

基于最大间隔的半监督图像搜索重排序方法

张桐喆, 苏育挺, 郭洪斌*

天津大学电气自动化与信息工程学院, 天津 300072

摘要 提出一种基于最大间隔原理的半监督图像搜索重排序学习算法。所提算法在最大间隔原理框架下, 首先利用超图正则化保持标注及未标注样本在原始空间中的局部近邻关系, 增强算法的稳健性; 其次, 利用少量的标注样本构造优先关系对, 将样本间先验的相关性等级信息引入目标函数中以更好地指导重排序模型的学习。在公开数据集 MSRA-MM 1.0 上的实验结果表明所提方法能更好地将符合用户需求的结果靠前优先呈现给用户, 提高搜索的准确性。

关键词 图像处理; 图像搜索; 视觉搜索重排; 超图正则化; 半监督排序

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.111001

A Max Margin Based Semi-Supervised Reranking Method

Zhang Tongzhe, Su Yuting, Guo Hongbin*

School of Electronic Information Engineering, Tianjin University, Tianjin 300072, China

Abstract We propose a max margin based semi-supervised reranking method for multimedia information retrieval. We use hypergraph regularization to preserve the neighborhood of the sample in the original space and introduce the labeled and unlabeled sample information to construct the objective function, so as to achieve full and efficient use of data information for ranking. By using a small amount of annotation samples to construct the priority relationship pairs, the priority information between samples is introduced into the objective function to construct a ranking learning model. This method can show users in priority the results that meet their demand better, and improve the retrieval accuracy. The experimental results on MSRA-MM 1.0 dataset suggest the proposed method provides superior performance compared with several state-of-the-art methods.

Key words image processing; image search; visual search reranking; hypergraph regularization; semi-supervised ranking

OCIS codes 100.2000; 100.3008; 150.1135

1 引言

随着信息技术的快速发展, 图像和视频等多媒体资源迅速增长。图像和视频含有丰富、直观、有趣的信息, 已成为人们获取信息的重要途径之一。在此背景下, 图像搜索成为一个积极和富有挑战性的研究领域。现有的商业搜索引擎对图像的搜索主要是通过图像所在网页的文本信息和基于元数据的特征进行搜索的。然而, 有限的文本信息并不能充分描述图像的丰富内容, 也不能准确描述图与查询的相关程度。此外, 文本描述与图像之间由于语义鸿沟的存在, 也可能存在错误匹配。由于上述因素, 现

有商业搜索引擎会出现搜索结果与查询目标不相关的情况, 甚至有时相关度不高的结果还会出现在前列。图像搜索重排序是对初始搜索结果进行二次排序的过程。图像搜索重排序可以更好地理解用户的搜索意图并提供更精准的搜索结果, 已经成为图像搜索研究新的发展方向^[1-2]。当前的图像搜索重排序研究可以大致分为四类: 基于分类的方法^[3-4], 基于簇的方法^[5-6], 基于排序学习的方法^[7], 基于图的方法^[8]。

基于分类的方法是把重排序问题转化为分类问题, 用相关性反馈或者伪相关性反馈作为标记, 训练出一个分类器或排序模型。Wang 等^[9]提出了一种主动的重排序方法用于网站图像搜索, 该方法要求

收稿日期: 2018-03-23; 修回日期: 2018-05-02; 录用日期: 2018-05-28

基金项目: 国家自然科学基金(61271069)

* E-mail: ghb3011204117@163.com

用户从初始基于文本的搜索结果中选取目标图像。基于簇的方法首先将基于文本的图片搜索结果分为不同的簇,然后根据其相关性分数进行排序。Chi等^[10]根据显著的视觉模式对图像进行区分聚合,进而对基于文本的搜索结果重排序。基于排序学习的方法因为其结果的提升效果明显受到了越来越多的关注,该方法通过对视觉特征的提取,用半监督或监督的方法学习得到排序模型。Liu等^[11]在重排序任务中习得分类和排序的不同,把重排序问题建模为对匹配的优化问题加以解决。基于图的方法可以看作不同排序列表的融合,其中基于这种方法的算法有 PageRank、Random Walk 和 Multi-level 等^[12-13]。Pang等^[14]提出一种依据维度约简的排序图嵌入框架,该方法通过不同的相关程度整合了若干图集。

实际情况中,简单图只考虑了两个定点之间的关系,不能够充分表示图像之间的关系。因此,考虑包含局部组信息的多顶点之间的关系会有助于更好地捕获样本间潜在的集合结构信息。和简单图只包含一对定点的边不同,超图的边是顶点集合的子集,更有助于充分挖掘样本间的关系。另外,受到最大间隔原理在排序任务中的优越性能的启发,提出一种基于最大间隔原理的半监督图像搜索重排序(MMBSR)算法。该方法步骤如下。1) 借助已标记样本和视觉特征用线性方法标记未标记样本,属于半监督学习^[15],其中的重构系数被进一步用于计算未标记样本的伪相关程度。在此基础上,整合相关程度信息或伪相关程度信息,使得样本之间的距离计算方式更具有判别性。2) 所有样本作为顶点构建超图,通过局部一致性约束构建超图正则化因子,以尽可能地保持样本在原始空间中的几何结构信

息。3) 将上述超图正则化因子嵌入最大间隔框架中,并将少量标注样本之间的优先级关系信息嵌入该框架中构建最终的目标函数。

本文提出了 MMBSR 算法用于图像搜索重排序,用公式把超图正则化因子和先验的对匹配优先信息整合在同一个正则化框架下。MMBSR 算法是一种半监督学习方法,使用了已标记样本和未标记样本,不同于已有工作,引入了一种更好的保留样本内部几何结构信息的创新超图重构策略。最后基于公开图像数据集的实验验证了该算法的有效性。

2 基本原理

2.1 基于最大间隔原理的半监督图像搜索重排序算法

本文提出的方法主要是将超图正则化学习与最大间隔相结合的半监督排序学习方法。首先利用有限的标注样本获得其余未标注样本的伪标注信息,然后利用新的相似度计算公式计算所有样本之间的相似度,将所有样本的标注信息引入超图学习中,并利用标注样本及优先级信息构造新的样本,在此基础上构造约束项指导排序学习,最后得到排序模型。

提出的排序学习算法的框架如图 1 所示。使用查询词“狗”为例。当在搜索引擎中输入“狗”作为关键字查询时,初始的基于文本的搜索结果会展示给用户。提取不同的视觉特征表示图像的视觉内容。通过相关性反馈获得标注样本,然后根据视觉一致性将相关性程度信息从标注样本拓展到未标注样本。使用标注样本和未标注样本作为 MMBSR 算法的输入数据以训练重排序模型。最后所有图像通过习得的排序模型进行重排序。

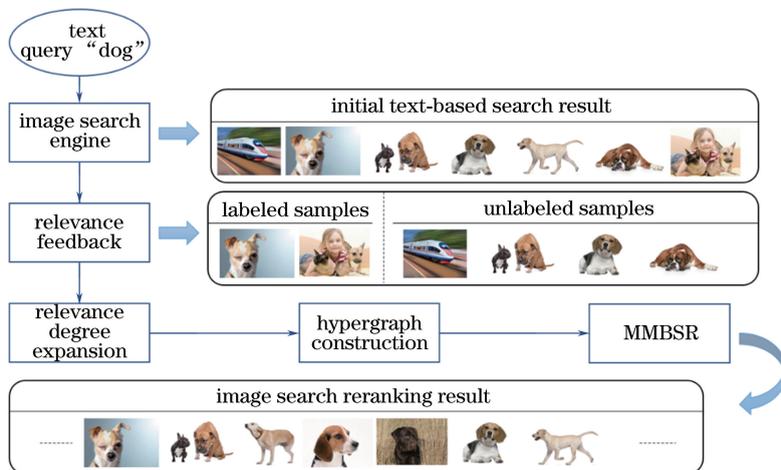


图 1 提出的重排序算法流程图

Fig. 1 Flow chart of the proposed reranking algorithm

设样本集合为 $X = \{x_1, \dots, x_l, x_{l+1}, \dots, x_n\} \in \mathbf{R}^{d \times n}$, d 表示样本的特征维数, n 表示样本个数, l 表示标记样本个数。设 $X_L = [x_1, \dots, x_l]$ 为标记样本集合, $X_U = [x_{l+1}, \dots, x_n]$ 为未标注样本集合。对已知的图像样本集合按照与查询主题相关性的程度划分为三个等级 2、1、0。其中 2 表示与查询非常相关, 1 表示一般相关, 0 表示不相关, 对任意一个样本 x_i , 其相应的标号为 y_i , 则 $y_i \in \{0, 1, 2\}$ 。 $\mathbf{Y}_L = [y_1, \dots, y_l]^T$ 为标注样本集合所对应的标注向量。

基于最大间隔原理的半监督排序学习方法分为三个部分: 构造拉普拉斯超图正则化因子, 构造目标函数, 目标函数求解。

2.2 构造拉普拉斯超图正则化因子

对于任意两个样本 x_i, x_j , 其对应的相关性等级标号分别为 y_i, y_j , 则两个样本之间的距离计算公式为

$$d(x_i, x_j) = \|x_i - x_j\|, \quad (1)$$

式中: $\|x_i - x_j\| = \sqrt{(x_i - x_j)^T (x_i - x_j)}$ 。

对任意两个样本 x_i, x_j , 若样本 x_i 是 x_j 的近邻点之一或 x_j 是 x_i 的近邻点之一, 则两个样本之间的相似度计算公式为

$$A_{ij} = \exp\left[-\frac{d(x_i, x_j)^2}{2\sigma^2}\right], \quad (2)$$

式中: 参数 σ 定义为 $\sigma = \frac{1}{n^2} \sum_{i,j=1}^n d(x_i, x_j)$; $d(x_i, x_j)$ 为距离度量。否则 $A_{ij} = 0$ 。

排序学习假设学习得到一个投影向量 $w \in \mathbf{R}^d$, 使得每一个样本 x_i 的排序分数为 $f_i = w^T x_i$ 。根据视觉一致性准则, 认为对于两个视觉上比较相似的样本, 其排序分数也应该一致, 基于此构建拉普拉斯超图正则化因子, 即

$$\min \frac{1}{2} \sum_{i,j=1}^n A_{ij} \|f_i - f_j\|^2. \quad (3)$$

2.3 构建基于最大间隔原理的损失函数

已知 L 个已标注样本 $X_L = \{(x_i, l_i)\}_{i=1}^L$, 其中 $l_i \in \{0, 1, \dots, r-1\}$ 是 x_i 的相关程度, r 表明程度大小。假设存在一个线性排序函数 $f \in F$, 应存在如下关系:

$$f(x_i) = w^T x_i, \quad (4)$$

$$x_i \succ x_j \Leftrightarrow f(x_i) > f(x_j), \quad (5)$$

式中: \succ 表示两个样本的优先关系; w 为函数投影向量。可得

$$x_i \succ x_j \Leftrightarrow w^T (x_i - x_j) > 0. \quad (6)$$

从以上分析可以定义新的向量序列来反映样本

对之间的优先关系:

$$x_1 - x_2, l = \begin{cases} 1 & \text{if } x_1 \succ x_2 \\ -1 & \text{if } x_2 \succ x_1 \end{cases}. \quad (7)$$

当构建的新样本 $x_1 - x_2$ 的标签值 $l = 1$ 时, 表示该构建的新样本为正样本, 即满足样本 x_1 的相关性等级高于样本 x_2 ; 反之亦然。基于训练集 X_L , 利用标注样本的相关性等级信息构造新的样本: $\forall x_i, x_j$, 如果 $x_i \succ x_j$, 则定义 $z_t = x_i - x_j$ ($t = 1, \dots, h$), 可以获得重构训练集 $Z = \{z_1, \dots, z_h\}$, 其中 h 为构造的新样本个数。基于最大间隔原理, 通过解决最优化问题来构建排序支持向量机模型:

$$\begin{aligned} \min_{w, \epsilon} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^h \epsilon_i, \\ \text{s.t.} & r_i w^T z_i \geq 1 - \epsilon_i, \\ & \epsilon_i \geq 0, i = 1, \dots, h, \end{aligned} \quad (8)$$

式中: C 为惩罚因子。

结合拉普拉斯超图正则化因子构造目标函数如下:

$$\begin{aligned} J(w) = & \frac{1}{2} \min \sum_{i,j=1}^n A_{ij} \|w^T x_i - w^T x_j\|^2 + C \sum_{i=1}^h r_i, \\ \text{s.t.} & w^T z_i \geq m - r_i, i = 1, \dots, h, \\ & r_i \geq 0, i = 1, \dots, h, \end{aligned} \quad (9)$$

式中: m 为自定义常数, 控制不同相关性等级样本的排序分数的差值; r_i ($i = 1, \dots, h$) 为松弛项。

2.4 目标函数求解

采用数学运算化简目标函数 $J(w)$, 得到如下等价形式:

$$\begin{aligned} J(w) = & \min \frac{1}{2} \sum_{i,j=1}^n A_{ij} \|w^T x_i - w^T x_j\|^2 + \\ & C \sum_{i=1}^h r_i = \frac{1}{2} w^T \mathbf{X} \mathbf{L} \mathbf{X}^T w + C \sum_{i=1}^h r_i, \end{aligned} \quad (10)$$

式中: $\mathbf{L} = \mathbf{D} - \mathbf{A}$ 为拉普拉斯矩阵, \mathbf{D} 为对角阵, 对角线元素 $D_{ii} = \sum_j A_{ij}$; \mathbf{X} 为样本组成的矩阵。

以拉格朗日乘子 $\alpha_i \geq 0, \beta_i \geq 0$ ($i = 1, \dots, h$) 分别乘以约束项并将其附加到目标函数上得到拉格朗日函数:

$$\begin{aligned} L(w, r, \alpha, \beta) = & \frac{1}{2} w^T \mathbf{X} \mathbf{L} \mathbf{X}^T w + \\ & C \sum_{i=1}^h r_i - \sum_{i=1}^h \alpha_i (w^T z_i - m + r_i) - \sum_{i=1}^h \beta_i z_i. \end{aligned} \quad (11)$$

得到目标函数对偶规划为

$$\max m \sum_{i=1}^h \alpha_i - \frac{1}{2} \left(\sum_{i=1}^h \alpha_i z_i \right)^T (\mathbf{X} \mathbf{L} \mathbf{X}^T) + \sum_{i=1}^h \alpha_i z_i$$

$$\text{s.t. } 0 \leq \alpha_i \leq C. \quad (12)$$

通过求解二次规划问题得到 α_i ($i=1, \dots, h$) 的值,且 $\mathbf{w} = (\mathbf{X}\mathbf{L}\mathbf{X}^T) + \sum_{i=1}^h \alpha_i \mathbf{z}_i$, 因此可求得 \mathbf{w} 向量。利用 $f_i = \mathbf{w}^T \mathbf{x}_i$ 可以求得各个样本的排序分数。

3 实验与分析

MSRA-MM 1.0 图像数据集基于搜索引擎的查询日志的 68 个代表性查询词,包含 65443 个图像,每个查询大约收集 1000 张图像。MSRA-MM 1.0 数据集提供完整的 899 维视觉特征以及每个图像的注释相关度标签。提取了七种类型的视觉特征并融合使用^[16-17],其中包括 225 维块状颜色矩,64 维 HSV 颜色直方图,256 维 RGB 颜色直方图,114 维颜色相关图,75 维边缘分布直方图,128 维纹理图,以及 7 维人脸特征。对于给定的查询词,这些图像的排序顺序被保存为初始搜索结果。与查询词相对应的每个图像的相关度标记为三个层次之一:非常相关,相关和无关。三个等级分别由 2、1、0 表示。

归一化折损累计增益(NDCG)^[18-19]被广泛应用于信息搜索领域进行绩效评估,特别是在两个以上相关性水平的情况下。采用 NDCG 评估最终排名结果。给定查询词,排名深度 d 处的 NDCG 得分定义为

$$\text{NDCG}@d = Z_d \sum_{j=1}^d \frac{2^{r_j} - 1}{\log(1 + j)}, \quad (13)$$

式中: r_j 是第 j 个数据的等级; Z_d 是选择用以确保 NDCG@ d 值的最理想的排序结果为 1 的归一化常数。

选取数据库提供的 899 维特征,对于每一个查询词,选取初始搜索结果的前 500 张图像,因为在 500 张之后相关性高的图片数量极少。本质上,MMBSR 算法是一种半监督排序算法,所以从不同相关程度的数据集中随机选取 k 个标记样本,共 $3k$ 个样本。对于所有实验,使用 NDCG 分别评估深度为 10,20,30,40,50,60,70,80,90,100 的排名。所有统计实验重复三次,求其平均结果。

评估不同惩罚因子 C 、每个相关性等级标注不同样本个数 k 、排序函数中设置相关性等级的不同排序分数间隔 m 的影响。表 1 列出了本文方法在惩罚因子 C 为 0.01~100 时的各种性能。本文方法中,惩罚因子 C 对分类的新样本进行松弛化处理以保证模型的可靠性。从表 1 可以看出 $C=1$ 时性能最佳, C 过大或者过小会对性能有损,这也表明实验过程中存在一些类别界限模糊的样本点,需要通过引入惩罚因子来增强模型对该类样本的稳健性。表 2 所示为每个相关性等级标注的样本个数在 5~20 之间的影响,可以看出,随着 k 的增加,重排序性能会有所提升,有效的监督信息的引入在提高模型的排序性能方面起到了积极的作用。排序函数中设置的不同相关性等级的排序分数间隔 m 如表 3 所示,可以看出,不同的排序分数间隔对排序结果也有一定的影响,当 $m=0.5$ 时性能最佳。尽管如此, m 取值为 1 和 1.5 时,也取得了具有竞争力的排序性能。此外, m 值过大或者过小都会导致排序性能变差,这在本质上是由于选取恰当的 m 值更有利于引导模型的其他参数在更合理、正常的区间内学习。

表 1 不同惩罚因子下的性能比较

Table 1 Performance comparison for different trade-off parameters

C	Depth									
	10	20	30	40	50	60	70	80	90	100
0.01	0.634	0.590	0.572	0.563	0.559	0.557	0.555	0.555	0.558	0.562
0.1	0.807	0.722	0.682	0.659	0.644	0.634	0.628	0.625	0.624	0.626
1	0.862	0.766	0.723	0.697	0.679	0.667	0.659	0.656	0.653	0.653
10	0.861	0.766	0.722	0.695	0.676	0.666	0.658	0.655	0.652	0.652
100	0.861	0.766	0.722	0.695	0.676	0.666	0.658	0.654	0.652	0.652

表 2 每个相关性等级不同标注样本个数的性能比较

Table 2 Performance comparison for different labeled numbers

k	Depth									
	10	20	30	40	50	60	70	80	90	100
5	0.862	0.766	0.723	0.697	0.679	0.667	0.659	0.656	0.653	0.653
10	0.930	0.844	0.783	0.747	0.728	0.714	0.704	0.698	0.694	0.693
15	0.866	0.879	0.827	0.789	0.762	0.744	0.731	0.723	0.717	0.715
20	0.803	0.851	0.847	0.812	0.786	0.766	0.751	0.742	0.735	0.730

表3 排序函数中设置的不同相关性等级的不同排序分数间隔性能比较

Table 3 Performance comparison for different ranking fractional intervals

m	Depth									
	10	20	30	40	50	60	70	80	90	100
0	0.769	0.695	0.661	0.640	0.626	0.618	0.613	0.610	0.610	0.614
0.5	0.862	0.766	0.723	0.697	0.679	0.667	0.659	0.656	0.653	0.653
1	0.856	0.764	0.722	0.697	0.679	0.666	0.659	0.655	0.653	0.653
1.5	0.850	0.761	0.719	0.692	0.677	0.665	0.656	0.652	0.650	0.650
2	0.844	0.756	0.715	0.686	0.671	0.661	0.654	0.650	0.647	0.647
2.5	0.838	0.752	0.711	0.683	0.666	0.657	0.650	0.647	0.644	0.643
3	0.832	0.746	0.705	0.680	0.661	0.653	0.646	0.642	0.639	0.640
3.5	0.827	0.740	0.699	0.674	0.657	0.648	0.641	0.637	0.635	0.637
4	0.823	0.736	0.695	0.670	0.654	0.643	0.637	0.633	0.631	0.634
4.5	0.815	0.729	0.688	0.663	0.648	0.638	0.632	0.628	0.627	0.630
5	0.807	0.722	0.682	0.659	0.644	0.634	0.628	0.625	0.624	0.626

本文方法与目前最流行的算法进行比较。RankSVM是具有成对优先约束的典型监督排序方法^[20];LPP+RankSVM中LPP^[21-23]通过保留整个数据的固有几何结构来降低原始特征维度,将维度降为150维;RANGE是一种经典的基于图形的重新排序方法^[14],其模型的全局结构和局部关系在不同的相关程度集。

如表4所示,MMBSR算法在视觉搜索重排问题上与对比方法相比获得了最好的效果;LPP+RankSVM、RANGE都是视觉搜索重排问题的半监

督方法,其排序性在不同的深度上都优于经典的RankSVM,表明保留数据在原始空间中整体内在几何结构在改善模型的稳健性并提高排序性能方面有积极作用。相比于RANGE算法,本文算法性能更好。这是由于本文提出的模型本质上是一种半监督的学习模型,在模型训练过程中,通过引入未标注的样本并结合拉普拉斯超图正则化因子保持样本的群组特性,以进一步提高模型的精度。以上所有方法性能均好于初始搜索结果,证明了视觉搜索重排方法的有效性。

表4 不同图像搜索重排序方法的实验结果比较

Table 4 Performance comparison for different image search reranking methods

Method	Depth									
	10	20	30	40	50	60	70	80	90	100
RankSVM	0.670	0.665	0.659	0.649	0.641	0.636	0.634	0.634	0.633	0.636
RankSVM+LPP	0.801	0.735	0.702	0.679	0.669	0.659	0.654	0.651	0.649	0.650
RANGE	0.835	0.753	0.717	0.692	0.676	0.666	0.660	0.658	0.656	0.657
Proposed	0.859	0.760	0.719	0.691	0.676	0.668	0.662	0.659	0.658	0.658

MSRA-MM 1.0 图像数据集包括“angel”“animals”“baby”“backgrounds”“baseball”“batman”“beach”“bees”等68个查询词。对68个查询词重排序后的结果进行可视化分析,并以“angel”为例进行展示说明,结果如图2所示。分别选择排序前的前10张图像以及重排序后的前10张图像进行对比,图2(a)为基于文本的原始搜索结果,其中等级分数为{2,1,2,1,0,2,0,2,2,0},图2(b)为重排序结果,排序后前10名的等级分数均为2,且它们的原始位置分别在{1,3,6,8,9,15,33,78,79,152}。由此可以看出本排序算法可以很好地判断图像搜索相关等级并优先展示。

整个数据集进行更精细的划分,即选取具有代表性的四类子数据集,并统计每个子类的重排序性能,划分的四类子数据集具体包括动物查询词(“bees”“birds”“cow”等)、实体查询词(“cake”“car”“rose”等)、人物查询词(“angel”“baby”“women”等)、抽象及模糊查询词(“backgrounds”“games”“sports”等)。实验结果如图3所示,可以看出,动物查询词和实体查询词由于其特征较为明显清晰,在构建超图关系的环节中有优势,重排序效果好于人物查询词和其他查询词;而抽象查询词和人物查询词由于其背景的复杂性,在重排序过程中效果稍差,这表明尽管低层视觉特征与图像的语义描述之间存在语义鸿沟,但与更加抽象化的图像类型相比,低层视觉特

最后,为了更好地验证本文模型的有效性,对

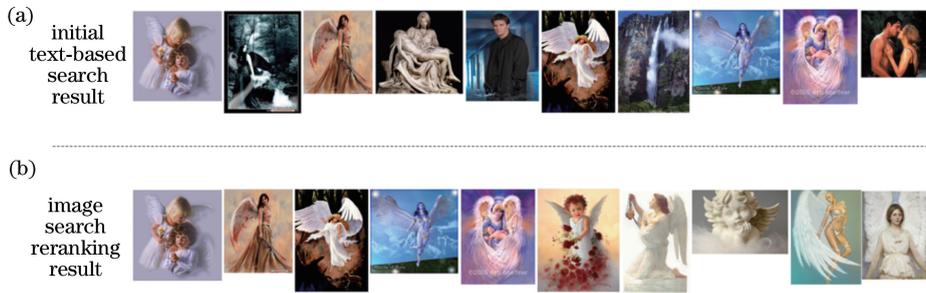


图2 基于查询词“angel”的(a)初始排序结果与(b)重排序结果对比

Fig. 2 Performance comparison between (a) initial search results and (b) reranking results based on query "angel"

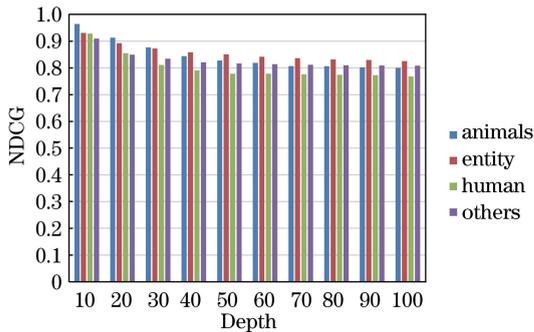


图3 不同类别数据的实验结果比较

Fig. 3 Performance comparison of different datasets

征在描述实体化的图像类型时更加有效。尽管如此,不同类别的数据集在该算法下的重排序性能均表现良好,体现了算法的稳健性。

4 结 论

针对排序学习中大量未标注样本及样本之间普遍存在相关性的特点,提出一种新颖的将超图学习与最大间隔原理相结合的半监督排序学习方法。其优势主要表现如下。1) 新颖性:提出一种新的排序学习方法,通过超图正则化学习引入未标注的样本,利用样本及样本的相关性等级信息构造新的样本点,并将超图正则化学习与新样本点相结合得到一种新的排序学习方法。2) 有效性:实验证明与传统的监督型排序方法相比,本文提出的 MMBSR 算法在图像搜索重排序实验中取得了更好的效果,能够有效利用标注样本以及大量无标注样本并提高排序性能。3) 实用性:简单可行,可以用于多媒体搜索中的视觉搜索重排序、个性化推荐等与排序相关的领域。

本文算法使用基于超图的半监督方法来描述样本整体的内在几何结构。在视觉相似和先验对匹配的约束下,将超图正则化因子和从已标记样本获得的先验对匹配信息结合成统一的排序学习框架。基于 MSRA-MM 1.0 数据库开展实验,显示了本文算

法在视觉搜索重排任务中的有效性和优越性。未来,我们将着眼于多实例学习,用以探究不同视觉概念的联系,进一步提高图片搜索重排序性能。

参 考 文 献

- [1] Hong C Q, Zhu J K. Hypergraph-based multi-example ranking with sparse representation for transductive learning image retrieval [J]. *Neurocomputing*, 2013, 101: 94-103.
- [2] Xie H, Lu Y M. Content-based image re-ranking technology in search engine[J]. *Journal of Computer Applications*, 2013, 33(2): 460-462.
谢辉, 陆月明. 搜索引擎中基于内容的图像重排序 [J]. *计算机应用*, 2013, 33(2): 460-462.
- [3] Krapac J, Allan M, Verbeek J, *et al.* Improving web image search results using query-relative classifier[C] // *IEEE Conference on Computer Vision and Pattern Recognition*, 2010: 1094-1101.
- [4] Tu S Q, Xue Y J, Liang Y, *et al.* Review on RGB-D image classification [J]. *Laser & Optoelectronics Progress*, 2016, 53(6): 060003.
涂淑琴, 薛月菊, 梁云, 等. RGB-D 图像分类方法研究综述 [J]. *激光与光电子学进展*, 2016, 53(6): 060003.
- [5] Ben-Haim N, Babenko B, Belongie S. Improving web-based image search via content based clustering [C] // *IEEE Conference on Computer Vision and Pattern Recognition Workshop*, 2006: 106.
- [6] Zeng T Y, Du F. Image super-resolution reconstruction based on hierarchical clustering [J]. *Acta Optica Sinica*, 2018, 38(4): 0410004.
曾台英, 杜菲. 基于层次聚类的图像超分辨率重建 [J]. *光学学报*, 2018, 38(4): 0410004.
- [7] Yang L, Hanjalic A. Supervised reranking for web image search[C] // *ACM International Conference on Multimedia*, 2010: 183-192.
- [8] Hsu W H, Kennedy L S, Chang S. Video search

- reranking through random walk over document level context graph[C] // ACM International Conference on Multimedia, 2007: 971-980.
- [9] Wang X, Liu K, Tang X. Query-specific visual semantic spaces for web image re-ranking[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2011: 857-864.
- [10] Chi M, Zhang P, Zhao Y, *et al.* Web image retrieval reranking with multi-view clustering [C] // ACM International Conference on World Wide Web, 2009: 1189-1190.
- [11] Liu Y, Mei T. Optimizing visual search reranking via pairwise learning [J]. IEEE Transactions on Multimedia, 2011, 13(2): 280-291.
- [12] Pang S, Xue J, Gao Z, *et al.* Image reranking with an alternating optimization[C] // ACM International Conference on Multimedia, 2014: 1141-1144.
- [13] Page L. The PageRank citation ranking: bringing order to the web[R/OL]. (1998-01-29) [2018-01-05]. <http://ilpubs.stanford.edu:8090/422/1/1999-66.pdf>.
- [14] Pang Y W, Ji Z, Jing P G, *et al.* Ranking graph embedding for learning to rerank [J]. IEEE Transactions on Neural Networks and Learning Systems, 2013, 24(8): 1292-1303.
- [15] Liang J Y, Gao J W, Chang Y. The research and advances on semi-supervised learning[J]. Journal of Shanxi University (Natural Science Edition), 2009, 32(4): 528-534.
梁吉业, 高嘉伟, 常瑜. 半监督学习研究进展[J]. 山西大学学报(自然科学版), 2009, 32(4): 528-534.
- [16] Jin Z F F, Hou Z Q, Yu W S, *et al.* Multiple feature fusion based on covariance matrix for visual tracking [J]. Acta Optica Sinica, 2017, 37(9): 0915005.
金泽芬芬, 侯志强, 余旺盛, 等. 基于协方差矩阵的多特征融合跟踪算法[J]. 光学学报, 2017, 37(9): 0915005.
- [17] Ji Z, Pang Y, He Y, *et al.* Semi-supervised LPP algorithms for learning-to-rank-based visual search reranking[J]. Information Sciences, 2015, 302(C): 83-93.
- [18] Wang L, Shuai J M. Query dependent visual similarity in image search reranking [J]. Computer Systems & Application, 2010, 19(11): 66-70.
王黎, 帅建梅. 图像重排序中与查询相关的图像相似性度量[J]. 计算机系统应用, 2010, 19(11): 66-70.
- [19] Rvelin K, Kek J. Cumulated gain-based evaluation of IR techniques[J]. ACM Transactions on Information Systems, 2002, 20(4): 422-446.
- [20] Herbrich R, Graepel, T, Obermayer K. Large margin rank boundaries for ordinal regression[C] // Workshop on Advances in Large Margin Classifiers, 2000: 115-132.
- [21] Zan B F, Kong J, Jiang M. Human action recognition based on discriminative collaborative representation classifier[J]. Laser & Optoelectronics Progress, 2018, 55(1): 011010.
笮宝锋, 孔军, 蒋敏. 基于判别协作表征分类器的人体行为识别[J]. 激光与光电子学进展, 2018, 55(1): 011010.
- [22] He X, Yan S, Hu Y, *et al.* Face recognition using Laplacian faces [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2005, 27(3): 328-340.
- [23] Zhou B, He Y Q, Wang J. Face recognition based on adaptive neighborhood locality preserving projection algorithm [J]. Laser & Optoelectronics Progress, 2018, 55(3): 031010.
周博, 何宇清, 王建. 基于自适应近邻局部保持投影算法的人脸识别[J]. 激光与光电子学进展, 2018, 55(3): 031010.