

为搜索引擎学习最优的排序模型

关键词：搜索引擎 排序

刘铁岩 徐君 李航 马维英
微软亚洲研究院

引言

目前，网络搜索引擎已经成为人们日常生活中的重要工具，它可以帮助人们在信息海洋中定位有价值的内容。在搜索引擎的各个组成部分中，相关性排序模型直接决定了人们看到的搜索结果，因此，这种模型对于搜索引擎的性能起着至关重要的作用。

在信息检索发展的历史上，人们提出了很多相关性排序模型，如BM25模型^[11]和语言模型^[17]等。这些模型对推动搜索技术发展起到过一定作用，但是也存在着一些问题：有的模型建立在人们对搜索问题的主观理解之上，需要根据经验人为设定模型参数；还有一些模型虽然可以从大量网页中学习不断调整参数，但无法利用用户的反馈信息对模型参数进行优化。由于用户提交不同的查询词，或者不同用户提交相同的查询词都有可能代表不同的信息需求，因此，仅从研究者的主观理解，或者仅从网页数据中学习排序模型，都无法很好地解决复杂的网络搜索问题。在这样的背景下，近年来研究人员开始尝试使用有监督的机器学习方法，即从用户标注或者反馈中学习最优的相关性排序模型。

为了学习最优的相关性排序模型，需要一个训练数据集。该集合包含随机抽取的查询词、和查询词有关的网页，以及这些网页的相关性标注。这些标注可能是由用户显式提供

的绝对信息，如一个网页和查询词是否非常相关、相关或不相关等；也可能是从搜索引擎的用户行为中挖掘出来的相对信息，如某个网页是否比另外一个网页更加相关。为了从这些标注数据中学到最优的排序模型，通常需要定义3个部分：一是表征网页信息的特征向量（如词频、页面分级（PageRank）^[1]等）；二是模型的基本形式（如线性、非线性等）；三是用来控制学习过程的损失函数（它衡量了当前模型的排序结果和标注信息之间的差别）。极小化损失函数可以得到与标注数据最吻合的模型参数。经过优化的模型将用于回答新的查询词：给定新的查询词，首先通过倒排表找到包含该查询词的网页，然后为每个网页提取特征向量，并将排序模型应用到这些特征向量上，从而给每个网页输出一个分数，最后将网页按照分数的降序进行排列并返回给用户。其大致流程如图1所示。

近年来，人们不仅将已有的机器学习算法应用到排序模型的训练当中，还为这个新课题开发了很多新算法。本文将着重介绍这方面的最新进展：基于网页列表的学习算法以及直接优化信息检索评价准则的学习算法。在此之前，先简要回顾这个领域的传统方法——基于网页对的学习算法。

基于网页对的学习算法

这类算法试图用分类技术（有监督学习

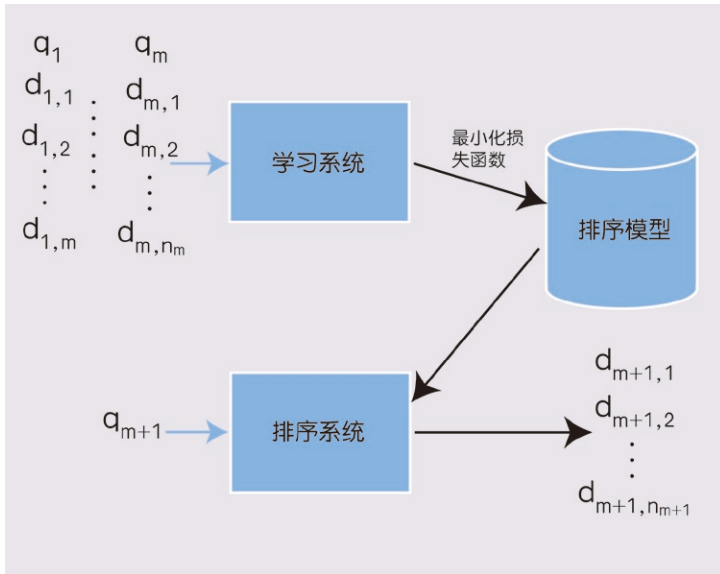


图1 排序模型学习过程示意图

领域的一个成熟分支)来解决排序模型的学习问题。为此,人们把训练集中的网页依据标注信息构造成网页对,使得每个网页对的第一个网页比第二个网页更加相关。如果把如此构造的网页对视为正例,而把反序的网页对视为负例,可以训练出一个二分类器。换言之,这类学习算法的损失函数与被错误分类的网页对的数目有关。如果学到的分类器能够对所有网页对都进行正确的分类,那么也就等价于给出了所有标注数据的正确排序。这类算法以Ranking SVM^[6,8]、RankBoost^[5]和RankNet^[2]为代表。它们的基本思想很类似,只是分类器分别选用支持向量机(Support Vector Machines, SVM)、Boosting算法和神经网络。

基于网页对的学习算法在信息检索的历史上取得了成功。实验表明,这类算法在多数情况下比BM25和语言模型表现得更好。然而,与此同时人们也发现了这类算法的缺点:在极小化算法中用到的损失函数时,MAP¹、DCG²和NDCG^{3[7]}等信息检索中常用的评价准则并不

一定得到相应的提升(如图2所示)。当这些准则越高时,就表明用户对搜索结果越满意,而基于网页对的算法并不一定能给出令用户最满意的排序模型。

以上提到的评价准则具有如下共同特点:(1)对于每个查询词的搜索结果可以计算出一个有界的实数值作为指标(通常是在0~1之间),而后对测试集中所有查询词的指标进行平均,所得值作为模型的性能评价;(2)排在搜索结果前列的网页对评价准则的影响比

较大。

基于这两个特点,不难分析出基于网页对的学习算法存在的问题:(1)这些算法以网页对为基本单位,忽略了查询词的存在,因此无法保证每个查询词所对应的损失是可比的。在训练集中不同查询词对应的网页对的数目可能差别很大,具有大量网页对的查询词会对训练过程产生主导性的影响;(2)由于网页对并




图2 随着RankNet的损失函数被极小化,评价准则NDCG并不相应提升

¹ Mean Average Precision, 平均准确率

² Discounted Cumulative Gain

³ Normalized Discounted Cumulative Gain

不反映网页在最终排序结果中的位置，因此无法保证排在前面的网页给予损失函数的影响更大。

基于网页列表的学习算法

为了解决基于网页对的学习算法的问题，曹（Cao）、秦（Qin）和刘（Liu）等提出了基于网页列表的学习算法—ListNet^[3]。这种算法的基本思想是：不再构造网页对，而是在网页列表的层次上直接定义损失函数，使得这种损失函数可以克服上节中提到的两个问题。

为此需要定义什么是网页列表。对于与给定查询词有关的一组网页，通过某种方式给每个网页赋一个分数，用以表征它和查询词之间的相关程度。这个分数可能是由排序模型输出的，也可能来自人工标注。把网页按照分数的降序进行排列就会得到一个网页列表。

ListNet算法首先根据排序模型的输出结果得到一个网页列表，然后通过人工标注的结果得到另一个网页列表。接下来，把每个网页列表映射成一个概率分布，并用这2个概率分布之间的差别来定义损失函数。为了建立网页列表和概率分布之间的映射关系，在给定每个网页分数的情况下，将网页列表视为对这些网页的一种特定的排列。在此基础上，把样本空间定义成对已知网页所有可能的排列，而每个排列出现的概率则由网页的分数所决定。进一步，如果认为网页的分数正比于该网页被排序模型排在其他网页前面的概率，根据全概率公式，便可以自然地定义出给定了一个网页列表之后，任意排列 π 出现的概率：

$$p_s(\pi) = p_1 \cdot \frac{p_2}{1 - p_1} \cdots \frac{p_n}{1 - \sum_{k=1}^{n-1} p_k} = \prod_{j=1}^n \frac{p_j}{\sum_{k=j}^n p_k}$$

在上述公式中， P_j 表示排列 π 中第 j 个网页排在其他网页前面的概率，正比于该网页的分

数。很自然地可以理解

$$\frac{P_j}{\sum_{k=j}^n p_k}$$

表示在第1, 2, ..., $j-1$ 个网页已经排在了前 $j-1$ 个位置上的条件下，第 j 个网页紧随其后的概率。容易验证，改变分数较高的网页在排列中的位置会对 $P_s(\pi)$ 产生较大的影响。

根据上述公式，可以为排序模型的输出结果定义一个概率分布；同时为标注数据（当标注数据是网页与查询词之间的相关程度，如非常相关、比较相关、相关、不太相关、毫不相关时，可以把每个相关性等级映射成一个实数值，如5、4、3、2、1等）定义另外一个概率分布。然后利用这2个概率分布之间的交叉熵或者KL-散度来定义损失函数。通过梯度下降等常用的优化方法极小化这个损失函数，就可以求得最佳的模型参数。由于ListNet算法为所有给定查询词下的网页计算了统一的损失，而不是为每个网页对建立单独的损失，每个查询词对总体损失函数的贡献是可比较的，由此就避免了那些拥有数目众多网页对的查询词主导训练过程的问题。

在ListNet的训练过程中，我们观察到极小化上述损失函数的同时，信息检索的评价准则也得到相应的提升（如图3所示）。进一步的实




图3 随着ListNet的损失函数被极小化，评价准则NDCG相应提升

验也验证了,在很多数据集上, ListNet比基于网页对的算法有更优的表现。

事实上,上面提到的ListNet算法只是基于网页列表的学习算法的一个例子。人们可以定义其他直接作用在网页列表上的损失函数和排序模型。由于排序需要考虑查询词的存在以及网页之间的位置关系(这是它区别于分类和回归的重要特征),基于网页列表的学习方法比以往的算法更加切合排序的应用。可以预见,这类算法会在排序及网络搜索中发挥越来越大的作用。

直接优化评价准则的学习算法

如图2所示,传统学习算法的损失函数与信息检索的评价准则存在较大差异。除了基于网页列表的学习算法以外,另一个自然的解决方案是直接优化信息检索的评价准则,这样可以使得训练的过程更加有的放矢。然而,这种解决方案的难点在于信息检索的评价准则(如MAP和NDCG)相对于模型参数而言,通常是不连续、不可导的,这使得优化过程变得非常困难。

为了解决上述问题,一些研究者寻找某一种评价准则的“平滑”近似来定义损失函数,这样定义的损失函数具有更好的数学性质(如连续、可导等),因此更容易优化。科索克(Cossock)和张(Zhang)^[4],以及李(Li)^[10]分别为信息检索的评价准则DCG^[6]寻找到了基于回归损失和分类损失的近似函数,并用Boosting算法对该近似函数进行优化;泰勒(Taylor)等提出了SoftRank算法^[13],其基本思想是对网页出现在不同位置上的概率进行高斯建模,把一个“硬”的网页列表近似为“软”的位置分布,进而得到评价准则的一个“软”近似。在他们的工作中,神经网络被用于优化这个近似的损失函数。

也有一些研究人员更加直接地对信息检索

评价准则进行优化。梅茨乐(Metzler)等提出基于流形学习的排序算法^[12],用来直接优化评价准则;乐(Le)等^[9]以及岳(Yue)等^[16]分别提出了基于支持向量机的学习算法,用来直接优化MAP。

徐(Xu)和李(Li)提出了基于Boosting的学习算法AdaRank^[14],用以直接优化任意一种信息检索的评价准则。AdaRank基于信息检索评价准则构造了指数损失函数,在加性模型的假设下,采用了逐步优化的方法对损失函数进行优化,其执行流程如下:

1. 初始化:为训练集中的每一个查询词(及其网页列表)分配重要性分布;
2. 训练“弱”排序模型:基于当前查询词的重要性分布,调用“弱”排序学习算法得到一个“弱”排序模型;
3. 计算权重:用指定的评价准则衡量“弱”排序模型,计算其权重(评价指标越高则权重越大)并线性叠加到当前排序模型中;
4. 更新重要性分布:用指定的评价准则衡量当前排序模型对每个查询词的排序效果,由此设置下一轮训练中查询词的重要性,使得在下一轮的训练中算法能够重点考虑“困难”的查询词;
5. 转到第2步,直至满足退出条件。

从以上流程可以看出,查询词(及其网页列表)是AdaRank训练过程的基本单元,并且在算法中直接考虑了信息检索的评价准则,这使得AdaRank更加切合于信息检索任务。实验表明,AdaRank算法在多个大规模数据集上都取得了良好的检索效果。

尽管上述各项工作取得了一定的成功,但是由于信息检索的评价准则本身不连续、不可导,造成直接对其进行优化仍然存在很多困难。相关的学习算法可能无法收敛,或者很容易陷入局部极值点。为了能让直接优化评价准则的学习算法的鲁棒性更强,叶(Yeh)等在他们的工作中使用遗传算法来优化评价准则^[15],

取得了一定的效果。不过总体上讲，这个方向还面临很多挑战，需要不断探索。

结语

本文介绍了网络搜索中排序模型的学习问

题及其前沿技术，着重讨论了基于网页列表的学习算法和直接优化信息检索评价准则的学习算法。由于网络搜索是网络上的主流应用，而且排序模型在网络搜索中起到了关键作用，因而相关的研究将会不断发展。■



刘铁岩

微软亚洲研究院网络搜索与挖掘组研究员，2003年在清华大学电子工程系获博士学位。目前主要研究方向为机器学习及其在信息检索中的应用，大规模数据挖掘的系统与算法等。



徐君

微软亚洲研究院网络搜索和挖掘组副研究员，2006年在南开大学信息技术科学学院获博士学位。主要研究方向是信息检索和机器学习。



李航

微软亚洲研究院网络搜索和挖掘组主任研究员，西安交通大学和南开大学的客座教授，博士生导师。1998年获得日本东京大学计算机博士学位。主要研究方向是统计学习、自然语言处理、数据挖掘和信息检索。



马维英

微软亚洲研究院网络搜索和挖掘组主任研究员，领导在信息检索、互联网搜索技术、数据挖掘、多媒体管理和移动信息浏览方面的研究。1997年获美国加州大学圣芭芭拉分校（UCSB）电气和计算机工程系博士学位。

参考文献

- [1] S. Brin and L. Page. The anatomy of a large-scale hypertextual Web search engine". Proceedings of World Wide Web Conference 1998, pages 107-117, 1998
- [2] C. Burges, T. Shaked, E. Renshaw, A. Lazier, M. Deeds, N. Hamilton, and G. Hullender. Learning to rank using gradient descent. Proceedings of ICML 2005
- [3] Z. Cao, T. Qin, T.-Y. Liu, M.-F. Tsai, and H. Li. Learning to rank: From pairwise approach to listwise approach. Proceedings of ICML 2007
- [4] D. Cossock and T. Zhang. Subset Ranking Using Regression. Proceedings of COLT 2006, pages 605-619, 2006
- [5] Y. Freund, R. Iyer, R. Schapire, and Y. Singer. An Efficient Boosting Algorithm for Combining Preferences. Journal of Machine Learning Research, 4(6):933-969, 2004
- [6] R. Herbrich, T. Graepel, and K. Obermayer. Large Margin Rank Boundaries for Ordinal Regression. Advances in Large Margin Classifiers. MIT Press, pages 115-132, 2000
- [7] K. Jarvelin and J. Kekalainen. IR evaluation methods for retrieving highly relevant documents. Proceedings SIGIR 2000, pages 41-48, 2000

參考文獻

- [8] T. Joachims. Optimizing search engines using clickthrough data. Proceedings of SIGKDD 2002, pages 133–142, 2002
- [9] Q. V. Le and A. J. Smola. Direct Optimization of Ranking Measures. Technical Report, 2007
- [10] P. Li, C. J. C. Burges, and Q. Wu. Learning to Rank Using Classifications and Gradient Boosting. Microsoft Research Technical Report MSR-TR-2007-74, 2007
- [11] S. E. Robertson. Overview of the okapi projects, Journal of Documentation, Vol. 53, No. 1, pp. 3–7, 1997
- [12] D. A. Metzler, W. B. Croft, and A. McCallum. Direct Maximization of Rank-Based Metrics for Information Retrieval. CIIR Technical Report IR-429, 2005
- [13] M. Taylor, J. Guiver, S. E. Robertson, and T. Minka. SoftRank: Optimising Non-Smooth Rank Metrics. Proceedings of SIGIR 2007 workshop on Learning to Rank for Information Retrieval, 2007
- [14] J. Xu and H. Li. AdaRank: A Boosting Algorithm for Information Retrieval. In Proceedings of SIGIR 2007, pages 391–398, 2007
- [15] J. Y. Yeh, J. Y. Lin, H. R. Ke, and W. P. Yang. Learning to Rank for Information Retrieval Using Genetic Programming. Proceedings of SIGIR 2007 workshop on Learning to Rank for Information Retrieval, 2007
- [16] Y. Yue, T. Finley, F. Radlinski, and T. Joachims. A Support Vector Method for Optimizing Average Precision. Proceedings of SIGIR 2007, pages 271–278, 2007
- [17] C. Zhai and J. Lafferty. A study of smoothing methods for language models applied to Ad Hoc information retrieval. Proceedings of SIGIR 2001, pages 334–342, 2001