

基于递归神经网络与注意力机制的 动态个性化搜索算法

周雨佳 窦志成 葛松玮 文继荣

(中国人民大学信息学院 北京 100872)

(中国人民大学大数据管理与分析方法研究北京市重点实验室 北京 100872)

摘要 个性化搜索已被证明可以有效提高搜索引擎检索质量. 大部分个性化搜索算法都是基于用户的历史行为构建用户模型, 然后通过比较文档和用户模型的相似度来对原始结果进行个性化重排. 本文认为用户查询需求具有动态性和随机性, 因此近期的用户查询行为以及当前查询相关的历史查询行为对个性化当前查询的贡献应当高于其他查询. 本文运用递归神经网络来构建用户个性化偏好, 对用户兴趣的动态性进行建模, 再利用注意力机制根据当前查询动态地对历史用户行为进行加权. 和以往对用户兴趣建模的方法不同, 本文构建出来的用户模型依赖于当前用户查询的需求. 最终, 文档得分包括表示用户模型与备选文档相似度的个性化得分, 以及查询与文档之间的相关度得分, 据此得分排序后的文档列表即为个性化排序结果. 实验表明, 相比于传统非个性化搜索方法以及现有的个性化搜索模型, 本文的动态个性化搜索模型取得了更好的个性化搜索结果, 在 SLTB 个性化搜索模型的基础上将 MAP 值提升了 2.7%. 并且通过多项对比实验证明了递归神经网络以及注意力机制的有效性.

关键词 个性化搜索; 递归神经网络; 注意力机制

中图法分类号 TP311 **DOI号** 10.11897/SR.J.1016.2020.00812

Dynamic Personalized Search Based on RNN with Attention Mechanism

ZHOU Yu-Jia DOU Zhi-Cheng GE Song-Wei WEN Ji-Rong

(School of Information, Renmin University of China, Beijing 100872)

(Beijing Key Laboratory of Big Data Management and Analysis Methods, Renmin University of China, Beijing 100872)

Abstract Traditional search engines always return the same result when facing the same query for different users. Therefore, when a user issues an ambiguous query, the search result can't fully meet the user's demands. Personalized search is a practicable method to solve this problem. It has been proven to be able to improve the search quality of search engines. The majority of existing personalized search algorithms re-rank the original results by comparing the similarity between documents and user profiles built based on historical user behaviors. These behaviors contain a wealth of information to reflect the user personalized preferences. However, most of them generally believe that user interests are stable and unchanged for a long time, which is inconsistent with the actual situation. In this paper, we argue that user information needs might dynamically change over time and sometimes the user information needs are random. Therefore, the users' recent search behaviors and the historical queries that are more similar to the current query contribute more to personalization than the others. This paper will take advantage of deep learning in feature extraction to build better user profiles. To solve the problem of dynamicity

收稿日期:2018-10-17;在线出版日期:2019-06-25. 本课题得到国家自然科学基金(61872370)和国家重点研究发展计划(2018YFC0830703)资助. 周雨佳, 博士研究生, 主要研究方向为自然语言处理、数据挖掘等. E-mail: 2015201988@ruc.edu.cn. 窦志成(通信作者), 博士, 教授, 中国计算机学会(CCF)会员, 主要研究领域为信息检索、数据挖掘、大数据分析等. E-mail: dou@ruc.edu.cn. 葛松玮, 硕士研究生, 主要研究方向为基于深度学习的的信息检索和数据挖掘以及跨模态检索. 文继荣, 博士, 教授, 国家千人计划专家, 中国计算机学会(CCF)会员, 主要研究领域为信息检索、数据库、大数据分析、数据挖掘.

of user information needs, we use recurrent neural networks to construct the user personalized preferences from his behaviors in history in order to model the dynamicity of user interest. With the aim of getting more accurate personalized preferences, we not only model user interest utilizing recurrent neural networks, but also assess the importance of each user interest based on the user's situation at this moment. The user's situation is modeled by another recurrent neural networks, thereby affecting the user's interests by gate control units. Based upon the consideration of randomness of information needs, we use the attention mechanism to dynamically assign different weights to different user interests based on their similarities to the current query. In contrast, to previous user interest modeling methods, the user models built in this paper hinge on the current search query. In other words, the attention mechanism allows us to dynamically adjust the user model to a theme that is more suitable for the current query based on topic similarity. Finally, given a candidate document, we calculate the personalized score by comparing the similarity between the user interest feature vector and the document, and then combine the relevance score which indicates the relation between the document and the query to get the final score. The list of documents sorted according to final score is the personalized search results. Experimental results show that our personalized search model outperforms traditional non-personalized search methods and existing personalized search models. Compared to the SLTB personalized search model, our model has increased by 2.7% in MAP, which demonstrates that deep learning helps to build user profiles better. In addition, through comparative experiments, we prove the correctness of our basic ideas and the effectiveness of the attention mechanism. The model proposed in this paper improves the results on non-navigational queries to a greater extent. This improvement confirms the validity of our model on ambiguous query.

Keywords personalized search; recurrent neural network; attention mechanism

1 引言

如今人们从互联网获取信息的主要手段之一是利用搜索引擎强大的检索功能. 当给定一个查询词时, 搜索引擎能够根据文档和查询词的匹配程度对互联网文档集进行排序, 进而为用户返回最相关的文档以满足用户的查询需求. 然而, 这种搜索方式目前却存在一个问题——在对文档进行排序时, 仅考虑了文档和查询词的相关度, 而忽略了用户信息. 面对不同用户的相同查询, 搜索引擎总是返回相同的结果. 然而事实上对于相同查询, 不同用户的真实意图往往不同. 这种现象在查询词具有歧义时尤为明显. 例如, 查询词为“MAC”, 一些用户希望能够得到有关苹果 MAC 电脑的信息, 而有些用户则希望能够获取与 MAC(魅可)品牌的口红的相关内容, 甚至有些用户希望能了解计算机网络中 MAC 子层的知识. 非个性化的信息检索方法并不能将此区分开来.

个性化搜索是解决上述查询歧义性问题的主要方法之一. 个性化搜索的主要目标是根据用户兴趣

不同, 为不同用户返回满足其需要的个性化的排序列表. 目前研究人员已经提出了一系列个性化搜索算法^[1-4]. 这些算法的基本思想是首先对用户兴趣进行建模, 进而在文档排序时, 除了考虑文档和查询的相关性, 还同时考虑文档和用户兴趣的匹配程度. 由于个性化算法的不同, 用户兴趣的表示和建模方法也不尽相同, 但其主要思路都是基于用户历史搜索行为来建立用户兴趣模型, 从而进行个性化排序. 例如, Cai 等人^[2]利用用户查询历史、页面浏览历史、点击驻留时间等多个因素对用户兴趣进行建模, 在对结果的个性化重排上取得了很好的效果. Dou 等人^[3]提出了基于用户对文档的历史点击次数和点击文档的主题分布来进行个性化排序的方法. 还有一些学者通过提取用户查询和点击页面的主题来刻画用户兴趣特征, 进而来评估文档与用户兴趣的相似性^[1,4-7].

虽然有大量的个性化搜索算法和用户建模方法被提出, 但如何有效利用用户历史准确地进行用户建模仍然是一个需要积极探索的问题. 现有的大部分研究工作普遍认为用户的兴趣爱好是稳定且长期

不变的,用户的兴趣爱好可以通过对所有历史用户行为进行简单聚合而获得.事实上,用户的查询需求具有动态性和随机性.所谓动态性,是指在现实生活中,由于生活和工作的需要,用户的信息需求会随着时间产生阶段性变化.用户可能会在一段时间内围绕着一个主题不断地查询,但当该阶段的任务完成后,用户可能会切换到另外一个主题.例如,一个学生可能在某个学期末频繁查询某门课程的相关内容来准备考试或撰写学期论文,而当考完试后,该用户则可能会持续查找某一地方旅游景点的信息来满足在假期旅游过程中的信息需求.很显然,在预测用户当前的查询需求方面,用户的近期查询历史比远期查询历史更可靠.所谓随机性,是指用户可能会因为需要而临时检索一些和自己的用户兴趣无关的内容.例如,用户在准备期末考试的过程中因为感冒而临时检索一些医院和科室的信息,而一个长期的计算机工作者也可能会临时查询旅游相关的信息.在对这些查询进行个性化处理时,需要对历史用户行为进行筛选.在后一个例子中,如果用户在查询旅游相关信息时,通过计算结果和计算机主题的匹配程度对结果进行个性化排序会导致错误的排序结果.

因为上述用户查询需求的动态性和随机性,简单地对用户历史行为进行等重加权来预测用户兴趣是不可靠的.目前的个性化搜索算法中对用户查询需求动态性和随机性问题的考虑和处理还非常有限. Dou 等人^[4]和 Bennett 等人^[1]观察到了用户兴趣的动态性.他们将用户的历史行为切分为短期行为(一般是和当前查询在同一个会话内的历史行为)和长期行为(一般是除当前会话之外的其他历史行为),并指出二者在个性化时的作用不同,应该分开建模. Shen 等人^[8]和 White 等人^[9]也提出用户通常为了获取短期的信息而进行文档搜索,短期查询在用户兴趣建模时的作用更大.然而,这种简单将用户历史一分为二的方式过于简单.例如,同样是长期用户行为中,用户一周之前的查询应该比一个月或者一年之前的查询在预测当前用户查询需求上的作用更大. Vu 等人^[10]进一步提出了一种按时间加权的模型.他们将每个历史行为的重要性按照距离当前时间的长短进行指数衰减,越近的行为权重越大.这种方法虽然刻画了用户历史行为重要性随着时间进行变化的特征,但这种所有用户行为都按照时间进行指数衰减的方式过于简单.一方面无法证明指数衰减是否符合真正的用户兴趣变化规律,另一方面,这种方法忽略了用户兴趣的随机性. Bennett 等人^[1]

证明了简单地添加一个按时间衰退的系数不会对结果产生显著性提升.

本文重点针对用户查询需求的动态性和随机性问题展开研究.本文认为:

(1) 基于对查询需求随机性问题的考虑,在用户兴趣建模时要考虑用户历史行为与当前查询需求的主题相关性.这种设置的目的是降低无关历史行为对个性化效果的负面影响,从而提升个性化搜索的准确性和可靠性.极端情况下,用户历史查询的点击行为对下一次相同查询的作用是最大的.这一现象被一些学者称为重查行为(Refinding)^[4,9,11-13].

(2) 基于对查询需求动态性问题的考虑,在用户兴趣建模时应更有效地考虑用户历史行为上的时序特征,通过监督学习的方法,自动学习出用户行为的演变规律以及对用户兴趣建模重要性的动态变化情况.

为了实现这个目标,本文引入递归神经网络(RNN)和注意力机制对用户历史进行建模.根据用户点击的时间序列信息,通过递归神经网络对用户历史行为进行分析,来构建不同时期的用户个性化偏好,建立起不同时间的查询对当前查询的影响力模型,解决查询需求动态性问题.而后利用注意力机制,根据当前查询与历史用户行为的主题相似性,动态地计算出不同个性化偏好的权重,并且通过线性组合产生更为有效的兴趣特征向量.该方法能够降低不相关历史行为对当前个性化排序的负面影响,提高个性化搜索算法的稳定性,在一定程度上解决查询需求随机性问题.此外,和采用非监督学习进行用户兴趣建模的方法不同,本文利用大规模搜索日志自动学习出每个历史用户行为的重要性以及不同行为之间的传递关系,使个性化搜索算法能够更稳定有效地发挥效果.

本文认为,用户模型不应该是一成不变的,对于用户提出的不同查询,用户模型也应当做出适应性的改变,注意力机制使我们可以根据主题相似性动态地将用户模型调整为更适合当前查询的主题;同时随着时间的发展,在对用户历史行为建模的过程中,使用的历史行为会被逐渐扩充,也就是说当用户提出新的查询时,上一个查询会被并入用户历史从而对用户模型产生影响.

本文进一步将用户兴趣建模和个性化搜索排序学习两个过程紧密结合在一起,使用排序学习算法 LambdaRank 融合查询、文档和用户兴趣等多个因素,训练个性化排序模型.最终,在某商业搜索引擎

上的大规模搜索日志数据上的实验证明, 本文所提出的动态个性化搜索算法能够进一步提高搜索精度, 更有效地提升用户体验。

本文在第 2 节介绍与本文研究相关的工作, 主要包括个性化搜索和深度学习在信息检索领域的应用; 第 3 节将对模型结构和建模过程进行阐述; 第 4 节将详细描述数据处理与实验设置, 对实验结果进行对比分析; 第 5 节则是结论部分。

2 相关工作

本文主要研究运用深度学习的方法完成个性化搜索, 相关工作主要包含两部分内容: (1) 个性化搜索; (2) 深度学习在信息检索领域的应用。

2.1 个性化搜索

现如今, 个性化搜索是各大搜索引擎的主要目标之一, 当前主流的个性化算法是基于文本内容进行分析, 即通过比较用户兴趣与文档相似度来对结果进行重排^[3, 14-15]。其主要依据用户点击数据来建立用户模型^[2], 刻画出用户兴趣特征, 以此来完成个性化搜索。

现有的个性化算法主要通过比较用户模型与文档的相似度来估计该文档与用户需求的契合程度。一部分研究人员运用关键词信息建立用户模型, 例如, Sugiyama 等人^[16]在 2004 年提出利用用户点击过的文档中关键词的出现频率建立词频向量, 并运用协同过滤算法建立用户模型, 最后与结果文档的关键词向量进行相似度计算, 实现对搜索结果的重排。Shen 等人^[8]使用统计语言模型对用户查询上下文进行建模, 通过计算用户模型与结果文档统计语言模型的相似度, 实现对结果文档的个性化排序。另一部分学者通过主题分类的方法建立用户模型, 根据点击日志生成用户兴趣主题类别, 进而完成对结果的个性化排序^[17-19]。最初的研究是通过人工对点击文档主题标注的方法来建模, 例如, Chirita 等人^[19]通过 Open Dictionary Project (ODP) 层级结构来描述用户兴趣, 但是这种方式会造成标注种类受限的问题。近期的研究中, Carman 等人^[20]采用无监督学习的方法来学习文档主题类, Harvey 等人^[5]提出 PTM 模型来构建用户主题类模型。同时众多具有创新性的算法出现在个性化搜索领域, 曾春等人^[21]利用领域分类模型上的概率分布来构建用户兴趣模型。Wang 等人^[22]提出基于全局排序模型和当前用户的查询, 快速调节原模型以匹配用户当前

需求的方法。但是, 这些方法依然存在用户特征不全面的问题。

深度学习的出现, 使个性化搜索可以借助深度学习自适应的优点, 独立地为每个用户建立模型, Li 等人^[23]通过深度学习的方法从用户历史资料中获得用户语义特征, 并将此特征用在对结果的排序上。除了从查询日志中提取用户特征, 一些其他的特征信息也被使用在个性化搜索中。例如: Bennett 等人^[24]将用户的位置特征并入个性化模型中。Collins-Thompson 等人^[25]研究并评估了用户不同阅读水平对个性化搜索的影响。近些年来, 个性化排序中建立用户模型的方法越来越广泛, Grbovic 等人^[26]除了利用用户点击文档, 同时结合未点击文档进行负向用户兴趣建模。Huang 等人^[27]通过引入知识库来刻画不同实体之间的联系, 进而反映在用户兴趣上。He 等人^[28]通过对抗神经网络建立更加细致的用户画像。然而, 这些方法中仍然存在一些问题, 比如在之前的研究中, 用户查询的动态性和随机性的特点往往被忽略。

在本文的模型中, 主要关注的是基于文档主题的个性化特征, 同时也考虑了用户查询需求动态性与随机性的特点, 根据历史查询时间的不同与查询内容的不同, 动态地赋予不同的权重, 进而影响当前文档排序结果。

2.2 深度学习在信息检索中的应用

深度学习的方法现如今已开始与信息检索领域崭露头角, 相比于传统的方法, 深度学习在自动学习单词嵌入和特征提取的能力上具有明显的优势, 尤其在 ad-hoc (即文档集不变, 查询改变) 任务中取得了令人满意的结果。He 等人提出 DSSM^[29]和 CDSSM^[30]方法, 将查询-文档对嵌入到语义空间中, 并根据嵌入文档和查询的相似度对结果进行排序。随后, Severyn 和 Moschitti^[31]使用卷积神经网络来表示查询-文档对并计算它们的语义相似性。Palangi 等人^[32]将长短期记忆网络应用于此, 利用查询具有时序性的特点, 进一步改善了查询-文档对的嵌入方法。近期, 研究人员设计出更加有效的模型, 例如 DRMM^[33]和 K-NRM^[34], 二者都通过在单词之间的相似度上建模, 再输入到深度学习模型中的方法改进了原有的模型, 后者作为前者的升级, 得到了更加准确的结果。

但是, 将深度学习应用在个性化搜索的研究在近几年才有所发展, Song 等人^[35]在 2014 年提出在全局排序模型的基础上, 对每个用户采用持续训练

的方法来实现个性化. Li 等人^[23]通过深度学习获得用户语义特征,进而改进查询结果.但是以上研究都只是在传统方法的基础上增加了深度学习的思想,本文的模型旨在用 listwise 方法训练出一个完整的深度学习框架来完成个性化搜索.

3 个性化搜索模型

如引言中所说,针对不同用户,应该建立不同的兴趣向量来刻画用户的特点,以此来返回更加符合用户需求的文档排序.除此之外,由于用户查询需求动态性和随机性的特点,本文的个性化搜索模型学习了用户行为的变化规律以及不同行为特征对用户兴趣建模重要性的动态变化情况,同时考虑了用户历史行为中对当前查询贡献度的差异性.

本文将采用深度学习的方法来改善上述问题,首先基于对查询需求动态性的考虑,运用递归神经网络(RNN)对用户历史进行建模.对于每一个用户 u ,其历史查询包含 (q_1, q_2, \dots, q_n) ,其中每一个 q_i 对应的相关文档为 $(d_{i,1}, d_{i,2}, \dots)$,首先通过 RNN 模型自动学习 q 和 d 的文本特征,得到用户兴趣表示,进而结合利用每一个 q_i 对应的查询特征 e_i 生成的用户状态向量,得到用户个性化偏好.而后基于对查询

需求随机性的考虑,引入注意力机制,针对不同的查询,对用户不同时期的个性化偏好赋予不同权重,加权求和得到用户兴趣特征向量 \mathbf{X}_u .最后计算出每一个文档的得分,并根据得分对文档集合进行排序.得分的计算如下:

$$Score(d_i) = PScore(d_i | \mathbf{X}_u) + RScore(d_i | q) \quad (1)$$

其中 $PScore(d_i | \mathbf{X}_u)$ 表示文档和兴趣特征向量的相关性,即文档针对当前用户的个性化得分. $RScore(d_i | q)$ 表示文档和查询之间的相关性,即不考虑个性化特征的相关度得分.其中文档和查询之间的相关性特性包含点击位置、点击次数和点击熵三部分,在 3.3 节会详细说明.本文模型结构图如图 1 所示,主要包含以下 3 个部分:

(1) 用户历史行为建模. 即利用用户历史行为和查询特征时序性的特点,根据用户兴趣与用户状态,建立用户个性化偏好模型,解决用户查询需求动态性问题.

(2) 使用注意力机制动态地对用户不同个性化偏好进行赋权,降低用户无关兴趣对当前查询的影响,解决用户查询需求随机性问题.

(3) 个性化排序结果生成. 即根据个性化得分和相关度得分对文档集进行重新排序,得到新的个性化排序结果.

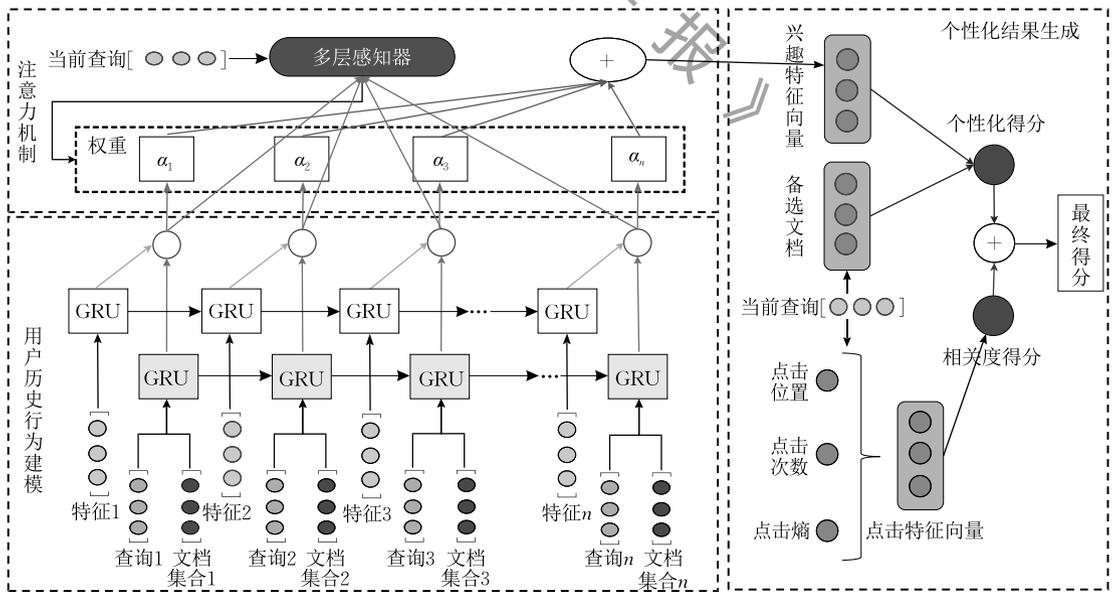


图 1 GRADP 模型结构图

3.1 用户历史行为建模

用户历史行为包含着丰富的个性化信息,其中最主要的是用户的兴趣信息,例如某用户喜欢打篮球,或喜欢某个明星.同时,也包含了用户的状态信

息,例如某用户通常使用精确查询来获取自己需要的信息,或通过泛化的查询来从结果中挑选自己感兴趣的信息.因此,本文将用户历史行为建模分为用户兴趣建模与用户状态建模,二者共同作用,更加精

确地生成用户个性化偏好。

3.1.1 用户兴趣建模

如前所述,用户的查询需求具有动态性.为了及时准确地捕捉到用户查询需求和兴趣爱好的变化,并根据查询的时序特征,寻找用户历史行为变化规律,本文拟采用递归神经网络(RNN)来建立用户兴趣模型,由于时间跨度较大,普通的RNN结构记忆效果会大幅减弱,因此选用更加适合长期记忆的Gated Recurrent Unit(GRU)或Long Short-Term Memory(LSTM)结构作为基本结点.GRU和LSTM是RNN的两种变体,二者都能够防止梯度消失,但GRU相比于LSTM,具有收敛速度更快、容易训练的特点.值得注意的是,本文使用更加适合长期记忆的结构是希望模型既可以刻画出用户兴趣随时间衰减的特点,同时参考用户早期的兴趣,来精确地对用户当前兴趣进行建模.

在对用户兴趣建模过程中,递归神经网络层的输入为用户的查询历史 $Q=(q_1, q_2, \dots, q_n)$ 和与其对应的相关文档集合 $D=(d_1, d_2, \dots, d_n)$ (d_i 是所有与查询 q_i 相关文档($d_{i,1}, d_{i,2}, \dots$)的集合向量),需要强调的是,这里的查询历史是指当前查询之前的所有查询,即用户模型会随着新的用户行为的加入而做出改变.在此运用监督学习的方法,经过递归神经网络层提取出不同时期用户的兴趣向量.其中每个时期的状态结点依赖于当前输入和上一时期状态结点,公式如下:

$$h_n = f(h_{n-1}, q_n, d_n) \quad (2)$$

h_n 代表当前状态结点向量,根据当前查询 q_n 、该查询相关文档集 d_n 以及上一状态结点 h_{n-1} 而得.

f 函数是根据RNN结点的类型而确定的.在本文的模型中,RNN结点类型为GRU.该函数计算如下:

$$r_n = \sigma(W_r[q_n, d_n] + V_r h_{n-1}) \quad (3)$$

$$z_n = \sigma(W_z[q_n, d_n] + V_z h_{n-1}) \quad (4)$$

$$c_n = \tanh(W_c[q_n, d_n] + V_c(r_n \cdot h_{n-1})) \quad (5)$$

$$h_n = (1 - z_n) \cdot h_{n-1} + z_n \cdot c_n \quad (6)$$

r_n 代表重置门, z_n 代表更新门,二者共同决定从前一状态结点和当前输入之中选取哪些信息传入下一状态结点. $\sigma(\cdot)$ 是sigmoid函数. $W_r, W_z, W_c, V_r, V_z, V_c$ 是需要训练过程中不断调整的参数.经过GRU层,将不同时期隐含层结点的输出记为集合 $H_1=(h_1, h_2, \dots, h_n)$,用来表示用户不同时期的兴趣.

3.1.2 用户状态建模

本文认为,随时间变化的不只是用户的兴趣,用

户的查询习惯、性格特点等用户状态都会进行阶段性的变化,例如:用户在刚入门一个领域时可能喜欢通过泛化的查询来获取相关信息,如“操作系统”等可个性化程度很高的查询,此时提取出的用户兴趣更加能够体现该用户的个性化偏好,而后会有针对性地提出“Windows系统创始人姓名”等可个性化程度很低的查询,这些查询下的用户兴趣并不具有代表性.在此过程中用户状态的变化会影响对用户兴趣的建模.在不同时期的用户状态下,对用户兴趣的关注度也应当不同.

在对用户状态建模过程中,为了获得其随时间的变化情况,同3.1.1节,本文采用GRU对其进行建模.GRU层的输入为用户的查询历史 $Q=(q_1, q_2, \dots, q_n)$,与其对应的是查询特征 $E=(e_1, e_2, \dots, e_n)$,查询特征主要用来刻画该查询的歧义性以及可个性化程度,包含以下六项指标:

点击熵.该指标用来衡量某查询下所有满意点击文档的离散程度^[3].其计算公式如下:

$$CE(q) = \sum_{d_i \in result(q)} -P(d_i|q) \log_2 P(d_i|q) \quad (7)$$

$CE(q)$ 指查询 q 的点击熵, $result(q)$ 指查询 q 的结果集合, $P(d_i|q)$ 指在查询 q 下,对文档 d_i 的点击数占该查询全部点击数的比例,这里用 $Clicks(d)$ 表示对文档 d 的点击次数,计算公式如下:

$$P(d_i|q) = \frac{Clicks(d_i)}{\sum_{d_j \in result(q)} Clicks(d_j)} \quad (8)$$

域点击熵.有时用户会点击多个文档,但其所在主域名是一致的,例如用户查询“dewalt parts”时点击如下两个文档,“www.dewalt.com/parts-and-service”,“www.dewalt.com/home”,虽然文档不同,但其真实意图是一致的,并不能说明该查询具有歧义性.因此我们将相同域名的文档合并,并将点击次数相加后计算点击熵,称作域点击熵^[36].

返回文档主题熵.刻画某查询返回所有文档的主题分布.计算方式如下:

$$TE(q) = \sum_{p=1}^{R^d} -d_p \log_2(d_p) \quad (9)$$

$TE(q)$ 指查询 q 的主题熵, R^d 是文档向量的维度, d_p 为查询 q 下所有文档向量和第 p 维的值.

满意点击文档主题熵.刻画某查询下满意点击文档的主题分布.只统计满意点击文档而非所有文档,计算公式同式(9).

nCS.在非歧义性查询中,用户往往会点击很少数的文档.因此,统计对某查询的多次检索中,用户

点击次数小于 n 的比例^[37].

nRS. 在非歧义性查询中,用户往往会点击位置靠前的文档.因此,统计对某查询的多次检索中,用户只在前 n 个结果中有满意点击的比例^[37].

递归神经网络计算同式(2),GRU层的输出表示不同时期的用户状态以及其随时间的变化情况,记为集合 H_2 .接下来本文将介绍如何将用户兴趣与用户状态相结合,从而计算出用户的个性化偏好.

3.1.3 用户个性化偏好生成

本文认为,在某一时刻的用户状态决定该时刻用户兴趣的重要程度,因此设置门控单元来控制对当时用户兴趣的关注度,从而得到用户不同时期的个性化偏好集合 S ,公式如下:

$$g = V_g \sigma(H_2 W_g + b_g) \quad (10)$$

$$S = g \cdot H_1 \quad (11)$$

H_1 与 H_2 分别表示用户兴趣建模与状态建模部分GRU层的输出, g 表示不同时期用户兴趣的权重, $\sigma(\cdot)$ 是sigmoid函数. V_g, W_g, b_g 是需要训练的参数. $S = (s_1, s_2, \dots, s_n)$ 表示在用户兴趣和用户状态的共同作用下,不同时期用户的个性化偏好.

最终我们通过对用户历史行为建模,得到用户不同时期的个性化偏好,学习到用户历史行为的演变规律以及不同历史行为对用户模型重要性的变化.这使得用户查询需求动态性问题得到了很好的解决,接下来本文将针对随机性问题进行分析.

3.2 注意力机制

不同的个性化偏好对不同新查询的影响力是不相同的.当一个用户的新查询与他之前的某些查询相关时,这些历史查询对个性化当前新查询的作用应该远大于那些和当前查询无关的历史查询.换句话说,与当前查询相关的历史查询上的用户行为在进行用户兴趣建模时,所占权重应该高于其他查询.例如:如果用户当前要查询“手机”,则该用户历史查询中的“华为”和“三星”等查询上的点击行为有助于帮助确定该查询的意图是手机电子产品而不是电影《手机》.而该用户历史查询中和“手机”无关的信息,例如“糖尿病”等,则对个性化当前查询无任何作用.从另外一个角度上讲,强制使用历史无关查询上的用户行为对当前查询进行个性化,反而会造成结果的混乱.作为该现象的一个特例,历史上如果该用户曾经查询过该查询“手机”,则当时用户点击过的文档很可能会被用户再次点击,这就是引言中提到的重查行为.

根据此特点,运用注意力机制可以很好的解决

这个问题.注意力机制最早用于视觉图像领域,在2014年Google Mind团队第一次在RNN模型上使用了注意力机制来进行图像分类^[38],该机制第一次应用在文本处理上是在2014年,Bahdanau等人^[39]将其用在了神经网络机器翻译上,很好地把握语言端的每个词和当前要预测翻译的词联系起来,效果有了很大提升.2017年Google团队提出多头自注意力机制,并代替RNN与CNN来完成多项任务,取得突破性进展,诠释了该机制在权重学习方面的重要性^[40].它能够考虑全局对于当前的影响,并且对全局中不同的结点赋予不同的权重.在本文的模型中,注意力机制作为解决用户查询需求随机性问题的方法,其主要思路如下所述.

在3.1节中我们对用户历史行为进行了细致的建模,为了去除无关兴趣的影响,本节将不同时期的个性化偏好 $S = (S_1, S_2, \dots, S_n)$ 和查询 q 作为注意力层的输入,计算出在当前查询 q 下,每一个 S_i 所对应的权重 α_i ,计算公式如下:

$$e_i = \varnothing(q, S_i) \quad (12)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^n \exp(e_j)} \quad (13)$$

$\varnothing(\cdot)$ 是一个多层感知机(MLP),使用 $\tanh(\cdot)$ 作为激活函数.MLP因其良好的自适应性,而被广泛应用于复杂函数的拟合,它可以根据训练目标,反向传播更新参数,在本文的个性化结果重排任务中,它可以根据当前查询,动态地学习出每一时期个性化偏好的权重,从而更加关注对个性化结果贡献大的用户偏好.相比于直接使用余弦相似度或点积来表示权重,MLP可以根据需要提取出更全面的语义特征来进行赋权.用户 u 基于当前查询的兴趣特征 \mathbf{X}_u 由 (S_1, S_2, \dots, S_n) 的线性组合计算得到,公式如下:

$$\mathbf{X}_u = \sum_{i=1}^n \alpha_i S_i \quad (14)$$

经过注意力机制,本文的模型可以利用用户兴趣与当前查询意图的相似度,对与当前查询主题更相关的用户个性化偏好赋予更高的权重,同时降低不相关偏好对当前个性化排序的负面影响,使个性化搜索算法的稳定性进一步提高.例如引言部分所举的例子,当计算机工作者临时查询旅游相关的信息时,经过注意力机制,与“计算机”相关的用户兴趣权重会很小,而是会更关注用户历史中与“旅游”相关的内容,从而解决查询需求随机性问题.

值得注意的是,注意力机制的使用,使模型的自适应性进一步增强,依据不同的当前查询,用户兴趣特征向量可以动态地向着当前查询主题的方向进行调整,从而保证用户兴趣特征向量的有效性.用户的兴趣特征向量 \mathbf{X}_u 将作为下一阶段的输入,与备选文档集中的文档进行相似度计算.

3.3 个性化排序结果生成

最终文档得分包括两个方面:个性化得分与相关度得分,前者指备选文档与兴趣特征向量的相似度,而后者表示文档与查询之间的相关程度.

个性化得分是通过计算文档和利用上述方法生成的用户兴趣特征向量 \mathbf{X}_u 的相似度得到的:

$$PScore(\mathbf{d}_i | \mathbf{X}_u) = Sim(\mathbf{X}_u \mathbf{W}, \mathbf{d}_i) \quad (15)$$

\mathbf{W} 是用来将兴趣特征向量 \mathbf{X}_u 映射到与文档 \mathbf{d}_i 相同维度空间中的矩阵,其参数在模型训练过程中会逐渐优化. Sim 是相似度计算函数.本模型中采用余弦相似度来刻画二者之间的关系.

$$Sim(X, Y) = \frac{X \cdot Y}{\|X\| \cdot \|Y\|} \quad (16)$$

相关度得分主要用原始排序中文档与查询之间的点击特征来描述,包括三部分:点击位置、点击次数和点击熵.点击位置特征是被点击文档在原始排序中的位置,即对于某个查询,被点击文档的排名越靠前,则二者相关度越高.点击次数特征包括备选文档历史点击的总次数,以及当前用户对备选文档的点击次数.点击熵则是用来衡量个性化潜在收益大小的指标,众所周知,有些查询在不同用户之间差异很小,此时个性化会没有作用甚至会产生副作用,因此引入点击熵来确定个性化得分与相关度得分之间的比例关系.计算方法同式(7)、(8).

最终将上述三种点击特征 f_1, f_2, f_3 通过多层感知机 $\varnothing(\cdot)$,使用 $\tanh(\cdot)$ 作为激活函数,得到文档与查询之间的相关度得分,再与文档与兴趣特征向量的相关度得分相加,得到最终文档得分.据此得分排序后的文档列表即为个性化排序结果.

$$\begin{aligned} Score(\mathbf{d}_i) &= PScore(\mathbf{d}_i | \mathbf{X}_u) + RScore(\mathbf{d}_i | q) \\ &= Sim(\mathbf{X}_u \mathbf{M}, \mathbf{d}_i) + \tanh(\varnothing(f_1, f_2, f_3)) \quad (17) \end{aligned}$$

本文采用 LambdaRank 排序算法训练模型.在 pairwise 的基础上,根据交换文档对顺序后对结果 MAP(4.1 节定义的一项评价指标)的影响,为每个文档对增加相应的权重^[41],例如:某文档对 (a_1, a_2) 在交换位置后,排序的 MAP 变化值为 a ,而另一文档 (b_1, b_2) 对交换位置后 MAP 变化值为 b ,如果 $a > b$,则说明 a_1 与 a_2 之间的差异大于 b_1 与 b_2 之间的差

异,根据这个特点,对差异较大的文档对赋予较大的权重,反之赋予较小的权重,可以使最终排序结果的平均准确度更高.本文选取相关文档集中的文档 \mathbf{d}_i 和不相关文档集中的文档 \mathbf{d}_j 作为文档对来训练模型,损失函数为预测值与实际值之间的交叉熵,其目标则是最大化二者得分的差距,定义如下:

$$Loss(RankNet) = -\overline{p_{ij}} \log(p_{ij}) - \overline{p_{ji}} \log(p_{ji}) \quad (18)$$

$$Loss(LambdaRank) = \Delta Loss(RankNet) \quad (19)$$

其中 p_{ij} 表示文档 \mathbf{d}_i 比 \mathbf{d}_j 更相关的预测概率, $\overline{p_{ij}}$ 表示实际概率.是通过 logistic 函数计算而得:

$$p_{ij} = \frac{1}{1 + \exp(-(\text{Score}(\mathbf{d}_i) - \text{Score}(\mathbf{d}_j)))} \quad (20)$$

最后再通过 AdamOptimizer 优化器逐步优化模型,每一次优化的过程如算法 1 所示.最终对计算出的文档分数排序后即个性化排序结果.

算法 1. GRADP 模型训练方法.

输入:用户历史查询 $Q = (q_1, q_2, \dots, q_n)$;

用户历史文档 $D = (d_1, d_2, \dots, d_n)$;

用户查询特征 $E = (e_1, e_2, \dots, e_n)$;

当前查询 q ; 文档对 $(\mathbf{d}_i, \mathbf{d}_j)$;

文档 $\mathbf{d}_{i/j}$ 的点击特征 f_1, f_2, f_3 ;

输出:更新后的所有参数 θ

1. 用户兴趣 $H_1 \leftarrow GRU(Q, D)$ 式(2)

2. 用户状态 $H_2 \leftarrow GRU(Q, E)$ GRU 同上

3. 个性化偏好 $S \leftarrow Gate(H_1, H_2)$ 式(10)、(11)

4. 兴趣特征向量 $\mathbf{X}_u \leftarrow Attention(S, q)$ 式(14)

5. $\mathbf{d}_{i/j}$ 个性化得分 $\leftarrow Sim(\mathbf{X}_u, \mathbf{d}_{i/j})$ 式(15)

6. $\mathbf{d}_{i/j}$ 相关度得分 $\leftarrow \tanh(\varnothing(f_1, f_2, f_3))$

7. $\mathbf{d}_{i/j}$ 最终得分 \leftarrow 个性化 + 相关度 式(17)

8. 损失函数 $loss \leftarrow$ 交叉熵 式(19)

9. 更新参数 $\theta \leftarrow$ AdamOptimizer 优化

算法 1 中,最耗时的部分集中在对用户历史行为建模的 GRU 层参数训练,即通过步骤 1~3 得到用户个性化偏好的过程,其次是注意力层(步骤 4)和计算相关度得分时(步骤 6)MLP 的参数训练.假设共有 n 组训练数据,其中每组用户历史数据平均长度为 m ,则步骤 1~4 的时间复杂度为 $O(mn)$,步骤 5~9 的时间复杂度为 $O(n)$,最终模型时间复杂度为 $O(mn)$.

4 实验与分析

4.1 实验设置

本文使用某搜索引擎的数据,包括从 2013 年 1 月 1 日至 2013 年 2 月 28 日的用户点击数据,用户

日志中的每一条数据包括用户 id, 查询内容, 查询时间, 搜索引擎返回的前二十个文档的 url, 以及点击的驻留时间. 在筛选掉不可用信息之后, 例如 url 无法访问. 最终数据包含 23528 个用户的 2635836 条查询, 其中不同的查询有 1612983 条, 相关文档的数量有 1202065 个. 在本文中, 相关文档被定义为用户驻留时间大于 30s 的文档以及用户最后点击的文档, 除此之外的文档被认为是不相关文档. 本文使用用户前六个星期的日志作为历史数据, 这部分数据仅作为历史参与建立用户模型, 而不作为训练集. 然后将后两个星期的数据按照 5:1 的比例划分为训练集和测试集, 两个星期的数据可以涵盖不同种类的查询并且训练量也可接受. 值得注意的是测试集中的点击特征是通过统计历史数据中用户的点击行为而得到的, 但计算用户兴趣时使用的不仅仅是历史数据中的查询, 而是当前查询之前的所有查询. 由于深度学习的方法要求数据量足够大, 且 RNN 要求时序信息要明显, 为了保证用户全部数据中既包含用来建立用户模型的历史数据, 也包含足够的训练和测试数据(两星期), 因此假如某用户的查询点击事件的时间跨度不足三个星期或后两个星期没有查询行为, 那么将该用户剔除, 最终剩余 7362 个用户. 对于所有的文档, 提取出其内容, 并将停用词、标点符号、特殊字符去掉之后, 使用谷歌的 word2vec 工具在训练集上训练单词嵌入矩阵, 每一个查询 q 和文档 d 的向量表示通过加权平均每个单词的词向量而得, 在这里使用 TF-IDF 为每个单词赋予权重, 以保证模型能够准确地通过该文档提取出用户兴趣. 在 word2vec 单词嵌入维度方面, 本文尝试了 300 维与 1000 维, 最终根据实验效果选取 300 维作为词向量维度.

为了检验模型的效果, 对于重新排序后的文档列表, 本实验采用 Mean Average Precision (MAP), Mean Reciprocal Rank (MRR), Precision@1 ($P@1$), Average Click Position (A.Click) 对结果进行评价, 为了更深入的评价模型, 本文对文档偏序对的改进数量进行了统计, 这项指标主要考虑到用户从前向后的浏览习惯, 由此推断, 在相关文档之前的未点击文档很大程度上是与用户查找内容不相关的, 而在其之后的未点击文档可能由于用户已经得到了满意的结果而停止浏览, 因此难以界定是否一定不相关. 因此, 偏序对的改进数量反映个性化搜索中可靠的改进, 最终用改进数量与全部偏序对的比值 $P\text{-imp}$ 作为评价指标. 例如: 原始文档列表为 (d_1, d_2, d_3, d_4) , 其

中只有 d_3 为相关文档, 则偏序对共有 $(d_1, d_3)(d_2, d_3)$ 两对, 即 d_3 一定比 d_1 和 d_2 更相关, 改进数量则是统计对原始列表重排后, 所有偏序对被改进的数量, 假设重排后序列为 (d_1, d_2, d_3, d_4) , 虽然 MAP 值没有变化, 但 (d_1, d_3) 偏序对被改进, $P\text{-imp} = 0.5$, 也可以说明模型是有效果的.

4.2 对比模型

我们将本文提出的动态个性化搜索模型标记为 GRADP (GRU-based RNN + Attention Dynamic Personalization). 同时选取了目前比较流行的几种个性化搜索模型作为对比:

PTM. PTM 是 Harvey 等人^[21] 提出的个性化搜索模型, 在 2010 年 Carman 等人^[20] 指出, 从人工标注的数据中提取文档特征的方法存在问题, 主要是由于使用这种方法会造成标注种类有限, 有些文档的特征难以被提取. 因此, 他建议采用无监督学习的方法, 全面学习文档的主题特征, 这其中包括更丰富的潜在特征. 2014 年, Vu^[7] 在此基础上, 进一步运用动态分组的方式, 取得了很好的效果.

PTM 根据给予查询和用户计算出的文档的个性化分数为

$$S(d|q, u) = P(d) \prod_{w \in q} \sum_z p(w|z) p(u|z)^\lambda p(z|d) \quad (21)$$

$$P(d) = \frac{\#click(d) + \sigma \frac{1}{|D|}}{\sum_{d_i} \#click(d_i) + \sigma} \quad (22)$$

其中 λ 用来平衡用户兴趣的权重, 进而影响最终文档排序. $P(d)$ 表示整个查询日志中对该文档点击的相对频率, 通过 Dirichlet 平滑得到最终得分.

P-click. Teevan^[11] 在论文中指出, 用户经常会用相同的查询来查找之前搜寻过的信息, 利用这个特点可以有效地改善检索效果, 即将用户多次点击过的文档优先返回给用户. 在 2007 年, Dou 等人^[3] 根据这个特点, 从个性化搜索的目标出发, 提出了 P-click 模型. 该模型的主要思想是, 对于用户 u , 在过去与当前查询相同的查询中, 将对某文档点击的概率作为当前查询下该文档的得分:

$$Score(d|q, u) = \frac{|clicks(q, d, u)|}{|clicks(q, \cdot, u)| + \beta} \quad (23)$$

其中, $|clicks(q, d, u)|$ 表示对于用户 u , 在查询 q 中, 点击文档 d 的次数, $|clicks(q, \cdot, u)|$ 表示用户 u 在查询 q 中全部点击次数, β 用来平滑比值, 通常设置为 0.5. 最终二者比值即为点击概率. 在 P-click 模型中, 点击次数越多的文档的得分越高, 在最终排

序结果中也越靠前。

SLTB. Bennett^[1] 在 2012 年提出了 SLTB 模型, 通过用户的长短期历史行为, 提取出基于不同时期的特征, 进而完成个性化搜索。其核心思想是通过四个方面的影响生成用户个性化特征。

(1) 特征种类。包括基于主题的特征和基于点击的特征。

(2) 文档涵盖范围。其中包括①所有查询下的文档; ②与当前查询相同的查询下的文档; ③包含当前查询的查询下的文档; ④被当前查询包含的查询下的文档。

(3) 所属时期影响。主要分为三种, 长期影响、短期影响、二者交互影响。

(4) 时间衰减影响。衰减函数为

$$decay = 0.95^{p(q_r)-1} \quad (24)$$

$p(q_r)$ 指的是 q_r 与当前查询之间的查询数量。0.95 为衰减率。

SLTB 同时考虑了点击熵、主题熵等众多特征因素的影响, 通过 LambdaMART 算法训练模型。

除了现有的个性化搜索模型, 本文同时设计了多种深度学习模型作为对比:

Interest. 在 GRADP 的结构中, 用户历史行为建模部分只保留用户兴趣建模, 并且不使用注意力机制, 直接将递归神经网络最后状态节点的输出作为兴趣特征向量。

Interest+Att. 在 GRADP 的结构中, 用户历史行为建模部分只保留用户兴趣建模, 而后通过注意力机制生成兴趣特征向量。

BRADP. 将 GRADP 中全部的 GRU 结点替换为普通的 Basic RNN 结点。

LRADP. 将 GRADP 中全部的 GRU 结点替换为 LSTM 结点。

参数设置方面, 通过多组参数的对比, 最终选取以下参数加入到模型中。

- (1) 单词嵌入维度: 300;
- (2) GRU 层状态结点数: 900;
- (3) 注意力层多层感知机隐层神经元: 1024;
- (4) 其他多层感知机隐层神经元: 64;
- (5) 学习速率: $1e^{-3}$;
- (6) nCS 与 nRS 指标中 n 设置: 2, 3。

4.3 实验结果分析

本节中, 我们对 4.2 节中的对比模型进行了实验, 并且在 MAP , MRR , $P@1$, $Avg.Click$ 以及 $P-imp$ 五个指数上进行了评估。结果如表 1 所示, 并在以下

几个方面进行了模型对比:

- (1) 深度学习模型与传统个性化搜索模型对比;
- (2) 本文模型间对比;
- (3) 注意力机制的效果;
- (4) 长短期用户历史建模效果对比;
- (5) 神经网络与非神经网络模型对比;
- (6) 有无点击特征的对比;
- (7) 导航式与非导航式查询对比。

表 1 不同模型排序效果

模型	MAP	MRR	P@1	A.Click	P-imp
原始排序	0.7226	0.7334	0.5931	2.292	
P-Click	0.7348	0.7467	0.6015	2.138	0.1419
PTM	0.6679	0.6801	0.5244	2.578	0.2845
SLTB	0.7776	0.7881	0.6698	2.054	0.4777
SLTB+PTM	0.7830	0.7929	0.6716	1.998	0.4878
Interest	0.7958	0.8073	0.6964	1.929	0.5140
Interest+Att	0.7970	0.8083	0.6963	1.927	0.5296
BRADP	0.7971	0.8085	0.6967	1.927	0.5302
LRADP	0.7984	0.8119	0.6979	1.924	0.5341
GRADP	0.7985	0.8119	0.6978	1.925	0.5337

4.3.1 深度学习模型与传统个性化搜索模型对比

将表 1 中数据以原始排序为基准, 得到不同模型的 MAP 变化值如图 2 所示。

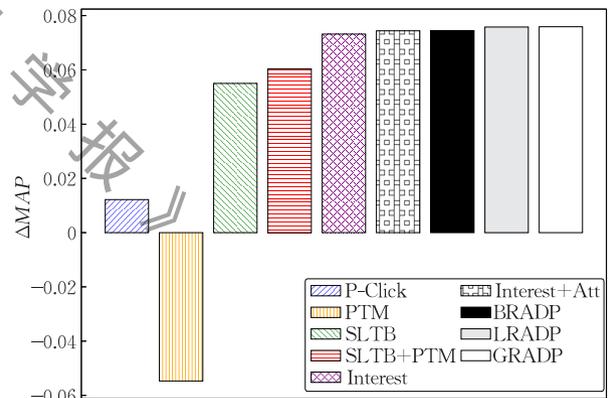


图 2 本文模型与传统模型 MAP 变化对比

根据图 2 中数据可知, 除了 PTM 方法外, 其他的传统个性化搜索算法都对原始排序进行了改进, 本文认为, 这是由于 PTM 只考虑了文档主题之间的相关性, 没有考虑点击熵, 错误地在点击熵很小的查询中(即所有用户趋于点击同样的结果, 可个性化程度很低)进行个性化排序, 造成结果的下降。其中, 效果最好的算法是 SLTB+PTM 方法, MAP 达到了 0.7830。然而, 在深度学习模型中, 重新排序的效果明显优于传统方法, GRADP 模型比传统模型中效果最好的 SLTB+PTM 的 MAP 高出 0.0155, MRR 与 $P@1$ 也分别高出 0.019 和 0.0262, $Avg.Click$ 平均提前了 0.073 的位置。 $P-imp$ 指标的提升也说

明本文的模型改进了更多的偏序对,对原始排序的优化更为可靠.通过双总体 t 检验,在 $p < 0.01$ 的标准上证明本文模型相比于传统的个性化搜索模型效果提升显著,这说明不同时间的历史查询重要程度不同,以及不同的兴趣特征对当前的影响力不同是合理的,在改进个性化搜索方面成效非常显著,并且运用深度学习的方法可以准确地学习出用户的兴趣特征及其权重.

4.3.2 本文模型间对比

通过对比 Interest、Interest + Att、GRADP 模型的实验结果可以看出,增加注意力机制与用户状态建模均带来了效果提升,说明根据用户状态控制对用户兴趣的重视程度,以及利用当前查询动态地为不同时期的兴趣赋权,均可以提升用户模型的准确性,从而对个性化排序产生积极作用.

通过对比 BRADP、LRADP、GRADP 模型的实验结果可以看出,使用普通 RNN 的模型效果最差,说明短期记忆不足以满足对用户个性化偏好建模的需要,远期的用户行为也会对个性化产生一定影响,不可完全忽略.而 LSTM 与 GRU 效果相近,因此,本文模型中的 GRU 结点可替换为 LSTM 结点,但由于 LSTM 参数较多,因此训练时间会略长.

4.3.3 注意力机制的效果

表 1 中数据体现出,递归神经网络加上注意力机制后,可以使结果得到进一步提升.本文认为,与当前查询无关的历史信息则很大概率与用户当前意图无关,注意力机制可以将这部分无关信息剔除,使最终查询结果更符合用户真实意图.为了更直观地展示注意力机制的作用,本文选取了某用户过去 8 个时期的兴趣特征,并提供 4 个当前查询作为测试,经过注意力层的权重赋值后,结果如图 3 所示.

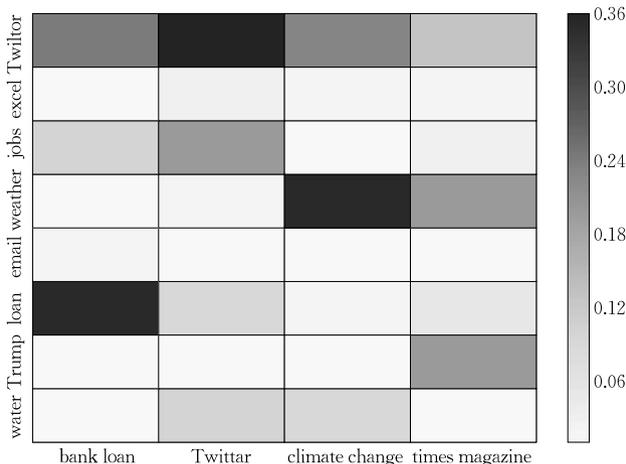


图 3 Attention 中不同的个性化偏好对当前查询影响

根据图 3 可知,注意力机制将与当前查询更相关的用户兴趣特征赋予了更高的权重,并且能够将不相关的信息过滤掉.例如:图 3 中当前查询词为“bank loan”时,“loan”被赋予了很高的权重,而“email”、“Trump”则基本被忽略.而兴趣特征“Twitter”在各个查询上权重都比较高,本文认为,这是由于此单词在过去查询频率过高,多个时期都包含该兴趣特征,综合成为权重较高的部分.

4.3.4 长短期用户历史建模效果对比

本实验中的数据是基于两个月的用户查询日志,为了探究本文的模型在长期和短期用户历史上的差别,我们分别选取了用户最近一个会话内以及该会话之前的查询日志作为用户历史,而后用 GRADP 建模,最终结果的 MAP 对比如图 4 所示(以 SLTB+PTM 为基准).

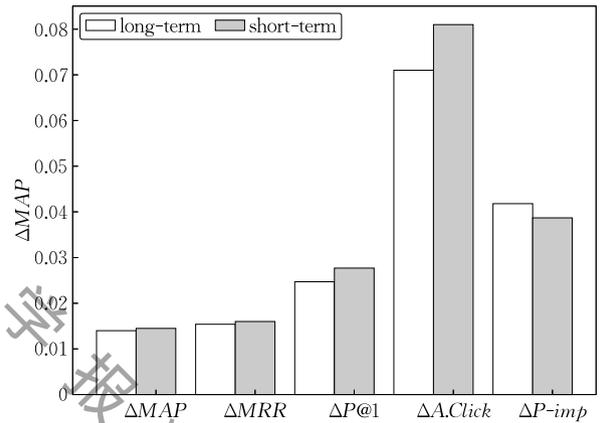


图 4 长短期用户历史建模效果对比

根据图 4 可知,使用短期用户历史建模的整体效果要略优于使用长期数据,这也印证了本文的核心思想——近期的查询行为对当前查询的个性化结果返回贡献更大.用户的兴趣往往具有阶段性的特点,在一个时期集中对某事物感兴趣.而利用长期历史建模会更多的考虑到用户长久的兴趣特征,可能会与用户近期兴趣点不相符.因此使用近期的用户查询日志能更准确地把握用户的真实意图,并将最适合的文档优先推荐给用户.

4.3.5 神经网络与非神经网络模型对比

为了直接验证本文基本模型的有效性,我们设置了非神经网络模型作为对比,其主要方式是除去递归神经网络层和注意力层,将用户历史平均赋权后与当前查询下的文档进行相似度计算,结合部分点击特征后,计算出每个文档的得分.实验结果如下:

非神经网络模型 MAP 值:0.6454;

GRADP 模型 MAP 值:0.7985.

实验结果表明,非神经网络的实验结果远差于 GRADP 模型,这验证了深度学习对于个性化的有效性.而且非神经网络模型相比于原始排序,整体效果更差,我们分析,这是由于非神经网络模型忽略时序性特征和当前查询,只考虑了用户历史与文档的相似性,这并不能完全满足用户个性化的需要,用户查询动态性和随机性问题未得到解决.

4.3.6 有无点击特征的对比

在本文的模型中,同时利用了表示学习的特征和人工定义的特征——点击特征,为了证明人工定义特征的必要性,本实验去除该特征作为对比,只利用表示学习生成的用户兴趣向量与当前文档进行相似度计算,以个性化得分作为最终文档得分,即只考虑用户兴趣与文档的相似度,而忽略文档与查询之间的相关度,实验结果如下:

无点击特征模型 MAP 值:0.5454;

有点击特征模型 MAP 值:0.7985.

该结果表明,点击特征中包含的相关度信息不可忽略,利用神经网络的方法通过点击特征可以学习到在该查询下此文档的重要程度以及可个性化程度.除去点击特征后的模型效果差于原始排序模型,说明只利用个性化信息对文档重排不足以得到最优的排序结果,即一味地追求个性化可能会对排序结果产生副作用,例如:某爱好旅游的用户查询“百度一下”,若只考虑用户兴趣则可能优先将百度地图推荐给用户,但实际上该查询点击熵很低,对于绝大多数用户而言,真实意图均为百度搜索.造成错排的原因主要是忽略了点击特征所包含的(1)百度搜索本身要比百度地图与查询词更相关和(2)“百度一下”该查询不适合个性化.

4.3.7 导航式与非导航式查询对比

所谓导航式查询,是指在某个查询下,用户点击行为没有太大差异,例如:“google.com”,用户的真实意图往往都是谷歌搜索.而非导航式查询是指用户之间点击行为差异较大的查询,例如歧义词查询.点击熵则是用来评价查询词歧义性的指标,为了衡量本文的模型在改善歧义性问题中的效果,我们将数据集分为导航式查询(点击熵 <1)和非导航式查询(点击熵 ≥ 1)分别测试模型效果,如图5所示.

实验结果表明,个性化搜索在两类数据集中都有一定作用,而在非导航式查询下提升尤为明显,这说明个性化搜索可以有效解决查询歧义性问题. GRADP 模型相比于 SLTB+PTM,在导航式查询中 MAP 提升 0.013,而在非导航式查询中 MAP 提

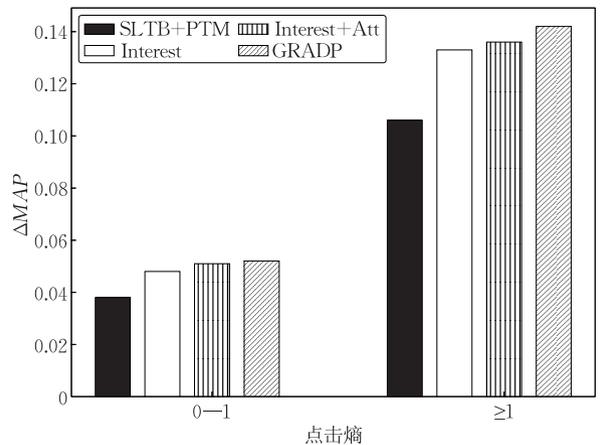


图5 导航式与非导航式查询对比

升 0.029,这也说明本文的模型在查询歧义性问题中表现更好.相比于 Interest+Att,GRADP 模型主要提升表现在非导航查询中,这体现出通过用户状态建模,可以更加关注用户非导航时查询中的个性化偏好,证明了模型对于个性化搜索结果的有效性.

5 结论

本文运用深度学习的方法实现了动态个性化搜索.特别在用户查询需求动态性和随机性问题上,引入递归神经网络和注意力机制准确地利用用户查询日志构建用户兴趣特征向量.递归神经网络根据不同发生时间对用户的历史行为加以利用;注意力机制针对当前查询对不同兴趣特征进行了赋权,减少了无关信息对结果的影响.与传统的个性化搜索方法相比,本文的模型达到了更好的个性化搜索结果.这也证明了近期用户行为比长期行为对于个性化搜索更为重要,而且与当前查询更相关的用户行为影响力也比无关查询更大.用户查询需求动态性和随机性的问题得到了很好的解决.

在未来的工作中,我们将在单词嵌入方面加以改进,例如,用另一层递归神经网络来训练单词嵌入模型.另外,我们将研究更加完善的注意力机制来进一步改善结果.同时,在用户历史行为建模部分,简单地将查询和文档集合进行拼接作为输入不能准确表达用户兴趣,因此我们希望能利用卷积神经网络提取潜在特征的优势,对此进行改进.

参考文献

[1] Bennett P N, White R W, Chu W, et al. Modeling the impact

- of short-and long-term behavior on search personalization//Proceedings of the 35th International ACM SIGIR Conference on Research and Development in Information Retrieval. Portland, USA, 2012: 185-194
- [2] Cai F, Liang S, De Rijke M. Personalized document re-ranking based on Bayesian probabilistic matrix factorization//Proceedings of the 37th International ACM SIGIR Conference on Research and Development in Information Retrieval. Gold Coast, Australia, 2014: 835-838
- [3] Dou Z, Song R, Wen J. A large-scale evaluation and analysis of personalized search strategies//Proceedings of the 16th International Conference on World Wide Web. Banff, Canada, 2007: 581-590
- [4] Wen J, Dou Z, Song R. Personalized Web Search, in Encyclopedia of Database Systems. Springer, 2009: 2099-2103
- [5] Harvey M, Crestani F, Carman M J. Building user profiles from topic models for personalised search//Proceedings of the 22nd ACM International Conference on Information and Knowledge Management. San Francisco, USA, 2013: 2309-2314
- [6] Sontag D, Collins-Thompson K, Bennett P N, et al. Probabilistic models for personalizing Web search//Proceedings of the 5th ACM International Conference on Web Search and Data Mining. Seattle, USA, 2012: 433-442
- [7] Vu T T, Song D, Willis A, et al. Improving search personalisation with dynamic group formation//Proceedings of the 37th International ACM SIGIR Conference on Research and Development in Information Retrieval. Gold Coast, Australia, 2014: 951-954
- [8] Shen X, Tan B, Zhai C. Context-sensitive information retrieval using implicit feedback//Proceedings of the 28th International ACM SIGIR Conference on Research and Development in Information Retrieval. Salvador, Brazil, 2005: 43-50
- [9] White R W, Bennett P N, Dumais S T. Predicting short-term interests using activity-based search context//Proceedings of the 19th ACM International Conference on Information and Knowledge Management. Toronto, Canada, 2010: 1009-1018
- [10] Vu T, Willis A, Tran S N, et al. Temporal latent topic user profiles for search personalization//Proceedings of the 37th European Conference on Information Retrieval. Vienna, Austria, 2015: 605-616
- [11] Teevan J. How people recall, recognize and reuse search results. ACM Transactions on Information Systems, 2008, 26(4): 19-27
- [12] Adar E, Teevan J, Dumais S T. Resonance on the Web: Web dynamics and revisitation patterns//Proceedings of the 27th ACM International Conference on Human Factors in Computing Systems. Boston, USA, 2009: 1381-1390
- [13] Teevan J. Supporting Finding and Re-finding Through Personalization [Ph. D. dissertation]. Massachusetts Institute of Technology, USA, 2007
- [14] Teevan J, Dumais S T, Liebling D J. To personalize or not to personalize: Modeling queries with variation in user intent //Proceedings of the 31st International ACM SIGIR Conference on Research and Development in Information Retrieval. Singapore, 2008: 163-170
- [15] Shen D, Pan R, Sun J, et al. Q²C@UST: Our winning solution to query classification in KDDCUP 2005. ACM SIGKDD Explorations Newsletter, 2005, 7(2): 100-110
- [16] Sugiyama K, Hatano K, Yoshikawa M. Adaptive Web search based on user profile constructed without any effort from users//Proceedings of the 13th International Conference on World Wide Web. New York, USA, 2004: 675-684
- [17] Pretschner A, Gauch S. Ontology based personalized search//Proceedings of the 11th International Conference on Tools with Artificial Intelligence. Chicago, USA, 1999: 391-398
- [18] Gauch S, Chaffee J, Pretschner A. Ontology-based personalized search and browsing. Web Intelligence and Agent Systems: An International Journal, 2003, 1(3-4): 219-234
- [19] Chirita P A, Firan C S, Nejd W. Summarizing local context to personalize global Web search//Proceedings of the 15th ACM International Conference on Information and Knowledge Management. Arlington, USA, 2006: 287-296
- [20] Carman M J, Crestani F, Harvey M, et al. Towards query log based personalization using topic models//Proceedings of the 19th ACM International Conference on Information and Knowledge Management. Toronto, Canada, 2010: 1849-1852
- [21] Zeng Chun, Xing Chun-Xiao, Zhou Li-Zhu. A personalized search algorithm by using content-based filtering. Journal of Software, 2003, 14(5): 999-1004(in Chinese)
(曾春, 邢春晓, 周立柱. 基于内容过滤的个性化搜索算法. 软件学报, 2003, 14(5): 999-1004)
- [22] Wang H, He X, Chang M W, et al. Personalized ranking model adaptation for Web search//Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval. Dublin, Ireland, 2013: 323-332
- [23] Li X, Guo C, Chu W, et al. Deep learning powered in-session contextual ranking using clickthrough data//Proceedings of the 28th Neural Information Processing Systems. Montréal, Canada, 2014
- [24] Bennett P N, Radlinski F, White R W, et al. Inferring and using location metadata to personalize Web search//Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. Beijing, China, 2011: 135-144
- [25] Collins-Thompson K, Bennett P N, White R W, et al. Personalizing Web search results by reading level//Proceedings

- of the 20th ACM International Conference on Information and Knowledge Management. Glasgow, UK, 2011; 403-412
- [26] Grbovic M, Cheng H. Real-time personalization using embeddings for search ranking at airbnb//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. London, UK, 2018; 311-320
- [27] Huang J, Zhao W, et al. Improving sequential recommendation with knowledge-enhanced memory networks//Proceedings of the 41st International ACM SIGIR Conference on Research and Development in Information Retrieval. Ann Arbor, USA, 2018; 505-514
- [28] He X, He Z, Du X, et al. Adversarial personalized ranking for recommendation//Proceedings of the 41st International ACM SIGIR Conference on Research and Development in Information Retrieval. Ann Arbor, USA, 2018; 355-364
- [29] Huang P, He X, Gao J, et al. Learning deep structured semantic models for Web search using clickthrough data//Proceedings of the 22nd ACM International Conference on Information and Knowledge Management. San Francisco, USA, 2013; 2333-2338
- [30] Shen Y, He X, Gao J, et al. A latent semantic model with convolutional-pooling structure for information retrieval//Proceedings of the 23rd ACM International Conference on Information and Knowledge Management. Shanghai, China, 2014; 101-110
- [31] Severyn A, Moschitti A. Learning to rank short text pairs with convolutional deep neural networks//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. Santiago, Chile, 2015; 373-382
- [32] Palangi H, Deng L, Shen Y, et al. Deep sentence embedding using long short-term memory networks: Analysis and application to information retrieval. *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 2016, 24(4): 694-707
- [33] Guo J, Fan Y, Ai Q, et al. A deep relevance matching model for ad-hoc retrieval//Proceedings of the 25th ACM International Conference on Information and Knowledge Management. Indianapolis, USA, 2016; 55-64
- [34] Xiong C, Dai Z, Callan J, et al. End-to-end neural ad-hoc ranking with kernel pooling//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Shinjuku, Japan, 2017; 55-64
- [35] Song Y, Wang H, He X. Adapting deep ranknet for personalized search//Proceedings of the 7th ACM International Conference on Web Search and Data Mining. New York, USA, 2014; 83-92
- [36] Yuan X, Dou Z, Zhang L, et al. Automatic user goals identification based on anchor text and click-through data. *Wuhan University Journal of Natural Sciences*, 2008, 13(4): 495-500
- [37] Liu Y, Zhang M, Ru L, et al. Automatic query type identification based on click through information. *Asia Information Retrieval Symposium*, 2006, 4182; 593-600
- [38] Mnih V, Heess N, Graves A. Recurrent models of visual attention; *Advances in neural information processing systems* //Proceedings of the 28th Neural Information Processing Systems. Montréal, Canada, 2014; 2204-2212
- [39] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*, 2014
- [40] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach, USA, 2017; 5998-6008
- [41] Burges C, Shaked T, Renshaw E, et al. Learning to rank using gradient descent//Proceedings of the 22nd International Conference on Machine Learning. Bonn, Germany, 2005; 89-96



ZHOU Yu-Jia, Ph. D. candidate. His research interests include natural language processing and data mining.

DOU Zhi-Cheng, Ph. D. , professor. His research interests include information retrieval, data mining, and big data analytics.

GE Song-Wei, M. S. candidate. His research interests include information retrieval and data mining.

WEN Ji-Rong, Ph. D. , professor. His research interests include information retrieval, database, data mining and big data analytics.

Background

The problem discussed in this paper is related to the field of information retrieval, which is the main method for users to obtain information. And personalized search has been increasingly popular due to technological development.

Personalized information retrieval aims to search results according to the user's interests and characteristics and return the document lists related to the user's needs. It has been proven to be able to improve the search quality of search

engines.

Most existing personalized search algorithms re-rank the original results by computing the similarity between documents and user interests. To build a proper user profile, lots of researchers made use of the topic features of user historical behavior to model user topical interests, or counted the clicks of documents in history; In a word, The more detailed the user profile is, the better effect of the personalized model has. However, most of the existing research work ignore the dynamicity and randomness of user interests.

In order to solve this problem, we leverage the recurrent neural network and attention mechanism to build user profile, with the aim of learning the evolution of user interest over time and dynamically assign different weights to different user preference based on the current query. Experiments show

that our personalized search model with deep learning outperforms existing personalized methods.

The authors of the paper have done lots of research on information retrieval and natural language processing, like “A Large-Scale Evaluation and Analysis of Personalized Search Strategies” in WWW’2007 (please refer to [3]) which proposed a novel framework called P-click, and “Personalized Web Search, in Encyclopedia of Database Systems” (please refer to [4]).

This work was supported by the National Key R&D Program of China No. 2018YFC0830703, the National Natural Science Foundation of China No. 61872370, and the Fundamental Research Funds for the Central Universities, and the Research Funds of Renmin University of China No. 2112018391.

《计算机学报》