

核子类凸包选样的核最近邻凸包分类器^{*})

姜文瀚 周晓飞 杨静宇

(南京理工大学计算机科学与技术学院 南京 210094)

摘要 为了保证核最近邻凸包分类器有效地处理大训练集的应用问题,本文提出一种与该分类器相结合的核子类凸包样本选择方法。核子类凸包样本选择方法是一个类内迭代算法,该算法在核空间里每次迭代选择一个距离选择集样本张成子类凸包最远的样本。在 Head Pose Image Database 系列 1 图像集上的实验中,本文方法不但可以取得较高的识别率,而且与未经选样的核最近邻凸包分类器相比,其执行速度要快许多。

关键词 样本选择,凸包,核最近邻凸包,核子类凸包样本选择,模式分类,人脸识别

Kernel Nearest Neighbor Convex Hull Classifier Based on Sample Selection

JIANG Wen-han ZHOU Xiao-fei YANG Jing-yu

(Department of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract Kernel nearest neighbor convex hull (KNNCH) classifier involves solving convex quadratic programming problems, which requires large memory and long computation time for large-scale problem. Therefore, it is important for KNNCH classifier to reduce the computation complexity without degrading the prediction accuracy. This paper presents a named kernel subclass convex hull sample selection method to choose training samples for KNNCH classifier. The sample selection method is an iterative algorithm in one class, which selects the furthest sample to the subclass convex hull of the chosen set at each step in kernel space. The experiments on the Head Pose Image Database show that our approach can reach 100% recognition rate with less samples and much faster test speed than KNNCH.

Keywords Samples selection, Convex hull, Kernel nearest neighbor convex hull, Kernel subclass convex hull sample selection, Pattern classification, Face recognition

1 引言

核最近邻凸包分类器^[1] (Kernel Nearest Convex Hull, KNNCH) 的分类原理是首先通过核函数方法隐式地将样本映射到高维特征空间,然后在高维特征空间利用最近邻凸包分类原理^[2]进行分类。该分类器在人脸识别应用中表现出了好于最近邻分类器和支持向量机的分类性能^[1]。核最近邻凸包分类算法的核心是求解高维特征空间测试样本到凸包距离的凸二次规划(QP)问题。标准 QP 问题优化求解算法(如 MATLAB QP 例程)的时间复杂度是 $O(N^3)$ ^[3] (N 是样本个数),QP 方程所涉及的核矩阵大小为 $N \times N$ 。显然,随着每类训练样本个数的增多,QP 问题求解所需的内存空间快速增大,求解时间也显著增加。因此,在内存资源有限的情况下,核最近邻凸包分类器在处理较大规模数据时将面临困难。解决这一困难的一个直接有效的途径是通过样本选择来减少训练样本,从而使得分类器所涉及的优化问题规模变小。

核最近邻凸包分类器的分类决策界直接与特征空间中各类训练样本映射的凸包有关,而凸包只需其顶点或边缘点的凸组合就可以表达^[4]。本文由此提出核子类凸包样本选择方法。该样本选择方法针对一类训练样本,在与分类器相同的特征空间内选择了训练集样本映射凸包的边缘特征样本,并使得由选择样本映射生成的子凸包能够迅速逼近原训练集

全部样本映射的凸包。本文将该样本选择方法下的核最近邻凸包分类器应用于较大规模数据集的人脸识别实验。在 Head Pose Image Database 系列 1 图像库上,本文方法在保持识别率不变的前提下,比照未进行样本选择的核最近邻凸包分类器的分类效率有了显著提高。

2 核最近邻凸包分类器

对于多类分类问题,核最近邻凸包分类器分别计算高维特征空间中待鉴别样本的映射与各类别样本映射凸包的距离,然后依据最近邻原则进行归类。

假设某类别训练集 $S = \{x_i | x_i \in R^n, i = 1, 2, \dots, l\}$, 并且有特征映射 $\Phi: R^n \rightarrow H$ 可将输入空间 R^n 映射到特征空间 H 。于是, S 在特征空间 H 中的映射集为 $\tilde{S} = \{\Phi(x_i) | \Phi: R^n \rightarrow H, x_i \in S, S \subset R^n, i = 1, 2, \dots, l\}$ 。 $\tilde{S}$ 的凸包为

$$co(\tilde{S}) = \left\{ \sum_{i=1}^l \alpha_i \Phi(x_i) \mid \sum_{i=1}^l \alpha_i = 1, \alpha_i \geq 0 \right\} \quad (1)$$

对于任意一个测试样本 $x \in R^n$ 在空间 H 中的映射点为 $\Phi(x)$, $\Phi(x)$ 到凸包 $co(\tilde{S})$ 的欧氏距离平方为

$$d^2(\Phi(x), co(\tilde{S})) = \min_{\eta \in co(\tilde{S})} \|\Phi(x) - \eta\|^2 \quad (2)$$

其中 η 可由 $\tilde{S}$ 中样本的凸组合表示,即

^{*} 国家自然科学基金(the National Science Foundation of China under Grant No. 60472060 and No. 60632050)。姜文瀚 博士研究生,主要研究方向为人工智能与模式识别;周晓飞 博士研究生,主要研究方向为人工智能与模式识别;杨静宇 教授,博士生导师,主要研究方向为计算机视觉、机器学习、智能机器人与模式识别等。

$$\eta = \sum_{i=1}^l \alpha_i \Phi(x_i), \quad \sum_{i=1}^l \alpha_i = 1, \alpha_i \geq 0 \quad (3)$$

令 $\alpha = (\alpha_1, \dots, \alpha_l)^T$, 于是式(2)可化为

$$d^2(\Phi(x), co(\tilde{S})) = \min_{\alpha} \|\Phi(x) - \sum_{i=1}^l \alpha_i \Phi(x_i)\|^2 = \min_{\alpha} (\Phi(x) \cdot \Phi(x) - 2 \sum_{i=1}^l \alpha_i \Phi(x) \cdot \Phi(x_i) + \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j \Phi(x_i) \cdot \Phi(x_j))$$

$$\text{s. t. } \sum_{i=1}^l \alpha_i = 1, \alpha_i \geq 0 \quad (4)$$

又令 $e = (1, \dots, 1)^T$ 是 $l \times 1$ 的列向量, 用满足 Mercer 条件的适当的核函数替代特征空间中的内积, 即 $k(x, y) = \Phi(x) \cdot \Phi(y)$, 则优化式(4)可变为

$$d^2(\Phi(x), co(\tilde{S})) = \min_{\alpha} (k(x, x) - 2k_x^T \alpha + \alpha^T K \alpha) \quad (5)$$

其中 $k_x = (k(x_1, x), k(x_2, x), \dots, k(x_l, x))^T$,

$$K = \begin{bmatrix} k(x_1, x_1) & k(x_1, x_2) & \dots & k(x_1, x_l) \\ k(x_2, x_1) & k(x_2, x_2) & \dots & k(x_2, x_l) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_l, x_1) & k(x_l, x_2) & \dots & k(x_l, x_l) \end{bmatrix}_{l \times l}$$

式(5)是关于 α 的函数, 省略优化无关项 $k(x, x)$, 并除以 2, 得凸二次规划式

$$\min_{\alpha} \frac{1}{2} \alpha^T K \alpha - k_x^T \alpha \quad (6)$$

s. t. $e^T \alpha = 1, \alpha \geq 0$

设 v 是式(6)的最优解, 则

$$d^2(\Phi(x), co(\tilde{S})) = k(x, x) - 2k_x^T v + v^T K v \quad (7)$$

对于 c 类问题 $\omega_1, \omega_2, \dots, \omega_c$, 有 c 类训练集 $S_1, S_2, \dots, S_c \subset R^n$, 相应的各类特征空间凸包为 $co(\tilde{S}_1), co(\tilde{S}_2), \dots, co(\tilde{S}_c)$ 。对待鉴别样本 x , 分别计算该样本在特征空间的映射 $\Phi(x)$ 到各凸包的平方距离 $d^2(\Phi(x), co(\tilde{S}_1)), \dots, d^2(\Phi(x), co(\tilde{S}_c))$ 的值, 并加以比较, 依最近邻原则判别分类:

$$x \in \omega_j, j = \arg \min_i d^2(x, co(\tilde{S}_i)), i = 1, 2, \dots, c \quad (8)$$

由以上过程可见, 核最近邻凸包分类算法的核心是求解高维特征空间(核空间)测试样本到每类凸包距离的凸二次规划问题式(6)。当处理较大训练数据集的应用问题时, 核最近邻凸包分类器会遇到内存需求大(甚至无法执行)以及执行速度慢的问题。因此, 从原训练集中筛选出实际分类有益的样本, 对于核最近邻凸包分类器具有重要意义。由于在高维特征空间中各类凸包直接决定了分类的决策界, 因此可以选择那些支撑凸包边缘的特征样本以实现降低计算代价, 提高分类效率的目的。本文为此提出核子类凸包样本选择方法。该样本选择方法针对一类训练样本, 在与分类器相同的高维特征空间内选择了训练集样本映射凸包的边缘特征样本, 并使得由选择样本映射生成的子凸包能够迅速逼近原训练集全部样本映射的凸包。下面详细介绍该样本选择方法。

3 核子类凸包样本选择方法

同样假设有某类别训练集 $S = \{x_i | x_i \in R^n, i = 1, 2, \dots, l\}$ 和特征映射 $\Phi: R^n \rightarrow H(x)$ 。 S' 是 S 的选出样本集, 包含有 m 个已选择样本: $S' = \{z_1, z_2, \dots, z_m\}$, $S' \subset S$ 。 S' 在空间 H 中的映射集合为 $\tilde{S}' = \{\Phi(z_1), \Phi(z_2), \dots, \Phi(z_m)\}$, 由 $\tilde{S}'$ 生成的子类凸包定义为

$$co(\tilde{S}') = \{ \sum_{j=1}^m \alpha_j \Phi(z_j) | \sum_{j=1}^m \alpha_j = 1, \alpha_j \geq 0 \}$$

针对训练样本集 S , 首先选择其在特征空间映射相距最远的两个样本构成初始选择样本集 S' 。然后, 分别计算 S 中其它样本 x_p 的映射 $\Phi(x_p)$ 到子类凸包 $co(\tilde{S}')$ 的距离 $d^2(\Phi(x_p), co(\tilde{S}'))$, 取其中距离最大的样本加入到选出样本集 S' 当中, 并在特征空间生成新的子类凸包 $co(\tilde{S}')$ 。重复上述过程, S' 和 $co(\tilde{S}')$ 不断扩大, 直到满足指定选择样本数或距离误差界(详见算法 1)。

算法 1 (核子类凸包样本选择算法)

设某类训练样本集 S 包含 l 个样本, 已选样本子集 S' , $\tilde{S}'$ 是 S' 在特征空间的映射集合, m 是已选样本数, $k(x, y)$ 是核函数。

①初始化。设定拟选择样本个数 $\bar{m}$, 逼近误差界 ϵ , 初始最大逼近误差 $e_{\max} = \inf$; 初始选择集 $S' = \{z_1, z_2 | [z_1, z_2] = \arg \max_{x_i, x_j} \|\Phi(x_i) - \Phi(x_j)\|_2^2, x_i, x_j \in S\}$, 其中 $\|\Phi(x_i) - \Phi(x_j)\|_2^2 = (\Phi(x_i) \cdot \Phi(x_i)) - 2(\Phi(x_i) \cdot \Phi(x_j)) + (\Phi(x_j) \cdot \Phi(x_j)) = k(x_i, x_i) - 2k(x_i, x_j) + k(x_j, x_j)$

②如果选择集 S' 的样本个数 $m < \bar{m}$, 则对于 $\forall x_p \in S \setminus S'$ ($x_p \in S$ 且 $x_p \notin S'$)。令 $z_{m+1} = \arg \max_{x_p \in S \setminus S'} d^2(\Phi(x_p), co(\tilde{S}'))$, $e_{\max} = d^2(z_{m+1}, co(\tilde{S}'))$; 否则退出。

③如果 $e_{\max} > \epsilon$, 则 $S' = S' \cup z_{m+1}$; 否则退出。

④Goto②。

算法 1 中②所涉及的样本映射 $\Phi(x_p)$ 到子类凸包 $co(\tilde{S}')$ 的距离平方 $d^2(\Phi(x_p), co(\tilde{S}'))$ 的优化问题的求解过程与上节的优化问题式(2)的求解过程相同, 也是一个凸二次规划问题。该问题所涉及的核矩阵大小仅为 $m \times m$ 。在实际应用中, 每类选出集样本个数 $\bar{m}$ 一般要远小于该类别训练集样本数 l , 因此所需内存空间比较未经选择时的情况要少许多。

本文样本选择方法的目的是要在高维特征空间以较少的凸包边界样本尽可能地体现高维特征空间映射样本的类别分布, 由选择样本集 S' 在特征空间的映射集合 $\tilde{S}'$ 的子类凸包 $co(\tilde{S}')$ 逼近类集 S 的所有映射样本的类凸包 $co(\tilde{S})$ 。当距离误差界 $\epsilon = 0$ 时, 子类凸包 $co(\tilde{S}')$ 实现了对类凸包 $co(\tilde{S})$ 的最佳逼近。

4 实验与分析

本节实验采用头部姿态图像数据库(Head Pose Image Database^[5], <http://www-prima.inrialpes.fr/perso/Gourier/Faces/>)的系列 1 图像集作为验证平台。该系列包含 15 人, 每人 93 幅不同姿态的面部图像。头部水平转向 $\{-90^\circ, -75^\circ, -60^\circ, -45^\circ, -30^\circ, -15^\circ, 0^\circ, +15^\circ, +30^\circ, +45^\circ, +60^\circ, +75^\circ, +90^\circ\}$, 竖直俯仰 $\{-90^\circ, -60^\circ, -30^\circ, -15^\circ, 0^\circ, +15^\circ, +30^\circ, +60^\circ, +90^\circ\}$ 。当俯仰角度为 -90° 和 $+90^\circ$ 时, 水平向变化只有 0° 。该系列各人图像间在配饰(眼镜)、衣着、发型、性别以及肤色等方面也有所差异。图像格式为 JPEG, 分辨率为 384×288 。图 1 为该系列一个人的部分示例图像。




图 1 Head Pose Image Database 系列 1 图像示例

实验中,全部图像首先被转换成 256 级灰度图像,并双三次插值缩为 16×16 大小。按照头部姿态水平和竖直方向旋转角度组合,该图像集被分为两部分。其中水平转向 $\{-90^\circ, -60^\circ, -30^\circ, 0^\circ, +30^\circ, +60^\circ, +90^\circ\}$ 且竖直俯仰 $\{-30^\circ, 0^\circ, +30^\circ\}$ 的每人 21 ($7 \times 3 = 21$) 幅图像,共 315 幅图像构成测试集;剩余的每人 72 幅图像,共 1080 幅则作为训练集。

实验在 Pentium IV 2.8GHz CPU, 256MB 内存的 PC 机上执行。样本选择和分类算法中所涉及的优化计算均由 Matlab 优化工具箱例程来完成。

实验 1 本实验对二次核函数的采用核子类凸包样本选择方法选择样本的核最近邻凸包分类器进行测试。首先,采用二次核函数核子类凸包样本选择方法从训练集中选择样本,然后利用二次核函数核最近邻凸包器进行分类。实验就不同的选样个数,测试了相应的样本选择时间、训练集的误识数和识别率、测试集的误识数和识别率、测试集识别时间和合计时间。对训练集,统计误识数和正确识别率,目的是考察选择样本对训练集自身的表征能力;而对测试集,实验不但可以通过误识数和正确识别率来衡量选择样本对分类器泛化能力的影响,而且还可以通过选样后的测试时间以及合计时间(选样时间+测试时间)来考察样本个数对分类器执行速度的影响。实验选样个数从 2 开始逐一增加,直到测试集识别率稳定在较高水平。实验结果见表 1。其中,选样率=(每类选样数/72) $\times 100\%$,误识数是错误识别样本的个数,识别率=(正确识别样本数/识别样本总数) $\times 100\%$ 。

表 1 核子类凸包样本选择方法的核最近邻凸包分类器(二次核)

选样数 (/类)	选样 率	选样时 间(s)	训练集测试		测试集测试		测试时 间(s)	合计时 间(s)
			误识数	识别率	误识数	识别率		
2	2.8%	2.36	568	47.41%	175	44.44%	8.187	10.547
3	4.2%	4.047	445	58.80%	152	51.75%	8.937	12.984
4	5.6%	5.797	308	71.48%	113	64.13%	10.203	16
5	6.9%	7.765	191	82.31%	75	76.19%	11.641	19.406
6	8.3%	10.016	110	89.81%	40	87.30%	13.468	23.484
7	9.7%	12.515	85	92.13%	32	89.84%	15.688	28.203
8	11.1%	15.375	63	94.17%	19	93.97%	17.922	33.297
9	12.5%	18.656	43	96.02%	15	95.24%	20.578	39.234
10	13.9%	22.36	23	97.87%	7	97.78%	23.484	45.844
11	15.3%	26.64	15	98.61%	8	97.46%	26.579	53.219
12	16.7%	31.5	16	98.52%	7	97.78%	30.062	61.562
13	18.1%	36.984	14	98.70%	3	99.05%	33.875	70.859
14	19.4%	43.094	12	98.89%	5	98.41%	37.828	80.922
15	20.8%	49.515	9	99.17%	2	99.37%	42.094	91.609
16	22.2%	56.937	7	99.35%	1	99.68%	46.672	103.609
17	23.6%	65.032	4	99.63%	1	99.68%	52.125	117.157
18	25.0%	73.954	4	99.63%	1	99.68%	57.656	131.61
19	26.4%	83.625	3	99.72%	0	100.00%	63.453	147.078
20	27.8%	94.39	1	99.91%	0	100.00%	68.828	163.218
21	29.2%	105.422	0	100.00%	1	99.68%	75.078	180.5
22	30.6%	117.438	0	100.00%	1	99.68%	81.781	199.219
23	31.9%	131.234	0	100.00%	1	99.68%	90.047	221.281
24	33.3%	145.203	0	100.00%	0	100.00%	98.515	243.718
25	34.7%	159.61	0	100.00%	0	100.00%	104.25	263.86
26	36.1%	175.531	0	100.00%	0	100.00%	114.187	289.718

由表 1 中的实验结果可见,随着选样个数的增加,训练集和测试集上的识别率都获得了较为稳定的提高。就训练集测试而言,在每类别选择 15 个样本时,有 99% 以上的样本被正

确识别;当每类选样增加到 21 个时,则已不存在误识样本。这充分证实了选择样本对训练集类别所具有的良好表征能力。测试集识别率几乎与训练集保持同步,当每类别选择 16 个样本时,仅有一个样本被误识,当每类选择 24 个样本时,识别率也稳定在 100%,而此时的选样时间为 145.203s,测试集测试时间为 98.515s。

实验将以上测试集上的实验结果与不进行样本选择的二次核函数核最近邻凸包分类器进行比较,结果见表 2。

表 2 未选样和经选样二次核的 KNNCH 分类器实验结果比较

实验方法	选样数 (/类)	识别率 (%)	选样时 间(s)	测试时 间(s)	合计时 间(s)
KNNCH	未选样	100	-	945.954	945.954
选样的 KNNCH	24	100	145.203	98.515	243.718

未经选样的二次核最近邻凸包分类器对测试集也能够全部正确识别,但由于每类样本个数较多(72 个),因此测试时间较长,为 945.954s。而本节方法在全部正确识别情况下,样本选择和测试的时间合计仅为 243.718s。两者相比,有近 700s 的差距。

实验 2 为进一步验证核子类凸包样本选择方法对核最近邻凸包分类器的适用性,以及分析不同核函数对实际选样和分类过程的影响,实验改用径向基核函数,尺度参数设为 $\sigma = 6$ 。其他实验方法和条件与实验 1 相同。实验结果见表 3。

表 3 核子类凸包样本选择方法的核最近邻凸包分类器(径向基核)

选样数 (/类)	选样 率	选样时 间(s)	训练集测试		测试集测试		测试时 间(s)	合计时 间(s)
			误识数	识别率	误识数	识别率		
2	2.8%	2.313	580	46.30%	175	44.44%	8.391	10.704
3	4.2%	3.953	373	65.46%	128	59.37%	8.485	12.438
4	5.6%	5.672	218	79.81%	76	75.87%	9.453	15.125
5	6.9%	7.531	183	83.06%	68	78.41%	10.765	18.296
6	8.3%	9.671	121	88.80%	53	83.17%	12.5	22.171
7	9.7%	12.109	87	91.94%	33	89.52%	14.5	26.609
8	11.1%	14.844	60	94.44%	23	92.70%	16.562	31.406
9	12.5%	18.047	49	95.46%	18	94.29%	18.891	36.938
10	13.9%	21.625	37	96.57%	13	95.87%	21.75	43.375
11	15.3%	25.766	23	97.87%	9	97.14%	24.765	50.531
12	16.7%	30.5	17	98.43%	4	98.73%	28.235	58.735
13	18.1%	36.609	14	98.70%	4	98.73%	31.953	68.562
14	19.4%	41.593	10	99.07%	3	99.05%	35.922	77.515
15	20.8%	47.844	6	99.44%	2	99.37%	39.875	87.719
16	22.2%	54.938	6	99.44%	2	99.37%	44.375	99.313
17	23.6%	62.609	2	99.81%	1	99.68%	49.688	112.297
18	25.0%	70.953	2	99.81%	1	99.68%	55.078	126.031
19	26.4%	80.141	1	99.91%	0	100.00%	60.609	140.75
20	27.8%	89.906	1	99.91%	0	100.00%	66.141	156.047
21	29.2%	100.281	0	100.00%	0	100.00%	72.282	172.563
22	30.6%	111.359	0	100.00%	0	100.00%	79.032	190.391
23	31.9%	123.156	0	100.00%	0	100.00%	86.344	209.5

分析表 3 的实验结果,可以看到:随着选样个数的增加,训练集和测试集上的识别率同样获得了较为快速的提高。当每类选择 14 个样本时,训练集和测试集的识别率均已达到 99% 以上。当每类选样个数为 19 时,测试集识别率达到 100%;而当每类选择 21 个样本时,训练集识别率也达到了 100%。同样将该实验的测试集结果与不进行样本选择的径向基核函数核最近邻凸包分类器进行比较。尺度参数均为 σ

=6。比较结果见表4。

表4 未选样和经选样的径向基核的 KNNCH 分类器实验结果比较

实验方法	选样数 (/类)	识别率 (%)	选样时 间(s)	测试时 间(s)	合计时 间(s)
KNNCH	未选样	100	-	932.485	932.485
选样的 KNNCH	19	100	80.141	60.609	140.75

未经选样的径向基核最近邻凸包分类器 100% 识别测试样本集需要 932.485s。同样的识别率下,经核子类凸包样本选择方法选样的核最近邻凸包分类器耗时仅为 140.75s,相比减少近 800s。

综合实验 1 和实验 2 的结果数据可以看出,核子类凸包样本选择方法选择的样本能够有效地支撑核最近邻凸包分类器分类。少量的选择样本在使得分类器获得较高的正确识别比率的同时,也大大加快了算法的处理速度。此外,分类算法的存储需求也相应减少许多。如实验 2,当测试集 100% 正确识别时,每类别只需要 19 个选择训练样本;相应核矩阵占用内存少于 3K,还不到未经选样时的 7%。

实验结果同时也反映了不同核函数及其参数对算法性能的影响。就本文实验而言,基于径向基核函数(尺度参数 $\sigma=6$)的方法的结果要略好于二次核函数的。因此,本文方法在实际应用时,同样存在如何选择核函数及设置合理参数的问题。

结束语 为使核最近邻凸包分类器适应更大规模的数据

集应用,本文提出核子类凸包样本选择方法与核最近邻分类器相结合的方法。该方法首先采用核子类凸包样本选择方法对训练集样本进行选择,然后将选出样本用于核最近邻凸包分类器。在 Head Pose Image Database 系列 1 图像集上,该方法取得了较好的实验效果。实验结果表明,在保持核最近邻凸包分类器泛化性能的前提下,核子类凸包样本选择方法能够有效约减训练集样本,减少分类算法的计算量,加快分类速度,并降低算法的存储需求,从而为核最近邻凸包分类器的更大规模的数据集应用提供一条可行的解决途径。

参考文献

- [1] 周晓飞,姜文瀚,杨静宇.一种新颖的核学习算法用于小波特征的人脸识别[J]. 计算机科学,2007,34(5):224-227
- [2] 周晓飞,姜文瀚,杨静宇. L_1 范数最近邻凸包分类器在人脸识别中的应用[J]. 计算机科学,2007,34(4):234-235,238
- [3] Shin H, Cho S. Neighborhood Property based Pattern Selection for Support Vector Machines [J]. Neural Computation, 2007, 19 (3):816-855
- [4] Horst R, Pardalos PM, Thoai N V. Introduction to Global Optimization 2nd Edition [M]. Dordrecht: Kluwer Academic Publishers, 2000
- [5] Gourier N, Hall D, Crowley J L. Estimating Face Orientation from Robust Detection of Salient Facial Features [A]// Proceedings of Pointing 2004, ICPR, International Workshop on Visual Observation of Deictic Gestures [C]. Cambridge, UK

(上接第 152 页)

周期性纹理的目标比较有效。值得一提的是,当 k 的值取比较大时,计算的结果比较好,但是带来的代价是计算时间需要比较多。将实验中的图形进行一些变换,针对 100 幅图像,考察 20 个不同的 k 值进行了统计。图 3 中体现了 k 值和分类效果、运算时间的关系。




图3 k 值与分类效果和运算时间的关系

可见,恰当地选择邻域大小,可以保证较高的运算效率。但是,邻域选得太大,会花费更多的运算时间。一般说来, $k=0.5$ 左右时,本文的方法可以取得较好的效果。

结束语 本文利用平均曲率来表现曲面的固有特征,借助

纹理分析中共生矩阵的概念,将共生矩阵从针对灰度的定义延伸到针对曲面平均曲率,形成了曲率共生矩阵,并且通过归一化,设计了一类与尺度变换和旋转变换无关的不变量。实验表明,该方法和传统方法相比,在不增加复杂度的情况下,提高了识别的效率,并且在计算复杂度上也具备较大优势。

参考文献

- [1] Miao Zhenjiang, Gandelin M-H, Yuan Baozong. Fourier transform based image shape analysis and its Application to flower recognition//IEEE 6th International Conference on Singal Processing[C]. Ottawa, Canada, 2002, 2: 1087-1090
- [2] 王涛,刘文印,孙家广,等.傅立叶描述子识别物体的形状[J]. 计算机研究与发展, 2002, 39(12):1714-1719
- [3] Belkasim S O, Shridhar M, Ahmadi M. Pattern recognition with moment invariant; A comparative study and new results. Pattern Recognition, 1991, 24: 1117-1138
- [4] Dubois S R, Glanz F H. An autoregressive model approach to two dimensional shape classification. IEEE Trans on PAM I, 1986, 8: 55-56
- [5] Loui A C P, Venetsanopoulos A N. Two-dimensional shape representation using morphological correlation functions//Proceeding of the 1990 International Conference on Acoustics, Speech, and Signal Processing, Albuquerque, 1990: 2165-2168
- [6] Gupta L, Sayeh M R, Tammana R. Neural network approach to robust shape classification. Pattern Recognition, 1990, 23 (6): 563-568
- [7] Dubrovina B A, Fomenko A T, Novikov S P. Modern geometry-methods and applications (I). Second Edition, GTM, Springer-Verlag, 1999 : 61-80
- [8] 孙龙祥,程义民,王以孝,等.深度图象分析.北京:电子工业出版社,1996
- [9] 程义民,丁红侠,王以孝,等.基于几何特征的曲面物体识别.中国图象图形学报,2000,5(7):573-579
- [10] Besl P J, Jain R C. Segmentation through variable-order surface fitting. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1988, 10 (2) : 167-192
- [11] Argenti F, Alparone L, Benelli G. Fast algorithms for texture analysis using co-occurrence matrices// IEEE Proceedings, Part F: Radar and Signal Processing, 1990, 137(6):443-448