

文章编号: 2095-4980(2021)02-0313-06

基于三元组损失函数的深度人脸哈希方法

郑大刚, 刘光杰, 茅耀斌*, 胥安东, 项文波

(南京理工大学 自动化学院, 江苏 南京 210094)

摘要: 大规模人脸数据集上的快速检索是人脸识别应用的关键问题。较短长度人脸哈希方法可降低人脸特征比对的计算量, 有助于大规模人脸识别的应用。为此提出了一种基于三元组损失函数的深度人脸哈希方法, 通过优化三元组损失函数训练深度卷积神经网络以提取图像深层特征, 使得由该特征表征的同类图像在欧式空间中的距离尽可能小, 不同类图像在欧式空间中的距离尽可能大; 通过在深度网络后添加随机映射层, 进一步将高维特征映射到低维空间, 并通过阈值化将低维空间映射到汉明空间。在多个标准的数据集上的实验结果表明本文方法相比于现有其他方法的优越性。

关键词: 三元组损失; 深度神经网络; 人脸检索; 图像哈希

中图分类号: TN919.8

文献标志码: A

doi: 10.11805/TKYDA2018108

Deep face Hashing based on ternary-group loss function

ZHENG Dagang, LIU Guangjie, MAO Yaobin*, XU Andong, XIANG Wenbo

(School of Automation, Nanjing University of Science and Technology, Nanjing Jiangsu 210094, China)

Abstract: Fast retrieval on large scale human face data sets is a key problem in face recognition applications. The face Hashing method with short length can reduce the computational amount of face feature alignment, and is helpful to the application of large-scale face recognition. In this paper, a deep face Hashing method based on the loss function of ternary-group is presented. By optimizing the loss function of ternary-group, the deep convolution neural network is trained to extract the deep feature of images. The distance between the similar images can be as small as possible, and that between different kinds of images is as large as possible. The high dimension feature is mapped to the low dimension space by adding the random mapping layer following the deep network. And the low dimension space is further mapped to Hamming space by the threshold algorithm. Experimental results on multiple standard datasets show that the proposed method outperforms other state-of-the-art methods.

Keywords: loss function of ternary-group; deep neural network; face retrieval; image Hashing

传统人脸识别方法通过提取人脸图像的特征并与已存储的特征进行比对实现识别。人脸识别的精确度通常与特征维数正相关, 即特征维数越高, 人脸识别精确度相对越高。当待识别的人脸图像数据规模较大时, 因遍历人脸库的计算开销, 使得该类方法的响应性能难以满足大规模应用需要。近年来, 最近邻搜索的代表性方法——哈希方法因其存储开销小、计算效率高等优点引起广泛关注。图像哈希方法的基本思想是将每张图像转换成较短的哈希码, 通过计算码之间的汉明距离来判断 2 张图像的相似度, 进而实现检索。图像哈希方法可以分为 2 类: 数据依赖(Data-dependent)方法和数据独立(Data-independent)方法。数据独立方法产生哈希码的过程不依赖数据, 其使用的哈希函数通常是人工设计或随机生成的, 局部感知哈希^[1](Locality Sensitive Hashing, LSH)即是典型的数据独立方法, 其使用随机投影将图像数据映射成二进制哈希码实现图像检索。数据依赖方法通过获取图像数据的相关信息来生成哈希码。数据依赖方法包括迭代量化^[2](Iterative Quantization, ITQ)、谱哈希^[3](Spectral Hashing, SH)、监督核哈希^[4](Supervise Hashing with Kernels, KSH)、二元重建嵌入^[5](Binary Reconstruction, BRE)和最小损失哈希^[6](Minimal Loss Hashing, MLH)等。

收稿日期: 2018-05-26; 修回日期: 2020-01-12

作者简介: 郑大刚(1992-), 男, 硕士, 主要研究方向为人脸识别和深度学习。email:549658109@qq.com

*通信作者: 茅耀斌 email:maoyaobin@163.com

通常,数据依赖方法在匹配性能上要优于数据独立方法,但其无法捕获样本数据的非线性流形。为此,研究人员提出基于深度卷积神经网络的图像哈希方法解决这一问题。如卷积神经网络(Convolutional Neural Network, CNN)哈希^[7]使用卷积神经网络提取图像的深层特征,使得学习到的哈希函数可以提取出图像的语义信息。现有哈希方法在图像检索方面取得了不错的效果,但是应用于人脸检索和识别问题仍存在一些不足。首先,一般的图像哈希方法的处理对象多是粗粒度图像,而人脸识别任务中的图像粒度更细,类间差异更加细微,相比于粗粒度图像分类,其难度更大;其次,现有哈希方法未考虑哈希码的分布以及在汉明空间中的碰撞概率。人脸图像作为相同类别的图像在特征空间中总是聚在一起的,其映射而成哈希码碰撞几率很大,难以做到精准识别。针对现有方法的不足,本文受启发于度量学习,针对人脸识别这种细粒度图像检索问题提出一种新的深度哈希方法,该方法在网络训练阶段通过引入三元组损失函数以实现压缩类内距离拉大类间距离的作用,使得深度网络学习到的特征更具区分性,提取人脸图像的本质的深层特征,在此基础上使用随机映射对第一步获得的特征进行降维处理,并将其映射到汉明空间得到人脸的哈希码。

1 相关工作

按照有无监督信息,图像哈希中的数据依赖方法又可以划分为有监督方法和无监督方法。无监督方法从无标签信息的样本数据中学习哈希码,效果较差;有监督方法能够从监督信息中学习样本数据之间的关系,效果比无监督方法要好。近年来,一些基于人工设计特征的有监督哈希方法广泛用于解决图像检索问题。如 KULIS 等^[5]提出通过最小化输入距离与重建汉明距离的平方损失来生成哈希码;CHANG 等^[4]提出一种基于核方法的监督哈希,将相似图像对和不相似图像对作为监督信息,使相似图像对应哈希码之间的汉明距离最小同时使不相似图像对应哈希码之间的汉明距离最大。为了得到更好的监督信息,LIN 等^[8]提出一种名为 FastHash 的方法,将哈希学习问题分解为 2 步:哈希码学习步骤利用图割算法根据样本间的关系推算出相应的哈希码,哈希函数步骤将推算出的哈希码作为监督信息来训练多个标准的二分类器。

手工设计的特征在一些图像处理领域表现出良好的性能,但固定的编码步骤使得生成的特征描述子缺乏学习能力,限制了特征描述子的图像表达能力。近几年来,卷积神经网络因其在图像识别上的良好表现受到广泛关注,相比于人工设计的特征,其提取的图像深层特征可以描述图像数据之间的内在关系,并且更有区分度和代表性。因此,一些基于卷积神经网络深层特征的哈希方法被提出,例如卷积神经网络哈希^[7]、深度哈希^[9](Deep Hash, DH)、监督语义保留深度哈希^[10](Supervised Semantics-preserving Deep Hashing, SSDH)等。深度哈希^[9]使用深度神经网络获取图像数据的分层非线性变换来学习二进制码。监督语义保留深度哈希是 YANG 等^[10]提出的使用深度网络中隐含层的输出得到哈希函数的方法。该方法通过最小化定义在分类误差上的目标函数来实现模型的学习,实现图像之间深层语义的保留。

2 本文方法

2.1 基于三元组损失的人脸嵌入

定义合适的距离度量对分类、图像检索等应用中的网络训练非常重要。度量学习的思想即是在特征空间学习一个合适的距离度量来使同一类的样本之间的距离尽可能小,不同类之间的样本尽可能大。近些年,研究人员提出许多度量学习的方法用以解决图像检索的问题。度量学习方法可以分为线性度量学习和非线性模型的度量学习。线性度量学习通过线性变换将图像数据映射到新的特征空间,因而无法捕获数据的非线性流形。为了打破这个限制,可以通过核方法将线性度量学习扩展为非线性度量学习。即首先将图像数据映射到高维特征空间,然后在高维特征空间中学习有区分度的距离度量。本文即采用非线性度量学习的方法,将人脸图像嵌入到欧式空间中,使得相似图像在欧式空间中相距较近,不相似图像相距较远,见图 1。

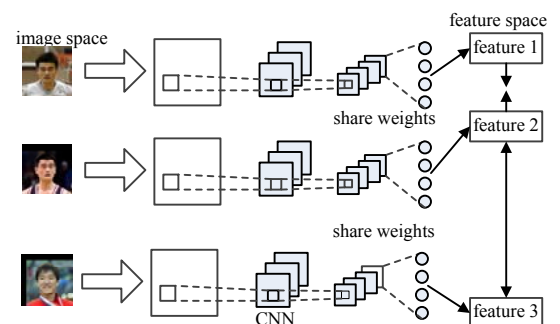


Fig.1 Face embedding based on triplet loss
图 1 基于三元组损失的人脸嵌入

使用深度卷积神经网络学习图像在欧式空间的特征表示, 满足相对距离关系(本文使用 L_2 范数度量)。换句话说, 使用深度神经网络来获得每张图像的特征, 并使用这些生成的特征进行匹配, 使得同一类别的图像对在特征空间的距离小于不同类别的图像对。在本文模型中, 相对距离关系使用一系列图像三元组来表示: $\{X_i\}=(x, x^+, x^-)$, x 为查询样本, x^+ 为正样本, 即与 x 同一标签的样本; x^- 为负样本, 即与 x 不同标签的样本。根据图像在欧式空间的距离, 将 2 张图像 x, x' 的相似性定义为:

$$S(x, x') = \|F(x) - F(x')\|_2 \quad (1)$$

式中 $F(x)$ 为将图像数据映射到欧式空间的函数, 对通过深度神经网络实现的特征映射函数, $F(x)$ 表示图像 x 的网络输出, 或是图像 x 的特征表示。对于训练时的一个三元组来说, 期望输出的特征表示应该在 L_2 范数下满足以下条件:

$$S(x, x^+) < S(x, x^-) \quad (2)$$

等价于

$$S^2(x, x^+) < S^2(x, x^-) \quad (3)$$

这里使用平方的形式便于后续实施优化时的导数计算。对于给定的三元组 $\{X_i\}$, 对分类问题而言, 需要最大化匹配图像对与不匹配图像对之间的距离, 因此可以定义三元组损失函数如下:

$$\text{loss}(x_i, x_i^+, x_i^-) = \max\{0, g + S^2(x_i, x_i^+) - S^2(x_i, x_i^-)\} \quad (4)$$

对于给定的训练集 $\mathbf{X}=\{X_i\}$, 相对距离约束可转化为以下目标函数的最小化问题, n 为训练集中三元组的数目。

$$L = \sum_{i=1}^n \max\{0, g + S^2(x_i, x_i^+) - S^2(x_i, x_i^-)\} + \frac{\lambda}{2} \|W\|_2^2 \quad (5)$$

式中 g 为度量匹配图像对与不匹配图像对之间距离的阈值参数, 该参数能够防止目标函数的整体值被易于识别的三元组主导, 这类似于合页损失函数中常用的技术^[11], 本文使用多个阈值进行了实验, 同时借鉴于文献[11], 在这里取 $g=-1$; W 为神经网络参数; λ 为提高网络模型泛化能力而引入的正则化系数。

在本文模型中, 最关键的部分是学习图像嵌入函数 $F(x)$, 传统方法通常使用人工设计的视觉特征, 学习线性或非线性变换来获得图像嵌入函数, 本文采用深度学习的方法直接从图像中学习相似度模型, 下面本文将阐述最小化目标函数的优化算法。

2.2 学习算法

1) 三元组损失函数优化

为便于讨论, 引入函数 $d(W, X_i)$ 表示三元组中匹配图像对与不匹配图像对之间的距离。即

$$d(W, X_i) = S^2(x_i, x_i^+) - S^2(x_i, x_i^-) \quad (6)$$

则目标函数可以进一步写成:

$$L = \sum_{i=1}^n \max\{0, g + d(W, X_i)\} + \frac{\lambda}{2} \|W\|_2^2 \quad (7)$$

为了将人脸图像库嵌入到特征空间中, 需要优化该目标函数, 使其最小。目标函数的偏导数为:

$$\frac{\partial L}{\partial W} = \sum_{X_i} h(X_i) \quad (8)$$

$$h(X_i) = \begin{cases} \frac{\partial d(W, X_i)}{\partial W} + \lambda W_j, & \text{if } d(W, X_i) + g > 0 \\ 0, & \text{if } d(W, X_i) + g \leq 0 \end{cases} \quad (9)$$

通过 $d(W, X_i)$ 的定义可以得到 $d(W, X_i)$ 的梯度如下:

$$\frac{\partial d(W, X_i)}{\partial W} = \frac{\partial \left[\|F(x) - F(x^+)\|_2^2 - \|F(x) - F(x^-)\|_2^2 \right]}{\partial W} = \frac{2[F(x) - F(x^+)]^T [\partial F(x) - \partial F(x^+)] - 2[F(x) - F(x^-)]^T [\partial F(x) - \partial F(x^-)]}{\partial W} \quad (10)$$

由此可以看出, 将三元组图像输入到网络中, 进行前向和反向计算即可得到三元组损失函数的梯度, 然后使用梯度下降算法即可得到优化的目标函数。

2) 三元组训练数据生成

假设有一个 M 个类别的标记数据集, 每个类别包含 N 个图像, 则共有 $M(M-1)N^2(N-1)$ 个不同的三元组, 如果采用所有可能的三元组训练神经网络, 训练网络耗费的计算资源较高, 且对训练可区分度比较强、性能比较好的网络来说也不利。选择和构造尽可能多的、且利于提高区分度的高质量的三元组进行网络训练是关键步骤之一。从所有可能的三元组中虽然可以通过随机采样构造三元组结合, 但是在这样的选择策略下, 2 个不同的三元组使用同一张图像的概率很低, 这就造成在每次训练迭代中只对选定的几个图像进行了距离约束, 总体的训练效率不高。另外, 根据梯度优化的过程, 可知道网络前向传导的次数取决于三元组中不同图像的数量, 要想获得好的模型应该产生更多的三元组来训练模型。本文借鉴 FaceNet^[12]的思想, 挖掘所有可能三元组中的难例让网络参与学习(也就是在极限的条件下进行学习), 以期获得性能更好的模型性能。具体的三元组训练结合的生成采用的方法是从每一个类的每个图像出发, 构造一个三元组。其中, 正样本从同一类别中选取, 为同一类别中最不相似的图像, 负样本从剩余的类别中选取, 为其他类别中与目标图像最相似的图像。该策略确保在少量图像上存在大量的距离约束, 能够保证模型收敛到局部极小值, 另外, 三元组均为难例, 使得学习到的特征更有区分度。

值得指出的是: 三元组损失优化过程中, 三元组中每张图像都要输入到网络中进行前向和反向计算, 但同一张图像可能会存在于不同的三元组中, 这意味着同一张图像会多次进入网络, 造成重复计算。为了降低计算复杂度, 加快训练速度, 本文通过符号标记, 重用出现在不同三元组的同一张以减少网络计算次数, 使网络传导计算的次数只依赖于三元组中不同图像的数量, 而非三元组的数量。这样的计算策略也有效降低了训练的计算消耗。

2.3 基于随机映射的哈希方法

大部分人脸图像检索方法所使用的特征维数较高, 往往带来维数灾难问题, 造成计算开销较大, 计算效率较低, 如上所述, 如果使用本文方法第一步训练的网络模型提取特征, 特征维数高达上千维, 以此为基础进行图像比对, 计算高维特征之间的余弦距离, 其计算开销可想而知。针对这一问题, 主要的解决方法是将高维特征映射到低维空间, 即对高维特征进行降维。常用的降维方法主要包括特征筛选和特征提取两大类。特征筛选会损失原有特征部分信息, 所以在人脸识别中未被广泛采用^[13]。特征提取是现今降维的主流途径, 主成分分析(Principal Component Analysis, PCA)即是典型的特征提取方法。在降维过程中, PCA 能够有效保留原特征的主要信息, 但随着特征维数的增长, PCA 的计算复杂度越来越高, 会加重计算系统的负担。其他降维方法如线性判别分析(Linear Discriminant Analysis, LDA)和独立成分分析(Independent Component Analysis, IDA)也存在类似问题。如何能够在保留原有特征有用信息的情况下减少计算开销, 对于实现人脸图像检索有非常重要的意义。

随机映射作为一种常用的降维方法, 计算效率较高, 通过随机矩阵将高维数据映射到低维空间, 同时不产生显著的失真, 能够保留原有数据结构。Johnson-Lindenstrauss 定理和约束等距性证明了使用随机映射降维可以保留原始数据在欧式空间的距离^[14], 这也是随机映射在信号处理方面广泛应用的原因。因此, 本文采用随机映射将人脸嵌入空间的高维特征映射到汉明空间, 以减少计算开销, 加快计算速度, 实现快速人脸图像比对。

随机映射通过随机矩阵实现, 随机矩阵中的元素都是独立同分布的随机变量, 如果随机矩阵其中的随机变量服从高斯分布, 则该随机矩阵为高斯随机矩阵, 如果其中的随机变量服从均匀分布, 则为均匀随机矩阵。在本文中, 随机映射的基本思想是选择一个随机的超平面, 用该超平面将原有特征映射到低维空间, 这里随机矩阵相当于一个超平面。假设原始特征 V 为 k 维, 降维后的特征 E 为 p 维, 即从 k 维的高维空间映射到 p 维的低维空间, $k \gg p$, 选择合适的 $k \times p$ 随机矩阵 M , 使得 $VM=E$, 这样就得到降维后的特征。

本文采用均匀随机矩阵将特征映射到相应的低维空间, 然后进行阈值化, 以得到对应位数的二进制哈希码。具体来说, 使用第一步训练好的深度模型提取人脸图像的 4 096 维特征, 之后生成 $4\ 096 \times p$ 维的随机矩阵, 使用高维特征与该矩阵相乘, 得到 D 维的低维特征, 对其进行归一化后再进行阈值化, 得到 p 位的哈希码。

3 实验结果及分析

3.1 实验设置

本文使用 VGG-Face^[15]作为基础模型, 使用 CASIA-WebFace^[16]数据集结合三元组损失函数优化方法训练该模型, 在训练好的模型后添加随机映射层, 并使用 FaceScrub^[17]数据集对所提方法性能进行了测试。同时, 为了测试本文所提方法在粗粒度图像分类上的表现, 使用 AlexNet^[18]模型, 结合本文方法, 在 CIFAR-10^[19]数据集上进行了实验。具体地, 对 AlexNet 模型结构进行了一些修改, 对其进行精调以实现特定图像的分类, 然后使用学习到的模型产生图像特征, 将高维特征映射到低维空间并阈值化, 得到对应的哈希码来实现图像检索。实验使用 Caffe^[20]对本文方法进行了具体实现, 将批量的大小设置为 32, 学习率为 0.01, 动量为 0.9, 同时全连接层的丢包率设置为 0.5, 以避免过拟合。

3.2 评估标准

为了与现有哈希方法进行对比,采用汉明排序来评价不同哈希方法的量化性能。本文基于返回图像与查询图像是否具有相同的样本标签来评价检索结果,通过计算汉明排序中返回 M 张图像的精确度进行汉明排序的评估,图像检索的目的是返回与查询图像同一类别的图像,所以本文使用汉明排序前 M 张图像的均值平均精确度(mean Average Precision, mAP)来评估检索方法的整体性能。根据与查询图像的汉明距离对返回图像进行排序,选取前 M 张图像作为检索结果,然后对于所有查询图像计算其 mAP。在 FaceScrub 数据集的实验中 $M=50$,在 CIFAR-10 数据集的实验中 $M=10\ 000$ 。作为对比,将本文深度哈希方法与现有的多种方法进行了同一数据集上的比较,其中包括无监督的方法、有监督的方法以及基于深度学习的方法,这些算法包括 LSH^[1],SH^[2],ITQ^[3],KSH^[4],BRE^[5],MLH^[6],DH^[9]和深度监督哈希^[21](Deep Supervised Hashing, DSH)。

3.3 实验结果

本文在 FaceScrub 数据集上进行了实验以检验人脸图像检索的性能,分别使用 12 位、24 位、32 位和 48 位哈希码进行实验。对于浅层学习方法,如 LSH,SH 和 ITQ 等,人脸图像用 236 维的局部二值模式(Local Binary Pattern, LBP)特征向量描述;对于深度方法如 CNNH,DH 和 DSH,直接将原始人脸图像作为视觉内容表征输入神经网络。实验结果对比见表 1。从表 1 中可以看出,与传统的基于人工设计特征的方法相比,基于深度学习的方法 DH 和 DSH 表现出更好的性能,而在基于深度学习的方法中,本文所提方法在不同的哈希码长度下均有更好的表现,这充分说明了本文方法的有效性和优势。

为了检验本文方法在粗粒度图像识别上的性能,在 CIFAR-10 数据集上进行了实验,使用 512 维的 GIST 向量表征 CIFAR-10 中的图像,结果比较见表 2。从表 2 中可以看出,虽然在精确度上不及 DSH 方法,但是随着哈希码长度增加,本文方法的检索精确度上升较快,并在 48 bit 时超越了 DSH 的方法。这说明二进制哈希码位数增加可以显著提高检索的精确度。

4 结论

基于深度网络的人脸哈希方法可降低人脸特征比对的计算量,是开展大规模人脸识别应用的关键技术之一。本文提出了一种基于三元组损失函数的深度人脸哈希方法。其主要思路是通过优化三元组损失函数的方式来训练深度卷积神经网络,使得深度网络提取的特征具备同类图像之间的距离尽可能小,异类图像之间的距离尽可能大的表征特点;特征到哈希码的映射通过在深度网络后添加随机映射层,并进一步通过阈值方法实现。相关实验结果表明本文方法的有效性和优越性。尝试采用新的网络结构以及新的降维方法是未来值得进一步研究的问题。

参考文献:

- [1] GIONIS A,INDYK P,MOTWANI R. Similarity search in high dimensions via Hashing[C]// 25th International Conference on Very Large Data Bases. Edinburgh,Scotland:Morgan Kaufmann Publishers Inc., 1999:518-529.
- [2] GONG Y,LAZEBNIK 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 & Machine Intelligence, 2013,35(12):2916-2929.
- [3] WEISS Y,TORRALBA A,FERGUS R. Spectral Hashing[C]// 21st International Conference on Neural Information Processing Systems. NY,US:Curran Associates Inc., 2008:1753-1760.
- [4] LIU W,WANG J,JI R,et al. Supervised Hashing with kernels[C]// 2012 IEEE Conference on Computer Vision and Pattern Recognition. Washington,DC,United States:IEEE Computer Society, 2012:2074-2081.

表 1 本文方法与其他方法在 FaceScrub 数据集上的 mAP 比较

method	12 bit	24 bit	32 bit	48 bit
LSH	0.016 3	0.036 1	0.046 5	0.068 1
SH	0.021 4	0.039 7	0.058 0	0.069 4
ITQ	0.020 8	0.046 3	0.059 1	0.086 2
KSH	0.022 7	0.047 5	0.055 7	0.081 2
BRE	0.071 0	0.094 8	0.109 9	0.121 1
MLH	0.070 4	0.091 2	0.110 4	0.133 4
DH	0.080 9	0.098 2	0.124 1	0.156 4
DSH	0.041 7	0.066 9	0.102 8	0.078 3
proposed method	0.090 3	0.114 0	0.147 3	0.187 2

表 2 本文方法与其他方法在 CIFAR-10 数据集上的 mAP 比较

method	12 bit	24 bit	32 bit	48 bit
LSH	0.121	0.126	0.120	0.120
SH	0.131	0.135	0.133	0.130
ITQ	0.264	0.282	0.288	0.295
KSH	0.303	0.337	0.346	0.356
BRE	0.159	0.181	0.193	0.196
MLH	0.182	0.195	0.207	0.211
DH	0.483	0.496	0.506	0.518
DSH	0.616	0.652	0.643	0.621
proposed method	0.554	0.585	0.613	0.639

-
- [5] KULIS B,DARRELL T. Learning to Hash with binary reconstructive embeddings[C]// International Conference on Neural Information Processing Systems. NY,US:Curran Associates Inc., 2009:1042–1050.
- [6] NOROUZI M,FLEET D J. Minimal loss Hashing for compact binary codes[C]// 28th International Conference on International Conference on Machine Learning. NY,US:Omnipress, 2011:353–360.
- [7] XIA R,PAN Y,LAI H,et al. Supervised Hashing for image retrieval via image representation learning[C]// AAAI Conference on Artificial Intelligence. Québec City,Canada:[s.n.], 2014:2156–2162.
- [8] LIN G,SHEN C,HENGEL A V D. Supervised Hashing using graph cuts and boosted decision trees[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015,37(11):2317–2331.
- [9] LIONG V E,LU J,WANG G,et al. Deep Hashing for compact binary codes learning[C]// Computer Vision and Pattern Recognition. Boston,MA:IEEE, 2015:2475–2483.
- [10] YANG H F,LIN K,CHEN C S. Supervised learning of semantics-preserving Hashing via Deep Neural Networks for large-scale image search[J]. Computer Science, 2015,40(2):437–451.
- [11] LI Hang. Statistical learning methods[M]. Beijing:Tsinghua University Press, 2012.
- [12] SCHROFF F,KALENICHENKO D,PHILBIN J. FaceNet:a unified embedding for face recognition and clustering[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston,MA,US:IEEE, 2015:815–823.
- [13] HHANG Anning,HHANG GenchUn,FANG Gao,et al. A new dimension reduction method in face recognition:random projection[J]. Laser Journal, 2015,36(4):117–121.
- [14] JOHNSON W B,LINDENSTRAUSS J. Extensions of Lipschitz mappings into a Hilbert space[C]// Proceedings of Conference in Modern Analysis and Probability. Providence,RI,USA:[s.n.], 1984,26:189–206.
- [15] PARKHI O M,VEDALDI A,ZISSERMAN A. Deep face recognition[C]// Proceedings of the British Machine Vision Conference(BMVC). Swansea,UK:[s.n.], 2015:7–10.
- [16] YI D,LEI Z,LIAO S,et al. Learning face representation from scratch[J]. arXiv preprint arXiv, 2014:1411.7923.
- [17] NG H W,WINKLER S. A data-driven approach to cleaning large face datasets[C]// IEEE International Conference on Image Processing. Paris:IEEE, 2015:343–347.
- [18] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017,60(6):84–90.
- [19] KRIZHEVSKY A,HINTON G E. Learning multiple layers of features from tiny images[R]. Computer Science Department, University of Toronto, 2009.
- [20] JIA Yangqing,SHELHAMER Evan,DONAHUE Jeff,et al. Caffe:convolutional architecture for fast feature embedding[C]// 2014 ACM Conference on Multimedia. NY,US:Association for Computing Machinery Inc, 2014:675–678.
- [21] LIU H,WANG R,SHAN S,et al. Deep supervised Hashing for fast image retrieval[J]. International Journal of Computer Vision, 2019,127(9):1217–1234.