

DOI: 10.7652/xjtuxb201708004

自适应多位编码量化的哈希图像检索方法

徐思雨, 蔡佳妮, 祝继华, 王佳星, 栾婷婷, 庞善民
(西安交通大学软件学院, 710049, 西安)

摘要: 针对目前哈希图像检索技术中多比特位量化方法通过将实数向量的每一维分别量化, 割裂了实数向量各个维度之间联系的问题, 提出了一种子空间自适应多位编码量化的哈希图像检索方法。该方法对一组实数做量化并且拓展到乘积空间, 将实数向量划分为若干个数据子向量。由于子空间的方差和信息量大小呈正相关, 该方法可根据子空间的方差计算并分配编码位数, 使方差大的子空间拥有更长的编码位数, 并且减小了因给不同的子空间分配相同的比特位而引起的信息损失, 提高了编码的精度。在公开的图像数据集 LabelMe 和 Flickr 上的测试结果表明: 与效果最优的同类方法相比, 该方法使得量化误差下降了 30%, 检索结果的平均准确率提升了 9.8%, 说明可以通过减小量化误差来提升检索精度。

关键词: 哈希图像检索; 方差; 数据子向量; 自适应多位编码
中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2017)08-0019-07

An Adaptive Hashing retrieval Method of Images Based on Multi-Bit Quantization

XU Siyu, CAI Jiani, ZHU Jihua, WANG Jiaxing, LUAN Tingting, PANG Shanmin
(School of Software Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Multi-bit quantization is a popular quantization approach in hashing method to retrieve images, but it separately quantizes each dimension of real values, thus may destroy the original neighborhood structure. In this paper, an adaptive multi-bit quantization method is proposed. The method decomposes the original data space into several subspaces and then extends them to a product space. Since there exists a positive correlation between the variance of each subspace and the amount of information in the subspace, the proposed method adaptively allocates the numbers of bits according to the variance of the subspaces and gives more bits to the subspace with larger variance. The proposed adaptive multi-bit quantization scheme makes the hashing method effectively decrease the distortion compared to those which allocating same bits to different subspaces, and greatly increases coding efficiency. Experiments on two large public image datasets, LabelMe and Flickr, and comparisons with some state-of-the-art hashing methods show that the proposed method reduces the quantization error by 30%, and improves the average accuracy of the retrieval results by up to 9.8%, indicating that the proposed method can largely improve the retrieval efficiency by reducing the quantization error.

Keywords: hashing image retrieval; variance; data subspace; adaptive multi-bit quantization

基于内容的图像检索是计算机视觉中的经典问题。哈希图像检索方法通过哈希函数将图像的特征压缩编码成二进制哈希码,使得哈希码尽可能地保持原空间中的近邻关系。使用哈希码之间的汉明距离度量图像间的相似度既节省了存储空间,又提高了检索速度^[1],因此哈希图像检索方法是提高图像检索效率的有效途径。

哈希图像检索方法分为投影和量化两个步骤:投影即为对原始空间的数据降维,得到低维空间的实数向量表示;量化即为对得到的实数向量量化,得到二进制哈希码。投影时根据是否利用图像的监督信息(如类别标签)分为非监督哈希方法^[2-5]、监督哈希方法^[6-8]和半监督哈希^[9-11]方法。

非监督哈希方法利用图像数据特征生成紧凑的二进制编码。局部敏感哈希(LSH)是其中的经典方法,且在相继的研究中建立多索引重排二进制编码可以提高检索效率^[2],但由于在构造哈希函数过程中并没有利用数据本身,所以检索准确率不高;谱哈希(SH)将问题转换成拉普拉斯特征图的降维问题来求解哈希码,提高了检索精度^[3];迭代量化方法学习最优旋转矩阵来减小量化误差,又进一步提高了检索精度^[5]。利用图像的标签信息对哈希函数进行训练,即为监督哈希方法。离散监督哈希方法通过解决一个正则化的子问题,可以处理大规模数据集^[6];基于核的监督哈希用带标签数据学习得到哈希函数,将各个数据分别输入哈希函数,得到所有图像数据的哈希编码序列^[7]。与非监督哈希方法相比,监督哈希方法在检索精度上有了提高。半监督哈希方法利用一小部分带有标签的图像数据作为监督信息,避免过拟合,提高了算法的泛化能力^[10]。

在量化阶段,大多数哈希学习方法仅通过某个预定的阈值将实数向量二值化得到二进制哈希码,这破坏了数据的原始空间结构,检索准确率不高。非对称哈希^[12]、双比特位量化哈希^[14]和曼哈顿哈希^[16]采用了多比特位量化,与单比特位量化相比,多比特位量化方法在检索准确度上有了较大提高^[17]。

目前的多比特位量化方法通过将实数向量的每一维分别量化,割裂了实数向量各个维度之间的联系。为此,相似性保持量化方法^[18]将对象量化为一个向量^[19]。同时扩展到乘积空间,将一个实数向量划分为若干个子向量,形成若干个数据子空间,但是该方法存在着将不同信息量的子空间量化成相同比特位的编码的问题。本文提出一种根据子空间信息量的大小自适应地分配多比特位的量化算法,使得

信息量大的子空间拥有更长的比特位编码。

1 自适应多位编码量化的哈希方法

1.1 传统哈希方法存在的问题

每个子空间的信息量不相同,信息量越大的子空间越重要。传统哈希方法使用与具有较多信息量的子空间相同位数的码字来量化具有较少信息量的子空间,会产生码字的冗余,而如果使用与具有较少信息量的子空间相同位数的码字来量化具有较多信息量的子空间,则部分信息将丢失,导致量化误差变大,因此,可利用投影数据的信息量大小来优化子空间编码分配策略,减小量化误差,提高检索精度。

1.2 子空间数据分布

对于 n 个原始图像 $\mathbf{S} = \{\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n\}$, $\mathbf{s}_k \in \mathbb{R}^D$, $k=1, 2, \dots, n$, 经过投影函数 $f(\mathbf{s}_k)$ 降维后的数据集表示为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, $\mathbf{x}_k \in \mathbb{R}^d$, 其中 $\mathbf{x}_k$ 表示 $\mathbf{s}_k$ 经过降维投影后的向量,即 $\mathbf{x}_k = f(\mathbf{s}_k)$, 设 $\mathbf{x}_k$ 编码为 b 位的二进制码 $\mathbf{c}_{y_k}$, 则经过编码量化后的数据集表示为 $\mathbf{C}_y = \{\mathbf{c}_{y_1}, \mathbf{c}_{y_2}, \dots, \mathbf{c}_{y_n}\}$, $\mathbf{c}_{y_k} \in \{0, 1\}^b$ 。将投影空间 $\mathbf{X}$ 分解为 m 个维度为 a 的子空间 $\mathbf{Y}_i$, $a = d/m$, $i=1, 2, \dots, m$, 每个子空间 $\mathbf{Y}_i$ 通过哈希量化学学习函数 $h_i(\cdot)$ 生成 2^{b_i} 个子码字, 并且 $\sum_{i=1}^m b_i = b$ 。对于任意 $\mathbf{x}_k$, 设其位于第 i 个子空间的子向量为 $\mathbf{x}_k^i$, $\mathbf{x}_k^i$ 通过 $h_i(\cdot)$ 生成长度为 b_i 的码字 $\mathbf{c}_{y_k}^i = h_i(\mathbf{x}_k^i)$, 连接 m 个子空间的所有码字, 可形成 $\mathbf{c}_{y_k}$ 。

在信息理论中,方差和熵是信息量的测量标准,本文选择方差作为信息量的度量。图1给出了数据集 CIFAR10 经过局部敏感哈希(LSH)、主成分分析(PCA)、谱哈希(SH)投影降维至 32 位后每个维度方差的分布情况。

使用 $\mathbf{Y}_i$ 的平均方差 $A(\mathbf{Y}_i)$ 来描述 $\mathbf{Y}_i$ 的信息量大小, $A(\mathbf{Y}_i)$ 的定义为

$$A(\mathbf{Y}_i) = \sum_{j=1}^a v(\mathbf{Y}_i^j) / a \quad (1)$$

式中: $v(\mathbf{Y}_i^j)$ 表示 $\mathbf{Y}_i$ 的第 j 维数据的方差 $j=1, 2, \dots, a$ 。定义整个投影数据空间 $\mathbf{X}$ 的信息量

$$S(\mathbf{X}) = \sum_{i=1}^m (A(\mathbf{Y}_i)) \quad (2)$$

2 子空间自适应编码量化策略

2.1 子空间编码位数粗分配

直观上,子空间二进制哈希码的比特位数应与子空间方差成比例。如图2所示,将 $\mathbf{X}$ 分为 4 个子




图1 CIFAR10数据集经过不同方法投影后的各个维度方差分布

空间,且4个子空间的方差依次增大,为保留原始空间的邻近结构,应使用更多的比特位编码具有更大方差的子空间,即使得 $b_1 > b_2 > b_3 > b_4$ 。




图2 CIFAR10数据集经过PCA投影后划分的4个子空间方差的分布直方图

对于给定长度为 b 的二进制编码,平均到每比特位上的方差为 $\mu = S(\mathbf{X})/b$,则 μb_i 表示子空间 $\mathbf{Y}_i$ 分配 b_i 比特位后的平均方差, μb_i 应与 $\mathbf{Y}_i$ 实际的平均方差 $A(\mathbf{Y}_i)$ 尽量接近。问题描述为

$$\begin{aligned} \min_{b_i} & \sum_{i=1}^m \|\mu b_i - A(\mathbf{Y}_i)\|^2 \\ \text{s. t. } & b_i \in \mathbb{N}^+, i = 1, \dots, m \end{aligned} \quad (3)$$

求解式(3),可以得到如下近似解

$$b_i = \lfloor bA(\mathbf{Y}_i)/S(\mathbf{X}) + 0.5 \rfloor \quad (4)$$

式中: $\lfloor \cdot \rfloor$ 表示向下取整。式(4)完成了根据子空间方差的大小来确定每个子空间的比特编码位数的粗分配。

2.2 编码分配优化

根据式(4)得到的子空间 $\mathbf{Y}_i$ 的比特编码位数分配存在以下两个问题。

(1) 若部分子空间的 $A(\mathbf{Y}_i)$ 值非常接近,且 $A(\mathbf{Y}_i)$ 的值又比较小,例如,假设 $A(\mathbf{Y}_i)$ 是投影数据集中第 p 个子空间的平均方差, $1 \leq p \leq m$, 那么当满足 $A(\mathbf{Y}_p) < 0.5 \sum_{i=1}^m A(\mathbf{Y}_i)/b$ 时,将会导致 $b_p = 0$ 并且 $\sum_{i=1}^m b_i \neq b$, 这与限定条件 $\sum_{i=1}^m b_i = b$ 不符。

为了解决该问题,本文参考多比特位量化方法^[17],将式(4)所表示的子空间编码分配方案调整为

$$b_i = \begin{cases} \left\lfloor 0.5 + bA(\mathbf{Y}_p) / \sum_{i=p}^m A(\mathbf{Y}_i) \right\rfloor, & p = 1 \\ \left\lfloor 0.5 + (b - \sum_{j=1}^{p-1} b_j)A(\mathbf{Y}_p) / \sum_{i=p}^m A(\mathbf{Y}_i) \right\rfloor, & p > 1 \end{cases} \quad (5)$$

根据式(5)可知,若 $b_p = 0$, 且 $\sum_{j=1}^{p-1} b_j \neq b$, 人为设定 $b_p = 1$, 则分配得到的第 i 个子空间哈希编码长度 b_i 满足了限定条件 $\sum_{i=1}^m b_i = b$ 。

(2) 对于第 i 个子空间,分配得到 d_i 位哈希编码,可以产生 2^{d_i} 个用于量化的子码字,与固定子空间相同编码位数的量化方法相比,每个子空间可以产生大小为 $2^{b/m}$ 的子码字,则可以通过对子空间个数 m 的控制实现对子码字大小的控制,而本文提出的根据子空间方差/信息量大小的自适应多位编码的分配策略无法实现对子码字大小的控制,从而可能产生问题:当投影数据集的大小 $n < 2^{b_i}$ 时,将会导致不足以生成 2^{b_i} 组子码字。

为解决该问题,本文先计算最大编码分配

$$b_{\max} = \lfloor \lg n \rfloor \quad (6)$$

根据式(6)计算出第 i 个子空间编码的初分配 b_i , 由于 $b_{\max}$ 的限制,因此,可以对 b_i 进行优化

$$b_i = \begin{cases} b_i, & b_i \leq b_{\max} \\ b_{\max}, & b_i > b_{\max} \end{cases} \quad (7)$$


至此,完成了根据子空间信息量分布,得到第 i 个子空间满足 $\sum_{i=1}^m b_i = b$ 的哈希编码 b_i 的分配及

优化。

2.3 非对称距离

在查询阶段,为提高量化精度,需要搭配快速近似距离计算^[15]以得到与查询图片相似的图片。根据是否将查询向量量化为二进制哈希码,计算向量间近似欧氏距离的方法可分为对称距离计算和非对称距离计算^[20]。

两种距离的计算方式如图 3 所示。对于给定的查询向量 $\mathbf{x}_2$ 和数据集中任一向量 $\mathbf{x}_1$,对称距离计算方法计算这两个向量量化后各自码字 $\mathbf{c}_{y1}$ 和 $\mathbf{c}_{y2}$ 间的距离,而非对称距离计算查询向量 $\mathbf{x}_2$ 本身与数据集中的向量 $\mathbf{x}_1$ 量化后的码字 $\mathbf{c}_{y1}$ 的距离。非对称距离比对称距离误差上界小^[20],因此利用非对称距离提高图像查询精度。



(a) 对称距离 (b) 非对称距离

图 3 编码间的对称距离与非对称距离计算示意图

Albert 提出了一种基于期望值的非对称距离算法^[21],对于样本 $\mathbf{x}, \mathbf{y}$,非对称距离定义为

$$d_E(\mathbf{x}, \mathbf{y}) = \sum_k d(\mathbf{f}_k(\mathbf{x}), E[\mathbf{f}_k(\mathbf{u}) \mid h_k(\mathbf{u}) = h_k(\mathbf{y})]) \quad (8)$$

式中: $d(\cdot)$ 表示欧氏距离; E 表示期望; $d_E(\cdot)$ 为查询向量 $\mathbf{f}_k(\mathbf{x})$ 与中间数据 $\mathbf{f}_k(\mathbf{u})$ 的对应期望之间的欧氏距离,使得 $h_k(\mathbf{u}) = h_k(\mathbf{y})$,其中 $h_k(s) = q_k[\mathbf{f}_k(s)]$ 。

本文利用 $d_E(\cdot)$ 的概念调整并满足自适应多位编码量化。每个子空间 $\mathbf{Y}_i$ 分配 b_i 位编码,得到 2^{b_i} 个 Voronoi 单元的向量集合 $\mathbf{H}^i = [\mathbf{H}_1^i, \mathbf{H}_2^i, \dots, \mathbf{H}_{l_i}^i], l_i = 2^{b_i}$,离线计算每个 Voronoi 单元的期望值 $\mathbf{c}_t^i$,其中 $t = 1, 2, \dots, l_i$,得到 $\mathbf{Y}_i$ 的码书 $\mathbf{C}^i = \{\mathbf{c}_1^i, \mathbf{c}_2^i, \dots, \mathbf{c}_{l_i}^i\}$ 。

$$\mathbf{c}_t^i = \sum_{\mathbf{x}_j^i \in \mathbf{H}_t^i} \mathbf{x}_j^i / |\mathbf{H}_t^i|, \quad t = 1, 2, \dots, l_i \quad (9)$$

式中: $\mathbf{x}_j^i$ 为 $\mathbf{Y}_i$ 内属于第 t 个码字的数据; $|\mathbf{H}_t^i|$ 表示 $\mathbf{Y}_i$ 内属于第 t 个码字的数据的数目。

设查询向量为 $\mathbf{e}$,经过投影后得到 $\mathbf{g} = f(\mathbf{e})$,将 $\mathbf{g}$ 划分成 m 个不相交的子向量 $\mathbf{g} = [\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_m]$,

数据集中的数据经过投影后为 $\mathbf{x}_k$,则 $\mathbf{g}$ 和 $\mathbf{x}_k$ 之间的非对称距离定义为

$$d_E(\mathbf{g}, \mathbf{x}_k) = \sum_{i=1}^m \left[\sum_t (\mathbf{g}_i - \mathbf{c}_t^i)^2 \right]^{1/2}, \quad t = 1, 2, \dots, l_i \quad (10)$$

为了进一步加快检索速度,非对称距离支持离线构建查找表进行快速计算。如果每个子码书包含 k^i 个子码字,则预先存储 m 个 $1 \times k^i$ 的查找表,当需要计算子向量和子码书间的距离时,一次查找只需与每个码书间进行一次计算,查询效率依然很高。

3 实验结果与对比

3.1 实验数据设置

选取了 LabelMe-22000 和 Flickr-15000 两个常用的公开数据集进行实验。LabelMe-22000 数据集包含了 22 019 张图像数据,提取了这些图像的 GIST 特征,每幅图像用 512 维 GIST 特征向量表示;Flickr-15000 数据集包含了 14 660 张图像数据,这些图像被分成了 33 个类别,使用 512 维的 GIST 特征向量表示每幅图像。

本文算法与 Jegou 等提出的基于固定长度编码量化的哈希算法(PQ)^[20]和 Ge 等提出的特征值分配的子空间分割的贪心算法(OPQ)^[13]进行对比,本节将选取相同的投影算法对 3 个量化算法进行对比。

设数据经过投影后的维度为 d ,每个子空间维度为 s ,则划分的子空间个数 $m = d/s$ 。由表 1 可知, s 取值越大检索性能越好, $s = 8$ 是平衡了效率和效果的合理取值,本文设定 $s = 8$ 为子空间的维数。

表 1 LabelMe-22000 数据集中不同子空间维数取值中的平均准确率对比

子空间 维数	平均准确率			
	16 位	32 位	48 位	64 位
2	0.091 8	0.162 7	0.249 1	0.317 4
4	0.123 3	0.222 4	0.352 8	0.456 7
8	0.171 7	0.344 3	0.458 6	0.548 4

表 2 和表 3 给出了不同编码位数下,LabelMe-22000 和 Flickr-15000 数据集中使用本文算法后各个子空间比特位分配情况。采用主成分分析作为投影函数,子空间的信息量依次递减,具有更多信息量的子空间分配到了更多的比特位编码。

3.2 实验结果分析

为测试效果,首先比较了本文算法与其他算法在量化过程中产生的量化误差。分别在 LabelMe-

表 2 LabelMe-22000 数据集中子空间自适应编码分配

编码位数	子空间编码分配
16	{13,3}
32	{14,10,5,3}
48	{14,14,8,5,4,3}
64	{14,14,12,8,6,4,3,3}

表 3 Flickr-15000 数据集中子空间自适应编码分配

编码位数	子空间编码分配
16	{13,3}
32	{16,8,5,3}
48	{13,13,9,6,4,3}
64	{16,16,9,7,5,4,4,3}

22000 和 Flickr-15000 数据集上进行实验,每个投影子空间的维度划分为 8 维。

实验结果见表 4、表 5,随着编码长度的增加,本文算法产生的量化误差随之减小,虽然子空间的增加带来了更高的量化误差,但是算法通过自适应地分配子空间不同大小的编码,减小了量化误差,且减小的幅度大于增加的幅度。表 6、表 7 比较了 3 种不同算法在 LabelMe-22000 和 Flickr-15000 数据集上的检索平均准确率,可见与同类算法相比,本文算法提高了平均准确率。

当哈希编码是 16,32,48 和 64 位的情况下,图 4 和图 5 分别给出了当检索返回图片数不同时,3 个

表 4 LabelMe-22000 数据集上的量化误差对比

编码位数	量化误差		
	PQ 算法	OPQ 算法	本文算法
16	0.202 2	0.175 5	0.139 6
32	0.248 3	0.181 6	0.126 3
48	0.272 6	0.176 6	0.117 2
64	0.288 3	0.166 7	0.108 0

表 5 Flickr-15000 数据集上的量化误差对比

编码位数	量化误差		
	PQ 算法	OPQ 算法	本文算法
16	0.200 6	0.177 4	0.142 5
32	0.249 1	0.189 6	0.132 1
48	0.273 5	0.184 1	0.120 9
64	0.288 5	0.175 2	0.113 0

表 6 LabelMe-22000 数据集上的平均准确率对比

编码位数	平均准确率		
	PQ 算法	OPQ 算法	本文算法
16	0.163 8	0.174 3	0.171 7
32	0.240 4	0.324 1	0.344 3
48	0.298 9	0.451 6	0.458 6
64	0.322 0	0.536 9	0.548 4

表 7 Flickr-15000 数据集上的平均准确率对比

编码位数	平均准确率		
	PQ 算法	OPQ 算法	本文算法
16	0.377 8	0.417 3	0.443 2
32	0.501 6	0.609 8	0.642 9
48	0.550 3	0.712 6	0.732 0
64	0.575 0	0.782 5	0.786 2

算法在召回率曲线与 3 个算法的准确率-召回率曲线。由图 4 可知,随着 N 的增加,3 种算法的召回率都随之增加,并且本文算法的前 1 000 个返回的召回率在不同编码位数下均高于其他 2 种算法。由图 5 可知,综合考虑准确率和召回率,本文算法在不同比特位下检索性能整体较好。

为了排除投影算法对本文算法的影响,同样测试了在不同的投影算法下本文算法与其他量化编码算法的比较。表 8 给出了 LabelMe-22000 数据集经




图 4 不同算法当编码长度不同时的召回率曲线




图 5 不同算法当编码长度不同时的准确率-召回率曲线

PCA、LSH、SH 降维到 32 位空间,再使用 PQ、OPQ 和本文算法量化后的检索平均准确率。由实验结果可知,本文算法在不同的投影算法时可以达到最好的检索效果,这表明检索性能的提升主要归因于量化阶段的编码的自适应分配。

表 8 不同投影算法时使用不同量化算法的平均检索准确率比较

投影算法	平均准确率		
	PQ 算法	OPQ 算法	本文算法
PCA	0.240 4	0.324 1	0.344 2
LSH	0.180 4	0.211 1	0.214 5
SH	0.254 8	0.242 0	0.265 9

图 6 给出了图像检索示例,表示在 Flickr-15000 数据集中使用 16 位编码,随机抽取两幅图像作为查询图像,返回数据集中与检索图像相似的前 20 幅图像,查询图像 id 是 773 199。图 6a~图 6c 分别是查询图像 773 199 通过 PQ、OPQ 和本文算法的检索示例。其中,检索结果的相关性排序从左到右、从上到下增大,检索的错误结果用方框标注出来。由图 6 可知,与其他哈希算法相比,本文算法效果得到提升。

4 结 语

传统的哈希图像检索方法在量化阶段对各空间




图 6 图像检索示例

给予固定长度的编码,这种方式会增加编码过程中的信息损失量。针对该问题,本文提出了自适应多位编码量化的方法,该方法通过计算子空间的方差大小分配编码位数。由于方差是测量信息量的标准之一,量化划分的子空间的方差越大信息量也越大,所获得比特编码位数越多。改进的编码方式可有效地提高编码效率,减少编码过程中的信息损失,从而改善哈希图像检索方法的性能。在公开数据集上的实验结果表明,本文算法在准确率、召回率方面均优于传统的编码方法。

参考文献:

- [1] 张胜杰, 查宇飞, 李运强, 等. 一种利用局部结构信息的加权哈希图像检索算法 [J]. 西安交通大学学报, 2016, 50(10): 78-85.
ZHANG Shengjie, ZHA Yufei, LI Yunqiang, et al. A weighted hashing algorithm based on local structured information for image retrieval [J]. Journal of Xi'an Jiaotong University, 2016, 50(10): 78-85.
- [2] ZHANG Xiaoyu, WANG Manlin, CUI Jiangtao. Efficient indexing of binary LSH for high dimensional nearest neighbor [J]. Neurocomputing, 2016, 213: 24-33.
- [3] WEISS Y, TORRALBA A, FERGUS R. Spectral hashing [C]// Proceedings of the Annual Conference on Neural information processing Systems. Cambridge, Massachusetts, USA: MIT Press, 2009: 1753-1760.
- [4] HEO J P, LEE Y, HE J, et al. Spherical hashing [C]// Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2012: 2957-2964.
- [5] GONG Y, LAZEBNI S, GORDO A, et al. 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.
- [6] SHEN Fumin, SHEN Chunhua, LIU Wei, et al. Supervised discrete hashing [C]// Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, IEEE, 2015: 1556-1564.
- [7] LIU W, WANG J, JI R, et al. Supervised hashing with kernels [C]// Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2012: 2074-2081.
- [8] GUI Jie, LIU Tongliang, SUN Zhenan. Fast supervised discrete hashing [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, PP (99): 1.
- [9] WU Chenxia, ZHU Jianke, CAI Deng, et al. Semi-supervised nonlinear hashing using bootstrap sequential projection learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2013, 25(6): 1380-1393.
- [10] WANG Jun, KUMAR S, CHANG S F. Semi-supervised hashing for scalable image retrieval [C]// Proceedings of the 2010 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2010: 3424-3431.
- [11] KAN Meina, XU Dong, SHAN Shiguang, et al. Semisupervised hashing via kernel hyperplane learning for scalable image search [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2014, 24(4): 704-713.
- [12] WENG Zhenyu, SUN Ziqiang, ZHU Yuesheng. Asymmetric hashing with multi-bit quantization for image retrieval [J]. Neurocomputing, 2016, 207: 71-77.
- [13] GE Tiezheng, HE Kaiming, KE Qifa, et al. Optimized product quantization for approximate nearest neighbor search [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2013: 2946-2953.
- [14] KONG Weihao, LI Wujun. Double-bit quantization for Hashing [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI, 2012: 137-138.
- [15] WANG Zhe, LIN Jie, DUAN Lingyu. Hamming compatible quantization for Hashing [C]// Proceedings of the International Joint Conferences on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2015: 2298-2304.
- [16] KONG Weihao, LI Wujun, GUO Minyi. Manhattan hashing for large-scale image retrieval [C]// Proceedings of the 35th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2012: 45-54.
- [17] GUO Qinzen, ZENG Zhi, ZHANG Shuwu. Adaptive bit allocation hashing for approximate nearest neighbor search [J]. Neurocomputing, 2015, 151: 719-728.
- [18] WANG Zhe, DUAN Lingyu, HUANG Tiejun, et al. Affinity preserving quantization for Hashing: a vector quantization approach to compact learn binary codes [C]// Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2016: 1102-1108.
- [19] GERSHO A, GRAY R M. Vector quantization and signal compression [J]. Springer International, 1992, 159(1): 407-485.
- [20] JEGOU H, DOUZE M, SCHMID C. Product quantization for nearest neighbor search [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(1): 117-128.
- [21] GORDO A, PERRONNIN F, GONG Y, et al. Asymmetric distances for binary embeddings [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(1): 33-47.

(编辑 武红江)