

# 结合多特征与线性判别分析的图像检索

丁功鸿<sup>1</sup> 黄山<sup>2\*</sup>

<sup>1</sup>(四川大学电气工程学院 四川 成都 610065)

<sup>2</sup>(四川大学计算机学院 四川 成都 610065)

**摘要** 卷积神经网络的全连接层特征缺乏对图像底层信息的描述,导致部分样本无法被成功检索。并且全连接层特征维度高,检索效率低下。针对这种情况,提出一种结合线性判别分析和多层特征的图像检索方法。该方法利用卷积神经网络提取卷积层和全连接层特征,并融合 HSV 特征,使用线性判别分析对融合特征降维。多层特征能增加图像的区分度,提升识别准确率。与其他算法的实验结果表明,该方法在检索精度和检索速度上有一定的提高。

**关键词** 深度学习 多特征 线性判别分析 图像检索

中图分类号 TP391.4

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.04.032

## IMAGE RETRIEVAL BASED ON MULTIPLE FEATURES AND LINEAR DISCRIMINANT ANALYSIS

Ding Gonghong<sup>1</sup> Huang Shan<sup>2\*</sup>

<sup>1</sup>(College of Electrical Engineering, Sichuan University, Chengdu 610065, Sichuan, China)

<sup>2</sup>(College of Computer Science, Sichuan University, Chengdu 610065, Sichuan, China)

**Abstract** The fully connected layer features of convolutional neural networks lack the description of the underlying information of image, result in that some samples cannot be retrieved successfully. Moreover, it's not efficient to retrieve directly due to the high dimension of the fully convolutional layer features. To solve this problem, we propose an image retrieval method by combining linear discriminant analysis and multiple features. Convolutional neural network was used to extract features from both convolutional layer and fully convolutional layer, and it merged HSV color features together. Dimension of the fused features was reduced by linear discriminant analysis. Multi-layer features could increase the image differentiation and improve the recognition accuracy. Comparison experiments show that this method makes improvement in precision and speed on the task of image retrieval.

**Keywords** Deep learning Multiple features Linear discriminant analysis Image retrieval

## 0 引言

随着现代通信技术以及存储技术的发展,每天都有海量的数据上传至分散在各地的服务器,其中就包括图像数据。图像检索的任务就是以给定的图像为标准,从服务器上的图像数据库中检索出与检索图像相似的图像,并将其返回给用户。由于图像数据库中的

图像没有标签,不可能人为地去手动标注,因此利用图像的特征进行图像检索一直是研究的热点。图像的特征包括颜色、纹理、形状等底层图像特征,基于内容的图像检索方法(Content-based Image Retrieval, CBIR)对这些特征进行处理,以查询到最相似的图像。传统的特征点检测算法有尺度不变特征变换(Scale-Invariant Feature Transform, SIFT)<sup>[1]</sup>、SURF(Speeded-up Robust Features)<sup>[2]</sup>等。SIFT算子是对局部特征的描述,具有

尺度不变性,能在一定程度上不受视角和噪声的干扰, SURF 改进了特征的提取方式,通过构建 Hessian 矩阵生成图像稳定的边缘点。基于图像纹理和轮廓信息的算法有局部二值模式(Local Binary Pattern, LBP)<sup>[4]</sup>、梯度直方图(Histogram of Oriented Gradient, HOG)<sup>[5]</sup>等, Pavithra<sup>[7]</sup>使用颜色矩信息从数据库中选择相关图像,然后使用 LBP 提取图像的纹理和轮廓信息。Ahmed 等<sup>[8]</sup>通过图像的原始特征去查找可能代表检索对象的兴趣点,该算法能识别复杂且杂乱的物体,在通用图像数据集的大多数图像类别中均具有出色的性能,而且计算成本低。Kundu 等<sup>[9]</sup>使用非下采样 Contourlet 变换的多尺度几何分析计算统计特征,并引入了相关性反馈机制,该机制使用图论方法根据用户的反馈对检索图像进行排名。传统的二进制组合方式是将每个通道的 LBP 特征连接起来,但是会增加特征的维度。Dubey 等<sup>[10]</sup>提出了一种多通道解码 LBP 图像描述方法,合并多个通道的 LBP 以进行图像检索。

随着深度学习<sup>[11]</sup>的发展,卷积神经网络 CNN 已经广泛地运用在图像检索领域,并且在速度和精度方面相对于传统的 CBIR 有很大的提升。深度哈希是当前研究的热点,这类算法将图像特征映射至二进制表示的哈希码。如 DSDH(Deep Supervised Discrete Hashing)<sup>[13]</sup>、DCH(Deep Cauchy Hashing)<sup>[14]</sup>、SSDH(Semi-supervised Deep Hashing)<sup>[15]</sup>和 RADH(Relaxed Asymmetric Deep Hashing)<sup>[16]</sup>。

本文没有采用深度哈希的方法,因为这类方法需要大量的训练数据。而 Caltech256 这样的数据集,大部分类别只有 100 幅左右的图像,无法满足训练要求。而且很多深度学习模型已经在大型图像数据库 ImageNet<sup>[17]</sup>上预训练完成,直接使用预训练模型提取图像特征将省去大量的训练时间。

文献[12]使用 VGG16 网络,提取 FC7 层的输出作为图像特征,并使用训练集训练 SVM 分类器,提高检索精度。但是,全连接层的特征维数高, VGG16 的 FC7 层有 4 096 个神经元,每一次检索都要对这 4 096 个特征作比较,检索速度慢。

为了充分利用卷积神经网络的多层特征,同时降低特征的维度,加快检索速度,本文提出了一种结合多特征与线性判别分析(Linear Discriminant Analysis, LDA)的图像检索算法。这种算法同时利用深度卷积神经网络提取的卷积层特征和全连接层特征,为了增

加特征中的图像细节,还融合了 HSV(Hue, Saturation, Value)颜色特征。LDA 降低了特征的维数,加快了检索的速度,同时还提升了检索的精度。

## 1 方法设计

### 1.1 多层特征提取

本文用 VGG19 来提取图像的基本特征,其中的权重参数已经在大型图像数据库 ImageNet 上训练完成。该网络由 16 个卷积层、5 个池化层和 3 个全连接层构成。模型中的卷积层通过多个滑动窗口提取图像的特征,然后在全连接层重新通过权重矩阵展开。本文提取特征的过程如图 1 所示,5 个池化层和 1 个全连接层提取的特征维度分别为 64、128、256、512、512 和 4 096。

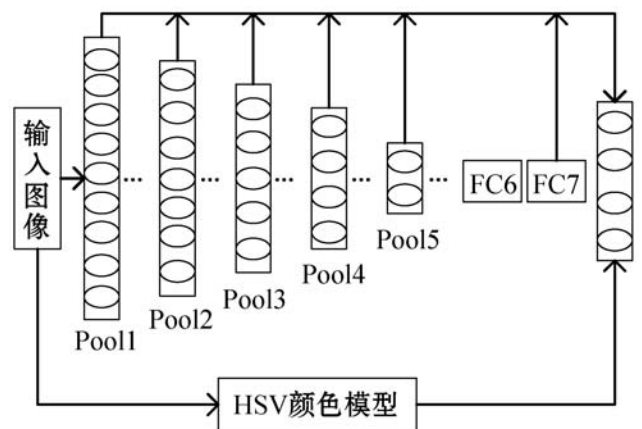


图1 特征提取流程

VGG19 的 16 个卷积层分为 5 个部分,每个部分由 2~4 个卷积层和 1 个池化层组成。对卷积层的特征,本文提取卷积层特征的方法和文献[18]类似,首先提取池化后的卷积特征,将每个通道加权成一个激活值,然后使用 L2 正则化处理特征,如式(1)所示。

$$\mathbf{F}(I) = [\mathbf{F}_1, \mathbf{F}_2, \dots, \mathbf{F}_k] \quad (1)$$

式中: $\mathbf{F}(I)$ 为图像  $I$  的一组卷积层特征; $\mathbf{F}_k$ 为图像第  $k$  个通道的激活值,其计算方式如式(2)所示。

$$\mathbf{F}_k = \sum_{x=1}^H \sum_{y=1}^Z I_k(x, y) \quad (2)$$

式中: $I_k(x, y)$ 表示图像  $I$  的第  $k$  个通道上空间坐标为  $(x, y)$  的激活值, $H$  和  $Z$  为每个通道中特征的尺寸。 $\mathbf{F}_k$ 就是最终获得的特征向量,计算方式如式(3)所示,包含  $k$  个值。

$$\mathbf{F}_s(I) = \frac{\mathbf{F}(I)}{\|\mathbf{F}(I)\|_2} \quad (3)$$

## 1.2 LDA 降维

线性判别分析<sup>[19]</sup>是一种有监督的数据降维技术。对于数据集的每个输入样本,必须有对应的类别输入标签。这点和主成分分析方法(Principal Component Analysis, PCA)有区别,PCA 在降维的过程中不考虑样本的类别输入。但是 PCA 在运算时对计算资源的要求比 LDA 高,在实验过程中,因数据量太大而无法降维,因此本文选定 LDA 作为降维方式。

假设数据集的特征为:

$$D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\} \quad y_i \in \{L_1, L_2, \dots, L_k\}$$

其中  $\mathbf{x}_i$  为特征向量,  $y_i$  为对应的类别标签,  $m$  为样本数量, 类别总数为  $k$ 。  $N_j (j = 1, 2, \dots, k)$  为第  $j$  类样本的个数,  $X_j (j = 1, 2, \dots, k)$  为第  $j$  类样本的集合。

$\mathbf{u}_j (j = 1, 2, \dots, k)$  为第  $j$  类样本的均值向量。则多类 LDA 线性降维的优化过程可以用式(4)来解释。

$$J(W) = \frac{\prod_{i=1}^d \mathbf{w}_i^T \mathbf{S}_b \mathbf{w}_i}{\prod_{i=1}^d \mathbf{w}_i^T \mathbf{S}_w \mathbf{w}_i} = \prod_{i=1}^d \frac{\mathbf{w}_i^T \mathbf{S}_b \mathbf{w}_i}{\mathbf{w}_i^T \mathbf{S}_w \mathbf{w}_i} \quad (4)$$

式中:  $\mathbf{S}_b$  为类间散度矩阵;  $\mathbf{S}_w$  为类内散度矩阵,  $d$  为特征降维之后的维度, 且  $d \leq k - 1$ 。若使类内方差尽可能小, 类间方差尽可能大, 等价于最大化  $J(W)$ 。根据文献[19],  $J(W)$  的最大值就是  $\mathbf{S}_w^{-1} \mathbf{S}_b$  的最大的  $d$  个特征值的乘积, 此时  $\mathbf{w}_i (i = 1, 2, \dots, d)$  是这  $d$  个特征值对应的特征向量, 并且  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$ 。  $\mathbf{S}_b$  和  $\mathbf{S}_w$  的计算方法如下:

$$\mathbf{S}_b = \sum_{j=1}^k N_j (\mathbf{u}_j - \mathbf{u}) (\mathbf{u}_j - \mathbf{u})^T \quad (5)$$

$$\mathbf{S}_w = \sum_{j=1}^k \sum_{\mathbf{x} \in X_j} (\mathbf{x} - \mathbf{u}_j) (\mathbf{x} - \mathbf{u}_j)^T \quad (6)$$

根据式(5) - 式(6)计算出矩阵  $\mathbf{S}_w^{-1} \mathbf{S}_b$  最大的  $d$  个特征值对应的  $d$  个特征向量, 构造投影矩阵  $\mathbf{W}$ , 最后再利用式(7)计算出每一个样本降维之后的特征:

$$\mathbf{x}'_i = \mathbf{W}^T \mathbf{x}_i \quad (7)$$

最后得到输出特征集合:

$$D' = \{(\mathbf{x}'_1, y_1), (\mathbf{x}'_2, y_2), \dots, (\mathbf{x}'_m, y_m)\} \quad y_i \in \{L_1, L_2, \dots, L_d\}$$

## 1.3 算法实现

本文的算法流程如图 2 所示。在图像检索中, 图像之间相似性定义为两幅图像特征之间的距离度量。两幅图像的特征距离越小, 说明这两幅图像越相似。本文用欧氏距离来度量两幅图像的相似度。

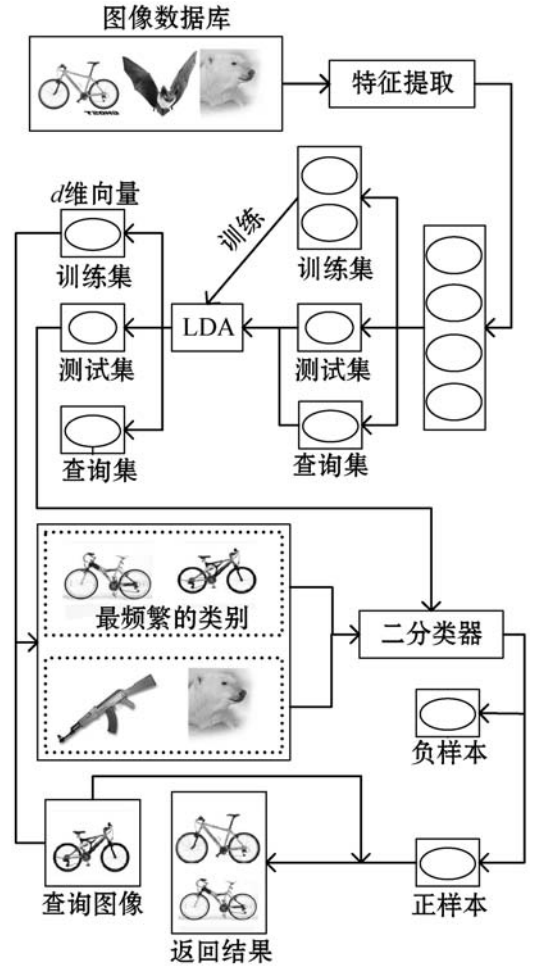


图2 本文算法的框架

算法的步骤如下:

(1) 将所有图像放入已经训练完成的 VGG19 模型, 提取 5 个池化层、1 个全连接层 FC7 的特征。然后再提取图像的 HSV 颜色特征, 将提取的三种特征融合。

(2) 将特征分为训练集、测试集和查询集三个部分。利用 LDA 算法, 用训练集训练 LDA 模型, 然后再将所有的图像特征降维至  $d$  维, 将特征存储至本地。再次读取时则不需要加载图像, 只需要根据存储的索引列表, 读取相应图像的特征。

(3) 给定查询图像, 计算降维后的查询图像特征与降维后的训练集图像特征的距离并排序。取前  $r$  个返回结果, 统计前  $r$  个返回结果中每一个类别出现的频率, 将出现频率最高的类别记为  $L_h$ 。

(4) 将训练集中属于  $L_h$  的特征作为正样本, 样本个数为  $P$ , 随机抽不属于  $L_h$  的样本作为负样本, 按照正负样本 1:3 的比例取负样本个数为  $3P$ 。将正负样本送入 LDA 分类器进行训练。

(5) 将降维后的测试集送入已经训练完成的 LDA 分类器, LDA 分类器会将测试数据预测为正样本和负样本, 正样本是指与查询图像属于同一个类别。这样

做的目的是在检索前将测试集中的图像过滤一部分,因为很多图像与查询图像并不相关,但是在特征上与查询图像会比较相似,在距离度量排序之后可能会排在靠前的位置,影响平均准确度。

(6) 将查询图像与测试集中的正样本进行相似性度量,取前  $r_0$  个结果作为最终的返回结果。对于负样本不做处理,因为在实验中负样本的检索结果会降低检索精度。

从图2可以看出,所有的图像最后都被压缩成了  $d$  维的特征向量,节省了存储空间,加快了读取速度。

## 2 结果与分析

### 2.1 数据和参数配置

为了验证本文提出的模型效果,在数据集 Caltech256<sup>[20]</sup>、Coil-100<sup>[21]</sup>、Corel-1k<sup>[22]</sup> 和 CIFAR-10<sup>[23]</sup> 上进行实验。Caltech256 是加利福尼亚理工学院收集整理的图像数据集,一共有 30 607 幅图像,对应着 256 个分类。每个类别的数量从 80 ~ 800 不等。Coil-100 包含 100 个类别的图像,每个类别有 72 幅图像,对应着同一个物体的 72 种姿态。Corel-1k 包含 10 个类别的图像,每个类别 100 幅图像。CIFAR-10 包含 10 个类别的图像,每个类别 6 000 幅图像。

在 Caltech256 数据集中,最少的一类图像只有 80 幅,为了使每一类图像的数量均衡,以 80 为标准,从每一类图像中随机抽取 80 幅图像,并对数据作增强处理以增加图像的数量。通过翻转、旋转和随机裁剪,将每一个类别的图像数量增加至 400 幅。对于 Coil-100 和 Corel-1k,分别将每一类的图像扩充至 288 幅和 400 幅。CIFAR-10 样本足够多,不做增强处理。数据集的划分方式如表 1 所示。

表 1 不同数据集的划分数量

集合	Caltech256	Coil-100	Corel-1k	CIFAR-10
查询集	2 560	7 200	1 000	1 000
测试集	23 040	7 200	1 000	54 000
训练集	76 800	14 400	2 000	5 000

LDA 能够对数据进行降维,但是数据降维之后的维度必须小于样本类别数。对于本文所使用 4 个数据集,使用 LDA 降维方法对特征降维。在 Caltech256 中将维数  $d$  设置为 250,在 Coil-100 中将维数  $d$  设置为 99,在 Corel-1k 和 CIFAR-10 中都将维数  $d$  设置为 9。因此,对于不同的数据集,前面提到的变量  $d$  分别取 250、99、9 和 9。

本文中,VGG19 模型的参数已经在 ImageNet 上预训练完成,可以直接提取池化层和全连接层的输出作为图像的深度特征。实验设备为台式主机,CPU 为 Intel-i5-9400F,GPU 为 GTX1660 SUPER。在 Windows 系统上的 PyCharm 2017 开发平台下开发实现,结合 OpenCV-Python-3.1.0,编程语言选用 Python。

### 2.2 评价指标

图像检索中最常用的两种评价指标是平均准确度 (Mean Average Precision, mAP) 和查准-查全率 (Precision-Recall) 曲线,也叫 P-R 曲线。查准率和查全率如下:

$$\text{查准率} = \frac{\text{检索结果中的相关信息数量}}{\text{检索结果中的信息总量}} \times 100\% \quad (8)$$

$$\text{查全率} = \frac{\text{检索结果中的相关信息数量}}{\text{数据库中相关信息的总量}} \times 100\% \quad (9)$$

从式(8)和式(9)可以看出,查准率和查全率是一对互逆的指标。查准率反映了检索系统的抗干扰性能,而查全率反映了系统从信息集合中检索出相关信息成功度的能力。随着查全率的提高,查准率也会下降。

mAP 的计算方法如式(10)所示。

$$mAP(x_q) = \frac{1}{x_q} \sum_{i=1}^{x_q} \frac{1}{n_i} \sum_{j=1}^{n_j} \frac{j}{r_j} \quad (10)$$

式中: $x_q$  查询样本图像的数量; $n_i$  为第  $i$  个查询样本返回的相关图像的数量,在返回的图像排序中; $r_j$  代表第  $j$  个相关图像的位置索引。mAP 不仅仅考虑了返回的相关样本的数量,还考虑了这些样本之间的排名,通过计算每个检索样本的准确度来获取系统在多个样本上的平均准确度。

在本文的实验中,所有的实验重复 5 次,每次随机抽取 50 幅查询图像,实验结果是 5 次实验的平均值。

### 2.3 Caltech256 数据集实验结果

本文的算法模型分为 3 个模块,分别是 VGG、LDA 和分类器。算法提取图像特征也包括卷积层特征、全连接层特征和 HSV 颜色特征。通过不同的模块组合和特征组合做比较,以证明本文算法的有效性。

图 3 是根据不同的模块组合绘制出的 mAP 曲线,横轴为每次检索返回图像的数量。可以看出,当返回数量相同时,本文提出的算法效果优于其他模块的组合。其次是 VGG + LDA 的组合,可见使用 LDA 不仅能降低特征的维度,还能提高检索的精度。当返回图像的数量从 10 增长至 100 时,曲线呈下降趋势。这是因为返回数量越多,返回结果中掺杂不相关图像的概率越高,导致 mAP 下降。




图3 不同模块组合的 mAP 曲线

图4 是根据不同特征组合绘制出的 mAP 曲线,其中 Conv 为卷积层的特征。为了控制变量,模型使用 VGG + LDA + 分类器的组合方式,即本文的算法模型,分类器是指 LDA 分类器。可以看出,单独使用 HSV 特征进行检索,效果最差。因为 HSV 颜色空间只是用颜色描述,但是一幅图像还有纹理、形状等特征,单一的特征并不能准确地描述一幅图像。在 FC7 特征的基础上融合 Conv 特征或者 HSV 特征,mAP 都提高了。因为 FC7 特征是对图像的高级描述,浓缩了图像的多层信息,但是也会丢失一些图像细节。而融合了 Conv 或者 HSV 特征之后,对图像细节进行了补充,这样就使得特征能更加准确地将不同类别的图像区分开。




图4 不同特征组合的 mAP 曲线

图5 所示的 P-R 曲线直观地对不同模块的组合性能进行了评估,横轴为查全率,纵轴为查准率。在实验中,返回结果设置 10 到 300,每次递增 10,即[10,20,...,300]。可以看出,本文提出的算法在查准率和查全率两个方面都比其他模块的组合效果好,其次是 VGG + LDA 的组合。如果直接使用 VGG19 的 FC7 层特征进行图像检索,检索效果最差,并且随着返回图像数量的增加,查准率也剧烈地下降。在图6中,使用 HSV 特征检索时,准确率和召回率都不足 2%。而融合了三种不同特征的算法表现性能最好,所以本文提出的多

特征融合能得到更优的检索结果。




图5 不同模块组合的 P-R 曲线




图6 不同特征组合的 P-R 曲线

### 2.4 Corel-1k 数据集实验结果

在 Corel-1k 数据集上,将本文算法和不同的算法进行性能对比,实验结果如表2所示, $T$  指的是单幅图像的检索时间,根据返回的前 100 个结果计算 mAP。从表中可以看出,本文算法提取的特征维度低,只有 9 个维度。和其他算法相比,检索精度高,检索速度快。

表2 不同算法在 Corel-1k 上的性能

算法	$T/s$	维度	mAP/%
Pavithra 等 <sup>[7]</sup>	1.108	>768	83.26
Ahmed 等 <sup>[8]</sup>	1.190	—	83.50
Kundu 等 <sup>[9]</sup>	—	99	55.50
Dubey 等 <sup>[10]</sup>	16.490	1 024	74.90
本文算法	0.006	9	99.13

### 2.5 CIFAR-10 实验结果

表3 是本文算法和 DSDH<sup>[13]</sup>、DCH<sup>[14]</sup>、SSDH<sup>[15]</sup>、RADH<sup>[16]</sup> 算法的比较结果,根据返回的前 5 000 个结果计算 mAP。在 CIFAR-10 数据集上,本文算法提取的特征是长度为 9 的浮点向量,因此没有哈希码长度

这一项。实验结果表明,在只有少量训练样本的情况下,同当前主流的哈希算法相比,本文算法具有更好的检索性能。

表3 不同哈希算法在 CIFAR-10 上的 mAP

算法	哈希码长度	mAP/%
本文算法	—	85.43
RADH <sup>[16]</sup>	48	84.92
SSDH <sup>[15]</sup>	48	81.40
DSDH <sup>[13]</sup>	48	82.00
DCH <sup>[14]</sup>	48	79.36

## 2.6 跨库性能测试

为了验证本文算法的适用性,在三种不同的数据集上进行对比实验,根据返回的前 100 个结果计算 mAP。表 4 是不同模块组合的 mAP 对比结果,为控制变量,使用的是 FC7 层特征。数据表明,在不同的数据集上,使用 LDA 降维会提升检索精度,特征维度的降低也使得检索速度更快。LDA 分类器使得 mAP 进一步提高。表 5 是不同特征组合的 mAP 对比结果,在 FC7 特征的基础上融合不同特征后,检索精度均得到提升。

表4 三种数据集上的 mAP 对比结果(%)

组合方式	Caltech256	Coil-100	Corel-1k
VGG	65.41	88.46	91.66
VGG + 分类器	66.15	95.85	98.21
VGG + LDA	79.15	99.59	97.69
VGG + LDA + 分类器	88.18	99.63	98.42

表5 三种数据集上的 mAP 对比结果(%)

组合方式	Caltech256	Coil-100	Corel-1k
FC7	88.18	99.63	98.42
Conv	80.26	99.80	99.19
HSV	25.29	94.18	91.96
Conv + FC7	92.39	99.97	99.10
FC7 + HSV	91.12	99.94	98.84
Conv + FC7 + HSV	96.03	99.99	99.13

## 2.7 不同算法的 mAP 对比

在三种数据集上,将本文算法和 SIFT<sup>[1]</sup>、LBP<sup>[4]</sup>、DoG<sup>[3]</sup>、RGLBP<sup>[6]</sup> 等算法进行对比,根据返回的前 100 个结果计算 mAP,实验结果如表 6 所示。实验表明,和传统的 CBIR 方法相比,本文算法在三种数据集上的检索性能最好。在 Coil-100 和 Corel-1k 上 mAP 均达到 99%,这是因为这两个数据集的图像类别少,

并且同一个类别的图像比较相似,很容易取得较高的 mAP。

表6 不同算法在三种数据集上的 mAP(%)

算法	Caltech256	Coil-100	Corel-1k
Ahmed <sup>[8]</sup>	71.30	92.30	83.50
SURF <sup>[2]</sup>	35.00	49.00	46.50
HOG <sup>[5]</sup>	22.30	43.70	40.50
RGLBP <sup>[6]</sup>	21.00	48.70	59.50
DoG <sup>[3]</sup>	33.00	30.00	52.00
LBP <sup>[4]</sup>	28.70	49.30	47.50
SIFT <sup>[1]</sup>	36.50	25.60	34.80
本文算法	96.03	99.99	99.13

## 3 结语

本文提出了一种结合多特征与线性判别分析的图像检索算法。该算法融合 VGG19 网络的卷积层和全连接层特征,以及 HSV 颜色特征,结合 LDA 对融合特征进行降维;然后再使用降维后的特征训练 LDA 分类器,使分类器能将测试集分为正样本和负样本;最后再根据特征作相似度排序,返回检索结果。实验对比结果表明,本文算法提取的特征维度低,检索精度高,检索速度快。与多种 CBIR 算法相比,本文算法具有更好的检索性能。

## 参 考 文 献

- [1] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004,60(2):91-110.
- [2] Bay H, Ess A, Tuytelaars T, et al. Speeded-up robust features(SURF)[J]. Computer Vision and Image Understanding,2007,110(3):346-359.
- [3] Xu X Y, Miler E L. Adaptive difference of gaussians to improve subsurface imagery[C]//IEEE International Conference on Image Processing,2002:3441-3443.
- [4] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2002,24(7):971-987.
- [5] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]//IEEE Conference on Computer Vision and Pattern Recognition,2005:886-893.
- [6] Ojala T, Pietikainen M, Maenpää T. Gray scale and rotation invariant texture classification with local binary patterns [C]//6th European Conference on Computer Vision,2000:

404 – 420.

- [ 7 ] Pavithra L K, Sharmila T S. An efficient framework for image retrieval using color, texture and edge features [ J ]. *Computers & Electrical Engineering*, 2018, 70: 580 – 593.
- [ 8 ] Ahmed K T, Ummesafi S, Iqbal A. Content based image retrieval using image features information fusion [ J ]. *Information Fusion*, 2019, 51: 76 – 99.
- [ 9 ] Kundu M K, Chowdhury M, Bulo S R. A graph-based relevance feedback mechanism in content-based image retrieval [ J ]. *Knowledge Based Systems*, 2015, 73(1): 254 – 264.
- [ 10 ] Dubey S R, Singh S K, Singh R K. Multichannel decoded local binary patterns for content-based image retrieval [ J ]. *IEEE Transactions on Image Processing*, 2016, 25(9): 4018 – 4032.
- [ 11 ] Fang S Y, Wang J F, Yang C, et al. Fast retrieval method of image data based on learning to hash [ J ]. *Journal of Physics: Conference Series*, 2020, 1631(1): 12 – 29.
- [ 12 ] 顾广华, 霍文华, 任贤龙, 等. 基于“点到面”策略的图像检索 [ J ]. *信号处理*, 2020, 36(9): 1464 – 1470.
- [ 13 ] Li Q, Sun Z N, He R, et al. Deep supervised discrete hashing [ C ] // 31st International Conference on Neural Information Processing Systems, 2017: 2479 – 2488.
- [ 14 ] Cao Y, Long M S, Liu B, et al. Deep Cauchy hashing for hamming space retrieval [ C ] // IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1229 – 1237.
- [ 15 ] Zhang J, Peng Y X. SSDH: Semi-supervised deep hashing for large scale image retrieval [ J ]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2019, 29(1): 212 – 225.
- [ 16 ] Li J X, Zhang B, Lu G M, et al. Relaxed asymmetric deep hashing learning: Point-to-angle matching [ J ]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(11): 4791 – 4805.
- [ 17 ] Deng J, Dong W, Socher R, et al. ImageNet: A large-scale hierarchical image database [ C ] // IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248 – 255.
- [ 18 ] 杨红菊, 李尧. 基于深度卷积网络的特征融合图像检索方法 [ J ]. *山西大学学报(自然科学版)*, 2018, 41(1): 114 – 119.
- [ 19 ] 周志华. *机器学习* [ M ]. 北京: 清华大学出版社, 2016: 60 – 63.
- [ 20 ] Giregory G, Alex H, Pietro P. Caltech-256 object category dataset [ R ]. Pasadena: California Institute of Technology, 2007.
- [ 21 ] Nene S A, Nayar S K, Murase H. Object image library (COIL-100): CUCS-006-96 [ R ]. New York: Columbia University, 1996.
- [ 22 ] Wang J Z, Li J, Wiederhold G. SIMPLcity: Semantics-sensitive integrated matching for picture libraries [ J ]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(9): 947 – 963.
- [ 23 ] Krizhevsky A. Learning multiple layers of features from tiny images [ EB/OL ]. [ 2020 – 12 – 24 ]. <https://docslib.org/doc/3916072/learning-multiple-layers-of-features-from-tiny-images>.

### (上接第 211 页)

- [ 9 ] 陈茹霞, 强振平, 邵小锋, 等. 基于 L0 范数的 Retinex 图像增强算法 [ J ]. *计算机工程与科学*, 2020, 42(7): 1244 – 1252.
- [ 10 ] Ji W, Qian Z J, Xu B, et al. A nighttime image enhancement method based on retinex and guided filter for object recognition of apple harvesting robot [ J ]. *International Journal of Advanced Robotic System*, 2018, 15(1): 1 – 12.
- [ 11 ] Wang T, Gong N S, Jiang G X. Enhanced image algorithm at night of improved Retinex based on HIS space [ C ] // Processing of the 2017 12th International Conference on Intelligent Systems and Knowledge Engineering. IEEE, 2017: 1 – 5.
- [ 12 ] 张杰, 周浦城, 薛模根. 基于方向性全变分 Retinex 的低照度图像增强 [ J ]. *计算机辅助设计与图形学学报*, 2018, 30(10): 1943 – 1953.
- [ 13 ] 涂清华, 戴声奎. 基于域滤波的自适应 Retinex 图像增强 [ J ]. *计算机工程与科学*, 2016, 38(9): 1830 – 1835.
- [ 14 ] Fu Q, Jung C, Xu K. Retinex-based perceptual contrast enhancement in images using luminance adaptation [ J ]. *IEEE Access*, 2018, 6: 61277 – 61286.
- [ 15 ] Wang J, Lu K, Xue J, et al. Single image dehazing based on the physical model and MSRCR algorithm [ J ]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, 28(9): 2190 – 2199.
- [ 16 ] 田子建, 王满利, 张元刚. 基于双域分解的图像增强算法 [ J ]. *电子学报*, 2020, 48(7): 1311 – 1320.
- [ 17 ] 李继泉, 时勤功, 李井文. 一种宽动态范围内的红外图像局部细节增强算法 [ J ]. *激光与红外*, 2019, 49(8): 1026 – 1032.
- [ 18 ] He K M, Sun J, Tang X O. Guided image filtering [ J ]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1397 – 1409.
- [ 19 ] 李忠海, 宋笑宇, 陈灿灿, 等. 基于 Retinex 算法的亮度分层图像增强算法 [ J ]. *数据采集与处理*, 2019, 34(1): 41 – 49.
- [ 20 ] 高古学, 赖惠成, 刘月琴. 结合 CLAHE 和改进 MSRCR 的沙尘图像增强 [ J ]. *计算机仿真*, 2020, 37(8): 157 – 161.
- [ 21 ] Xu L, Lu C W, Xu Y, et al. Image smoothing via  $L_0$  gradient minimization [ J ]. *ACM Transactions on Graphics*. 2011, 30(6): 174 – 184.