

基于集成 BP 网络的人脸识别研究*

苏超, 肖南峰

(华南理工大学 计算机科学与工程学院, 广州 510006)

摘要: 在对人脸图像使用小波变换进行数据压缩的基础上, 使用 PCA 进行特征提取, 再将特征输入集成 BP 神经网络实现对人脸图像的识别。集成 BP 网络将多分类问题转换为多个相互独立的二分类问题, 在提高网络泛化能力的同时缩短了网络的训练时间。另外, 集成网络通过增添子网络或者重新训练子网络的方法解决了网络“失忆”问题, 使其具有增量式学习的能力。通过在 ORL 人脸库上仿真的实验, 证明了集成网络的人脸识别以及增量学习都具有良好的性能。

关键词: 人脸识别; 主成分分析; 集成反向传播网络; 增量学习

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1001-3695(2012)11-4334-04

doi: 10.3969/j.issn.1001-3695.2012.11.086

Face recognition based on integrated back-propagation neural network

SU Chao, XIAO Nan-feng

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

Abstract: After compressing of image in wavelet transform, obtaining features by PCA, then this paper inputted the features to integrated BP neural network to realize face recognition. It divided the multi-class classification into many independent 2-class classifications by the integrated BP neural network, then it could get better generalization ability and reduced training time. Additionally, the integrated BP neural network solved net's "forgetfulness" by adding new subnets into the integrated net or retraining subnets, so integrated network had the ability of incremental learning. The experiments in ORL show that the integrated BP neural network has a good performance on face recognition and the incremental learning.

Key words: face recognition; PCA (principal component analysis); BP (back propagation) neural network; incremental learning

0 引言

BP 神经网络是一种按反向传输算法训练的多层前馈网络, 是目前应用最广泛的神经网络模型之一。人脸图像的分类识别是 BP 神经网络在模式识别和分类方面的一个重要应用。人脸图像的数量规模较小时, 单一 BP 神经网络的泛化能力以及运行时间都比较理想; 而随着识别种类的增加, BP 网络的结构也随之变得复杂, 导致网络出现训练时间长、收敛慢、容易陷入局部极小、泛化能力差等问题。另外, 当新的学习样本出现时, 神经网络在单独学习了新知识之后, 就会改变原来的网络参数, 从而影响到以前学习到的样本记忆, 导致要重新训练整个网络使其具有识别新老类别的能力。

针对 BP 网络的规模大、训练时间长的问題, 本文使用多个简单的 BP 网络组成的集成网络来代替结构复杂的单一 BP 网络进行人脸识别。集成网络比单一的网络有更好的容错性和泛化性, 且能进行分布式计算, 大大缩短了网络的训练时间。本文还针对神经网络的“失忆”问题, 提出了适于该集成网络的增量学习方法, 当新的学习样本出现时, 系统能够快速的学习和记忆, 在学习了新知识的同时, 能够维持网络原本已学习的样本知识, 从而使集成网络具有增量式学习的能力。

1 人脸图像的特征提取

一张 112×92 的人脸图像超过万维, 如果直接送入神经网络进行训练或者识别会消耗大量的计算时间, 直接利用 PCA 提取特征向量的计算量也十分庞大, 因此对人脸图像进行压缩处理, 减少图像包含的信息量是很有必要的。

1.1 小波变换

小波变换是基于多层次函数分解的数学工具, 具有变换速度快、同时在时域和频域都具有良好的局部化特性。经小波分解的图像由一系列不同分辨率的子图像组成, 图像特征的主要信息保存在低频子图中, 冗余信息和噪声信息一般保存在高频子图中。以分解后的低频子图作为识别对象, 不但降低了图像的维度, 而且去除了噪声和冗余信息。

小波分解过程如图 1 所示。图 1(a) 表示原始的人脸图像, (b) 表示对 (a) 进行一级小波变换分解得到的结果; (c) 表示对 (a) 进行二级小波变换分解得到的结果。虽然对数据进行了压缩, LL 子图的信息容量有所减小, 但图像依然清晰度很高, 即小波域的能量并未减小很多。本文使用二级变换后的 LL 子图作为后续特征提取对象。


1.2 人脸图像的 PCA 分析

主成分分析 (PCA) 的目的是在数据空间中找到一组向量

收稿日期: 2012-03-24; **修回日期:** 2012-04-30 **基金项目:** 国家自然科学基金资助项目 (61171141)

作者简介: 苏超 (1989-), 女, 江西宜春人, 硕士研究生, 主要研究方向为人工智能与神经网络 (haidehuan19@163.com); 肖南峰 (1962-), 男, 江西南昌人, 教授, 博导, 博士, 主要研究方向为仿人机器人。

尽可能地解释数据的方差,把图像在高维空间表示转换到低维空间表示,降维后保存数据中的主要信息,从而使数据更易于处理。利用 PCA 提取的特征向量不但对光照、表情、姿态的细微变化不太敏感,还可以较好地反映人脸图像的全局和局部特征。



设人脸图像样本的总数为 N , 每个人脸图像样本的大小为 $m \times n$, 将每幅图像按列排列成 $M (M = m \times n)$ 维列向量。因此, 所有样本可以用一个 $M \times N$ 的矩阵来表示:

$$X = (X_1, X_2, \dots, X_N) \in \mathbb{R}^{M \times N} \quad (1)$$

其中: 每个列向量代表一个人脸样本。

PCA 的算法步骤如下:

a) 构造所有训练样本的协方差矩阵:

$$C = \frac{1}{N} \sum_{i=1}^N (X_i - \varphi)(X_i - \varphi)^T = \frac{1}{N} A A^T \in \mathbb{R}^{M \times N} \quad (2)$$

其中: $\varphi = \frac{1}{N} \sum_{i=1}^N X_i$ 为平均人脸, 即所有训练样本的均值; $A = [X_1 - \varphi, X_2 - \varphi, \dots, X_N - \varphi] \in \mathbb{R}^{M \times N}$ 为所有样本与平均脸的差构成的矩阵。

b) 计算矩阵 $L = A^T A \in \mathbb{R}^{M \times N}$ 的特征向量 v_i 和特征值 μ_i , 则 C 的特征向量为 $\phi_i = A v_i \in \mathbb{R}^{M \times N}$, 特征值为 $\frac{1}{N} \mu_i$ 。

c) 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。特征值越大, 与之对应的特征向量对方差的贡献也就越大。依照公式

$$t = \min_k \left\{ \frac{\sum_{j=1}^k \mu_j}{\sum_{j=1}^N \mu_j} > \alpha, k \leq t \right\} \quad (3)$$

计算累积贡献率大于 α 的 t , 选取前 t 个特征值对应的特征向量构成降维后的特征脸子空间 $U = [\phi_1, \phi_2, \dots, \phi_t] \in \mathbb{R}^{M \times t}$ 。

d) 所有的样本在特征脸子空间 U 上的投影为

$$Z = U^T X \quad (4)$$

这样用前 t 个主成分代替原始变量 X , 不但使人脸的特征参数维数降低, 也不会损失原始图像太多的特征信息。

2 集成 BP 网络的人脸识别

2.1 单一 BP 网络的人脸识别

神经网络可以看做是一个函数映射, 适用于有明确的输入与输出的对应关系。人脸识别可以看成将人脸图像的主分量作为输入, 图像属于哪一类人的判别为输出的复杂函数映射问题。因此, 可以用 BP 神经网络作为人脸识别器进行识别。

人脸识别中一般采用标准的三层 BP 神经网络作为分类器, 神经网络结构如图 2 所示。输入层的 N 个节点对应人脸特征的维数, 输出层的节点数 K 对应人脸类别数。输入层到隐含层的激活函数通常采用 Sigmoid 函数, 隐含层到输出层的激活函数采用线性函数 purelin 函数, 可得网络输出与输入的

关系如下:

$$o_t = \sum_{j=0}^n w_{jt} \times f(\sum_{i=0}^n v_{ij} x_i - \theta_j) \quad t = 1, \dots, K \quad (5)$$

其中: v_{ij} 为连接权值; θ_j 为阈值; o_t 为网络实际输出。

网络的总误差小于 ε , 最小均方函数为误差函数, 可得

$$E = \frac{1}{2} \sum_{t=0}^k (d_t - o_t)^2 \leq \varepsilon \quad (6)$$

其中: d_t 为第 t 个输出神经元的期望输出值。

1) 训练 设有 K 类人脸图像, 将已知图像 $\{x_i\}$ 在特征脸子空间的投影 $\{s_i\}$ 作为 BP 神经网络的输入, 当 x_i 属于第 j 类时, 相应的输出为 $o = (o_1, o_2, \dots, o_k)$ 满足 $o_j = 1, o_{i \neq j} = 0$ 。采用批处理方式, 有动量的梯度下降训练函数对训练样本进行训练, 当误差函数达到期望的最小误差值, 完成网络训练。

2) 测试 将未知图像 x 的主成分向量输入训练好的网络, 输出神经元为 $o_t (t = 1, \dots, K)$ 。当 o_t 最大时, 该神经元对应的训练样本和 x 匹配。

2.2 集成分类器的设计

集成网络分类器设计的核心思想就是将一个 K 类的模式分类问题转换为 K 个相互独立的二类分类问题^[1]。这种思想将一个复杂的分类问题分解为多个简单的分类问题。根据这一思想, 本文将多个 BP 网络组合成一个集成网络分类器, 即将 K 个多输入单输出的 BP 网络集成, 一个 BP 网络就是一个子网络, 只负责识别 K 个模式类别中的一个, 各子网络之间互相并联。集成网络的结构如图 3 所示。




图2 三层BP神经网络结构




图3 集成网络结构

理论分析证明, 具有单隐层的 BP 可以映射所有函数^[2]。因而选取标准的三层 BP 神经网络作为集成网络中的子网络。其中输入层的神经元数对应提取的人脸特征维数。由于集成网络将 K 类的分类问题分解成了 K 个子网络的二分类问题, 每个子网络只负责识别其中一种模式, 因此各子网络中输出层神经元的数目为 1。隐含层神经元的数目由以下的经验式计算得出:

$$n_1 = \sqrt{n + m} + a \quad (7)$$

其中: m 为输出神经元数; n 为输入神经元数; a 为 1 ~ 10 之间的常数^[3]。

对于集成 BP 网络, 其具体的训练和识别过程如下:

1) 训练 设训练集中有 K 类的人脸图像, 每类人有 s 幅图像。集成网络中的第 $i (i = 1, 2, \dots, K)$ 个子网络负责识别第 i 类人, 将整个训练集作为第 i 个子网络的训练集, 以第 i 类人的 s 幅图像作为正例, 目标输出值为 1, 其他人的样本图像作为反例, 目标输出值为 -1。对所有子网络分别进行训练, 当各子网络的误差都小于要求精度时, 集成网络训练结束。

2) 识别 将待识别的人脸特征向量 x 输入训练好的集成网络, 即输入各个训练好的子网络, 分别计算各个子网络的输

出。若第 $j(j=1,2,\dots,K)$ 个子网络的输出值最大,则将 x 归为第 j 类。

集成网络虽然总共要训练 K 个子网络,但其子网络的结构比单一的 BP 网络更加简单。设人脸图像特征提取后的维数为 S ,即网络输入层神经元数为 S ,则集成网络中每个 BP 子网络的结构为 $S - (\sqrt{S+1} + a) - 1$,单一 BP 网络的结构为 $S - (\sqrt{S+K} + a) - K$ 。网络结构复杂时,每多一个神经元,网络的训练时间将大大增加。另外,随着规模的逐渐庞大,越来越复杂的网络结构容易出现收敛慢、陷入局部最小值、泛化能力差等现象。相比之下,由多个简洁的子网络组合起来的集成网络能够在更短的时间内训练得到更加稳定、高效的分类器。

2.3 人脸识别的算法流程

结合小波分解对人脸图像的降维处理与 PCA 方法的特征提取,集成神经网络的人脸识别算法基本步骤如下:

a) 读入人脸图像,生成训练集与测试集。

b) 对训练集与测试集的图像进行降维处理,选取经小波分解后的低频图像作为后续特征提取的对象。

c) 根据贡献率值构造特征空间,依次计算训练样本与测试样本在特征空间上的投影向量,生成训练集以及测试集的人脸图像主分量。

d) 对 c) 得到的数据进行归一化处理,将输入数据变换为 $[-1,1]$ 区间的值,方便神经网络训练时阈值和权值的调整及误差的计算。

e) 将 d) 得到的训练集数据输入各 BP 子网络进行训练。

f) 将 d) 得到的测试集数据作为集成网络的输入进行测试,根据各子网络输出层节点的输出值大小判断测试集中各图像的所属类别。

3 集成 BP 网络的增量学习

3.1 增量学习

增量学习是一种在巩固原有学习成果和不需要用到原有数据的情况下快速有效地获取新知识的学习模式。在模式识别的应用中,设计出具有增量学习功能的神经网络分类器非常重要。目前基于前馈神经网络的增量学习主要通过神经网络权值调整、结构调整以及神经网络集成的方法实现^[4]。

文献[5]给出了一种通过调整 BP 神经网络权值实现增量学习的方法。当新样本到来时,在权值的有效区间内调整权值,采用结构化的自适应学习规则,用初始的固有知识来限制对样本的学习过程,从而使 BP 网络在学习到新样本知识的同时,保持了原有的知识。文献[6]提出了一种通过在网络中添加隐单元的方式实现增量学习的方法,每次添加一个隐单元,直到网络误差小于给定的值,结束对新样本的学习。

当新样本规模较大时,通过权值调整、结构调整的方法实现增量学习将会出现困难,可行的途径是利用多个神经网络集成一个系统。当新样本到来时,通过在集成系统中嵌入具有新样本知识子网络的方式使集成系统学习到新样本知识,每个子网络在学习过程中不会破坏其他网络已学习的知识,因此对新知识的学习不会影响整个集成系统^[7]。文献[8]介绍了一种 Learn++ 算法,它根据 AdaBoost^[9] 算法中弱分类器集成的思想,顺序生成一系列弱分类器,后面生成的弱分类器的训练集依赖于在其之前生成的弱分类器的表现;最后所有生成的弱分

类器通过加权投票的方式集成产生最后的输出。

3.2 集成 BP 网络的增量学习

虽然本文中的集成 BP 网络与 3.1 节中提到的集成网络在子网络的生成与作用上有很大的区别,但两者的整体结构是相同的,即都是通过多个子网络的集成来达到各自的目的。基于此点,本文参考 3.1 节中神经网络集成的增量学习的思想,对其进行适当的更改,得出适用于本集成系统的增量学习方法。

当新样本到来时,先对新样本的所属类别进行判断,将新样本分为已知类别与未知类别两种情况分别进行处理。新样本的所属类别为已知类别(集成网络已学习的类别)时,将新样本输入集成网络进行测试,当测试结果正确时,认为当前网络已具有该知识,不需要额外的学习。而当测试错误时,认为对应类别的子网络的泛化能力不高,需要加入新样本作为训练数据,对该子网络进行重新训练,使子网络具有该样本的知识,提高子网络的泛化能力。重新训练的训练集为原训练集与新样本作为正例的并集。

当新样本为未知类别(不在集成网络已学习的范围内)时,在集成网络中新建一个子网络,将新模式的样本作为正例,原训练集中的样本作为反例,组成训练集对新的子网络进行训练,使新的子网络成为只能识别新类别的二类子分类器,从而使集成网络在保持原有知识的基础上具有识别新模式的能力。

综上所述,给出集成 BP 网络的增量学习过程。

输入:新样本 new,集成网络 Net

输出:新的集成网络 NNet

if(new 是否属于已知类别)

```
{
    //测试集成网络是否能正确识别新样本 new
    if(! recognize(new))
```

```
{
    //不能正确识别 new,I 为 new 所属类别
```

```
//新的训练集为原训练集 + 新样本
```

```
newTrain = train(I) ∪ new;
```

```
//重新训练子网络 I
```

```
NNet = train(Net(I), newTrain);
```

```
更新训练样本集的内容
```

```
}
//能正确识别 new 时,不需要对新样本进行学习
else
```

```
NNet = Net;
```

```
}
else //new 属于未知类别
```

```
{
    //集成网络中子网络数目加 1
```

```
count = count + 1;
```

```
//创建新的子网络
```

```
new(count) = newff();
```

```
// * 构造新的子网络的训练样本集:原训练样本作为反例样本, new 作为正例样本 *
```

```
newTrain;
```

```
//训练新的子网络
```

```
NNet = train(Net(count), newTrain);
```

```
更新训练样本集的内容
```

```
}
```

4 实验与分析

实验在 Intel T6570 2.1 GHz、2.00 GB 内存、Windows 7 的环境下,使用 MATLAB 2011a 编程进行。实验使用剑桥大学 AT&T 实验室创建的 ORL 人脸数据库。该人脸数据库由 112×92 的 256 级灰度图像组成,库中包含 40 个人的 400 张面部图像,其中每人 10 幅图像。所有的图片都是以暗色作为背景,人脸姿态各异,表情、位置、角度、尺度都有所不同,深度旋转和平旋转可达 20° ,脸的尺度也有多达 10% 的变化。

适当的小波分解层数和 PCA 贡献值,既可节省训练时间又可提高识别率。实验中使用两层小波分解后的低频图像 (28×23 维)进行贡献值为 0.85 的 PCA 特征提取。训练前,对输入数据按式 (8) 进行归一化处理,将其限制在 $[-1, 1]$ 范围内。

$$x_{\text{new}}^i = 2 \frac{x^i - x_{\min}^i}{x_{\max}^i - x_{\min}^i} - 1 \quad i = 1, 2, \dots, l \quad (8)$$

其中: l 为提取的特征矢量的维数; $x_{\min}^i$ 、 $x_{\max}^i$ 分别为所有训练样本数据矢量的第 i 分量 x^i 的最小值和最大值。

4.1 人脸识别的仿真与分析

实验中,将 ORL 数据库中每人的第 1、3、5、7、9 幅,共 200 幅人脸图像组成训练集。将训练集外的 200 幅样本图像作为测试集。为检验出集成网络的识别效果,实验对 ORL 人脸库各采用 PCA + 单一 BP 网、WT (小波变换) + PCA + 单一 BP 网、PCA + 单一 BP 网、WT + PCA + 集成 BP 网四种方法进行实验,重复多次,最后取平均识别率和平均用时,结果如表 1 所示。

表 1 不同识别方法的识别率比较

编号	识别方法	识别率/%	平均用时/s
1	PCA + 单一 BP 网	66.2	117.94
2	WT + PCA + 单一 BP 网	67.29	70.79
3	PCA + 集成 BP 网	91.7	35.44
4	WT + PCA + 集成 BP 网	93.3	30.78

从表中看出,同样的特征提取方法,集成 BP 网与单一 BP 网相比,识别时间大大缩短,识别率也得到大幅度提升;同样的分类器(单一 BP 网或集成 BP 网)下,基于 WT 的 PCA 特征提取比单独的 PCA 特征提取所用时间稍短,识别率也稍有提高。从图 4 与 5 的对比中,能够更加直观地看出,单一 BP 网在迭代到 20 次左右时 MSE 的下降变得十分缓慢,导致网络的训练不能达到要求的精度。而集成网络中各子网络的结构相对简单,能够快速收敛,达到目标精度。本文的人脸识别方法与前三种方法相比,取得了非常好的效果:较高的识别率,在四种方法中识别率最高;识别时间更短,比 PCA + 单一 BP 网方法所用时间减少将近三倍。另外,在本实验中,集成 BP 网中各子网络的训练串行进行的,即在上一个子网络训练完成后才进行下一个子网络的训练。若集成网络运行在并行机之上,可使各子网络的训练并行进行,网络的训练时间将会进一步缩短。由此可以看出,本文的人脸识别方法是一种有效的识别方法。

4.2 增量学习的仿真与分析

实验中用 ORL 数据库中前 35 人的第 1、3、5、7、9 幅人脸图像样本对集成网络进行训练,得到一个能够识别 35 类模式的基础分类器。这 35 人的第 2、4、6、8、10 幅人脸图像作为测试集,余下 5 人的数据作为增量学习中新类别的样本用于学习

与测试。在已训练好的集成网络的基础上,对新样本进行增量学习。根据新样本的所属类别,分两种情况进行实验,即新样本属于已知类别和新样本属于未知类别。




图 4 方法 2 训练时的 MSE




图 5 方法 4 中子网络训练时的 MSE

为了测试新样本为已知类别时的增量学习效果,实验中直接对基本网络测试集中不能正确识别的样本逐个进行学习。通过对比增量学习前后测试集的识别率来检验增量学习的效果。如表 2 所示,初始集成网络的识别率为 94.86%,通过逐步对错误识别的样本进行增量学习,识别率逐渐提升到 100%。由此说明了在增量学习的过程中,集成网络学习新样本知识的同时,能够维持固有知识。另外,集成网络的人脸识别率较高,当新样本为已知类别时,分类器能正确识别新样本的几率很高,因此对已知类别的新样本进行增量学习的可能性较小,避免了集成网络频繁地增量学习。增量学习过程中识别率的变化。如图 6 所示。

表 2 新样本为已知类别时的增量学习测试

分类器状态	识别率/%	识别错误的样本编号
初始	94.9	1, 2, 79, 121, 137, 139, 164, 171, 173
学习样本 1	96	79, 121, 137, 139, 164, 171, 173
学习样本 79	96.6	121, 137, 139, 164, 171, 173
学习样本 121	97.1	137, 139, 164, 171, 173
学习样本 137	98.3	164, 171, 173
学习样本 164	98.9	171, 173
学习样本 171	100	无




图 6 增量学习过程中识别率的变化

对于新样本为未知类别的情况,有两个方面需要测试,即增量学习的效果以及增量学习是否影响固有的知识。因此,设计了如下实验:在已学习过 35 类人的集成网络上,每次增量学习一个新人物的编号为奇数的五张人脸图片,余下的五张图像作为其测试集,记录测试的识别率,保存增量学习后的集成网络系统,然后再继续下一个新人物的增量学习。共学习 5 个新的人物,编号分别为 1、2、3、4、5。同时,为了检验集成网络是否保持原有的知识,对所有已学习的人物测试集进行识别,5 个人物的测试集分别编号为 A、B、C、D、E。

从表 3 中的结果可知,随着新知识的逐渐增加,增量学习后的分类器对原测试集仍有较高的识别率,新的子网络的增加并不影响集成网络中原有的子网络。

(下转第 4341 页)

4 结束语

步态识别是生物特征识别技术中的一个新兴领域,它旨在根据个体的行走方式识别身份,具有重要的现实意义。本文在 Isomap 的基础上,提出了一种监督 Isomap 算法。该方法引入了样本的类别信息,提高了分类能力,并且提高了原 Isomap 算法的泛化能力。将该方法应用于步态识别中,实验结果表明该算法是有效可行的。但由于步态特征不像指纹和掌纹那样稳定不变,易受行走速度、衣着、携带品、遮挡、行走路面等情况影响,所以本文提出算法的识别性能还有待提高,主要包括提高步态识别算法的鲁棒性以及研究多模态的步态识别方法。

参考文献:

- [1] YOO J-H, NIXON M S, HARRIS C J. Extracting human gait signatures by body segment properties [C]//Proc of the 5th IEEE South-west Symposium on Image Analysis and Interpretation. Washington DC:IEEE Computer Society, 2002:35-39.
- [2] 陈昌由. 流形学习理论和算法及其在生物认证中的应用 [D]. 上海:复旦大学,2010.
- [3] XU Su-li, ZHANG Qian-jin. Gait recognition using fuzzy principal component analysis [C]//Proc of the 2nd International Conference on e-Business and Information System Security. Piscataway, NJ: IEEE Press,2010:1-4.
- [4] SIVAPALAN S, CHEN D, DENMAN S. 3D ellipsoid fitting for multi-view gait recognition [C]//Proc of the 8th IEEE International Conference on Advanced Video and Signal-Based Surveillance. Piscataway, NJ:IEEE Press,2011:355-360.
- [5] 王斐, 闻时光, 张育中, 等. 基于时-频分析的步态模式自动分类 [J]. 北京科技大学学报, 2012, 34(1):32-36.
- [6] 贵观辉, 徐森, 王科俊. 行人步态的特征表达及识别综述 [J]. 模式识别与人工智能, 2012, 25(1):71-81.
- [7] 贵观辉, 徐森, 王科俊. 基于 Trace 变换的步态识别算法 [J]. 吉林大学学报:工学版, 2012, 42(1):156-160.
- [8] 贵观辉, 王科俊, 马慧. 视频下的正面人体身份自动识别 [J]. 智能系统学报, 2012, 7(1):69-74.
- [9] 贵观辉, 安实, 王健, 等. 基于线性插值的张量步态识别算法 [J]. 计算机应用研究, 2012, 29(1):355-358.
- [10] ZHANG Chang-shui, WANG Jun, ZHAO Nan-yuan, et al. Reconstruction and analysis of multi-pose face images based on nonlinear dimensionality reduction [J]. Pattern Recognition, 2004, 37(2):325-336.
- [11] TENENBAUM J B, De SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500):2319-2323.
- [12] COX T F, COX M A A. Multidimensional scaling [M]. London: Chapman & Hall, 1994.
- [13] BEN Xian-ye, MENG Wei-xiao, YAN Rui. Dual-ellipse fitting approach for robust gait periodicity detection [J]. Neurocomputing, 2012, 79(1):173-178.
- [14] ZHAO Hai-tao, SUN Shao-yuan. Optimal locality preserving projection [C]//Proc of the 17th IEEE International Conference on Image Processing. 2010:1861-1864.
- [15] CAI Deng, HE Xiao-fei, ZHOU Kun, et al. Locality sensitive discriminant analysis [C]//Proc of the 20th International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann, 2007:708-713.

(上接第 4337 页)

表 3 增量学习新类别时的测试识别率/%

测试集	初始	学习 1	学习 2	学习 3	学习 4	学习 5
初始	96.6	96.6	96.6	96.6	96.6	96
A	-	100	100	100	100	100
B	-	-	100	100	100	100
C	-	-	-	60	60	60
D	-	-	-	-	100	100
E	-	-	-	-	-	40

由于整个分类器由相互独立的子网络构成,使得分类器的结构比较灵活。各子网络的识别率只与该子网络的训练样本以及训练效果有关。当新样本规模较大时,只需向集成网络中添加或者重新训练相应的子网络,就能在保持良好泛化能力的同时快速达到增量学习的目的,从而避免了对整个分类器的重新训练。

5 结束语

本文在对人脸图像进行小波分解与 PCA 特征提取的基础上,使用集成 BP 网络实现对面脸图像的识别,克服了单一 BP 网络规模大、训练时间长、容易陷入局部极小的缺点。当有新的样本需要学习时,向集成网络中添加新的子网络获取未知类型的样本知识,或者通过重新训练相应的子网络来实现对错误识别的新样本的学习。文中集成网络的增量学习时子网络的训练用到了所有样本的特征信息,用时间保证了较优的识别率。这为下一步的研究提供了方向,即在训练集庞大的情况

下,如何选取部分训练样本集使得集成网络的增量学习保持良好的效果。

参考文献:

- [1] 马怡然, 张凤玲. 基于 DCT 的 PCA 及神经网络的人脸识别研究 [J]. 郑州大学学报:理学版, 2007, 39(3):76-79.
- [2] 韩力群. 人工神经网络教程 [M]. 北京:北京邮电大学出版社, 2006:74-75.
- [3] 李军梅, 胡以华, 陶小红. 基于主成分分析与 BP 神经网络的识别方法研究 [J]. 红外与激光工程, 2005, 34(6):719-723.
- [4] 刘建军, 胡卫东, 郁文贤. 基于前馈神经网络的增量学习研究 [J]. 计算机与现代化, 2009(7):1-4.
- [5] FU Li-min, HSU H-H, PRINCIPE J C. Incremental backpropagation learning networks [J]. IEEE Trans on Neural Networks, 1996, 7(3):757-761.
- [6] ZHANG Jie, MORRIS A J. A sequential learning approach for single hidden layer neural networks [J]. Neural Networks, 1998, 11(1):65-80.
- [7] 周静, 程兴国, 肖南峰. CPN 网络模拟仿人机器人学习推理能力的应用 [J]. 重庆理工大学学报:自然科学版, 2011, 25(6):73-78.
- [8] POLIKAR R, UPDA L, UPDA S, et al. Learn++: an incremental learning algorithm for supervised neural networks [J]. IEEE Trans on Systems, Man and Cybernetics, Part C: Applications and Reviews, 2001, 31(4):497-508.
- [9] FREUND Y, SCHAPIRE R. A decision-theoretic generalization of on-line learning and application to boosting [J]. Journal of Computer and System Sciences, 1997, 55(1):119-139.