

概 述

Francesco Ricci、Lior Rokach 和 Bracha Shapira

摘要 推荐系统(Recommender System, RS)是向用户建议有用物品的软件工具和技术。在本章中,我们会简要地介绍推荐系统的基本思想和概念。主要目标是用连贯和结构化的方式描述这本手册的章节内容,以此来帮助读者理解这本手册提供的极其丰富和详细的内容。

1.1 简介

推荐系统(RS)是一种软件工具和技术方法,它可以向用户建议有用的物品[60, 85, 25],这种建议适用于多种决策过程,如购买什么物品、听什么音乐、在网上浏览什么新闻等。

“物品”是用来表示系统向用户推荐内容的总称。一个推荐系统通常专注于一个特定类型的物品(如 CD 或新闻),因此它的设计、图形用户界面以及用于生成建议的核心的推荐技术都是为特定类型的物品提供有用和有效的建议而定制的。

推荐系统主要针对的是那些缺乏足够的个人经验和能力的人,他们无法评估潜在的大量可供选择的物品,比如,某个网站提供的商品[85]。一个典型的例子是图书推荐系统,它帮助用户挑选一本书来读。在亚马逊,网站采用个性化推荐系统为每个客户进行推荐[47]。由于推荐通常是个性化的,不同的用户或用户组接收的建议是不同的。当然也存在非个性化推荐。它们都是非常简单的,通常出现在报纸或杂志上。典型的例子包括书籍和 CD 等的 top 10 推荐(最热销的前 10 名)。虽然在某些情况下它们可能是有用和有效的,但这些类型的非个性化推荐通常不是推荐系统研究要解决的问题。

个性化推荐最简单的形式是提供一个排好序的物品列表。通过这个排序列表,推荐系统试图根据用户的偏好和其他约束条件来预测最合适的产品或服务。为了完成这样的计算任务,推荐系统收集用户的喜好,这种喜好是显式的,如为产品打分,或通过解释用户的行为做出推断。例如,推荐系统可能会把访问某个特定商品详情页的行为作为该用户喜爱这个主页上的商品的隐式信号。

推荐系统的发展源于一个很简单的现象:人们在做日常工作和日常决策时总是依赖于其他人提供的建议[60, 70]。例如,要选择一本书的时候,通常依靠朋友的推荐;雇主依靠推荐信做招聘的决定;当选择观看的影片时,人们倾向于阅读并且依赖影评家写在报纸

Francesco Ricci, Faculty of Computer Science, Free University of Bozen-Bolzano, Italy e-mail: fricci@unibz.it
Lior Rokach, Department of Information Systems Engineering, Ben-Gurion University of the Negev, Israel
e-mail: liorrk@bgu.ac.il

Bracha Shapira, Department of Information Systems Engineering, Ben-Gurion University of the Negev, Israel
e-mail: bshapira@bgu.ac.il

翻译:燕山大学-王孝先 审核:王二朋,承皓,严强

上的影评。

为了模拟这种行为,第一个推荐系统通过算法将社区用户的建议推荐给一个活跃用户,也就是在寻找推荐的用户。推荐的物品是这些相似用户(那些品味相似的用户)喜欢的。这种方法称为协同过滤,它的理论依据是,如果这个活跃的用户以前与一些用户有相似爱好,那么来自这些相似用户的其他推荐应该是相关的,这些推荐也是此活跃用户感兴趣的。

随着电子商务网站的发展,迫切需要出现一种能过滤所有可用的替代品的推荐系统。让用户从这样纷繁复杂的物品(产品和服务)中作出最恰当的选择是非常困难的。

互联网信息的爆炸式增长和种类的纷繁复杂以及新兴电子商务服务(购买产品、产品比较、拍卖等)的出现经常压得用户喘不过气来,导致用户无所适从。这种选择多样性不但没有产生经济效益,反而降低了用户满意度。大家都明白可选择是好的,但是太多的选择就不是很好了。实际上,随着选择对自由、自治和自我决定带来的影响变得过度,我们就会因为选择而觉得自由是一件痛苦的事情[96]。

近年来,推荐系统被证明是一种解决信息过载问题的有效工具。从根本上来讲,推荐系统是通过为用户指引该用户不熟悉的新物品来解决信息过载现象的,这些新物品或许与该用户当前的需求相关。对于用户每一个清晰表达的请求,根据不同的推荐方法和用户所处的环境和需求,推荐系统利用存储在自定义数据库的关于用户、可用物品以及先前交易的数据和各种类型的其他知识产生推荐内容。然后用户可以浏览推荐的内容。用户可能接受也可能不接受推荐,也可能马上或者过一段时间提供隐式或者显式的反馈。所有这些用户的行为和反馈可以存储在推荐数据库,并且可用于在下次用户和系统相互作用时产生新的推荐。

如上所述,相比于其他经典的信息系统的工具和技术(如数据库或搜索引擎),推荐系统的研究是相对较新的。在20世纪90年代中期,推荐系统成为一个独立的研究领域[35, 60, 70, 7]。近年来,下面的事实说明人们对推荐系统的兴趣大大增加:

- 对于一些有很高评价的网站,如 Amazon.com、YouTube、Netflix、Yahoo!、Tripadvisor、Last.fm 和 IMDb,推荐系统扮演了重要的角色。此外,许多媒体公司正在开发和部署推荐系统作为它们提供给用户的服务的一部分。例如,Netflix(一家提供在线电影租赁服务的网站)向第一个能够成功地显著提高推荐系统性能的团队奖励了100万美元[54]。
- 本领域有专门的正式会议和相关的专题研讨会。在这里专指 ACM 推荐系统会议(RecSys),该会议成立于2007年,现在是新的推荐技术的研究和应用的顶级年度盛会。此外,像数据库、信息系统和自适应系统领域等更传统的大会也经常包括以推荐系统为主题的会议。在这些会议中,值得一提的是 ACM SIGIR(Special Interest Group on Information Retrieval)、UMAP(User Modeling, Adaptation and Personalization)和 ACM SIGMOD(Special Interest Group on Management Of Data)。
- 世界各地的高等教育机构在本科生和研究生的课程中已经提供专门研究推荐系统的课程;在计算机科学会议中关于推荐系统的专题报告也引起了人们的极大关注;最近一本介绍推荐系统技术的书也已经出版[48]。
- 在学术期刊中,已经有一些特刊专题涵盖推荐系统领域的研究和发展。期刊中包括推荐系统专刊的有:《AI Communications》(2008)、《IEEE Intelligent Systems》(2007)、《International Journal of Electronic Commerce》(2006)、《International Journal of Computer Science and Applications》(2006)、《ACM Transactions on

Computer-Human Interaction》(2005)和《ACM Transactions on Information Systems》(2004)。

本章简要介绍了推荐系统的基本思想和概念。主要目标并不是对推荐系统给出包罗万象的综合介绍和概览,而是用一个连贯和结构化的方式描述这本手册的章节内容,以此帮助读者理解这本手册提供的极其丰富和详细的内容。

本书分成五部分:推荐相关技术、推荐系统的应用和评价、推荐系统的交互、推荐系统和社区、主流算法。

- 第一部分介绍当前构建推荐系统最普遍使用的技术,例如,协同过滤、基于内容的数据挖掘的方法和上下文相关的方法。
- 第二部分概述了已用于评价推荐质量的技术和方法。这一部分还涉及推荐系统设计与实践方面;描述设计和实施推荐系统的注意事项;为选择更合适的算法提供准则。这部分还考虑到可能影响推荐系统设计(域、设备、用户等)的方面。最后是评估开发的推荐系统所用的方法、挑战和评测指标。
- 第三部分包括一些涉及推荐系统如何呈现、浏览、解释和可视化等若干问题的论文。这里讨论的技术使推荐过程更加结构化以及具有可交互性。
- 第四部分讨论的是一个相当新颖的话题,利用各类用户生成内容(UGC,如标签、搜索查询、信任评价等)来产生类型新颖且更可信的推荐结果。尽管这个话题相对新颖,但它实质上根植于基于协同推荐核心理念。
- 第五部分展示了关于几个高级课题的论文,例如,探索如何用主动学习的原则来指导新知识的获取;防止推荐系统受恶意用户攻击的合适技术;如何整合多种类型的用户反馈以及用户偏好信息来构造更可靠的推荐系统。

1.2 推荐系统的功能

在前面的内容中,将推荐系统定义为软件工具和技术,这些工具和技术用于为用户提供物品建议信息,而这些推荐信息用户或许会利用。现在我们要完善该定义,以此来表明推荐系统可以起到一系列可能的作用。首先,我们必须区别推荐系统在服务提供商和用户这两方面分别起到的作用。例如,旅游中间商(如 Expedia.com)或目的地管理机构(如 Visitfinland.com)通常会采用旅游推荐系统来增加营业额,比如,销售更多的房间,或者增加目的地的游客数量[86]。然而,用户访问这两个系统的主要动机是在去某个目的地旅游时,找到合适的酒店和有趣的事件或景点。

事实上,服务提供商采用这种技术的原因是多样的:

- **增加物品销售数量。**这可能是商用推荐系统最重要的作用,即与没有使用任何一种推荐系统相比,能卖出一些额外的物品。能做到这一点是因为推荐物品可能适合了用户的需求和愿望。或许用户在尝试过几个推荐后,会认识到这一点[⊖]。非商业应用也有类似的目标,虽然用户在选择物品的时候无须任何费用。例如,一个基于内容的新闻推荐系统的目的是提高网站上新闻类物品的阅读量。通常,从服务提供商的角度来看,引入推荐系统的主要目的是提高转化率,即接受推荐并消费物品的用户数量比上仅浏览了这些信息的普通访客数量。

⊖ 说服用户接受推荐的问题,会在我们解释预测用户对一物品的兴趣与用户挑选推荐物品的可能性之间的差异时再次进行讨论。

- **出售更多种类的物品。**一个推荐系统的另一个主要功能是让用户能够选择物品。如果没有这样精准的推荐系统，用户可能很难找到自己要选择的物品。例如，对于像 Netflix 这样的电影推荐系统，服务提供者感兴趣的是要能租出去清单里的所有 DVD，而不仅仅是最热门的。如果没有推荐系统，这就很困难了。因为服务提供商没法保证推销的电影就一定适合特定用户的口味。相反地，推荐系统就能向合适的用户建议或推销不那么热门的电影。
- **增加用户满意度。**一个设计良好的推荐系统还可以提高网站或者应用程序的用户体验。用户会觉得推荐结果既有趣又相关，而且如果人机交互设计得合理，他还会乐于使用这个系统。准确有效的推荐结果，加上可用的用户接口，这些措施将会增加用户对系统的主观评价。反过来这将增加系统的使用率和推荐结果被接受的可能性。
- **增加用户忠诚度。**用户应该忠于一个网站，这样当用户访问该网站时，该网站能够识别出老客户并把他作为一个有价值的访问者。这是一个推荐系统的固有特性，因为许多推荐系统是利用用户之前与网站的交互信息来产生推荐结果的，这些交互信息包括该用户对物品的评分记录等。因此，用户与网站的交互时间越久，用户模型就变得越精确，即用户偏好的系统表示越准确；与此同时，更多的推荐能有效地匹配用户的喜好。
- **更好地了解用户需求。**推荐系统另一个重要的功能是用来描述用户的喜好（这一功能能够在许多其他应用中使用），这些喜好是收集到的显式反馈或者由系统预测到的（隐性反馈）。然后，为了其他目的，如提高物品的库存管理或生产管理，服务提供商可能重新使用这方面的知识。例如，在旅游领域，目的地管理机构可以通过分析由推荐系统收集的数据（用户的交易），决定为一个特定区域的新客户部门做宣传或为特定类型的促销信息发布广告。

我们在上述中提到了电子服务提供商引入推荐系统的几个重要动机。但是如果推荐系统能够有效地支持用户的任务或目标，他们或许也会考虑使用推荐系统。因此推荐系统必须平衡这两类参与者的需求，并为两者都提供有价值的服务。

Herlocker 等[25]的一篇论文已经成为这一领域经典的参考文献，文中定义了推荐系统能够实现的 11 个常见的功能。有些可能通常被视为与推荐系统相关的主要或核心任务，即可能会对用户有用的物品推荐。其他的可能更多地被视为以“机会主义”的方式开发的。事实上，这种任务的分化与使用搜索引擎所遇到的事情很相似，搜索引擎的主要功能是找到用户需求信息的相关文件，但它也可以用于检查一个网页的重要性（在查询结果列表中该页的位置）或发现一个词在文档中的不同用法。

- **发现一些好的物品：**根据用户对物品的喜欢程度（例如，1 到 5 星的评分）的预测结果，我们可以用列表榜单的形式推荐给用户一些物品。对商业系统来说，这是推荐系统的主要任务（见第 9 章）。有些系统不显示具体的预测评分。
- **发现所有好的物品：**推荐所有能满足用户需求的物品。在这种情况下，仅找到一些合适的物品是不够的。当相关物品的数量很少或当推荐系统扮演关键角色时，推荐系统要格外精确。例如，推荐系统在医疗或金融领域的应用。在这些情况下，除了仔细评估所有可能性带来的好处，用户还可以从推荐系统的物品排序或者推荐系统额外产生的解释（推荐理由）中受益。
- **产品注解：**在给定的上下文语境中（如一个物品推荐列表），我们根据用户的长期

偏好来确定这些物品的重要性。例如，一个电视推荐系统会标识在电子节目菜单中出现的哪些电视节目是值得观看的(第 18 章提供了这个任务的一个有趣实例)。

- **推荐系列产品：**这个思路是将物品的序列作为一个令用户满意的整体进行推荐，而不是集中产生单一的推荐。典型的例子包括推荐一个电视节目系列；推荐一本数据挖掘的书之后，还推荐一本关于推荐系统的书；或者是一个音乐曲目的总集[99]，[39]。
- **搭配推荐：**提供一组完美搭配的物品。例如，一个旅行计划可能由某个特定区域的不同景点、目的地和住宿服务组成。从用户的角度来看，用户可以考虑这些不同的替代方案，并选择一个唯一的旅游目的地[87]。
- **闲逛：**在这项任务中，用户只是简单地浏览目录而并不带有强烈的购买意图。推荐系统的任务是帮助用户浏览一些其在特定浏览时期可能会感兴趣的物品。自适应超媒体技术[23]已经支持该服务。
- **发现可信的推荐系统：**有些用户不信任推荐系统，于是他们抱着试试看的态度去尝试推荐系统的推荐结果。因此，除了那些仅仅想要获得推荐的用户，一些系统还提供特定的功能让用户测试推荐系统的行为。
- **完善用户资料：**这涉及用户向推荐系统提供自己偏好信息的能力。为了提供个性化推荐，这是一个基本任务，也是绝对必要的。如果系统不了解活跃用户(即寻求推荐帮助用户)的明确信息，那系统只能提供给该活跃用户与一般用户一样的推荐。
- **自我表达：**有些用户可能一点也不在意给出的推荐结果。相反，对他们重要的是，系统允许他们展示他们的评分，并表达他们的评价和观念。这种行为产生的用户满意度仍会有助于保持用户和应用程序的紧密关系(正如我们前面讨论服务提供商的动机中提到的那样)。
- **帮助他人：**有些用户乐于贡献信息，如他们对物品的评价(评分)，因为他们相信社区能从他们的贡献中获得益处。这可能是将这类信息输入推荐系统的主要动机，即使他们不经常使用这个推荐系统。例如，汽车推荐系统中，一个已经买了新车的用户将评价信息输入推荐系统时，他更多考虑的是这些信息对于其他用户有用，而不是为了下次再买一辆车。
- **影响他人：**在基于 Web 的推荐系统中，某些用户的主要目标是对其他购买特定产品的用户产生明显的影响。实际情况是，有一些恶意用户可能利用系统仅仅用来促进或抑制某些物品的销售(见第 25 章)。

正如这些观点所表明的那样，信息系统中的推荐系统的作用是有很大区别的。这种多样性需要利用一系列不同的知识源和技术。在接下来的两节中，我们将讨论一个推荐系统的数据和推荐系统常用的核心技术。

1.3 数据和知识资源

推荐系统是信息处理系统，为了实现推荐，该系统会积极收集各种数据。数据主要是关于推荐的物品和收到这些推荐结果的用户，但是由于推荐系统获得的数据和知识来源可能区别很大，它们最终是否可以被利用取决于推荐技术(见 1.4 节)。这种推荐技术将在本手册的不同章节中有更加清晰的阐述(详见第 11 章)。

通常，有的推荐技术用的知识(领域)较少，如只用到用户评分或者对物品的评价等一

些简单且基础的数据(第4、5章)。其他的技术则依赖于更多的知识,如利用用户或物品的本体性描述(第3章),或者约束性条件(第6章),或者用户的社交关系和行为活动(第19章)。在任何情况下,推荐系统使用的数据一般指的是三种对象:物品、用户和事务,也就是用户和物品的关系。

物品。物品是被推荐的对象集。物品具有复杂性和有价值或效用的特点。如果物品对于用户是有用的,那么物品的作用就是积极的;否则如果物品对于用户不适合,那物品的作用就是消极的,从而导致用户在选择时做出错误决定。我们注意到,当一个用户需要获得一个物品时,他总会付出代价,其中包括搜索物品的认知代价和最终为物品支付的费用。

例如,一个新闻推荐系统的设计师必须考虑新闻物品的复杂性,即新闻的结构、文本表述和任何新闻物品的时变重要性。但是推荐系统的设计者必须意识到,即使用户没有花钱阅读新闻,他们还是为搜索并阅读这些新闻物品付出了认知上的代价。如果选择的物品和用户相关,这个代价就被用户得到有用信息的收益覆盖了,可一旦不相关,推荐物品对用户的净价值就是负面的在其他领域,如汽车或者金融投资,当选择最恰当的推荐方法时,物品真正的货币成本成为一个考虑的重要因素。

复杂度低且价值小的物品是:新闻、网页、书籍、光盘、电影。复杂度高且价值大的物品是:数码相机、手机、个人电脑等。我们通常认为最复杂的物品是保险政策、金融投资、旅游、工作[72]。

根据其核心技术,推荐系统可以使用物品集的一系列属性和特征。例如,在电影推荐系统中,我们可以使用电影种类(如喜剧、悲剧等)信息、导演信息和演员信息来描述电影,并用于弄清楚物品的效用是如何依赖其特征的。物品集可以用各种信息和表述方法来表示,如可以简约到单一的ID码,或者丰富到为一组属性,甚至是该领域本体表示中的一个概念(第3章)。

用户。正如前面提到的那样,推荐系统的用户可能有非常不同的目的和特点。为了使推荐结果和人机交互个性化,推荐系统使用用户的一系列信息。这种信息可以用不同的方式组织,而且同样的是,选择哪种信息建模取决于推荐技术。

例如,在协同过滤中,所有用户被建模为一个简单的列表,该列表包含每个用户对若干个物品的评分记录。在基于人口统计学的推荐系统中,会用到如年龄、性别、职业和教育程度等社会统计学特征。用户数据用来构成用户模型[21, 32]。用户模型简明扼要地描述了用户的特征,即对用户偏好和需求进行编码。不同的建模方法已经在推荐系统中得到应用,在一定意义上,推荐系统可以被看作一个构建并使用用户模型来产生推荐的工具[19, 20]。如果没有一个实用的用户模型,个性化推荐是不可能的(除非推荐系统本身就是像top10那样是非个性化的),因此用户模型起到非常重要的作用。例如,再次考虑协同过滤方法,要么用户被直接描述为他对物品的评价记录,要么系统根据该用户的评分记录构建一个因子向量,不同用户之间的区别是这些因子权重在他们模型中的差别(第4、5章)。

用户也可以通过他们的行为模式数据来描述,如网站浏览模式(在基于Web的推荐系统中)[107]或旅游搜索模式(在旅游推荐系统中)[60]。此外,用户数据包括用户间的关系,如用户间的信任级别(第20章)。推荐系统能利用这些信息给用户推荐物品集,而这些物品集也是相似用户或可信任用户所喜欢的。

事务(transaction)。我们一般将一个事务看作用户和推荐系统进行交互的一条记录。

人机交互过程中产生的这种类似日志的数据存储着重要的信息,并且这些数据对系统中推荐生成算法是有用的。比如,事务日志可能会涉及用户选择物品,以及特定推荐所处上下文描述信息(如用户的目的和查询词)。如果可能,事务也会包括用户提供的显式反馈,如对选择物品的评分。

实际上,评分是推荐系统收集交易数据最流行的方式。这些评分可能是用显式或者隐式的方式收集的。收集显式评分时,用户需要在某个评级尺度内给出自己对物品的看法。根据[93],评级可以采用各种方式:

- 数字评分,就像 Amazon.com 的书籍推荐系统中的 1 到 5 星的评价。
- 序数评价,例如,“强烈同意,同意,一般,不同意,强烈反对”,用户在其中选择最能代表自己观点的术语(一般是通过问卷调查)。
- 二元制评价,用户仅仅被要求确定一个物品的好或者不好。
- 一元制评价,用来表示用户已经看到或者买了一个物品,或由此对物品进行明确的评价。在这种情况下,评分值的缺失意味着关联用户和物品的信息是未知的(也许用户在其他地方买了这个物品)。

另一种评价的形式就是关联用户和物品的标签。例如,在 Movielens 推荐系统(<http://movielens.umn.edu>)中,标签表示 Movielens 用户对电影的感觉,例如,“太长”或“表演不错”。第 19 章侧重讲解这类交互行为。

从事务中隐式收集用户评级,系统的目标是根据用户的行为推断用户的意图。例如,如果用户在亚马逊网站输入“瑜伽”进行搜索,那么她将得到关于书的一个很长的列表。作为回报,用户为了获得额外信息会单击列表中的书。从这点上看,系统可以推断用户对那本书有一定的兴趣了。

在会话(conversational)系统中,即支持交互过程的系统中,交易模型更加精确。在这些系统中,用户请求和系统行为交替出现(见第 13 章)。更准确地说,用户请求一个推荐,系统就产生一个推荐列表。但是系统仍然需要额外的用户偏好信息,以期产生更好的结果。在这个交易模型中,系统收集各种请求—响应信息,并且最终通过观察推荐过程的结果来修改系统的交互策略[60]。

1.4 推荐技术

为了实现其核心功能,即识别对用户有用的物品,推荐系统必须预测出有推荐价值的物品。为了实现上述目的,系统必须能预测一些物品的效用性(the utility of some of them),或者至少对物品的效用性作对比,然后根据比较决定该推荐的物品。虽然推荐算法中对预测这一步描述不是很明确,但是我们仍然可以使用统一的模型来描述推荐系统的一般作用。我们的目的是提供给读者一个统一的思路,而不是所有不同推荐方法的总和,这些方法会在本书中逐步讲解。

为了说明推荐系统中的预测这一步,我们考虑一个简单的非个性化的推荐算法,该算法仅推荐最流行的歌曲。这个方法的理论依据就是在不知道用户偏好这样更精确的信息的情况下,有理由认为一首流行度高的歌曲会被很多用户喜欢,所以很可能也被一个普通用户喜欢,因此选择一首流行度高的歌曲的效果肯定会比随机选取的歌曲好。因此,这些流行度高的音乐的有效性对于普通用户理所当然就要高。

文献[3]中提到把核心推荐计算过程当作预测某件物品对某个用户的效用的观点。他们把用户 u 对物品 i 的可用度建模为实数值函数 $R(u, i)$,在协同过滤中通常指的是用户

对物品的评分。然后协同过滤推荐系统的主要任务是通过用户与物品对来预测 R 的值,即计算 $\hat{R}(u, i)$, 这里把 $\hat{R}$ 作为估计值, 并由此得到真实函数 R 的值。接下来, 在物品集上算出活跃用户 u 的预测值也就是 $\hat{R}(u, i_1), \dots, \hat{R}(u, i_N)$ 之后, 系统将会选择最大效用的物品 $i_{j_1}, \dots, i_{j_K} (K \leq N)$ 作为推荐结果。 K 通常是个小的数字, 要远小于物品集的基数, 或者说是用户效用预测计算所依赖的物品的基数, 即推荐系统“过滤”出推荐给用户的物品。

正如前面所说, 一些推荐系统在做出推荐之前不是计算全部效用, 但是它们可以应用很多启发式的方法猜测一个物品对用户是否有帮助。典型的案例是专家系统。这些效用预测是通过特殊算法(如下)计算的, 并使用了各种各样的关于知识、用户、物品和效用函数本身的知识(见 1.3 节)[25]。例如, 系统假定效用函数是布尔型的, 只需要确定一个物品是否对用户有用。因此, 对于一个请求推荐的用户, 如果系统能够获得该用户的一些知识(有可能得不到), 如物品信息以及曾经接收到推荐结果的其他用户的知识, 系统就能使用恰当的算法利用这些信息产生各种效用预测并且据此产生推荐[25]。

我们有必要注意, 有些时候物品对用户的效用是依赖于其他可变因素的, 我们把这些可变因素统称为“语境”[1]。例如, 物品对用户的效用会被用户的领域信息所影响(例如, 使用数码相机的高手与新手), 或者随着推荐请求发生的时间而变化。或者用户可能对离他当前位置近的物品(如一家饭店)更感兴趣。因此, 推荐结果必须与这些特殊的附加信息相适应。但是这样做的结果是, 准确地计算出正确的推荐越来越困难。

本书介绍了许多不同种类的推荐系统, 这些推荐系统根据使用的信息和用户领域知识的不同而变化, 但正如一开始所说那样还是主要随着推荐算法而变化, 即如何预测推荐内容的效用。其他的不同是推荐系统最终如何组合推荐结果并如何把它展示给用户用以响应用户的请求。这些方面在导言的后面也会讨论。

为了提供不同类型推荐系统的综述, 我们引用[25]提出的分类法, 此分类方法是区分推荐系统的一种经典的方法。文献[25]为六种不同的推荐方法做了划分:

基于内容(content-based): 系统为用户推荐与他们过去的兴趣类似的物品。物品间的相似性是基于被比较的物品的特征来计算的。例如, 如果某个用户对一部喜剧电影有了正面的评价, 那么系统就能学会从喜剧类型中(为该用户)推荐其他电影。第 3 章给出了基于内容的推荐系统的综述, 梳理出了在涉及系统设计和实现时广泛性和多样性方面的关系, 除此之外, 还介绍了基于内容推荐的基本概念、专业术语、高层次的体系结构以及主要的优点和缺点。接下来对在几个应用领域内使用的最先进系统做了概述。报告还包括了在如何表示物品和用户信息方面的经典方法和最新技术的全面描述。最后讨论了推荐系统的趋势和引领下一代推荐系统的未来研究。

协同过滤(collaborative filtering): 这种方法是找到与用户有相同品味的用户, 然后将相似用户过去喜欢的物品推荐给用户, [93]是对这种方法有最简单和最原始的实现。两用户间的相似偏好是通过计算用户历史评分记录相似度得到的。这也是[94]将协同过滤比作“人对人的相互关系”的原因。协同过滤被认为是推荐系统最流行和最广泛实现的技术。

第 4 章介绍了基于邻域的协同过滤方法。这种方法关注物品之间的关系或者用户之间的关系。基于物品的方法依据同一用户对与某个物品的相似物品集的评分, 对用户对该物品的偏好建模。基于邻域的方法享有相当的知名度, 因为它们简单、高效以及具有产生精确计算和个性化推荐的能力。作者将会说明实现基于邻居推荐系统所必需的结论, 并且提供了得到这些结论所需的信息。

最后,第4章还涉及了数据稀疏和覆盖率有限的问题,而这些问题经常出现在大型电子商务推荐系统中。本章提出了这些问题的一些解决方法。

第5章介绍了构建协同过滤推荐系统的最新进展。作者特别介绍了隐语义模型(LFM),例如,矩阵因子分解(如奇异值分解、SVD)。这些方法把用户集和物品集映射到同一个隐语义空间。这样就可以通过因子同时表示产品和用户,利用隐语义空间解释根据用户反馈自动推断出的评分。作者解释了SVD如何处理这些数据的额外特征,包括隐式反馈和时间信息。还描述了克服基于邻域的技术存在的缺点的技术,为此他们建议使用包含了全局优化技术的更加严格的数学公式。利用这些技术我们就能够放宽邻域大小的限制,同时又能把隐性反馈和动态时序信息增加到模型中。预测结果的准确性与矩阵因子分解模型的准确性很接近,同时又提供了一些实用的优势。

基于人口统计学的(demographic):这种类型的推荐系统推荐物品时是基于人口统计信息的。我们假设不同的人群信息应该产生不同的推荐。许多网站采用基于人口统计学的简单而有效的个性化解决方案。例如,根据用户的语言或者国籍,划分到特定的网站。或者根据用户的年龄定制推荐。虽然这种方法在营销的文献中相当流行,但是推荐系统方面对此一直很少研究[59]。

基于知识(knowledge-based):基于知识的系统根据特定的领域知识推荐物品,这些知识是关于如何确定物品的哪些特征能够满足用户需要和偏好,以及最终如何确定物品对用户有用。著名的基于知识的推荐系统是基于案例的[22, 87]。在这些系统中,相似函数用来估算用户需求(问题描述)与推荐(解决问题)的匹配度。这里的相似性得分,可以理解为用户推荐的可用性。

基于约束的系统是另一种基于知识的推荐系统(第6章)。从使用的知识(knowledge)方面来说,这两个系统是相似的:收集用户需求;当找不到解决方法的时候系统自动提供不合理需求的修改方案;并且能对推荐做出解释。这两者主要的不同在于解决方案的计算方法。基于案例的推荐是基于相似的方法,然而,基于约束的推荐系统主要是利用预定义的知识库,这些库包括了如何把消费者需求和物品特征相关联的明确规则。

在刚开始部署的时候,基于知识的系统往往比其他方法工作得更好。但是如果它们没有配备自动学习组件,那么其他利用用户日志或人机交互(如在协同过滤中的交互)信息这样浅显方法的系统就可能超越它。

基于社区(community-based):这种推荐方法依赖用户朋友的偏好。这种技术有个业界流行的表述“告诉我你的朋友是谁,我将知道你是谁”[8, 14]。有证据表明,人们往往都会更依赖朋友的建议而不是陌生人的建议[103]。这个现象的出现,加上日益普及的社交网络,于是基于社区的推荐系统就应运而生,并且得到人们越来越多的关注。这种系统通常叫作社会化推荐系统[34]。这种推荐系统获取用户的社会关系和用户朋友的偏好等信息并以此进行建模。推荐结果基于用户朋友提供的评分。实际上,这类推荐系统是随着社交网络产生的,可以简单而又全面地采集与用户社交关系相关的数据。

在这个方面的研究还处于起始阶段,并且关于系统性能的定论还很混乱。例如,[34, 64]对社交网络推荐系统做了全面的报告。报告显示,一般情况下,这类系统的准确性没有传统的协同过滤方法高,除非是用户对一个特殊物品的评价变化特别大(即有争议的物品)或者冷启动等特殊的情况。在这种情况下,用户不能提供足够多的评分去计算与其他用户的相似度。其他研究人员表明,在某些情况下,利用社交网络的数据产生的推荐结果比使用用户资料相似度数据产生的推荐结果更加准确[37],并且把社交网络数据增加到传

统的协同过滤算法中能够提高推荐结果的准确性[36]。第20章概述了该领域的研究成果,并对当前结论进行了分析。

混合推荐系统(hybrid recommender system): 这类推荐系统综合了上面提到的技术。混合推荐就是综合A和B方法,利用A的优势弥补B的不足。例如,协同过滤方法遭遇的新物品冷启动问题,也就是不能推荐尚未被评分的物品。而基于内容的方法没有这个限制,因为新物品的预测是基于物品描述(特征),而这些特征都是容易获得的。给出两个(或多个)基本的推荐技术,采用一些方法将这些技术综合起来产生一个混合的系统(文献[25]有详细描述)。

我们说过,当用户需要推荐的时候,基于上下文的方法能使系统推荐更加个性化。例如,考虑时间上下文这个因素时,冬天和夏天的假期推荐应该有很大的区别。或者如饭店推荐系统,工作日和同事一起吃饭的推荐应该和周六晚上与朋友吃饭的推荐有很大区别。

第7章介绍了上下文的一般概念,还介绍了推荐系统是如何对它建模的。此外,作者还提供了案例用于研究如何使几种上下文敏感的推荐技术整合为一个单一算法的可能性。

在这里讨论了把上下文信息整合到推荐过程的三个不同的算法范式:化简(预过滤)、上下文的后过滤以及上下文建模。在基于化简(预过滤)方法中,仅当信息与当前使用的上下文相匹配时(如在同一上下文的物品评分)才能用于计算推荐结果。在上下文后处理方法中,推荐算法会忽略上下文信息。该方法的推荐结果会被过滤或调整,以便只包含与目标上下文相关的推荐结果。上下文建模方法是三种方法中最复杂的方法。在该方法中,上下文信息在预测模型中被显式地使用。

1.5 应用与评价

推荐系统的研究着重放在实践和商业应用上。因为除了理论方面的贡献,这方面的研究一般旨在切实促进商业推荐系统的发展。因此,推荐系统的研究包括实现这些系统的实践方面。这些方面与推荐系统生命周期的不同阶段都相关,即系统设计、实现以及系统运行过程中的维护和改善。

系统设计阶段所需考虑的影响因素或许会影响算法的选择。第一个要考虑的因素——应用的领域是算法选择的主要影响因素。[72]提供了推荐系统的分类,并且对特定应用领域的推荐系统应用做了分类。基于这些特定的应用领域,我们为最普遍的推荐系统应用做了更一般的领域分类:

- 娱乐: 电影、音乐和IPTV的推荐。
- 内容: 个性化新闻报纸、文件推荐、网页推荐、电子学习程序和电子邮件过滤。
- 电子商务: 为消费者推荐要购买的产品,如书籍、照相机、电脑等。
- 服务: 旅游服务推荐、专家咨询推荐、租房推荐或者中介服务。

随着推荐系统的流行,一些新应用上的潜在优势激发了人们的兴趣。例如,可以像在www.tweeter.com网站那样推荐一个朋友列表或者一个推特信息列表。因此,诸如上面的列表并不能覆盖推荐技术所涉及的所有应用领域,这些列表只是给出了不同类型的应用领域的初始描述。

特定应用领域的推荐系统开发商应该了解该领域的特殊方面、具体的要求、应用程序面临的挑战和局限性。只有在分析这些因素之后,才能选择最佳推荐算法,并且设计更高效的人机交互。

本书第 11 章提供了推荐技术与应用领域相匹配的指南。Burke 和 Ramezani 写的章节中为推荐系统提供了一个新的分类。与以往推荐系统分类方法(如[25, 94, 3, 7])不同, Burke 和 Ramezani 采用以人工智能为核心的方法, 而且重点关注不同推荐方法所需要的知识源, 并把与这些推荐方法相关联的约束条件作为选择算法的入门指南。该章讨论了针对不同问题选择的不同推荐技术的适用性, 并提出了选择这些技术的决策准则。

该章的目的很明确, 就是为系统实现者“推荐”合适的推荐技术。作者描述了不同领域的推荐系统中可用的知识库以及确定一种推荐技术时所不可获取的知识库。这就意味着设计推荐系统首先要注重的是分析知识库的来源, 然后再据此选择算法。

第 12 章记述了另一个需要根据领域来调整推荐方法的示例, 这个示例关于推荐系统的技术增强型学习(TEL)。TEL 基本覆盖了支持各种形式的教学活动的技术, 其目的是设计、发展和测试新方法与技术来增强个人和组织双方的学习实践能力。TEL 的主要收益来源于将推荐系统技术整合到个性化学习过程中, 并根据用户先前的知识、能力和偏好逐步调整。该章阐述了能满足 TEL 的特定需求的推荐系统; TEL 设置阶段用户需要做的任务; 其他推荐系统的用户任务和这些任务有什么区别。例如, 对 TEL 来说, 用户的特殊任务是“发现新资源”, 也就是尝试仅仅推荐新的或者新奇的物品。或者, 我们考虑另一个例子, 即“发现新路径”, 也就是通过学习知识库推荐可选的路径。该章提出的过滤方法的分析对 TEL 很有用, 有关现有 TEL 系统的调查显示, 推荐技术已经被部署到系统中。

第 10 章讨论了推荐系统发展的实践方面, 目的在于为推荐的设计、实现和个性化系统的评测提供指导。设计推荐系统的时候, 除了考虑预测算法, 也要考虑其他因素。第 10 章列了许多因素: 目标用户的种类和他们的上下文、需要用的设备、推荐系统在程序中的作用、推荐的目标, 还有之前提到的可用的数据。

作者建议为此环境搭建一个三维模型, 三个维度分别是: 系统用户、数据特征和程序的综合应用。推荐系统的设计要基于这个模型。作者阐述了其指导方案以及建立在他们自己开发的一个新闻推荐系统上的模型。

有关推荐系统实际部署方面的另一个重要的问题就是对推荐系统的测评。出于各种各样的目的, 推荐系统生命周期的不同阶段都要进行测评[25, 1]。在设计时, 需要用测评去判定推荐算法的选择。在设计阶段, 测评过程是离线完成的, 并且推荐算法需要拿来和用户交互作比较。离线测评包括在同一个用户互动(如评分)数据集上运行多个算法并且比较各自的性能。如果能够获得合适的的数据, 这种测评通常都是在一些公开的基准数据上进行的, 否则, 就要在自己收集的数据集上进行。为了确保结果的可靠性, 离线实验的设计需要与已知的实验设计方法保持一致[11]。

系统上线运行以后依然需要评测。当解决一些核心推荐问题(如预测用户评分)时, 算法可能需要非常精确, 但是有些情况下系统可能不会被用户接受, 例如, 当系统的表现和用户期望的不一致时。实施在线评测并且分析系统日志以增强系统性能就显得很有必要了。另外, 大多数算法都包含参数, 如阈值权重、近邻的数量等, 都需要不断地调整和校准。

另一种测评方法是当在线测评不可行或太冒险的时候, 可以进行一个集中的用户研究(a focused user study)。在这类测评中, 需要实施一种可控制的实验, 即一小群用户被要求执行随着系统变化的不同的任务。然后才有可能分析用户喜好以及分发调查问卷以使用户报告各自的用户体验。在这样的实验中, 我们一般能够收集到关于系统的数量大、质量高的用户反馈信息。

第12章也讲了TEL系统环境下的测评方法,对测评方法和工具进行了详细的分析。这些方法和工具可以用来在一组特定的标准下评估TEL推荐技术,这组标准是与每个选择的部分(如用户模型、领域模型、推荐策略和算法)相对应的。

第8章详细阐述了用于评估推荐系统的三种实验,并阐述了它们各自的优缺点,最后为测评选择方法制定了指导原则。通常文献中有关评估的讨论都会提到算法预测的精准度及相关度量方法,本章则独树一帜,专门讨论定向特性的评估。除了精准度,还给出了一大组特性。每个特性都有相应的实验验证和度量方法。这些特性包括覆盖率、冷启动、信心值、可信度、新颖性、风险度和惊喜度。

当讨论推荐系统的实践方面时,我们最好分析真实实现的系统。我们的想法是在理论上验证直观的假设,目的是确定它们在实践中是否成立。但是我们必须面对的事实是,商业推荐系统的所有者通常不愿意公开他们真实的做法并且甚至连这样合作的机会几乎也没有。

第9章介绍了一个这样的时机并阐述了一个真实推荐系统的操作,由此说明了适用于推荐系统实践阶段和评估过程的实践层面。Fastweb是欧洲最大的IPTV服务商,本章着重介绍了如何把推荐系统整合到Fastweb的生产环境中。本章描述了需求和考虑因素,包括规模和准确度,而这些正是选择推荐算法的主导因素。除此之外,本章还描述了系统中用到的离线和在线评测方法,并且说明了系统应该如何进行相应的调整。

1.6 推荐系统与人机交互

正如前面阐明的那样,研究人员主要关注一系列技术解决方案的设计,以及利用各种知识库更好地预测目标用户喜欢什么和喜欢的程度。这种研究活动背后的基本假设是仅能展示正确的推荐(也就是最好的选项)就足够了。换句话说,系统给用户推荐,如果是正确的,用户应该明确地接受推荐。很明显,这极度简化了推荐问题,其实把推荐结果传递给用户并不简单。

实际上,因为用户没有足够的知识库做明确的决定,所以才需要推荐。让用户评价系统提供推荐并不是件容易的事情。因此,很多研究人员试图了解让指定用户接受推荐结果的因素[105, 30, 24, 97, 33]。

其中[105]第一个指出推荐系统的有效性依赖于很多因素,而不仅仅是预测算法的质量。实际上,推荐系统必须说服用户去尝试(或听、购买、阅读、看)所推荐的物品。当然,这取决于被选择物品的个体特征,也取决于推荐算法。当物品被推荐、比较、解释(解释为什么被推荐)的时候,该过程也取决于系统支持的特定的人机交互。[105]发现,从用户角度来看,一个有效的推荐系统必须能激发用户对系统的信任;它必须有一个显而易见的系统逻辑(个人理解为系统不能有逻辑错误);它必须指引用户面向新的、用户不熟悉的物品;它必须提供推荐物品的详细信息,包括图片和社区评分;最终,[105]提供改进推荐的方法。

[105]和其他相似方向的研究者并没有忽略推荐算法的重要性,但是他们声称推荐算法的有效性不能仅根据预测结果的准确性(即用标准且流行的IR指标,如MAE、准确度或NDCG)来衡量(见8.5节,第9章)。他们认为涉及用户接受推荐系统以及其推荐结果的其他角度也应该被测量。这些想法在[33]中也被明确地提出并讨论。在这项工作中,作者提出评价推荐系统要以用户为中心,包括推荐列表的相似度,推荐系统有意外新发现的能力,以及推荐系统中用户需求和期望的重要性。

讨论过[105]提出的观点之后,我们介绍由人机交互研究引出的几个重要观点,我们将在本书中进一步研究人机交互。

1.6.1 信任、解释和说服力

首先讨论信任。本书讨论了关于信任的两种不同概念:对推荐系统其他用户的信任和对推荐系统本身的信任。

第20章集中讨论了第一种观念,并分析了一类叫作“社会化推荐系统”的推荐系统。这些系统试图从用户资料和用户关系中推导出更有用的推荐,这些资料 and 关系在目前几乎随处可见,如在 Facebook、LinkedIn 和 MySpace 等社交网站中。由于基于信任的推荐系统主要利用它们在社交网站发现的信任关系来构造新的推荐算法(如[34]),所以它们在核心评分预测问题上只能使用信任关系。这类系统的主要优势是用户可以知道推荐系统的本质是什么,如这些推荐结果是如何确定的,这样用户便会更加信任这些推荐结果。换句话说,我们可以利用用户之间的相互信任来提高用户对推荐系统的信任度。

对推荐系统产生的推荐结果的信任在第15章讨论。该章主要介绍了解释推荐的作用,还介绍了信任是推荐解释在推荐系统扮演的七大作用之一。这七大作用是:**透明度**,即说明系统是如何工作的;**可反馈性**,即允许用户告诉系统有错误[50];**信任**,即增加用户对系统的信心;**有效性**,即帮助用户做出好的决定;**说服力**,即说服用户去尝试或购买;**高效性**,即帮助用户快速抉择;**满意度**,即增加用户舒适度或乐趣。

该章也阐述了一系列构造解释的方法。如协同过滤方法,其解释的形式是“跟你相似的用户喜欢这个物品”。在基于内容的风格解释中,系统会根据最能代表物品的特征属性把物品推荐给用户。例如,电影推荐系统中,一种推荐形式有可能是“这部电影被推荐是因为你可能喜欢 Bruce Willis 这个明星”,或者“物品 X 被推荐是因为你对物品 Y 和 Z 评价很高,而 Y、Z 和 X 有共同的属性 A 和 B”。用基于案例的解释,系统会引用与推荐物品相似的物品,例如,“这个物品被推荐是因为你说自己拥有物品 X”或者“这些物品的推荐是基于你最近浏览的物品”。最后,用基于知识库的风格解释,系统会解释推荐物品和另一个物品的差异,并且会说推荐物品是如何符合用户目标的:“这个房间面朝大海,并且比之前推荐的房间大,这将更加浪漫,如你所愿。”

回到信任的话题上来,我们把它视为实现推荐系统主要目标,即说服用户接受推荐结果并且尝试推荐的物品。这个问题最终与整个推荐系统的说服力有关,即推荐系统的各个因素,包括推荐什么,如何推荐,在人机交互过程中实际是如何运作的。这个话题将在第14章有所讨论。在这里,作者强调说推荐系统应该值得信赖并且经常被人们想到。当人们想到使用推荐系统时,不仅仅是因为他们知道它能产生推荐结果,而且是把它当作一个建议给予者。实际上,关于说服力的文献资料表明人们容易接受来自可靠消息的推荐,所以我们得到结论:推荐系统的可靠性对于增加用户接受推荐结果的可能性是至关重要的。因此,作者讨论了推荐系统的可信度是如何提高的,并且提供了有关信任度研究的概要。

1.6.2 会话系统

推荐系统算法的另一个严格限制是这些算法被设计为一次性收集输入数据,而且一旦返回推荐结果便结束整个过程。在很多情况下,这种模型会失效,因为用户还不能完全意识到自己的喜好,除非他们与系统进行一定程度交互并且大致了解选择的范围。或者在确

信一些可能适合自己的推荐之前会浏览更多的可选择的选项。这也可能意味着系统一开始的推荐就是错误的,但用户可能愿意提供额外的信息用于修复这些问题,最终得到一些好的推荐。

这些问题已经得到了致力于“会话式推荐系统”[27, 110, 67, 60]的研究人员的重视并解决。会话式推荐系统为预测评分或排序使用了各种技术。然而,这些技术都在试图提供交互过程,该过程中,用户和系统能彼此查询或提供信息。最具决定性的问题是如何设计这个会话(也就是会话策略),以及如何设计用户和系统在交互的各个阶段必须执行的动作。提供的会话必须有效,即当用户终止会话时应该得到解决方案(如预订机票),而且速度要快(会话步骤较少)。在本手册中,有两章处理这一重要话题。

第13章提供了基于评价的推荐系统的研究综述。给定一个关于用户偏好信息的初始集(例如,一些物品特征的优选值),基于评价的界面或者会话模型能够展示给用户推荐的物品以及支持用户表述“评价”,例如,“给我展示更多像A的物品,但是比A更便宜”。

基于评价的系统已经在一些领域中得到了很大的关注,在这些领域中,我们需要一个更加复杂且具有交互性的决策/推荐支持系统,如旅游领域[88, 32, 100]或者计算机系统领域[82, 83]。基于评价的系统最初的设计是用于有效地解决用户偏好提取问题的,但是现在已经对其他目的或应用变得非常重要,例如,小组推荐、初始混合推荐、用户自适应交互接口、解释推荐、移动推荐。

另一种与会话系统有关的方法是基于偏好的[67]。基于偏好和基于交互的方法相似,因为他们都是在之前就给用户一些推荐,这些推荐也许不会是最好的,但是总有一部分的物品能引起用户的兴趣。这种额外的信息能帮助提高系统表现用户偏好(用户模型)的能力,从而能使系统产生新的且更好的推荐。

第16章阐述了这些新颖的方法和系统,集中讲了这种基于偏好推荐系统的用户,即系统交互的三个方面:初始偏好提取;偏好修正;推出推荐结果。本章的内容可以作为来源于一些系统的可用性指南的集合,这些指南可被广泛和大规模应用。而且,为了选择指导准则,作者不仅关注准确性这一个指标,还考虑到这样的一个事实:人类的认知资源有限,因此如果需要我们付出过多的努力,将不大可能会得到高准确度的结果。他们选择的方法能产生准确度很高的推荐结果,同时要求的努力程度是我们愿意接受的。

之前提到的方法(基于交互的和基于偏好的)已经主要应用于基于案例的推理系统[22],这类系统的检索部分是依赖相似性度量的。在这种情况下,由于在一定程度上,产品总是跟一个可探测(查询)结果类似,所以一条查询可以检索出目录下的所有产品,并对这些产品进行排序。如果查询语言支持其他限制条件(例如,等同限制或排序限制),查询返回的结果可能不会令人满意[47, 71, 31]。针对这种情况,研究人员提出了许多技术,这些技术通过放宽约束的最小数量来修复这种查询问题,其目的是使返回的查询结果令人满意。这个课题也在专讲基于约束(第6章)的推荐系统中有所讨论。

1.6.3 可视化

目前,我们重点强调了人机交互问题,而这些问题已经在推荐系统的研究中得以解决,本手册也对此进行了讨论。总之,我们认为系统如何展示并且可视化计算得到的推荐结果是影响用户接受推荐结果和该推荐系统的关键因素。

推送(将推荐推到用户那里)和解释技术是不可分的:一个好的推送技术也要有解释推荐的能力,也要诱导用户提出进一步请求,包括对解释推荐的请求。目前已有的这些技术

有一个共同点,就是推荐结果按照物品列表的方式显示。推荐列表长度是可变的,但是核心推荐算法的输出通常是个排序列表,该列表在最终展示推荐结果时会用到。

本书单设一章阐明一种有别于传统模式的推送方法。在第 17 章,作者注意到在排序列表这种可视化方法中丢失了大部分信息。这里的原因是:对于两个产品,即使它们都与用户请求或者用户模型相匹配,但如果是基于完全不同的产品特征集,也是有区别的。如果用一个二维的基于图的可视化推荐,还可能保留部分信息。在图中,我们可以在一个受限的范围内为各个相似推荐安排位置。该章提出了建立二维图推荐的两种方法,并且讨论了各自的优缺点。

1.7 推荐系统是个交叉学科领域

设计和开发推荐系统是多个学科共同努力的结果,这得益于多个计算机科学领域的成果,特别是机器学习、数据挖掘、信息检索和人机交互。这在本书章节中和上述讨论可以明显地看出来。在此,简要地梳理一下这些关系。

机器学习和数据挖掘,是人工智能的子领域,它们是让计算机学习示例、数据或过去的经验从而使其执行某些任务时性能最佳[109]。例如,购买“Da Vinci Code”的顾客也买了“The Five People You Meet in Heaven”,数据挖掘就可以利用这类交易数据进行学习。因此,可以用这种相互关联信息构建推荐系统。

为了预测用户对物品的评价,或者为了学习如何修正推荐列表排序,许多推荐系统以利用各种机器学习和数据挖掘算法为中心。本书第 2 章对上下文推荐系统预处理方法使用的数据挖掘技术做了总述,例如,抽样或降维;分类技术,如贝叶斯网络和支持向量机的方法;聚类技术,如 k-means 算法;关联规则。

其他例证推荐系统和数据挖掘关系的章节是:第 12 章讨论了利用主动学习获取信息;第 5 章建立预测评分模型的最优化技术;第 7 章介绍利用上下文数据提供了各类预测评分模型;第 24 章介绍数据挖掘技术,利用多准则的物品评价标准,更好地预测用户综合评价;第 25 章重点讲了数据挖掘的推荐系统攻击检测方法,建立健壮性算法的解决方案;第 4 章阐述目前基于学习的协同过滤系统的很多实例;第 19 章阐述了复合矩阵或超边(用户、资源、标签)的超图的数据挖掘解决方法;第 20 章介绍数据挖掘的信任网络解决方法。

信息检索(IR)的目的是帮助用户存储和检索各种不同形式的内容,如文本、图像、视频[63]。利用信息检索工具,用户可以很快找到自己需要的有关的信息和全面的信息。虽然 IR 并不始于 Web,但由于 Web 搜索引擎的发展,万维网在开创这一新观念方面扮演了重要的角色。

信息检索和推荐系统都面临着过滤和排序问题。IR 一般重点发展全局检索技术,通常忽略个体需要和用户偏好。而[25]声称,推荐系统还没有明显地与信息检索分离。推荐系统和信息检索或搜索引擎最核心的区别是“考虑个体”与“用户感兴趣和对用户有用”,而推荐系统正尝试在这方面取得成功。

目前,现代的 Web 搜索引擎已经依赖推荐技术来解决 Web 搜索的挑战,实现更先进的搜索功能。例如,搜索引擎给用户查询推荐相似查询。各种搜索引擎也试图通过产生用户查询结果实现个性化,返回的结果不仅根据用户查询条件还要参考用户上下文(例如,他的位置)和他的检索历史。

第 18 章讨论了 IR 的研究目标,涉及从推荐系统角度实现 Web 检索个性化。作者阐

述了如何应用推荐系统技术解决搜索引擎面临的挑战。该章的重点是改进搜索引擎的两个有望实现的想法：个性化和协同。该章描述了利用用户偏好和上下文信息影响搜索结果的一系列不同的方法，去实现个性化 Web 搜索。另外，该章讨论了协同信息检索方面目前要做的工作，协同信息检索尝试利用潜在的合作关系(朋友间、同事间或者有相似需求的用户间)实现一系列的信息检索任务。这种新型的研究叫作社交检索，得益于社交网络中的特性，检索结果受用户偏好和用户经验影响。作者预见“推荐系统和检索系统的汇聚”，并且相信在搜索引擎算法上这些资源的整合可以产生用户的高满意度，让用户能在正确的时间收到正确的信息。

跟 IR 研究相关同时又阐述这方面研究的是：第 19 章针对上下文标签的检索问题；第 3 章介绍了根植于当前搜索引擎技术的基于上下文方法的概述。

最后，推荐系统最终目标是给用户提供了有用的信息，因此，在推荐最终能否被接受这个问题上，人机交互起了重大作用。实际上，许多领域的研究清楚地表明，从用户角度来看，HCI 中与系统可用性相关的方面对用户是否愿意使用推荐系统以及为了更有效的推荐结果而提供主动的输入有巨大的影响。这些问题在 1.6 节讨论过。

1.8 出现的问题和挑战

1.8.1 本书对出现的问题的讨论

从前面的讨论可以很明显地看出，推荐系统的研究正在向众多不同的方向发展，同时新的主题不断出现，或者正成为更重要的研究课题。读者也可以参考最近的 ACM RecSys 会议资料，参考其他优秀的论文，将其作为额外的研究素材[7, 3]。本手册中涵盖许多这种话题。实际上，很多已经介绍过了，例如，上下文感知推荐(第 7 章)；新的可视化技术(第 17 章)；基于社区的个性化搜索(第 18 章)；基于信任的推荐系统(第 20 章)。其他一些重要的话题在手册最后两部分，我们现在简短地介绍一下这些章节。

第 19 章介绍社会标签系统(STS)，这是随着 Web 2.0 的发展而出现的跟推荐系统相关的新话题。STS 如同 Flickr、Bibsonomy、Delicious 这类网站一样，允许普通用户发表和编辑内容，同样也允许用户产生和共享标签(即自定义关键字)。STS 用户正面临着信息过载问题，因为 STS 有数以百万计的用户，他们进入系统后发表的内容和标签不受控制，这就给传统的推荐系统造成检索困难。因此，需要推荐系统来帮助用户找到相关的信息，于是许多商业 STS 开始提供推荐服务(如 Delicious)。

该章讨论了 STS 推荐系统面对的新挑战，如推荐系统的新任务。这些不仅包括传统的内容推荐也包括相关标签推荐，甚至其他相似用户推荐。标签推荐系统(即推荐给用户一个物品的相近标签)，与传统的推荐系统有很多独特性，因为系统可以推荐经常出现的标签，不像传统的推荐系统一般不对相同物品进行二次推荐。另外，STS 的推荐系统解决的是三维问题(用户、资源、标签)，而不是传统推荐系统的二维问题(用户、物品)，这个问题会影响算法的复杂性。该章有一项最新调查，是关于支持 STS 的新一代推荐系统的。详述了给真实 STS 系统部署推荐系统遇到的挑战，并且为解决 STS 和标签推荐系统面临的挑战提供了新的算法。

第 21 章处理这样的情形，就是系统最好能够给一群用户推荐信息或物品，而不是给单个用户推荐。例如，推荐系统可以为一个群组选择电视节目，或者推荐歌单，其模型是基于整体群组成员的。为群组推荐很明显要比为个体推荐更复杂。假设我们能精确地知道

单个用户喜好,那么问题就是如何组合单个用户模型。在本章中,作者讨论了群体推荐如何工作,面临的问题,目前的进展。

第22章讨论了聚合用户偏好、准则和相似度这一普遍性问题。通常这类聚集是通过利用算术平均值或最大最小值函数完成的。但是许多其他有灵活性和适应性,并且最终能产生更相关的推荐结果的聚合函数经常被忽略。在本章,作者回顾了聚集函数的基础和特性,并且介绍了最重要的几个,包括广义集群,Choquet积分和Sugeno积分,有序加权平均,三角模自生成,双极性聚合函数。这种函数可以模拟输入条件之间的各种相互作用,包括连续的、分散的和混合的行为。

在第23章中,作者着重讲了推荐系统的另一个重要问题,即推荐系统生命周期过程中需要积极寻找新数据的问题。这个问题通常被忽略,因为用户访问系统时,系统就假设没有足够大的空间管理系统收集的数据(如评分)。实际上,推荐系统可以激发用户兴趣,许多系统在推荐过程中明确地询问用户偏好。因此,通过调整推荐过程,用户可以提供一系列不同的信息。特别是系统可以要求用户评价特定商品,用户对这些物品的评价在特定的条件下是非常有用的,比如,为一些用户或者整个用户群体产生更加多样化的推荐结果,或者简单地提高系统的预测准确性。此时,主动学习出现了;主动学习可以增强推荐系统,帮助用户更了解自己的偏好,产生更有效和更有用的问题。同时,主动学习可以为系统提供新信息,为随后的推荐作分析。因此,推荐系统应用主动学习能使推荐过程个性化[61]。这可以通过允许系统积极地影响用户遇到的物品(例如,在用户注册或用户定期使用时给用户展示物品)来完成,同样也可以通过用户自由探索自己的偏好来完成。

第24章介绍了另一个新兴话题,即多准则推荐系统。多数推荐系统通常是考虑单一标准值来决定物品的效用,例如,整体评价或者一个用户对一个物品的评分。但是目前这个假设被认为具有局限性。因为用户做选择的时候,系统为一个特定用户推荐的物品是否合适要根据用户考虑的多方面因素判断。多准则的组合可以影响用户意见,从而产生更有效更精确的推荐。

第24章提供了多准则推荐系统的一个概述。首先,它把推荐问题定义为一个多准则决策问题,并且回顾了支持多准则推荐实现的方法和技术。随后,集中讨论了多准则评分推荐技术的分类,这种技术主要是根据物品在不同准则上的评分向量对用户效用模型建模来产生推荐的。给出了有关利用多准则评分计算评分预测值并生成推荐的当前算法的概述。该章包括这些推荐系统的有争议问题和未来面临的挑战。

本书最后一章(第25章)概述了安全方面的话题。这个话题在过去几年是一个重要问题。目前这个话题的工作在[28, 45, 102, 112]有介绍。该章分析能产生更具健壮性推荐的算法设计,即推荐不易受到恶意用户影响。实际上,协同过滤推荐系统依赖用户信誉,即默认假设用户与系统相互作用的目的是为自己得到好的推荐,从而给邻居提供有用的数据。然而,在某些情况下用户与推荐系统的交互有一系列的目的,这些目的可能是与系统所有者或系统多数使用者背道而驰的。也就是说,这些用户想去破坏推荐系统网站或者干预提供给访客的推荐,例如,给一些物品更高的分数或更低的分数,而不是进行公正的评价。

该章作者提出一个有效的攻击模型,这种攻击的成本很低,但是对系统输出产生的影响很大。由于这些攻击可以在攻击网站时运行良好,因此很有必要检测它们并尽快制定对策。同时,研究人员已经研究出许多能经受攻击的健壮性算法,而且与有效攻击相比,这些算法具有较低的影响曲线。这些方法在本章中也涉及了。利用这些技术的结合,研究人

员考虑的不再是避免攻击而是去控制攻击的影响，让他们付出高昂的代价。

1.8.2 挑战

新兴的具有挑战性的推荐系统话题，不限于我们上面提到的章节中描述的那些。此外，覆盖所有的主题并不在这个简短介绍的范围内。读者可以参考本书最后的讨论部分，讨论其他值得关注的问题。

下面简短地介绍其他具有挑战性的话题，我们认为这些话题对推荐系统的研究发展很重要，但本书并没有涵盖这些内容。

- **大的真实数据集背景下的算法扩展性。**随着核心技术进步与成熟的研究，算法扩展性明显成为推荐系统的重要问题，它决定着如何把核心推荐技术嵌入真实系统里，如何处理用户和物品互动(评分、偏好、评论等)产生的大量动态的数据集。有个方法是在相对较小的数据集离线测试，但这个方法在非常大的数据集上可能失效或者完全不适应。需要进行新方法和大规模的评估的研究[91, 92, 33, 38, 116, 75, 75]。
- **主动推荐系统**，即虽然没有明确的请求[90, 24, 62, 80]，推荐系统也产生推荐。到目前为止大多数的推荐系统都遵循一个“pull”模型[94]，用户为获得推荐而发起请求。时过境迁，计算机无处不在，用户间总是相连的，人们很自然地想到推荐系统能够探测到隐藏的请求。所以需要预测不仅是推荐什么，还要考虑什么时候，如何去推送推荐。这样推荐系统变得积极主动而不用被视为骚扰。
- **推荐系统中的用户隐私保护**[81, 26, 79, 56, 17, 28, 102, 16, 5, 53, 70, 114]。推荐系统利用用户数据产生个性化推荐。在尝试建立更多更好的推荐系统时，它们尽可能多地收集用户数据。这无疑会对用户隐私产生负面影响，用户可能开始觉得系统知道太多关于自己真实想法的信息。因此，需要设计解决方案，简约并明智地使用用户数据。同时这些解决方案将确保用户信息库不被恶意用户随意获得。
- **推荐给目标用户的物品多样性**[104, 66, 69, 55, 54, 46, 119]。推荐列表中包含的物品如果具有一定程度的多样性，用户就更有可能找到合适的物品。为受限种类的产品做完美推荐是没有意义的，除非用户已经表示他的偏好在一个狭窄的范围内。有许多情况，特别是在推荐过程的早期阶段，用户想要探索新的多样性的方向。在这种情况下，用户使用推荐系统作为一个知识发现工具。在这个话题上的研究仍处于初级阶段，需要描述“多样性”的特性，即我们要从几次不同推荐中还是从一次推荐中寻找多样性，以及如何保证推荐精确性的同时兼有多样性。
- **在建立推荐列表的过程中整合用户的长期和短期偏好**[6, 40, 74]。推荐系统可以分为两类：一种是建立长期的配置资料，通过聚集所有系统收集的用户交易数据产生推荐(如系统过滤)；另一种更侧重于用户的短期偏好，例如，在基于案例的方法中。显然，在解决偏好整合问题上，这两方面都很重要，无论是精确的用户任务还是物品的可用性都要兼顾。实际上，在当有足够的证据表明用户的短期偏好与长期偏好发生偏离时，需要建立混合模型来正确地决定是要发生兴趣偏移，还是不要偏向用户的偶然偏好。
- **通用的用户模型和交叉领域推荐系统能够在不同的系统和应用领域调配用户数据**[41, 18, 52, 19, 20, 49, 15]。使用通用的用户模型技术，一个单一的推荐系

统可以产生多种物品的推荐。这对于一般的推荐系统是不可能的,因为一般的推荐系统能够把多种技术整合到一个混合的方法中,但是却不能利用在一个领域收集到的用户偏好信息来在另一个领域产生推荐结果。

- **在开放式网络中运行的分布式推荐系统**[38, 116, 92, 113, 17, 102]。大多数推荐系统的计算模型是典型的客户端-服务器结构。用户客户端请求推荐,推荐系统服务端产生推荐以回应请求。这显然是个严重的限制,受到集成式控制系统中所有传统问题的折磨。新兴的网格计算或云计算的出现,为推荐系统实现更具健壮性和灵活性的计算模型提供了良机。
- **最优化推荐序列的推荐系统**[120, 99, 10, 59, 61, 107, 106]。我们已经提到过传统的推荐系统是为了提高推荐质量,这依赖一个简单的方法:一次性的请求/响应。会话式推荐系统可以通过实现学习能力进一步提高,不仅可以优化推荐的物品,而且可以优化如何使用用户系统在所有可能情况下都能展开对话。
- **移动上下文的推荐系统**[117, 98, 55, 51, 4, 115, 111, 57, 29, 9, 77, 76, 89, 73, 44, 95, 13]。移动计算作为个人计算最自然的平台。当用户移动的时候可能产生推荐请求,例如,在城市旅游时的超市或者酒店。因此我们需要使用用户界面“移动”起来(需求是“移动”的),需要设计能充分利用有限的移动资源(计算能力和屏幕尺寸)的计算方案。

最后,在结束引言之前,我们想介绍一些额外的挑战,即在最近的 RecSys 会议中一个教程中讨论的,该次会议地点在纽约,时间是 2009 年 10 月 22 日到 25 日, [<http://recsys.acm.org/tutorial3.pdf>]。John Riedl(Uni-versity of Minnesota)、Todd Beaupre(Yahoo!)和 John Sanders(Netflix)提出研究推荐系统的八个重要挑战:透明度、探索与利用、指导准则、时间价值、用户行为解释、评价推荐系统、扩展性、学术/工业之间关系。

在引言中已经讨论过一些问题。例如,当讨论解释推荐的作用时介绍了透明度,我们强调透明度在使推荐更易被用户接受上有重大作用。同时,推荐系统的评估方法(也就是评估中被测量的一系列重要角度)这个话题在另一章(第 8 章)有完整的阐述。

推荐的时间价值在上下文感知推荐系统(第 7 章)的评论部分讨论过。然而,实际上面临的挑战是,给定的一系列推荐不可能永远适用,而这些物品需要过一段时间才能被系统推荐。例如,当谈及新闻物品时,人们显然想要了解最新发生的事件和新闻,而这些新闻甚至是与最初发布间隔一天后仍不能被推荐给用户。

主动学习(第 23 章)对探索还是利用的话题有所涉及。这个过程面临的挑战也是设计师必须妥善解决的主要困境,即在系统当前可用数据的给定条件下,推荐目前能识别出的好物品,还是为了得到未来更新也可能更好的推荐结果,而去探索用户的偏好(比如,要求用户对额外的特定物品评分)。

索引式导航栏,导航栏指的是将传统的推荐列表(即推荐结果)和能够让用户在选项中更加自主浏览的工具相结合。用户行为解读指的是,除了用户显式评分之外,还可以探测、分析用户在操作推荐系统中产生的更多行为,并用于构建更好的预测模型。这个想法是,每个用户的用户行为都应该被利用在推荐过程中。但是解读用户行为(即一个行为的背后意图)是个挑战,有些行为需要被舍弃,因为这不是由原来真正的用户产生的,例如,在同一个浏览器中不同用户执行的行为,或者是虚假和恶意注册,或者是由机器人和爬虫引起的数据或日志。

先前也提到过可扩展性。我们强调,很显然这是个问题,当前文献中对这个问题的探

讨并不完整, 因为可扩展性一直被大多数工业实践者研究调查。

最后, 关于工业界和学术界合作一事在研讨会上讨论得兴致勃勃。工业界有一些特殊的问题, 但这些问题没有明确地公开。这有很多原因, 包括不向竞争对手透露关键信息。相反, 学术界正在寻找能在允许的时间和资源框架内解决的问题, 学术界通常会专注一个能对科学界产生影响的专题。这种不同会使工业/学术合作变得困难。但是推荐系统是个需要新的实际挑战的领域, 这些挑战是有助于解决问题或使问题变得成熟的。如果我们不解决那些有用的但是有风险的挑战, 那么该领域的研究就真正有停滞不前的风险。

我们希望本书能成为实践工作者和研究人员的有用工具, 有助于在这个令人激动并且有用的研究领域进一步开发知识。这样我们相信能减少两组人员(工业与学术)走不同路线的风险。目前推荐系统领域极大地得益于工业界和学术界对此的兴趣和努力。因此, 当他们两组人阅读本书时, 我们都会奉上最美好的祝愿。希望能吸引更多的研究者在这个非常有趣又充满挑战的领域奋斗!

参考文献

1. Adomavicius, G., Sankaranarayanan, R., Sen, S., Tuzhilin, A.: Incorporating contextual information in recommender systems using a multidimensional approach. *ACM Trans. Inf. Syst.* **23**(1), 103–145 (2005)
2. Adomavicius, G., Tuzhilin, A.: Personalization technologies: a process-oriented perspective. *Commun. ACM* **48**(10), 83–90 (2005)
3. Adomavicius, G., Tuzhilin, A.: Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering* **17**(6), 734–749 (2005)
4. Ahn, H., Kim, K.J., Han, I.: Mobile advertisement recommender system using collaborative filtering: Mar-cf. In: *Proceedings of the 2006 Conference of the Korea Society of Management Information Systems*, pp. 709–715 (2006)
5. Aïmeur, E., Brassard, G., Fernandez, J.M., Onana, F.S.M.: Alambic : a privacy-preserving recommender system for electronic commerce. *Int. J. Inf. Sec.* **7**(5), 307–334 (2008)
6. Aïmeur, E., Vézeau, M.: Short-term profiling for a case-based reasoning recommendation system. In: R.L. de Mántaras, E. Plaza (eds.) *Machine Learning: 2000, 11th European Conference on Machine Learning*, pp. 23–30. Springer (2000)
7. Anand, S.S., Mobasher, B.: Intelligent techniques for web personalization. In: *Intelligent Techniques for Web Personalization*, pp. 1–36. Springer (2005)
8. Arazy, O., Kumar, N., Shapira, B.: Improving social recommender systems. *IT Professional* **11**(4), 38–44 (2009)
9. Averjanova, O., Ricci, F., Nguyen, Q.N.: Map-based interaction with a conversational mobile recommender system. In: *The Second International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies, 2008. UBIComm '08*, pp. 212–218 (2008)
10. Baccigalupo, C., Plaza, E.: Case-based sequential ordering of songs for playlist recommendation. In: T. Roth-Berghofer, M.H. Göker, H.A. Güvenir (eds.) *ECCBR, Lecture Notes in Computer Science*, vol. 4106, pp. 286–300. Springer (2006)
11. Bailey, R.A.: *Design of comparative experiments*. Cambridge University Press Cambridge (2008)
12. Balabanovic, M., Shoham, Y.: Content-based, collaborative recommendation. *Communication of ACM* **40**(3), 66–72 (1997)
13. Bellotti, V., Begole, J.B., Hsin Chi, E.H., Ducheneaut, N., Fang, J., Isaacs, E., King, T.H., Newman, M.W., Partridge, K., Price, B., Rasmussen, P., Roberts, M., Schiano, D.J., Walendowski, A.: Activity-based serendipitous recommendations with the magitti mobile leisure guide. In: M. Czerwinski, A.M. Lund, D.S. Tan (eds.) *CHI*, pp. 1157–1166. ACM (2008)
14. Ben-Shimon, D., Tsikinovsky, A., Rokach, L., Meisels, A., Shani, G., Naamani, L.: Recommender system from personal social networks. In: K. Wegrzyn-Wolska, P.S. Szczepaniak (eds.) *AWIC, Advances in Soft Computing*, vol. 43, pp. 47–55. Springer (2007)
15. Berkovsky, S.: *Mediation of User Models: for Enhanced Personalization in Recommender Systems*. VDM Verlag (2009)

16. Berkovsky, S., Borisov, N., Eytani, Y., Kuflik, T., Ricci, F.: Examining users' attitude towards privacy preserving collaborative filtering. In: International Workshop on Data Mining for User Modeling, at User Modeling 2007, 11th International Conference, UM 2007, Corfu, Greece, June 25, 2007, Proceedings (2007)
17. Berkovsky, S., Eytani, Y., Kuflik, T., Ricci, F.: Enhancing privacy and preserving accuracy of a distributed collaborative filtering. In: RecSys '07: Proceedings of the 2007 ACM conference on Recommender systems, pp. 9–16. ACM Press, New York, NY, USA (2007)
18. Berkovsky, S., Kuflik, T., Ricci, F.: Cross-technique mediation of user models. In: Proceedings of International Conference on Adaptive Hypermedia and Adaptive Web-Based Systems [AH2006], pp. 21–30. Dublin (2006)
19. Berkovsky, S., Kuflik, T., Ricci, F.: Mediation of user models for enhanced personalization in recommender systems. *User Modeling and User-Adapted Interaction* **18**(3), 245–286 (2008)
20. Berkovsky, S., Kuflik, T., Ricci, F.: Cross-representation mediation of user models. *User Modeling and User-Adapted Interaction* **19**(1-2), 35–63 (2009)
21. Billsus, D., Pazzani, M.: Learning probabilistic user models. In: UM97 Workshop on Machine Learning for User Modeling (1997). URL <http://www.dfki.de/~bauer/um-ws/>
22. Bridge, D., Göker, M., McGinty, L., Smyth, B.: Case-based recommender systems. *The Knowledge Engineering review* **20**(3), 315–320 (2006)
23. Brusilovsky, P.: Methods and techniques of adaptive hypermedia. *User Modeling and User-Adapted Interaction* **6**(2-3), 87–129 (1996)
24. Bulander, R., Decker, M., Schiefer, G., Kolmel, B.: Comparison of different approaches for mobile advertising. *Mobile Commerce and Services*, 2005. WMCS '05. The Second IEEE International Workshop on pp. 174–182 (2005)
25. Burke, R.: Hybrid web recommender systems. In: *The Adaptive Web*, pp. 377–408. Springer Berlin / Heidelberg (2007)
26. Canny, J.F.: Collaborative filtering with privacy. In: *IEEE Symposium on Security and Privacy*, pp. 45–57 (2002)
27. Carenini, G., Smith, J., Poole, D.: Towards more conversational and collaborative recommender systems. In: *Proceedings of the 2003 International Conference on Intelligent User Interfaces*, January 12–15, 2003, Miami, FL, USA, pp. 12–18 (2003)
28. Cheng, Z., Hurley, N.: Effective diverse and obfuscated attacks on model-based recommender systems. In: RecSys '09: Proceedings of the third ACM conference on Recommender systems, pp. 141–148. ACM, New York, NY, USA (2009)
29. Church, K., Smyth, B., Cotter, P., Bradley, K.: Mobile information access: A study of emerging search behavior on the mobile internet. *ACM Trans. Web* **1**(1), 4 (2007)
30. Cosley, D., Lam, S.K., Albert, I., Konstant, J.A., Riedl, J.: Is seeing believing? how recommender system interfaces affect users' opinions. In: *Proceedings of the CHI 2003 Conference on Human Factors in Computing Systems*. Fort Lauderdale, FL (2003)
31. Felfernig, A., Friedrich, G., Schubert, M., Mandl, M., Mairitsch, M., Teppan, E.: Plausible repairs for inconsistent requirements. In: *Proceedings of the 21st International Joint Conference on Artificial Intelligence (IJCAI'09)*, pp. 791–796. Pasadena, California, USA (2009)
32. Fisher, G.: User modeling in human-computer interaction. *User Modeling and User-Adapted Interaction* **11**, 65–86 (2001)
33. George, T., Merugu, S.: A scalable collaborative filtering framework based on co-clustering. In: *Proceedings of the 5th IEEE Conference on Data Mining (ICDM)*, pp. 625–628. IEEE Computer Society, Los Alamitos, CA, USA (2005)
34. Golbeck, J.: Generating predictive movie recommendations from trust in social networks. In: *Trust Management, 4th International Conference, iTrust 2006, Pisa, Italy, May 16–19, 2006, Proceedings*, pp. 93–104 (2006)
35. Goldberg, D., Nichols, D., Oki, B.M., Terry, D.: Using collaborative filtering to weave an information tapestry. *Commun. ACM* **35**(12), 61–70 (1992)
36. Groh, G., Ehming, C.: Recommendations in taste related domains: collaborative filtering vs. social filtering. In: GROUP '07: Proceedings of the 2007 international ACM conference on Supporting group work, pp. 127–136. ACM, New York, NY, USA (2007)
37. Guy, I., Zwerdling, N., Carmel, D., Ronen, I., Uziel, E., Yogev, S., Ofek-Koifman, S.: Personalized recommendation of social software items based on social relations. In: RecSys '09: Proceedings of the third ACM conference on Recommender systems, pp. 53–60. ACM, New York, NY, USA (2009)
38. Han, P., Xie, B., Yang, F., Sheng, R.: A scalable p2p recommender system based on distributed collaborative filtering. *Expert systems with applications* (2004)

39. Hayes, C., Cunningham, P.: Smartradio-community based music radio. *Knowledge Based Systems* **14**(3-4), 197–201 (2001)
40. He, L., Zhang, J., Zhuo, L., Shen, L.: Construction of user preference profile in a personalized image retrieval. In: *Neural Networks and Signal Processing, 2008 International Conference on*, pp. 434–439 (2008)
41. Heckmann, D., Schwartz, T., Brandherm, B., Schmitz, M., von Wilamowitz-Moellendorff, M.: Gumo - the general user model ontology. In: *User Modeling 2005, 10th International Conference, UM 2005, Edinburgh, Scotland, UK, July 24-29, 2005, Proceedings*, pp. 428–432 (2005)
42. Herlocker, J., Konstan, J., Riedl, J.: Explaining collaborative filtering recommendations. In: *In proceedings of ACM 2000 Conference on Computer Supported Cooperative Work*, pp. 241–250 (2000)
43. Herlocker, J.L., Konstan, J.A., Terveen, L.G., Riedl, J.T.: Evaluating collaborative filtering recommender systems. *ACM Transaction on Information Systems* **22**(1), 5–53 (2004)
44. Horozov, T., Narasimhan, N., Vasudevan, V.: Using location for personalized POI recommendations in mobile environments. In: *Proc. Int'l Sym. Applications on Internet*, pp. 124–129. IEEE Computer Society (2006)
45. Hurley, N., Cheng, Z., Zhang, M.: Statistical attack detection. In: *RecSys '09: Proceedings of the third ACM conference on Recommender systems*, pp. 149–156. ACM, New York, NY, USA (2009)
46. Hwang, C.S., Kuo, N., Yu, P.: Representative-based diversity retrieval. In: *Innovative Computing Information and Control, 2008. ICICIC '08. 3rd International Conference on*, pp. 155–155 (2008)
47. Jannach, D.: Finding preferred query relaxations in content-based recommenders. In: *3rd International IEEE Conference on Intelligent Systems*, pp. 355–360 (2006)
48. Jannach, D., Zanker, M., Felfernig, A., Friedrich, G.: *Recommender Systems An Introduction*. Cambridge University Press (2010)
49. Jessenitschnig, M., Zanker, M.: A generic user modeling component for hybrid recommendation strategies. *E-Commerce Technology, IEEE International Conference on* **0**, 337–344 (2009). DOI <http://doi.ieeecomputersociety.org/10.1109/CEC.2009.83>
50. Kay, J.: Scrutable adaptation: Because we can and must. In: *Adaptive Hypermedia and Adaptive Web-Based Systems, 4th International Conference, AH 2006, Dublin, Ireland, June 21-23, 2006, Proceedings*, pp. 11–19 (2006)
51. Kim, C.Y., Lee, J.K., Cho, Y.H., Kim, D.H.: Viscors: A visual-content recommender for the mobile web. *IEEE Intelligent Systems* **19**(6), 32–39 (2004)
52. Kobsa, A.: Generic user modeling systems. In: P. Brusilovsky, A. Kobsa, W. Nejdl (eds.) *The Adaptive Web, Lecture Notes in Computer Science*, vol. 4321, pp. 136–154. Springer (2007)
53. Kobsa, A.: Privacy-enhanced personalization. In: D. Wilson, H.C. Lane (eds.) *FLAIRS Conference*, p. 10. AAAI Press (2008)
54. Koren, Y., Bell, R.M., Volinsky, C.: Matrix factorization techniques for recommender systems. *IEEE Computer* **42**(8), 30–37 (2009)
55. Kramer, R., Modsching, M., ten Hagen, K.: Field study on methods for elicitation of preferences using a mobile digital assistant for a dynamic tour guide. In: *SAC '06: Proceedings of the 2006 ACM symposium on Applied computing*, pp. 997–1001. ACM Press, New York, NY, USA (2006)
56. Lam, S.K., Frankowski, D., Riedl, J.: Do you trust your recommendations? an exploration of security and privacy issues in recommender systems. In: G. Müller (ed.) *ETRICS, Lecture Notes in Computer Science*, vol. 3995, pp. 14–29. Springer (2006)
57. Lee, H., Park, S.J.: Moners: A news recommender for the mobile web. *Expert Systems with Applications* **32**(1), 143 – 150 (2007)
58. Linden, G., Smith, B., York, J.: Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing* **7**(1), 76–80 (2003)
59. Mahmood, T., Ricci, F.: Towards learning user-adaptive state models in a conversational recommender system. In: A. Hinneburg (ed.) *LWA 2007: Lernen - Wissen - Adaption*, Halle, September 2007, Workshop Proceedings, pp. 373–378. Martin-Luther-University Halle-Wittenberg (2007)
60. Mahmood, T., Ricci, F.: Improving recommender systems with adaptive conversational strategies. In: C. Cattuto, G. Ruffo, F. Menczer (eds.) *Hypertext*, pp. 73–82. ACM (2009)
61. Mahmood, T., Ricci, F., Venturini, A., Höpken, W.: Adaptive recommender systems for travel planning. In: W.H. Peter O'Connor, U. Gretzel (eds.) *Information and Communication Technologies in Tourism 2008, proceedings of ENTER 2008 International Conference*, pp. 1–11. Springer, Innsbruck (2008)

62. Mahmoud, Q.: Provisioning context-aware advertisements to wireless mobile users. Multi-media and Expo, 2006 IEEE International Conference on pp. 669–672 (2006)
63. Manning, C.: Introduction to Information Retrieval. Cambridge University Press, Cambridge (2008)
64. Massa, P., Avesani, P.: Trust-aware collaborative filtering for recommender systems. In: Proceedings of the International Conference on Cooperative Information Systems, CoopIS, pp. 492–508 (2004)
65. McCarthy, K., Salamó, M., Coyle, L., McGinty, L., Smyth, B., Nixon, P.: Group recommender systems: a critiquing based approach. In: C. Paris, C.L. Sidner (eds.) IUI, pp. 267–269. ACM (2006)
66. McGinty, L., Smyth, B.: On the role of diversity in conversational recommender systems. In: A. Aamodt, D. Bridge, K. Ashley (eds.) ICCBR 2003, the 5th International Conference on Case-Based Reasoning, pp. 276–290. Trondheim, Norway (2003)
67. McGinty, L., Smyth, B.: Adaptive selection: An analysis of critiquing and preference-based feedback in conversational recommender systems. International Journal of Electronic Commerce **11**(2), 35–57 (2006)
68. McNee, S.M., Riedl, J., Konstan, J.A.: Being accurate is not enough: how accuracy metrics have hurt recommender systems. In: CHI '06: CHI '06 extended abstracts on Human factors in computing systems, pp. 1097–1101. ACM Press, New York, NY, USA (2006)
69. McSherry, D.: Diversity-conscious retrieval. In: S. Craw, A. Preece (eds.) Advances in Case-Based Reasoning, Proceedings of the 6th European Conference on Case Based Reasoning, ECCBR 2002, pp. 219–233. Springer Verlag, Aberdeen, Scotland (2002)
70. McSherry, F., Mironov, I.: Differentially private recommender systems: building privacy into the net. In: KDD '09: Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining, pp. 627–636. ACM, New York, NY, USA (2009)
71. Mirzadeh, N., Ricci, F.: Cooperative query rewriting for decision making support and recommender systems. Applied Artificial Intelligence **21**, 1–38 (2007)
72. Montaner, M., López, B., de la Rosa, J.L.: A taxonomy of recommender agents on the internet. Artificial Intelligence Review **19**(4), 285–330 (2003)
73. Nguyen, Q.N., Ricci, F.: Replaying live-user interactions in the off-line evaluation of critique-based mobile recommendations. In: RecSys '07: Proceedings of the 2007 ACM conference on Recommender systems, pp. 81–88. ACM Press, New York, NY, USA (2007)
74. Nguyen, Q.N., Ricci, F.: Conversational case-based recommendations exploiting a structured case model. In: Advances in Case-Based Reasoning, 9th European Conference, ECCBR 2008, Trier, Germany, September 1–4, 2008. Proceedings, pp. 400–414 (2008)
75. Papagelis, M., Rousidis, I., Plexousakis, D., Theoharopoulos, E.: Incremental collaborative filtering for highly-scalable recommendation algorithms. In: M.S. Hacid, N.V. Murray, Z.W. Ras, S. Tsumoto (eds.) ISMIS, *Lecture Notes in Computer Science*, vol. 3488, pp. 553–561. Springer (2005)
76. Park, M.H., Hong, J.H., Cho, S.B.: Location-based recommendation system using bayesian user's preference model in mobile devices. In: J. Indulska, J. Ma, L.T. Yang, T. Ungerer, J. Cao (eds.) UIC, *Lecture Notes in Computer Science*, vol. 4611, pp. 1130–1139. Springer (2007)
77. Park, S., Kang, S., Kim, Y.K.: A channel recommendation system in mobile environment. Consumer Electronics, IEEE Transactions on **52**(1), 33–39 (2006). DOI 10.1109/TCE.2006.1605022
78. Pazzani, M.J.: A framework for collaborative, content-based and demographic filtering. Artificial Intelligence Review **13**, 393–408 (1999)
79. Polat, H., Du, W.: Privacy-preserving collaborative filtering using randomized perturbation techniques. In: Proceedings of the 3rd IEEE International Conference on Data Mining (ICDM 2003), 19–22 December 2003, Melbourne, Florida, USA, pp. 625–628 (2003)
80. Puerta Melguizo, M.C., Boves, L., Deshpande, A., Ramos, O.M.: A proactive recommendation system for writing: helping without disrupting. In: ECCE '07: Proceedings of the 14th European conference on Cognitive ergonomics, pp. 89–95. ACM, New York, NY, USA (2007). DOI <http://doi.acm.org/10.1145/1362550.1362569>
81. Ramakrishnan, N., Keller, B.J., Mirza, B.J., Grama, A., Karypis, G.: When being weak is brave: Privacy in recommender systems. IEEE Internet Computing **cs.CG/0105028** (2001)
82. Reilly, J., McCarthy, K., McGinty, L., Smyth, B.: Dynamic critiquing. In: Advances in Case-Based Reasoning, 7th European Conference, ECCBR 2004, Madrid, Spain, August 30 - September 2, 2004. Proceedings, pp. 763–777 (2004)
83. Reilly, J., Zhang, J., McGinty, L., Pu, P., Smyth, B.: Evaluating compound critiquing recom-

- menders: a real-user study. In: EC '07: Proceedings of the 8th ACM conference on Electronic commerce, pp. 114–123. ACM, New York, NY, USA (2007)
84. Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., Riedl, J.: Grouplens: An open architecture for collaborative filtering of netnews. In: Proceedings ACM Conference on Computer-Supported Cooperative Work, pp. 175–186 (1994)
85. Resnick, P., Varian, H.R.: Recommender systems. *Communications of the ACM* **40**(3), 56–58 (1997)
86. Ricci, F.: Travel recommender systems. *IEEE Intelligent Systems* **17**(6), 55–57 (2002)
87. Ricci, F., Cavada, D., Mirzadeh, N., Venturini, A.: Case-based travel recommendations. In: D.R. Fesenmaier, K. Woeber, H. Werthner (eds.) *Destination Recommendation Systems: Behavioural Foundations and Applications*, pp. 67–93. CABI (2006)
88. Ricci, F., Missier, F.D.: Supporting travel decision making through personalized recommendation. In: C.M. Karat, J.O. Blom, J. Karat (eds.) *Designing Personalized User Experiences in eCommerce*, pp. 231–251. Kluwer Academic Publisher (2004)
89. Ricci, F., Nguyen, Q.N.: Acquiring and revising preferences in a critique-based mobile recommender system. *IEEE Intelligent Systems* **22**(3), 22–29 (2007). DOI <http://doi.ieeecomputersociety.org/10.1109/MIS.2007.43>
90. Sae-Ueng, S., Pinyapong, S., Ogino, A., Kato, T.: Personalized shopping assistance service at ubiquitous shop space. *Advanced Information Networking and Applications - Workshops, 2008. AINAW 2008. 22nd International Conference on* pp. 838–843 (2008). DOI 10.1109/WAINA.2008.287
91. Sarwar, B., Karypis, G., Konstan, J., Riedl, J.: Incremental singular value decomposition algorithms for highly scalable recommender systems. In: *Proceedings of the 5th International Conference in Computers and Information Technology* (2002)
92. Sarwar, B.M., Konstan, J.A., Riedl, J.: Distributed recommender systems for internet commerce. In: M. Khosrow-Pour (ed.) *Encyclopedia of Information Science and Technology* (II), pp. 907–911. Idea Group (2005)
93. Schafer, J.B., Frankowski, D., Herlocker, J., Sen, S.: Collaborative filtering recommender systems. In: *The Adaptive Web*, pp. 291–324. Springer Berlin / Heidelberg (2007)
94. Schafer, J.B., Konstan, J.A., Riedl, J.: E-commerce recommendation applications. *Data Mining and Knowledge Discovery* **5**(1/2), 115–153 (2001)
95. Schifanella, R., Panisson, A., Gena, C., Ruffo, G.: Mobhinter: epidemic collaborative filtering and self-organization in mobile ad-hoc networks. In: *RecSys '08: Proceedings of the 2008 ACM conference on Recommender systems*, pp. 27–34. ACM, New York, NY, USA (2008)
96. Schwartz, B.: *The Paradox of Choice*. ECCO, New York (2004)
97. van Setten, M., McNee, S.M., Konstan, J.A.: Beyond personalization: the next stage of recommender systems research. In: R.S. Amant, J. Riedl, A. Jameson (eds.) *IUI*, p. 8. ACM (2005)
98. van Setten, M., Pokraev, S., Koolwaaij, J.: Context-aware recommendations in the mobile tourist application compass. In: W. Nejdl, P. De Bra (eds.) *Adaptive Hypermedia 2004*, pp. 235–244. Springer Verlag (2004)
99. Shani, G., Heckerman, D., Brafman, R.I.: An mdp-based recommender system. *Journal of Machine Learning Research* **6**, 1265–1295 (2005)
100. Sharda, N.: *Tourism Informatics: Visual Travel Recommender Systems, Social Communities, and User Interface Design*. Information Science Reference (2009)
101. Shardanand, U., Maes, P.: Social information filtering: algorithms for automating “word of mouth”. In: *Proceedings of the Conference on Human Factors in Computing Systems (CHI'95)*, pp. 210–217 (1995)
102. Shokri, R., Pedarsani, P., Theodorakopoulos, G., Hubaux, J.P.: Preserving privacy in collaborative filtering through distributed aggregation of offline profiles. In: *RecSys '09: Proceedings of the third ACM conference on Recommender systems*, pp. 157–164. ACM, New York, NY, USA (2009)
103. Sinha, R.R., Swearingen, K.: Comparing recommendations made by online systems and friends. In: *DELOS Workshop: Personalisation and Recommender Systems in Digital Libraries* (2001)
104. Smyth, B., McClave, P.: Similarity vs diversity. In: *Proceedings of the 4th International Conference on Case-Based Reasoning*. Springer-Verlag (2001)
105. Swearingen, K., Sinha, R.: Beyond algorithms: An HCI perspective on recommender systems. In: J.L. Herlocker (ed.) *Recommender Systems, papers from the 2001 ACM SIGIR Workshop*. New Orleans, LA - USA (2001)

106. Taghipour, N., Kardan, A.: A hybrid web recommender system based on q-learning. In: Proceedings of the 2008 ACM Symposium on Applied Computing (SAC), Fortaleza, Ceara, Brazil, March 16-20, 2008, pp. 1164–1168 (2008)
107. Taghipour, N., Kardan, A., Ghidary, S.S.: Usage-based web recommendations: a reinforcement learning approach. In: Proceedings of the 2007 ACM Conference on Recommender Systems, RecSys 2007, Minneapolis, MN, USA, October 19-20, 2007, pp. 113–120 (2007)
108. Takács, G., Pilászy, I., Németh, B., Tikk, D.: Scalable collaborative filtering approaches for large recommender systems. *J. Mach. Learn. Res.* **10**, 623–656 (2009)
109. Tan, P.N.: Introduction to Data Mining. Pearson Addison Wesley, San Francisco (2006)
110. Thompson, C.A., Goker, M.H., Langley, P.: A personalized system for conversational recommendations. *Artificial Intelligence Research* **21**, 393–428 (2004)
111. Tung, H.W., Soo, V.W.: A personalized restaurant recommender agent for mobile e-service. In: S.T. Yuan, J. Liu (eds.) Proceedings of the IEEE International Conference on e-Technology, e-Commerce and e-Service, EEE'04, pp. 259–262. IEEE Computer Society Press, Taipei, Taiwan (2004)
112. Van Roy, B., Yan, X.: Manipulation-resistant collaborative filtering systems. In: RecSys '09: Proceedings of the third ACM conference on Recommender systems, pp. 165–172. ACM, New York, NY, USA (2009)
113. Wang, J., Pouwelse, J.A., Lagendijk, R.L., Reinders, M.J.T.: Distributed collaborative filtering for peer-to-peer file sharing systems. In: H. Haddad (ed.) SAC, pp. 1026–1030. ACM (2006)
114. Wang, Y., Kobsa, A.: Performance evaluation of a privacy-enhancing framework for personalized websites. In: G.J. Houben, G.I. McCalla, F. Pianesi, M. Zancanaro (eds.) UMAP, *Lecture Notes in Computer Science*, vol. 5535, pp. 78–89. Springer (2009)
115. Wietsma, R.T.A., Ricci, F.: Product reviews in mobile decision aid systems. In: Pervasive Mobile Interaction Devices (PERMID 2005) - Mobile Devices as Pervasive User Interfaces and Interaction Devices - Workshop in conjunction with: The 3rd International Conference on Pervasive Computing (PERVASIVE 2005), May 11 2005, Munich, Germany, pp. 15–18. LMU Munich (2005)
116. Xie, B., Han, P., Yang, F., Shen, R.: An efficient neighbor searching scheme of distributed collaborative filtering on p2p overlay network. *Database and Expert Systems Applications* pp. 141–150 (2004)
117. Yuan, S.T., Tsao, Y.W.: A recommendation mechanism for contextualized mobile advertising. *Expert Systems with Applications* **24**(4), 399–414 (2003)
118. Zhang, F.: Research on recommendation list diversity of recommender systems. *Management of e-Commerce and e-Government, International Conference on* pp. 72–76 (2008)
119. Zhang, M.: Enhancing diversity in top-n recommendation. In: RecSys '09: Proceedings of the third ACM conference on Recommender systems, pp. 397–400. ACM, New York, NY, USA (2009)
120. Zhou, B., Hui, S., Chang, K.: An intelligent recommender system using sequential web access patterns. In: *Cybernetics and Intelligent Systems, 2004 IEEE Conference on*, vol. 1, pp. 393–398 vol.1 (2004)
121. Ziegler, C.N., McNee, S.M., Konstan, J.A., Lausen, G.: Improving recommendation lists through topic diversification. In: WWW '05: Proceedings of the 14th international conference on World Wide Web, pp. 22–32. ACM Press, New York, NY, USA (2005)