

循证理论在科技文献推荐中的可行性研究^{*}

曹元元 吴振新

【摘要】为提高科技文献推荐系统的精准性,打破目前推荐系统普遍存在的用户针对性低、依据性差的问题,引入在医学上证明普遍有效的循证理论,其通过构建治疗证据体系,将自然科学方法理论引入到以经验为主的诊疗过程。类似的,将其用于科技文献推荐模型,能够构建层次化的推荐依据,使推荐结果更具有说服力和精准性。将该方法应用于真实开放数据集上,通过线性回归的机器学习方法给证据打分并分层,从而构建层次化的推荐证据体系,证明该方法具有有效性和可实施性。

【关键词】科技文献推荐 循证实践 精准性 线性回归

Abstract: In order to explore the accuracy of the document recommendation system and to solve the problems of low pertinence and poor basis in the current recommendation system. The introduction of evidence-based theory in medicine has led to modern medicine being more objective and accurate through the construction of evidence-based treatment systems and it introduces natural science methodologies into the experience-based treatment process. Similarly, using it in a literature recommendation model, a hierarchical recommendation can be constructed, making the recommendation more persuasive and accurate. The method is applied on a real open data set, through linear regression machine learning method to score, stratify evidences and to build a hierarchical evidence-based recommendation system, and it is proved that the method is effective and practical.

Key words: literature recommendation evidence-based practice accuracy linear regression

DOI:10.15941/j.cnki.issn1001-0424.2018.08.006

0 引言

随着信息技术的飞速发展与应用,数字信息资源数量急剧增长,科研用户面临的问题不再是信息缺乏,而是信息过载,如何从海量数字信息中准确获取符合自身需求的文献资源,已经成为目前迫切需要解决的问题,也是信息服务领域目前研究的重点和热点。

早在数字图书馆出现之初,就已开始了个性化推荐的研究,根据用户的个性化科研需求,为用户推荐个性化信息资源。随着大数据时代的来临,精准推荐则成为目前的研究热点。无论是个性化推荐还是精准推荐,其核心问题是推荐方法。很多机构和研究人员从不同的角度来探索和完善推荐方法,目前常见的文献推荐方法主要有基于内容的、基于协同过滤的和基于矩阵分解的,这些方法大都建立在用户偏好建模的层面,也取得了较好的效果。但存在不能挖掘用户潜在研究方向上的科技信息、推荐依据层面略显单一的不足^[1]。为了更好地揭示影响科技文献推荐的特征,将在管理学、教育学、护理学、建筑学、信息服务、软件工程等领域得到广泛应用的循证理论纳入科技文献推荐研究中。

循证理论最先应用于医学领域,在疾病的诊治过程中,将来自各方面的信息加以综合考虑,以获得最佳的医疗决策。不难看出,文献推荐模式与循证医学模式有着极为相似之处,即需要综合各方面信息来获得最佳推荐结果。本文通过深入分析循证的原理以及其证据体系的构建,尝试探索该原理在科技文献推荐中的应用可能,进而指导科技文献推荐实践。

^{*} 本文系中国科学院文献情报能力建设专项项目“基于大数据的知识服务发现平台建设”(项目编号:院 1759)的研究成果之一。

1 相关研究进展概述

1.1 循证理论的原理及应用

循证理论最先应用于医学领域，1992年加拿大临床流行病学专家 David Sackett 教授率先提出“循证医学 (Evidence-based Medicine)”。目前在循证医学领域对循证广为接受的定义是“慎重、准确、明智地应用当前所能获得的最佳研究证据来确定患者的治疗措施。”^[2]其核心思想是在对疾病的诊治过程中，将医生的临床专业知识与最佳的研究证据以及病人的选择加以综合考虑，通过最新研究的证据、最全科研证据方式获取决策证据，据此来确定最佳的医疗诊疗方案。

循证医学的核心是证据，它最鲜明的特点是对证据质量进行分级，并在此基础上作出推荐，是能够对证据资源进行收集、解释、整合和评价的一种信息方法学^[3]，这种证据具有真实性、可靠性，是从研究中获取的。实际执行时要对证据资源按其重要性程度的不同，进行分类分级，往往形成证据金字塔，金字塔越往上，证据等级越高。以循证医学证据体系分类为例，依据证据质量和可靠程度大体可以分为以下五级，证据质量和可靠性程度依次降低，如图1所示。

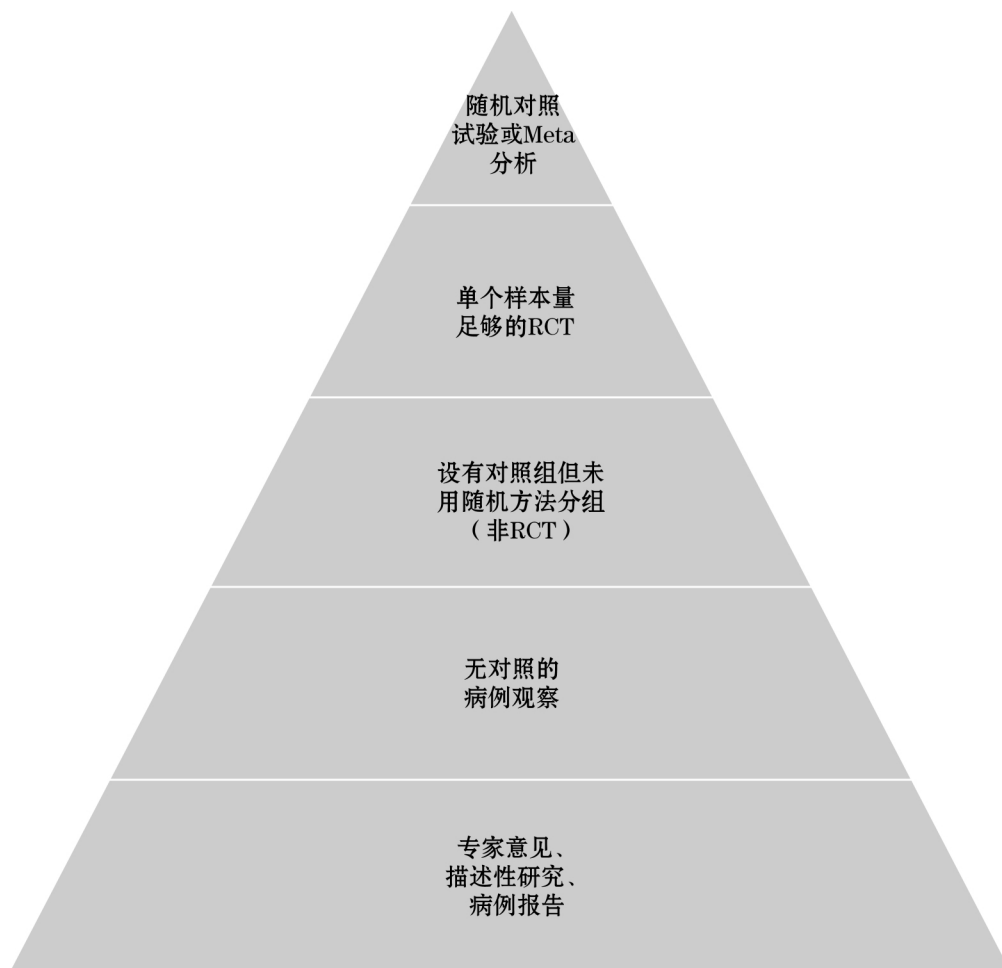


图1 循证医学证据金字塔^[4]

实施循证一般包含5个步骤^[5]:

- (1) 提出明确的待解决问题，构建一个准确的、可回答的问题。
- (2) 系统检索相关文献，全面收集证据，查找当前的最佳证据。
- (3) 评价证据，从证据的真实、可靠、适用性等方面对证据做出具体评价。
- (4) 综合分析所获取的证据，应用最佳证据，指导实践，做出决策。
- (5) 后效评价循证实践的结果，通过实践进行效果和效率的优化。

循证是一种思维和工作方法，其中心思想是寻求最好的证据，以提供最佳的决策，取得最佳效果。循证理论

的研究不断向管理学、教育学、护理学、建筑学、信息服务、软件工程等新兴学科领域发展,使得其核心原理的扩展以及循证实践的发展^[6]。为了探究循证理论在科技文献推荐领域的应用可能,本文对与其相关的信息服务领域研究进展进行了探索和总结。其中,Atkins等^[7]将循证理论引入到高校图书馆专题图书推荐研究中,提出高校图书馆面向学生的专题图书推荐是一个需要尝试循证理论的领域,与循证实践有着天然的契合点。分析出高校图书馆推荐应解决的核心问题、应展开的维度及循证实践流程。Li等^[8]提出在循证信息资源采集中利用数据挖掘技术大有前途,根据科学证据,结合用户需求和兴趣,以这些证据为依据,做出信息资源采集决策,使图书馆及文献收藏单位的信息资源建设更具科学性。Oates等^[9]提出循证网络资源知识挖掘即根据用户具体的研究要求,用智能化的手段发现与所需知识相关的显性信息和隐性信息,为用户提供有效的知识服务。Sharma等^[10]提出尝试利用循证分析的方法对领域科技创新各阶段进行综合分析,从循证思维构建科技创新演化发展的判据,综合多种资源作为证据进行循证情报分析。

1.2 在科技文献推荐研究中的适用性分析

科技文献推荐系统是根据科研用户学术研究的兴趣偏好,为科研用户推荐满足其需求的学术资源^[11],现有科技文献推荐服务大都根据用户的搜索关键词以及浏览记录,依据推荐模型进行相关度排序,再筛选资源库的文献来进行推荐,如国外的数据库PubMed、Google Scholar,国内的中国知网、万方数据等。分析现有的科技文献推荐服务,发现其缺乏对影响文献推荐特征的分类分级、整合处理及综合因素的考虑,其推荐结果不免有相当大的局限性和片面性^[12],而循证理论以证据为依托,在理论层面上提供了依据的可解释性,在实际运用中利用最新的科学方法与统计手段,以信息处理、数据挖掘等技术为依托,为研究理论与具体实践的整合提供了一个现实的、具体可行的实践框架,因此探索其在科技文献推荐服务中的可行性。

首先科技文献推荐的目标是提供个性化、精准的科技文献推荐服务,而循证实践提出的也是个性化、精准的解决方案,这与科技文献推荐目标一致。所以在科技文献推荐中,就可利用其原理多渠道广泛收集科研用户需求证据获得高质量的证据,把不同的知识片段、来自多方面的信息进行整合,使文献推荐的证据等级较之传统推荐采用的研究方法更为严格,有效防止过多关注低级别证据中的固有缺陷和主观倾向。借鉴循证医学和循证信息服务工作领域的证据分级制度,在保证循证实践方法科学性的前提下,可以根据科技文献推荐的特点,将精准推荐的证据进行分级处理。

经过对现有科技文献推荐服务的研究^{[13][14]},今后科技文献推荐研究可从以下两个方面着手:第一,深度而全面地进行科研用户兴趣模型构建,以便更准确把握特征信息,分析科研用户偏好。第二,多渠道广泛收集科研用户需求,为科研用户推荐更全面的符合其需求的有价值信息。这也与循证的理论相契合,所以本文将循证理论借用到推荐方案中,以科研用户为核心,用循证的理论对影响推荐的特征进行分析,提高推荐决策的科学性和可靠性,提高推荐的精准度。

2 循证理论在科技文献推荐中的应用

在科技文献推荐领域,为了达到获取“最佳证据”的目的,使推荐结果具有更高精准性,本文创新性地将循证理论应用于科技文献推荐研究中,将循证理念从医学研究领域映射到文献推荐领域,将文献推荐领域的特征类比为医学领域的证据,采用机器学习的方法构建证据体系,并按照特征权重的大小给证据分层,最终达到使文献推荐更具有科学性和准确性。借鉴循证理念,根据科技文献推荐证据体系的自身特点,有针对性地构建证据的形成方法,产生推荐的理论证据,是依据循证理论指导科技文献推荐实践指南制定的核心。

2.1 应用思路

本文结合开展循证实践^[15]的过程,基于循证理论来做科技文献推荐的总体思路主要包括以下几点。

2.1.1 首先提出待解决的问题,即寻找文献推荐的重要特征

特征的提取是推荐系统的基础,特征提取的基本原则之一是针对性,本文根据科技文献推荐的性质,进行推荐特征的信息收集、分析、加工和处理,有针对性地确定应提取的特征。

2.1.2 查找研究证据,即通过定性和定量分析特征

为了能够得到可靠的证据体系,本文综合运用定性和定量的科学方法,力求对检索到的相关证据进行来源定级、真实性、重要性、相关性评估和统计分析,综合分析影响文献推荐的因素,并将其作为证据。

2.1.3 评估证据,即学习特征权重参数

通过上述定性和定量分析确定出影响文献推荐的特征,按照机器学习方法学习出证据权重,依据每个证据特

征的重要程度,舍弃掉不重要的特征,提炼出更多的有效证据特征。

2.1.4 根据评估结果给证据分层,构建证据体系

依据循证理念,根据学习出的证据权重,给证据进行分类分级,进行证据体系的构建,为科研用户推荐文献提供科学依据。

2.1.5 应用证据,通过最终的证据体系进行科技文献推荐,同时进行精准度验证

通过构建出的证据体系,学习出明确的推荐结果。并与其他推荐方法所得出的推荐结果进行对比,验证依据循证理论进行科技文献推荐的精准度。

循证思想用于医学和文献推荐领域具体映射思路的对应关系如表1所示。

表1 循证用于医学和文献推荐对照

领域	医学领域	文献推荐
核心关键词	证据	特征
核心方法	统计方法	机器学习
框架	证据构建	特征选择
手段	证据分级	特征重要程度分层
证据体系构建方法	随机对照试验/文献研究	逻辑回归/文献研究
目的	使医学治疗更科学性	使文献推荐具有精准性

2.2 关键问题研究

在循证医学里面,目前主要是通过随机对照试验和 meta 分析基于统计思想的方式^[16]进行打分,中等以上的证据水平纳入研究,从而构建证据体系。在文献推荐领域中,将随机对照试验放置于证据等级的最高点似乎是不切实际的,这些方法可以延伸为用机器学习的方法,来选择特征,依据特征的重要性构建证据体系,然后再依据构建的证据体系给用户推荐文献,能使精准度更高。具体地,可以用逻辑回归模型,在有标记的数据样本中学习特征权重 W,依据特征权重进行分层,从而构建出层级化的特征体系。

本文借鉴循证理念,根据文献推荐证据体系的自身特点,有针对性地构建证据形成方法。在科技文献推荐领域特征分析中采用逻辑回归算法结合得到的用户兴趣,同时利用机器学习方法,针对影响科技文献推荐精准度的各种要素进行分析,同时通过推荐结果进行修改更新,最终形成完善的证据体系框架。

2.2.1 构建证据体系

本文借鉴循证使医学治疗具有科学依据和统计规律的思想,给文献推荐模型引入证据体系,并采用机器学习逻辑回归的方法自动地学习有用的证据,能根据标注样本自动学习特征的重要程度,依据证据程度给证据划分等级,根据分层后得到的证据进行科技文献推荐,使得文献推荐具有精准性、高可用性和科学性,利用算法的统计规律使推荐过程透明化。

本文采用逻辑回归的方法设计一套证据分级机制。逻辑回归^[17](Logistic Regression)是一种广义的线性回归分析模型,是统计学习中的经典分类方法。将逻辑回归模型应用到推荐系统领域,因变量是否推荐,自变量是用户和推荐候选文档的各种特征。为了更精细化地刻画是否推荐,本文将最后的二分类的输出结果转化成推荐概率输出,采用 Sigmoid 函数放缩最后的结果,Sigmoid 能将无界的数值预测转化为 0~1 的概率,能够达到不仅能推荐,而且还能提供推荐强度指示。Sigmoid 函数公式如下:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{(-x)}} \quad (1)$$

本文定义交叉熵^[18](Cross Entropy)为最终的损失函数,交叉熵能够衡量预测的推荐概率分布和已知的正负样本的分布间的差异性信息,其中推荐概率和交叉熵计算公式如下:

$$P(X_i) = \text{Sigmoid}(X_i) = \frac{1}{1 + e^{(-w^* X_i)}} \quad (2)$$

$$Cost = -\frac{1}{N} \left(\sum_{i=1, y_i=1}^N y_i \log P(X_i) + \sum_{i=1, y_i=0}^N (1 - y_i) \log (1 - P(X_i)) \right) \quad (3)$$

以最小化误差函数为目标, 采用随机梯度下降的方法学习权重参数, 对权重 w 求导, 得到更新函数, 然后逐步更新 w , 直到最终收敛。计算公式如下:

$$\frac{\partial Cost}{\partial w} = \frac{1}{N} \sum_{i=1}^N [(P(X_i) - y_i) X_i] \quad (4)$$

记用户特征为 U , 文献特征为 P , 用户和文献的组合特征为 C , 所有的特征拼在一起, 记为 $X = [U, P, C]$, 记特征个数为 m , 推荐概率记为 $y \in (0, 1)$, w 为权重向量, w_i 表示第 i 个特征 X_i 的权重, 记所有样本特征为 X , 所有样本的预测结果为 Y , 记样本总数为 N , 记 Iteration 为迭代次数, Sum_ Iteration 为总的迭代次数。更新权重计算公式如下:

$$w = w - \frac{\partial Cost}{\partial w} \quad (5)$$

$$Iteration = Iteration + 1; \text{ 判断该条件 } Iteration > \text{Sum_ Iteration} \text{ 是否成立} \quad (6)$$

具体算法步骤为:

- (1) 获取标记数据 X, Y , 维度分别为 $[N * m], [N * 1]$;
- (2) 采用标准正态分布初始化权重向量为 w , 初始化 Iteration = 0;
- (3) 依据公式 (2)、(3), 计算误差函数 Cost;
- (4) 依据求导公式 (4), 计算 w 的导数;
- (5) 依据公式 (5), 更新权重 w ;
- (6) 依据公式 (6), 计算停止条件; 如果满足停止条件, 则退出, 否则转步骤 (3), 重复计算。

2.2.2 依据证据体系进行文献推荐

依照 (5) 算法学习出特征权重向量 w 后, 按照 w 绝对值大小从大到小对特征排序, 记排序之后特征序列为 X_1, \dots, X_m , 依次尝试只用 X_1, \dots, X_p 个特征 ($1 < p < m$) 进行文献推荐, 并采用信息检索领域常见的排序问题评价指标 DCG (Normalized Discounted Cumulative Gain) 来对推荐结果进行评判, 并进行比较。DCG 能给靠前的、排对的文档给更多的权重, 主要思想是越相关、越靠前得分越高, 计算公式如下:

$$DCG(i) = \begin{cases} G(i) & \text{if } i = 1 \\ DCG(i-1) + \frac{G(i)}{\log(i)} & \text{其他} \end{cases} \quad (7)$$

其中 i 表示排在第 i 名。在实验中, 只用判断推荐文献是否在用户标记的相关文献里, 所有采用相关或者不相关用 0 和 1 来表示, 也即 $G(i) = 1$ 表示推荐的文献和用户相关, 推荐正确; $G(i) = 0$ 表示推荐的文献和用户不相关, 推荐错误。在推荐领域, 本文只关心推荐前几名的文献是否相关, 所以用 NDCG@N ($N=5$) 来评价, N 表示推荐的总数。 p 个特征构建证据体系计算公式如下:

$$p_{best} = \arg \max_p (NDCG@N(N=5) f(x_1 \dots x_p)) \quad (8)$$

其中 f 函数表示预测函数, 找出在测试集上推荐结果最好的 p 作为最后的证据个数。并用这 p 个特征构建证据体系。

将 p 个特征按 w 绝对值大小分成 K 等分, 形成 K 级证据体系, 一级证据最重要, 二级证据次重要, 依此类推, 第 K 级证据最不重要。这样就可以使得推荐结果更精准, 第一级证据贡献最大, 所涵盖的信息量最大, 如果缺少了前几级证据, 将使推荐结果不精确。正是因为有了前几级证据, 才有这样的推荐结果。

此外, 还可以根据现实意义对前几级证据进行横向扩充, 使得每一级的证据更细粒度, 使证据的分级层次化更分明, 利用证据的多方面扩充和分类分级的思想进一步提高推荐效果。

3 实证研究

本文将该方法应用在开放的公开文献推荐数据集上, 验证了证据构建框架的有效性, 并证明将循证应用于文献推荐领域, 能提高推荐的精准度, 增强文献推荐的可解释性, 同时能使推荐结果与证据关联起来, 为进一步分析推荐原因和寻找更多证据提供科学根据和参考意见。

3.1 实验数据

本文使用互联网上文献推荐领域公开的一个数据集，它由 Sugiyama 和 Kan 在 2010 年发布^[19]。该数据集提供了自然语言处理国际顶级学术会议 ACL (Association for Computational Linguistics) 2 000 到 ACL 2 006 部分研究者发表文章、文章被引用情况以及文章参考其他文章的信息，整体统计情况如表 2 所示，共 597 篇长文作为候选集，以下将用 P 表示发表文章集合，C 表示文章被引用文章集合，R 表示文章参考文章集合，D 表示候选文章集合。该数据集中每篇文章用该文章中出现的单词表示，并且将单词进行了简单处理：去掉了停用词（停用词基本上在每篇文章都出现，出现比例高，富含信息量少），并且进行了词干还原（英语中表示同一个意思的单词，有很多不同的形态，词干还原能还原单词表示的本质含义）。该数据集对每个用户提供了与其相关的文章信息，本文中将其作为标记数据，也就是如果对该用户推荐该文章，则表示正确推荐，否则表示错误推荐，用该标记数据给模型进行训练，从而学习特征权重参数，并最终用来给证据分层，最后构建证据体系。

3.2 实验分析

为了构建证据体系，并评测证据重要程度，从而给证据分层。本文对所给数据，先将能想到的证据全部罗列记为 F_{all} (见表 2)，然后通过逻辑回归的方法，学习每个证据的权重，然后再根据证据权重对证据进行分层，舍弃不重要的证据，留下的特征记为 F_{remain} ，设计实验验证 F_{remain} 的效果和 F_{all} 相差不大或者比 F_{all} 要好。将 F_{remain} 分成 5 层证据体系，最后对每一层的证据单独实验，验证每一层证据产生的效果，并作比较，验证证据体系构建的有效性。

表 2 实验所有特征 (证据) F_{all}

	Cos 相似度	单词共现比	排序	从大到小分组 (100 个为一组)
所有已发文章和候选文章	most_recent_cos	most_recent_comm	most_recent_rank	most_recent_group
最近发表文章和候选文章	pub_cos	pub_comm	pub_rank	pub_group
所有引用文章和候选文章	cit_cos	cit_comm	ref_rank	ref_group
所有参考文章和候选文章	ref_cos	ref_comm	cit_rank	cit_group
被引用文章加权后的已发文章和候选文章	pub_cit_cos	pub_cit_comm	pub_cit_rank	pub_cit_group
被已发文章加权后的参考文章和候选文章	pub_ref_cos	pub_ref_comm	pub_ref_rank	pub_ref_group
被引用文章加权后的已发文章+被已发文章加权后的参考文章和候选文章	pub_cit_ref_cos	pub_cit_ref_comm	pub_cit_ref_rank	pub_cit_ref_group

本文实验主要分为两个部分：

实验一：证明采用逻辑回归寻找证据的算法能使推荐结果更精确。

将数据中样本的 75% 作为训练集和 25% 作为测试集，采用逻辑回归的算法， F_{all} 表示所有证据，并对测试集进行推荐预测，记结果为 $Result(F_{all})$ 。得到特征权重后，将特征权重按照绝对值从大到小排序，排序结果见表 3。

表3 学习出的各特征(证据)权重

特 征	特征权重	特 征	特征权重
pub_cit_ref_comm	4.135	pub_ref_comm	4.135
ref_comm	-3.865	cit_comm	2.521
most_recent_group	1.977	most_recent_rank	1.977
most_recent_comm	1.787	most_recent_cos	1.531
pub_ref_group	1.340	pub_ref_rank	1.340
ref_group	-1.339	ref_rank	-1.339
pub_cos	-1.191	ref_cos	-1.105
pub_cit_rank	1.037	pub_cit_group	1.037
pub_ref_cos	-0.850	pub_cit_ref_cos	-0.811
pub_cit_ref_group	0.641	pub_cit_ref_rank	0.641
pub_cit_cos	-0.492	pub_rank	0.334
pub_group	0.334	cit_group	-0.330
cit_rank	-0.330	pub_cit_comm	-0.297
pub_cos_comm	0.297	cit_cos	-0.122

相应的曲线图如图2所示。




图2 特征权重绝对值排序图

选择最靠前的 K 个特征作为 F_{remain} ， K 的选取可以通过画 topK 测试效果图，找到效果最好的那个 K 值，如图 3 所示。

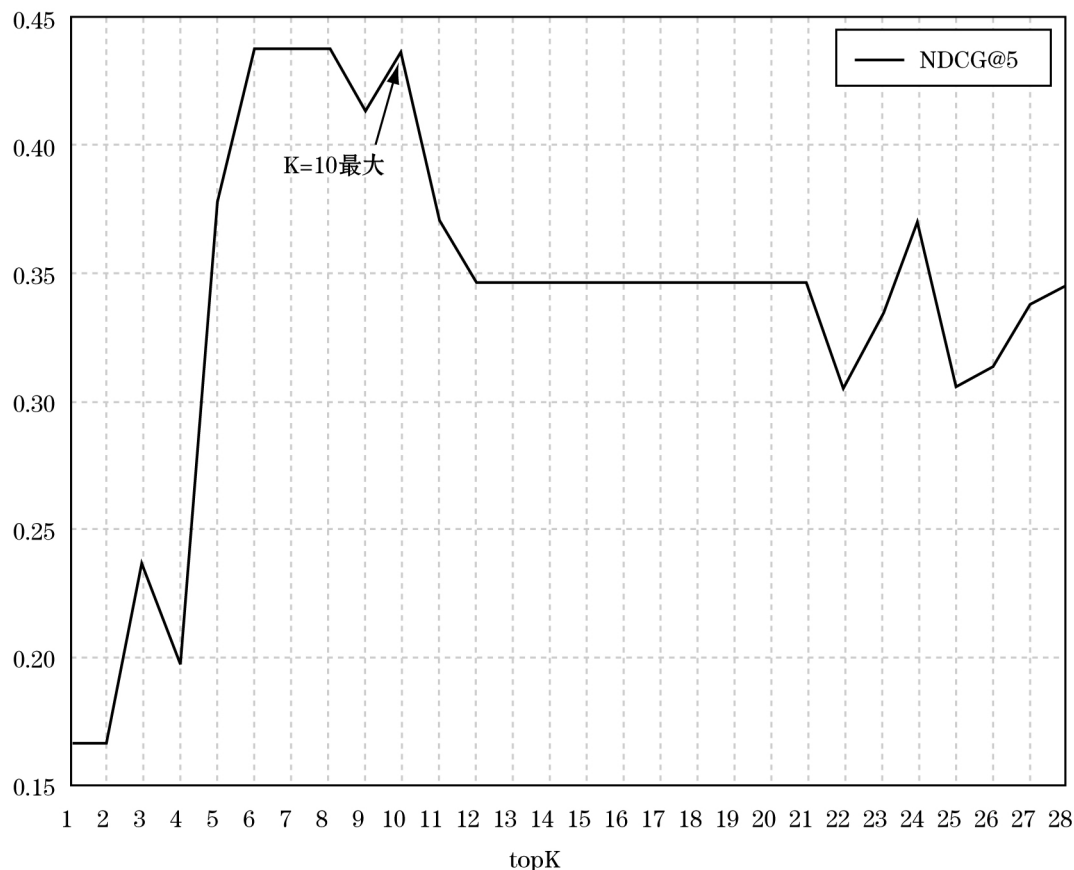


图 3 前 K 个特征测试结果

测试结果如表 4 所示。

表 4 F_{all} 和 F_{remain} 测试结果

实验特征	实验结果 (NDCG@ (5))
Result (F_{all})	0.346169
Result (F_{remain})	0.43744

从表 4 中，可以看出 Result (F_{remain}) 的效果比 Result (F_{all}) 效果好出 26%，由此可以得出， F_{remain} 的证据是有效的，用 F_{remain} 的证据能达到所需效果，利用逻辑回归机器学习方法能寻找出合理正确的证据，基于最佳证据进行科技文献推荐能使推荐结果更精准。

实验二：证明证据体系的划分和构建能使推荐结果具有有效性。

为了划分证据，对证据进行分类分级，构建证据体系，将 F_{remain} 特征划分成 5 级，形成五级证据体系，划分方法同样是按照机器学习方法学习出来的证据权重。为了分析各级证据的影响力，本文单独对每一级证据分别进行验证，验证结果如图 4 所示。

由图 4 可以得出，各级证据的作用不同，一级证据的效果最好，五级证据效果最差，且一到五级证据效果逐渐降低。由此可以得出，采用逻辑回归的证据体系构建算法是有效的。将循证理念用到科技文献推荐领域，能起到很好的效果，即具有有效性。

本文构建出如表 5 所示的证据体系，能很容易地知道每级证据的含义，将证据和推荐结果关联起来，能很容易地解释推荐结果，所以将循证理念应用文献推荐领域，通过构建证据体系给证据划分层次的思路是可行的。




图4 各级证据单独测试效果

表5 各级证据划分

证据体系	证 据
一级证据	pub_cit_ref_comm, pub_ref_comm
二级证据	ref_comm, cit_comm
三级证据	most_recent_group, most_recent_rank
四级证据	most_recent_comm, most_recent_cos
五级证据	pub_ref_group, pub_ref_rank

通过实验一和实验二，验证了循证文献推荐是可行的，采用逻辑回归的方法给证据打分评级并构建证据体系，最后给证据分层的方法是有效的，拿到分级证据后，根据每一级的证据所占的权重不同，得到最佳证据再进行文献推荐，可以使推荐结果更精准。

4 结语

基于循证理论的科技文献推荐方法是一种新探索，将循证纳入科技文献推荐研究中最鲜明的特点就是对证据质量进行分级，并在此基础上作出推荐，从而确保推荐有理可依，有据可查。它与传统推荐方法之间有一定的关联性，也有一定的独立性，二者之间的关系不是替代性，而是补充性，在一定程度上，利用循证理论来做科技文献推荐涉及了现有推荐方法未涉及的层面。因此，有必要尝试将循证理论的思想纳入科技文献推荐研究中，更全面、生动地揭示科技文献推荐的特征，通过对这些特征进行重要性程度的分级，以提高推荐的精准度。

本文为文献推荐研究开辟了一个新的视角，采用循证分析即有证可循的思想，试图建立一种进行科技文献推荐实践的实用方法，用于收集和综合科技文献推荐研究中所获得的最佳证据即特征以指导科技文献推荐决策，基于有理有据的分析和与科技文献推荐紧密联系的思考模式，来促进文献推荐精准度的提高。循证式推荐立足拓展

数据收集和分析的范畴, 提出相应的原则和方法, 确保推荐的文献能真正满足科研用户的需求, 发挥切实有效的作用。当然如何找到更多的原始证据还是很困难的, 开展循证所依赖的证据库缺少系统的支持, 这成为基于循证实施科技文献推荐的主要障碍。后续研究将收集更多的特征数据, 进行训练学习, 以应用到真实有效的数据库服务平台上。

注释

- [1] Girardi R, Marinho L B. A Domain Model of Web Recommender Systems Based on Usage Mining and Collaborative Filtering [J]. Requirements Engineering, 2014 (1): 23-40.
- [2] Hysong S J, Kell H J, Petersen L A, et al. Theory-Based and Evidence-Based Design of Audit and Feedback Programmers: Examples from Two Clinical Intervention Studies [J]. Bmj Quality & Safety, 2016 (4): 323-334.
- [3] Sackett D, Rosenberg W, Gary J M, et al. Evidence Based Medicine: What It Is and What It Isn't [J]. British Medical Journal, 1996 (7023): 71-72.
- [4] 李幼平, 杨克虎. 循证医学[M]. 北京: 人民卫生出版社, 2014: 18-33.
- [5] Jiang W, Zhan J. A Modified Combination Rule in Generalized Evidence Theory [J]. Kluwer Academic Publishers, 2017 (3): 1-11.
- [6] 谢静之. 面向循证医学的多文档自动文摘技术研究[D]. 大连: 大连海事大学, 2010.
- [7] Atkins D, Best D, Briss P A, et al. Grading Quality of Evidence and Strength of Recommendation [J]. Bmj British Medical Journal, 2004 (7653): 1106-1110.
- [8] Li Y, Zhu Y, Wu J. Research on Expert Weighting Method Based on D-S Evidence Theory [C]. Proceedings of IEEE Advanced Information Technology, Electronic & Automation Control Conference, 2017: 992-996.
- [9] Oates B J. On Systematic Review for Evidence-Based Practice [J]. Journal of Information Technology, 2015 (2): 177-179.
- [10] Sharma M, Bilgic M. Evidence-Based Uncertainty Sampling for Active Learning [J]. Data Mining & Knowledge Discovery, 2016 (1): 1-39.
- [11] Sugiyama K, Kan M-Y. Scholarly Paper Recommendation Via User's Recent Research Interests [C]. Proceedings of the 2010 Joint International Conference on Digital Libraries, Queensland, 2010.
- [12] Wang Z, Liu Y, Yang J, et al. A Personalization-Oriented Academic Literature Recommendation Method [J]. Data Science Journal, 2015 (17): 1-9.
- [13] Kobza A. Privacy-enhanced Web Personalization [J]. Adaptive Web, 2007 (8): 628-670.
- [14] Ana S, Nagar S. A Hybrid Recommender System User Profiling from Keywords and Ratings [C]. Proceedings of IEEE/WIC/ACM International Joint Conferences on Web Intelligence, 2013 (1): 73-80.
- [15] Milano G. The Hierarchy of the Evidence-Based Medicine Pyramid: Classification beyond Ranking [J]. Joints, 2016 (3): 101.
- [16] Roddham M. Evidence-Based Practice for Information Professionals: A handbook [J]. Health Information & Libraries Journal, 2004 (4): 276-277.
- [17] Zhang Z. Model Building Strategy for Logistic Regression: Purposeful Selection [J]. Annals of Translational Medicine, 2016 (6): 111.
- [18] Konstan J A, Miller B N, Maltz D, et al. GroupLens: Applying Collaborative Filtering to Usenet News [J]. Communications of the ACM, 2007 (3): 77-87.
- [19] Dataset 1 for Scholarly Paper Recommendation [EB/OL]. [2017-12-20]. <http://www.comp.nus.edu.sg/~sugiyama/Dataset1.html>.

曹元元 中国科学院文献情报中心, 中国科学院大学, 硕士研究生。

吴振新 中国科学院文献情报中心研究馆员, 硕士生导师。