

基于 TWSVM 的图像分类

朱志宾¹, 丁世飞^{1,2}

(1. 中国矿业大学计算机科学与技术学院, 江苏 徐州 221116)
(2. 中国科学院计算技术研究所智能信息处理重点实验室, 北京 100190)

[摘要] 图像分类技术是图像数据处理中最重要的技术之一. 支持向量机是基于统计学习理论而提出的机器学习算法, 在样本数少的时候能达到很好的分类效果. 孪生支持向量机是基于支持向量机而提出来的, 其性能优于支持向量机. 通过提取彩色图像的颜色特征与纹理特征, 利用孪生支持向量机与支持向量机对这些特征向量进行分类, 孪生支持向量机的分类准确率与稳定性都高于支持向量机.

[关键词] 图像分类, 支持向量机, 孪生支持向量机, 特征提取

[中图分类号] TP181 [文献标志码] A [文章编号] 1001-4616(2014)03-0008-07

Image Classification Based on Twin Support Vector Machines

Zhu Zhibin¹, Ding Shifei^{1,2}

(1. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China)
(2. Key Laboratory of Intelligent Information Processing, Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: The image classification is one of the most important technologies of image data processing. Support Vector Machine is a machine learning algorithm based on statistical learning theory, which can achieve a good classification results in the small sample size. Twin Support Vector Machines is based on Support Vector Machine, which is superior to Support Vector Machine. By extracting color features and texture features of images, using Twin Support Vector Machines and Support Vector Machine to classify these feature vectors, the results shows that the accuracy and stability of Twin Support Vector Machines is higher than Support Vector Machine.

Key words: image classification, Support Vector Machine, Twin Support Vector Machines, feature extraction

图像分类是在对图像进行分析处理时不依赖于人, 而依靠计算机技术代替人的视觉判读, 它是将图像的各个像素或区域都进行定量地分析, 将它们正确地划归为所属的类别^[1,2]. 它可以方便用户准确地找寻所需要的图片, 从另一方面来说, 这项技术还能更好地解决人工对图像分类周期长、费用高、效率低的缺点, 从长远来说, 这是一项很有价值很有发展潜力的关键技术.

20 世纪 90 年代早期, 基于统计学习理论的支持向量机 (Support Vector Machine, SVM) 这一方法被 Vapnik 等人提出^[3,4], 它是机器学习领域的一种新的方法. 它是专门为有限样本的情况而使用的, 这是非常有用的, 因为当面对样本数很少的时候它可以达到一个很好的分类泛化能力^[5]. 由于它采用结构风险最小化的原则而具有良好的学习能力和泛化性能^[6,7], 目前, SVM 被作为一种成熟的机器学习方法广泛应用于文本识别^[8]、手写字体识别^[9]、人脸图像识别^[10]、基因分类^[11]、时间序列预测^[12]等. 但在实际应用中面对大规模数据, 分类算法需要进行大量的二次规划计算, 分类计算量大分类速度慢, 速度问题上限制了 SVM 的应用.

孪生支持向量机 (Twin Support Vector Machines, TWSVM) 是 2007 年由 Jayadeva 提出^[13], 它类似于经典的 SVM, 但时间开销上缩减到 SVM 的 1/4. 将孪生支持向量机应用于图像分类中, 不仅能够得到支持向量机在图像分类中的效果, 而且能够大大地缩小运算时间. 这在面对大规模数据、运算量大的情况下, 孪生支持向

收稿日期: 2014-02-16.

基金项目: 国家重点基础研究发展规划 (973 计划) (2013CB329502)、国家自然科学基金 (61379101).

通讯联系人: 丁世飞, 博士, 教授, 博士生导师, 研究方向: 人工智能、模式识别、数据挖掘等. E-mail: dingsf@cumt.edu.cn

量机的优越性会更加的突出. 因此,将孪生支持向量机应用于实际当中,显得更为可行,而这也将成为一种趋势. 基于以上的考虑,利用 TWSVM 分类算法,可以构建出一个全新的可供研究用的图像分类算法.

在本文中,先介绍图像特征提取的一些知识,然后介绍了 SVM 的相关知识和 TWSVM 的一些理论知识,接下来讨论了 TWSVM 应用与图像分类中主要考虑的因素和需要注意的一些技术细节以及系统模型,最后对实验结果进行分析并简要介绍了存在的缺点与不足.

1 图像特征提取

特征提取是计算机视觉和图像处理中的一个概念^[14]. 它指的是使用计算机提取图像信息,决定每个图像的点是否属于一个图像特征^[15]. 特征提取是图像处理中的一个初级运算,从另一个角度上说它是对图像进行的第一个运算处理. 在这个过程中,会对图像中的每个像素进行遍历,由此而判断该像素是否为一个特征. 在平常的研究中,颜色特征、形状特征、空间关系特征、纹理特征是经常被使用的图像特征. 而在本文中,运用到的有颜色特征和纹理特征.

1.1 颜色特征

颜色是图像的一种重要视觉性质,是图像内容组成的基本要素,是人识别图像的主要感知特征之一^[16-18]. 颜色特征定义明确,其获取也比较容易. 和其他的图像特征相比较,它具有稳定性,对图像的各种变化(如旋转、平移、尺度变化等)都具有一定的不敏感性,表现出了其健壮性. 另一方面,它的计算也很简单,也正因如此,它得到了广泛的研究与重视,是在图像处理中应用最广泛的特征.

1.1.1 颜色特征提取

颜色特征提取的总体思路是选定一种颜色空间模型经过计算得到颜色直方图从而得到图像相对应的颜色特征向量.

本文采用的是 HSV 颜色空间,这是因为人们感受彩色的方式和色调与饱和度有着紧密的联系,而 HSV 模型是非常合适的选择. 其中,最重要的一步便是颜色空间的量化.

在这,有一个问题需要讨论,那就是量化级别. 很明显,将颜色空间量化为越多的区间能够得到更加准确的特征描述,而与此同时,程序的时间复杂度会相应的增加. 还有一个问题就是对量化是取均匀的还是不均匀的. 在现实中,人眼对颜色空间的感知是不均匀的,因此,采用非均匀的颜色空间量化更加符合人眼视觉的感受.

对颜色空间的量化方法有很多,本文采用非均匀的量化方法. 在这,将颜色空间非均匀量化为 256 个,将 H 量化成 16 级, S 量化成 4 级, V 量化成 4 级.

在此,对 HSV 空间的详细划分方法如下:

$$H = \begin{cases} 0, & h \in (345, 15], \\ 1, & h \in (15, 25], \\ 2, & h \in (25, 45], \\ 3, & h \in (45, 55], \\ 4, & h \in (55, 80], \\ 5, & h \in (80, 108], \\ 6, & h \in (108, 140], \\ 7, & h \in (140, 165], \\ 8, & h \in (165, 190], \\ 9, & h \in (190, 220], \\ 10, & h \in (220, 255], \\ 11, & h \in (255, 275], \\ 12, & h \in (275, 290], \\ 13, & h \in (290, 316], \\ 14, & h \in (316, 330], \\ 15, & h \in (330, 345]. \end{cases} \quad S = \begin{cases} 0, & s \in (0, 0.15], \\ 1, & s \in (0.15, 0.4], \\ 2, & s \in (0.4, 0.75], \\ 3, & s \in (0.75, 1]. \end{cases} \quad V = \begin{cases} 0, & v \in (0, 0.15], \\ 1, & v \in (0.15, 0.4], \\ 2, & v \in (0.4, 0.75], \\ 3, & v \in (0.75, 1]. \end{cases}$$

总计

$$L = H \times Q_S \times Q_V + S \times Q_V + V,$$

其中 Q_S 、 Q_V 分别是 S 和 V 的量化级数。

1.1.2 提取过程

Step 1. 读入图像,将 RGB 空间转化为 HSV 空间并用矩阵 $[h, s, v]$ 表示(假设图像是 $m \times n$ 的大小,那么 h, s, v 都是 $m \times n$ 大小的矩阵,记录了图像中每个彩色像素的 h, s, v 分量);

Step 2. 遍历 h, s, v 矩阵,将其值对应于非等间隔划分区间,来对相应的 H, S, V 矩阵赋相应的值(H, S, V 矩阵都是 $m \times n$ 大小的矩阵,记录图像每个点经过非等间隔量化后的值);

Step 3. 遍历 H, S, V 矩阵,利用公式 $L = H \times Q_S \times Q_V + S \times Q_V + V$ (Q_S 、 Q_V 分别是 S 和 V 的量化级数)将 3 个颜色分量合成为一维特征向量;

Step 4. 计算 L 的直方图,生成一个 Hist 矩阵;

Step 5. 对 Hist 矩阵进行归一化处理,最后得到的便是颜色特征向量。

1.2 纹理特征

另一个经常使用的概念是纹理. 纹理是描述图像的一个很重要的特征^[19],和颜色有点相同的地方是,它也是依赖于人的感知,并且它也拥有很广泛的应用前景,无论是在图像处理还是模式识别中. 纹理是一种局部性质,它体现的是图像的局部区域中像素与像素的关系. 另一方面,它还能定量描述图像的空间信息.

纹理具有统计特性和结构特性. 目前,有 4 种纹理分析方法:结构法,统计法,模型法,空间法/频率域联合分析法. 现在并没有形成一个大家公认的标准来对纹理特征进行精确地描述,被认为比较有效的一个方法是以灰共生矩阵为基础的提取. 这一切都是因为人的主观认知对纹理特征有很大的差异.

1.2.1 纹理特征提取

从目前大量的实验结果来看,在纹理描述上,二阶统计量能起到很好的作用. 二阶统计方法是统计方法里面最常用的. 其中共生矩阵,即灰度共生矩阵(The Spatial Gray Level Dependence Matrix)是最为出名的.

从灰度共生矩阵上能计算出 14 个二阶统计函数,分别为:能量、对比度、相关性、方差、逆差距、和平均、和方差、和熵、熵、差方差、差熵、相关性信息度量、另一个相关性信息度量、最大相关性系数.

在上述的这些纹理特征中,并不是每一个都是可行的. 有的效果并不理想,有的计算难度过大. 经过一些研究和大量实验得出,其中的 5 个特征用于描述纹理特征有很好的效果,分别是:熵(Entropy)、能量(Energy)、逆差距(Inverse Different Moment)、相关性(Correlation)和对比度(Contrast).

本文利用灰度共生矩阵中能量、熵、逆差距、相关性 4 个量,其详细计算公式如下:

$$(1) \text{能量(Energy, or Uniformity, or Angular Second Moment)}: \sum_{i,j} p(i,j)^2,$$

$$(2) \text{熵(Entropy)}: - \sum_{i,j} p(i,j) \log(p(i,j)),$$

$$(3) \text{逆差距(Inverse Difference Moment)}: \sum_{i,j} \frac{1}{1+(i-j)^2} p(i,j),$$

$$(4) \text{相关性(Correlation)}: \frac{\sum_{i,j} ij p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y},$$

其中 $p(i,j)$ 表示图像中 (i,j) 位置的灰度值, μ_x 、 μ_y 、 σ_x 和 σ_y 分别是 $p_x(i) = \sum_k p_x(i,k)$ 和 $p_x(j) = \sum_k p_y(k,j)$ 的均值和方差.

1.2.2 提取过程

Step 1. 读入图像,将各颜色分量转化为灰度 **Gray**(假设图像是 $m \times n$ 的大小,则 **Gray** 为 $m \times n$ 大小的矩阵);

Step 2. 对灰度级压缩,将 **Gray** 矩阵均匀量化为 16 级;

Step 3. 对矩阵 **Gray** 进行遍历,计算 4 个共生矩阵 P (P 为 $16 \times 4 \times 4$ 大小的矩阵),取距离为 1,角度分别为 0、45、90、135;

Step 4. 对灰度共生矩阵 P 进行归一化处理;

Step 5. 根据公式对共生矩阵计算 E (能量)、 H (熵)、 I (逆差距)、 C (相关性) 4 个纹理参数;

Step 6. 计算 E, H, I, C 的均值和标准差, 形成一个 1×8 的矩阵 T , 这便是最终的 1×8 纹理特征向量.

1.3 综合特征

本文将 256 维的颜色特征向量和 8 维的纹理特征向量组合成总维数 264 的综合特征向量, 综合特征即颜色特征和纹理特征的组合.

2 TWSVM 理论基础

孪生支持向量机是基于支持向量机而提出来的, 它相对于支持向量机有更好的性能与效率, 支持向量机在统计学习理论中十分年轻, 而孪生支持向量机却更为年轻, 它于 2007 年才被提出, TWSVM 借助于最优化的方法来解决机器学习的问题, 是数据挖掘中的一项新技术.

孪生支持向量机于 2007 年由 Jayadeva 等提出, 近几年它的理论研究以及算法实现都取得了突破性的进展. TWSVM 算法的主要优点如下:

(1) 由于该算法是基于 SVM 而提出, 形式上类似于传统支持向量机, 该算法是解决一对二次寻优问题, 而 SVM 是解决一个二次寻优问题, 因此, 和 SVM 一样, 得到的也是全局最优点, 不会有像其他算法的局部极值问题;

(2) 与 SVM 方法相比, 对一个二分类的问题, TWSVM 的时间复杂度是 SVM 的 $1/4$, 时间上远远优于 SVM, 因此在大规模数据上 TWSVM 有更好的处理能力;

(3) 二分类问题中, 往往会出现样本数据量不平衡的现象, 也就是一个样本数据少, 一个样本数据多, 当这种数量上的差距很大的时候, TWSVM 还能有较好的性能, 而 SVM 却得不到预料的效果, 因为在 TWSVM 中, 面对两类样本可以使用不同的惩罚系数 c_1 和 c_2 , 这样, TWSVM 就克服了 SVM 在处理样本不平衡问题时的缺点.

2.1 SVM 理论简介

SVM 是一种研究有限样本预测的学习方法. 和传统的统计学相比, SVM 是一种新型的结构化学习方法, 它是建立在结构风险最小化原理基础上的, 并不以传统的经验风险最小化原则作为基础.

SVM 是从线性可分情况下的最优分类面发展而来的, 其基本思想可用图 1 的两维情况说明. 图中实心点和空心点代表两类样本, H 为分类线, H_1, H_2 分别为各类中离分类线最近的样本且平行于分类线的直线, 它们之间的距离叫做分类间隔 (margin)^[20,21]. 所谓最优分类线就是要求分类线不但能将两类正确分开 (训练错误率为 0), 而且分类间隔最大. 分类线方程为 $\omega \cdot x + b = 0$, 我们对它进行归一化处理, 使得对线性可分的样本集 $(x_i, y_i), x \in \mathbf{R}^d, y_i \in \{+1, -1\}, i = 1, 2, \dots, l$, 满足

$$y_i((\omega \cdot x_i) + b) \geq 1, \quad i = 1, 2, \dots, l.$$

此时分类间隔等于 $2 / \|\omega\|^2$, 使间隔最大等价

于使 $\|\omega\|^2$ 最小. 满足上式且使得 $\frac{1}{2} \|\omega\|^2$ 最小的分类面就叫最优分类面, H_1, H_2 上的训练样本点就称作支持向量.

SVM 的一个核心是对推广能力的控制, 这种控制能够使分类间隔达到最大. SVM 实现了结构风险最小化原则.

实现结构风险最小化原则可以有两种思路: 一是在每个子集中求最小经验风险, 然后选择最小风险和置信范围之和最小的子集. 显然这种方法比较费时, 当子集数目很大甚至是无穷时将不可行. 因此有第二种思路, 即设计函数集的某种结构使每个子集都能取得最小的经验风险 (如使训练误差为 0), 然后只需选择适当的子集使置信范围最小, 则这个子集中使经验风险最小的函数就是最优函数. 下面是对第二种思路的实现:

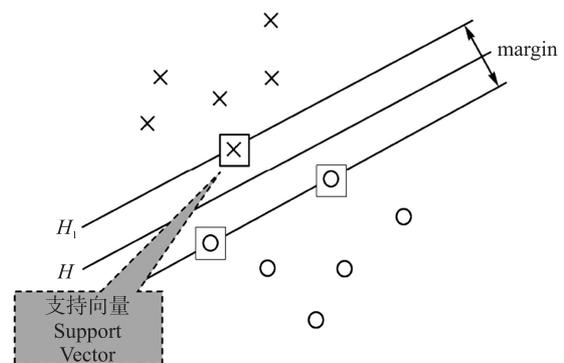


图 1 线性可分情况下的最优分类面

Fig.1 Optimal classification plane in linear case

在线性可分情况下,不同的 (ω, b) 值对应于不同的分类函数 $\omega \cdot x + b = 0$. ω 取值的不同所得到的分类函数的 VC 维不同.

(1) 寻找一种子集划分方法,使函数集的某种结构能够让每个子集都能取得最小的经验风险(如使训练误差为 0). SVM 对其的实现表现在:以 ω 的不同,划分为一系列分类函数,这些函数都能将两类点无差别地分开. 这样就固定了经验风险.

(2) 选择置信范围最小的子集. 分类间隔 $2/\|\omega\|$ 最大,使得 VC 维上界最小. 即通过这种方法,寻找到使置信范围最小的子集,该子集中的分类函数具有相同的 ω 值和不同的 b 值.

在该函数子集中寻找使经验风险为 0 的分类函数. 在 SVM 中即是利用(2)步计算出的 ω 求解 b ,使得 $\omega \cdot x + b = 0$ 能将两类点无差错地分开.

2.2 TWSVM

2007 年 Jayadeva 等提出了一种改进的二值数据的分类器双分界面支持向量机. 它在形式上类似于传统的支持向量机,具有支持向量机的优点,并且对大规模数据具有更好的处理能力.

TWSVM 为两个类各自得到一个分类平面,属于每个类的数据尽量围绕在与之相对应的分类平面周围,然后 TWSVM 通过优化一对分类平面来构建分类超平面. 也就是说 TWSVM 需要解决一对二次规划(Quadratic Programming, QP)问题,而 SVM 则是解决一个 QP 问题,但是在 TWSVM 中,其中一个类的数据要作为另一个 QP 问题的约束条件,反之亦然. TWSVM 是把经典 SVM 中的一个二次优化问题转化为两个规模较小的二次规划问题(Quadratic Programming Problem, QPP),得到了两个不平行的分类超平面,每类一个^[22-25].

孪生支持向量机求解如下两个二次优化问题:

$$\begin{aligned} \min_{w^{(1)}, b^{(1)}} \quad & \frac{1}{2} \|K(A, C')w^{(1)} + e_1 b^{(1)}\|^2 + c_1 e_2' q \\ \text{s. t.} \quad & -(K(B, C')w^{(1)} + e_2 b^{(1)}) + q \geq e_2 \\ & q \geq 0, \end{aligned} \tag{1}$$

$$\begin{aligned} \min_{w^{(2)}, b^{(2)}} \quad & \frac{1}{2} \|K(A, C')w^{(2)} + e_2 b^{(2)}\|^2 + c_2 e_1' q \\ \text{s. t.} \quad & (K(B, C')w^{(2)} + e_1 b^{(2)}) + q \geq e_1 \\ & q \geq 0, \end{aligned} \tag{2}$$

其中, K 表示核函数, A 表示 m_1 个正类样本, B 表示 m_2 个负类样本, e_1 和 e_2 为相应维数的单位向量, c_1 和 c_2 为惩罚系数, $C = \begin{pmatrix} A \\ B \end{pmatrix}$, w 和 b 分别为最优超平面的法向量和偏移量, q 为松弛变量. 通过求解式(1)、(2),得到如下两个超平面:

$$\begin{aligned} K(x', C')w^{(1)} + b^{(1)} &= 0, \\ K(x', C')w^{(2)} + b^{(2)} &= 0. \end{aligned}$$

这两个超平面分别对应一个类. 对于一个新样本 x_0 , 计算其到两个超平面的垂直距离, 如果它到正类超平面的距离小于它到负类超平面的距离, 则它属于正类, 否则它属于负类. 图 2 和图 3 分别是线性和非线性 TWSVM 的几何解释.

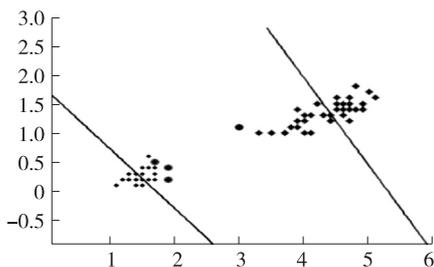


图 2 线性 TWSVM
Fig. 2 Linear TWSVM

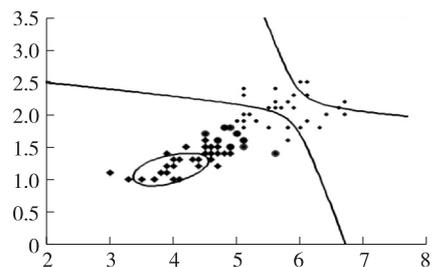


图 3 非线性 TWSVM
Fig. 3 Nonlinear TWSVM

3 实验过程及实验结果

本次实验通过互联网,从图片网站下载了共 339 幅图像,包括鸟、鱼、狗这 3 种.之所以没使用 UCI 标准数据集是因为本文对图像的特征向量的选择,维数还有提取方法都有一定的要求.为了能够有效地进行试验,实验中所选的图像类别主要有如下两个原则:第一,所选的图像不能太过抽象,如风景、季节等,这是因为这种图像很难从颜色和纹理特征上把握它的共同点;第二,同一种类别的图像之间不能出现太过相似的情况,否则实验就失去了它本身的意义.如背景颜色相同的各国国旗,它们使用传统的基于内容的检索方法就能达到极好的检索效果.

每种类别的图像数据分布见表 1.

通过上述介绍的特征提取方法,分别从这 3 类图像中提取出每幅图像的颜色特征向量、纹理特征向量以及利用这两个向量组合成的综合特征向量.

将图像的特征向量作为输入,利用 TWSVM 对其进行分类就实现了对图像进行分类.由于所设计的 TWSVM 是针对二分类的,故在进行实验的时候,是两两分开进行,得到的实验结果如表 2~4 所示(表中的时间都是以 s 为单位).

实验结果分析:

(1) 稳定性

本文使用准确率的标准差来表示分类方法的稳定性.

$$\sigma_1 = 3.172\ 06, \quad \sigma_2 = 2.614\ 2,$$

$$\sigma_3 = 5.805\ 97, \quad \sigma_4 = 4.926\ 28,$$

$$\sigma_5 = 0.421\ 591, \quad \sigma_6 = 2.439\ 6,$$

其中 σ_1, σ_2 分别表示 TWSVM、SVM 在基于颜色特征图像分类中的稳定性, σ_3, σ_4 分别表示 TWSVM、SVM 在基于纹理特征图像分类中的稳定性, σ_5, σ_6 分别表示 TWSVM、SVM 在基于综合特征图像分类中的稳定性.

从上面的结果可以得到在分类的过程中运用综合特征相较于单一特征有更好的稳定性;在单一特征下 SVM 的稳定性优于 TWSVM,综合特征下 TWSVM 的稳定性优于 SVM.

(2) 准确率

通过表 2~4 的对比可以看到,不论是基于哪种特征,TWSVM 的分类准确率都普遍高于 SVM;基于综合特征的图像分类的准确率也普遍高于基于单一特征的图像分类,并且在基于综合特征的情况下 TWSVM 的分类准确率能达到 90%.

因此,综合稳定性、准确率这两方面来看,基于图像的综合特征使用 TWSVM 分类方法来进行分类会是一个比较好的选择.

4 结语与展望

本文提出了一种基于孪生支持向量机的图像分类方法,并通过 matlab 进行实验验证了这种方法在图像分类中的良好效果.

从本文的实验结果看,使用 TWSVM 对图像进行分类能够达到预期的要求,且使用图像的综合特征还具有一定的稳定性和高准确率.使用 TWSVM 进行分类准确率普遍要比 SVM 高出 5% 左右.

另一方面,使用 TWSVM 和使用 SVM 对图像进行分类受到训练样本的影响,训练样本不同会导致分类结果波动很大,不论是 TWSVM 还是 SVM 都会出现这种现象.但对相同的训练样本与分类数据,TWSVM 和 SVM 相比显示出其在图像分类中的优越性.

表 1 各种图片数量分布

类别	鸟	狗	花
数量	106	103	130

表 2 基于颜色特征的图像分类结果

	花,鸟	花,狗	狗,鸟
TWSVM	87.500 0%	91.489 0%	83.720 0%
SVM	85.416 7%	82.978 7%	79.069 8%

表 3 基于纹理特征的图像分类结果

	花,鸟	花,狗	狗,鸟
TWSVM	85.416 7%	72.340 0%	83.720 0%
SVM	66.666 7%	65.957 4%	76.744 2%

表 4 基于综合特征的图像分类结果

	花,鸟	花,狗	狗,鸟
TWSVM	91.666 7%	91.489 4%	90.697 0%
SVM	85.416 7%	87.234 0%	81.395 3%

综上,提取图像的综合特征,利用 TWSVM 进行图像的分类能得到很好的效果. 如果对该算法做进一步的完善,实现多分类并加强纠错能力,会更加趋于实际应用.

[参考文献]

- [1] 李弼程,彭天强,彭波. 智能图像处理技术[M]. 北京:电子工业出版社,2004.
- [2] Marques de Sa J P,吴逸飞. 模式识别—原理、方法及应用[M]. 北京:清华大学出版社,2002.
- [3] Vapnik V N. 统计学习理论[M]. 许建华,张学工,译. 北京:电子工业出版社,2004.
- [4] Cristianini N,Shawe-Taylor J. 支持向量机导论[M]. 李国正,王猛,曾华军,等译. 北京:电子工业出版社,2004.
- [5] 丁世飞,齐丙娟,谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报,2011,40(1):2-10.
- [6] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报,2000,26(1):32-42.
- [7] 顾亚祥,丁世飞. 支持向量机研究进展[J]. 计算机科学,2011,38(2):14-17.
- [8] 刘晓亮,丁世飞. SVM 用于文本分类的适用性[J]. 计算机工程与科学,2010,32(6):106-108.
- [9] 林开标,王周敬. 基于支持向量机的传真收件人识别方法[J]. 计算机工程与应用,2006(7):156-158.
- [10] 谢塞琴,沈福明,邱雪娜. 基于支持向量机的人脸识别方法[J]. 计算机工程,2009,35(16):186-188.
- [11] 李颖新,阮晓钢. 基于支持向量机的肿瘤分类特征基因选择[J]. 软件工程,2005,42(10):1 796-1 801.
- [12] 高伟,王宁. 浅海混响时间序列的支持向量机预测[J]. 计算机工程,2008,34(6):25-27.
- [13] Jayadeva R K,Khemchandani R,Chandra S. Twin support vector machines for pattern classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2007,29(5):905-910.
- [14] 张志安,冯宏伟. 一种新的基于纹理和空间分布特征的图像检索[J]. 光电子学报,2008,37(2):400-403.
- [15] Pun C M, Lee M C. Rotation invariant texture feature for content based image retrieval[J]. Computer Vision and Image Understanding,2003,89(1):24-43.
- [16] Han Jun, Ma Kaikuang. Fuzzy color histogram and its use in color image retrieval [J]. IEEE Transactions on Image Processing,2002,11(8):944-952.
- [17] Deng Yining, Manjunath B S, Kenney Charles, et al. An efficient color representation for image retrieval [J]. IEEE Transactions of Image Processing,2001,1(10):140-147.
- [18] Gomez-Moreno H, Maldonado Bascon S, Lopez Ferreras F. Edge detection in noisy images by using the support vector machines[C]//International Work-Conference on Artificial Neural Networks. Heidelberg:Springer-Verlag,2001:686-692.
- [19] 常哲,候榆青,程涛,等. 综合颜色和纹理特征的图像检索[C]//全国第三届信号智能信息处理与应用学术交流会. 昆明:计算机工程与应用,2009,1(11):237-240.
- [20] Qi Bingjuan, Ding Shifei, Huang Huajuan, et al. Support vector extraction method based on clustering membership [J]. International Journal of Digital Content Technology and its Applications,2012,6(13):1-10.
- [21] 齐丙娟,丁世飞. 基于 FCM 隶属度的支持向量机[J]. 微电子学与计算机,2011,28(10):48-51.
- [22] Ding Shifei, Yu Junzhao, Huang Huajuan, et al. Twin support vector machines based on particle swarm optimization [J]. Journal of Computers,2013,8(9):2 296-2 303.
- [23] Huang Huajuan, Ding Shifei, Wu Fulin. Invasive weed optimization algorithm for optimizing the parameters of mixed kernel twin support vecotr machines [J]. Journal of Computers,2013,8(8):2 077-2 084.
- [24] Ding Shifei, Wu Fulin, Nie Ru, et al. Twin support vector machines based on quantum particle swarm optimization [J]. Journal of Software,2013,8(7):1 743-1 750.
- [25] Ding Shifei, Huang Huajuan, Nie Ru. Forecasting method of stock price based on polynomial smooth twin support vector regression [J]. Lecture Notes in Computer Science,2013,7 995:96-105.

[责任编辑:丁 蓉]