artificial Intelligence

ZHAO Li-kun¹, WANG Yu-ke²

(1. Computer Teaching and Research Office, Changchun Medical College, Changchun 130000, China;

2. Computer College, Jilin University, Changchun 130012, China)

[Abstract] In order to improve the quality of personalized service of social networks and study the significance of data cycle recommendation algorithm, a social network user behavior data cycle recommendation algorithm based on artificial intelligence was proposed. It aimed to solve the problems of low similarity calculation accuracy, low recall rate and long time consuming of traditional recommendation algorithm. Firstly, a scoring matrix was established based on user behavior, and Pearson correlation coefficient was used to calculate the similarity between scoring matrix and network behavior data. According to the similarity, cooperative filtering was used as the core to detect recommended user data content in social networks. Secondly, Top-N method was used to generate user neighborhood set. Finally, the social network user behavior data content cycle recommendation was realized. The experimental results show that the proposed algorithm has high accuracy of similarity calculation. The accuracy of recommended results of network user behavior data cycle can be as high as 97.2%, and the recall rate of recommended results is high and the time consuming is low, which improves the quality of personalized service of social networks.

[Key words] collaborative filtering; social networks; user behavior; semblance; data recommendation

社交网络在人们的工作、学习和生活中发挥着重要的作用,人们之间的互动、交流方式不再局限于时间、地点。然而,随着社交平台用户数量的增多,以用户为中心的信息生产模式造成了社交平台数据的大量增长,引发信息过载问题^[1],人们要想在庞大的数据信息中快速、准确寻找到自己所需要的内容较为困难。为此,相关专家提出了以搜索引擎为核心的数据信息检索与推荐技术,其原理是通过用户输入相关词汇来实现信息检出,进而完成数据推荐,然而受用户对关键信息的提取与描述的影

响,这种方法检出的信息质量不高,因此数据推荐精度并不能得到很好的保证^[2]。

李凯凯等^[3]通过移动社交网络用户行为和偏好的预测机制的建立进行了基于移动社交网络的用户情景化偏好预测、采集和识别研究;冉晓斌等^[4]进行实证分析Tobit模型对个体特征信息和使用行为数据,证实个体特征调节同伴活跃度与个体活跃度之间的关系;乔少杰等^[5]提出一种新的基于模块度聚类和图计算思想面向复杂网络大数据的重叠社区检测算法,使得识别准确率增加;莫文杰

等^[6]所做研究表明,基于移动 sink 节点与集合节点的优化分簇算法与已有的低功耗自适应分簇算法相比,具有良好的能耗均衡性;王保华等^[7]采用基于以平均负载率为中心的预测域的免疫遗传算法对优化模型进行全局最优求解,使 MVB(multifunction vehicle bus)网络的负载能力得到提高,加强系统的控制;包涛等^[8]集成了五种不同性能的 AI 算法进行无功优化计算,用以指导电网对无功投切量和变压器变比等参数的优化调整;郭昆等^[9]在人工数据集和真实数据集上的实验表明,文中算法可以有效应对网络结构突变和增量计算累积误差带来的影响,降低时间复杂度。但以上文献研究有关社交网络用户行为数据周期部分内容需要用户提供明确关键词才可完成信息检索,在一定程度上受到用户本身的限制,忽视了人工智能的先进性与重要性。

针对上述问题,以协同过滤为核心研究一种推荐算法,以用户以往社交行为和数据基础,建立一个相关模型,从而为用户主动推荐所需要或感兴趣的数据信息。根据上述描述,基于人工智能的社交网络用户行为数据周期推荐算法共分为三个部分:首先根据用户行为建立评分矩阵,然后计算评分矩阵与网络数据内容相似度并进行相似度排序,最后将相似度最高的 N 个数据项目推荐给用户。与传统推荐算法相比,基于人工智能 ($\{a, b\}$ 协同过滤) 的社交网络用户行为数据周期推荐算法性能更好,为测试本文推荐算法的有效性,进行仿真测试,以便用户快速寻找所需信息,提高社交平台服务质量。

1 协同过滤下社交网络用户行为数据周期推荐算法

随着互联网技术的广泛应用,社交网络平台上的用户能够轻而易举地获得大量数字信息资料,然而面对这些庞大的数据信息,如何从中有效识别出自己所需要的信息成为用户面临的一大问题^[10]。面对上述信息超载现象,个性化信息服务技术成为研究的重点课题。人们力求在人工智能的帮助下,使得社交网络平台能够自动识别出用户当前感兴趣的信息内容,从而实现为用户主动推荐。

在社交网络平台上经常会主动搜索一些自己感兴趣的内容,如电影、美食、音乐、明星等,将这一搜索过程转变为完全自动化的推荐过程,就被称为推荐协同信息过滤^[11],简称协同过滤,其基本原理如图 1 所示。

协同过滤是依据信息交流平台用户的历史行为分析其兴趣爱好,然后通过计算用户兴趣爱好数据内容的相似性来找到与用户兴趣爱好相似的群

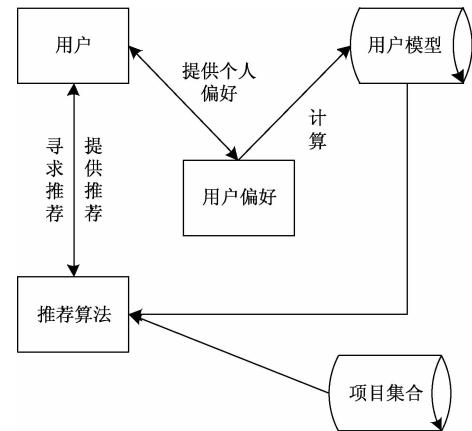


图 1 推荐协同信息过滤基本原理

Fig. 1 Basic principle of recommended collaborative information filtering

体^[12],最后将相似性较高的前 N 个群体推荐给用户的过程。下面对协同过滤过程进行形式化描述。

设 A 为社交网络用户行为数据集合, B 为待推荐数据集合, 用户对某一项目的查询历史通过一个矩阵来表示, 公式如下:

$$\begin{cases} -1 < T = |A| \otimes |B| < 0, & \text{无兴趣} \\ 0 < T = |A| \otimes |B| < 1, & \text{有兴趣} \end{cases} \quad (1)$$

式(1)中: $a \in A$ 代表用户, $b \in B$ 代表集合 B 中第 b 项目; T 表示评价矩阵, 其中每一项 $t_{ab} \in \{-1, 0, 1\}$ 都代表用户 a 对项目 b 的搜寻, “-1” 表示用户对项目 b 不感兴趣, “0” 表示用户 a 对项目 b 未关注, “1” 表示用户 a 对项目 b 感兴趣, 由此可得:

$$\begin{cases} -1 < T = |A| \otimes |B| < 0, & \text{无兴趣} \\ 0 < T = |A| \otimes |B| < 1, & \text{有兴趣} \end{cases} \quad (2)$$

给定一个用户项目对, 令 $Q\{a, b\}$ 代表用户 a 对项目 b 的感兴趣程度, 即 $Q \in \{A \otimes B \rightarrow T\}$ 。给定一个待推荐数据集合列表 C , 根据 $Q\{a, b\}$ 计算 C 中每个项目的得分, 表示如下:

$$R_a = \operatorname{argtop}_{b \in C} NQ\{a, b\}, \quad \forall a \in A \quad (3)$$

根据式(3)能够获取得分结果, 然后根据分值按照从大到小的顺序排列, 将得分最高的前 N 个项目 R_a 作为该用户行为数据^[13], 进行用户感兴趣程度数据周期推荐。

1.1 建立评分矩阵

协同过滤下的社交网络用户行为数据周期推荐算法, 是在以下前提条件下进行的, 也就是说, 若用户在进行某些项目的测试, 得到的分数结果接近, 则其在进行其他种类的项目测试, 得到分数结果也较接近^[14]。因此, 协同过滤的核心步骤是依据用户对特定项目的喜爱程度创建评分规则矩阵, 即利用用户的浏览记录、点击、收藏内容等作为评分

指标,对用户的感兴趣项进行打分,以此建立评分矩阵,如表1所示。

表1 用户-项目评分矩阵
Table 1 User item rating matrix

用户	项目 B1	项目 B2	...	项目 Bb	...	项目 Bn
用户 A1	T11	T12	...	T1b	...	T1n
用户 A2	T21	T22	...	T2b	...	T2n
⋮	⋮	⋮		⋮		⋮
用户 Am	Tm1	Tm2	...	Tmb	...	Tmn

注:Tmb是用户Am对项目Bb的评分,表中的每一个数值表示一名用户对一个项Administrator评分值,评分矩阵值的大小对应数据周期内容推荐强度。

1.2 计算相似性

一般情况下,只要寻找到与用户兴趣爱好相近的项目,就可完成数据周期推荐^[15],而寻找到相近的项目就需要进行相似性计算问题研究。一般相似性计算方法有两种:皮尔逊相关系数相似度、余弦相似度计算。

1.2.1 皮尔逊相关系数相似度计算

Pearson(皮尔逊)相关系数,又被称为Pearson积差关联性系数,对于延续的变量之间的系数关联性,起到衡量作用,其取值范围为[-1,1]^[16],公式表示为

$$P(a,b) = \frac{\sum_{I_{aa'}} (S_{ab} - \bar{S}_a)(S_{a'b} - \bar{S}_{a'})}{\sqrt{\sum_{I_{aa'}} (S_{ab} - \bar{S}_a)^2 (S_{a'b} - \bar{S}_{a'})^2}} \quad (4)$$

式(4)中:P(a,b)为系数关联相似性;I_{aa'}表示持续变量的用户a和用户a'之间联合测评项目集合数据量;S_a和S_{a'}分别表示变量过后用户a和用户a'对全部项目测评结果的平均量;S_{ab}和S_{a'b}分别为用户a和用户a'对项目b的测评分数结果。

1.2.2 余弦相似度计算

用户a和用户a'通过两个n维向量I_a和I_{a'}来表示,则二者之间的相似度为

$$P(a,b) = \cos(I_a, I_{a'}) = \frac{I_a \cdot I_{a'}}{\|I_a + I_{a'}\|} \quad (5)$$

式(5)中:cos(I_a, I_{a'})为向量I_a和I_{a'}之间的夹角余弦值,其值越大,用户之间的相似度就越大,反之则越小^[17-18]。

然而上述标准的余弦相似度与用户自身制定的评分标准有着直接关系,标准定得过高或过低均会对相似度计算结果产生直接影响。为此,需要进行修正,公式为

$$P(a,b) = \frac{\sum_{I_{aa'}} (S_{ab} S_{a'b})}{\sqrt{\sum_{I_a} (S_{ab})^2} \sqrt{\sum_{I_{a'}} (S_{a'b})^2}} \quad (6)$$

式(6)中:I_{aa'}为修正后用户a和用户a'配合测评项目的集合量;I_a表示用户a测评过后的子集;I_{a'}表示用户a'测评过后的子集。

根据上述分析,选择皮尔逊相关系数方法对用户之间的相似度进行计算。根据皮尔逊相关系数方法的相关公式[式(4)]可知计算公式为

$$P(t,m) = \cos(I_{tm}, I_t) = \frac{I_{tm} \cdot I_t}{\|I_{tm} + I_t\|} \quad (7)$$

1.3 社交网络用户行为数据周期推荐实现

在上述的基础上,根据已经计算好的相似度生成用户邻居集,实现社交网络用户行为数据周期推荐。在这里生成用户邻居集的方法有两种:一是阈值法,即通过判断相似度是否大于设定阈值,当大于阈值时,该用户就是目标用户最近的邻居,也就是要推荐的数据^[19-20]。二是Top-N法,其原理是按照从大到小的顺序自动生成推荐列表,然后取其中相似度最高的前N个用户组成集合,也就是说,按照一定顺序排列组合,最终依据用户对测评项目结果的满意程度选取最佳偏好,实现非测评项目的预测目的,并形成集合推荐给用户,即要推荐的周期数据,形成数据集。典型预测公式为

$$F_{a,b} = \frac{\sum_{a' \in A} T_{a',b}}{n} \quad (8)$$

转换为

$$F_{a,b} = k \sum_{a' \in A} P(a,b) T \quad (9)$$

$$k = \frac{1}{|\sum_{a' \in A} P(a,b)|} \quad (10)$$

式中:F_{a,b}为预测偏好值。

综合前面的描述,协同过滤下的社交网络用户行为数据周期推荐算法实现过程如图2所示。

STEP 1 根据用户评分建立m×n用户-项目评分矩阵。

STEP 2 计算邻域间目标用户的相似性,且依据用户对项目的满意程度和契合程度规划相近的邻域集。

STEP 3 利用Top-N法建立推荐列表,实现社交网络目标用户行为数据周期推荐。

2 实验结果与分析

在算法设计完成后,需要进行性能测试,以验证本文算法的性能以及推荐质量。实验采集GaGaMatch社交平台(www.gagamatch.com)的1 000位用户数据,包括用户的浏览记录、点击、收藏内容等,将其兴趣爱好定为电影、美食、美妆及影视明星等,并进行用户-项目评价打分,产生约1 000万个

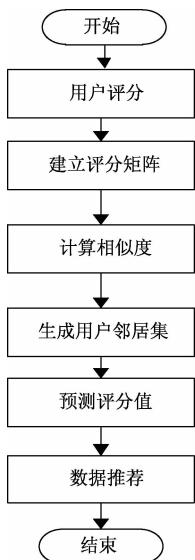


图 2 协同过滤下社交网络用户行为数据周期推荐算法

Fig. 2 Recommendation algorithm of social network user behavior data cycle under collaborative filtering

评分数据,以此作为实验测试数据,进行社交网络用户行为数据周期推荐性能分析。

在 MATLAB 环境下进行实验分析,运行系统为 Windows 8。实验参数设置如表 2 所示。

表 2 软硬件环境配置

Table 2 Software and hardware environment configuration

名称	参数
CPU	Intel Core(TM) i5-4590@ 3.30 GHz
内存	4.00 GB
操作系统	64 位 Windows8 专业版
开发语言	Python
编程环境	Eclipse4.2
编译器	JetBrains PyCharm Community Edition

2.1 测试指标

选取以下几个评价指标进行实验测试分析,具体如下:

(1) 相似度计算准确率。相似度计算结果的准确率对于推荐效果具有重要影响,以相似度计算准确率为指标验证本文算法的有效性。

(2) 推荐精度 Z 。

$$Z = \frac{1}{n} \sum (v - v') \quad (11)$$

式(11)中: n 为社交网络中用户的打分项目数量; v 为用户的实际打分; v' 为用户的预测打分。

(3) 召回率 L 。

$$L = \frac{\sum [\alpha(a) \cup \beta(a)]}{\sum_{a \in A} \alpha(a)} \quad (12)$$

式(12)中: $\alpha(a)$ 表示在推荐列表中为用户 a 召回量; $\beta(a)$ 表示用户 a 在测试结果最终选择的对象集合的召回量。

(4) 不同数据源下的推荐耗时。数据推荐结果往往容易受数据源种类的影响,本实验在单一数据源和多数据源条件下进行推荐耗时测试,验证本文算法性能。

2.2 实验结果与分析

2.2.1 相似度计算准确率

为验证上述本文算法推荐精度较高的这一结论,对推荐算法实现过程中的相似度计算这一指标进行分析,分别利用本文算法和文献[5]算法计算相似度准确率,结果如图 3 所示。

根据图 3 分析结果可知,本文算法计算精度比文献[5]算法高,平均在 85% 左右,提高了计算结果的准确性,为社交网络用户行为数据周期推荐的完成奠定了基础。这是因为详细分析了皮尔逊相关系数相似度和余弦相似度计算方法,选择了性能较好的皮尔逊相关系数相似度计算方法,获取了较好的结果,相似度计算准确率高于文献方法。

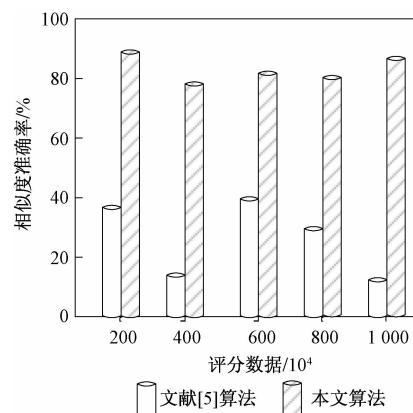


图 3 相似度计算准确率测试结果

Fig. 3 Test results of similarity calculation accuracy

2.2.2 推荐精度对比

基于上述实验环境和数据,将本文算法与文献[5-7]算法的推荐精度进行对比,结果如表 3 所示。

从表 3 中可知,将本文算法应用在微博用户行

表 3 推荐精度对比结果

Table 3 Comparison results of recommended accuracy

实验次数	精度/%			
	本文方法	文献[5]算法	文献[6]算法	文献[7]算法
100	92.3	90.3	90.4	91.1
200	90.4	85.2	88.7	89.9
300	90.6	78.9	85.5	85.2
400	97.2	89.5	92.8	90.6
500	95.7	92.7	90.1	92.3

为数据周期推荐当中,推荐结果的精度在多次实验测试中均较高,文献[5]算法的推荐精度最高为92.7%,文献[6]算法的推荐精度最高为92.8%,文献[7]算法的推荐精度最高为92.3%,而本文算法的推荐精度最高可达97.2%,具有明显的优势,弥补了传统推荐算法存在的不足,达到了预期目标[18]。

2.2.3 召回率对比

将本文算法与文献[6-8]算法的召回率进行对比,结果如图4所示。

分析图4可以看出,文献[6-8]算法的召回率分布范围集中在40%~60%,召回率较低,本文算法的召回率分布较为平稳,在85%左右波动,最高可达到90%,由此可见,本文算法具有一定的优势,推荐结果更为全面。

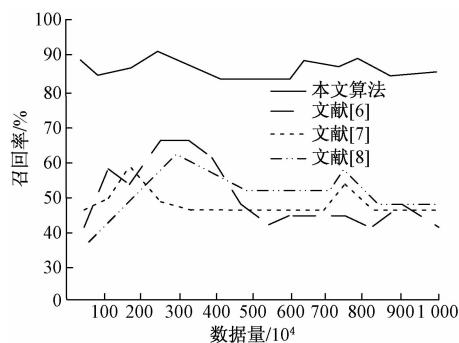


图4 召回率对比

Fig. 4 Comparison of recall rate

2.2.4 不同数据源下的推荐耗时对比

在单一数据源和多数据源条件下进行推荐耗时测试,结果如表4所示。

表4 推荐耗时对比

Table 4 Comparison of recommended time consumption

算法	单一数据源耗时/ms			多数据源耗时/ms		
	一组	二组	三组	一组	二组	三组
文献[6]算法	75	72	63	79	89	61
文献[7]算法	77	70	60	85	85	76
文献[8]算法	87	72	66	63	72	71
本文算法	33	35	34	38	40	39

根据表4分析结果可知,本文算法的推荐耗时不受数据源种类的影响,在单一数据源和多数据源条件下推荐耗时均不超过40 ms,而其他三种文献方法的推荐耗时均受数据源种类的影响,在多数据源条件下的耗时较长。此外,从整体数据分析结果可以看出,本文算法的耗时远远低于其他文献方法,可充分验证本文算法的有效性。

3 结论

综上所述,近年来社交网络平台的应用越来越广泛,在人们的生产、工作、生活中起到了重要作用,但近些年由于海量数据的不断增长,用户越来越难以从庞大的信息量当中提取出自己所需要的内容。为此,本次针对以往推荐算法存在的缺点,提出一种基于人工智能的社交网络用户行为数据周期推荐算法。该算法以协同过滤为核心,通过计算相似度来提取推荐内容,推荐精度有了极大提高,因此本文算法的性能更优越,更能为个性化服务提供支持。

然而该算法随着用户数量的增多,其计算量也在呈现几何式增长,推荐效率会有所降低,社交网络平台服务质量受到影响,且没有克服用户本身的限制,推荐方式与内容依旧单一,因此需要进一步改进,增强人工智能算法的应用,提高算法性能,为社交网络用户行为数据周期推荐提供更加切实有效的算法推荐。

参 考 文 献

- 刘慧婷,杨良全,凌超,等.社交网络中融合社交关系和语义信息的推荐算法[J].模式识别与人工智能,2018,31(3):236-244.
Liu Huiting, Yang Liangquan, Ling Chao, et al. Recommendation algorithm for integrating social relations and semantic information in social networks[J]. Pattern Recognition and Artificial Intelligence, 2018, 31(3): 236-244.
- 章讯,龙华,周芝民.基于网络结构改进社交网络好友推荐算法研究[J].信息技术,2017(8):152-156.
Zhang Xun, Long Hua, Zhou Zhimin. Research on improving social network friend recommendation algorithm based on network structure [J]. Information Technology, 2017(8): 152-156.
- 李凯凯,宋礼鹏.基于社交网络的用户行为记忆性研究[J].微电子学与计算机,2017,34(3):133-135.
Li Kaikai, Song Lipeng. Research on user behavior memory based on social network[J]. Microelectronics and Computer, 2017, 34 (3): 133-135.
- 冉晓斌,刘跃文,姜锦虎.社交网络活跃行为的大数据分析:网络外部性的视角[J].管理科学,2017,30(5):77-86.
Ran Xiaobin, Liu Yuewen, Jiang Jinhui. Big data analysis of social network activity behavior: the perspective of network externality[J]. Management Science, 2017, 30(5): 77-86.
- 乔少杰,韩楠,张凯峰,等.复杂网络大数据中重叠社区检测算法[J].软件学报,2017,28(3):631-647.
Qiao Shaojie, Han Nan, Zhang Kaifeng, et al. Overlapping community detection algorithm in complex network big data[J]. Journal of Software, 2017, 28(3): 631-647.
- 莫文杰,郑霖.优化网络生命周期和最短化路径的WSN移动sink路径规划算法[J].计算机应用,2017,37(8):2150-2156.
Mo Wenjie, Zheng Lin. WSN mobile sink path planning algorithm for

- optimizing network life cycle and shortest path[J]. Computer Application, 2017, 37(8): 2150-2156.
- 7 王保华, 严翔, 王立德, 等. 基于负载均衡的MVB周期数据调度优化[J]. 中国铁道科学, 2017, 38(5): 114-120.
Wang Baohua, Yan Xiang, Wang Lide, et al. MVB cycle data scheduling optimization based on load balancing[J]. China Railway Science, 2017, 38(5): 114-120.
- 8 包涛, 程乐峰, 陈柏熹, 等. 基于人工智能算法的无功优化分析软件设计[J]. 电力系统保护与控制, 2018(3): 89-96.
Bao Tao, Cheng Lefeng, Chen Baixi, et al. Design of reactive power optimization analysis software based on artificial intelligence algorithm [J]. Power System Protection and Control, 2018(3): 89-96.
- 9 郭昆, 彭胜波, 陈羽中. 基于密度聚类的增量动态社区发现算法[J]. 模式识别与人工智能, 2018, 31(11): 3-16.
Guo Kun, Peng Shengbo, Chen Yuzhong. Incremental dynamic community discovery algorithm based on density clustering[J]. Pattern Recognition and Artificial Intelligence, 2018, 31(11): 3-16.
- 10 Chen T, Zhu Q, Zhou M X, et al. Trust-based recommendation algorithm in social network environment [J]. Journal of Software, 2017, 28(3): 721-731.
- 11 郭宁宁, 王宝亮, 侯永宏, 等. 融合社交网络特征的协同过滤推荐算法[J]. 计算机科学与探索, 2018, 12(2): 208-217.
Guo Ningning, Wang Baoliang, Hou Yonghong, et al. Collaborative filtering recommendation algorithm integrating social network features [J]. Computer Science and Exploration, 2018, 12(2): 208-217.
- 12 王鹏, 宋艳红, 李松江, 等. 针对行为特征的社交网络异常用户检测方法[J]. 计算机应用, 2017, 37(S2): 219-224.
Wang Peng, Song Yanhong, Li Songjiang, et al. Abnormal user detection method of social network based on behavioral characteristics [J]. Computer Application, 2017, 37(S2): 219-224.
- 13 陈永建, 周艳, 刘超英. 基于遗传算法的大规模社交网络社区发现算法[J]. 计算机工程与设计, 2018, 39(8): 60-67.
Chen Yongjian, Zhou Yan, Liu Chaoying. Community discovery algorithm of large-scale social network based on genetic algorithm[J]. Computer Engineering and Design, 2018, 39(8): 60-67.
- 14 郑永广, 岳昆, 尹子都, 等. 大规模社交网络中高效的关键用户选取方法[J]. 计算机应用, 2017, 37(11): 3101-3106.
Zheng Yongguang, Yue Kun, Yin Zidu, et al. Efficient key user selection methods in large-scale social networks[J]. Computer Applications, 2017, 37(11): 3101-3106.
- 15 卢露, 朱福喜, 高榕, 等. 基于用户-内容主题模型的兴趣点联合推荐算法[J]. 计算机工程与应用, 2018, 54(4): 154-159.
Lu Lu, Zhu Fuxi, Gao Rong, et al. Joint recommendation algorithm of interest points based on user content theme model[J]. Computer Engineering and Application, 2018, 54(4): 154-159.
- 16 Zhang M. Personalized recommendation algorithm on microblogs [J]. Computer Science and Exploration, 2012, 6(10): 895-902.
- 17 刘雪晴. 面向科研社交网络的小同行双向推荐算法[J]. 计算机应用与软件, 2018, 35(10): 177-186.
Liu Xueqing. Small peer two-way recommendation algorithm for research social network [J]. Computer Application and Software, 2018, 35(10): 177-186.
- 18 张祖平, 沈晓阳. 基于深度学习的用户行为推荐方法研究[J]. 计算机工程与应用, 2019, 55(4): 147-152.
Zhang Zuping, Shen Xiaoyang. Research on user behavior recommendation method based on deep learning[J]. Computer Engineering and Application, 2019, 55(4): 147-152.
- 19 任星怡, 宋美娜, 宋俊德. 基于位置社交网络的上下文感知的兴趣点推荐[J]. 计算机学报, 2017, 40(4): 824-841.
Ren Xingyi, Song Meina, Song Junde. Recommendation of interest points based on context awareness of location-based social networks [J]. Journal of Computer Science, 2017, 40(4): 824-841.
- 20 杨文潮, 王际科, 崔光海. 基于节点策略学习行为的社交网络合作促进机制[J]. 计算机工程, 2017, 43(11): 140-145.
Yang Wenchao, Wang Jike, Cui Guanghai. Promotion mechanism of social network cooperation based on node strategy learning behavior [J]. Computer Engineering, 2017, 43(11): 140-145.