

基于混沌理论和支持向量机的人脸识别方法^①

张新明^② 徐久成

(河南师范大学计算机与信息技术学院 新乡 453007)

摘要 针对如何选定主成分分析(PCA)特征维数和如何选定支持向量机(SVM)的参数来进一步提高人脸识别系统性能的问题,提出了一种基于混沌理论和支持向量机的人脸识别方法。首先,在统一的目标函数下,在采用 PCA 方法对人脸图像进行降维和将得到的特征送入 SVM 中进行训练期间,使用具有可操作性的改进混沌优化算法同时对 PCA 图像特征维数和分类器参数进行优化选择,然后用得到的优化人脸特征和最佳参数的分类器对未知图像进行识别。基于该方法,对 ORL 和 Yale 人脸库进行实验,其识别率都高达 99% 以上,仿真结果表明,该方法极大地提高了人脸识别能力。

关键词 人脸识别,混沌优化算法(COA),支持向量机(SVM),主成分分析(PCA)

0 引言

人脸识别是利用计算机分析人脸图像,从中提取有效信息用来“辨认”对象身份的一种技术,该技术在许多领域具有广泛的应用前景,如身份自动识别系统、自动门卫系统、公共场所监控系统等。目前,人脸识别技术取得了巨大的进展,涌现了一批新的方法^[1]。但创建一个自动、高识别率的计算机人脸识别系统并非易事,有许多困难仍然没有得到解决。主成分分析(principal component analysis, PCA)^[2,3]是用于人脸特征抽取的最为经典和广泛实用的方法之一,其目的是在最小均方意义上寻找最能代表原始数据的投影方向,从而达到对特征空间进行降维的目的。但最大的问题是很难根据特征值有效选取特征向量,例如特征维数为多少才能既有利于识别性能,又能提高识别速度。特征维数不同,人脸识别率则不同,而且单纯的 PCA 法识别率不是很理想。在 20 世纪 90 年代中期,Vapnik 及其工作组基于统计学习理论提出了一种新的学习算法——支持向量机(support vector machine, SVM)方法^[4]。SVM 是为解决小样本问题学习和分类提出的,它克服了神经网络等方法所固有的过学习和欠学习问题。因此,SVM 被广泛应用于人脸识别^[5,6]。但是,SVM 的性能与核参数的选取密切相关,不同

的核参数对应着不同的识别性能。虽然很多学者都提出了核参数选择的有效办法,如留一法(leave-one-out, LOO)^[7,8]、支持向量计数法(support vector count, SVC)^[7,8]等,但 LOO 方法缺乏坚实的理论基础,而且计算复杂度高。而 SVC 方法虽然计算复杂度较低,但效果并不太好。混沌理论揭示的是有序与无序的统一,确定性与随机性的统一。混沌优化算法(chaotic optimization algorithm, COA)是一种全新的优化算法^[9],混沌运动所具有内在的随机性、遍历性、“规律”等特点,使混沌搜索能在一定范围内按其自身的“规律”不重复地遍历每一个状态,因此比随机优化方法更容易跳出“谷”、“沟”、“槽”等局部极值点,加之其算法简单易用,在数字图像处理中得到应用^[10]。由此本文提出了一种基于混沌理论和 SVM 的人脸识别方法,该方法首先利用改进的混沌优化算法对 PCA 特征维数和 SVM 的参数同时进行优化,然后用得到的优化人脸特征和最佳参数的分类器对未知图像进行识别,实验已验证了此方法的有效。

1 混沌优化算法

混沌优化算法^[9]的基本思想就是把混沌变量线性映射到优化变量的取值区间,然后利用混沌变量进行搜索。如采用 Logistic 映射混沌系统,它的模型如式

^① 河南省科技攻关项目(0624220039, 09Z102210017)和河南省教育厅科技攻关项目(2007520024, 2008B520021)资助。
^② 男,1963 年生,硕士,副教授;研究方向:混沌理论应用和数字图像处理等;联系人,E-mail:xinmingzhang@126.com
(收稿日期:2008-04-09)

$$z_{m+1} = 4z_m(1 - z_m) \quad (1)$$

所示,其连续对象的优化问题可描述为

$\min f(x_1, x_2, \dots, x_n) \quad x_i \in [a_i, b_i] \quad (i = 1, 2, \dots, n)$, 其中 x_i 为待优化的参数, $[a_i, b_i]$ 为 x_i 的取值区间。

那么优化算法的基本原理就是利用式(1)产生的混沌序列值进行“载波”,将待优化的参数与混沌变量相对应,然后进行迭代,并将每次迭代结果映射到 $[a_i, b_i]$ 区间上,得到相应的 x_i ,求出 $f(\mathbf{x})$ 的值,以判断是否最优,若不是则继续迭代。本文对文献[9]的混沌优化算法进行了改进,具体改进的优化算法的步骤如下:

步骤 1: 算法初始化。设置搜索次数和二次搜索迭代次数分别为 $M1, M2$, 对式(1)赋予 n 个微小差异的初值(注意避免取几个特殊的值 0, 0.25, 0.5, 0.75, 1) $z_{i,0}$ ($i = 1, 2, \dots, n$), 产生 n 个不同轨迹的混沌变量集合 $\{z_{i,m}\}$, 设置迭代常数 j_0 , 置 $k = 0, k' = 0, j = 0$ 。

步骤 2: 第一次载波。通过式(1)将选定的 n 个混沌变量 $z_{i,m}$ 分别引入到相应的第 i 个优化变量中使其变成混沌变量

$$x_{i,m} = a_i + (b_i - a_i)z_{i,m} \quad (2)$$

使混沌变量的变化范围分别“放大”到相应的优化量的取值范围。

步骤 3: 粗搜索。令 $x_i(k) = x_{i,m}$, 计算相应的性能指标 $f_i(k)$, 其中 $f_i(k)$ 由目标函数计算。令 $x_i^* = x_i(0), f^* = f(0)$; if $f_i(k) \leq f^*$, then $f^* = f_i(k), x_i^* = x_i(k)$ else if $f_i(k) > f^*$ then 放弃 $x_i(k)$ 。

步骤 4: 如果 $k < M1$, 那么 $k = k + 1$ 并且跳到步骤 3, 否则停止第一次搜索。

步骤 5: 第二次载波。按式

$$x'_{i,m} = x_i^* + \alpha_i(z_{i,m} - 0.5) \quad (3)$$

进行第二次载波,其中 $\alpha_i = (b_i - a_i)/(j + j_0)$, j 为迭代次数, x_i^* 为当前最优解。

步骤 6: 精搜索。令 $x_i(k') = x'_{i,m}$, 并作越界处理,若 $x_i(k') < a_i$, 则 $x_i(k') = a_i$, 若 $x_i(k') > b_i$, 则 $x_i(k') = b_i$; 计算相应的性能指标 $f_i(k')$; if $f_i(k') \leq f^*$, then $f^* = f_i(k'), x_i^* = x_i(k')$ else if $f_i(k') > f^*$ then 放弃 $x_i(k')$ 。

步骤 7: 如果 $k' < M1$, 则 $k' = k' + 1$ 并且转到步骤 6。

步骤 8: 如果 $j < M2$, 则 $j = j + 1$ 并且转到步

骤 6,否则停止第二次搜索,输出最优解。

在以上的算法中作了三点改进:第一,将原有的混沌算法中调节系数 α_i 改为与迭代次数相关;第二,在步骤 6 中增加了越界处理;第三,将原有第二次载波改为按(3)式载波。通过以上改进大大提高了混沌优化效果。

通过以下两个连续函数优化例子(求最小值)来比较本文提出的混沌优化算法的性能:

$$\begin{aligned} F1 &= 100(x_1^2 - x_2)^2 + (1 - x_1)^2 \\ -2.048 &\leq x_i \leq 2.048 \\ F2 &= 5e^{-0.5x} \sin(30x) + e^{0.2x} \sin(20x) + 6 \\ 0 &\leq x \leq 8 \end{aligned}$$

对于 $F1$ (此函数的最优目标值为 0), 文献[11]中用遗传算法在种群大小为 50、采用浮点数编码、随机联赛选择、算术交叉、交叉概率 0.8、非均匀变异、变异概率 0.05 等设置下取得最佳值 $7.76046e-4$, 平均时间 3.9392(s), 而利用本文的混沌优化算法, 最佳值为 $3.3812e-8$, 平均时间为 0.0228(s)。

对于 $F2$, 文献[12]中用蚁群算法并进行了如下设置:

$$\begin{aligned} m &= 10, \alpha = 1, \beta = 2.5, \rho_{\min} = 0.2, \tau_{ij} = 1, \\ \Delta\tau_{ij}(0) &= 0, N_C = 0, N_{C\max} = 20, Q = 30 \end{aligned}$$

表 1 给出了这种算法与本文的混沌算法的对比。

表 1 蚁群算法与本文的混沌算法对比

算法类型	最优目标值	运算次数	minF 均值
文献[12]蚁群算法	1.2573	1000	1.4095
本文的混沌算法	1.2573	720	1.2573

从以上两个算例的优化结果可以看出:无论从优化的准确性还是运行时间,本文提出的混沌优化算法远远好于遗传算法和蚁群算法,主要原因有两点:其一,混沌优化算法直接利用混沌序列遍历性进行优化,而没有其他诸如交叉、变异、更新信息素等操作,节约了时间;其二,混沌优化擅长处理连续域优化问题,搜索过程按混沌运动自身规律进行,不是按某种概率接受“劣解”跳出局部最优解,所以搜索时间短,效率高。例如对于 $F2$, 本文的优化算法在准确性高的情况下目标函数运算次数(720)少于蚁群算法。而且相比之下,混沌优化算法需要设置的参数少,易于掌控。所以本文利用混沌优化算法在最小误差上界函数为目标函数情况下对 SVM 参数进行优化。

2 支持向量机及核参数

设包含 l 个样本的训练集 $\{\mathbf{x}_k, y_k\}_{k=1}^l, \mathbf{x}_k \in \mathbf{R}^q$ 为输入向量, $y_k \in \{-1, +1\}$ 为类别标识。SVM 就是通过映射 $\psi: \mathbf{x} \rightarrow z$ 将输入向量 $\mathbf{x} \in \mathbf{R}^q$ 变换到一个高维特征空间 $z \in \mathbf{F}$, 在特征空间寻找最优的线性分类面。

对于线性可分 SVM(无训练误差), 最优分类面可以通过求解下述优化问题获得^[4]:

$$\min_{w,b} \frac{1}{2} w^T w \quad (4)$$

约束条件: $y_k(w^T \psi(\mathbf{x}_k) + b) \geq 1, k = 1, 2, \dots, l$ 。

根据最优化理论,SVM 决策函数如下:

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i \in SV} a_i^0 y_i K(\mathbf{x}, \mathbf{x}_i) + a_0\right) \quad (5)$$

其中, a_i^0 为下列优化问题的最优解:

$$W(\mathbf{a}) = \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (6)$$

约束条件: $\sum_{i=1}^l a_i y_i = 0$, 且 $a_i \geq 0, i = 1, 2, \dots, l$ 。

函数 $[K]_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \langle \psi(\mathbf{x}_i), \psi(\mathbf{x}_j) \rangle$ 为满足 Mercer 条件的核函数。如果训练样本 \mathbf{x}_i 对应的 $a_i > 0$, 那么它就是支持向量。

Vapnik 给出了线性可分 SVM 的误差上界函数:

$$T = \frac{1}{l} \frac{R^2}{r^2} = \frac{1}{l} R^2 \|w\|^2 \quad (7)$$

R 和 r 为包含所有 $\psi(\mathbf{x}_k)$ 的最小球半径和分类间隔。

对于线性可分 SVM, 由于训练误差为零, 因此易于产生分类器过训练的情况, 推广性能差。因此在实际应用中, 为保证分类器具有良好的推广性, 允许一定的训练误差存在。

对于线性不可分的 SVM, 允许存在一定的训练误差, 需在式(4)中增加一个松弛项。当松弛项为训练误差的平方时, 式(4)变为

$$\min_{w,b,\xi} \frac{1}{2} w^T w + \frac{C}{2} \sum_{i=1}^l \xi_i^2 \quad (8)$$

其中 ξ_i 为训练误差, C 为惩罚因子, 起调节误差与正则项 $w^T w / 2$ 间比例的作用。该问题的对偶问题为:

$$\begin{aligned} W(\mathbf{a}) &= \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) - \frac{1}{2C} \sum_{i=1}^l a_i^2 \\ &= \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j K_C(\mathbf{x}_i, \mathbf{x}_j) \end{aligned} \quad (9)$$

约束条件: $\sum_{i=1}^l a_i y_i = 0$, 且 $a_i \geq 0, i = 1, 2, \dots, l$ 。其中

$$[K_C]_{ij} = K_C(\mathbf{x}_i, \mathbf{x}_j) = [K + \frac{1}{C} I]_{ij} \quad (10)$$

I 为单位矩阵, 根据式(10)修改核矩阵, 式(8)所表示的问题转化为了线性可分情况, 惩罚因子 C 可以看作是 SVM 的一个参数。

根据 Vapnik 的理论, 分类间隔可以表示为

$$\|w\|^2 = 2W(\mathbf{a}^0)$$

$$= 2 \sum_{i=1}^l a_i^0 - \sum_{i,j=1}^l a_i^0 a_j^0 y_i y_j K_C(\mathbf{x}_i, \mathbf{x}_j) \quad (11)$$

最小球半径 R 可以由下列优化问题获得:

$$R^2 = \max_{\beta} \sum_{i=1}^l \beta_i K_C(\mathbf{x}_i, \mathbf{x}_i) - \sum_{i,j=1}^l \beta_i \beta_j K_C(\mathbf{x}_i, \mathbf{x}_j) \quad (12)$$

约束条件: $\sum_{i=1}^l \beta_i = 1$, 且 $\beta_i \geq 0, i = 1, 2, \dots, l$ 。

当选择高斯函数为核函数时, 则有

$$K(\mathbf{x}, \mathbf{y}) = \exp\left\{-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right\}, \sigma \text{ 是高斯核 SVM 的另一个参数。}$$

3 基于混沌理论和支持向量机的人脸识别

3.1 人脸特征提取

PCA 起源于 K-L 变换^[13], 具体算法如下:

将大小为 $w \times h$ 的一幅人脸图像按列展开, 形成 $n = w \times h$ 维的向量 $\mathbf{x}_i (i = 1, 2, \dots, M)$, 其中 M 为样本数。则样本的协方差矩阵为

$$\mathbf{S}_t = \frac{1}{M} \sum_{i=1}^M \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^T = \frac{1}{M} \Phi_t \Phi_t^T$$

其中 $\bar{\mathbf{x}}_i = \mathbf{x}_i - \bar{\mathbf{x}}$, $\Phi_t = [\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \dots, \bar{\mathbf{x}}_M]$, $\bar{\mathbf{x}}$ 为所有样本的总体平均向量。求解 \mathbf{S}_t 的特征值, 并将其按降序方式排列, 则定义前 $N (N \leq n)$ 个最大值对应的特征向量 $v_j (j = 1, 2, \dots, N)$ 为主元。将这 N 个向量张成一个子空间, 并把一幅人脸图像的样本向量向这一子空间投影, 形成 N 个投影分量(一般情况下, 依据最优化准则来确定 N)。由这 N 个投影分量构成的 N 维向量称为该图像的特征向量, 将其作为人脸识别的依据, 这样就把人脸图像向量从原来的 n 维降到了 N 维。

3.2 人脸识别系统

确定目标函数(7)式应该是 $T = f(C, \sigma, N)$, 其

中 C 是 SVM 的惩罚因子, σ 是高斯核参数, N 是 PCA 提取的特征向量维数。基于混沌理论和 SVM 的人脸识别系统流程如下:首先获取图像数据,进行必要的预处理,如直方图均衡和能量归一化处理,在此统一的目标函数之下,再利用混沌优化算法对 C , σ , N 同时进行优化。在混沌优化算法中,第一,给 N 、 C 和 σ 设定取值区间,第二,进行 K-L 变换降维获取特征和训练 SVM, 经过二次载波和混沌搜索,当 T 达到最小时,获取最佳的 C , σ 和 N 。最后用得到的 C 、 σ 和 PCA 特征对未知图像测试 SVM, 获取识别结果。

4 仿真实验及结果分析

为了验证本文方法的有效性,将本文方法在 ORL 人脸库 (<http://www.uk.research.att.com/facedatabase.html>) 和 Yale 人脸库 (<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>) 上进行了测试。ORL 人脸库包含 40 个人,每个人有 10 幅图像。图像为单一深色背景的正面图像,包含了一定的光照变化、表情变化(睁眼和闭眼,笑与不笑)、面部细节变化(戴眼镜与不戴眼镜)以及一定范围内的深度旋转。这些图像大小均为 92×112 像素。对每个人,选取 4 张图像作为训练样本,其余的 6 张用来测试识别方法的性能。由于 ORL 人脸库的图像(部分见图 1)背景单一,仅仅将图片由 112×92 分辨率降为 28×23 (为了提高优化速度),未作其他预处理。Yale 人脸库包含 15 类人脸,每类人脸有 11 幅图像,图像中光照条件、人的表情和姿态有着很大程度的变化,为了提高处理时间,将这些图像也仅做了裁减,裁减为 50×50 (部分图像见图 2)。实验软件环境为 Matlab 6.5,硬件环境为神舟承龙 S263C 笔记本电脑(CPU 为 AMD2600+(1.6G)、内存 256M)。其中实验 1、2、3 是在 ORL 人脸库上进行的。参考文献[14]和[15]中都用到了 PCA 和 SVM,其中文献[14]实验条件是:固定 PCA 特征维数 64,核参数依据实验结果手动调整,文献[15]核参数也是手动确定的。



图 1 在 ORL 中的一些图像

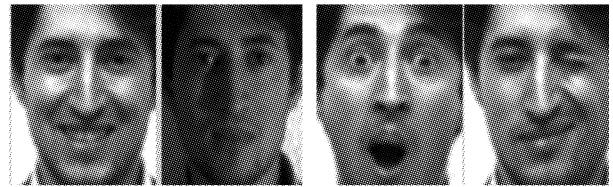


图 2 在 Yale 中的一些图像

仿真实验 1:为了分析核参数以及特征维数对人脸识别率的影响,用手动的方式调整参数并记录结果。固定核参数 $C = 5$, $\sigma = 1e-7$, 特征维数与人脸识别率的关系见表 2 和图 3; 固定特征维数 $N = 7$, 核参数与人脸识别率的关系见图 4, 其中在样本类别数为 5, 识别率是指各个不同类别的分类器作用于整个测试集的结果。

仿真实验 2: 固定核参数 $C = 6$ 和 $\sigma = 3e-8$, 用混沌优化算法优化 PCA 特征维数, 需要分类的样本类别数分别为 4, 5, 8, 10, 20, 40 类, 得到的结果见表 3。其中识别率是指各个不同类别的分类器作用于整个测试集的结果, 这里的时间是指作用于整个人脸库的 PCA 特征提取、训练、优化和测试的总时间。

仿真实验 3: 在统一的目标函数下,用混沌优化算法同时对图像特征维数和分类器参数进行优化选择,得到的结果见表 4。为了与文献[14]和[15]识别方法进行对比,对每个人,选取 5 张图片作为训练样本,其余的 5 张用来测试,在类别数为 40 的识别性能见表 5 和表 6。

仿真实验 4: 在 Yale 人脸库上,对每类人脸选取 5 张图片作训练,其余 6 张作测试。在统一的目标函数下,用混沌优化算法同时对图像特征维数和分类器参数进行优化选择,然后进行识别,并与文献[15]进行对比,其相应的结果见表 5。

结果分析:

(1) 需分类的类别数少,需要的区分特征就少;需要分类的类别数越高,特征向量维数越多;只要这样才能更好地识别;特征向量维数越高,处理时间就增加。这从仿真实验 1 可以看出:需要分类的类别数是 4, 特征维数为 5, 而类别数为 40, 特征维数为 26;而且识别时间也随着维数的增加而增加。与原特征空间相比,优化后的特征维数大大减少,见表 3, 随之相应的分类时间也大大降低。

(2) 很显然分别单独对核参数和特征维数优化所对应的识别率低于在统一的目标函数下用混沌优化算法同时对图像特征维数和分类器参数进行优化选择得到的识别结果,见表 3 和表 4。

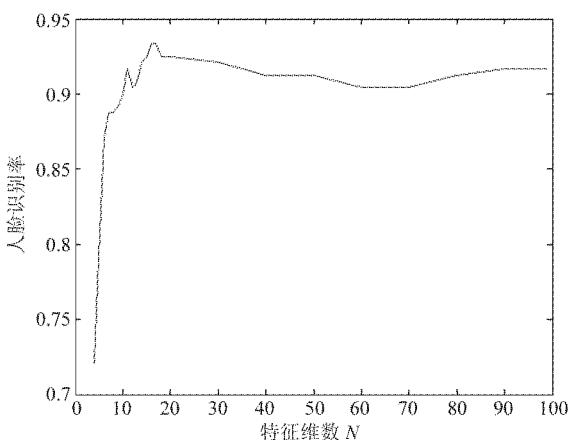
(3) 图片数据中光照、表情变化表现为特征数据变化,通过 COA 自动调整核参数和特征维数,这样可以达到最佳的识别效果,如此较好地克服传统识别方法中识别性能对光照、表情等变化的敏感性,从实验 4 的结果得到验证:Yale 人脸库中的图片在姿态、光照、表情等变化上比 ORL 人脸库中的图片程度要大,但本文提出的方法其识别率也达到了 99% 以上,而且效果比文献[15]提出的方法好,见表 5。

(4) 不同的分类 SVM 如 5 类 SVM、8 类 SVM 等,虽然作用于同一人脸库和采用的核函数相同(都是高斯核),但对应的最佳识别性能的核参数是不同的,特征维数肯定不同,见表 3 所示,这说明对特征维数和 SVM 核参数的优化是必要的。这也说明如果用手工方式调整,随着输入图像数据和需要识别的类别数的不同,就要不断地手工调整,这既浪费时

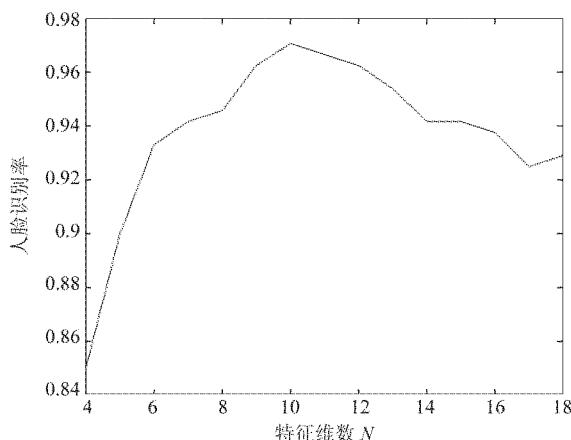
间,又不利于提高识别性能;用优化算法优化核参数和特征数可以达到自动调整的效果。与文献[15]的方法相比,虽然它采用了小波变换和核主成分分析(kernel PCA, KPCA)融合先进技术,但本文提出的方法在各个参量同时经过混沌优化后的识别率优于文献[15],也好于文献[14](见表 5);从运行时间看,本文提出的方法总耗时约为 168s,而其中大量的时间花在优化过程上,占用了 165.5s,而在优化处理中主要是 PCA 计算。但正是因为优化后特征维数大大降低,使得分类时间大大减少,所以远远少于文献[15]的分类时间(见表 6)。总之,本文提出的方法不管是识别率还是分类速度都有比较好的表现。另外本文所有实验采用 MATLAB 6.5 语言编程,因为 MATLAB 是解释性语言,所以若采用 C++ 编程,算法运行会快一些。

表 2 在不同的特征维数下的人脸识别率($C=5, \sigma=1e-7$)

类别数	特征维数 N																	
	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18			
4	0.9500	0.9625	0.9542	0.9542	0.9583	0.9500	0.9417	0.9375	0.9417	0.9458	0.9417	0.9542	0.9542	0.9542	0.9625			
5	0.9625	0.9458	0.9583	0.9708	0.9548	0.9375	0.9333	0.9292	0.9292	0.9292	0.9375	0.9417	0.9375	0.9333	0.9292			
8	0.8500	0.9000	0.9333	0.9417	0.9458	0.9625	0.9708	0.9667	0.9625	0.9542	0.9417	0.9417	0.9375	0.9250	0.9292			
10	0.8625	0.9617	0.9375	0.9458	0.9333	0.9333	0.9500	0.9500	0.9542	0.9542	0.9458	0.9333	0.9292	0.9250	0.9208			
20	0.7208	0.7917	0.8708	0.8875	0.8875	0.8917	0.9000	0.9167	0.9042	0.9083	0.9208	0.925	0.9333	0.9333	0.9250			



(a) 类别数为 20 支持向量机识别率与特征维数的关系



(b) 类别数为 8 支持向量机识别率与特征维数的关系

图 3 在 $C=5, \sigma=1e-7$ 情况下, 支持向量机的人脸识别率与特征维数的关系表 3 在核参数 $C=6, \sigma=3e-8$ 的条件下, 用混沌优化算法优化 PCA 特征维数的实验结果

类别数	4	5	8	10	20	40
原特征维数	16	20	32	40	80	160
优化后的特征维数	5	11	13	15	23	26
最高识别率	0.9875	0.9875	0.9792	0.9792	0.9500	0.9292
识别时间(s)	36.56	38.56	44.45	49.36	66.58	121.47

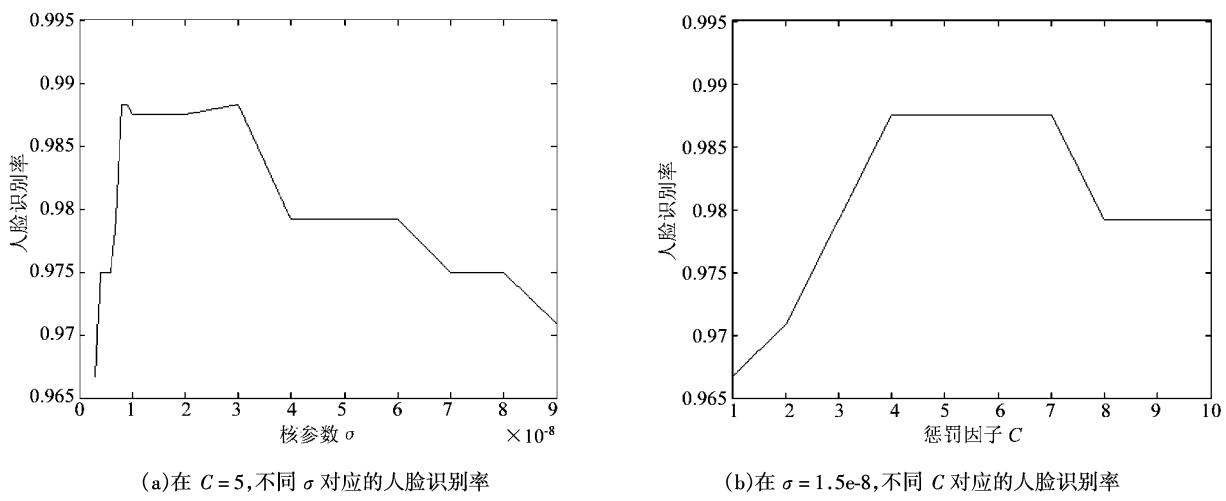


图4 在样本类别数为5,特征维数为7时,不同的核参数所对应的人脸识别率

表4 同时进行混沌优化后各个类别的核参数 σ 、 C 值以及PCA特征维数 N 和对应的人脸识别率

样本类别数	优化后的 SVM			优化后的 PCA			人脸识别率		
	σ	C	N	样本类别数	σ	C	N		
4	1e-8	5	10	100	10	4e-8	7	17	100
5	1.5e-8	6	11	100	20	3.5e-8	8	22	99.2
8	5e-8	6	14	100	30	3e-8	8	32	98.33

表5 不同方法识别率的比较

人脸库	方法	具体的算法	核参数选择	识别率	预处理情况
ORL 人脸库	文献[14]的方法	PCA + SVM	手动	97%	未作预处理
		KPCA + SVM	手动	93.82%	一层小波变换
	文献[15]的方法	KPCA + SVM	手动	95.74%	二层小波变换
		KPCA + SVM	手动	98.52%	三层小波变换
Yale 人脸库	本文的方法	PCA + SVM	COA 自动	99.06%	仅分辨率降为 28 × 23
		KPCA + SVM	手动	91.63%	一层小波变换
		KPCA + SVM	手动	95.58%	二层小波变换
	文献[15]的方法	KPCA + SVM	手动	96.41%	三层小波变换
		PCA + SVM	COA 自动	99.01%	仅裁减为 50 × 50

表6 两种方法在ORL人脸库上运行时间的比较

方法	CPU	内存	语言	预处理时间(s)	处理时间(s)			平均总耗时(s)
					选参数	特征提取	分类	
文献[15]提出的方法	Pentium IV(1.4G)	256M	VC++ 6.0	一层小波变换			120.52	30.27
				二层小波变换	不详	不确定	53.37	29.61
				三层小波变换			34.06	29.37
本文的方法	AMD2600+(1.6G)	256M	MATLAB 6.5	降低分辨率			165.5	2.51 168.01

5 结论

(1) 基于混沌理论的混沌优化是一种新型的直接搜索优化算法,它直接采用混沌变量在允许解空

间进行搜索,搜索过程按混沌运动自身规律进行,与按某种概率接受“劣解”跳出局部最优解的优化算法相比,它更易于跳出局部最优解,搜索效率高。用混沌优化算法在本文提出的目标函数下,对SVM核参数进行优化,实验表明:效果明显,算法简单,可操作

性强,相对于遗传、蚁群等算法,计算复杂度较低。

(2) 将PCA特征的选择与SVM核参数选择同时进行优化选择,相对于分别单独对他们进行优化选择来说,提高了识别性能,也提高了识别速度。依据需要识别的类数来选择特征维数,如类别数较少时,特征维数较少,如此,系统处理更快。

(3) SVM的分类性能与核参数密切相关,核参数优化选择是必要的,对于诸如SVM的核学习方法都存在核参数选择问题,用优化算法来自动选择核参数也对于其他核学习方法具有实际指导意义,而混沌优化算法可调参数很少,相对于遗传算法和蚁群等优化算法(多个参数需要调节)更容易掌控,更适宜用于这些优化问题。

致谢:感谢审稿专家给本文提出的宝贵意见!

参考文献

- [1] 李武军,王崇俊,张炜等.人脸识别研究综述.模式识别与人工智能,2006,19(1): 58-66
- [2] Turk M A, Pentland A P. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86
- [3] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs Fisherfaces: recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7):711-720
- [4] Vapnik V N. The Nature of Statistical Learning Theory. New York: Springer-Verlag, 2000
- [5] Phillips P J. Support vector machines applied to face recognition. In: Proceedings of the 1998 conference on Advances in Neural Information Processing Systems 11. USA: MIT Press, 1998. 803-809
- [6] 崔国勤,高文.基于双层虚拟视图和支持向量的人脸识别方法.计算机学报,2005,28(3):368-376
- [7] Chapelle O, Vapnik V, Bousquet O, et al. Choosing multiple parameters for support vector machines. *Machine Learning*, 2002, 46(1):131-159
- [8] Dong C, Rao X, Yang S, et al. Method for selecting the parameters of support vector machines. *Systems Engineering and Electronics*, 2004, 26(8):1117-1120
- [9] Li B, Jiang W. A novel stochastic optimization algorithm. *IEEE Trans on Systems, Man and Cybernetics-part B: Cybernetics*, 2000, 30(1):193-198
- [10] 张新明,孙印杰.基于混沌优化的自适应中值滤波.电子技术应用,2007,33(9):63-65
- [11] 朱筱蓉,张兴华.基于改进量子遗传算法的连续函数优化研究.计算机工程与设计,2007,28(21): 5195-5197
- [12] 段海滨,马冠军,王道波等.一种求解连续空间优化问题的改进蚁群算法.系统仿真学报,2007,19(5): 974-977
- [13] 边肇祺,张学工.模式识别.第2版.北京:清华大学出版社,2000. 212-227
- [14] 崔国勤,李锦涛,高文等.基于支持向量机的人脸识别方法.计算机科学,2003,30(4): 11-15
- [15] 谢永华,陈伏兵,张生亮等.融合小波变换与KPCA的分块人脸特征抽取与识别算法.中国图象图形学报,2007,12(4): 666-672

Face recognition based on the chaos theory and support vector machine

Zhang Xinming, Xu Jiucheng

(College of Computer and Information Technology, Henan Normal University, Xinxiang 453007)

Abstract

Aiming at the problem of how determining the dimensions of the eigenvectors and how selecting the kernel parameters of support vector machines (SVM) to enhance the face recognition performance, this paper presents a face recognition method based on the chaos theory and the SVM algorithm. Firstly, the method reduces the image feature dimensions with the principal component analysis (PCA) and inputs the features to the SVM to train, and then, optimizes these kernel parameters and the dimensions of PCA features simultaneously using the controllable and improved chaotic optimization algorithm (COA) so that the optimal dimensions and kernel parameters can be obtained, and finally, classifies the unlabeled face images with the optimal PCA features and the optimal SVM. The results of the experiments in the ORL and Yale face databases show that the proposed method obtains both the face recognition rates of over 99% and greatly improves the efficiency of face recognition.

Key words: face recognition, chaotic optimization algorithm (COA), support vector machine (SVM), principal component analysis (PCA)