

基于模糊核聚类的图像 SVM 分类辨识

于文勇¹ 康晓东¹ 葛文杰² 王 昊¹

(天津医科大学医学影像学院 天津 300070)¹ (河北工业大学电子信息工程学院 天津 300130)²

摘要 提出一种结合特征场和模糊核聚类支持向量机的图像分类辨识方法。首先,构造符合人类视觉特性的图像彩色和纹理特征数据场,一方面,引入新阈值,建立图像纹理特征;另一方面,在图像彩色特征上,对能够引起注意的像素区域的像素点进行加权处理,并使用彩色空间分布离散度来描述彩色的空间分布。其次,采用模糊核聚类支持向量机对图像进行分类研究。在使用特征空间时,不仅考虑了样本与类中心间的关系,还考虑了类中各个样本间的关系,以模糊连接度来度量类中各个样本间的关系,并以二叉树方式构造子分类器。实验结果表明,该方法可以获得较好的图像分类效果。

关键词 支持向量机,隶属度函数,模糊核聚类,数据场

中图分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.3.063

Image Classification and Identification through SVM Based on Fuzzy Kernel Clustering

YU Wen-yong¹ KANG Xiao-dong¹ GE Wen-jie² WANG Hao¹

(School of Medical Imaging, Tianjin Medical University, Tianjin 300070, China)¹

(School of Electronic and Information Engineering, Hebei University of Technology, Tianjin 300130, China)²

Abstract A method of image classification and identification combined with characteristic field and SVM based on fuzzy kernel clustering was proposed in this paper. First, the structure corresponds to image color of human visual characteristics and data field of texture. For one thing, the new threshold is introduced and the image texture is established. For another, attractive pixel to pixel area is weighted and processed, and the spatial distribution of color is described by using dispersion of color spatial distribution. Second, SVM based on fuzzy kernel clustering is adopted to study a classification of image identification. On the feature space, not only the relationship of samples between its cluster centers but also the each samples are all taken into account. The relation between each samples in the cluster is measured based on fuzzy connectedness and a binary tree classifier is constructed. Experimental results show that this method can achieve a better effect of image classification.

Keywords Support vector machine (SVM), Membership function, Fuzzy kernel clustering, Data field

随着信息社会的发展以及各种成像设备的迅速普及,数字图像的数量急剧膨胀,如何将这些图像信息有效地组织和快速准确地分类便成了人们亟待解决的课题。目前用于图像分类的技术有很多,如贝叶斯分类器、K 近邻算法、人工神经网络(Artificial Neural Network, ANN)、AdaBoost 算法等。但这些分类方法只有在样本数目足够多的前提下,其性能才有理论上的保证,但在实际问题中,样本数量往往是有限的。因此其分类效果在实际应用中不尽人意。支持向量机(Support Vector Machine, SVM)是由 Vapnik 等人提出的一种机器学习方法,是建立在统计学习理论的 VC 维理论和结构风险最小原理基础上的,其根据有限样本信息在模型复杂性和学习能力之间寻求最佳折中,以期获得最好的推广能力。在图像分类领域,SVM 具有小样本学习、非线性、高维数、抗噪声性能、学习效率高与推广性好的优点^[1,2]。

SVM 因有统计数学支撑,且能够将低维空间中线性不可

分的点映射到高维空间中,使它们成为线性可分,以构造最优分类面,因而有着较多的应用。为适合 SVM 的大样本应用,出现了许多新算法,主要包括粒度支持向量机(Granular SVM)和模糊支持向量机(Fuzzy SVM),前者将大规模的二次规划问题(Quadratic Programming Problem, QP)分解为系列小的子问题求解,后者将模糊数学与 SVM 结合起来处理训练样本中的噪声^[3,4]。

图像样本数据采集,彩色是其最直观的视觉特征,但传统的彩色直方图(Color Histogram)分类技术只考虑了像素彩色的统计特性,忽略了彩色的空间分布信息,造成内容完全不同的图像也可有近似的彩色直方图。为增强直方图反映彩色空间分布的能力,文献[5]认为每个像素彩色子块在检索分类中所起的作用不同,提出对每个子块指定权值,并假设中心区域子块最重要。王向阳等^[6]对此方法进行了改进,提出了一种基于视觉权值分块的彩色直方图处理方法,该方法以反

到稿日期:2014-05-08 返修日期:2014-07-11

于文勇(1986—),男,硕士生,主要研究方向为图像处理;康晓东(1964—),男,博士,教授,主要研究方向为医学图像处理与医疗信息系统集成;葛文杰(1994—),男,主要研究方向为电子信息;王 昊(1984—),男,硕士生,工程师,主要研究方向为图像处理。

映局部区域变换的像素点彩色复杂度为基础,计算图像各子块的视觉权值,然后利用视觉权值对子块彩色直方图进行加权处理。邢强^[7]等提出一种基于加权彩色直方图的算法,该算法先计算像素点的彩色值在原始图像中所占比例,然后再对该像素点的灰度级进行加权处理,从而构造出能反映原始图像中不同彩色像素点数量的彩色直方图。

与彩色特征一样,图像纹理特征是反映图像数据特征的另一个方面。与仅利用彩色特征和仅利用纹理特征的图像辨识方法相比,同时结合两类特征的方法已经被证明更稳定和高效^[8-10]。

本文提出了一种结合图像特征数据场和模糊核聚类 SVM 的图像分类辨识方法。首先,构造符合人类视觉特性的图像彩色和纹理特征数据场;其次,采用模糊核聚类支持向量机方法对图像进行分类,并以二叉树方式构造子分类器,得到图像的分类结果。

1 图像特征场及其确定

1.1 彩色权值直方图及其分布

彩色直方图是 RGB 彩色通道亮度的概率分布。对于图像 $I(x_M, y_N)$, M, N 为其长和宽, $I(x, y)$ 为 I 在像素 (x, y) 处的彩色值,则 I 的彩色直方图为

$$H = (h[1], h[2], \dots, h[i], h[j]) \quad (1)$$

式中, $\sum_{i=1}^j h[i] = 1, 0 \leq h[i] \leq 1, h[i]$ 是彩色为 c_i 的频率,且有

$$h[i] = \frac{\sum_{x=1}^M \sum_{y=1}^N f(x, y, i)}{x_M y_N} \quad (2)$$

$$f(x, y, i) = \begin{cases} 1, & Q(T \times I[x, y]) = i \\ 0, & \text{other} \end{cases} \quad (3)$$

式(2)和式(3)中, Q 为图像像素的 HSV 量化过程, T 为从 RGB 到 HSV 的转化。

(1) 彩色权值直方图

一幅图像中,像素点由于其所处的位置不同,对图像内容理解所起的作用也不一样。而彩色对比度可以通过计算该像素与其多个尺度邻域的彩色差异和来得到^[11]。当其以 $S(x, y)$ 表示时,有

$$\begin{cases} S(x, y) = \frac{1}{3} [D_{\frac{w}{2}}(x, y) + D_{\frac{w}{4}}(x, y) + D_{\frac{w}{8}}(x, y)] \\ D_t(x, y) = d[c(x, y), m_t(x, y)] \\ = \sqrt{(L - L_m)^2 + (a - a_m)^2 + (b - b_m)^2} \end{cases} \quad (4)$$

式中, $D_t(x, y)$ 为 (x, y) 的像素值与其 $t \times t$ 邻域内像素的欧氏距离, $c(x, y)$ 为 (x, y) 的像素值 $[L, a, b]^T$, $m_t(x, y)$ 为 (x, y) 的 $t \times t$ 邻域内像素的平均 $[L_m, a_m, b_m]^T$, $t = \{\frac{w}{2}, \frac{w}{4}, \frac{w}{8}\}$, $w = \min(M, N)$ 。若图像噪声较大时, $c(x, y)$ 也可设定为像素 (x, y) 的一个较小的邻域,此时的 $D_t(x, y)$ 为

$$\begin{aligned} D_t(x, y) &= d[\bar{c}(x, y), m_t(x, y)] \\ &= \sqrt{(\bar{L} - L_m)^2 + (a - a_m)^2 + (b - b_m)^2} \end{aligned} \quad (5)$$

式中, $\bar{c}(x, y)$ 为 (x, y) 邻域内像素的平均 $[\bar{L}, \bar{a}, \bar{b}]$ 。

将由式(4)得到的彩色对比度 $S(x, y)$ 归一化到区间 $[0, 1]$ 上,并记为 $\tilde{S}(x, y)$,再以 $\tilde{S}(x, y)$ 对每个像素加权以构造出

可有效表达视觉特征的加权彩色直方图。即将式(2)调整为

$$h'[i] = \frac{\sum_{x=1}^M \sum_{y=1}^N \tilde{S}(x, y) f(x, y, i)}{\sum_{x=1}^M \sum_{y=1}^N \tilde{S}(x, y) f(x, y, i)} \quad (6)$$

由式(6)所得到的 $h'[i]$ 可以保证当彩色直方图对比度大时,权值 $\tilde{S}(x, y)$ 大的像素点在直方图中可有更多的贡献,而不重要像素点在直方图有很少贡献。

(2) 同种彩色像素的空间离散度

对于一般图像,虽然孤立分布的像素点与彩色块分布的像素点在统计上一样,但其所反映的图像信息可能是不一样的,为此需要进一步以同种彩色像素点空间离散度来描述像素的空间分布情况。若 A_k 为 HSV 彩色空间量化后彩色值为 c_k 的像素的集合, n 为图像彩色量化的数目。令图像中彩色量化值为 c_k 的像素取值为 1,其余像素取为 0,则取值为 1 的所有像素必在平面上形成一个点集,且该点集的离散程度就反映了图像中量化彩色为 c_k 的像素的空间分布情况^[12]。设 (x_i, y_j) 为该点集的质心, n_k 为点集中像素的数目, $n_k = \max(i, j)$,则 x_i 和 y_j 可表示为

$$\begin{cases} x_i = \frac{1}{n_k} \sum_{(x, y) \in A_k} x \\ y_j = \frac{1}{n_k} \sum_{(x, y) \in A_k} y \end{cases} \quad (7)$$

而点集 A_k 的分布情况可以用像素点的空间离散度 $\rho(k)$ 描述为

$$\rho_k = \frac{1}{n_k} \sum_{k=1}^{n_k} \sqrt{(x_k - x_i)^2 + (y_k - y_j)^2} \quad (8)$$

式中, (x_k, y_k) 为集合 A_k 中任意像素的坐标。离散度越大,则 A_k 空间分布越分散,否则分布越集中。

1.2 图像局部纹理特征确定

粗糙度 (coarseness)、对比度 (contrast) 和方向度 (directionality) 为图像纹理的重要组成部分^[13]。考虑图像 $I(x_M, y_N) \rightarrow \{0, 1, 2, \dots, L-1\}$, 其中 $x_M \in [1, H], y_N \in [1, W], H, W, L$ 分别为图像的长、宽和灰度级。则以 (x_M, y_N) 为中心的 3×3 邻域局部像素的图像的平均灰度值和灰度特征为

$$avg_{gray}(x_M, y_N) = \sum_{i=x_M-1}^{x_M+1} \sum_{j=y_N-1}^{y_N+1} \frac{1}{9} f(i, j) \quad (9)$$

和

$$C'(x_M, y_N) = \sum_{i=x_M-1}^{x_M+1} \sum_{j=y_N-1}^{y_N+1} \frac{1}{8} [f(i, j) - avg_{gray}(x_M, y_N)]^2 \quad (10)$$

(1) 图像粗糙度特征

参考文献[10],现以像素 (x_M, y_N) 粗糙度量与平均粗糙度间的差异作为该像素的粗糙度特征。对于以 (x_M, y_N) 为中心、大小为 $k \times k$ 个的像素,仿照式(9)和式(10),其水平及垂直方向的互不重叠的邻域平均灰度差为

$$\begin{cases} E_{k,u}(x_M, y_N) = |A_k(x_M+k, y_N) - A_k(x_M-k, y_N)| \\ E_{k,v}(x_M, y_N) = |A_k(x_M, y_N+k) - A_k(x_M, y_N-k)| \end{cases} \quad (11)$$

而可使 E 值无方向性地达到最大值 k 值的像素粗糙度量度为

$$k_{best}(x_M, y_N) = \max\{E_{k,\delta}(x_M, y_N) | k \in [1, 5], \delta = u, v\} \quad (12)$$

像素的平均粗糙度为

$$avg_{\text{gra}}(x_M, y_N) = \sum_{i=x_M-1}^{x_M+1} \sum_{j=y_N-1}^{y_N+1} \frac{1}{9} k_{\text{best}}(i, j) \quad (13)$$

则该像素的粗糙度特征为

$$C''(x_M, y_N) = |k_{\text{best}}(x_M, y_N) - avg_{\text{gra}}(x_M, y_N)| \quad (14)$$

(2) 图像对比度特征

局部对比度指图像局部最亮区域与最暗区域间不同亮度层级的测量,可通过统计像素灰度值的局部分布得到,即:首先计算以像素 (x_M, y_N) 为中心,大小为 3×3 像素的图像邻域中像素灰度值的四阶矩;其次,计算该图像邻域像素灰度的统计值。如

$$M_4(x_M, y_N) = \sum_{i=x_M-1}^{x_M+1} \sum_{j=y_N-1}^{y_N+1} \frac{1}{9} [f(i, j) - avg_{\text{gray}}(x_M, y_N)]^4 \quad (15)$$

和

$$C'''(x_M, y_N) = \frac{C'(x_M, y_N)}{M_4(x_M, y_N)^{\frac{1}{4}}} \quad (16)$$

(3) 图像方向度特征

图像方向度通过计算统计梯度向量的方向角局部分布情况得到,具体步骤如下:

计算像素 (x_M, y_N) 处的梯度向量和方向,依次为

$$|\Delta G(x_M, y_N)| = \frac{|\Delta u(x_M, y_N)| + |\Delta v(x_M, y_N)|}{2} \quad (17)$$

和

$$\theta(x_M, y_N) = \arctan \frac{|\Delta v(x_M, y_N)|}{|\Delta u(x_M, y_N)|} + \frac{\pi}{2} \quad (18)$$

式(17)和式(18)中, $|\Delta u(x_M, y_N)|$ 及 $|\Delta v(x_M, y_N)|$ 分别为水平和垂直方向上的变化量,其可通过图像 3×3 卷积的操作得到。

考虑对阈值 τ ,若 $|\Delta G(x_M, y_N)| < \tau$,则像素 (x_M, y_N) 处的像素方向角设为0,即^[14]

$$\theta'(x_M, y_N) = \begin{cases} 0, & \text{if } |\Delta G(x_M, y_N)| < \tau \\ \theta(x_M, y_N), & \text{其他} \end{cases} \quad (19)$$

式中, τ 也称为平滑修正方向角。此时像素的平均方向角为

$$avg_{\text{dir}}(x_M, y_N) = \sum_{i=x_M-1}^{x_M+1} \sum_{j=y_N-1}^{y_N+1} \frac{1}{9} \theta'(i, j) \quad (20)$$

则该像素的方向角与以其为中心的平均方向角间的差异为方向度特征,为

$$C''''(x_M, y_N) = |\theta'(x_M, y_N) - avg_{\text{dir}}(x_M, y_N)| \quad (21)$$

(4) 图像纹理特征场描述

将上述特征均归一化为整数,就构成了描述图像信息的特征空间。对于任意给定的图像 $I(x_M, y_N)$ ($x_M = 1, 2, \dots, M; y_N = 1, 2, \dots, N$),若设 $I_{x_M y_N}^d$ ($d = 1, 2, \dots, N_d$)为对应的特征矩阵, N_d 是特征维数目,则这些特征矩阵就实现了对图像纹理的高维描述。

特别地,当图像尺寸较大时,允许对图像进行诸如随机取样、均匀取样和非均匀取样等形式的二次采样。现采用均匀二次取样,取样窗宽为 $\epsilon = 8$,即从图像 $I(x_M, y_N)$ 中每隔 ϵ 行或 ϵ 列产生新的取样图像 I' 。显然, I' 中将仅包含 $\frac{x_M y_N}{\epsilon^2}$ 个像素的信息。

2 模糊支持向量机

对线性不可分的样本数据,SVM通过非线性映射把样本

数据从原空间映射到高维特征空间,再在高维特征空间里建立优化超平面,并在高维特征空间里进行分类。对非线性映射 $\psi(x); R^n \rightarrow H(R^n)$,SVM将训练样本数据从原空间映射到高维特征空间时,若样本集线性可分,则存在分离超平面,使得^[4]

$$y_i \{[\psi(x_i), \omega] + b\} \geq 1, i = 1, 2, \dots, l \quad (22)$$

对于一个固定的超平面,参数 (ω, b) 不唯一确定(相差一个常数因子)。故总能够找到一对 (ω, b) 使式(22)中至少有一个等式成立,为此令 $[\psi(x_i), y_i]$ 到该超平面的最小距离为 $\frac{1}{\|\omega\|}$ 。若训练样本集线性不可分(或事先不知道它是否线性可分),则允许存在一些误分类的点。现引入非负松弛变量 ζ_i ($i = 1, 2, \dots, l$),则式(22)变为

$$y_i \{[\psi(x_i), \omega] + b\} \geq 1 - \zeta_i, i = 1, 2, \dots, l \quad (23)$$

式中, ζ_i 是训练样本关于分离超平面的偏差, $\zeta_i = 0$ 时,即为完全线性可分。

为得到大边缘的最优超分类面,可使训练样本集到超平面的最小距离最大。此时,高维特征空间中线性不可分问题就转化为优化问题,有

$$\min \psi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \zeta_i \quad (24)$$

$$\text{s. t. } y_i \{[\psi(x_i), \omega] + b\} \geq 1 - \zeta_i, i = 1, 2, \dots, l$$

式中, $C > 0$ 是一个自定义的惩罚因子,它控制着对错分样本惩罚的程度。 C 越大,惩罚就越大,对错分样本的约束程度就越大。

通过Lagrange算子,可将式(24)对应地优化为

$$\begin{cases} \max W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \psi(x_i) \psi(x_j) \\ \text{s. t. } 0 \leq \alpha_i \leq C \quad \sum_{i=1}^l \alpha_i y_i = 0 \end{cases} \quad (25)$$

式(25)的优化解为 $\omega = \sum_{i=1}^l \alpha_i \psi(x_i)$ 。 α_i 是每个样本对应的拉格朗日算子。

若 $\alpha_i \geq 0$,则相应的 x_i 为支持向量SV,其判别函数为

$$f(x) = \omega \psi(x) + b = \sum_{i \in \text{SV}} \alpha_i \psi(x_i) \psi(x) + b \quad (26)$$

式(26)说明:计算判别函数 $f(x)$,不需要知道映射 ψ 的具体形式,只考虑在高维特征空间的内积运算即可,若特征空间的内积为

$$K(x, y) = \sum_i \psi_i(x) \psi_i(y) \quad (27)$$

则称式(27)的内积为核函数。常用的核函数有线性核、多项式和高斯核。特别地,对于高斯核,有

$$K(x, z) = \exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right) \quad (28)$$

式中, σ 为高斯分布宽度。此时的判别函数变为

$$f(x) = \omega \psi(x) + b = \sum_{i \in \text{SV}} \alpha_i K(x_i, x) + b \quad (29)$$

将上述扩展为多类问题,采用“一对一”方法,同时使用高斯核,即:在 N 类训练样本中构造所有可能的两类分类器,每类仅在 N 类中的2类训练样本上训练,可构造 $K = \frac{N(N-1)}{2}$ 个分类器。

SVM的最优分类面主要由支持向量决定,支持向量一般处于类边缘,但含噪声的样本也处于类边缘附近。在确定样本的隶属度时,若既考虑样本到所在类中心间的距离,也考虑

样本与类中其他样本间的关系,将样本与类中其他样本间的关系通过类中样本的紧密度来反映,则可将有效样本与含噪声样本区分。

设训练样本集为 $[y_1, x_1, \mu(x_1)], \dots, [y_n, x_n, \mu(x_n)]$ 。每个样本的特征表示为 $x_i \in R^n$,类标识为 $y_i \in \{-1, 1\}$,隶属度为 $0 < \mu(x_i) \leq 1$ 。再令 $z = \varphi(x)$ 为将训练样本从原空间 R^N 映射到高维特征空间 H 间的映射,映射关系为 φ 。由于隶属度 $\mu(x_i)$ 为该样本属于某类的可靠程度, ξ_i 是支持向量机目标函数中的分类误差项, $\mu(x_i)\xi_i$ 为带权误差项,则最优分类面应是下面目标函数的最优解^[2]。

$$\Phi(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \left[\sum_{i=1}^n \mu(x_i) \xi_i \right] \quad (30)$$

约束条件为

$$\begin{cases} y_i [(\omega^T, z_i) + b] - 1 + \xi_i \geq 0, & i=1, 2, \dots, n \\ \xi_i \geq 0, & i=1, 2, \dots, n \end{cases} \quad (31)$$

式中, C 为惩罚因子, ω 为线性分类函数 y_i 的权系数。显然,当 $\mu(x_i)$ 很小时,将减小 ξ_i 在式(30)中的影响,以致可将 x_i 看作不重要的样本。此时,相应的关于核函数最优分类面的判别函数式就成为

$$f(x) = \text{sgn} \left[\sum_{x_i \in SV} \alpha_i y_i K(x_i, x) + b \right] \quad (32)$$

仍采用高斯核, σ 为高斯分布宽度时, α_i 的条件式就成为

$$0 \leq \alpha_i \leq \mu(x_i) C; i=1, 2, \dots, n \quad (33)$$

由式(33)知, $\alpha_i > 0$ 的样本集合 x_i 为支持向量,其中满足 $0 < \alpha_i < \mu(x_i) C$ 的向量位于分类面附近;而满足 $\alpha_i = \mu(x_i) C$ 的向量为错误分类样本。

3 模糊核聚类支持向量机算法

核聚类是把低维空间中不易聚类的数据映射到高维特征空间来扩大模式类间的差异,然后在高维空间中对其进行聚类,以达到更好的聚类效果的方法。此时,隶属度函数用来反映样本间的相近信息^[15,16]。

设 $x_1, \dots, x_l \in R^n$ 为样本集,核映射 $\Phi(x_i)$ 是将样本 x_i 映射到高维特征空间 H 的非线性映射。模糊划分矩阵为 $U = \{\mu_{ij}\}, 1 \leq j \leq K, 1 \leq i \leq n, K$ 是聚类数,为一个大于1的常数; $\mu_{ij} \in [0, 1]$ 表示 x_i 隶属于第 j 个类的程度, v_j 是第 j 个簇的聚类中心, $m \in [1, \infty]$ 是模糊加权指数。设定分类数目 k ,构造 $k-1$ 个SVM子分类器。首先利用模糊聚类技术求取每类样本的聚类中心,再将其聚类成两类并将各聚类中心对应的样本数据分别标记为正类 A_1 和负类 B_1 ,构造新的训练样本集 N_1 和第一级SVM子分类器 SVM_1 。然后将 A_1 对应的聚类中心点又聚类成两类,并将各聚类中心对应的样本数据也分别标记为正类 A_2 和负类 B_2 ,构造第二级子分类器。对负类 B_2 采取相同的做法。再对 A_2 和 B_2 对应的各聚类中心分别聚类成两类,用同样的办法构造第三级子分类器,依次下去直到每个子类仅含一个聚类中心点。

对于存在混合类样本训练集合,存在3种情况:①拥有一个类标识的样本,称正类样本,设其输出为 $y_i = 1$;②拥有第二个类标识的样本,称负类样本,设其输出为 $y_i = -1$;③同时拥有第一和第二类标识的,称混合类样本,设其输出为 $y_i = 0$ 。再令样本集分别为 $X = \{(x_1, y_1, \mu_1), \dots, (x_l, y_l, \mu_l)\}, x_i \in R^d (i=1, 2, \dots, l), d$ 维空间中的第 i 个训练样本集合, $y_i \in$

$\{-1, 0, 1\}$;样本函数值 y_i 为1、-1和0的样本个数分别为 $l^+, l^-, l^0, (l^+ + l^- + l^0 = l)$; δ 是模糊隶属度,为不小于零的实数,也是模糊隶属度 μ_i 的下界, $\delta \leq \mu_i \leq 1$ 是样本点 (x_i, y_i, μ_i) 隶属于某类的程度。

不失一般性,构造第 i 个子分类器 SVM_i 时,引入核函数 $K(x_i, x_j)$,则第 i 个 SVM_i 对应的最优化问题就转化为式(25)。此时,核函数 $K(x_i, x_j)$ 应对应某特征空间 Z 中的内积,即 $K(x_i, x_j) = [\Phi(x_i), \Phi(x_j)]$,变换 $\Phi: X \rightarrow Z$ 将样本从原空间映射到特征空间。对于样本中的混合类 $X^0 = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$,类中心和半径分别定义为 a_m 和 r_m 时,有

$$\begin{cases} a_m = \frac{1}{n} \sum_{j=1}^n \Phi(x_j) \\ r_m = \max_{x_j \in X^0} \|\Phi(x_j) - a_m\| \end{cases} \quad (34)$$

用 $\mu_\delta(x_i)$ 表示样本 x_i 对类 $y \in \{-1, 0, 1\}$ 的隶属度,此时,模糊支持向量机的隶属度函数为

$$\mu_\delta(x_i) = \begin{cases} (1-\delta) \left[\frac{1-d(x_i)}{r_\delta} \right] + \delta, & d(x_i) \leq r_\delta \\ \frac{\delta}{1+d(x_i)-r_\delta}, & d(x_i) > r_\delta \end{cases} \quad (35)$$

式中, $\delta \in [0, 1], d(x_i) = \|\Phi(x_i) - a_\delta\|$ 。

结合特征场和模糊核聚类SVM图像分类的主要步骤如图1所示。

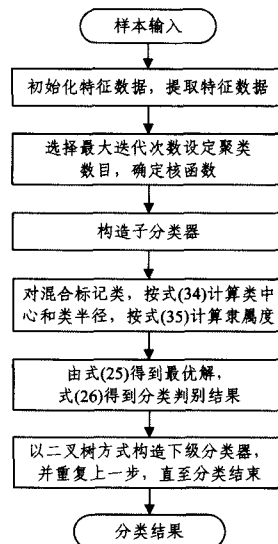


图1 算法流程图

4 应用与结果分析

为验证算法的可行性,本文以图像彩色权值直方图、图像彩色空间离散度、图像粗糙度、图像对比度和方向度等特征为样本集合,分别通过人脸表情数据库和舌苔数据对算法进行应用实验,实验环境为Dell E520, 2GB内存, Windows XP, Matlab 7.4平台。表1、表2是算法的实验结果。实验时,模糊隶属度 δ 、惩罚因子 C 和高斯分布宽度 σ^2 依据经验选取。本文中, δ 取0.4, C 取1000, σ^2 取0.65(一般为0.51)。

在进行人脸表情识别验证时,选JAFPE数据库样本,取

(下转第320页)

参 考 文 献

- [1] 陶涛,夏新宇,李琳,等. 面向数据融合计算的动画角色处理平台[J]. 合肥工业大学学报:自然科学版,2014,31(1):59-62
- [2] Zhou Ya-tong, Li Lin, Xia Ke-wen. Research on weighted priority of exemplar-based image inpainting[J]. Journal of Electronics, 2012, 29(1): 166-170
- [3] Xu Zong-ben, Sun Jian. Image inpainting by patch propagation using patch sparsity[J]. IEEE Transaction on Image Processing, 2010, 19(5): 1153-1165
- [4] Kwok Taz-Ho, Sheung H, Wang C C L. Fast query for exemplar-based image completion[J]. IEEE Transactions on Image Processing, 2010, 19(12): 3106-3115
- [5] 孟春芝,何凯,焦芳兰. 自适应样本块大小的图像修复方法[J].

- 中国图象图形学报, 2012, 17(3): 337-341
- [6] 曹健,李海生,蔡强. 图像目标的特征提取技术研究[J]. 计算机仿真, 2013, 30(1): 409-413
- [7] 孙震,王兆霞,白明,等. 基于自组织神经网络 SOM 和 K-means 聚类算法的图像修复[J]. 科学技术与工程, 2012, 12(8): 1790-1794
- [8] 罗海驰,李岳阳,孙俊. 一种基于自适应神经模糊推理系统的图像滤波方法[J]. 计算机科学, 2013, 40(7): 302-306
- [9] 张芳芳. 基于邻域梯度图像拼接算法研究[J]. 科技通报, 2012, 10(28): 61-63
- [10] 李志丹,和红杰,尹忠科,等. 基于块结构稀疏度的自适应图像修复算法[J]. 电子学报, 2013, 41(3): 549-554
- [11] 王栋,尚堃. 基于改进蚁群算法的红外图像边缘检测方法[J]. 四川兵工学报, 2014, 35(7): 87-90

(上接第 310 页)

个体的一幅表情图为测试样本,其余为训练样本。将本文方法分别与基于 k -邻近法则的 KNN 方法和基于迭代的 AdaBoost 方法比较。循环 5 次,取平均值为识别率。实验结果如表 1 所列。

表 1 人脸表情识别精度比较

	AdaBoost	KNN	本文方法
生气	89.2	90.4	90.2
开心	90.3	91.5	91.3
恐惧	87.2	87.9	88.7
伤心	90.7	91.5	91.2
惊讶	90.1	90.3	90.9
厌恶	88.8	89.2	89.5
识别率	89.4	90.1	90.3
惊讶	50.0	50.3	71.1
厌恶	50.7	49.2	70.5
识别时间	50.4	50.1	70.7

实验结果显示,在对 JAFFE 数据库进行样本识别时,本文方法的识别率略高于 KNN 法和 AdaBoost 法,说明本文方法在图像分类识别效果上有一定的提高。

以本文与天津中医药大学和北京京慧溢科技有限公司合作的方式,对涉及舌苔齿痕、胖瘦、瘀斑、老嫩、裂纹和点刺的舌形辨识做了初步验证,实验结果如表 2 所列。

表 2 舌形辨识实验结果

	识别率	识别时间(秒)
齿痕	87.2	70.3
胖瘦	80.3	69.3
瘀斑	77.2	71.7
老嫩	80.7	71.9
裂纹	80.1	69.2
点刺	78.8	69.5

显然,表 2 的实验结果一方面受中医医生主观判读的影响,另一方面与训练学习样本的规范性有关。但实验结果也同时显示,本文方法有着不错的识别率和可以接受的识别时间,因而具有一定的临床诊断应用价值。

结束语 针对图像分类辨识,本文提出一种结合特征场和模糊核聚类支持向量机的方法。首先,构造符合人类视觉特性的图像彩色和纹理特征数据场,特别是在图像彩色特征上,对能够引起注意的像素区域的像素点进行加权处理。其次,采用模糊核聚类支持向量机对图像进行分类研究,以模糊连接度来度量类中各个样本间的关系,以二叉树方式构造子

分类器。实验结果表明,本文方法可以获得较好的图像分类效果。

参 考 文 献

- [1] 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
- [2] 张翔,肖小玲,徐光祐. 模糊支持向量机中隶属度的确定与分析[J]. 中国图象图形学报, 2006, 11(8): 1188-1192
- [3] 康晓东. 医学影像图像处理[M]. 北京:人民卫生出版社, 2009
- [4] Huang C, Davis L S, Townshend J R G. An assessment of support vector machines for land cover classification[J]. Int. J. Remote Sens., 2002(23): 725-749
- [5] Li X L. Image retrieval based on perceptive weighted color blocks[J]. Pattern Recognition Letters, 2003, 24(12): 1935-1941
- [6] 王向阳,杨红颖,郑宏亮,等. 基于视觉权值的分块颜色直方图图像检索算法[J]. 自动化学报, 2010, 10: 1489-1492
- [7] 邢强,袁保宗,唐晓芳. 一种基于加权色彩直方图的快速图像检索方法[J]. 计算机研究与发展, 2005, 42(11): 1903-1910
- [8] 赵海英,徐光美,彭宏. 纹理粗糙度量算法的性能比较[J]. 计算机科学, 2011, 38(6): 288-293
- [9] 郭裕兰,鲁敏,谭志国,等. 距离图像局部特征提取方法综述[J]. 模式识别与人工智能, 2012, 25(5): 783-791
- [10] 杨关,冯国灿,陈伟福,等. 纹理分析中的图模型[J]. 中国图象图形学报, 2011, 16(10): 1818-1825
- [11] Eihhauser W, Konig P. Does luminance-contrast contribute to a saliency map for overt visual attention[J]. European Journal of Neuroscience, 2003, 17: 1089-1097
- [12] Achanta R, Hemami S, Estrada E, et al. Salient region detection and segmentation[C] // Proceedings of the 6th International Conference on Computer Vision Systems, Santorini, 2008: 66-75
- [13] Hideyuki A, Shunji M, Takashi Y. Textural Features Corresponding to Visual Perception[J]. IEEE Transactions on Systems, Man and Cybernetics, 1978, 8(6): 460-473
- [14] Rosin P L. Unimodal thresholding [J]. Pattern Recognition, 2001, 34(11): 2083-2096
- [15] 张国云,郭龙源,吴健辉,等. 计算机视觉与图像识别[M]. 北京:科学出版社, 2012
- [16] 郑文博. 基于模糊核聚类和模糊支持向量机的多标签分类方法研究[D]. 成都:西南交通大学, 2011