

# 基于 HOG 特征和 DSPP 降维的人脸识别算法

田亚娜<sup>1</sup>, 童莹<sup>2</sup>, 曹雪虹<sup>2</sup>

(1. 南京邮电大学 通信与信息工程学院, 江苏 南京 210003;

2. 南京工程学院 通信工程学院, 江苏 南京 211167)

**摘要:**稀疏保留投影(SPP)是一种以保持数据的稀疏表示结构为目的的降维方法,该方法仅考虑了数据的稀疏重构关系而没有充分利用样本的类别信息。为提高分类识别性能,提出一种有监督的判别稀疏保留投影方法(DSPP)。首先在构建样本的稀疏重构关系时,通过样本系数和类内样本平均系数的差来重新表示类内紧凑度,同时考虑不同类样本的类别信息和同类样本的类内紧凑度信息,优化得到具有较强鉴别能力的稀疏表示系数;再通过最小化重构误差准则来得到最优投影,从而提取有效的人脸信息;最后用稀疏表示分类方法进行人脸分类识别。HOG算子可以很好地表征人脸图像的局部特征同时有很好的鲁棒性,文中在HOG算子提取图像特征的基础上,用DSPP方法对图像特征降维后再进行人脸识别分类。实验结果表明,结合HOG特征和DSPP算法的人脸识别在Extended Yale B和LFW库上的平均识别率分别达到98.33%和77.93%,相比其他方法有较好的识别结果。

**关键词:**稀疏保留投影;有监督;降维;梯度方向直方图;人脸识别

中图分类号:TP273

文献标识码:A

文章编号:1673-629X(2018)01-0069-05

doi:10.3969/j.issn.1673-629X.2018.01.015

## Face Recognition Algorithm Based on HOG Feature and DSPP Dimension Reduction

TIAN Ya-na<sup>1</sup>, TONG Ying<sup>2</sup>, CAO Xue-hong<sup>2</sup>

(1. School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;

2. School of Communication Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

**Abstract:** Sparsity preserving projections (SPP) is a kind of good dimensionality reduction algorithm for maintaining the sparse representation structure of data. It only considers the sparse reconstruction relations of the data without using the class information of the samples. To improve the performance of classification and recognition, we proposed a supervised discriminant sparse preserving projection (DSPP). Firstly, when constructing the sparse reconstruction relations of the samples, the class information of different samples and the intraclass dispersion information of the same class of samples are taken into account at the same time, which the intraclass dispersion is represented using the difference between the average coefficient of the sample coefficients and the intraclass sample coefficient. And then the sparse representation structure with strong discriminating ability are obtained. Then, the optimal projection is obtained by minimizing the reconstruction error to extract the effective face information. Finally, the sparse representation classification is used to face recognition. HOG operator can well represent the local features of face images and has good robustness. Based on the feature extraction of face image by HOG operator, we use DSPP to reduce the dimension of image features and then classify them. Experiment shows that the average recognition rate of face recognition based on HOG feature and DSPP algorithm achieves 98.33% and 77.93% on Extended Yale B and LFW face databases respectively, and the recognition rates are obviously higher than that of some other related methods.

**Key words:** sparsity preserving projections; supervised; dimension reduction; HOG; face recognition

收稿日期:2017-02-13

修回日期:2017-06-16

网络出版时间:2017-10-19

基金项目:国家自然科学基金(61471162);江苏省自然科学基金(BK20141389);南京工程学院科研基金(QKJA201304)

作者简介:田亚娜(1993-),女,硕士研究生,研究方向为图像处理与模式识别;童莹,副教授,研究方向为图像处理与模式识别;曹雪虹,教授,研究方向为无线通信系统与信息理论。

网络出版地址: <http://cnki.net/kcms/detail/61.1450.TP.20171019.1625.046.html>

## 1 概述

随着信息技术的发展,高维数据的问题普遍存在,尤其是在许多模式识别和数据挖掘运用中,比如人脸图像识别和生物基因数据分析等。在高维数据的分析和学习中,数据降维有着非常重要的作用。数据降维不仅使得数据便于存储和计算,而且能够去除数据冗余信息,找到高维数据的低维表示以利于分析。目前,已有许多种数据降维方法成功运用到模式识别、图像处理等领域。

在现有的数据降维方法中,主成分分析(PCA)<sup>[1]</sup>和线性判别分析(LDA)<sup>[2]</sup>都是在图像数据满足高斯分布的假设条件下,计算图像的全局欧式结构来进行降维分析,没有分析局部结构特征。在实际运用中,很多人脸数据并不满足高斯分布,而且高维数据的局部结构特征对表示图像和图像分类判别是非常重要的。后来,流形学习成了研究热点,通过学习高维空间中样本的局部邻域结构,从高维空间中找到低维流形以实现维数约简。最有代表性的流形学习算法有拉普拉斯特征映射(LE)<sup>[3]</sup>、局部线性映射(LLE)<sup>[4]</sup>和局部保持投影(LPP)<sup>[5]</sup>等。LE是用一个无向加权图来描述一个流形图,在保持图的局部邻接关系的情况下,从高维空间降到低维表示空间;LLE是寻找每个样本的局部近邻点并计算样本的重建权值矩阵,通过保留嵌入在高维原始数据中的低维局部线性结构关系进行降维;LPP是构建高维空间中各样本的远近亲疏关系图,在降维投影时保持这种关系图不变来分析数据的局部结构特征。尽管这些算法的实现方法不一样,但它们的实现原理都可以统一到图形嵌入框架<sup>[6]</sup>。也就是说,它们的区别在于图结构的构造不同和边权重的计算不同。图结构的不同构造方法是不同降维算法的重点。LPP邻接图通过映射使得高维空间中邻域范围内的点在低维空间中尽可能近,同时使得其他不在邻域内的点通过映射在低维空间中尽可能远。而这些算法都非常依赖于参数的选择,需要人工选择邻域大小参数和边权重参数。

近年来,基于稀疏表示的方法在人脸识别中得到广泛应用。Wright等<sup>[7]</sup>提出将稀疏表示用在图像分类中,并且得到了很好的分类结果。文献[8-9]中认为稀疏表示能够很好地表征数据的局部结构关系。基于稀疏表示的概念,乔立山运用稀疏表示系数构建一种新的图结构,提出稀疏保留投影(SPP)算法<sup>[10]</sup>。算法实现过程中,稀疏表示系数是通过最小化L1范数求得,因此这种邻接图又叫L1图,L1图的构建过程继承了稀疏重构的优点,同时解决了人工参数选择的问题。文献[11-13]也相继提出基于稀疏表示方法构建L1图进行人脸识别。文献[14]在最小化L1正则化目标

函数中引入了类别信息再结合稀疏重构误差来分析投影矩阵。文献[15]提出了一种判别稀疏邻域保持嵌入算法,通过结合SPP和最大边缘准则进行投影,提高了人脸识别率。

在稀疏保留投影算法获得重构关系时,既没有利用不同类样本的类别信息,也没有充分考虑同类样本间的相似问题。文中提出一种新的有监督的判别稀疏保留投影方法(DSPP)。首先利用样本系数与类内样本的平均系数之差来重新定义类内离散度,在获得稀疏重构关系时,对每个训练样本仅利用和样本同类别的其余样本来线性表示,同时添加类内离散度约束项以减小每个类的表示系数的变化。这样得到的稀疏表示系数具有更好的判别能力,能够保留不同类样本之间具有判别性的结构信息,然后再通过最小化重构误差准则,保留投影获取有效的人脸特征信息来提高分类识别能力。

在人脸识别过程中,对原图像直接分类判别能够得到一定的识别率,可是受光照、表情、姿态等的变化会对人脸图像的识别造成不利影响。为克服这些因素的影响,提取有效的表征人脸信息的特征也是至关重要的。梯度方向直方图(histograms of oriented gradients, HOG)算子<sup>[16-17]</sup>是通过局部梯度大小和边缘信息将图像局部特征化,是一种局部信息描述算子。HOG特征具有很好的鲁棒性,能够很好地表征人脸的特征。文中在HOG算子提取图像特征的基础上,用DSPP方法降维处理再进行分类判别,并通过实验对其进行验证。

## 2 HOG 特征提取

HOG算子<sup>[17]</sup>通过计算图像局部区域的梯度,并统计分布在不同方向的梯度幅值,得到梯度方向直方图来构成HOG特征。图像的局部外观和形状通过局部梯度和边缘信息得到很好的表征和描述。HOG特征具有对方向、尺度、光照的不敏感性,对图像区域的小变化保持不变性。HOG算子提取图像特征的过程如下:

(1)遍历图像的所有像素点,并计算各个像素点的梯度幅值和梯度方向,捕获图像边缘信息,弱化光照的干扰。

(2)将图像均匀划分为 $2 \times 2$ 像素的单元(cell)并对每个单元的梯度方向进行统计。将 $[0, \pi]$ 分为9个区间,平均每 $20^\circ$ 为一个区间(bin),这样每个单元获得一个9维的梯度方向直方图。

(3)把相邻的 $2 \times 2$ 个不重叠的cell组合成一个网格(block),将每个block块内的4个cell的直方图拼接,经过L2-norm标准化处理,得到一个block块的梯

度直方图。

(4)将一张图像划分的所有 block 块的梯度直方图进行拼接,统计得到整个图像的 HOG 特征。

对于大小为  $32 \times 32$  的一幅图像,可划分为  $64 (8 \times 8)$  个 block 块,得到的 HOG 特征维数为  $2\ 304 (8 \times 8 \times 4 \times 9)$ 。HOG 算子有良好的局部特性,对于光照等变化的影响具有鲁棒性,是提取图像特征的有效算子。

### 3 稀疏保留投影 (sparsity preserving projections, SPP)

不同于 LLE<sup>[4]</sup>、LPP<sup>[5]</sup> 等流形学习方法, SPP<sup>[10]</sup> 是利用稀疏表示的原理构建样本之间的重构关系图,再通过最小化重构误差准则进行最优投影,使得高维空间中样本之间的重构关系在低维空间中保持不变。

受稀疏表示的启发,每个图像样本可以由其余样本稀疏表示,样本之间的关系可以通过稀疏系数来表示。许多研究<sup>[18-19]</sup>表明,通过求解 L1 范数最小化可以得到最优稀疏表示系数。图结构有效地表征数据之间的相互关系,用得到的稀疏系数构建的邻接图叫做 L1 图,用 L1 图结构来表示样本图像之间的关系。假设有  $n$  个训练样本,样本集记为  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$ ,  $\mathbf{X} \in R^{m \times n}$ ,通过求 L1 范数最小化问题构建邻接图  $\zeta = \{\mathbf{X}, \mathbf{W}\}$  来表示样本之间的相互关系。对任一训练样本  $\mathbf{x}_i$ :

$$\min_{\mathbf{w}_i} \|\mathbf{w}_i\|_1 \quad \text{s. t.} \quad \mathbf{x}_i = \mathbf{X}_i \mathbf{w}_i \quad (1)$$

其中,  $\mathbf{X}_i = [\mathbf{x}_1, \dots, \mathbf{x}_{i-1}, \mathbf{x}_{i+1}, \dots, \mathbf{x}_n] \in R^{m \times (n-1)}$  表示除  $\mathbf{x}_i$  以外的其余训练样本构成的矩阵;  $\mathbf{w}_i = [w_{i1}, \dots, w_{ij}, \dots, w_{in}]^T \in R^{n-1}$  表示系数向量;  $w_{ij}$  表示训练样本  $\mathbf{x}_j$  对重构  $\mathbf{x}_i$  的稀疏表示系数值,系数值越大表示对应样本和重构样本越相似。再依次求得每个训练样本的稀疏表示系数向量,得到  $\mathbf{W} = [w_1, \dots, w_i, \dots, w_n]$ ,也就构建完成 L1 邻接图。

由得到的 L1 邻接图,根据最小化重构误差准则,通过最优化目标函数得到一个线性投影,使得样本之间的重构关系在降维前后保持不变,其目标函数是:

$$\min_p \sum_{i=1}^n \|\mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \mathbf{X} \tilde{\mathbf{w}}_i\|^2 \quad (2)$$

其中,  $\tilde{\mathbf{w}}_i$  是式(1)的最优化解。通过简单的数学推导,式(2)转换为求解式(3)广义特征值问题,选取最大  $d$  个特征值对应的特征向量构成最优投影矩阵。

$$\mathbf{X}(\mathbf{W} + \mathbf{W}^T - \mathbf{W}^T \mathbf{W}) \mathbf{X}^T \mathbf{p} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{p} \quad (3)$$

将训练样本和测试样本分别在投影矩阵上进行投影降维,然后再进行分类识别。SPP 算法利用 L1 范数最小化问题分析样本之间的稀疏重构关系,既没有人工参数选择,又具有很好的鲁棒性和适应性,在人脸识别

别中得到明确的验证和运用。

### 4 判别稀疏保留投影 (discriminant sparse preserving projection, DSPP)

稀疏保留投影算法在构建图结构时用其余所有的训练样本线性表示某一个样本,保留高维空间中数据的稀疏重构关系,没有利用不同样本的类别信息,也没有充分考虑同类样本之间的相似性。为了提高 SPP 算法的分类识别性,文中提出了一种判别稀疏保留投影算法(DSPP)。该算法利用样本的标签信息同时添加类内散度约束项,获得样本的稀疏重构关系,通过构建新的具有判别性的邻接图结构来保留样本之间的相互关系,再由最小化重构误差得到最优线性投影,从而提取更有效的人脸信息进行分类识别。

#### 4.1 构建邻接图

假设  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in R^{m \times n}$  是共  $c$  类的  $n$  个训练样本,每类样本有  $n_k$  个训练样本,满足  $\sum_{k=1}^c n_k = n$ ,  $\ell_{(x_i)}$  表示样本  $\mathbf{x}_i$  的类别信息。通过解以下最优化问题得到样本之间的稀疏表示系数:

$$\min_{s_i} \|\mathbf{x}_i - \mathbf{X}^{\ell_{(x_i)}} \mathbf{s}_i\|_F^2 + \lambda \|\mathbf{s}_i\|_F^2 + \|\mathbf{s}_i - \mathbf{F}_{\ell_{(x_i)}}\|_F^2 \quad (4)$$

其中,  $\mathbf{x}_i$  为任意一个训练样本;  $\mathbf{X}^{\ell_{(x_i)}}$  为由除  $\mathbf{x}_i$  以外并且和  $\mathbf{x}_i$  有相同类别的训练样本组成的矩阵;  $\mathbf{s}_i$  为  $\mathbf{X}^{\ell_{(x_i)}}$  训练样本集对样本  $\mathbf{x}_i$  的线性表示系数;  $\lambda$  为大于零的参数。

有研究<sup>[20]</sup>表明, L1 范数的稀疏约束在基于稀疏表示的人脸识别中没有起到至关重要的作用,这里用  $F$  范数替代 L1 范数对系数进行正则化约束。 $\mathbf{F}_{\ell_{(x_i)}}$  是与  $\mathbf{x}_i$  有相同类别的所有样本的平均表示系数,最小化  $\|\mathbf{s}_i - \mathbf{F}_{\ell_{(x_i)}}\|_F^2$  目的是使相同类别的样本的表示系数接近它们的平均值,以减小每类的系数向量的变化,使每类类内散度最小化。

式(4)变形化简得到:

$$\begin{aligned} \|\mathbf{x}_i - \mathbf{X}^{\ell_{(x_i)}} \mathbf{s}_i\|_F^2 + \lambda \|\mathbf{s}_i\|_F^2 + \|\mathbf{s}_i - \mathbf{F}_{\ell_{(x_i)}}\|_F^2 = \\ \text{tr}(\mathbf{x}_i^T \mathbf{x}_i) - 2\text{tr}(\mathbf{s}_i^T \mathbf{X}^T \mathbf{x}_i) + \text{tr}(\mathbf{s}_i^T \mathbf{X}^T \mathbf{X} \mathbf{s}_i) + \\ \lambda \text{tr}(\mathbf{s}_i^T \mathbf{s}_i) + \text{tr}(\mathbf{s}_i^T \mathbf{s}_i) - 2\text{tr}(\mathbf{s}_i^T \mathbf{F}_{\ell_{(x_i)}}) + \\ \text{tr}(\mathbf{F}_{\ell_{(x_i)}}^T \mathbf{F}_{\ell_{(x_i)}}) \end{aligned} \quad (5)$$

式(5)对  $\mathbf{s}_i$  求偏导,并令偏导式右边等于 0,整理可得到最优  $\mathbf{s}_i$ :

$$\mathbf{s}_i = \mathbf{X}^T \mathbf{X} + (\lambda + 1)^{-1} (\mathbf{X}^T \mathbf{x}_i + \mathbf{F}_{\ell_{(x_i)}}) \quad (6)$$

由计算得到  $\mathbf{s}_i = [s_{i1}, \dots, s_{ij}, \dots, s_{in_i}]$ ,  $j \in \ell_{(x_i)}$ ,构建新的样本之间的邻接图关系  $\zeta = \{\mathbf{X}, \mathbf{W}\}$ , 其中  $\mathbf{W} = [\mathbf{w}_1, \dots, \mathbf{w}_i, \dots, \mathbf{w}_n] \in R^{n \times n}$ ,  $\mathbf{w}_i = [w_{i1}, \dots, w_{ij}, \dots, w_{in}]^T$ ,  $w_{ij}$  定义为:



$$w_{ij} = \begin{cases} s_{ij}, \ell_{(x_i)} = \ell_{(x_j)} \text{ and } i \neq j \\ 0, \ell_{(x_i)} \neq \ell_{(x_j)} \text{ or } i = j \end{cases} \quad (7)$$

4.2 最优投影

上述邻接关系图的构建过程中,不仅利用不同类样本的类别信息,而且充分考虑了同类样本集的相似性,通过计算稀疏表示系数很好地表示了样本之间的关系。

图结构矩阵  $\mathbf{W}$  表示了高维空间中各样本之间的内在关系,为了在低维空间中最大限度地保留这种关系,类似 SPP 算法,通过最小化重构误差函数得到最优投影:

$$\min_P \sum_{i=1}^n \| \mathbf{P}^T \mathbf{x}_i - \mathbf{P}^T \mathbf{X} \mathbf{w}_i \|^2 \text{ s. t. } \mathbf{P}^T \mathbf{X} \mathbf{X}^T \mathbf{P} = \mathbf{I} \quad (8)$$

其中,  $\mathbf{P}$  为投影矩阵;  $\mathbf{w}_i$  为样本  $\mathbf{x}_i$  的稀疏重构系数;约束项是为了防止退化解。

通过数学公式推导,可转化得到如下最优问题:

$$\min_P \mathbf{P}^T \mathbf{X} (\mathbf{I} - \mathbf{W} - \mathbf{W}^T + \mathbf{W}^T \mathbf{W}) \mathbf{X}^T \mathbf{P}$$
$$\text{s. t. } \mathbf{P}^T \mathbf{X} \mathbf{X}^T \mathbf{P} = \mathbf{I} \quad (9)$$

令  $\mathbf{W}_\beta = \mathbf{W} + \mathbf{W}^T - \mathbf{W}^T \mathbf{W}$ , 为计算严谨,转换最小化问题为求解一个最大化问题。

$$\max_P \frac{\mathbf{P}^T \mathbf{X} \mathbf{W}_\beta \mathbf{X}^T \mathbf{P}}{\mathbf{P}^T \mathbf{X} \mathbf{X}^T \mathbf{P}} \quad (10)$$

求解最优解  $\mathbf{P}$  即转化为求解广义特征值问题,  $\mathbf{X} \mathbf{W}_\beta \mathbf{X}^T \mathbf{p} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{p}$ , 选取前  $d$  个最大特征值对应的特征向量构成投影矩阵,记为  $\mathbf{W}_{\text{DSPP}} = [\mathbf{p}_1, \mathbf{p}_2, \cdots, \mathbf{p}_d]$ 。将训练样本  $\mathbf{X}$  在  $\mathbf{W}_{\text{DSPP}}$  上进行投影,得到一个  $d \times n$  维矩阵,同样也将测试样本在  $\mathbf{W}_{\text{DSPP}}$  上进行投影,得到具有判别性的人脸信息后再进行分类识别。

然而在某些高维数据中,训练样本的维数大于样本个数,使得矩阵  $\mathbf{X} \mathbf{X}^T$  是奇异矩阵,无法计算式(10)。为解决这个问题,首先采用主成分分析法对原始的训练样本进行预处理,得到降维后的样本  $\mathbf{X} = \mathbf{P}_{\text{PCA}}^T \mathbf{X}$ , 矩阵  $\mathbf{X} \mathbf{X}^T$  是非奇异的。不失一般性,仍然用  $\mathbf{X}$  表示预处理后的样本。

5 实验仿真

为了验证算法的有效性,与其他算法 (PCA<sup>[1]</sup>、LDA<sup>[2]</sup>、LPP<sup>[5]</sup>、LSDA<sup>[21]</sup>、SPP<sup>[10]</sup>) 进行比较。DSPP 算法中,参数  $\lambda$  设置为 0.05。文中采用 Extended Yale B 人脸库<sup>[22]</sup> 和 LFW 人脸库<sup>[23]</sup> 进行实验。所有实验采用稀疏表示分类方法进行分类识别,通过用训练样本集对测试样本进行稀疏表示,求出稀疏系数向量,根据系数向量对测试样本在每个类上进行重构,分别计算测试样本和每类的重构样本之间的残差,将测试样本判别为残差最小的类别。

5.1 Extended Yale B 库

Extended Yale B 库包含 38 类人在光照条件变化的情况下获得的人脸照片,图像大小为  $192 \times 168$ ,每类人有大约 64 张,共 2 414 张正面对齐图像。选取有 64 张图像的人脸作为实验数据,共 31 类,共 1 984 张图像,并且每张图像大小裁剪调整为  $32 \times 32$  大小,并进行归一化处理。图 1 为 Extended Yale B 人脸库中某类人的一些样本图像。



图 1 Extended Yale B 库的样本图像

实验包括两部分,分别是对人脸原图像的分类识别和基于原图像 HOG 特征的分类识别。在每类人的图像中随机选取 10 个样本进行训练,其余样本用于测试,重复进行 10 次,最后计算得到平均值和标准偏差。表 1 是对 Extended Yale B 库的人脸原图像在不同方法下的平均识别率和标准偏差;表 2 是在 Extended Yale B 库人脸图像 HOG 特征的基础上再利用不同方法降维的平均识别率和标准偏差。

表 1 Extended Yale B 库原图像的实验结果

指标	PCA	LDA	LPP	LSDA	SPP	DSPP
平均识别率	82.03	83.53	87.31	87.39	87.36	89.10
标准偏差	±1.79	±0.65	±1.21	±1.09	±1.32	±0.79

表 2 Extended Yale B 库图像 HOG 特征的实验结果

指标	PCA	LDA	LPP	LSDA	SPP	DSPP
平均识别率	94.46	97.44	97.86	97.85	92.24	98.33
标准偏差	±0.63	±0.34	±0.61	±0.73	±1.02	±0.45

从表 1 可以看出,文中提出的 DSPP 算法的识别率相比其他算法有很大提升,提高到 89.10%,主要原因是 DSPP 算法实现过程中同时考虑了不同类的类别信息和相同类的离散度信息,在降维过程中更充分地保持了数据的内在结构和便于分类的结构信息,从而更好地提高了识别率。结合表 1 和表 2 可以看出,相比原图像的分类判别,基于人脸图像 HOG 特征的分类判别结果有明显提高,主要原因是 HOG 算子是具有鲁棒性的局部特征描述子,HOG 特征很好地表征了图像的局部特征,提取了有效的人脸特征信息,从而取得了较高的识别率。

5.2 LFW 库

LFW 库包含 5 749 类人的 13 233 张人脸图像,图片大小为  $250 \times 250$ ,其中 1 680 类人有两张以上的图

片,剩余的 4 069 类人只有一张图片。实验中,选取有 20 张以上(包括 20 张)图像的人脸作为实验数据,共 62 类,共 3 023 张图像。基于图论的视觉显著性算法对图像检测人脸区域,并调整图像大小为 128 × 128,再进行归一化处理。图 2 为 LFW 人脸库中某类人的一些样本图像。



图 2 LFW 库的样本图像

实验包括两部分,分别是对人脸原图像的分类识别和基于原图像 HOG 特征的分类识别。实验过程中,对每类人的图片分别随机选取 10 个样本进行训练,其余样本用于测试,即有 620 个训练样本,2 403 个测试样本,重复进行 10 次,最后以计算得到的平均值和标准偏差作为最后的识别结果进行分析。结果如表 3 和表 4 所示。

表 3 LFW 库的原图像的实验结果

指标	PCA	LDA	LPP	LSDA	SPP	DSPP
平均识别率	34.32	49.93	48.75	45.51	38.24	57.06
标准偏差	±1.01	±0.95	±2.15	±1.86	±1.56	±1.03

表 4 LFW 库的图像 HOG 特征的实验结果

指标	PCA	LDA	LPP	LSDA	SPP	DSPP
平均识别率	77.66	74.79	73.78	75.96	73.86	77.93
标准偏差	±0.82	±1.26	±1.69	±1.19	±1.01	±1.76

从表 3 可以看出,对 LFW 人脸库原图像分类判别,DSPP 算法取得 57.06% 的识别率,比 PCA、LDA、LPP、LSDA、SPP 的识别结果分别提高 22.74%、7.13%、8.31%、11.55%、18.82%,识别效果提高明显。

从表 4 可以看出,在 LFW 库人脸图像 HOG 特征的基础上,DSPP 算法的识别率达到 77.93%,对比人脸原图像识别结果提高 20.87%,充分验证了该算法的可行性和有效性。

6 结束语

提出一种新的判别性稀疏保留投影算法,在构建数据间的稀疏重构关系时,同时考虑样本不同类的类别信息和相同类的类内散度信息,保持了数据具有判别性的内在结构信息,提高了人脸图像的识别率。鉴于 HOG 算子能够描述图像的局部特征,克服了图像对光照、姿态等变化的影响,具有很强的鲁棒性。所以该算法能够提取得到更有效的人脸特征信息,使得人脸识别效率有不断的提高。

参考文献:

[1] ABDI H, WILLIAMS L J. Principal component analysis[J]. Wiley Interdisciplinary Reviews: Computational Statistics, 2010, 2(4): 433-459.

[2] IZENMAN A J. Linear discriminant analysis[M]//Modern multivariate statistical techniques. New York: Springer, 2013: 237-280.

[3] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396.

[4] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.

[5] HE X, YAN S, HU Y, et al. Face recognition using Laplacian-faces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.

[6] YAN S, XU D, ZHANG B, et al. Graph embedding and extensions: a general framework for dimensionality reduction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.

[7] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.

[8] WRIGHT J, MA Y, MAIRAL J, et al. Sparse representation for computer vision and pattern recognition[J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.

[9] ELHAMIFAR E, VIDAL R. Sparse subspace clustering: algorithm, theory, and applications[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2765-2781.

[10] QIAO L, CHEN S, TAN X. Sparsity preserving projections with applications to face recognition[J]. Pattern Recognition, 2010, 43(1): 331-341.

[11] YANG J, CHU D, ZHANG L, et al. Sparse representation classifier steered discriminative projection with applications to face recognition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2013, 24(7): 1023-1035.

[12] 杜春, 孙即祥, 周石琳, 等. 基于稀疏表示和非参数判别分析的降维算法[J]. 国防科技大学学报, 2013, 35(2): 143-147.

[13] GAO Q, HUANG Y, ZHANG H, et al. Discriminative sparsity preserving projections for image recognition[J]. Pattern Recognition, 2015, 48(8): 2543-2553.

[14] ZANG F, ZHANG J. Discriminative learning by sparse representation for classification[J]. Neurocomputing, 2011, 74(12): 2176-2183.

[15] GUI J, SUN Z, JIA W, et al. Discriminant sparse neighborhood preserving embedding for face recognition[J]. Pattern Recognition, 2012, 45(8): 2884-2893.

表 1 是 Barbara 图像在不同码率下, JPEG2000 算法与文中算法编码的 PSNR 值对比。从表 1 可见,文中算法在各码率下均能取得较高的 PSNR,尤其在低码率下,文中算法约超过 JPEG2000 算法 1 dB 左右。

表 1 不同码率下的 PSNR 对比

码率 R	JPEG2000 算法	文中算法
1	66.53	66.73
0.5	50.15	51.79
0.4	46.96	47.53
0.25	42.05	42.77
0.2	40.31	41.16
0.1	34.77	35.96

4 结束语

将 WBCT 与 EBCOT 编码算法相结合,通过码块熵最小化原则优化小波变换高频子带的方向分解,增加码块内部系数的相关性,提高编码效率,利用 EBOCT 编码算法生成编码流。经过对比实验,结果表明,文中算法不仅可以提高峰值信噪比,而且对图像中的局部纹理保持效果较好。

参考文献:

[1] 韦长江,郝鹏威,石青云. 基于整型 DCT 变换的图象编码研究[J]. 中国图象图形学报,2002,7(3):287-291.

[2] 田金文,柳 斌,柳 健. 基于整数小波变换的准无失真图像压缩技术[J]. 电子学报,2000,28(4):64-68.

[3] 何玉杰,李 敏,吕 东,等. 一种基于 Curvelet 变换的红外图像去噪方法[J]. 计算机工程与应用,2011,47(32):191-193.

[4] DO M N, VETTERLI M. Contourlets: a directional multiresolution image representation[C]//Proceedings of IEEE international conference on image processing. [s. l.]: IEEE, 2002: 357-360.

(上接第 73 页)

[16] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]//IEEE computer society conference on computer vision and pattern recognition. [s. l.]: IEEE, 2005: 886-893.

[17] DÉNIZ O, BUENO G, SALIDO J, et al. Face recognition using histograms of oriented gradients[J]. Pattern Recognition Letters, 2011, 32(12): 1598-1603.

[18] CHENG B, YANG J, YAN S, et al. Learning with l1-graph for image analysis[J]. IEEE Transactions on Image Processing, 2010, 19(4): 858-866.

[19] YANG Y, WANG Z, YANG J, et al. Data clustering by Laplacian regularized L1-graph[C]//Twenty-eighth AAAI conference on artificial intelligence. [s. l.]: [s. n.], 2014: 3148-3149.

[5] ESLAMI R, RADHA H. Wavelet-based contourlet transform and its application to image coding[C]//Proceedings of IEEE international conference on image processing. Singapore: IEEE, 2004: 3189-3192.

[6] 王发牛,梁 栋,程志友,等. 一种基于非抽样 LP 的 Contourlet 变换图像去噪方法[J]. 中国图象图形学报, 2009, 14(3): 458-462.

[7] 唐国维,张 岩,王苦社,等. 基于 Contourlet 方向滤波优化的 SPECK 图像编码算法[J]. 信息与控制, 2015, 44(6): 641-647.

[8] ISLAM A, PEARIMAN W A. An embedded and efficient low complexity hierarchical image coder[C]//Conference on visual communications and image processing. [s. l.]: [s. n.], 1999: 294-305.

[9] TAUBMAN D. High performance scalable image compression with EBCOT[J]. IEEE Transactions on Image Processing, 2000, 9(7): 1158-1170.

[10] BALSTER E J, FORTENER B T, Turri W F. Post-compression rate-distortion development for embedded block coding with optimal truncation in Jpeg2000 imagery [J]. International Journal of Image & Graphics, 2011, 11(4): 611-627.

[11] 宋蓓蓓,许录平,孙文方. 一种基于小波的 Contourlet 变换的图像压缩算法[J]. 西安交通大学学报, 2007, 41(4): 479-483.

[12] AULILLINAS F. Entropy-based evaluation of context models for wavelet-transformed images[J]. IEEE Transactions on Image Processing, 2015, 24(1): 57-67.

[13] 朱悦心,张 静,王 勇,等. JPEG2000 全通道并行 EBCOT-Tier1 编码器结构设计[J]. 电子与信息学报, 2006, 28(12): 2362-2366.

[14] 庄怀宇. 内嵌图像编码中高效码率控制技术研究[D]. 西安: 西安电子科技大学, 2006.

[15] DUNCAN D Y, DO M N. Directional multiscale modeling of images using the contourlet transform[C]//IEEE workshop on statistical signal processing. [s. l.]: IEEE, 2003: 262-265.

[20] ZHANG L, YANG M, FENG X. Sparse representation or collaborative representation: which helps face recognition? [C]//2011 International conference on computer vision. [s. l.]: IEEE, 2011: 471-478.

[21] GAO Q, LIU J, CUI K, et al. Stable locality sensitive discriminant analysis for image recognition [J]. Neural Networks, 2014, 54: 49-56.

[22] LEE K C, HO J, KRIEGMAN D J. Acquiring linear subspaces for face recognition under variable lighting[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(5): 684-698.

[23] HUANG G B, RAMESH M, BERG T, et al. Labeled faces in the wild: a database for studying face recognition in unconstrained environments[R]. Amherst: University of Massachusetts, 2007.