

图像奇异性检测的核分类新方法

孙永宣 谢 昭 高 隽

(合肥工业大学图像信息处理研究室, 安徽 合肥 230009)

摘要 利用数据空间中的奇异点可有效提升判别的准确性,关注于如何有效检测并选择奇异点,在独立子空间分析(ISA)中进行近邻传播(AP)聚类分析,形成一种无参密度估计下的新的奇异点检测方法,与支持向量机(SVM)的支持向量类似,得到新的核分类器用于分类任务。该方法可有效检测原始数据空间分布下的奇异点,实现样本选择,并可用于图像分类,图像检索等具体视觉任务。实验表明,图像奇异性检测的核方法,优于当前主流特征表示与学习方法,同时,也验证了奇异性图像检测过程可有效提升分类准确率的结论。

关键词 图像处理;可见光图像分类;奇异点检测;支持向量;独立子空间

中图分类号 TP391 文献标识码 A doi: 10.3788/AOS201333.1015001

A Novel Kernel Classification Method via Image Novelty Detection

Sun Yongxuan Xie Zhao Gao Jun

(Laboratory of Image Information Processing, Hefei University of Technology, Hefei, Anhui 230009, China)

Abstract The outliers in data space can benefit the boundary decision procedure in the training of classifiers. A new outlier detection method based on non-parametric affinity propagation clustering in independent subspace analysis (ISA) feature space is proposed. Similar to support vectors in support vector machine (SVM), the outliers are used for the training of kernel-based classifiers. Proposed method analyzes the sample distribution in original unlabeled data space, of which the samples far from exemplars are selected as outliers, and also serves as high quality training set in both image classification and retrieval tasks. Experiments show the proposed kernel method via outliers detection outperforms state-of-art feature models. Also, the results validate the outliers detection promote classification accuracy indeed.

Key words image processing; optical image classification; outlier detection; support vector; independent subspace

OCIS codes 150.4065; 330.5000; 110.2960

1 引 言

奇异性图像是指在分类判决中处于分类边界附近的图像,这些数据空间中的图像点归属不同类别的程度越接近,奇异性越大,因此奇异性较大的图像通常称为其相应数据空间中的奇异点^[1],奇异点具有混淆性,但奇异性样本对于分类器的训练学习起着至关重要的作用。

目前,国内外已逐步关注于图像奇异性检测提

升图像分类准确性的研究工作。Guo等^[2]指出高斯核变换空间中奇异样本点的筛选与构造过程,通过寻找最近边缘点重新定义核变换关系。Wu等^[1]使用小球体和大间隔(SSL)策略,将奇异性检测和二值分类过程进行有效结合,同时考虑了视频中人脸标签的奇异数据分布。Cour等^[3]在判决函数的学习过程中,针对其判决标签联合概率分布形式,引入了各样本的奇异性度量,完成视频中的人脸识别

收稿日期: 2013-04-28; 收到修改稿日期: 2013-05-21

基金项目: 国家自然科学基金(61273237,61271121)

作者简介: 孙永宣(1978—),男,博士研究生,讲师,主要从事可见光图像处理与分析等方面的研究。

E-mail: syx@hfut.edu.cn

导师简介: 高 隽(1963—),男,教授,博士生导师,主要从事光学图像处理、大气偏振光学等方面的研究。

E-mail: gaojun@hfut.edu.cn

本文电子版彩色效果请详见中国光学期刊网 www.opticsjournal.net

问题。由此可见,检测奇异点提升分类正确率的关键包含两个部分:1)有效的特征空间映射与核化表示;2)高效的奇异点检测方法。与此同时,还需综合考虑样本的可分性代价以及样本数据分布的统计特性等多种要素。

在图像特征空间描述方面,通常采用全局和局部相结合的方式,全局特征如 Gist 特征^[4-5];局部特征表示稍显复杂,在提取局部特征描述子如尺度不变特征变换算法(SIFT)^[6-7]的基础上,结合特征统计方法如词汇包(BoW)模型^[8]、空间金字塔匹配(SPM)模型^[9]等完成图像表示。由于表示过程存在信息噪声冗余,稀疏编码^[10-11]保证编码系数具有稀疏性,使得每一个图像块能够用较少的非零系数来线性表示,是一种较好的图像特征表示方法。在稀疏编码中,独立成分分析(ICA)^[12]和独立子空间分析(ISA)^[13]在图像基元的学习过程中加入了独立性约束,是一种特殊的稀疏编码方式。稀疏表示模型^[14]可以提高高光谱图像的分类性能。

图像样本奇异性检测,目的在于实现支持向量的分布捕获^[15],是基于支持向量机的图像分类的关键问题。2012年,Weinshall等^[16]研究了分类过程中不同类别的差异代表性图像,分析奇异性检测方法对分类预测能力的提升,并分析样本的概率可信度实现对新类别的检测。近邻传播聚类^[17](AP)在图论理论基础,考虑消息传播模型,能够更有效地描述样本数据的空间分布。本文旨在分析原始数据空间下的分布特性,通过无参密度估计思想,设计合理的奇异点检测方案,挑选出奇异样本集合,结合图像的有效特征表示构建分类核空间,提高分类学习过程的有效性。

2 图像奇异性检测的核分类

2.1 图像的 ISA 空间分析

ISA 特征表示图像可有效去除数据分布固有噪声的干扰,提升可分性。通过无监督方式学习得到 ISA 基元,并利用所学基元计算图像块的基元响应描述子,最后利用 SPM 模型对特征进行空间层次化的统计,得到图像 ISA 特征的统计直方图。

ISA 模型是两层结构^[13],假设基元矩阵 $\mathbf{A} = \{a_1, a_2, \dots, a_d\}$ 由 d 个基元组成,则图像块 \mathbf{b} 可通过这 d 个基元线性表示为 $\mathbf{b} = \mathbf{A}\mathbf{S}$,其中第一层响应 $\mathbf{S} = \{s_1, s_2, \dots, s_d\}^T$ 为组合系数。通常假设 \mathbf{A} 可逆,则得到 ISA 网络的第一层响应输出为 $\mathbf{S} = \mathbf{W}\mathbf{b}$,其中 $\mathbf{W} = \mathbf{A}^{-1}$ 为基元逆矩阵。ISA 网络的第二层中,第一

层输出响应分量 \mathbf{S} 被平均分为 N 个组 $\{\mathbf{S}_n | n = 1, 2, \dots, N\}$,第二层输出响应可以表示为各组分量的非线性组合,形式可表示为

$$\mathbf{U}_n = \sqrt{\sum_{i \in s_n} (s_i)^2} = \sqrt{\sum_{i \in s_n} (\mathbf{w}_i \mathbf{b})^2}. \quad (1)$$

在获取 ISA 基元后,即可通过计算 ISA 双层响应输出 \mathbf{U} 作为图像特征。并在此基础上,采用 SPM 模型进行特征统计。SPM 模型对图像特征集合进行 Kmeans 聚类得到视觉词汇,所有词汇组成词汇码本,码本长度由聚类中心数决定。假设构建的空间金字塔层数为 $l = 1, 2, \dots, L$,则每层所包含的网格数为 $C_l = 2^{2(l-1)}$ 。模型赋予不同层次以不同的权重,网格化分越细的层次包含的空间布局信息更多,故其所具有的权重越大。对于一幅场景, $h_l(i)$ 表示其在第 l 层的第 i 个网格内的特征直方图,则加权的特征直方图为

$$H_l(i) = \begin{cases} \frac{1}{2^l} h_l(i), & l = 1, 2, \dots, L-1 \\ \frac{1}{2^{L-1}} h_l(i), & l = L \end{cases}. \quad (2)$$

SPM 模型通过匹配过程在特征直方图之间寻找一致性。假设 H_l^A 和 H_l^B 分别表示图像 x_A 和 x_B 在金字塔第 l 层的特征直方图,则其匹配度可由直方图交叉函数进行计算。直方图交叉函数是对特征数据的一种非线性变换,使变换后的数据样本具有更高的可分类性。

2.2 AP 聚类的奇异性样本检测

本文提出一种基于 AP 聚类的奇异样本检测方法,用于有效估计判决边界附近的奇异样本点,并进行核空间的构建。通过本文方法选出的奇异样本集合能够有效提升分类超平面选取的准确性。

AP 聚类算法利用数据点之间的相似度构造相似度关系矩阵 \mathbf{S} ,以 \mathbf{S} 为基础经过数次迭代,在数据点之间传递消息,寻找最优的聚类代表点集合,使包含所有样本的数据空间场的能量函数 $E(c)$ 达到最小值^[17]

$$E(c) = - \sum_{i=1}^{N_m} S(i, c_i), \quad (3)$$

式中 N_m 表示数据的个数; c_i 表示点 i 所在的聚类中心点, $S(i, c_i)$ 表示点 i 与聚类中心点 c_i 之间的相似度。这里, N_m 个数据点 $x_i (i = 1, 2, \dots, N_m)$ 之间的相似性的度量一般使用负的欧氏距离来计算: $S(i, j) = - \|x_i - x_j\|$ 。相似度矩阵 \mathbf{S} 中,两样本点越相似,其相似度值就越大,与 Kmeans 等算法不同的是, AP 算法将所有数据点都作为潜在的聚类中

心,这样就避免了初始聚类中心选择的随意性。

利用 AP 算法搜寻所有样本中的聚类代表点的集合 C_x 后,为了有效实现奇异点检测,通过计算每个样本与其所属类簇的代表点之间的距离 $S(x_i, c_{x_i})$,归一化后作为该样本点的奇异性度量

$$f_i(x_i) = \frac{S(x_i, c_{x_i})}{\max\{S(x_j, c_{x_j})\}}, \quad c_j = c_{x_i}, \quad (4)$$

$$\begin{cases} X_{\text{out}} = \{X_{\text{out}, y_i}, y_i \in Y\} \\ X_{\text{out}, y_i}^{(v)} = \{x | \operatorname{argmax} f_v(x), x \in X_{y_i}, v = 1, \dots, N_v\} \end{cases}, \quad (5)$$

式中 N_v 为各分类类别的样本选择数量。总体来说,本文 AP 奇异点检测过程具有以下 4 个计算优势:

1) 奇异样本的检测剔除了样本集合中多数稳定样本点(即 Lagrange 系数 $\alpha = 0$),保证训练过程中多数样本的 $\alpha > 0$,降低了 SVM 的样本筛选代价;

2) 聚类奇异点检测方法不依赖于样本的标签,不受任务约束,属于无监督学习过程;

3) AP 聚类方法不需要定义聚类中心数量(Kmeans 和 Kcenter 方法),也不需要定义类内方差(Meanshift 方法),无参数依赖,具有稳定性;

4) 样本奇异性的定义考虑聚类后类簇内各样本的距离关系,并逐一对样本的奇异程度进行排序,不依赖于奇异样本集合数量,允许样本的选择与扩充。

通过 AP 奇异点检测得到奇异样本集合 X_{out} 之后,利用这些奇异样本构建核空间。奇异样本集合在进行核映射后的表示为

$$Z_{\text{out}}(X) = K(X, X_{\text{out}}) = \langle \varphi(X) \cdot \varphi(X_{\text{out}}) \rangle. \quad (6)$$

本文提出的基于奇异性检测核空间构建方法是对原始数据空间的深度分析过程,利用奇异性检测与支持向量的内在关联,实现核化特征变换,提高特征变换后的类间差异,既降低了 SVM 的计算代价,又提升了最优判决超平面构建的准确性。

2.3 奇异点的核分类判别

在分类(检索本质上属于弱分类)任务中需要数据集来训练任务模型^[18],然而目前训练数据集的选取大多采用随机方式,实验结果浮动且需要通过多组实验的统计数据来评价系统性能。本文采用 AP 聚类的样本距离度量方法来获得高质量的奇异样本集合 X_{out} 和核空间 $Z_{\text{out}}(X)$,进而有效指导分类器的训练过程。

具体来说,在图像检索中,通过该方法获取奇异性最高的样本集合作为检索训练的源图像集;而在图像分类中,则将该方法所得到的奇异样本集合作

在一个类簇中,远离类代表点的样本 $S(x_i, c_{x_i})$ 越大,所具有类别特征性能越好。至此,各样本点的奇异性计算过程不依赖于分类类别标签,属于无监督过程。根据具体的分类任务,为了保证各类采样数量的平衡,选取出自各分类样本集合中奇异性较大样本,构成奇异样本集合 X_{out} :

为 SVM 分类器的训练集。奇异样本集的大小可以通过(5)式中的 N_v 进行控制。最后在奇异训练集所构造的核空间内完成分类判决界面的划分。下面将通过实验证明,基于 AP 奇异点检测的训练集(即奇异样本集)构造核分类方法,不仅可以简化学习过程,而且能提高分类判决的准确性。

3 实验结果与分析

本文实验选用 MIT 的 Oliva&Torralla(简称 OT)室外场景图像集进行分类实验,包含海滨、森林、公路、城市、高山、乡村、街道和高楼共 8 个类别的图像,图像大小均为 256 pixel \times 256 pixel,共 2688 幅。

3.1 ISA 特征参数选择

设置采样图像块大小为 16 pixel \times 16 pixel, ISA 子空间大小为 4 pixel,实验发现当输入样本数为 5000 时在迭代 1000 次后仍无法得到规则性的特征基元,故选取增量样本数 $T = 10,000$,增量学习次数 $\Delta = 5$,每轮学习迭代次数 $R = 500$ 进行实验。设置 SPM 模型中的词汇码本长度 $K = 200$,金字塔层数 $L = 3$ 。

固定每类别训练集样本数为 100,训练集以外的所有图像全部作为测试集。由于基元个数 d 小于等于输入数据(即图像块)的维数,故实验分别取 d 为 40、80、120、160、200、240,考察不同基元个数下本文方法的场景检索性能。图 1 为 ISA 基元个数对场景检索性能的影响。

从图 1 可见,相较来说 $d = 120$ 时的效果最好, $d = 200$ 和 $d = 240$ 时效果明显降低。这是因为 ISA 基元是在独立性准则下优化而得,基元数 d 的增加反而会弱化基元间独立性,最终导致分类结果的降低。适量的样本个数不但可以保持最优的独立性,同

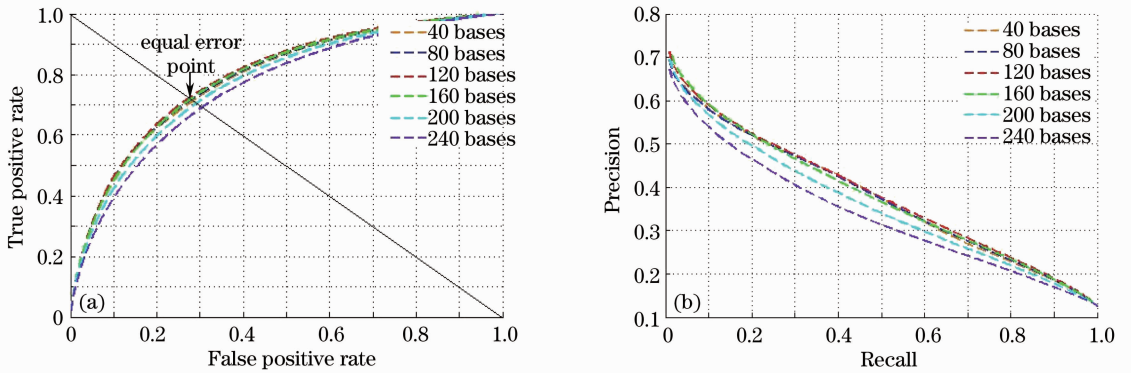


图 1 ISA 基元个数对场景检索性能的影响。(a) ROC 曲线；(b) P-R 曲线

Fig. 1 Image retrieval performance as the increasing number of ISA bases. (a) Curve of ROC; (b) curve of P-R

时也降低了特征计算时的维数,提高了特征的表征效率。

3.2 图像检索

下面选取几种经典的图像特征模型与本文所用的 ISA 特征模型的实验结果进行比较。共进行 5 组对比实验:1) Gist 特征;2) LBP 特征;3) SIFT 特征+BoW 模型;4) SIFT 特征+SPM 模型;5) SC 特征+SPM 模型。其中,Gist 特征为经典的多尺度多方向的场景全局特征;LBP 特征在纹理描述与分析中有着广泛的应用;SIFT 是一种基于梯度的图像块状描述子,是目前最有效最具代表性的局部特征,结合前文提到的 BoW 模型与 SPM 模型分别进行实验,这四种对比方法均是较为常用的特征表示方法,对分类问题具有较强的不变性和抗干扰性特点,第五种 SC+SPM 方法是最为有效的特征学习方法。

所用模型的实验参数均参考相关文献,选取常用参数如下:1) Gist 选用尺度数为 4,方向数为 8;2) LBP 选用 Uniform 模式,半径为 1,邻域为 8;3) SIFT+BoW 选用词汇码本长度为 1000;4) SIFT+SPM 选用词汇码本长度为 200,金字塔层数为 3;5) SC+SPM 基元个数为 1024,金字塔层数为 3;6) ISA 模型选用基元个数为 120,词汇码本长度为 200,金字塔层数为 3。其中,SIFT 特征与 ISA 特征的图像分块大小均为 16 pixel \times 16 pixel,块间距为 8 pixel。所有实验均在 OT 场景集中进行,每类别通过奇异性核检测方法选出 100 幅图像作为训练样本,剩余所有图像均用于测试。图 2 为 6 种特征模型在本文奇异性检测核分类方法下的检索性能定量对比,注意这里每种模型下自动选取的训练样本集合是不同的。




图 2 不同特征表示下图像检索性能评价。(a) ROC 曲线；(b) P-R 曲线

Fig. 2 Image retrieval performances in different feature representations. (a) Curve of ROC; (b) curve of P-R

对于每幅待检索图像,训练图像集中始终包含有 100 幅正例图像和 700 幅负例图像,由于负例图像所占比例较大,因而增加了检索的难度。由图 2 所示,ISA 特征模型与 SIFT+BoW 模型下的实验效果很接近,且性能较好;LBP 模型下检索性能最差,该模型不适合用于场景检索。

下面考察训练集构造方式对场景检索效果的影响,取 ISA 特征模型下不同图像类别的接受者操作特性(ROC)曲线来分析。由于场景类别数较多,因此分为两张图来显示,图 3(a)是类别为{coast, forest, highway, inside city}的场景检索性能,图 3(b)是类别为{mountain, open country, street,

tall building}的场景检索性能。图中,“AP”表示本文基于 AP 奇异点检测的训练集构造方法,“Rand”

表示传统随机训练集构造方法,实验数值为 5 次随机采样的平均检索性能。

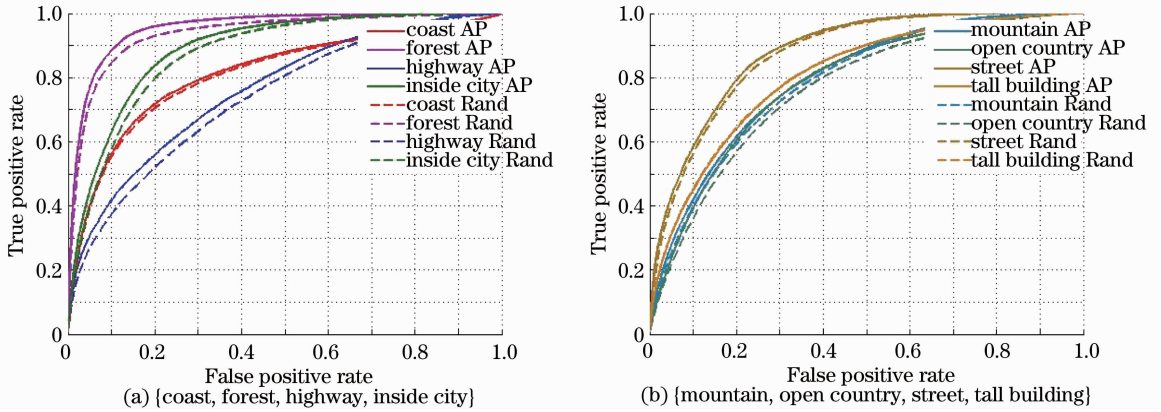


图 3 不同训练集构造方法下的图像检索性能比较

Fig. 3 Performance comparison between random training set selection and the proposed method

由图 3 可以看出,AP 奇异点检测的核化训练集选取方法下的场景检索效果基本上优于随机方法,但对每类场景检索的性能提升有高低之分。此外,在 ISA 特征模型下采用 AP 奇异点检测的核化训练集选取方法对 {forest, highway, inside city} 这几类场景性能提升较多,对 {coast, mountain, open country, street} 场景性能提升很少。总体来说,AP 奇异点检测的核化训练集选取方法下的检索结果比随机选取方法好。其他特征模型下各类场景的检索性能大致与 ISA 特征模型下的结果相同。因此,采用 AP 奇异点检测的核化训练集选取方法确实能够提高场景检索的判决精度。

表 1 和表 2 给出了 6 种图像特征模型下的检索性能定量对比,在固定的返回图像数 K 下,考察系统的平均查准率(mAP)与平均查全率(mAR)。其中,表 1 为随机训练集构造方法下的检索性能,实验

数值为 5 次随机采样的平均检索性能,表 2 为本文基于 AP 奇异点检测的训练集构造方法下的检索性能。AUC 表示曲线下面积,EER 表示平均误差率。

从表 1 和表 2 中的结果可见,随着 K 的增加,mAP 不断逼近 0.125,mAR 则逼近 1。在 $K=100$ 时,由于返回图像总数与源图像集中正例总数相等,故 mAP 与 mAR 始终相等。ISA 特征模型在相同的检索条件下总体取得了不错的效果,说明 ISA 特征空间表示方法在进行图像描述时具有一定的优势。通过对表 1 和表 2 中的数据进行对比,可知基于 AP 奇异点检测的训练集构造方法确实提高了分类器判决精度,这是因为通过奇异性检测选出的样本集合对于类别的表征性更强,并通过核化空间增大了不同类别图像间的可分性,提高了图像检索中近邻样本距离度量的准确性。

表 1 随机训练集构造方式下各模型的检索性能

Table 1 Retrieval performance of different models as training samples which are randomly selected

Model	Gist ^[4]	LBP ^[19]	SIFT+BoW ^[8]	SIFT+SPM ^[9]	SC+SPM ^[11]	ISA	
AUC	0.778	0.634	0.823	0.813	0.811	0.821	
EER	0.293	0.403	0.249	0.258	0.265	0.251	
mAP	$K=20$	0.572	0.395	0.601	0.610	0.603	0.612
	$K=50$	0.491	0.320	0.529	0.530	0.550	0.537
	$K=100$	0.408	0.266	0.449	0.444	0.443	0.450
	$K=200$	0.303	0.211	0.339	0.312	0.328	0.337
mAR	$K=20$	0.114	0.079	0.120	0.122	0.127	0.122
	$K=50$	0.245	0.160	0.264	0.265	0.265	0.269
	$K=100$	0.408	0.266	0.449	0.444	0.443	0.450
	$K=200$	0.606	0.422	0.678	0.663	0.657	0.674

表 2 基于 AP 奇异点检测的训练集构造方式下各模型的检索性能

Table 2 Retrieval performance of different models as training samples which are selected by AP outlier detection

Model	Gist ^[4]	LBP ^[19]	SIFT+BoW ^[8]	SIFT+SPM ^[9]	SC+SPM ^[11]	ISA(Ours)	
AUC	0.785	0.647	0.833	0.823	0.822	0.833	
EER	0.287	0.394	0.239	0.249	0.257	0.240	
mAP	$K=20$	0.600	0.429	0.636	0.646	0.651	0.647
	$K=50$	0.511	0.345	0.554	0.556	0.557	0.564
	$K=100$	0.422	0.282	0.466	0.463	0.467	0.468
	$K=200$	0.309	0.220	0.348	0.340	0.341	0.348
mAR	$K=20$	0.120	0.086	0.127	0.129	0.135	0.129
	$K=50$	0.255	0.172	0.277	0.278	0.274	0.282
	$K=100$	0.422	0.282	0.466	0.463	0.466	0.450
	$K=200$	0.619	0.440	0.697	0.682	0.677	0.674

3.3 图像分类

由于图像检索由弱分类器来判决,下面将本文方法用于图像分类,考察基于 AP 奇异点检测的训练集构造方法对强分类器判决的有效性。分类实验在 SVM 分类器中重复实验 5 次,计算分类正确率的均值和标准误差。图 4 给出了在 ISA 特征模型

下的图像分类混淆矩阵,图 4(a)为随机训练集构造下的结果,图 4(b)为 AP 奇异点检测的训练集构造方法下的结果,而图 4(c)为二者间的差值,通过该差值可以清楚地反映出基于奇异点检测方法下的分类结果优于随机方法。

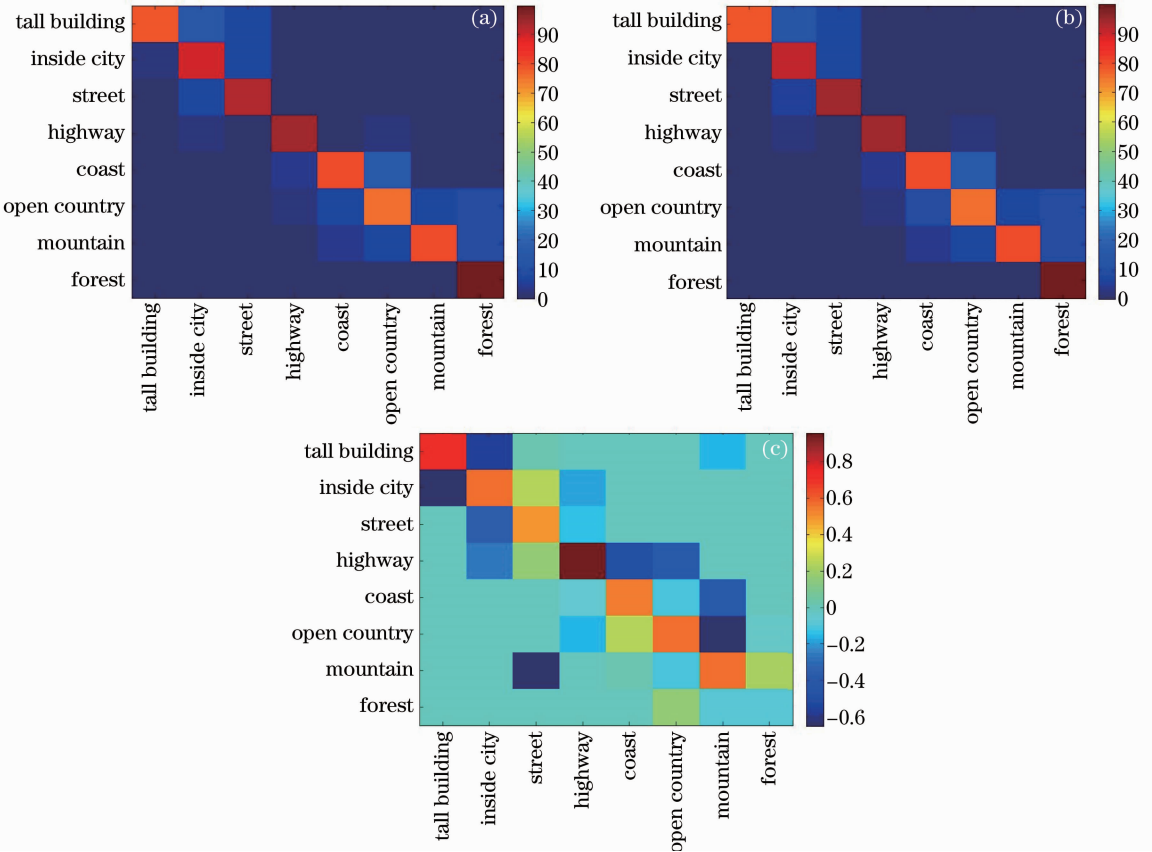


图 4 图像分类结果混淆矩阵。(a)随机训练集构造方法；(b) AP 奇异点检测的训练集构造方法；(c)两种方法分类精度的差值

Fig. 4 Confusion matrix of image classification. (a) Training samples which are randomly selected; (b) training samples which are selected by AP outlier detection; (c) difference of two methods of classification accuracy

表 3 给出了不同特征模型下的分类性能对比(‘/’左边为随机训练集构造方法下的分类性能,右边为本文基于 AP 奇异点检测的训练集构造方法下的分类性能)。

从表 3 数据来看,在特征层面上,ISA 特征模型

表 3 不同训练集构造方法下 OT 数据集的分类性能比较

Table 3 Classification performance of different training set selection methods on OT dataset

Model	Gist ^[4]	LBP ^[19]	SIFT+BoW ^[8]	SIFT+SPM ^[9]	SC+SPM ^[11]	ISA(ours)
Average /%	83.6±1.0/84.9	77.9±2.1/78.2	82.8±0.8/84.6	85.0±0.5/86.6	82.3±1.3/82.9	86.3±0.6/86.8

在训练集构造层面上,从前后数据对比可发现基于 AP 奇异点检测的训练集构造方法确实一定程度上提升了分类器的有效性,分类结果中在基于 AP 奇异点检测的训练集构造方法下的结果比随机训练集构造下的结果好。这是由于本文方法通过 AP 聚类进行奇异点检测,找出了所有样本中分类难度较高的奇异性样本,并将这些奇异样本作为训练样本集合,强调了这些样本在分类学习中所发挥的作用,不仅简化学习过程,而且提高了分类器在判决界面划分时的准确性。

本文算法的时间效率分析,重点考察 2 个步骤,即 ISA 特征训练和 AP 奇异性分析过程,也是本文的主要耗时过程。在图形处理工作站 HP Z800,4 核 CPU 2.40 GHz,内存 6.00 GB 基础上,本文算法流程的先后执行时间效率为:增量学习过程求解 ISA 基元,每 1000 个图像块训练耗时约 2313.72 s (收敛条件为循环迭代次数 500 次);每张图像 ISA 特征提取时间约 0.18 s;构建全部样本的距离空间并进行 AP 聚类分析,耗时约 34.13 s;利用聚类分析结果进行 AP 奇异点检测,耗时约 0.17 s;基于核 SVM 的图像分类耗时约 5.38 s。在相同数据集的分类过程中,SC^[11]基元对偶训练每 1000 个图像块耗时为 260 s,注意到本文提出的算法,ISA 基元训练和 AP 实例选择,不需要重复执行,本文算法执行效率与 SC+SPM 算法耗时相当。

本文方法的后续研究工作包括:1)对数据集的选取方式仍然有待探究,是否有更好的选取方法来得到更有效的数据集;2)在不同特征模型下,该方法对实验结果的提升效果不稳定,特征的复杂性对奇异样本集合是否有一定适应性;3)是否可以将该奇异性检测过程嵌入 SVM 的支持向量选择过程中,这些都将是未来研究的重点内容。

4 结 论

由于增强奇异性检测在训练学习过程中的影响

取得较好的分类效果,八类别的平均分类正确率达到 86.8%。其中,SIFT 特征的维数是 128 维,ISA 特征维数为基元个数除以分组长度也就是 $120/4=30$ 维,相较于 SIFT 得到大幅降低,提高了特征的特征效率。

作用可以提高分类器的有效性,提出一种图像奇异性检测的核分类新方法,通过奇异性训练集的构造提高了分类器的有效性。通过在图像分类和检索中的大量实验证明了基于 AP 聚类的样本距离度量方法选取出的训练集确实有效,奇异性检测核分类方法能够提高分类判决的精确度。

参 考 文 献

- 1 M Wu, J Ye. A small sphere and large margin approach for novelty detection using training data with outliers [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(11): 2088–2092.
- 2 S M Guo, L C Chen, J S H Tsai. A boundary method for outlier detection based on support vector domain description [J]. IEEE Transactions on Pattern Recognition, 2009, 42(1): 77–83.
- 3 T Cour, B Sapp, C Jordan, *et al.*. Learning from ambiguously labeled images [C]. Miami: Proceedings of CVPR Workshops IEEE Computer Society, 2009. 919–926.
- 4 A Oliva, A Torralba. Modeling the shape of the scene a holistic representation of the spatial envelope [J]. International Journal in Computer Vision, 2001, 42(3): 145–175.
- 5 A Oliva, A Torralba. Building the gist of a scene: the role of global image features in recognition [J]. Progress in Brain Research: Visual Perception, 2006, 155(1): 23–36.
- 6 M Ranzato, Huang Fujie, Y Boureau, *et al.*. Unsupervised learning of invariant feature hierarchies with applications to object recognition [C]. Minneapolis: Proceedings of CVPR, IEEE Computer Society, 2007. 31–39.
- 7 K Kavukcuoglu, M Ranzato, R Fergus, *et al.*. Learning invariant features through topographic filter maps [C]. Miami: Proceedings of CVPR IEEE Computer Society, 2009. 1605–1612.
- 8 F F Li, P Perona. A bayesian hierarchical model for learning natural scene categories [C]. San Diego: Proc of CVPR IEEE Computer Society, 2005. 524–531.
- 9 S Lazebnik, C Schmid. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories [C]. New York: Proc of CVPR IEEE Conf on Computer Society, 2006. 2169–2178.
- 10 J C Yang, K Yu, F J Lü, *et al.*. Locality-constrained linear coding for image classification [C]. San Francisco: Proceedings of CVPR IEEE Conf on Computer Society, 2010. 3360–3367.
- 11 J C Yang, K Yu, Y H Gong, *et al.*. Linear spatial pyramid matching using sparse coding for image classification [C]. Miami: Proceedings of CVPR IEEE Computer Society, 2009. 1794–1801.
- 12 C Kanan, G W Cottrell. Robust classification of objects faces and flowers using natural image statistics [C]. San Francisco:

- Proceedings of CVPR IEEE Computer Society, 2010. 2472—2479.
- 13 A Hyvärinen. Statistical models of natural images and cortical visual representation [J]. *Topics in Cognitive Science*, 2010, 2 (2): 251—264.
- 14 Song Lin, Chen Yongmei, Zhao Yongqiang. Hyper-spectrum classification based on sparse representation model and auto-regressive model [J]. *Acta Optica Sinica*, 2012, 32 (3): 0330003.
宋琳, 程咏梅, 赵永强. 基于稀疏表示模型和自回归模型的高光谱分类[J]. *光学学报*, 2012, 32(3): 0330003.
- 15 Zhao Chunhui, Qi Bin, Zhang Yi. Hyperspectral image classification based on variational relevance vector machine [J]. *Acta Optica Sinica*, 2012, 32(8): 0828004.
赵春晖, 齐滨, 张毅. 基于改进型相关向量机的高光谱图像分类[J]. *光学学报*, 2012, 32(8): 0828004.
- 16 D Weinshall, A Zweig, H Hermansky, *et al.*. Beyond novelty detection: incongruent events, when general and specific classifiers disagree [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(10): 1886—1901.
- 17 B J Frey, D Dueck. Clustering by passing messages between data points [J]. *Science*, 2007, 315(5814): 972—976.
- 18 D F Qin, S Gammeter, L Bossard, *et al.*. Hello neighbor: accurate object retrieval with k-reciprocal nearest neighbors [C]. Colorado Springs: Proceedings of CVPR IEEE Computer Society, 2011. 777—784.
- 19 T Ojala, M Pietikainen, T Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971—987.

栏目编辑: 何卓铭