

## 一种消除位置偏差的搜索自动补全深度学习排序算法

周明星, 闫湘洲, 于敬, 高昌举, 陈运文, 纪达麒, 金克

### 引用本文

周明星, 闫湘洲, 于敬, 高昌举, 陈运文, 纪达麒, 金克. 一种消除位置偏差的搜索自动补全深度学习排序算法[J]. 计算机科学, 2023, 50(11A): 220800179-5.

ZHOU Mingxing, YAN Xiangzhou, YU Jing, GAO Changju, CHEN Yunwen, JI Daqi, JIN Ke. [Unbiased Deep Learning to Rank Algorithm for Suggestion Auto-completion](#) [J]. Computer Science, 2023, 50(11A): 220800179-5.

---

### 相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

#### [基于语义注意力的医学图像超分辨率方法](#)

Medical Image Super-resolution Method Based on Semantic Attention

计算机科学, 2023, 50(11A): 221200107-6. <https://doi.org/10.11896/jsjcx.221200107>

#### [一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

#### [接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

#### [基于LSTM神经网络的QPSK智能接收机设计](#)

Design of QPSK Intelligent Receiver Based on LSTM Neural Network

计算机科学, 2023, 50(11A): 230200219-5. <https://doi.org/10.11896/jsjcx.230200219>

# 一种消除位置偏差的搜索自动补全深度学习排序算法

周明星 闫湘洲 于敬 高昌举 陈运文 纪达麒 金克

达观数据 上海 200120

**摘要** 搜索提示自动补全是正式提交搜索之前,影响用户输入搜索内容的关键手段之一,是商业搜索引擎不可或缺的核心功能之一。如何提供更好的提示词,是一个排序问题。在机器学习排序领域,收集的训练数据有位置偏差,且会影响训练模型的排序效果,已经是一个较为普遍的认识。针对以上训练数据有偏问题,对位置偏差和相关度使用深度学习分别建模,并结合改进后的上下文语义特征,新设计一种同时学习位置偏差和提示词相关度的深度学习排序算法(An Unbiased Deep Learning To Rank Algorithm for Suggestion Auto-completion,UDLTR-SAc)提升搜索提示自动补全的排序效果。UDLTR-SAc能自动学习训练数据中由于位置引入的偏差,从而学习到更为准确的相关度计算模型,在与没有考虑有偏问题的同类型算法及经典补全排序算法对比上分别获得显著增长;同时,在线上A/B测试上也获得+0.1%( $p < 0.1$ )的GMV增长。

**关键词:** 位置偏差;深度学习;LTR;提示词;自动补全;上下文语义

**中图分类号** TP183

## Unbiased Deep Learning to Rank Algorithm for Suggestion Auto-completion

ZHOU Mingxing, YAN Xiangzhou, YU Jing, GAO Changju, CHEN Yunwen, JI Daqi and JIN Ke

Datagrand Co., Ltd., Shanghai 200120, China

**Abstract** Suggestion auto-completion is one of the key means to influence users' input before searching submission, and it is one of the indispensable core functions of commercial search engines. How to provide better suggestion words is also a ranking problem. In the field of machine learning ranking, it has been a common perception that the collected training data has position bias [1-8] which can affect the ranking effect of a training model. To address the above problem of biased training data, this paper combines improved context-based semantic feature to design an unbiased deep learning to ranking algorithm for suggestion auto-completion(UDLTR-SAc) which learns position bias and suggestion relevance simultaneously. According to offline experiments and online A/B tests, UDLTR-SAc can automatically learn the training data bias introduced by the position to obtain a more accurate model in calculating correlation when compared with the similar algorithm without considering the bias problem or the classical completion ranking algorithm respectively. What's more, it also achieves a 0.1% ( $p < 0.1$ ) increase in GMV on the online A/B tests.

**Keywords** Position bias, Deep learning, Learning to rank(LTR), Suggestion, Auto-completion, Context-based semantic

## 1 引言

搜索提示词自动补全是商业搜索服务系统不可或缺的重要能力之一。良好的搜索提示词补全算法能够基于有限的输入,结合用户的使用习惯,捕捉用户的输入意图,提供符合用户需求的输入提示关键词,协助用户快速高效地完成搜索前的输入过程。准确适当的搜索词,也能够更好地帮助搜索引擎快速、准确召回用户需要的物料信息,从而提升搜索能效。

搜索提示词自动补全的整个工作流程主要分为两步:1)根据用户有限的输入内容,从搜索引擎里面基于前缀匹配的方式,召回可能的提示关键词;2)利用用户使用搜索提示词自动补全,搜集到的行为数据训练模型,对步骤1召回的候选提示关键词进行排序。经过上述两步,可以得到良好排序的提示关键字。然后,可以根据前端展示需要,取对应的TOP N返回前端显示给用户。

根据近些年机器学习排序的研究来看,排序学习使用的从用户使用搜索引擎时收集的行为日志挖掘得到的训练数据都有位置偏差<sup>[1-8]</sup>,也意味着使用该有偏训练数据训练得到的排序模型学习到的不是真实的相关度计算模型,而是夹杂了用户针对位置主观偏差的相关度计算模型。也就是说,如果模型能够注意到训练数据的位置偏差,并自动从有偏的数据中学习到的真实的相关度信息,模型将会得到更好的排序效果。

同时,Yuan等<sup>[9]</sup>认为基于session的上下文语义信息特征,对输入提示具有正向作用。他们使用了简单的10分钟的方式切割得到段落,使用fastText库进行了上下文的编码。该切分段落的方式有可能会切分原不应切分的段落或合并应该切分的段落。为了更好地捕捉上下文语义信息,本文改进使用更为合理的句子分隔方式,并使用Genism库,底层选用CBOW对(输入项)上下文进行语义编码。

基于对以上训练数据有偏问题和语义编码的改进措施,

基金项目:上海市科学技术委员会“科技创新行动计划”青年科技启明星计划资助项目(21QB1400100)

This work was supported by the Shanghai Rising-Star Program(21QB1400100).

通信作者:周明星(zhoumingxing@datagrand.com)

结合搜索提示自动补全排序需求,本文提出一种学习位置偏差的搜索自动补全深度学习排序算法。该算法主要创新点包括:1)做了适当的调整和设计后,首次将无偏深度学习算法应用到搜索提示自动补全领域;2)改进〈输入项〉上下文段落切分方法,从而得到更为合理的上下文语义编码。本文提出的算法(UDLTR-SAc)在与 DeepLTR<sup>[9]</sup>,UDLTR-SAc with Unimproved Contextual semantic Features(UDLTR-SAc UCF,结构与UDLTR-SAc一致,排除位置特征外,其他特征与DeepLTR一致)及经典 MPC<sup>[10]</sup>,MPGC 和 LambdaMART<sup>[11]</sup>(不考虑有偏信息)算法的比较中,均取得显著优势。在线上 A/B 测试中,获得+0.1%( $p < 0.1$ )的 GMV 增长。

## 2 相关工作

搜索排序问题一直是比较火热的研究领域,大量学者投入研究并取得了丰硕的结果。文献[12-13]分别对 PageRank 和网页排序做了深入研究;Lai 等<sup>[14]</sup>从信息论的角度,提出对元数据排序的有效思路;随着深度学习的高速发展,语义信息<sup>[15-16]</sup>能很好地在排序中被使用。现阶段,搜索应用大量使用的机器学习排序(LTR)<sup>[1-8]</sup>,除了在主搜索中受到各界关注,也由于搜索提示补全对搜前影响越来越大,有学者<sup>[17]</sup>将LTR应用到提示补全上来。

Claudio 等在搜索提示词自动补全的综述<sup>[17]</sup>中提出了两种方法:启发式和基于学习的方法。启发式方法是使用一种固定的计算候选提示词相关分的算法,计算后重排提供给前端用户使用。基于学习的方法,是使用机器学习排序算法(LTR)<sup>[18]</sup>,在搜集大量用户使用输入提示的行为日志后,从中提取、筛选形成特征,训练排序模型,再使用训练得到的模型对候选提示词进行排序打分。在这两种方法的比较中,基于学习的方法一般比启发式方法效果要好很多<sup>[19]</sup>。

基于学习的方法使用的特征一般包括:关键词特征、个性化特征、上下文语义特征及相似度特征。关键词特征是指一系列由其自身衍生出来的特征,并且可能随着时间变化,比如搜索关键词的热门情况;也可能不会变化,如关键词长度。个性化特征主要是指与用户关联的一系列特征,比如用户标签、画像等。上下文语义特征认为用户某一时刻搜索的内容具有一定的连贯性,借助上下文语义信息,搜索系统能更好地捕捉用户当前的需求。相似度特征能衡量用户输入关键词与候选提示词之间的语义关联度,排序候选词时,能辅助在语义相似度层面做必要的权衡。

在基于学习的方法中,除了收集并获取特征外,训练数据的标签也是排序模型学习不可或缺的重要信息。基于近些年LTR领域的研究<sup>[1-8]</sup>,一个普遍的认知是:传统方法收集用户日志获取的训练数据中的标签信息,掺杂了用户对位置的偏差信息。针对上述偏差,常使用两种方式消除偏差,以获得更好的排序模型。文献[1-4,20]主要参考观测统计到的偏差,设计线下训练来学习尽可能消除偏差的排序模型;还有一些工作<sup>[5,7-8]</sup>,设计交互式的学习方式,以期获取无偏的训练日志,从而提升排序效果。Joachims 等<sup>[5]</sup>基于统计学方式,计算各位置可能的偏差信息,并将该信息直接告诉模型,以期学到更好的无偏模型。Tang 等<sup>[21]</sup>直接对偏差建模,让模型自己能学到偏差的影响,从而获得无偏模型。

本文在结合改进的上下文语义特征的基础上,采用对

偏差直接建模的方式,经过合理的设计调整,将无偏深度学习排序方法首次应用于搜索提示词排序领域。

## 3 无偏深度学习排序算法(UDLTR-SAc)

### 3.1 训练数据采集

搜索提示词补全排序所使用的训练数据,是从用户日常使用提示词自动补全功能时会话记录的日志中提取得到的。从用户输入第一个关键字开始,系统从后台待提示的数据中召回提示候选结果,将其通过排序算法排序后提供给用户。用户面对结果,有两个选择:通过选择候选的结果,直接确定需要输入的关键词;继续输入,再确定是否要从提示内容中选择需要搜索的关键词。循环上述过程,直到用户确认输入关键词内容。详细的输入过程如图1所示。

query	d	query	da	query	dat
d1	data mining ×	d1	data mining ×	d1	data mining ×
d2	download center ×	d2	data-informed ×	d2	data-informed ×
d3	data-informed ×	d3	dasymeric modelling ×	d3	datagrand ✓
d4	dock receipt ×	d4	datagrand ✓	d4	date of birth ×
d5	document retrieval ×	d5	damage control ×	d5	date night ×
d6	determination of total ×	d6	damage tolerance ×	d6	date moive ×
d7	degradation of p-cresol ×	d7	date of birth ×	d7	data center ×
d8	development validation ×	d8	date night ×	d8	date warehouse ×
d9	dasymeric modelling ×	d9	date moive ×	d9	datasheet view ×
d10	dynamic time warping ×	d10	data center ×	d10	database management ×

图1 提示词服务过程

Fig.1 Process of suggestion

在上述搜索提示词服务的流程中,用户输入〈输入项〉(input query,  $q$ ),系统返回〈提示词列表〉(document list,  $d$ ),最终用户从候选〈提示词列表〉中选择一个提示内容作为〈搜索项〉,或者不选,使用自己输入的内容作为〈搜索项〉(target query,  $q_t$ )。在整个过程中,如果针对特定的〈输入项,提示词列表〉,用户〈搜索项〉是〈提示词列表〉中的某一项,则可以构建一个训练样例,标签用  $l$  表示,则  $t = \langle q, d, l \rangle$ ,其中数据的标签计算如下:

$$l_i = \begin{cases} 1, & \text{for } d_i \in d, \text{ if } d_i = q_t \\ 0, & \text{else} \end{cases} \quad (1)$$

其中, $l_i$ 为0的为非相关提示词, $l_i$ 为1的为相关提示词;整个训练集  $T = [t_1, t_2, t_3, \dots, t_n]$ ,其中  $n$  为自然整数。将数据集展开为标准排序问题数据集  $S = [s_1, s_2, s_3, \dots, s_m]$ ,其中  $m$  为自然整数。

### 3.2 无偏算法建模

机器学习排序算法不断地挖掘训练数据的信息,从而提升训练模型的排序效果。从 Point Wise 到考虑样本中两两排序信息的 Pair Wise 方法,再到考虑整个列表信息的 List Wise 方法,排序算法的效果不断在提升。在基于文献[1-8]研究后,训练数据有偏,已经成为一个普遍的认知。也因此,新一轮的LTR算法研究从单一的建模相关度转至同时建模相关度和训练数据偏差。

对相关度建模:

$$y = f(q, d) \quad (2)$$

其中, $f$ 是衡量输入的〈输入项〉 $q$ 与〈提示词列表〉中 $d$ 的相关度的计算函数。

针对有偏的训练数据,普遍认为训练数据中,从用户交互行为收集计算得到的标签由两部分组成,一部分为真实的 $q$ 与 $d$ 相关度,还有一部分为位置引起的偏差,即:

$$y = f(q, d) \cdot \epsilon(p) \quad (3)$$

其中,  $f(q, d)$  为  $q$  与  $d$  的真实相关性计算模型,  $\epsilon(p)$  为位置引起的偏差。

### 3.3 基于上下文的语义特征

因为线上性能的需要, 此处用于编码文本的模型采用了简单的 W2V 算法, 使用了开源库 Genism 来训练, 底层选用 CBOW 方法, 该方法是根据句子上下单词来预测缺失的中心词。训练语料使用基于用户 ID 分类的历史搜索关键字。

在语料构建上, 区别于 Yuan 等<sup>[9]</sup> 使用 10 分钟来划分不间断的搜索关键字, 本文首先根据用户搜索比较长的间隔, 将搜索关键字划分为语料片段。如果划分的语料片段长度适中(适中的句子长度, 采用统计候选搜索内容的平均句子长度的方式获得), 即与正常表述句子长度差不多, 则直接成句; 对于过长的语料片段, 按照段落搜索关键字之间的时间间隔, 从大到小递归分隔, 直至语料片段与正常表述句子长度相近。此种划分方式, 从时间角度考虑了搜索内容成句的合理性。

上下文语义特征计算流程如图 2 所示。

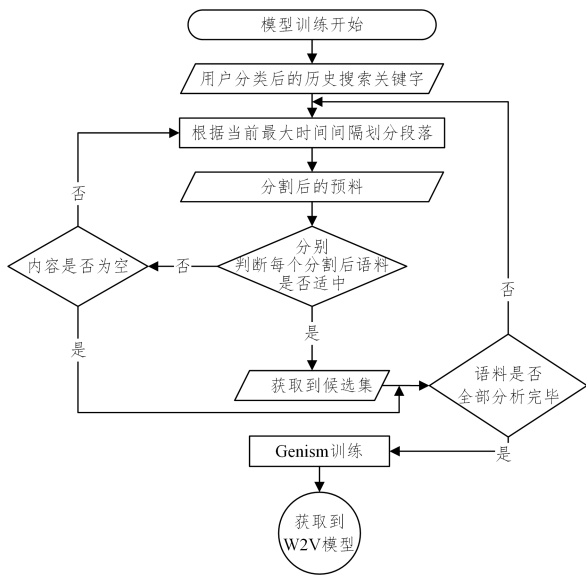


图 2 上下文语义特征计算流程

Fig. 2 Computation flow of contextual semantic features

基于图 2 得到的分句训练语料, 训练得到 W2V 模型, 然后计算当前搜索关键字与用户前 64 个搜索关键字的余弦相似度, 得到一个 64 维的上下文语义特征供后续排序学习

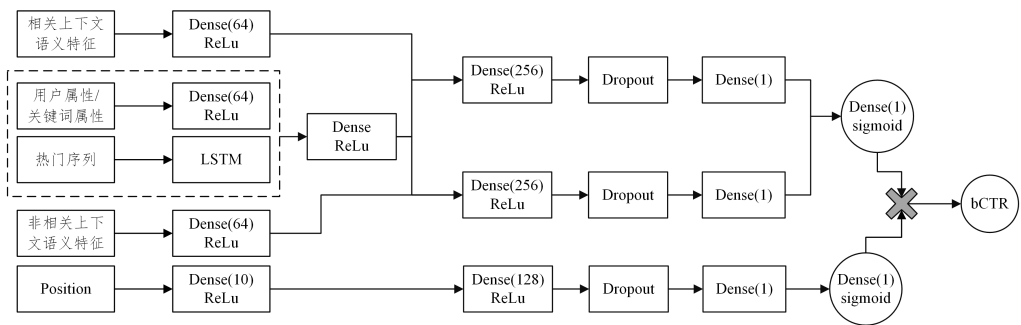


图 3 深度学习网络结构

Fig. 3 Architecture of UDLTR-SAC

## 4 实验

### 4.1 数据集及设置说明

本实验采用的数据是来自于线上系统的实际数据。按照

使用。其中, 相关提示关键词的为相关上下文语义特征, 非相关提示词的为非相关上下文语义特征。

### 3.4 损失函数定义

本文采用经典的排序损失函数: 加上 List 信息的 Pair Wise 损失函数。Pair Wise 损失函数由交叉熵和样本权重构成, 在此基础上加上 nDCG 信息组成最终的排序损失函数。

$$L = -\frac{1}{|S|} \sum_{p,n \in S} [(y \log P_{p,n} + (1-y) \log(1-P_{p,n})) \cdot |\Delta nDCG_{p,n}| \cdot W_{p,n}] \quad (4)$$

其中,  $p, n$  是样本集  $S$  的单个提示词样本,  $|S|$  为整个集合元素个数,  $P_{p,n}$  表示样本  $p$  排序比  $n$  靠前的概率, 定义参见式(5);  $|\Delta nDCG|$  见式(6), 表示交换  $p, n$  样本的排序顺序时, 所引起的 nDCG 变化的绝对值;  $w_{p,n}$  表示样本的权重, 是样本的重要性度量。当搜索优化中有其他指标如 GMV 需要同时优化时, 可将 GMV 作为权重信息加入。

$P_{p,n}$  的计算如下:

$$P_{p,n} = \frac{1}{1 + e^{-(f_p - f_n)}} \quad (5)$$

其中,  $f_p$  和  $f_n$  分别为优化后的模型针对提示词  $p$  和提示词  $n$  的排序得分。

$|\Delta nDCG|$  的计算如式(6)所示:

$$|\Delta nDCG| = \left| \frac{2^{rel_p} - 1}{\log(rank_p - 1)} - \frac{2^{rel_n} - 1}{\log(rank_n - 1)} \right| \quad (6)$$

这个问题中, 选取成对样例  $f_p > f_n$ , 即  $p$  排在  $n$  前面, 并且  $p$  是被点击的提示词, 则  $rel_p = 1$ , 式(6)化简得:

$$|\Delta nDCG| = \left| \frac{1}{\log(rank_p - 1)} - \frac{1}{\log(rank_n - 1)} \right| \quad (7)$$

由于是排序问题, 成对正样本, 交换则为负样本, 所以只需要考虑全部正样本的情况, 因此取  $y = 1$ 。结合式(4)、式(5)与式(7), 化简损失函数得式(8):

$$L = -\frac{1}{|S|} \sum_{p,n \in S} \left[ \log \frac{1}{1 + e^{-(f_p - f_n)}} \cdot \left| \frac{1}{\log(rank_p - 1)} - \frac{1}{\log(rank_n - 1)} \right| \cdot W_{p,n} \right] \quad (8)$$

### 3.5 UDLTR-SAC 模型结构

本文考虑训练数据位置偏差, 结合改进的上下文语义特征, 新提出一种同时学习位置偏差和提示词相关度的深度学习排序算法, 算法的结构如图 3 所示。

3.1 节中制定的采集方式, 共采集 100 多万可用 ( $GMV > 0$ ) 的 <输入项, 提示词列表> 及其对应的 <输入项> 上下文, 从中随机选择 80 多万用作训练数据, 10 万用作训练验证数据, 10 万用作训练完后的测试数据。4.4 节给出的线下实验的结果,

都是多次重复独立训练后的模型,在测试数据上计算对应指标的平均值。

模型训练、测试等计算,都是在一台 64 核 128GB,带 8 块显存为 16GB/块的英伟达显卡的服务器进行的,深度学习模型层数参数如图 3 所示,训练时,Dropout 设置为 0.5。

#### 4.2 实验对照组及线上 A/B 测试

本次设置了 6 组实验来验证本文提出的 UDLTR-SAc 算法的有效性,参与比较的算法有 MPC,MPGC,LambdaMART,DeepLTR,UDLTR-SAc UCF。

(1)MPC:搜索热门提示方式<sup>[10]</sup>,即根据搜索输入内容匹配的候选内容,按照热门情况进行降序排列,取 Top N 作为结果进行提示。这是一个比较常用的搜索输入提示的基础方法,常被拿来作为搜索输入提示的基础参照线。

(2)MPGC:搜索高 GMV 提示方式,即根据搜索输入内容匹配的候选内容,按照历史得到 GMV 的情况进行降序排列,取 Top N 作为结果进行提示。从 GMV 角度考虑的一个常用作基础参照的方法。

(3)LambdaMART:一个非常经典的排序算法<sup>[11]</sup>,在很多基于人工特征的排序场景中,能得到比深度学习更好的结果。在参与本实验的比较时,该算法不考虑训练数据位置偏差问题,并且没有加入上下文语义特征。

(4)DeepLTR<sup>[9]</sup>:Yuan 和 Kuang 基于亚马逊业务提出的自动补全排序算法。加入本算法,是为了对比特征一致的情况下,训练数据偏差问题的影响。

(5)UDLTR-SAcUCF:该算法与本文提出的 UDLTR-SAc 算法具有相同的网络结构,使用的上下文语义特征与 DeepLTR 的计算方式一致。

(6)UDLTR-SAc:本文新提出的算法,考虑了训练数据有偏性问题,并使用改进后的上下文语义特征进行训练。

加入 MPC,MPGC 和 LambdaMART 作为实验对照组,是为了展示本文所使用数据的基线情况;实验对照组 DeepLTR 与 UDLTR-SAc UCF 具有完全一致的特征(包括上下文语义特征)。UDLTR-SAc UCF 的优势在于考虑了训练数据的有偏性。加入该实验对照组是为了验证考虑训练数据有偏性在提示词排序问题上的有效性。

实验对照组 UDLTR-SAc 与 UDLTR-SAc UCF 具有完全一致的算法结构,都考虑了训练数据有偏性。特征方面,UDLTR-SAc 的上下文语义特征的计算方式,按照本文提出的方式进行了改进。加入本实验对照组,是为了验证上下文

语义特征改进的有效性。

线上 A/B 测试是工业排序算法上线之前必备的过程,UDLTR-SAc 的效果经过常规线上 A/B 测试及相应的指标比对进行验证。线上 A/B 步骤如下:

(1)设立线上输入提示服务方案 B;

(2)通过负载,将 1% 的流量分配至 B 服务,以确认服务正常;

(3)将 B 服务流量按 5%,10%,20%,40% 的增长计划,以日为单位提升;

(4)保持服务运行,根据 A,B 服务记录的累计数据,计算对应的 GMV;

(5)比较 A,B 指标效果,在  $p < 0.1$  情况下,判定 A,B 效果显著不同,并根据平均结果判定好坏后,决定是否接受 B 服务切换为正式服务。

#### 4.3 评价指标

针对线下实验,本文主要采用常用的排序指标进行评价,分别为 MRR 和 nDCG。同时,针对线上 A/B 测试,使用 GMV 来进行评价。MRR 的计算方式详细如下:

$$MRR@p = \frac{1}{|S|} \sum_{q_i} \frac{w}{rank(A, q_i)} \quad (9)$$

其中,  $q_i$  表示用户从输入提示中点击的目标(输入项),  $|S|$  是对应计算数据的集合的(输入项,结果列表)个数。  $rank(A, q_i)$  是根据算法 A 排序后,目标(输入项)处于列表中的位置,如果在考察的长度限制  $p$  内没有点击,则  $rank(A, q_i) = \infty$ ,  $w$  是该样本的权重,比如 GMV 值。

nDCG 的计算方式如下:

$$nDCG@p = \frac{\sum_{s \in S} \left( w_s \cdot \left( \sum_{i=1}^p \frac{2^{rel_i} - 1}{i \log(i+1)} \right) \right)}{\sum_{s \in S} w_s} \quad (10)$$

其中,  $i$  是列表长度限制  $p$  之前的某个位置,在本实验数据中,  $rel_i \in \{0, 1\}$ , 被点击项  $rel_i = 1$ , 否则为 0。若长列表长度限制  $p$  内没有点击,所有得分都为零,对 nDCG 值没有贡献。  $w_s$  为样本  $s \in S$  的权重,因为搜索提示词的特殊性,一般情况下,只有一个被交互。理想情况下,如果某个样本的收益就是  $w_s$ , 那么总的理想收益为所有样本权重的和。

#### 4.4 算法结果展示

MPC, MPGC, LambdaMART, DeepLTR, UDLTR-SAc UCF 及 UDLTR-SAc 算法在数据测试集上的 MRR@1, MRR@3, nDCG@1 和 nDCG@3 的平均值如表 1 所列。

表 1 各算法在相同参数设置下重复独立训练 10 次后,在测试集上对应的 MRR 及 nDCG 平均值

Table 1 Corresponding MRR and DGG average values of each algorithm on test set after repeated independent training for 10 times with the same parameter settings

模型	MRR@1	MRR@3	nDCG@1	nDCG@3
MPC	0.281(-19.2%)	0.450(-16.8%)	0.281(-22.6%)	0.445(-18.80%)
MPGC	0.289(-16.9%)	0.468(-13.5%)	0.296(-18.5%)	0.466(-14.96%)
LambdaMART	0.348	0.541	0.363	0.548
DeepLTR <sup>[9]</sup>	0.353(1.44%)	0.552(2.59%)	0.366(0.83%)	0.562(2.55%)
UDLTR-SAc UCF	0.355(2.01%)	0.559(3.33%)	0.369(1.65%)	0.566(3.28)
UDLTR-SAc	0.358(2.87%)	0.564(4.25%)	0.371(2.20%)	0.570(4.01%)

从 UDLTR-SAc UCF 与 DeepLTR 的对比中可以看到,对于同样的特征信息,在考虑了训练数据的有偏问题后,UDLTR-SAc UCF 相较于 DeepLTR,在 MRR 与 nDCG 指标上都有明显的增长,这说明了算法能一定程度学习到训练数

据的有偏信息,得到更为精确的排序模型。

从 UDLTR-SAc 与 UDLTR-SAc UCF 的对比中可以看到,当网络结构一致时,在使用改进后的上下文语义特征的情况下,UDLTR-SAc 相较于 UDLTR-SAc UCF,在 MRR 与

nDCG 指标上也都有一定的增长,这说明改进的上下文语义特征能够更好地帮助模型排序候选的搜索提示词。

更进一步,UDLTR-SAc 与线上使用的 LambdaMART 进行了 A/B 测试。从线上的 A/B 结果可以看出,UDLTR-SAc 获得了 +0.1% ( $p < 0.1$ ) 的 GMV 增长,更进一步验证了 UDLTR-SAc 的有效性。

**结束语** 本文考虑提示词训练语料的有偏问题,并结合搜索输入上下文语义特征,新提出一种无偏深度学习排序算法用于搜索提示词排序问题。设置 UDLTR-SAc UCF 与 DeepLTR 的对照实验,验证学习训练数据有偏问题在提示词排序问题上是有有效的;设置 UDLTR-SAc 与 UDLTR-SAc UCF 的对照组,验证改进的上下文语义特征的有效性。以上两组实验,验证了本文提出的算法 UDLTR-SAc 的有效性。UDLTR-SAc 与线上使用的 LambdaMART 进行 A/B 测试,获得了 +0.1% ( $p < 0.1$ ) 的 GMV 增长,更进一步验证了 UDLTR-SAc 在实际生产上的有效性。

本文所研究内容,在上下文语义特征的精细化设计方面还有一定的挖掘空间。上下文信息考虑的权重,根据多个搜索关键字之间的时间跨度不一样,应该考虑不一样的权重;在训练数据有偏问题的学习方法和考虑因素方面,目前只考虑了位置信息对训练数据的影响,是否有更多影响训练数据的因素,也是值得深入探讨的问题。后续将对这些方面进行进一步的研究与挖掘。

## 参考文献

- [1] AI Q, BI K, LUO C, et al. Unbiased learning to rank with unbiased propensity estimation[C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. 2018:385-394.
- [2] WANG X, BENDERSKY M, METZLER D, et al. Learning to rank with selection bias in personal search[C]//Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2016:115-124.
- [3] WANG X, GOLBANDI N, BENDERSKY M, et al. Position bias estimation for unbiased learning to rank in personal search[C]//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. 2018:610-618.
- [4] HU Z, WANG Y, PENG Q, et al. Unbiased lambdamart: an unbiased pairwise learning-to-rank algorithm [C] // The World Wide Web Conference. 2019:2830-2836.
- [5] YUE Y, JOACHIMS T. Interactively optimizing information retrieval systems as a dueling bandits problem[C]//Proceedings of the 26th Annual International Conference on Machine Learning. 2009:1201-1208.
- [6] SCHUTH A, OOSTERHUIS H, WHITESON S, et al. Multileave gradient descent for fast online learning to rank[C]//Proceedings of the Ninth ACM International Conference on Web Search and Data Mining. 2016:457-466.
- [7] WANG H, LANGLEY R, KIM S, et al. Efficient exploration of gradient space for online learning to rank[C]//The 41st Inter-

national ACM SIGIR Conference on Research & Development in Information Retrieval. 2018:145-154.

- [8] OOSTERHUIS H, DE RIJKE M. Differentiable unbiased online learning to rank[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. 2018:1293-1302.
- [9] YUAN K, KUANG D. Deep Pairwise Learning To Rank For Search Autocomplete[J]. arXiv:2108.04976, 2021.
- [10] BAR-YOSSEF Z, KRAUS N. Context-sensitive query auto-completion[C]//Proceedings of the 20th International Conference on World Wide Web. 2011:107-116.
- [11] CHEN T, GUESTRIN C. Xgboost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining. 2016:785-794.
- [12] LI Z Y, YANG W, XIE Z J. A survey of PageRank research[J]. Computer Science, 2011, 38(B10):185-188.
- [13] WANG X P, LI Z Z. An improved ranking algorithm for web page searching[J]. Computer Science, 2004, 31(9A).
- [14] LAI X X, HAN L X, ZENG X Q, et al. Research on meta-search ranking algorithms based on information quantity and information entropy[J]. Computer Science, 2012, 39(3):153-156.
- [15] WEN K M, LU Z D, SUN X L, et al. A survey of semantic search research[J]. Computer Science, 2008, 35(5):1-4.
- [16] ZHANG X, QU Y Z. Ranking problems in the Semantic Web [J]. Computer Science, 2008, 35(2):5.
- [17] CARPINETO C, ROMANO G. A survey of automatic query expansion in information retrieval[J]. Acm Computing Surveys (CSUR), 2012, 44(1):1-50.
- [18] LIU T Y. Learning to rank for information retrieval[J]. Foundations and Trends © in Information Retrieval, 2009, 3(3):225-331.
- [19] CAI F, DE RIJKE M. A survey of query auto completion in information retrieval[J]. Foundations and Trends © in Information Retrieval, 2016, 10(4):273-363.
- [20] JOACHIMS T, SWAMINATHAN A, SCHNABEL T. Unbiased learning-to-rank with biased feedback[C]//Proceedings of the Tenth ACM International Conference on Web Search and Data Mining. 2017:781-789.
- [21] GUO H, YU J, LIU Q, et al. PAL: a position-bias aware learning framework for CTR prediction in live recommender systems [C]//Proceedings of the 13th ACM Conference on Recommender Systems. 2019:452-456.



**ZHOU Mingxing**, born in 1991, master, data scientist. His main research interests include learning to rank, deep learning, image processing, nature language processing, evolutionary algorithms, data mining, and complex networks.