

DOI: 10.7652/xjtub201610012

一种利用局部结构信息的加权哈希图像检索算法

张胜杰¹, 查宇飞¹, 李运强¹, 李寰宇², 杨源²

(1. 空军工程大学航空航天工程学院, 710038, 西安; 2. 空军工程大学空管领航学院, 710051, 西安)

摘要: 针对图像检索领域中现有哈希算法仅考虑数据的全局信息,同时平等地对待每一维投影数据,导致得到的哈希码不能很好地保持原始数据的相似性的问题,提出利用图像数据局部结构信息的加权哈希(WLSH)算法。该算法同时考虑原始图像空间的局部结构信息和投影数据的各维方差,首先利用数据之间的相似性构建关系矩阵,进而获得原始图像数据的局部结构信息;然后通过迭代量化的方法寻找最优的正交旋转矩阵,使得投影以后的量化误差最小;最后通过权重矩阵平衡各维方差,保证每一维的单位编码信息相同,从而实现对原始数据最优的保距映射。在图像库上的实验结果表明,WLSH 算法应用于图像检索时在查准率和查全率上比主成分分析-迭代量化方法分别提高了 3%和 2%。

关键词: 投影函数;局部结构信息;迭代量化;平衡各维方差;图像检索

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2016)10-0078-08

A Weighted Hashing Algorithm Based on Local Structured Information for Image Retrieval

ZHANG Shengjie¹, ZHA Yufei¹, LI Yunqiang¹, LI Huanyu², YANG Yuan²

(1. School of Aeronautics and Astronautics Engineering, Air Force Engineering University, Xi'an 710038, China;

2. School of Air Control and Navigation, Air Force Engineering University, Xi'an 710051, China)

Abstract: A weighted local structured Hashing (WLSH) method is proposed to address the problem in the field of image retrieval that most existing Hashing methods only consider the global information and treat each projected dimension equivalently, which leads to a problem that the binary codes cannot efficiently preserve the data similarity. The proposed method considers local structure information of original image data and the variance of each projected dimension simultaneously. An affinity weight matrix is built to describe the relationship between data points and to acquire local structure information of the original image data. Then, an iterative quantization is used to find an optimal orthogonal transformation matrix and to minimize the quantization error. Finally, a weighted matrix is used to balance the variances and to guarantee equivalent information of each Hashing bits, thus the data similarity is effectively preserve. Experimental results based on some large scale datasets show that the precision and recall of the WLSH algorithm are improved by 3% and 2% over principal component analysis-iterative quantization, respectively.

Keywords: projection functions; local structure information; iterative quantization; balance the variance; image retrieval

目前,最近邻搜索已经被广泛地应用于数据压缩、模式识别、文档检索等领域。进入大数据时代,如何快速地进行图像检索成为亟待解决的问题。哈希学习^[1]通过学到数据的二进制哈希码表示,使得哈希码尽可能地保持原空间中的近邻关系,节省了存储空间,提高了查询速度,在大数据的最近邻搜索中被广泛应用。

数据独立哈希算法包括局部敏感哈希(locality sensitive Hashing, LSH)算法^[2]以及它的拓展算法^[3-4],通过随机生成一个投影矩阵作为哈希函数,使得相似的样本以较高的概率映射到同一个哈希桶中,但这些算法需要较长的哈希码才能取得理想的精度。数据依赖哈希算法^[5-8]从原始数据中学习出哈希函数,只需较短的哈希码就能取得理想的精度。谱哈希(spectral Hashing, SH)算法^[5]将编码过程视为图分割过程,对高维数据进行谱分析,通过放松约束条件将问题转化成拉普拉斯特征图的降维问题从而求得哈希函数。数据依赖的多索引哈希算法^[6]采用自适应投影的方法使得哈希表中的元素下标接近于均匀分布,进而提升查询速度。线性嵌入哈希算法^[7]利用相关性预测函数保持高维数据与其编码之间的邻近关系,构建线性哈希映射矩阵,获得紧致的哈希编码,提高了图像与编码间的相关性,实现了高精度的图像检索。基于哈希的目录索引算法^[8]将 Hash 表与 B⁺ 树结合从而高效地索引目录的子索引节点。另外,主成分分析哈希(principal component analysis hashing, PCAH)算法^[9]通过主成分分析(PCA)学得投影矩阵。投影之后的各维度方差各不相同,但其将每一维度编码成相同的码长,从而降低了检索性能。迭代量化(iterative quantization, ITQ)哈希算法通过学习一个最优的正交旋转矩阵平衡各维方差,进而减小量化误差,但其不能保证平衡之后的各维方差完全相等。监督哈希算法^[10-11]利用数据的类标信息可以取得很好的检索性能,但是类标信息有限且很难获得。半监督哈希算法^[12]利用少量的标注样本和大量的未标注样本学习得到哈希函数。非监督哈希算法^[9,13]不需要数据的类标信息,但存在诸多限制条件而使性能受到一定影响。

以上传统的哈希算法均存在 2 点不足:一是仅考虑数据的全局信息;二是平等地对待每一维的投影数据,导致得到的哈希码不能很好地保持原始数据的相似性。针对这 2 点问题,本文同时考虑原空间的局部结构信息和投影数据的各维方差,提出了加权局部结构哈希(WLSH)算法。该算法首先利用

数据之间的相似性构建关系矩阵,挖掘原始数据的局部结构信息,继而创建局部结构变换矩阵,对原始样本数据进行线性变换得到一种局部结构数据。然后,将该数据作为训练样本进行主成分分析得到投影函数,通过迭代量化寻找最优的正交旋转矩阵,使得量化误差最小;最后通过权重矩阵平衡各维方差,保证每一维的单位编码信息相同,从而实现对原始数据最优的保距映射。

1 加权局部结构哈希

选取 n 个样本构成样本集合 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, $\mathbf{x}_i \in \mathbf{R}^m$, m 为样本的维度。学习哈希函数的就是为了得到哈希码,即 $h: \mathbf{X} \rightarrow \mathbf{Y} \in \{1, -1\}^{n \times k}$, 哈希函数表示为 $h(\mathbf{x}_i) = \text{sgn}[f(\mathbf{x}_i)]$, $f(\mathbf{x}_i)$ 为投影函数, $\mathbf{Y}$ 为哈希码矩阵形式, k 为哈希函数的个数, $\text{sgn}(\cdot)$ 表示符号函数。

1.1 局部结构数据

为了保持原始数据空间与汉明空间数据结构的一致性,谱哈希(SH)算法^[5]挖掘数据内部的谱性质,通过约束经哈希映射后的二进制编码中某一位(bit)结果为一1或1的概率相等以及二进制哈希码的每一位不相关,从而建立目标函数如下

$$\begin{aligned} \min_{\mathbf{Y}} \quad & \text{tr}(\mathbf{Y}^T \mathbf{L} \mathbf{Y}) \\ \text{s. t.} \quad & \left. \begin{aligned} \mathbf{Y}(i, j) &\in \{-1, 1\} \\ \mathbf{Y}^T \mathbf{1} &= \mathbf{0} \\ \mathbf{Y}^T \mathbf{Y} &= \mathbf{I} \end{aligned} \right\} \end{aligned} \quad (1)$$

式中: $\mathbf{L} = \mathbf{D} - \mathbf{A}$ 表示拉普拉斯矩阵, $\mathbf{A}$ 表示样本之间的对称关系矩阵^[5], $\mathbf{D}$ 是一个对角矩阵,其对角元素 $d_{ij} = \sum_j a_{ij}$ 。SH 算法采用 k 近邻法,原始高维空间的相似度可以通过高斯核度量计算,即 $a_{ij} = \exp\left[-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma_{ij}^2}\right]$, 方差 σ_{ij} 通过一定准则选取。

然而,对于大的数据库而言,传统构建关系矩阵的方法将带来高复杂度,使得计算效率非常低。针对这一问题,目前一些算法通过建立一个锚点图(anchor graph)^[14]去加速谱分析的过程。锚点图是对数据集中所有数据点进行 k 均值聚类后得到的 d 个聚类中心 $\mathbf{U} = \{\mathbf{u}_j \in \mathbf{R}^d\}_{j=1}^m$ 组成的,它可以作为数据集中所有 n 个点的近邻图。锚点图相似矩阵 $\mathbf{z}(x)$ 能通过核回归方法计算得到

$$[\mathbf{z}(x)]_j = \begin{cases} \frac{\kappa(x, \mathbf{u}_j)}{\sum_{\mathbf{u}'_j \in N(x, s)} \kappa(x, \mathbf{u}'_j)}, & \mathbf{u}_j \in N(x, s) \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中: $N(\mathbf{x}, s)$ 表示样本 $\mathbf{x}$ 在 $\mathbf{U}$ 中最近的 s 个锚点, 本文设置 $s=5$ 。

通过相似矩阵 $\mathbf{Z}$, 可以计算对称关系矩阵 $\mathbf{A} = \mathbf{Z}\mathbf{Z}^T$, 进而可求得 $\mathbf{A}$ 的标准化形式

$$\bar{\mathbf{A}} = \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2} = \mathbf{D}^{-1/2} \mathbf{Z} \mathbf{Z}^T \mathbf{D}^{-1/2} = \mathbf{Q} \mathbf{Q}^T \quad (3)$$

式中: $\mathbf{Q} = \mathbf{D}^{-1/2} \mathbf{Z} \in \mathbf{R}^{n \times d}$ 。这里, 定义 $\mathbf{Q}$ 为局部结构变换矩阵, 该矩阵是由锚点图相似矩阵 $\mathbf{z}(x)$ 变换得到, 包含了丰富的局部结构信息。下面将引出由该矩阵变换所得的局部结构数据。

首先, 放宽约束条件 $\mathbf{Y} = \mathbf{X} \mathbf{H}$, $\mathbf{X}$ 表示样本集合, $\mathbf{H}$ 表示投影函数, 再将标准化的拉普拉斯矩阵 $\bar{\mathbf{L}} = \mathbf{I} - \bar{\mathbf{A}}$ 代入式(1), 则目标函数式(1)变为

$$\max_{\mathbf{H}} \text{tr}(\mathbf{H}^T \mathbf{X}^T \mathbf{Q} \mathbf{Q}^T \mathbf{X} \mathbf{H}) \quad (4)$$

令 $\bar{\mathbf{X}} = \mathbf{Q}^T \mathbf{X} \in \mathbf{R}^{d \times m}$, 并将该形式代入式(4), 则目标函数表示为

$$\max_{\mathbf{H}} \text{tr}(\mathbf{H}^T \bar{\mathbf{X}}^T \bar{\mathbf{X}} \mathbf{H}) \quad (5)$$

式(5)目标函数与主成分分析(PCA)在形式上完全相同, 其中, $\mathbf{H}$ 是由 $\bar{\mathbf{X}}^T \bar{\mathbf{X}}$ 进行特征值分解得到的前 k 个最大的特征值对应的特征向量组成。

主成分分析是一种非常经典有效的降维算法, 虽然在变换过程中存在一定程度上的信息损失, 但其绝大部分能量能被保留在前 k 个最大的特征值对应的维度上。哈希算法目的是通过尽可能少的维度去保留尽可能多的能量, 从而实现快速图像检索, 虽然 PCA 变换存在一定程度的信息丢失, 但并不影响对图像进行快速检索。

定义 $\bar{\mathbf{X}} = \mathbf{Q}^T \mathbf{X} \in \mathbf{R}^{d \times m}$ 为局部结构数据, 其中 d 为样本数, m 为样本的维度。该数据可以直观地理解成由局部结构变换矩阵 $\mathbf{Q} \in \mathbf{R}^{n \times d}$ 对原始样本数据进行线性变换所得到的一个新的样本数据。该数据有 2 个特点: ①局部结构数据是在锚点图的基础上变换所得, 样本数等于锚点数 $d < n$; ②该数据是通过挖掘原始样本内部的局部结构性质变换而成, 包含了丰富的局部结构信息。

图 1 是局部结构特征提出和变换示意图。图 1 表示对原始数据 $\mathbf{X}$ 进行局部结构特征提取得到对




图 1 局部结构特征提取和变换示意图

称关系矩阵 $\mathbf{A}$, 然后由学习得到的局部结构变换矩阵 $\mathbf{Q}$ 对原始数据进行线性组合得到局部结构数据。


1.2 迭代量化方法

迭代量化方法^[9]通过旋转主成分方向使得各主成分方向的方差尽量保持平衡。随机生成两组满足高斯分布的数据集, 并将这两组数据集分别进行无旋转、随机旋转、最优旋转的操作, 最终得到如图 2 所示的可以形象表达迭代量化方法的示意图。图中点代表训练样本, 线代表主成分方向。当对这些训练样本进行二值量化, 由图 2a 可知, 同一类样本被不同的哈希编码序列表示了, 即相似的样本落在了不同的哈希桶中。图 2b 对主成分方向进行了一次随机旋转, 使得同一类样本尽可能多地落在相同的哈希桶中。图 2c 是通过迭代量化方法得到的投影向量及哈希码编码序列, 可以看出, 相似的训练样本落在了相同的哈希桶中。

为了寻找到最优的正交旋转矩阵 $\mathbf{R}$, 目标函数可表示为

$$\min Q(\mathbf{Y}, \mathbf{R}) = \|\mathbf{Y} - \mathbf{V} \mathbf{R}\|_F^2 \quad (6)$$

式中: $\mathbf{V} = \mathbf{X} \mathbf{H}^*$ 表示训练样本经主成分分析后的投影数据; $\mathbf{H}^*$ 为投影函数; $\mathbf{Y}$ 代表哈希码矩阵; $\|\cdot\|_F$ 表示 F 范数。



(a) 无旋转 (b) 随机旋转 (c) 最优旋转

图 2 迭代量化方法示意图

1.3 加权平衡方法

迭代量化方法^[9]通过不断迭代降低量化误差, 从而使得每维方差趋于相等, 然而, 这种方式并不能获得相等的方差。本文采用 CIFAR-10 数据库^[16]分别在随机正交旋转(PCA-RR)、10 次和 50 次迭代 3 种情况下对投影数据进行单位化方差与投影数据的比特数关系实验, 结果如图 3 所示。

为了进一步平衡各维方差差异, 运用加权平衡的方法。假设 $\{\lambda_i\}_{i=1}^k$ 表示对训练样本进行主成分分析后选取的前 k 个最大的特征值, 特征值越大的主成分包含的信息量越大; $\{z_i\}_{i=1}^n \in \mathbf{R}^k$ 表示在主成分方向上的投影数据, 其中 $\bar{z} = \frac{1}{n} \sum z_i = 0$; $\{v_i\}_{i=1}^k$ 表示投影数据的方差大小 $v_i = \text{var}(z^i)$ 。则,




图 3 3 种情况下单位化方差与投影数据比特数的关系

$v_i / \sum_{i=1}^k v_i = \lambda_i / \sum_{i=1}^k \lambda_i$, 即方差大小与包含的信息量大小具有一致性, 方差越大, 包含的信息量越大。

同样, 经过迭代量化后同样满足方差大小与信息量大小的一致性。在哈希码编码序列上, 方差越大的维包含的信息量越大, 则需分配的权重值也应更大, 因此可以求得每一位哈希码对应的权值为

$$w_p = v_p / \sum_{i=1}^k v_i \tag{7}$$

2 模型构建及其优化

2.1 模型构建

由 1.1 节所述, 通过构建局部结构变换矩阵 Q 将原始数据 X 转换成局部结构数据 $\bar{X}$, 从而建立目标函数式(5), 式中投影矩阵 H 是由局部结构数据的协方差矩阵 $\bar{X}^T \bar{X}$ 进行特征值分解得到的前 k 个最大的特征值对应的特征向量组成。如果直接采用得到的 H 进行哈希编码, 会导致各维哈希码的方差并不相等。1.2 节采用迭代量化方法去平衡各维方差, 虽然该方法能够有效平衡各维方差, 但并不能保证各维方差相等。1.3 节采用加权的方式去进一步平衡各维方差, 方差越大, 分配的权重值也越大, 若任意给定维数 p , 其权重值 w_p 与方差 v_p 成正比, 即 $w_p / v_p = w_q / v_q$ 。因此, 结合局部结构数据和加权平衡方法, 构建目标函数如下

$$\begin{aligned} & \max_{W, H} \text{tr}(WH^T \bar{X}^T \bar{X} H) \\ & \text{s. t. } \begin{cases} H^T H = I; & \sum_p w_p = 1 \\ \frac{w_p}{v_p} = \frac{w_q}{v_q}; & \forall p, q \end{cases} \end{aligned} \tag{8}$$

式中: W 是一个 $k \times k$ 的对角矩阵, 它的对角元素 w_p 代表每一维哈希码分配的权重; $\sum_p w_p = 1$ 表示各维权重之和为 1; 约束条件 $H^T H = I$ 要求得到的哈

希超平面相互正交。

2.2 模型优化

这一小节将对模型进行优化。为了解决上述问题, 运用固定一个变量, 求解另一变量的方式对模型进行优化求解。

2.2.1 固定 W 计算 H 对每一维哈希码的权重进行初始化, 将各维权重设为等值, 并且约束权重之和等于 1, 则初始化权重矩阵表示为 $W = k^{-1} E$, 其中 k 是哈希码的长度, E 是单位矩阵。将初始化权重矩阵代入式(8), 则目标函数变为

$$\begin{aligned} & \max_H \text{tr}(H^T \bar{X}^T \bar{X} H) \\ & \text{s. t. } H^T H = I \end{aligned} \tag{9}$$

从形式上来看, 目标函数(9)完全相同于 PCAH, 不同的是, 上式将局部结构数据 $\bar{X}$ 作为训练样本, 首先对其进行主成分分析得到投影函数 H^* , 投影函数 H^* 挖掘了原始样本内部的局部结构性质, 保持了更加丰富的局部结构信息。

然后, 应用投影函数 H^* , 得到投影数据 $V = XH^*$, 选择符号函数 $\text{sgn}()$ 作为编码函数, 即可求得哈希码 $Y = \text{sgn}(XH^*)$ 。

然而, 主成分分析得到的投影数据各主成分方向的方差(或信息量)通常各不相等, 迭代量化算法通过旋转主成分方向使得旋转后各方向的方差尽量保持平衡。该方法的目标是通过寻求最优正交矩阵 R , 最小化量化误差

$$\begin{aligned} & \min_R Q(Y, R) = \|Y - VR\|_F^2 \\ & \text{s. t. } R^T R = I \end{aligned} \tag{10}$$

采用迭代量化方法去逼近量化误差最小值, 其交替进行的步骤如下。

- (1) 初始化 R 为随机正交矩阵。
- (2) 固定 R , 更新 $Y = \text{sgn}(XH^* R)$ 。
- (3) 固定 Y , 更新 R 。目标函数变为

$$\min_{R^T R = I} \|Y - VR\|_F^2 \tag{11}$$

式(11)属于正交普克拉提斯问题(orthogonal procrustes problem, OP)^[15], 当 Y 固定时, 求解目标函数式(11)的步骤是先对 $k \times k$ 矩阵 $Y^T V$ 进行奇异值分解——SVD($Y^T V$) = $S \Omega S^T$ (其中 SVD[$\cdot$]表示奇异值分解), 接着得到 $R = \bar{S} S^T$ 。

(4) 当量化误差足够小时, 所得到的正交矩阵 R 和哈希码 Y 即为所求, 实验表明当迭代次数在 40~60 时, 算法趋于平稳, 本文选择迭代 50 次。最终可以求得最优正交旋转矩阵 R 及 $H = H^* R$ 。

2.2.2 固定 H 求解 W 在上一小节中, 固定 W , 通

过优化目标函数式(8),解得了投影函数 $\mathbf{H}$ 。图3表明,迭代量化方法求得的方差并不完全相等,还存在差异性,为了进一步平衡各维方差差异,提出了加权平衡的方法。本小节将利用已经求得的投影函数 $\mathbf{H}$,求解每位哈希码上分配的权重 $\mathbf{W}$ 。首先,求解每位哈希码的方差 $v_i = \text{var}(y^i)$;然后结合公式(7),即可求得权值

$$w_p = v_p / \sum_{i=1}^k v_i \quad (12)$$

总结 WLSH 算法流程如下。

输入 原始样本数据 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, $\mathbf{x}_i \in \mathbf{R}^m$, 哈希码维度 k , 迭代次数 t , 构建锚点图的参数^[14]。

初始化 $\mathbf{W} = k^{-1} \mathbf{E}$ 。

(1) 运用式(1)~(4)构建局部结构数据 $\bar{\mathbf{X}} = \mathbf{Q}^T \mathbf{X}$;

(2) 运用局部结构数据,计算投影函数

$$\mathbf{H}^* \leftarrow \text{PCA}(\bar{\mathbf{X}});$$

(3) for $i = 1:t$;

(4) 固定 $\mathbf{R}$, 更新 $\mathbf{Y}$

$$\mathbf{Y} = \text{sgn}(\mathbf{X}\mathbf{H});$$

(5) 固定 $\mathbf{Y}$, 更新 $\mathbf{R}$

$$\text{SVD}(\mathbf{Y}^T \mathbf{V}) = \mathbf{S} \mathbf{\Omega} \mathbf{S}^T$$

$$\mathbf{R} = \mathbf{S} \mathbf{S}^T;$$

(6) end for;

(7) 用式(12)计算权重矩阵 $\mathbf{W}$ 。

输出 投影函数 $\mathbf{H} = \mathbf{H}^* \mathbf{R}$, 权重矩阵 $\mathbf{W}$ 。

2.3 时间复杂度分析

分别对本文算法的训练和测试时间复杂度进行分析。

训练时间复杂度: 训练时间复杂度主要包括3部分,分别是计算相似度矩阵、PCA变换和迭代量化过程中的时间复杂度。首先,相似矩阵 $\mathbf{Z}$ 的时间复杂度是 $O(dmnT + dmn)$, 其中 T 是 k 均值聚类的次数, d 是聚类中心数, n 是样本数, m 是样本维度。由于 $d \ll n$, 因此锚点图的时间复杂度与样本 n 是线性关系,而采用构建 k 近邻图方法的时间复杂度是 $O(mn^2)$, 与样本 n 是二次关系,因此采用构建锚点图的方式更加快速。其次,对学习到的局部结构数据 $\bar{\mathbf{X}}$ 进行 PCA 变换,其时间复杂度为 $O(\min(n^2 m, nm^2))$ 。最后,采用迭代量化的方法求解 $\mathbf{R}$ 和 $\mathbf{Y}$, 其时间复杂度为 $O(nk^2 + nkm + k^3)$ 。

对于任意一个测试样本,生成哈希码的测试时间复杂度为 $O(mk)$, 相对于一些非线性哈希算法如 SH 和 KLSH, 测试时间复杂度有所降低。虽然本

文算法的训练时间相对于一些算法有所增加,但是测试时间很快,能够满足现实需要。

3 实验结果及分析

3.1 数据集与实验设置

实验选用2个比较常用的数据库 CIFAR-10^[16] 和 MNIST^[12] 来验证本文算法的有效性。

CIFAR-10 含有 60 000 个样本,每个样本维度为 320,该数据库包含飞机、汽车、鸟、猫、鹿、狗、青蛙、马、轮船和卡车 10 个分类,每类数据集有 6 000 个样本。MNIST 是数字手写识别数据库,该数据库中 70 000 个维度为 784 的数据样本。本文随机选取 5 000 个样本作为训练集和 1 000 个样本作为测试集。数据库具体信息如表 1。

所有实验均在 3.06 GHz、6 GB 内存的 64 bit 计算机环境下通过 MATLAB 2013a 软件平台仿真实现。

表 1 2 种数据库的具体信息

数据库	测试集 大小/ 10^3	训练集 大小/ 10^3	分类数	维度
CIFAR-10	1	5	10	320
MNIST	1	5	10	784

3.2 对比算法及评价标准


为验证本文算法的有效性,实验中选用非监督哈希(LSH)算法^[17]、谱哈希(SH)算法^[5]、SKLSH 算法^[18] PCAH 算法^[9]、PCA-RR 算法^[19] 及 PCA-ITQ 算法^[9] 进行比较,其中 SKLSH 算法选用高斯

核函数, $\lambda^2 = \sum_{i=1}^n \sum_{j=1}^m \kappa(\mathbf{x}^{(i)}, \mathbf{x}_j) / n$ 。对基准算法 PCAH 算法、PCA-RR 算法以及 PCA-ITQ 算法分别采用加权平衡方法,得到 WPCAH 算法、WPCA-RR 算法和 WPCA-ITQ 算法,并与基准算法进行对比,以验证本文加权平衡方法的有效性。本文实验采用的评价指标为查准率和召回率。为了构建新的局部结构数据,需要对一些参数^[14] 进行设置。首先,设置锚点数 d ,锚点数决定了局部结构数据的样本数,本文选取 300 个锚点。另外,选取核函数为二次核函数,设置 $s=5$ 。


3.3 实验结果分析

图 4 为在数据库 CIFAR-10 和 MNIST 上,返回 500 幅检索图像时加权平衡算法 WPCAH、WPCA-RR、WPCA-ITQ 和基准算法 PCAH、PCA-RR、PCA-ITQ 的查准率随比特数变化的关系。由图 4

可以看出,对基准算法 PCAH 进行加权平衡,效果提升显著,而对迭代量化算法(ITQ)进行加权平衡效果提升不太明显,因为迭代量化过程也有平衡方差的作用。



(a)CIFAR-10 数据库



(b)MNIST 数据库

图 4 2 个数据库上 6 种对比算法的查准率与比特数关系

图 5 显示了本文算法和比较算法在数据库 CIFAR-10 上哈希码分别为 16、32、64 和 128 bit 时的检索效果。由图 5 可以看出:本文算法在哈希码为 16、64 和 128 bit 时,查准率明显高于其他哈希算法;在 32 bit 时,其他算法有逼近本文算法的趋势。

图 6 表示在数据库 MNIST 上,哈希码为 64 和 128 bit 时查准率和查全率随检索样本数的关系。在数据库 MNIST 上,由于 SKLSH 算法的不具有可比性,因此未选用该算法作为对比算法。由图 6 可以看出,本文算法在 64 bit 和 128 bit 时查准率和查全率都明显高于其他哈希算法。

图 7 表示了图像库 CIFAR-10 和 MNIST 上,当返回 500 幅检索图像时的查准率随比特数变化的关系。图 7 同样反映了图 5 和图 6 的问题:当哈希码在 32 bit 时,其他算法有逼近本文算法的趋




图 5 数据库 CIFAR-10 上 5 种算法在不同比特数下的查准率与返回检索样本数的关系






图 6 数据库 MNIST 上 5 种算法在不同比特数下的查准率和查全率与返回检索样本数的关系


势;在 32 bit 之后,查准率随着比特数增加呈不断上升趋势。

4 结 论

本文提出了一种加权局部结构哈希算法——



(a) CIFAR-10 数据库



(b) MNIST 数据库

图7 2种数据库上8种对比算法的查准率与比特数关系

WLSH,相比于以往哈希算法,该算法同时考虑了原空间的局部结构信息和投影数据的各维方差大小,最大程度的减少了信息损失。在2个大的数据库上进行图像检索,实验结果表明,该算法在所有比特数上的查准率和查全率都高于其他相关算法。

但是,该方法在取得优异性能的同时也存在着一定的问题和不足,主要体现在两个方面:一是算法中参数过多,在一定程度上增加了算法的复杂性,降低了实时性;二是对数据进行主成分分析过程本身会造成一定的信息损失。这些问题都有待通过进一步的研究来解决和完善。

参考文献:

- [1] 李武军,周志华. 大数据哈希学习: 现状与趋势 [J]. 科学通报, 2015, 60(5/6): 485-490.
LI Wujun, ZHOU Zhihua. Learning to Hash for big data: current status and future trends [J]. Chin Sci Bull, 2015, 60(5/6): 485-490.
- [2] GIONIS A, INDYK P, MOTWANI R. Similarity search in high dimensions via Hashing [C]// International Conference on Very Large Data Bases. New

York, USA: ACM, 2000: 518-529.

- [3] KULIS B, JAIN P, GRAUMAN K. Fast similarity search for learned metrics [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2143-2157.
- [4] 赵永威,李弼程,彭天强,等. 一种基于随机化视觉词典组和查询扩展的目标检索方法 [J]. 电子与信息学报, 2012, 34(5): 1154-1161.
ZHAO Yongwei, LI Bicheng, PENG Tianqiang, et al. An object retrieval method based on randomized visual dictionaries and query expansion [J]. Journal of Electronics & Information Technology, 2012, 34(5): 1154-1161.
- [5] WEISS Y, TORRALBA A, FERGUS R. Spectral hashing [C]// Proceedings of the 22nd Annual Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT, 2008: 1753-1760.
- [6] 马艳萍,姬光荣,邹海林,等. 数据依赖的多索引哈希算法 [J]. 西安电子科技大学学报, 2015, 42(4): 159-164.
MA Yanping, JI Guangrong, ZOU Hailin, et al. Data-oriented multi-index Hashing [J]. Journal of Xidian University, 2015, 42(4): 159-164.
- [7] 王秀美,丁利杰,高新波. 一种相似度保持的线性嵌入哈希方法 [J]. 西安电子科技大学学报, 2016, 43(1): 94-98.
WANG Xiumei, DING Lijie, GAO Xinbo. Linear embedding Hashing method in preserving similarity [J]. Journal of Xidian University, 2016, 43(1): 94-98.
- [8] 刘贤焯,王劲林,朱明,等. Hash表与B⁺树相结合的高效目录索引结构 [J]. 西安交通大学学报, 2013, 47(4): 105-111.
LIU Xianzhuo, WANG Jinlin, ZHU Ming, et al. Effective directory index framework taking advantages of Hash table and B⁺ tree [J]. Journal of Xi'an Jiaotong University, 2013, 47(4): 105-111.
- [9] GONG Y C, LAZEBNIK S. Iterative quantization: a procrustean approach to learning binary codes for large scale image retrieval [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(12): 2916-2929.
- [10] LIN G S, SHEN C H, SHI Q F, et al. Fast supervised Hashing with decision trees for high-dimensional data [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE Computer Society, 2014: 1971-1978.
- [11] WANG Q F, SHEN B, WANG S M, et al. Binary

- codes embedding for fast image tagging with incomplete labels [C]// 13th European Conference on Computer Vision. Berlin, Germany: Springer-Verlag, 2014: 425-439.
- [12] WANG J, KUMAR S, CHANG S F. Semi-supervised Hashing for scalable image retrieval [C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2010: 3424-3431.
- [13] XIA Y, HE K M, KOHLI P, et al. Sparse projections for high-dimensional binary codes [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE, 2015: 3332-3339.
- [14] LIU W, WANG J, KUMAR S, et al. Hashing with graphs [C]// Proceedings of the 28th International Conference on Machine Learning. New York, USA; Association for Computing Machinery, 2011: 1-8.
- [15] SCHONEMANN P. A generalized solution of the orthogonal Procrustes problem [J]. Psychometrika, 1966, 31(1): 1-10.
- [16] LENG Cong, CHENG Jian, YUAN Ting, et al. Learning binary codes with Bagging PCA [C]// Proceedings of European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases. Berlin, Germany: Springer Verlag, 2014: 177-192.
- [17] LIU X L, HE J F, DENG C, et al. Collaborative Hashing [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE Computer Society, 2014: 2147-2154.
- [18] RAGINSKY M, LAZEBNIK S. Locality-sensitive binary codes from shift-invariant kernels [C]// 23rd Annual Conference on Neural Information Processing Systems. Red Hook, NY, USA; Curran Associates Inc., 2009: 1509-1517.
- [19] JEGOU H, DOUZE M, SCHMID C, et al. Aggregating local descriptors into a compact image representation [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA; IEEE Computer Society, 2010: 3304-3311.

(编辑 刘杨)

(上接第 48 页)

- [8] 郭前建. 数控滚齿机几何误差与热误差实时补偿技术研究 [D]. 上海: 上海交通大学, 2008: 26-44.
- [9] 王时龙, 杨勇, 周杰, 等. 大型数控滚齿机热误差补偿建模 [J]. 中南大学学报(自然科学版), 2011, 42(10): 3066-3072.
- WANG Shilong, YANG Yong, ZHOU Jie, et al. Modeling of thermal error compensation of large-scale numerical control gear hobbing machine [J]. Journal of Central South University (Science and Technology), 2011, 42(10): 3066-3072.
- [10] 王时龙, 祁鹏, 周杰, 等. 数控滚齿机热变形误差分析与补偿新方法 [J]. 重庆大学学报, 2011, 34(3): 13-17.
- WANG Shilong, QI Peng, ZHOU Jie, et al. Thermal deformation error analysis and a novel compensation method for NC gear hobbing machine tools [J]. Journal of Chongqing University, 2011, 34(3): 13-17.
- [11] 杨勇, 王时龙, 周杰, 等. 基于自动编程系统的大型滚齿机热误差补偿 [J]. 计算机集成制造系统, 2013, 19(3): 569-576.
- YANG Yong, WANG Shilong, ZHOU Jie. Thermal error compensation of large-scale numerical control gear hobbing machine based on the automatic programming [J]. Computer Integrated Manufacturing Systems, 2013, 19(3): 569-576.
- [12] 杨勇. 大型数控滚齿机加工误差及补偿研究 [D]. 重庆: 重庆大学, 2012: 127-143.
- [13] 商向东. 齿轮加工精度 [M]. 北京: 机械工业出版社, 1999: 85-119.
- [14] 吴焱明, 陶晓杰. 齿轮数控加工技术的研究 [M]. 合肥: 合肥工业大学出版社, 2005: 81-96.
- [15] 吴序堂. 齿轮啮合原理 [M]. 2 版. 西安: 西安交通大学出版社, 2009: 126-172.
- [16] 陈永鹏. 高速干切滚齿多刃断续切削空间成形模型及其基础应用研究 [D]. 重庆: 重庆大学, 2015: 73-75.

(编辑 杜秀杰)