

SHEHUI BIAOZHU XITONG ZHONG
BIAOQIAN TUIJIAN FANGFA YANJIU

社会标注系统中 标签推荐方法研究

张 引 赵玉丽 张 斌 高克宁 著



東北大學出版社
Northeastern University Press

社会标注系统中标签 推荐方法研究

张 引 赵玉丽 张 斌 高克宁 著

东北大学出版社

· 沈 阳 ·

© 张 引 赵玉丽 张 斌 高克宁 2016

图书在版编目 (CIP) 数据

社会标注系统中标签推荐方法研究 / 张引等著. —沈阳: 东北大学出版社, 2016.7

ISBN 978-7-5517-1340-5

I. ①社… II. ①张 … III. ①计算机算法—研究 IV. ①TP301.6

中国版本图书馆 CIP 数据核字 (2016) 第 158998 号

内容简介

本书主要研究了社会标注系统中的标签推荐方法。针对标签语义的建模问题, 通过利用少见标签的明确语义及标签间的语义互标注, 构建了基于语义互标注的标签的语义模型。针对标签数据的预处理问题, 通过识别并区分分类与主题标签、共识与非共识标签及研究基于关系的标签扩展, 实现了基于标签区分及关系扩展的社会标注数据的预处理。针对推荐算法在对推荐线索的利用以及用户个性化建模等方面还存在着不足的问题, 研究了融合多种异构对象分析的标签推荐方法, 帮助解决社会标注系统数据稀疏、标签推荐线索不足的问题, 并进一步研究了用户自主意识的建模方法, 实现了更加个性化的标签推荐。

出 版 者: 东北大学出版社

地址: 沈阳市和平区文化路三号巷 11 号

邮编: 110819

电话: 024-83680267 (社务室) 83687331 (市场部)

传真: 024-83687332 (总编室) 83680178 (出版部)

网址: <http://www.neupress.com>

E-mail: neuph@neupress.com

印 刷 者: 沈阳航空发动机研究所印刷厂

发 行 者: 东北大学出版社

幅面尺寸: 170mm×240mm

印 张: 8

字 数: 151 千字

出版时间: 2016 年 7 月第 1 版

印刷时间: 2016 年 7 月第 1 次印刷

组稿编辑: 罗 鑫

责任校对: 春 晓

责任出版: 唐敏志

责任编辑: 汪彤彤

封面设计: 刘江旻

ISBN 978-7-5517-1340-5

定 价: 30.00 元

前言

Web 2.0开放的信息发布方式极大地简化了信息的发布过程,令更多的信息可以更自由地在互联网上传播,但是同时也为如何有效地组织这些信息带来了问题。社会标注系统使用基于纯文本标签的方法分类信息,其简单性与便捷性获得了用户的认可,并成为了Web 2.0时代最为重要的信息组织方式。然而,受到其不受控制的本质的影响,社会标注系统的标注结果普遍存在着分类视角不一致、分类词汇不一致、分类结果不一致、分类结果冗余、分类结果不完备、分类使用不规范等多方面的问题。为了提升社会标注的质量,标签推荐作为一种社会标注辅助方法成为了相关领域研究的热点。

标签推荐问题已经获得了广泛而深入的研究。科研人员提出了大量的标签推荐方法,并在很多实际的数据集上取得了良好的效果。然而,当前的标签推荐方法在一些关键的问题上仍旧缺乏深入的研究。首先,这些方法要么不关注标签的语义信息,要么采用基于外部语义源的语义描述方法。受到领域覆盖、概念定义角度、更新频率等方面的限制,外部语义源无法很好地适应大范围的社会标注应用。其次,这些推荐方法较少关注对社会标注系统数据的有效预处理,无法为推荐算法提供一个有效的数据基础。最后,这些推荐算法在对推荐线索的利用以及用户个性化建模等方面还存在着不足。这些方面的问题限制了标签推荐的质量。

本书共分为5章,重点阐述了笔者近年来为实现社会标注系统中高质量的标签推荐而取得的一些研究成果。第1章为绪论,介绍了Web 2.0开放的信息发布方式的特点,简述了社会标注系统诞生的背景及其模型化描述,对社会标注系统中标签使用的基本特征进行了分析和总结,讨论了基于标签的Web信息处理技术和相关研究工作,阐述了社会标注系统中实行标签推荐的重要性及所面临的问题。第2章提出了基于互标注的社会标注系统标签语义模型。标签语义的有效建模是进行标签推荐的基础,而当前的基于外部知识源的标签语义描述方法面临着多方面的问题。通过分析社会标注系统中标签具体的使用情况,探讨了利用特殊标签自身的特征作为语义建模的基础,以及利用标签间互相标注关系作为语义建模手段的标签语义建模方法,利用有吸收状态的马尔可夫过程建模标签语义的具体体现过程,并通过具体实验验证了该建模方法的有效性。第3章研究了社会标

注系统标签数据的预处理。受到社会标注系统不受控制的使用方式的影响,基于标签的分类结果中存在着大量的无意义、错误的低质量标注结果,同时又存在着大量没有被完善标注的信息。这些包含大量噪声,同时又不完备的分类结果很容易误导标签推荐算法,使其给出错误的推荐结果,影响推荐的整体质量。针对标签标注的质量问题,提出了用户具有共识语义及不具有共识语义标签的识别方法;针对标签使用混乱的问题,提出了分类标签及主题标签的识别方法;针对资源标注不完善的问题,提出了资源标签的扩展方法。第4章研究了融合异构对象分析的社会标注系统标签推荐方法。标签推荐的核心问题是建立起社会标注系统中标签、用户及资源之间的标注关系。这一基本思路决定了标签推荐方法普遍依赖分析对象之间的关系。然而,对现实世界社会标注系统的研究可以发现,系统中对象之间的关系通常非常稀疏,并严重影响关系分析方法的性能。针对这一问题,通过提出一个以统一方式建模多种异构对象的、具有较强可扩展性的标签推荐模型,实现了模型引入额外标签推荐线索的能力,提升了数据的稠密程度,解决了数据的稀疏问题。实验表明该模型可以有效地在稀疏的数据中获取标签推荐线索,实现高质量的标签推荐。第5章研究了面向用户自主意识的社会标注系统标签推荐方法。在标签推荐过程中,用户最终决定了被推荐结果是否能够被采纳,而用户对标签的选择不仅仅依赖标签的质量,还取决于用户自身的偏好。用户的这种对标签的偏好构成了用户的自主意识,但当前的个性化标签推荐方法缺乏对用户这种自主意识的明确描述,因而无法完整地捕获用户的个性化信息。针对这一问题,研究了面向用户自主意识的标签推荐方法,通过明确地建模用户在使用社会标注系统时,对具体每个标签的使用偏好,实现了完善的个性化标签推荐。

本书的完成得到了东北大学计算机科学与工程学院智能信息服务研究所各位同事的大力支持,特别感谢学生李鹏飞、刘大力、朱思创、刘鑫伟为本书所付出的辛勤劳动。本书的研究工作得到了国家自然科学基金项目(61572116、61572117、61502089),国家关键科技研发基金项目(2015BAH09F02),辽宁省科技项目攻关项目(2015302002),中央高校东北大学基本科研专项基金项目(N140404016, N150408001, N150404009)的支持。

由于笔者水平有限,书中难免存在不妥及疏漏之处,欢迎各位专家和广大读者给予批评指正。

笔 者

2016年4月

目 录

第1章 绪论	1
1.1 研究背景	1
1.1.1 Web 2.0与社会标注系统	1
1.1.2 标签的基本特征研究	3
1.1.3 基于标签的Web信息处理	6
1.1.4 标签推荐	9
1.2 社会标注系统中的标签推荐问题	12
1.3 本书的主要研究内容	13
1.4 本章小结	15
第2章 基于语义互标注的社会标注系统标签语义建模方法	16
2.1 社会标注系统的标签语义建模问题	17
2.1.1 研究目标	17
2.1.2 研究的基本出发点	19
2.2 相关研究	21
2.3 社会标注系统中标签的语义互标注现象	24
2.3.1 实验设定	25
2.3.2 实验结果的观察与讨论	26
2.4 基于语义互标注的标签语义建模随机关联模型	30
2.4.1 模型描述	30
2.4.2 计算细节	32
2.5 实验评估	34
2.5.1 实验设定	34
2.5.2 实验结果与分析	36
2.6 本章小结	38
第3章 社会标注系统的标签数据预处理方法	40
3.1 社会标注系统的标签数据预处理问题	41
3.2 相关研究	43
3.3 社会标注系统标签数据预处理方法	45

3.3.1	分类标签与主题标签的识别方法	45
3.3.2	共识标签与非共识标签的识别方法	50
3.3.3	社会标注系统的资源标签扩展方法	55
3.4	实验评估	57
3.4.1	实验数据集	57
3.4.2	分类标签与主题标签区分评测	57
3.4.3	共识标签与非共识标签区分评测	59
3.4.4	标签扩展评测	61
3.5	本章小结	63
第4章	融合多种异构对象分析的社会标注系统标签推荐方法	64
4.1	社会标注系统中的标签推荐问题	65
4.2	相关研究	68
4.3	基于异构对象融合分析的社会标注系统模型	70
4.3.1	基础与假设	70
4.3.2	单用户情况下的模型描述	73
4.3.3	多用户情况下的模型描述	74
4.3.4	推荐模型的直观解释	75
4.4	基于异构对象融合分析模型的信息标签推荐方法	76
4.4.1	利用融合分析模型进行标签推荐	77
4.4.2	模型参数的确定	77
4.4.3	模型的增量更新	79
4.5	实验评估	81
4.5.1	实验设定	81
4.5.2	潜在主题的数量	82
4.5.3	判断用户生成文章的能力	84
4.5.4	标签推荐效果对比	85
4.5.5	方法的复杂度分析	87
4.6	本章小结	88
第5章	面向自主意识的个性化社会标注系统标签推荐方法	89
5.1	标签的个性化推荐问题	89
5.2	相关研究	92
5.3	面向用户自主意识的标签推荐模型	94
5.3.1	用户自主意识的建模方法	95

5.3.2 模型的数学描述.....	96
5.3.3 模型的参数估计.....	98
5.3.4 面向用户自主意识的个性化标签推荐方法.....	99
5.4 实验评估	100
5.4.1 实验设定	100
5.4.2 实验结果与分析	102
5.4.3 面向自主意识的个性化标签推荐算法的进一步讨论	104
5.5 本章小结	105
参考文献	106

第1章 绪 论

1.1 研究背景

Web 2.0开放的信息发布方式令普通用户成为了互联网信息发布的主体。与这种开放的信息发布方式相对应,作为对传统的、基于固定分类体系的信息分类方法的替代,Web 2.0使用基于标签的信息组织方法,使用户免于记忆和使用复杂的分类体系,而可以使用任意的词汇对信息进行分类^[1]。研究表明,与传统的方法相比,这种简单而直观的信息组织方法可以更加有效地帮助用户组织和分享数据,并具有能够反映信息被共享或使用时的上下文背景信息等重要的优势^[2]。

1.1.1 Web 2.0与社会标注系统

Web 2.0^[3-4]是相对于传统的、相对封闭的Web而定义的,以用户为中心的,鼓励所有人参与其中的Web应用环境。虽然从诞生之日起,Web就以其参与方式的开放性、信息传播的快速性及获取信息的便捷性而获得了广泛的使用,但由于网络的管理、服务器的维护及网站的创建仍旧存在着较高的技术门槛,在传统的Web环境下,信息的发布权仍旧掌握在相对少数的网站管理者手中,更多的普通用户则只能被动地接受信息。而Web 2.0的诞生及随之而来的以用户为中心的应用设计理念,则通过为用户提供简单、便捷同时又多样化、个性化的信息发布方法,突破了传统Web所存在的信息发布上的技术障碍,使普通用户可以任意地发布与共享任何类型的信息。这种自由性极大地激发了用户的参与热情。仅以我国为例,典型的Web 2.0应用如博客、微博与社交网站就分别获得了62.1%、48.7%和47.6%的使用率^[5]。毫无疑问,这种广泛的参与性已经令普通用户成为了互联网信息发布的主体之一,并在令互联网信息获得极大丰富的同时使其能够覆盖过去无法引起少数的信息发布者注意的更加广泛的主题与领域。

然而,Web 2.0开放的信息发布方式在为互联网带来更加丰富的信息的同时,其不受控制的信息发布方法也为如何有效地组织、索引进而查找这些信息

带来了困难。在传统的 Web 环境中,信息的发布与组织主要由网站的管理人员完成,并按照各个网站自有的分类体系进行分类。这些分类体系虽然各不相同,但一般都按照用户能够直观理解的方式进行组织,同时在较长的时间里保持固定。对于一个分类,用户通常可以通过分类名称来判断该类别所代表的分类语义。而即便对于不能直接判断语义的分类,用户也可以通过检视该分类下的信息来理解该分类所代表的信息。这种公开的、易于理解的同时相对固定的分类体系成为了信息的发布者和使用者之间共同的语义基础,为信息的发布、组织、索引与查找提供了一个一致平台。

而在 Web 2.0 环境下,开放的信息发布方式令普通用户逐渐地成为互联网信息发布的主体。这种变化在改变互联网信息内容结构的同时,也改变了互联网信息组织的方式。一方面,开放的信息发布方式在令信息所涉及的主题及领域快速膨胀的同时也导致了分类的进一步细化,这便要求使用覆盖面更广、描述能力更强、更加复杂的信息分类方法;另一方面,普通用户通常没有耐心去记忆并使用一个复杂的信息分类方法,这又要求信息的分类方法必须尽可能简单与直观。这种矛盾的需求使得在传统的 Web 环境下所使用的基于固定分类体系的分类方法不再适应 Web 2.0 环境下信息发布与组织的要求。

针对这一情况,为了适应 Web 2.0 信息发布方式所具有的开放、自由的特点,人们研究并使用同样开放且自由的社会标注系统^[6]来实现对 Web 2.0 信息的组织、索引与查找。在社会标注系统中,发布、共享或再发布信息的用户为信息附加纯文本标签作为元数据信息,并使用这些标签来组织、索引并查找信息。这种信息组织方法不限制用户所使用的词汇,避免了传统的信息组织方法受到自身所采用分类法的描述能力的限制,使其可以用于分类组织任意主题及类型的信息^[7]。并且,相对于传统的将信息唯一地分类到分类法的某个类目下的过程,社会标注系统采用一种更加直观的多元分类策略,使分类的形成更加灵活,并可以充分地利用人类对事物认知的直觉力量^[8]。最后,由于不会受到给定分类法的限制和干扰,用户可以更好地集中在对信息的分类过程中,并因此可以触发更多方面的标注角度,令分类结果能够更好地反映信息被发布、共享或再发布时的上下文^[2]。

这些方面的事实令社会标注系统具备了大量传统分类方法所不具备的优势,并使其在获得用户大量使用的同时,也获得了研究人员的大量关注。Robu 等^[9]指出用户在使用社会标注系统时会对标签的语义形成共识,并且这种共识信息可以被用于发现概念间的关联。Tsui 等^[10]则进一步地利用社会标注系统获得了概念的层次关系。Wu 等^[11]的研究表明从社会标注系统中提取的全局语义模型可以帮助对标签的语义进行消歧,并帮助识别具有相似意义的标

签,进而帮助搜索并发现语义关联的资源。Cattuto等^[12]证明了社会标注结果可以用于搜索引擎的查询扩展服务。Gawinecki等^[13]则采用社会标注结果来辅助进行服务发现。这些多样化的研究证明了社会标注系统的潜在价值。

在社会标注系统中,用户将标签作为元数据标记给资源。这一过程包括了三种类型的对象(即用户、被标记的资源、用于标记资源的标签),以及关联三种对象的一种关系(即标记关系)。这一结构使得社会标注系统可以很自然地描述为一种三部图结构:用户集合 $U=\{u_1, u_2, \dots\}$ 、资源集合 $R=\{r_1, r_2, \dots\}$ 、标签集合 $T=\{t_1, t_2, \dots\}$ 及这些节点之间用以表示标注关系的超边集 E ^[14]。

这种简单的模型只考虑了最低限度的信息,因此只提供了有限的描述能力。为了适应不同的、更加复杂的应用场景,一些研究也提出了对这一模型的改进。Gruber^[15]认为当需要同时处理来自不同社会标注系统的标注数据时,来源不同的数据需要被分别地处理,并提出了一个四元组社会标注系统的定义: *Tagging(Object, Tagger, Source)*。Wu等^[11]则将社会标注行为抽象为一个包含标签、用户、资源以及标注发生时间的四元组。Schmitz等^[16]则在研究应用关联规则方法到社会标注系统中时进一步将标签的上下位关系引入了建模中。这些研究表明,随着视角的变化,社会标注系统可以进行不同方式与角度的建模,并可以传达出不同类型的信息。这种多样性也证明了社会标注系统不仅仅是基于关键字的元数据信息,更可以体现出大量用户对信息的一致观点。

1.1.2 标签的基本特征研究

标签作为社会标注系统最为重要的核心,其基本特征已经获得了广泛的研究。最为直观地研究标签基本特征的方法是观察标签的使用情况。Mathes^[1]的研究指出,标签的使用频率服从幂律分布,即大部分的标签只被少数的用户在少数的资源上使用有限的次数,相反的却有少数标签被大量的用户在很多场景上广泛地使用。进一步的研究可以发现,那些使用频率较高的标签通常对应着关键的概念或实体,因此在研究和应用中需要被重点关注。Sen等^[17]在研究社会标注系统中用户所使用的词汇集的演进的过程中也发现,一些标签只在用户个人的书签中出现,是非常特别的,甚至是用户自己创造的词。这些词汇不会被其他用户所使用,它们的使用范围也仅限于用户用于浏览自己的资源。Halpin等^[2]通过深入研究标签幂律分布的形成过程发现,在基本的标注形成后,其他用户会继续使用已经存在的热门标签对资源进行标注,从而形成越来越稳固的幂律分布特征,而这些重复的标注则可视为用户对高频标签的一种认可。

标签的另一个重要的基本特征是其与传统分类方法的区别。Jacob^[8]指出,传统的分类(Classification)是将对象严格地划分到某一个类别中,类别之间是没有重叠的。而类似于标签的分类(Categorization)则更灵活地将对象分成组,组内的对象在特定的背景下具备共同特征,同一个对象也可以存在于多个组中。Körner^[18]从标记动机的角度将使用标签的用户分为分类者与描述者,并认为分类者所做的标记是为了方便自身对资源的访问,而描述者则是为了方便他人对资源的访问。在类似的研究中,Nov等^[19]更具体地提出了对应于分类者的组织动机与对应于描述者的交流动机。分类者通常会使用一些个性化的标签,而描述者则会用规范的标签以及很多同义词标签来描述资源。典型的分类者是网络收藏系统的用户,典型的描述者则为博客、视频的发布者。很明显,规范的标签更易于分析标签间的关系,也因此更有利于社会标注结果的应用。

社会标注的根本出发点在于有效地组织、索引并查找资源,因此标签的搜索性能也是其重要的基本特征。Heymann等^[20]针对标签是否能够帮助改善网络资源搜索质量的问题进行了大量的研究。他们的研究发现,对于网络书签资源,标签出现在被其所标记的超过50%的资源中,并且只有20%的标签没有出现在被标记资源、其父链接资源和其子链接资源中。然而,虽然标签能够提供无法从其他数据源获得的、可以用于搜索资源的信息,但仅仅依靠标签数量及使用分布等信息仍旧难以形成明显的影响,因此对标签进行更深入的研究是获得良好搜索效果的基础。Stampouli等^[21]认为标签歧义性是影响资源搜索准确率的重要因素,并设计了借助Wikipedia消除标签歧义的方法。Wu等^[11]也研究了标签的歧义识别问题,并且发现从社会标注系统中提取的全局语义模型可以对标签的语义进行消歧,并识别具有相似意义的标签。

作为社会标注系统三部图模型的一部分,标签之间的关系也形成了复杂的网络特征。吴超等^[22]通过复杂网络的分析方法对社会标注系统中标签间的关系进行了分析,发现基于共现的标签网络具有较小的平均路径长度以及较大的聚类系数,体现出明显的小世界特征。对这种现象的一个合理的解释是,网络中有类似于树形结构根节点的标签将众多标签联系了起来,这意味着为标签构建概念层次关系是可行的。贾君枝等^[23]对网络书签应用Del.icio.us中文标签的特点进行了全面的分析,发现用户倾向于选择简单的词汇来描述资源,且概括性词汇的使用多于具体性词汇的使用。由于概括性的标签更适合作为层次关系中的节点,这一现实有利于形成更清晰、更有价值的标签层次结构。Zlatic^[24]等利用一组拓扑质量指标研究了照片分享网站Flickr与文献组织网站CiteULike的社会标注系统所形成的网络,发现这些社会标注网络具有类似的性质。这一

结果使得上述研究可以推广到很多类似的系统中。

标签语义特征研究可以通过对标签进行分类实现。Eda等^[25]认为标签可以分为主观标签和客观标签,同时只有客观标签可以用于构建标签层次关系。Lin等^[26]则将标签分为标准标签、复合标签、术语标签以及无意义标签四个类别。Xu等^[27]将标签分为如下五种类型:基于内容的标签,如Autos, Honda Odyssey等;基于上下文的标签,如Golden Gate Bridge, 2005-10-19等;表示属性的标签,如资源发布者的姓名等;主观性的标签,如funny, cool等;组织性的标签,如my paper, to-read等。在此基础上,Xu等认为高质量的标签应具有如下特性:涵盖较多的方面,高使用度,尽可能少的数量,规范的格式,不包含特定分类的标签。Golder等^[28]则更进一步地将标签分为七种类型:标记资源的内容的、标记资源的类型的、标记资源的拥有者的、进一步描述分类的、标记资源的质量或特点的、自我引用的,以及任务组织性的。基于这些工作,Bischoff等^[29]提出了一种启发式方法和机器学习方法相结合的标签类别识别方法,针对不同类别的标签采用不同的识别方法,实现了自动化的标签分类。

标签间关系分析的一种方式借助预定义的概念关系系统。Plangprasopchok等^[30]研究了用户对个人使用的标签所进行的分类组织过程,并给出了一种合并不同用户的标签组织以得到公共分类结构的方法。Angeletou等^[31]则利用WordNet、在线本体等外部的形式化语义源来提供标签之间的关系,验证了这些形式化语义源在基于社会标注系统的搜索方面的作用。在文献[32]中,Angeletou等进一步对比了利用WordNet及在线本体进行面向标签的查询扩展的效果,并指出WordNet可以扩展更多数量的标签,包含更多不同的语义,同时包含更多的上下位概念。而本体则在上层概念的扩充方面体现出了比较强的效能。Pan等^[33]利用本体来扩展大众分类法。这一方法的本质是将标签对应到本体上,并利用本体作为基础建立与其他标签间的关系。Tsui等^[34]则利用Wikipedia作为辅助分析标签间的层次关系的工具,通过利用标签所对应的Wikipedia网页中对标签词汇的分类提取标签间的层次关系。

预定义的概念关系系统虽然可以有效地帮助分析标签间的关系,但其通常只能用于有限的场景,并且无法有效地适应新出现的标签,因此一些工作也研究直接建立标签间的关联。Solskinnsbakk等^[35]指出缺乏清晰的结构是大众分类法固有的问题,并提出将用户对资源的一次标记作为事务对标签进行关联规则挖掘,通过关联规则置信度选取子节点构建标签层次关系的方法。Cattuto等^[12]研究了社会标记系统中标签间的语义距离,并对比了用于计算标签间相似度的五种方法。他们的研究指出,这些相似度计算方法均可以使用基于共同

标注关系的余弦距离来代替,并且共同标注关系向量和资源向量有助于发现标签的同义关系。Meo等^[36]提出了一种依据用户提交的查询标签进行扩展得到标签体系的方法。针对每一个查询标签,该方法计算其最相似标签,通过计算标签间的相似度得到候选标签集合,并利用标签出现的频率关系构建标签层次,以及利用标签的覆盖率确定标签的语义粒度。Candan等^[37]提出了一种构建标签层次关系的方法,以便提高资源导航的效率。根据标签标记资源的情况,该方法构建标签-资源关系矩阵,对该矩阵进行奇异值分解及奇异值削减,并针对削减后的矩阵应用余弦距离计算标签间的相似度。进一步地,该方法利用能量确定标签间的上下位关系,并利用有向图最小生成树算法构建标签层次关系。

1.1.3 基于标签的Web信息处理

社会标注系统开放、自由、灵活的使用特征令标签可以覆盖更加广阔的主题与领域,同时令标签携带了包括信息被发布和共享时的上下文^[2]、信息本身不具备的特征^[20],以及信息多方面的属性^[27]等大量潜在的信息。充分利用这些潜在的信息可以有效地辅助多种类型的Web信息处理任务,因此标签吸引了Web信息处理领域研究人员的大量关注。

社会标注系统的提出本身是作为对传统的基于受控词汇表、固定分类体系或本体的分类方法的替代。由于同样携带了关于如何依照概念对信息进行分类的信息,人们也研究利用社会标注系统的分类结果构建概念层次关系。Chen等^[38]研究了从社会标注结果中提取基本概念的问题。一个基本概念对应了一组概念中最具有区分度的概念,这样的一组概念很明显适合作为受控词汇表使用。Monnin等^[39]提出基于RDF和标签行为模型的本体构建方法。它化解了各个标签模型之间的冲突,使得用户的每一次标记行为都可以被精确地描述,并通过具体化用户标记资源的动机分析潜在的标签语义。Jie Tang等^[40]首先通过概率主题模型对标签和文档进行建模,并计算标签之间的语义差异程度。针对两个标签间上下位词、同义词和无关词的关系,定义了构建层次、合并和保留三种基本操作,逐步完成了标签本体的构建。Caro等^[41]认为标签的层次体系应该体现出两方面的内容:标签的上下位关系及标签之间的语义相似度。通过利用潜在语义分析标识标签的语义,以及利用标签在文章中出现的上下文,Caro等利用扩展布尔模型将标签逐步地组合到一个层次中,实现概念分类体系的构建。

对于单个的用户来说,社会标注是一种高度个性化信息组织和标注工具。因此,用户个人的信息标注成果,从被用户标注的资源 and 用户所使用的标签两

个方面,体现出了用户自身的兴趣爱好。这种用户个人兴趣的直接体现使社会标注结果特别适合于进行个性化资源推荐任务。个性化资源推荐中一种重要的方法是协作性过滤方法。Meo等^[42]提出了一种基于查询扩展和用户个性化信息强化的方法来提升协作性过滤系统的推荐性能。该方法为每一个用户维护一个个性化信息,利用PageRank方法计算标签的Rank,以此为基础返回一组可能的扩展标签供用户选择。Durão等^[43]提出了一种混合考虑标签的文本相似度、语义相似度、热度、表现力以及标签和用户之间的关系等多种因素的基于标签的支持语义扩展的推荐系统,用于推荐相似的资源。Guan等^[44]研究了基于图的子空间学习方法来实现基于标签的文档推荐方法。给定用户-标签、标签-文档、文档-用户和文档-文档四个关系矩阵,该方法学习一个用户-标签-文档的语义子空间,使其能最大程度地保存那些矩阵之间的关联结构。利用这一子空间,用户没有标记过的文档便可以推荐给用户。Yoshida等^[45]利用标签扩展了基于内容的资源推荐。在他们的方法中,资源之间的相似度使用标签的评级来评价,与用户的日志文件中最为相似的资源则被推荐给用户。Gemmell等^[46]对比了基本的资源推荐、基于标签的资源推荐以及一种基于线性混合的资源推荐方法,并表明混合方法可以在多种不同现实数据集上取得最佳的推荐质量。

作为一种对资源进行分类、索引和查找的工具,标签最为重要的应用是辅助用户对各种类型的信息进行搜索。Golub等^[47]的研究表明,虽然受控词汇表可以提供高质量的标签候选,但自由的标签却可以提供更多的新概念描述,以及超越受控词汇表所能提供的更多的信息。Abbasi等^[48]研究了用于社会标注搜索的查询松弛方法。该方法利用标签的分布情况确定标签的语义抽象层次,并利用资源-标签以及用户-标签矩阵来计算资源的上下文相似性,并以此为基础扩展查询线索,实现查询松弛。Abel等^[49]将资源的分组信息作为背景扩展社会标注信息,实现对信息的有效检索。该方法利用资源分组信息为原本不相关的信息提供一个共同的用户组作为上下文,利用一组标记规则如分组的标签等价于组内资源的标签等实现标签信息的传递,并利用FolkRank^[14]方法实现结合上下文信息的资源排序方法。Amer-Yahia等^[50]认为搜索过程不仅依赖于用户的需求与用户的历史行为,还依赖于来自其他用户所能提供的信息的帮助。基于这种观察,Amer-Yahia等利用LDA(Latent Dirichlet Allocation)或手工指定的主题向量发现用户的社区,并在这种社区的基础上实现了基于标签的资源搜索。Djuana等^[51]从社会标注系统中提取领域本体,并反过来用于标签推荐。他们的研究表明,利用提取的领域本体来帮助对推荐结果进行重新排序将可以进一步提升推荐的质量。

由于标签是由用户在使用资源的过程中逐渐添加的,其可以携带大量原始信息中没有明确指明的细节。这种额外的标注信息令标签可以揭示关于信息更多的内容,进而帮助搜索系统提升搜索结果质量。Biancalana等^[52]提出了一种基于标签的查询扩展方法,该方法记录和处理用户的行为,以便依据用户的兴趣提供个性化的搜索结果。过程对用户完全透明,依赖用户进行的选择、提交的关键字以及点选的网页进行,并利用搜索过程获得的信息进行动态的更新。针对一个查询,该方法使用不同的扩展方法,以针对不同的语义项或领域进行扩展,并将结果按照不同的组别进行分组,呈现在一个页面中。Cattuto等^[12]的研究表明,标签的共现向量和标签-资源向量有助于发现同义词的集合、拼写错误以及 WordNet 同义词集合,因此可以被用于查询扩展任务。Bhagwan等^[53]则探讨了使用社会标注改善桌面搜索质量的方法。桌面搜索面临的主要问题是冷启动问题。针对这一问题,Bhagwan等利用社会标注网站提供的标签-资源关系为桌面搜索提供基础标注,解决了冷启动问题,提供了一个有效的元数据推荐机制,同时保护了用户的隐私。

除了这些与分类及搜索直接相关的领域,社会标注系统也因其灵活性而在大量其他领域中发挥着特有的作用。Arabshian等^[54]利用基于社会标注的服务标注系统对服务进行索引,并通过将标签对应到一个本体系统上实现对Web服务的发现和选取。Gawinecki等^[13]也采用了类似的方法,通过结合社会标注系统的灵活性与结构化的Web服务功能和结构描述实现了一个结构化的Web服务社会标注系统来提升Web服务的描述能力。Bouillet等^[55]也利用用户参与的服务标记实现了对Web服务的建模。传统的Web服务模型如语义Web服务模型建模成本高昂,同时要求很多的参与、标注和管理。而Bouillet等提出的方法利用了社会标注系统不需要集中管理的优势,虽然描述能力低于传统的服务建模方法,但其已经能够提供基于标签的服务操作输入和输出描述,且在实验中体现出足够的标注能力。Chou等^[56]则利用标签来描述用户的服务需求和服务所能提供的功能,并使用形式化概念分析匹配用户的需求和服务的功能,为构建MashUp应用提供支持。除了Web服务相关研究之外,标签也在多媒体信息检索方面体现出了特有的价值。Abbasi等^[57]研究了结合用户信息从社会标注系统中提取具有特殊属性的图片的方法。通过将具有特殊性质的用户群体所使用的标签作为样本,以及将特定类型用户群体所使用的标签作为反例,该方法学习并识别具有特殊标记意义的标签,并通过这种方法从Flickr.com中识别地标建筑图片。

上述研究表明,标签及其组成的社会标注系统可以为大量不同类型的Web信息处理任务提供支持。这种广泛的应用,一方面证明了社会标注系统巨大的

潜力,另一方面也对社会标注系统的标注质量提出了更高的要求。因此,如何进一步地提升社会标注系统的标注质量,以便促进社会标注系统在不同领域中的应用,使其发挥更大的价值,成为了社会标注领域中引起广泛关注的问题。

1.1.4 标签推荐

社会标注系统开放与自由的信息分类方法为用户带来了巨大的灵活性。这种灵活性令用户可以为信息提供尽可能丰富、具体的元数据信息,令社会标注系统可以提供除信息分类之外的大量其他类型的元数据。这种信息的丰富性赋予了社会标注系统大量优秀的性质,也使其可以被用于支持多种类型的Web信息处理任务。然而,这种完全不受控制的信息发布方法使得用户只能完全依照个人的习惯以及对信息的理解来控制标签的质量。这种缺乏质量控制的分类方法为社会标注系统带来了如下方面的现象^[7]:

(1) 分类视角不一致:在通常情况下,一条信息可以包含多个方面的内容。即便只包含一方面的内容,随着出发点的不同,也可以得出完全不同的分类。此外,用户的信息需求及产生信息需求的上下文背景也不完全相同,这也导致了用户可能会使用多样的视角来描述信息的分类。一方面,这种多样化的视角为资源带来了角度丰富且其原始内容无法涵盖的元数据描述,可以有效地扩展资源搜索的线索,提升搜索的质量。但另一方面,这种多样性的视角也使得很多标注结果难以被直观地理解,而大量难以理解的标注必然会以噪声的形式影响整体的标注质量。

(2) 分类词汇不一致:社会标注系统使用基于自然语言的标签来分类信息。自然语言的灵活性导致了很多内容可以使用多种不同的表达形式来描述,并导致了分类词汇使用上的不一致,具体地体现在两个方面。一方面,相同的概念通常可以使用多个不同的词汇进行描述,而不同的用户会倾向于使用不同的词汇表述相同的概念。另一方面,同一领域内的词汇其语义通常存在着粒度上的差异,使得一些词汇可以涵盖其他一组词汇的语义。这些现象的存在导致用户在使用标签进行信息标注时使用不一致的分类词汇,进而导致用户查找信息时无法准确使用标签来完善地将个人的信息需求与资源的标注进行对应,影响信息的检索质量。

(3) 分类结果不一致:自然语言的灵活性所导致的另一个现象是标签所对应的词汇可能具有多种不同的语义信息,即标签的语义存在歧义性。由于用户是依照标签的语义对信息和标签进行对应的,并且歧义标签的语义通常横跨多个不同的领域,几种不同语义之间可能完全不存在关联,这种标签语义的歧义性导致了同一分类下存在着大量语义完全不同的信息。很明显,这些语义无关