

基于 RBF 神经网络的人脸识别研究

吴畏¹ 肖南峰¹

摘要

针对人脸识别技术中存在的高维问题、小样本问题和非线性问题展开研究。围绕人脸特征提取,采用基于主成分分析和 Fisher 线性鉴别来克服在人脸识别中的小样本问题,同时将人脸图像从高维空间映射到低维空间从而解决了高维问题;在分类识别方面,采用具有很强的非线性映射功能的 RBF 神经网络进行模式分类,能够解决人脸识别中的非线性问题。在 ORL 人脸数据库上进行的仿真实验表明,该方法进行人脸识别具有较高的识别率。

关键词

人脸识别;特征提取;主成分分析;Fisher 线性鉴别;RBF 神经网络

中图分类号 TP391.41

文献标志码 A

收稿日期 2010-03-24

资助项目 国家自然科学基金与中国民用航空总局联合资助项目(60776816);广东省自然科学基金重点基金(251064101000005)

作者简介

吴畏,男,硕士生,主要研究方向为智能计算与计算机应用。risako@vip.qq.com

肖南峰(通讯作者),男,博士,教授,博士生导师,主要研究方向为智能计算与计算机应用。xionf@scut.edu.cn

0 引言

Introduction

人脸识别是利用分析比较人脸视觉特征信息进行身份鉴别的计算机技术,其应用涉及图像处理、机器视觉、模式识别、神经网络等诸多学科。研究人脸识别技术的目的是使计算机具有人类一样对人进行识别的能力,人脸识别技术在人机交互、身份鉴别、安全监控、图像视频处理等领域有着广阔的应用前景。然而,人脸识别系统的识别率往往受到一些“非面部”因素的影响,诸如光照的变化、表情、发型、脸部佩戴物(如眼镜)、脸部姿态等,除此之外,还涉及人脸检测和跟踪、实时检测等一系列相关技术问题。

人脸识别主要包括但不限于以下 4 个方面的研究内容:人脸检测、人脸图像规范化、人脸特征提取、人脸分类识别。本文将针对人脸特征提取和分类识别 2 个方面进行研究。

1 人脸特征提取

Face feature extraction

在人脸识别系统中,人脸图像特征提取直接影响到系统的识别性能。特征选择的过程至关重要,如果选择了包含充分分类能力的特征,将极大地简化分类器的设计,且能提高分类性能。本文采用一种基于主成分分析和 Fisher 线性鉴别的特征提取方法——Fisherface,该方法由 Belhumeur 等^[1]提出,已经在模式识别领域中得到了广泛应用。

1.1 主成分分析(PCA)

主成分分析(Principal Component Analysis, PCA)法的基础是 Karhunen-Loeve 变换(简称 K-L 变换)——一种常用的正交变换。PCA 可将高维度的资料(如人脸图像)进行压缩,它是最小均方误差下的最优维数据压缩技术,而且 PCA 法所提取特征之间是互不相关的, Turk 等^[2]最早将 PCA 用于特征脸的提取。

设人脸图像样本的总数为 N ,每个人脸图像样本的大小为 $m \times n$,因此,所有样本可以用一个 $M \times N$ ($M = m \times n$) 的矩阵来表示:

$$\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N) \in \mathbf{R}^{M \times N}. \quad (1)$$

其中,每个列向量代表一个人脸样本。

PCA 的算法步骤如下:

1) 构造所有训练样本的协方差矩阵

¹ 华南理工大学 计算机科学与工程学院,广州,510006

$$C = \frac{1}{N} \sum_{i=1}^N (X_i - \mu)(X_i - \mu)^T = AA^T \in \mathbf{R}^{M \times N}. \quad (2)$$

其中: μ 为平均人脸, 即所有训练样本的均值; $A = [X_1 - \mu, X_2 - \mu, \dots, X_N - \mu] \in \mathbf{R}^{M \times N}$ 为所有样本与平均脸的差构成的矩阵.

2) 计算矩阵 $L = A^T A \in \mathbf{R}^{N \times N}$ 的特征向量 v_i 和特征值 μ_i , 则 C 的特征向量为 $\phi_i = Av_i \in \mathbf{R}^{M \times N}$, 特征值仍为 μ_i .

3) 计算得到的 C 的所有特征向量 $[\phi_1, \phi_2, \dots, \phi_N]$ 是按特征值 $[\mu_1, \mu_2, \dots, \mu_N]$ 从大到小排列的正规化特征向量. 若要求 PCA 变换后的数据降为 k 维, 则选取特征值最大的 k 个特征向量构造特征空间 $U = [\phi_1, \phi_2, \dots, \phi_N] \in \mathbf{R}^{M \times k}$.

4) 所有的样本在基底 U 上的投影为

$$Z = U^T X. \quad (3)$$

基于 K-L 变换的 PCA 方法在最小均方误差下能够得到最好的信息压缩, 然而, 最大特征值对应的特征向量未必具有最佳的分类能力, 并且 PCA 方法的无监督训练使得 PCA 的训练过程无法利用样本的类别信息. 在很多情况下, PCA 方法未必能在低维空间内取得最大的分类性能, 因此, 需要对 PCA 方法得到的特征空间进行进一步地特征提取.

1.2 Fisher 线性鉴别 (FLD)

在图像识别中, 由于 Fisher 线性鉴别分析 (Fisher 具有 Linear Discriminant, FLD) 极佳的分类能力, 当图像投影到 Fisher 特征空间时, 同类样本聚集在一起, 而不同类样本会被分开, 即类间距离与类内距离的比值最大化, 因此它能得到比 PCA 更好的识别效果. FLD 方法中使用了 2 个散布矩阵的定义. 设样本中包含 c 个人的人脸样本, 即共有 c 类, 则:

1) 类内散布矩阵 (Within-Class Scatter Matrix)

$$S_w = \sum_c \sum_x (x_k - \mu_i)(x_k - \mu_i)^T. \quad (4)$$

其中: μ_i 是第 i 类样本的均值, 显然, S_w 代表同一类样本相聚的程度.

2) 类间散布矩阵 (Between-Class Scatter Matrix)

$$S_b = \sum_{i=1}^c N_i (\mu_i - \mu)(\mu_i - \mu)^T. \quad (5)$$

其中: μ_i 是第 i 类样本的均值, μ 是所有样本的均值, N_i 是第 i 类样本的数目.

FLD 的目的是找到使 S_b/S_w 最大化的投影 $W_{opt}^{[2-3]}$,

$$W_{opt} = \operatorname{argmax}_W \frac{|W^T S_b W|}{|W^T S_w W|} = [w_1, w_2, \dots, w_{c-1}]. \quad (6)$$

式(6)可以看成以下特征值问题:

$$S_b w_i = \lambda_i S_w w_i, \quad i = 1, 2, \dots, c-1. \quad (7)$$

即 λ_i 和 w_i 分别为矩阵 $S_w^{-1} S_b$ 的特征值和特征向量, 该矩阵最多只有 $c-1$ 个非零特征值. 如果希望映射到 FLD 空间的特征向量的维数为 r , 则同样选择最大的 r 个特征值对应的特征向量作为 FLD 空间的基底, 即

$$W_{opt} = [w_1, w_2, \dots, w_{c-1}], \quad 0 < r \leq c-1. \quad (8)$$

所有样本在 FLD 空间上的投影为

$$Z = W_{opt}^T X. \quad (9)$$

1.3 PCA + FLD 方法 (Fisherface)

如前所述, 人脸识别为小样本训练问题, 训练样本数远远小于每个样本的维度 (像素数), 在这种情况下, 类内散布矩阵 S_w 往往会出现不可逆 (非满秩) 的情况. 因此, 为了解决这一问题, 可采用 PCA 方法将人脸图像映射到低维特征空间, 从而确保 S_w 非奇异, 再通过 FLD 方法将映射到 PCA 特征空间中的样本进一步映射到 FLD 特征空间 (图 1).

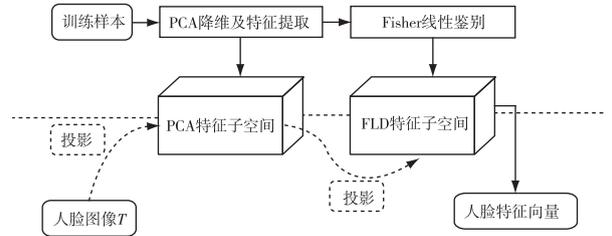


图 1 PCA + FLD (Fisherface) 特征提取的框架

Fig. 1 Frame of PCA + FLD (Fisherface)

2 人脸图像识别

Face recognition

人工神经网络是基于人脑组织结构、活动机制的初步认识提出的一种新型信息处理系统, 通过大量的简单关系连接来实现复杂的函数关系. 它具有很强的鲁棒性和容错性, 善于联想、概括、类比、推广, 有很强的自适应和自学习能力. 径向基函数 (Radial Basis Function, RBF) 神经网络具有全局最佳逼近、收敛速度快、分类能力好等优点, 因此被广泛用于模式识别问题. 本章给出了 RBF 神经网络的结构、分类器设计以及学习算法.

2.1 RBF 神经网络的结构

图 2 给出了一个 RBF 神经网络的结构, 和 3 层感知器结构类似, 它是一个包含 3 个层的前馈型结

构:输入层、隐层、输出层,但是,RBF神经网络的隐层模型和功能和多层感知器有着很大的不同.RBF神经网络在解决小样本训练集问题、非线性可分问题等复杂的模式分类问题上有着很好的性能.

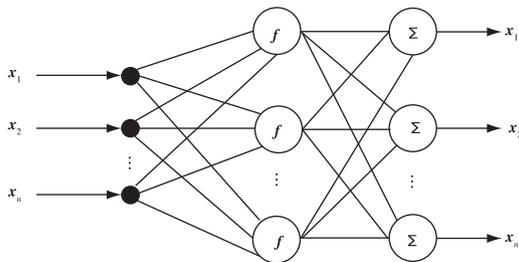


图2 RBF神经网络的结构

Fig. 2 Structure of RBF neural network

2.2 径向基函数

设 X 为 r 维输入向量, $X = [x_1, x_2, \dots, x_r] \in \mathbf{R}^r$, 第 i 个 RBF 神经元的中心为 C_i , 高斯宽度为 σ_i , 则每个隐层单元的输出为

$$R_i(X) = R_i(\|X - C_i\|). \quad (10)$$

式(10)为径向基函数的通用形式,其参数是输入向量 X 到中心 C_i 之间的欧几里德距离. 本文采用高斯函数(Gauss Function)作为基函数:

$$R_i(X) = \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right). \quad (11)$$

高斯函数具有形式简单、解析性好、任意阶可导的优点^[4]. 高斯函数对输入信号产生局部响应,输入信号越靠近某个隐层中心,该隐层单元的输出越大.

2.3 RBF神经网络设计

RBF神经网络需要完成的是从特征子空间到模式类别的映射,每一个模式类别对应一个输出节点. 因此,很直观地:

- 1) 输入层神经元的数目与特征向量的维数相等;
- 2) 输出层神经元的数目与模式类别的数量相等.

目前,隐层的初始化方法主要有自组织映射(SOM)、K-均值(K-Mean)算法、正交最小二乘法等. 本文将采用文献[3]提出的一种监督聚类算法来完成 RBF 神经网络的设计.

2.3.1 隐层中心的聚类算法

分别设输入层和输出层神经元的个数为 r 和 s .

- 1) 初始化隐层神经元个数为模式类别数 $u = s$.

- 2) 计算各类样本的均值,作为该类的初始中心.

$$C_k = \frac{1}{n_k} \sum_{i=1}^{n_k} p_i^k, \quad k = 1, 2, \dots, u. \quad (12)$$

其中: n_k 为 k 类样本的总数; p_i^k 为第 i 个 k 类样本.

- 3) 找出 k 类样本中距离该类中心最远的点 $p^k(f)$, 并记录该点到该类中心 C_k 的距离

$$d_k = \|p^k(f) - C_k\|. \quad (13)$$

- 4) 计算出 k 类中心到其他所有类 j 的中心的欧氏距离,找出其中距离 k 类中心最近的中心,并记录该点的索引以及该最近距离

$$dc(k, j) = \|C_k - C_j\|,$$

$$d_{\min}(k, l) = \underset{l}{\operatorname{argmin}}(dc(k, l)),$$

$$j = 1, 2, \dots, u, \quad j \neq k. \quad (14)$$

根据 d_k, d_l 和 $d_{\min}(k, l)$ 的关系对 k 类进行判定:

- i) 若 $d_k + d_l \leq d_{\min}(k, l)$, 则 k 类与其他类不存在重叠;

ii) 否则, k 类与其他类重叠,有可能造成分类错误,进一步分为2种情况讨论: $d_k + d_l > d_{\min}(k, l)$ 且 $|d_k - d_l| \leq d_{\min}(k, l)$, k 类与其他类相交; $d_k + d_l > d_{\min}(k, l)$ 且 $|d_k - d_l| \geq d_{\min}(k, l)$, k 类包含其他类或被其他类包含. 对于第一种情况, k 类与其他类不存在重叠,不需要进行划分;对于后一种情况,需要根据5)对 k 类进行划分判断.

- 5) 如果 k 类完全包含其他类 l , 即 $d_k + d_l > d_{\min}(k, l)$ 且 $|d_k - d_l| \leq d_{\min}(k, l)$ 则 k 类需要被划分成2类;否则,如果 k 类包含其他类的特征超过1个,则 k 类需要被划分成2类.

- 6) 重复执行2~5步直到所有的聚类都不需要被划分.

2.3.2 高斯宽度的估计

为了保证隐层神经元的覆盖范围尽可能的大,又尽可能的不相互重叠,需要合理地选取各中心的高斯宽度. 根据文献[7]给出的估计算法:

$$\sigma^k = \max(\sigma_w^k, \sigma_B^k).$$

其中:

$$\sigma_w^k = \frac{d_k}{|\ln \beta|}; \quad (15)$$

$$\sigma_B^k = \gamma \times d_{\min}(k, l). \quad (16)$$

β 为置信度, $0.5 \leq \beta \leq 1$, γ 可按以下公式计算

$$\gamma \approx \frac{\sum_{k=1}^c \frac{d_k}{|\ln \beta|}}{\sum_{k=1}^c d_{\min}(k, l)}. \quad (17)$$

2.4 RBF 神经网络的混合学习算法

RBF 神经网络的隐层节点的参数调整是一个非线性过程,输出层连接权的调整则是一个线性的过程. 鉴于这两个学习过程的差异,本文采用一种混合学习算法 (Hybrid Learning Algorithm, HLA)^[3,7] 对 RBF 神经网络进行训练.

1) 采用线性最小二乘法 (Linear Least Square, LLS), 调整输出层的连接权.

2) 采用梯度下降法, 调整隐层神经元的中心和高斯宽度.

2.4.1 计算连接权

输入矩阵为 $\mathbf{X} \in \mathbf{R}^{T \times N}$ 时, 隐层的输出矩阵为 $\mathbf{R} \in \mathbf{R}^{u \times N}$, 输出层的输出矩阵为 $\mathbf{Y} \in \mathbf{R}^{s \times N}$, 其中 N 为训练样本的总数.

RBF 网络的待定输出层权值 $\mathbf{W} \in \mathbf{R}^{s \times u}$, 则隐层输出矩阵、输出层权值、网络输出矩阵有如下关系:

$$\mathbf{Y} = \mathbf{W} \times \mathbf{R}. \quad (18)$$

设样本的目标输出为 $\mathbf{T} \in \mathbf{R}^{s \times N}$, 则为了使目标输出与网络实际输出之间的误差最小, 可以采用线性最小二乘法 (LLS), 通过 \mathbf{R} 的伪逆 \mathbf{R}^+ 求出 \mathbf{W} :

$$\mathbf{W} = \mathbf{R}^+ \times \mathbf{T}. \quad (19)$$

2.4.2 调整隐层中心及宽度

隐层的中心和宽度采用监督学习算法进行训练, 所有的参数都经历一个误差修正的学习过程. 本文中, 采用梯度下降法^[3-6] 进行训练, 该方法过程如下:

定义误差函数

$$\mathbf{E} = \frac{1}{2} \sum_{n=1}^N \mathbf{E}^n. \quad (20)$$

式中, N 为样本数, \mathbf{E}^n 为输入第 n 个样本时的误差, 定义为

$$\mathbf{E}^n = \sum_{k=1}^s (\mathbf{t}_k^n - \mathbf{y}_k^n)^2. \quad (21)$$

为使误差函数最小化, 参数的修正量应该与其负梯度成正比, 即:

$$\Delta \mathbf{C}_j = -\eta_1 \frac{\partial \mathbf{E}}{\partial \mathbf{C}_j}, \quad \Delta \sigma_j = -\eta_2 \frac{\partial \mathbf{E}}{\partial \sigma_j}. \quad (22)$$

展开后得到的具体计算公式为

$$\Delta \mathbf{C}_j = 2\eta_1 \sum_{n=1}^N \sum_{k=1}^s (\mathbf{t}_k^n - \mathbf{y}_k^n) \mathbf{w}^n(k, j) \mathbf{R}_j^n \frac{\mathbf{P}^n - \mathbf{C}_j^n}{(\sigma_j^n)^2}. \quad (23)$$

$$\Delta \sigma_j = 2\eta_2 \sum_{n=1}^N \sum_{k=1}^s (\mathbf{t}_k^n - \mathbf{y}_k^n) \mathbf{w}^n(k, j) \mathbf{R}_j^n \frac{\|\mathbf{P}^n - \mathbf{C}_j^n\|^2}{(\sigma_j^n)^3}. \quad (24)$$

在输入完所有样本后, 使用该修正公式对参数进行调整, 迭代公式为

$$\mathbf{C}_j(m+1) = \mathbf{C}_j(m) + \Delta \mathbf{C}_j, \quad (25)$$

$$\sigma_j(m+1) = \sigma_j(m) + \Delta \sigma_j. \quad (26)$$

其中, m 为迭代次数, η_1 和 η_2 分别为中心和高斯宽度的学习速率, 为了保证分类器性能, 采用的高斯宽度的学习速率通常大于中心的学习速率 (一般取 $\eta_2 = 2\eta_1$).

2.4.3 RBF 神经网络的学习过程

RBF 神经网络的学习过程如图 3 所示:

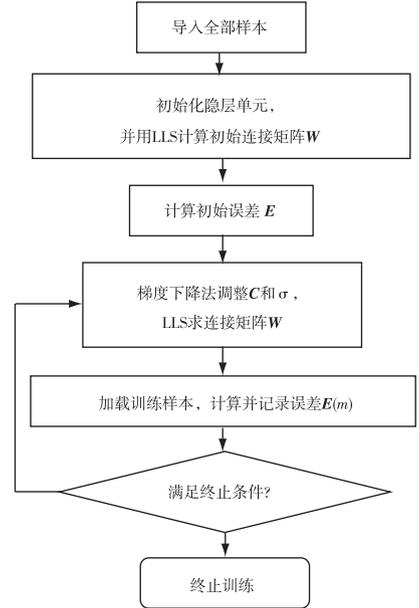


图 3 RBF 神经网络的学习过程

Fig. 3 Learning procedure of RBF neural network

3 实验与分析

Simulation & analysis

本文采用剑桥大学 AT&T 实验室创建的 ORL 人脸库 (图 4) 上使用 Matlab 进行仿真实验, 该数据库包含 40 个人的每人 10 幅, 总共 400 幅面部图像, 实验中将人脸图片分为训练集和测试集 2 组, 其中 200 幅用于训练, 200 幅用于测试.

实验分别对不同的 PCA 子空间维数、FLD 子空间维数以及不同的学习次数、学习速度、置信度进行反复实验, 并讨论不同参数对分类器性能的影响. 在未作说明的情况下, 学习速率指高斯宽度的学习速率, 中心的学习速率为它的一半. 实验中对性能的主要评判标准是平均错误率, 其定义如下:

$$E_{ave} = \frac{\sum_{t=1}^T n_{mis}^t}{T \cdot n_{total}}. \quad (27)$$

其中, n_{mis}^t 为第 t 次仿真时的错误识别数, n_{total} 为每次仿真时的测试样本数, 实验中每次仿真采用同样数

量的测试样本, T 为仿真次数.



图4 ORL人脸库中的人脸样本图像

Fig. 4 Samples of facial images in ORL database

3.1 PCA + FLD 中的特征数对识别率的影响

固定学习速率为 0.1, 置信度 0.7, 训练次数 200.

3.1.1 PCA 子空间维数对识别率的影响

固定 FLD 子空间的维数为 25, 调整 PCA 子空间的维数, 并分别进行 2 次仿真实验, 结果如表 1 所示.

表1 PCA子空间维数对平均错误率的影响

Table 1 E_{ave} for different dimensions of PCA subspace

PCA 子空间维数	$E_{ave}/\%$
30	9.0
50	7.0
70	5.5
90	6.0
120	10.5
140	19.0
160	71.0

从表 1 结果可以看出, 如果在 PCA 方法中提取

了过多的特征, 会导致分类器性能的急剧下降. PCA 子空间维数为 50 ~ 90 之间时, 有较好的分类性能.

3.1.2 FLD 子空间维数对识别率的影响

固定 PCA 子空间的维数为 70, 调整 FLD 子空间的维数, 并分别进行 2 次仿真实验, 结果如表 2 所示.

表2 FLD子空间维数对平均错误率的影响

Table 2 E_{ave} for different dimensions of FLD subspace

FLD 子空间维数	$E_{ave}/\%$
39	7.5
35	7.0
30	5.5
25	5.0
20	6.5
15	7.5
10	11.0

从结果看出, FLD 中子空间的维数在 25 和 30 时, 平均错误率低至 5% 左右, 而维数过高或过低, 都会不同程度地影响 RBF 的分类性能.

3.2 RBF 分类器分类性能分析

在采用 2.3 中的方法初始化 RBF 隐层中心并通过 2.4 中的方法进行学习后, 设置不同的参数对分类器的性能进行分析.

3.2.1 置信度 β 的选取

固定训练次数 200、中心学习速率 0.025、高斯宽度学习速率 0.05、PCA 子空间维数为 70, 对不同的置信度 β 和不同的 FLD 子空间维数进行多组实验统计错误识别数及网络训练完成的截止误差. 结果如表 3 所示. 综合所有不同特征向量下的结果, 不难发现, 在置信度为 0.6 ~ 0.7 时, RBF 分类器具有较好的识别效果.

表3 不同置信度和不同 FLD 子空间维数下的性能分析

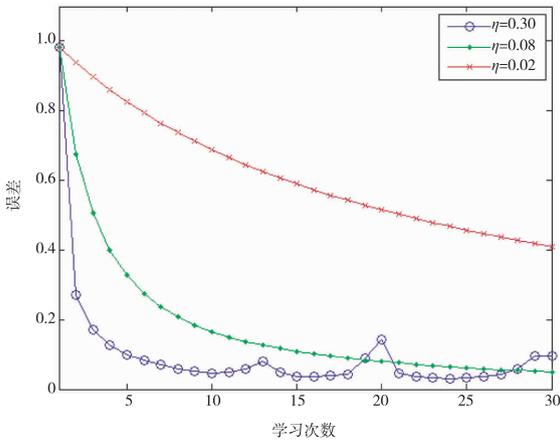
Table 3 Performances under different confidences and FLD subspace

β	错误识别数				网络截止误差			
	35	20	25	30	35	20	25	30
0.5	14	11	11	13	0.001 9	0.002 8	0.003 3	0.005 4
0.6	13	11	11	10	0.004 5	0.006 0	0.007 9	0.011 8
0.7	14	10	11	11	0.012 5	0.015 9	0.019 4	0.026 9
0.8	14	13	11	13	0.039 8	0.049 8	0.056 3	0.075 2
0.9	16	13	13	13	0.107 5	0.224 8	0.279 8	0.340 4

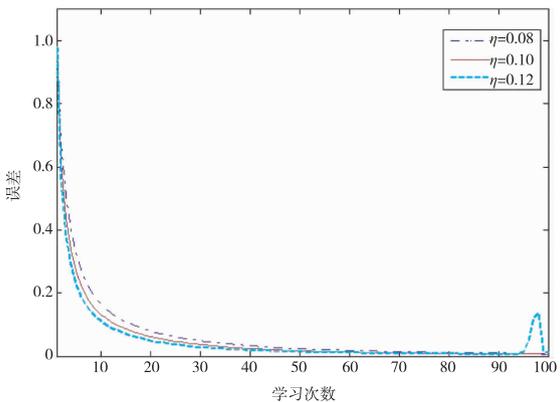
3.2.2 学习速率 η 的选取

本实验使用不同的 η 值对学习算法进行实验, 固定置信度 β 为 0.6, PCA 子空间维数为 70, FLD 子空间维数为 25. 为直观表明学习率对学习过程的影响, 设置训练次数为 30, 使用 3 组差别较大的 η 值进行测试, 图 5a 给出 3 条不同学习速率下的误差变化曲线(横坐标为学习次数). 这里的 η 是高斯宽度的学习速率, 中心的学习速率选为 $\eta/2$.

为了进一步分析最优的学习速率, 增大训练次数, 微调学习速率进行实验, 得出图 5b 的实验结果. 可以看出, 学习速率为 0.12 时, 在训练开始阶段保持下降趋势, 到最后发生了误差反弹, 学习速度为 0.10 和 0.08 时, 都没有发生反弹. 因此, 在本文方法中, 学习速率控制在 0.10 左右比较合适.



a. 3条不同学习速率下的误差变化曲线



b. 增大训练次数, 微调学习速率时的误差

图 5 学习速率对网络误差的影响

Fig. 5 Network errors with respect to learning rates

3.2.3 学习次数 Epochs 的选取

固定学习速率为 0.1, 对同一组样本进行学习次数为 20、100、150、200、500、800 进行了 6 次仿真, 结果如表 4 所示.

表 4 学习次数 Epochs 对错误分类数和网络误差的影响

Table 4 Performances under different Epochs

学习次数 Epochs	截止误差	错误分类数
20	0.113 01	12
100	0.015 85	10
150	0.008 65	10
200	0.005 57	9
500	0.001 75	9
800	0.001 46	9

由表中可以看出, 学习次数为 200 以上, 虽然误差有所下降, 但错误分类数没有减少. 事实上, 过高的训练次数会降低分类器的泛化性能从而导致分类器性能的下降^[7].

3.2.4 分类器的抗噪性能分析

为了更好地测试分类性能, 给测试集的人脸图像加上随机噪声(图 6)进行测试.



图 6 加入不同强度的噪声后的人脸图像

Fig. 6 Samples of facial images with different noise amplitude

取 PCA、FLD 空间维数分别为 70 和 25、学习次数 200、学习速率 0.1、置信度 0.6 进行实验, 得到的结果如图 7 所示. 结果表明: 分类器有良好的抗噪性能, 在高强度的噪声下, 也能保持较高的识别率.

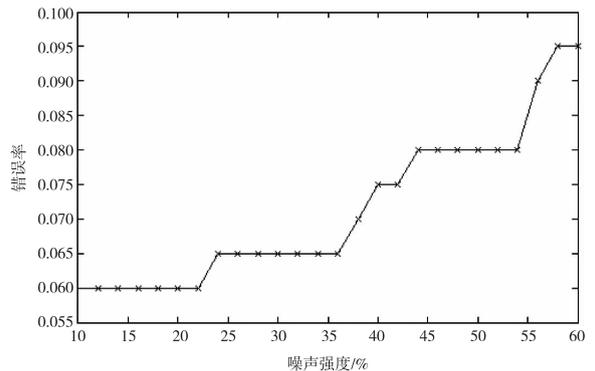


图 7 不同噪声强度对分类器性能的影响

Fig. 7 Error rate with respect to different noise amplitude

4 结论和展望

Conclusion & future work

经过实验,本文的方法在 PCA 子空间维数 70、FLD 子空间维数 25、学习次数 200、学习速率 0.1、置信度 0.6 的情况下,取得了 95.5% 的识别率.图 8 给出了识别测试的一部分结果,其中每行最右边一张为该行人脸的实际输出结果.由图 8 可以看出,在具有较大的角度变化、附属物(如眼镜)等情况下,分类器均能正确识别,具有较好的鲁棒性.



图 8 部分识别测试的结果

Fig. 8 Samples of experiment result

下一步将要进行的工作是:1)考虑将特征提取的线性鉴别分析改进成为加权的核 Fisher 鉴别分析^[8],使样本向中心靠拢以避免类与类之间重叠,从而提高识别率;2)选取一个好的方法来动态计算学

习速率和判定学习终止条件.

参考文献

References

- [1] Belhumeur P N, Hespanha J P, Kriegsmann D J. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720
- [2] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86
- [3] Er M J, Wu S Q, Lu J W, et al. Face recognition with Radial Basis Function (RBF) neural networks[J]. IEEE Transactions on Neural Networks, 2002, 13(3): 697-709
- [4] 韩立群. 神经网络教程[M]. 北京:北京邮电大学出版社, 2006
- [5] HAN Liqun. Artificial networks[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2006
- [6] Theodoridis S, Koutroumbas K. 模式识别[M]. 2版. 北京:电子工业出版社, 2004
- [7] Theodoridis S, Koutroumbas K. Pattern recognition[M]. 2th ed. Beijing: Publishing House of Electronics Industry, 2004
- [8] Kumar S. Neural networks[M]. New York: McGraw Hill, 2005
- [9] 王忠. 基于 Gabor 小波与 RBF 神经网络的人脸识别技术研究[D]. 福州:福州大学机械工程及自动化学院, 2005
- [10] WANG Zhong. Research on face recognition based on gabor wavelet and RBF neural networks[D]. Fuzhou: School of Mechanical Engineering and Automation, Fuzhou University, 2005
- [11] 刘晓亮,王福龙,黄诚,等. 一种加权的核 Fisher 鉴别分析在人脸识别中的应用[J]. 广东工业大学学报, 2009, 26(4): 65-69
- [12] LIU Xiaoliang, WANG Fulong, HUANG Cheng, et al. The application of a weighted kernel Fisher discriminant analysis applied in face recognition[J]. Journal of Guangdong University of Technology, 2009, 26(4): 65-69

Research on face recognition based on RBF neural networks

WU Wei¹ XIAO Nanfeng¹

1 School of Computer Science & Engineering, South China University of Technology, Guangzhou 510006

Abstract In this paper, feature extraction and recognition of facial images is studied in order to resolve the high-dimension problem, small size samples problem and non-linear separable problem that exist in face recognition technology. The proposed feature extract method based on Principal Component Analysis (PCA) and Fisher's Linear Discriminate (FLD) can solve the small size samples problem and the high-dimension problem by mapping the samples from a high-dimension space to a low-dimension Eigen space. In the recognition stage, RBF neural network, which represents a brilliant performance on small training set, non-linear separable and high-dimension pattern recognition problems, is used for pattern classification. Simulation results on the ORL face database indicate that the proposed method for face recognition yielded a good recognition rate.

Key words face recognition; feature extraction; principal component analysis; Fisher's linear discriminate; RBF neural network