

# 基于迹变换和旋转增量调制特征的模糊人脸识别

汪宇玲<sup>1</sup>, 陈立<sup>1</sup>, 黎明<sup>2</sup>, 钟国韵<sup>1</sup>, 何月顺<sup>1</sup>, 常玉祥<sup>1</sup>, 宋伟宁<sup>1</sup>

(1. 东华理工大学江西省核地学数据科学与系统工程技术研究中心, 江西南昌 330013;  
2. 南昌航空大学江西省图像处理与模式识别重点实验室, 江西南昌 330063)

**摘要:** 为提高各种不同特殊场景下的模糊人脸识别精确性和鲁棒性, 本文提出一种基于迹变换和旋转增量调制编码的特征提取方法. 该方法将通信语音编码技术与图像变换技术相结合, 首先通过迹线旋转扫描整幅图像, 并对迹线上的采样信息进行增量调制编码, 从而获得多角度的全局有序结构特征, 然后用支持向量机对样本图像的这些特征进行训练以分类并识别图像. 实验结果表明, 在各种不同模糊级的低质量人脸数据库上, 本文方法对不同光照变化、不同拍摄角度、不同遮挡等不同场景的人脸图像均能取得较好的识别效果, 与一些传统方法相比识别性能大幅提升, 相对于 VGGNet 和 Sphreface 两种先进方法在三组不同模糊度测试图像集的平均识别率分别提高 2.18% 和 2.20%, 具有更高的识别精度和更好的鲁棒性.

**关键词:** 模糊人脸识别; 特征提取; 迹变换; 旋转增量调制

**中图分类号:** TP391.4; TN911.73

**文献标识码:** A

**文章编号:** 0372-2112(2021)12-2437-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20200599

## Rotational Delta Modulation Feature and Its Application in Blurry Face Recognition Based on Trace Transform

WANG Yu-ling<sup>1</sup>, CHEN Li<sup>1</sup>, LI Ming<sup>2</sup>, ZHONG Guo-yun<sup>1</sup>, HE Yue-shun<sup>1</sup>, CHANG Yu-xiang<sup>1</sup>, SONG Wei-ning<sup>1</sup>

(1. Jiangxi Engineering Technology Research Center of Nuclear Geoscience Data Science and System,  
East China University of Technology, Nanchang, Jiangxi 330013, China;

2. Key Laboratory of Jiangxi Province for Image Processing and Pattern Recognition, Nanchang Hangkong University,  
Nanchang, Jiangxi 330063, China)

**Abstract:** For the accuracy and robustness of the blurry face image recognition in various special scenarios; this paper proposes a novel rotation delta modulation texture extraction method based on trace transform and delta modulation encoding. The method combines the communication speech coding with the image transformation technology. Firstly, the whole image is scanned by the rotating trace line based on trace transformation theory. Secondly, the sampled pixels on the trace line are encoded used delta modulation technology. The global ordered structure features are obtained in various angles. Finally, the features are trained by support vector machine for blurry face image classification and recognition. The experimental results indicate the proposed method has the better performance of blurry face image recognition under illumination fluctuations, various camera angles and image occlusions, and so on, on a variety of low-quality face image sets with different blur levels. The average recognition ratio are increased 2.18% and 2.20% compared to VGG and Sphreface methods on the face image sets with three blur levels, which indicates the proposed method has the higher accuracy and better robustness.

**Key words:** blurry face image recognition; feature extraction; trace transformation; rotational delta modulation

## 1 引言

近三十年来, 人脸识别一直是计算机视觉和图像处理的一个重要研究领域, 而对于不受限制的低分辨率或

模糊人脸识别问题近些年来尤其吸引学界的关注. 目前人脸图像识别比较流行的是传统的人工定义特征提取方法与基于神经网络的方法, 比如 Gabor 小波, 局部二值模式、尺度不变特征转换等人脸特征提取方法, 还

收稿日期: 2020-06-22; 修回日期: 2021-08-03; 责任编辑: 梅志强

基金项目: 国家自然科学基金(No. 62066003, No. 61866025, No. D0213); 国家重点研发计划(No. 2018YFB1702702); 江西省核地学数据科学与系统工程技术研究中心开放基金(No. JETRCNGDSS202006)

有一些以卷积神经网络为基础的深度学习方法. 近年来, 虽然基于卷积神经网络的深度学习技术在图像识别上已经达到了当下最好的性能, 但其需要大量的训练样本, 以及通用性和特征数依然存在不足等<sup>[1]</sup>, 因而应用受到一定限制, 而且对一些特殊情形如低分辨率图像、模糊图像的识别效果也有较大提升空间. 因此, 很多研究人员针对低分辨率和模糊人脸图像等开展了很多工作, 比如对图像进行超分辨率重建<sup>[2]</sup>, 改进传统特征提取方式直接对模糊图像进行识别<sup>[3]</sup>, 采用多种特征结合的方式解决单一特征对低分辨率图像特征描述不充分的问题<sup>[4]</sup>, 采用基于映射的算法<sup>[5]</sup>提高对模糊人脸图像的识别效果, 通过定义更广泛的隶属函数<sup>[6]</sup>, 设计图像模糊识别分类器并应用于人脸识别, 获得了良好的识别性能. 这些研究工作虽然都使得识别性能有一定的提升, 但对于实际的工程应用还存在较大的提升空间.

Zafeiriou S 等人<sup>[7]</sup>基于光度立体视觉提出一种适用于 2D 和 3D 人脸识别的数据集, 并在此基础上对多数识别算法进行了全面的评估. Masi 等人<sup>[8]</sup>提出了对现有的公开的人脸数据集利用 pose+shape+expression 三个方面进行人脸重建和扩增, 识别率为 98.07%. Facebook 提出深度卷积神经网络 DeepFace<sup>[9]</sup>, 在 3D 对齐之后进行模型训练, 识别率达到 97.35%. 同年, 香港中文大学的汤晓鸥提出了原创的 DeepID 系列 CNN 模型, 其中 DeepID1<sup>[10]</sup>采用 4 层卷积, 最后一层为 Softmax 回归函数, 采用多个网络模型训练特征, 组合成高维特征, 然后通过联合贝叶斯进行人脸识别, 识别率达到 98.52%. 百度 AI 开放平台中的人脸识别方法采用 multi-patch deep CNN 和 deep metric learning 相结合获得人脸特征, 最终的人脸识别结果最高达到 99.77%<sup>[11]</sup>. 紧接着, DeepID2<sup>[12]</sup>在 DeepID1 的基础上, 对损失函数进行了改进, 在反应类间变化的分类损失基础上, 添加了减少类内离散度的验证损失, 使人脸识别性能更佳. DeepID3<sup>[13]</sup>对网络结构进行了优化, 尤其在遮挡问题上提升了鲁棒性. Google 提出 FaceNet<sup>[14]</sup>, 用 Triplet Loss 代替 Softmax 损失函数, 用以提升类间离散度, 同时降低类内散度, 识别率达到 99.63%. Liu 等人<sup>[15]</sup>提出 L-Softmax, 去掉分类层的偏置项, 加入人工设定的角度, 以便达到更好的分类效果, 接着提出 A-Softmax, 在 L-Softmax 的基础上归一化权重再进行分类. Heinsohn D 等<sup>[16]</sup>提出低分辨率人脸图像的稀疏表示方法, 使用具有不同模糊度的词典识别人脸, 获得了对于低质量图像更健壮的描述算法. 尽管一些人脸识别算法能有效地处理受控环境和一些无约束条件下的对象, 但在低质量人脸图像识别中还不够完美<sup>[17]</sup>.

迹变换<sup>[18]</sup>是一种优秀的图像不变纹理特征提取方法, 对各种不同的情景及复杂环境下的图像均有不俗的

描述性能, 在图像处理等领域有广泛应用, 如 Zhan S 等人<sup>[19]</sup>将 2DNP 与迹变换结合用于人脸识别, 迹变换也可用于地震监测<sup>[20]</sup>等, 也有研究人员对迹变换特征进行分析, 提出提升迹变换性能的诸多方法<sup>[21-23]</sup>, 迹变换的研究工作虽然在正常的图像纹理识别及应用方面均取得了令人瞩目的成果, 但缺乏在模糊人脸图像识别上的研究.

为了改善模糊人脸图像的识别性能, 利用不变特征对各种特殊场景和复杂环境的鲁棒描述能力, 本文基于迹变换及通信编码技术, 在旋转迹线上采样进行增量调制编码, 提出了 2 种具有全局有序结构特性的图像特征提取方法, 对应获得 2 种图像全局特征描述子, 一种是旋转增量调制特征描述子, 另一种是旋转分块增量调制特征描述子. 在一些公开人脸数据集中的测试表明, 该方法对实际场景中模糊的图像识别具有更加优异的表现.

## 2 迹变换及其纹理特征

迹变换 (Trace Transformation, TT) 由 Kadyrov A 和 Petrou M 共同提出, 是 Radon 变换的泛化, 在图像不变特征领域有十分重要的理论地位, 是一种通过对图像进行重建和泛函作用提取图像不变特征的方法. 图 1 为迹变换的参数定义, 迹线  $t$  的位置由参数  $\phi$  和  $\rho$  给出,  $\phi$  为迹线  $t$  的法线与水平轴的夹角,  $\rho$  为迹线  $t$  与中心点  $O$  的垂直距离, 每组  $(\phi, \rho)$  确定一条迹线  $t$ .




图1 迹变换参数定义

迹变换通过多种泛函组合对图像进行特征提取, 由于泛函的种类多样, 不同泛函及其不同组合得到的特征能反映图像的不同特性, 如果使用不变泛函或敏感泛函, 则能得到具有平移、旋转及缩放不变的特征, 因此迹变换是一种具有较强泛化能力和较高鉴别性能的不不变纹理分析方法.

图 2 是对一张人脸图像采用迹变换纹理分析方法提取三重特征过程示意图. 首先迹变换沿着穿过图像不同位置各个方向上的迹线计算泛函的值, 该泛函称为迹泛函, 记作  $T$ ,  $T$  作用在图像的所有迹线上消除了  $t$ ,

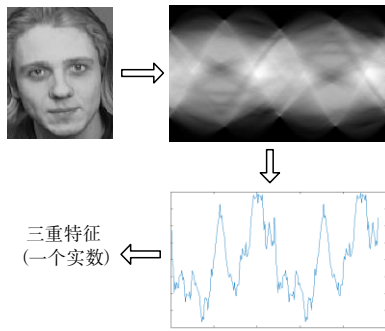


图2 构造迹变换纹理特征过程

得到仅与  $\phi$  和  $\rho$  有关的迹变换结果,迹变换结果是一个矩阵,称为迹矩阵;接着按列对迹矩阵作用泛函消除参数  $\rho$ ,此泛函称为直径泛函,记为  $P$ ,此时得到仅与  $\phi$  有关的一维向量,称为直径向量;最后在直径向量上作用圆周泛函  $\Phi$ ,消除参数  $\phi$ ,得到一个实数,即图像的一个迹变换纹理特征。

### 3 旋转增量调制特征

#### 3.1 增量调制原理

增量调制是通信编码技术中用来把模拟语音信号数字化的一种技术,如图3所示,对模拟信号的抽样间隔为  $T_s$ ,若当前抽样值大于前一抽样值,则当前编码为1,反之则编码为0。




图3 模拟语音信号数字化中的增量调制技术

在通信领域,增量调制编码对低质量音频信息,比如含噪音的或是不够清晰的音频信息等有很好的描述性能<sup>[24]</sup>。考虑到迹线上的像素灰度信息变化类似于声音的波形,本文借鉴通信编码技术,对一行像素也采用增量调制编码来构建迹线特征,如图4所示。相对应地,对迹线的增量调制编码对于低质量图像的描述也是有益的。

#### 3.2 旋转增量调制特征提取算法

本节利用旋转迹线采样思路,结合增量调制编码技术,提出了一种旋转增量调制特征提取方法(Rotational Delta Modulation, RDM)。如图5所示,在输入图像的每一条垂线(迹线)上按照从上下的顺序等间隔选取9个采样点,记作  $c_1, c_2, \dots, c_9$ ,并对其采用增量调制原理编码,如式(1)所示:




图4 图像中一行像素采用增量调制编码的思路

$$z_x = \begin{cases} 1, & c_{x+1} \text{ 且 } x \in \{1, 2, \dots, 8\} \\ 0, & \text{others} \end{cases} \quad (1)$$

按采样顺序对选取的9个像素点中依次相邻的两个像素点进行比较,如果后一个点的像素值大于前一个点的像素值,则编码为“1”,否则编码为“0”,这样选取的9个点经过依次两两相比,得到一个8位的二进制值,即为该条迹线的特征值,依次对所有不同步长  $\rho$  和不同角度  $\phi$  的迹线进行增量调制编码就能得到一个二维的特征迹矩阵。

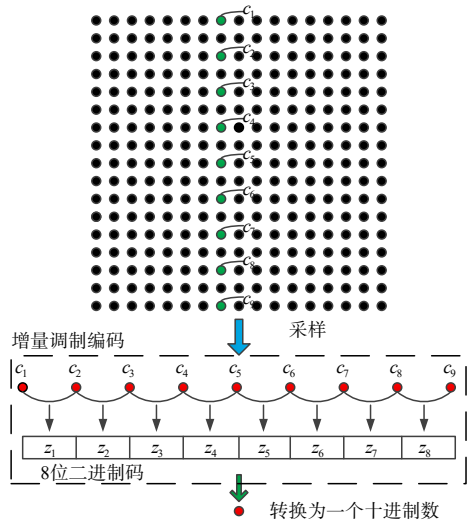


图5 采用增量调制编码获得迹线特征

#### 3.3 旋转分块增量调制特征提取算法

上一节的RDM算法对迹线采用了间隔采样的方式,忽略了对像素邻域信息的表达,为了能获得对图像信息更全面的特征表达,本节利用邻域块编码的方式来描述迹线上的采样点信息,其他和RDM算法相同,提出了旋转增量调制分块特征提取算法(Rotational Block-Delta Modulation, RBDM)。

不同于3.2小节, RBDM需同时考虑各采样点与其8邻域内各点像素值的关系,在采样点的8邻域块内用增量调制编码代替原来的采样点灰度信息,邻域块的采样点选取与编码方法如图6所示。以某一采样点  $x_3$  为例,假设

其8邻域内像素点为 $c_1 \sim c_8$ ,相较于3.2小节, $c_1 \sim c_7$ 像素点值比较方式如式(2)所示,剩余的 $c_8$ 与 $x_3$ 进行比较,结果为 $z_8$ ,最终可得到8位二进制码 $z_1, \dots, z_8$ ,将其转换为对应的

十进制数 $d_3$ 作为采样点 $x_3$ 的编码值,同理求出其他采样点对应的特征值分别为 $d_1, \dots, d_9$ ,此时将特征值 $d_1 \sim d_9$ 采用式(3)的方式两两进行比较.

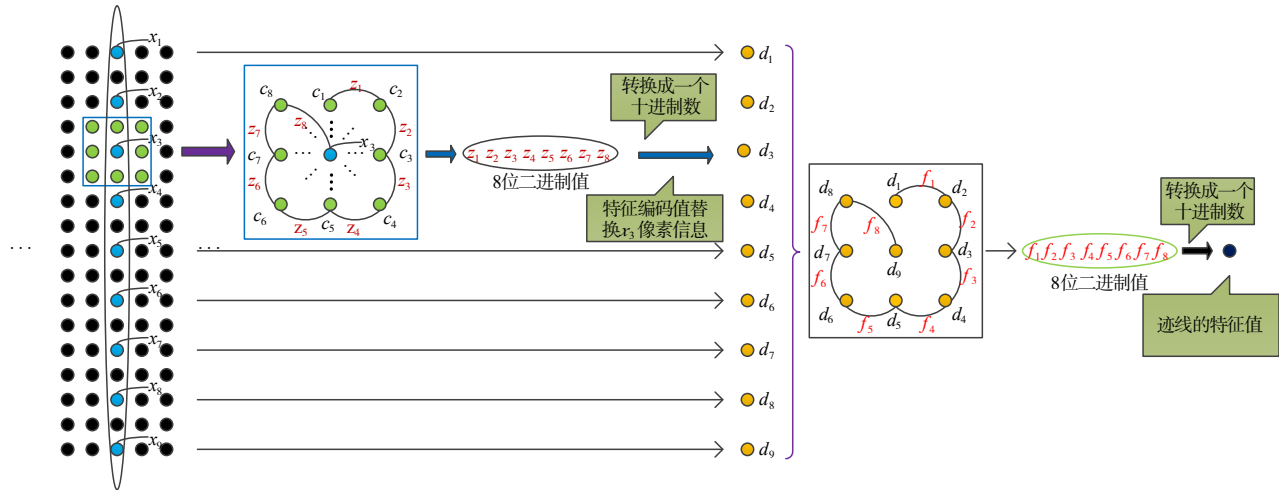


图6 采样点选择图及其邻域像素点

$$z_x = \begin{cases} 1, c_{x+1} > c_x \text{ 且 } x \in \{1, 2, \dots, 7\} \\ 0, \text{others} \end{cases} \quad (2)$$

$$f_x = \begin{cases} 1, d_{x+1} > d_x \text{ 且 } x \in \{1, 2, \dots, 8\} \\ 0, \text{others} \end{cases} \quad (3)$$

由上述公式可得8位二进制码 $f_1, \dots, f_8$ ,同样求其对应的十进制数,将该十进制数值作为从此列迹线提取到的特征值.后面的步骤与RDM算法相同,同样可以得到一个二维的特征迹矩阵.

#### 4 模糊人脸图像识别

通过以上小节分析,本文提出的基于迹变换理论及通信编码技术的旋转增量调制特征提取算法(包括RDM和RBDM)描述如算法1.

基于上述算法并结合图像预处理等一系列相关操

##### 算法1 旋转(分块)增量调制特征提取算法描述

```

输入: original image,  $\Delta\phi$ 
输出: Characteristics of figure
BEGIN
    读取原图像 image, 灰度化;
    将 image 扩充至正方形图像, 得到 pad_image; angle_index=0;
    FOR angle from 0 to 359 step  $\Delta\phi$ 
        angle_index=angle_index+1;
        将 pad_image 旋转 angle 角度, 得到 rotate_image;
        选取采样点;
        [feature] = RDM/RBDM(rotate_image);
    END
    
```

作,确定本文的模糊人脸图像识别算法流程如图7所示.首先输入一张图片,然后对图像进行旋转以提取图像多角度特征,在这个过程中,为了保证图像信息完整性,对旋转后的图片进行扩充,扩充部分的像素值为‘0’,接着对旋转后图像的每一列都提取一个旋转增量调制特征值,则每一张旋转角度图片会得到一个一维行向量,所有旋转角度图片的特征向量组合成一个特征矩阵,对该特征矩阵按行统计计算直方图并归一化,将所有行的直方图链接成一个一维列向量,将其输入到支持向量机中进行训练并识别.

##### 4.1 图像预处理

为了减少后续处理的计算量,首先将输入图像进行灰度化处理.同时,为了提高对迹线采样的精度及利于算法实现,对不同角度迹线的选取通过图像旋转来实现.如图8所示,预处理后的灰色区域为原始图像区域.

由于图像旋转会导致部分边角图像信息丢失,为了使不同旋转角度的图像在旋转后仍保留住所有原始图像信息,遂对原始图像扩充成以原对角线为边长的一个正方形,扩充部分的像素值为0,扩充后的整体区域为本文提取特征所用的图像.

##### 4.2 直方图归一化

对旋转增量调制特征提取方法提取到的特征统计其直方图并归一化,因为在提取旋转增量调制特征过程中,图像以等间隔角度旋转 $360/\Delta\phi$ 次,本文所有实验 $\Delta\phi$ 取值为1.5,每个旋转角度的图片在特征提取后得到一个一维行向量,对该行向量统计直方图,即其中每个

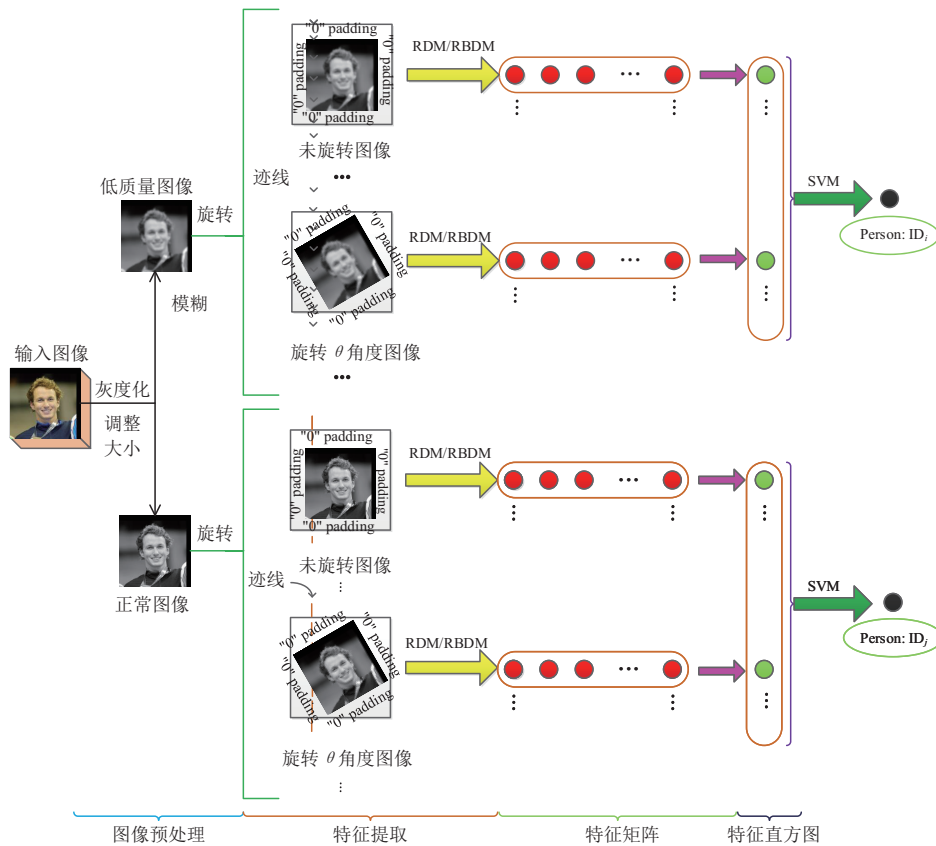


图7 基于迹变换和旋转增量调制编码特征的模糊人脸识别算法流程图

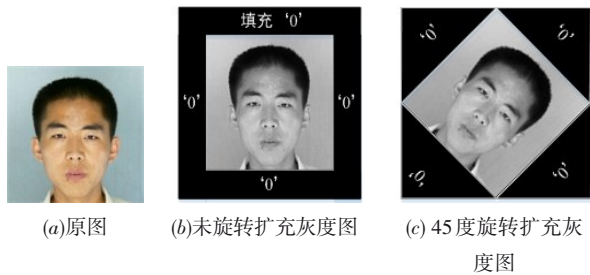


图8 图像预处理

数字(十进制数特征值)出现的频率,灰度级为 256,然后对该直方图进行归一化处理.公式如下:

$$\begin{cases} p_i = \frac{n_i}{N}, i = \{1, 2, \dots, k-1\} \\ \sum p_i = 1 \end{cases} \quad (4)$$

其中  $n_i$  表示图像  $i$  的像素个数,  $p_i$  表示像素的灰度数,  $N$  表示图像的全部像素数.

最后将得到的所有旋转角度图片的统计直方图链接成一个行向量,也就是整幅图的旋转增量调制特征.然后将此特征向量作为样本输入到支持向量机中进行训练识别.

### 4.3 特征提取优化与多特征融合

为了更加完整地表达图像的纹理信息,提高人脸

识别效率,同时增强上文所提算法的泛化能力,本文分别从像素点采样与编码方式、数据量调整、特征联合等方面对整个人脸识别方案进行进一步优化.

#### 4.3.1 迹线上进行交叉多点采样

在 3.2 节、3.3 节中我们采取的方法是每条迹线上等间隔采样 9 个像素点,然后使用增量调制编码技术得到一个 8 位的二进制码,即在图像每条迹线上提取一个特征值,用这个特征值来描述迹线的纹理信息.显然仅用 9 个采样点描述迹线纹理是远远不够的,为了更丰富迹线的特征信息,我们对采样方式进一步优化,如图 9 所示,在每条迹线上等间隔交叉选取 18 个采样点,然后采用交叉编码方式获取迹线特征,即对采样点从上往下依次编号为  $x_1, x_2, \dots, x_{18}$ , 然后对选取的 18 个像素点中采样点  $x_1, x_3, x_5, x_7, x_9, x_{11}, x_{13}, x_{15}, x_{17}$  采用前文所述增量调制技术进行编码组成一个 8 位的二进制码,剩下的 9 个采样点  $x_2, x_4, x_6, x_8, x_{10}, x_{12}, x_{14}, x_{16}, x_{18}$  作为一组像素点,也通过增量调制技术进行编码组成一个 8 位的二进制码,则每条迹线上能够获得 2 个不同的增量调制特征,从而更全面地描述迹线的纹理及结构信息,丰富了迹线的纹理特征信息.

当然,此优化方案可以不局限于在每条迹线上提取 2 个特征值,按照交叉编码的思路,也可以扩展到每

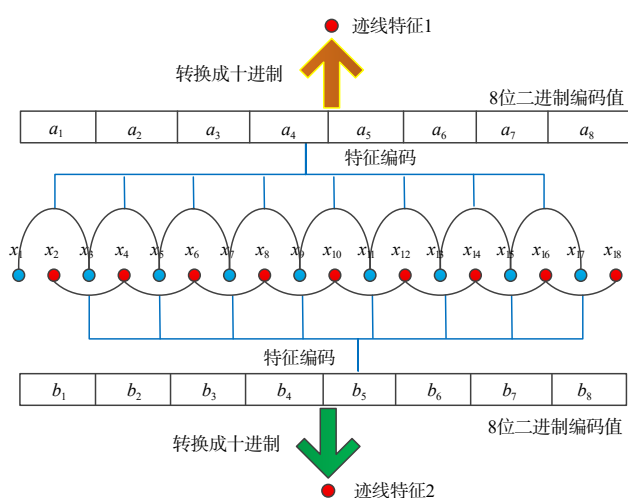


图9 增量调制交叉编码

条迹线上提取更多个特征值。与此同时,在此过程中同样引入了图像旋转的思想,最终由于图像旋转且每条垂直直线提取两个特征值来描述直线纹理信息,所以一张图片最后获得的特征是一个三维的形式,对此需要将其转化为二维矩阵的形式以方便后续的直方图归一化操作。

#### 4.3.2 在统计直方图的过程中降灰度级

在前面的方法中做统计直方图归一化时,统计的灰度级为256,这样得到的数据量较大,影响时效,其中的冗余信息也会影响到最终的识别效果。为此,这里做出的调整是在统计直方图过程中降低灰度级,分别将降为128、64、32,这样不仅减少了数据量,使得分类识别的速度得到了提升,也能适当剔除对分类识别产生不利影响的干扰数据,对最终图像的分类识别会是更有意义的。

#### 4.3.3 旋转增量调制特征和迹变换特征融合

旋转增量调制特征是按照迹线上像素的顺序进行依次编码提取出来的,特征与特征之间是按照既定的顺序进行排列的,因此旋转增量调制特征是一种对图像纹理全局有序的表达。迹变换特征通过对迹线作用不同的泛函组合,以此来提取图像的三重纹理特征,因此迹变换提取到的特征是无序的,只是不同特征值的一个排列组合。图10给出了一张人脸图像的迹变换结果与旋转增量调制编码技术得到的结果对比。

迹变换特征是对图像的一种无序统计描述,旋转增量调制特征是对图像的一种全局有序结构描述,两者是对图像不同角度的表达,是两种能够相互补充的图像描述信息。因此,本节将旋转增量调制特征和迹变换特征融合,从多角度描述图像信息,以提升图像的识别效果。

由于RDM和RBDM方法本身也是通过迹线采样然后进行特征编码得到迹线特征,并通过迹线全方位扫

描图像,获得所有图像特征。所以旋转增量调制特征RDM/RBDM是迹变换和增量调制编码方法结合得到的,有别于迹变换特征的图像描述,为增强图像特征的多样性,将TT特征和RDM/RBDM特征联合后利用主成分分析方法,去除不利特征和冗余特征,从而得到两者的融合特征。




图10 旋转增量调制编码结果与迹变换结果对比

## 5 实验与结果分析

本文的实验环境是Ubuntu 16.04 64位操作系统,Intel(R) Core(TM) i7-7700HQ CPU, 32GB内存, Nvidia GTX1080 GPU。由于各人脸库图片大小都不同,在本文实验过程中,对于较大图像reshape至100×100的大小,对于本身图像较小的AR数据集则保持不变,以方便实验进行。本文利用支持向量机对旋转局部梯度模式特征进行分类识别,为了更好地进行效果对比,本文采用C-SVC型支持向量机,linear核,gamma值为1,其他参数默认。

### 5.1 实验数据库及实验设计

鉴于增量调制编码对不清晰声波信息的有效表达,本文实验着重验证将所提方法在模糊人脸图像上的描述性能。实验使用了3个人脸数据库,分别是东方人脸数据库(Oriental Facial Database, OFD)、AR人脸库及CASIA-Webface<sup>[25]</sup>人脸数据集。OFD数据集包含1247位志愿者的33669幅人脸图像,每位志愿者有27张样本图像,包含19张不同拍摄角度和8张不同光照变化的图像。AR人脸库包含不同性别对象的不同视角图像,每个对象都有不同面部表情、不同照明条件及不同遮挡(围巾、眼镜等)的图像。CASIA-Webface是数据量较大的一个主流公开人脸数据集,包含10,575人共494,414张人脸图像,所有图像均从互联网收集而来,因而该数据集中的人脸图像来自各种不同场景。三个人脸数据集的部分示例如图11所示,从图中可以看出,实验选用的3个数据集存在光照及旋转变化、拍摄视点和焦距变化、表情变化、不同遮挡、不同种族、不同性别等各种复杂情形及场景,有利于全面测试算法的性能。

实验使用4.3节中融合方法得到迹变换特征,泛函组合参照文献<sup>[18,21,26]</sup>,选择了利于比对,且能有效描述

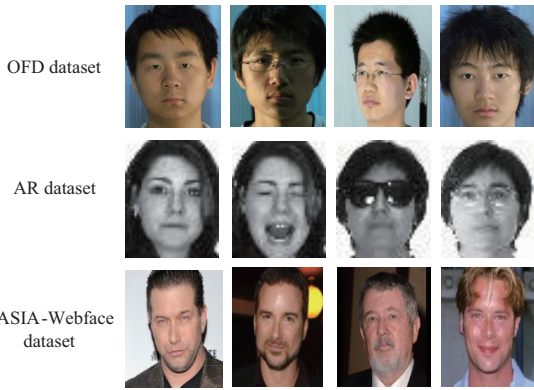


图 11 实验用人脸数据集示例

图像纹理和边缘信息的泛函,包括 8 个迹泛函  $T$ 、3 个直径泛函  $P$  和 7 个圆周泛函  $\Phi$ ,见表 1~3. 其中  $r_1 = r - m_2$ ,

$$r_2 = r - m_2, \quad m_1 = \text{median} \left( \left\{ r_k \right\}_k, \left\{ \left| \zeta(r_k) \right| \right\}_k \right), \quad m_2 =$$

$$\text{median} \left( \left\{ r_k \right\}_k, \left\{ \left| \zeta(r_k) \right|^{1/2} \right\}_k \right), r_k \text{ 对应于迹线上的采样点,}$$

$\Phi_5$  中的参数  $q$  和  $r$  值可取三组不同数值,分别为  $(q = 0.5, r = 1)$ 、 $(q = 0.5, r = 2)$  和  $(q = 0.25, r = 4)$ . 三重泛函作用后得到  $8 \times 3 \times 7 = 168$  维的迹变换特征. 迹变换的其他参数设置为角度  $\phi$  的增量取 1.5 度,取值范围  $[0, 360)$ ,  $\rho$  的最大值为图像对角线长度,最小值为 0.

表 1 实验使用的  $T$  泛函

序号	$T$ 泛函
$T_1$	$\int \zeta(r) dr$
$T_2$	$\int_{R_1} r \zeta(r) dr$
$T_3$	$\int_{R_1} r^2 \zeta(r) dr$
$T_4$	$\left  \int_{R_1} e^{i3 \ln r_1} \zeta(r_1) dr_1 \right $
$T_5$	$\left  \int_{R_1} e^{i4 \ln r_1} r_1^{0.5} \zeta(r_1) dr_1 \right $
$T_6$	$\left  \int_{R_1} e^{i5 \ln r_1} r_1 \zeta(r_1) dr_1 \right $
$T_7$	$\text{median}_{r_k > 0} \left\{ \left  \zeta(r_1) \right , \left  \zeta(r_1) \right ^{1/2} \right\}$
$T_8$	$\text{median}_{r_k > 0} \left\{ \left  r_2 \zeta(r_2) \right , \left  \zeta(r_2) \right ^{1/2} \right\}$

在实验过程中,由于本文方法在编码过程是按照从上往下的顺序进行的,所以提取到的特征之间的信息也是有序排列的,同时其还具有全局结构性的特点. 在 OFD 东方人脸库 1247 类人、CASIA-Webface 和 AR 数据集上,每类随机选取其中 80% 图像组成训练集,剩下图像作为测试集,每种特征提取算法各测试 100 次求出

表 2 实验使用的  $P$  泛函

序号	$P$ 泛函
$P_1$	$\int  f(\rho)'  d\rho$
$P_2$	$\text{median} \left( \left\{ f(\rho_k) \right\}_k, \left\{  f(\rho_k)  \right\}_k \right)$
$P_3$	$\int  F\{f(\rho)\}(\omega) ^4 d\omega$

表 3 实验使用的圆周泛函  $\Phi$

序号	$\Phi$ 泛函
$\Phi_1$	$\int \zeta(t) dt$
$\Phi_2$	$\int  \zeta(t)'  dt$
$\Phi_3$	$\max(\zeta(t))$
$\Phi_4$	$\max(\zeta(t)) - \min(\zeta(t))$
$\Phi_5$	$\left( \int  \zeta(t) ^q dt \right)^r$

平均识别率作为最终算法对应的识别率. 同时实验还比较了各算法在图像单列上提取多个特征值、不同直方图灰度级(如 4.3 小节所述,以单点和双点特征值为例)及将不同特征结合后表现出的差异.

### 5.2 正常人脸库下实验结果与分析

在正常人脸库下,使用本文方法在不同灰度级下进行人脸识别实验. 将一条迹线上采 9 个样本点的一个特征值的情况记为  $F(1)$ ,一条迹线上采 18 个样本点交叉编码得 2 个特征值的情况记为  $F(2)$ ,表 4 为在前述三个人脸数据库上的实验结果.

表 4 本文所提算法在正常数据集下的识别率(%)

算法	灰度级	CASIA-Webface		AR		OFD	
		$F(1)$	$F(2)$	$F(1)$	$F(2)$	$F(1)$	$F(2)$
RDM	256	96.07	97.33	97.47	98.08	98.13	98.33
	128	96.97	97.01	<b>98.33</b>	98.82	97.88	97.75
	64	96.13	97.33	97.75	98.58	97.25	97.75
	32	96.99	97.67	97.50	<b>99.16</b>	98.38	97.87
RBDM	256	96.44	97.67	96.67	97.10	96.62	97.25
	128	96.89	<b>98.71</b>	97.23	97.35	97.19	98.62
	64	95.33	98.33	98.05	98.17	<b>98.87</b>	98.50
	32	<b>97.56</b>	98.01	97.70	98.78	98.25	<b>98.75</b>

分析表 4 可知,直方图灰度级分级情况会因数据集不同而存在差异,但基本可以推测出直方图分级过少会导致特征大量丢失,进而影响识别效果. 总的来看,本文提出的方法在三种数据集上的表现均可以比肩目前主流的基于卷积神经网络的方法在此类数据集上的识别率,这充分表明本文特征提取方法在图像识别领域尤其是人脸识别方面具有可竞争的性能优势.

### 5.3 模糊人脸库下实验结果与分析

为验证所提算法在模糊人脸图像集上的鲁棒性,同时考虑到在实际应用中,摄像头采集到的图像分辨率不佳的情况居多,因此本文将以上三类数据集分别进行不同级别的高斯滤波模糊处理(视为模糊数据集)后再进行识别.

本节实验采用二维高斯分布对图像进行模糊处理,高斯模糊的方差 $\sigma$ 设置为4.0,对数据集中图像进

行三种不同级别的模糊,一级模糊采用 $7 \times 7$ 的高斯模板记为 $B(1)$ ,二级模糊采用 $9 \times 9$ 的高斯模板记为 $B(2)$ ,三级模糊采用 $11 \times 11$ 的高斯模板记为 $B(3)$ ;然而AR人脸库由于其图像本身分辨率与其他数据集相比较小,仅为 $40 \times 50$ ,故其一级模糊采用 $3 \times 3$ 的高斯模板,二级模糊采用 $5 \times 5$ 的高斯模板,三级模糊采用 $7 \times 7$ 的高斯模板,图12为原始人脸图像与不同模糊程度的图像对比.在模糊条件下,RDM和RBDM在三种数据集上的识别效果分别如表5~7所示.



图12 多级模糊效果

表5 本文所提算法在模糊数据集CASIA-Webface上的识别率(%)

算法	灰度级	CASIA-Webface					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RDM	256	94.87	92.40	91.40	97.89	96.50	96.67
	128	93.30	96.10	91.17	96.89	95.67	93.83
	64	95.67	<b>97.87</b>	91.83	98.22	97.83	94.17
	32	97.87	97.77	94.40	97.11	97.00	95.83
RBDM	256	96.98	94.37	94.62	97.94	96.62	96.75
	128	96.91	96.69	93.75	97.59	97.77	97.35
	64	97.86	96.42	95.14	98.25	<b>98.10</b>	97.13
	32	<b>97.95</b>	97.50	<b>95.33</b>	<b>98.47</b>	97.91	<b>97.78</b>

表6 本文所提算法在模糊数据集AR上的识别率(%)

算法	灰度级	AR					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RDM	256	97.88	96.70	97.33	97.51	97.97	95.51
	128	98.79	98.50	95.67	95.85	96.24	95.28
	64	98.25	98.54	95.33	97.62	96.72	94.99
	32	<b>98.96</b>	98.85	96.92	97.10	96.84	94.85
RBDM	256	96.67	94.47	92.56	97.63	96.89	96.01
	128	97.23	97.45	93.25	97.33	95.67	94.73
	64	98.45	97.16	<b>98.67</b>	98.17	<b>97.99</b>	95.58
	32	98.90	<b>98.96</b>	94.25	<b>98.78</b>	97.44	<b>96.67</b>

通过以上实验可对比得出,当图像每一列上只取一个特征值的识别率要略低于取两个特征值,原因在于采用交叉多点采样时能够更多保留原图像上各像素点间的关联信息及整体纹理特征;另一方面,当直方图灰度级下降时,不考虑个别特例数据,可以看出识别率

表7 本文所提算法在模糊数据集OFD上的识别率(%)

算法	灰度级	OFD					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RDM	256	96.75	96.63	97.25	97.34	96.08	97.26
	128	96.63	97.75	<b>97.63</b>	97.60	97.03	96.09
	64	98.05	97.13	97.00	98.28	98.02	96.03
	32	97.63	97.13	97.38	<b>98.75</b>	96.92	96.67
RBDM	256	96.56	95.62	95.12	97.87	96.25	97.71
	128	97.34	96.04	95.59	97.56	96.04	95.12
	64	98.03	97.77	94.14	97.85	<b>98.25</b>	96.75
	32	<b>98.65</b>	<b>98.72</b>	97.07	98.72	96.47	<b>97.92</b>

有小幅增加,这是由于在此过程中去除了大量干扰性的冗余数据,因此对最终识别结果影响不大.对于模糊图片,本文所提算法在三个数据集上的识别率并未由于图片模糊程度加深而出现大幅度波动,显示出算法较好的鲁棒性.

将RDM、RBDM及RDM/RBDM+TT的融合算法分别与LBP、迹变换、Sphereface<sup>[27]</sup>、VGG19<sup>[28]</sup>、ResNet101<sup>[29]</sup>、DenseNet<sup>[30]</sup>和SE-ResNeXt<sup>[31]</sup>、DPN<sup>[32]</sup>算法在以上三类模糊数据集上进行对比实验,图像同样有三级模糊、灰度级为256,对图像每列提取 $F(2)$ 特征值,实验结果如表8所示.显然LBP、迹变换与其它算法在识别率上有较明显差距,VGG19、Sphereface等算法表现优异,但随着模糊度的递增算法识别率出现轻微下降;此外,RBDM略优于RDM算法,RBDM算法考虑到了各采样像素点的分块信息,保留了原图像的局部特征,同时含有同一列上其他点的等间隔邻接特征,获得的图像信息更丰富.两种算法融合适

变换后,很明显融合算法在识别率上得到了进一步提高. 本文所提算法的整体表现要优于人脸识别的

一些经典算法和 VGG19、Sphereface 等算法,与实验预期相符.

表 8 模糊数据集下本文所提算法与其他算法的识别率(%)对比

算法	CASIA-Webface			AR			OFD		
	$B(1)$	$B(2)$	$B(3)$	$B(1)$	$B(2)$	$B(3)$	$B(1)$	$B(2)$	$B(3)$
LBP	91.46	90.10	86.89	92.05	88.33	86.26	90.10	86.89	83.21
Trace transform <sup>[18]</sup>	90.56	89.66	85.13	89.91	87.26	87.19	91.79	91.46	89.78
Sphereface <sup>[27]</sup>	95.35	96.22	95.23	97.43	98.35	96.63	96.68	96.35	95.39
VGG19 <sup>[28]</sup>	96.81	96.48	95.87	97.24	95.42	96.55	96.95	95.53	96.95
ResNet-101 <sup>[29]</sup>	97.82	97.56	97.32	97.85	96.59	95.79	97.56	97.54	96.54
DenseNet <sup>[30]</sup>	97.35	97.36	97.32	97.59	97.56	97.17	97.15	96.32	96.58
SE-ResNeXt <sup>[31]</sup>	97.65	98.01	97.65	98.02	97.35	97.86	97.98	98.01	97.65
DPN <sup>[32]</sup>	97.67	98.02	98.17	98.89	98.02	97.82	98.89	98.25	98.17
RDM(ours)	97.89	96.50	96.67	97.51	97.97	95.51	97.34	96.08	97.26
RDM+TT(ours)	<b>98.95</b>	97.33	96.47	<b>99.36</b>	98.62	98.37	99.01	<b>98.56</b>	98.09
RBDM(ours)	97.94	96.62	96.75	97.63	96.89	96.01	97.87	96.25	97.71
RBDM+TT(ours)	98.62	<b>98.12</b>	<b>98.40</b>	99.04	<b>98.87</b>	<b>98.59</b>	<b>99.29</b>	98.23	<b>98.25</b>

为了更直观显示本文算法的优越性,将各算法在 CASIA-Webface、AR、OFD 模糊数据集上的平均识别率对比情况展示为图 13,很明显地,在三种模糊级别上,本文提出的算法在人脸识别性能上要远远优于传统 LBP 与迹变换算法,对比 VGG19 算法及 Sphereface 算法的平均识别率分别提高 2.18% 和 2.20%,优势依然明显. 基于深度学习方法的识别率会随着数据集模糊级别变化而产生较大波动,算法稳定性不足,尤其是在图像本身尺寸较小的情况下. 而本文算法在模糊数据集上表现出了较强的鲁棒性与拓展性,这主要是由于算法能够存储整张图像在多角度多尺度以及多维度(可将图像旋转后的堆叠视为第三维特征)上的特征,是一种线性有序的图像特征描述方法. 而基于深度学习的方法是将图像的各类特征进行概率性地无序组合,然后对图像进行识别,但是模糊图像的细节信息会失真,使得深度神经网络相关方法的优势不能很好地发挥,而且此类方法没有表征出人脸图像的空间结构性特

征,也不具有图像特征旋转不变性等,因此本文算法的识别性能略占优势.

#### 5.4 不同受限环境下的模糊人脸实验结果与分析

本节实验样本选自 AR 数据集中不同光照和不同遮挡的人脸图像以及 OFD 数据集中不同拍摄角度的人脸图像. 其中,AR 数据集有 120 类 1680 张不同光照人脸数据集(14 张/类)和 120 类 1440 张 2 种不同遮挡类型人脸数据集(6 张/2 种/类);OFD 数据集有 1247 类 23693 张 19 种不同拍摄角度人脸数据集(19 张/类). 数据集中不同光照、不同拍摄角度和不同遮挡等场景所用部分人脸图像样例如图 14 所示. 其中 14(a)为 AR 数据集中不同光照的人脸图像示例;14(b)为 AR 数据集中不同遮挡的人脸图像示例,主要包括墨镜遮挡和围巾遮挡;14(c)为 OFD 数据集中不同拍摄角度的人脸图像示例.

为验证算法在不同光照、不同拍摄角度以及不同遮挡等场景下的模糊人脸的识别性能,本节中选择了性能较好的 RBDM+TT 算法进行对比实验. 首先采用如 5.3 节所述的模糊处理方式对人脸图像进行模糊处理,得到  $B(1)$ 、 $B(2)$  和  $B(3)$  三种模糊等级的人脸图像,其中 80% 作为训练集,20% 作为测试集,然后分别多次进行不同光照、不同遮挡场景和不同拍摄角度下的模糊人脸图像识别实验,以消除因训练样本和测试样本选择不同所带来的差异性. 实验结果如表 9~11 所示. 此外,在输入图像灰度级均为 256,迹线特征数为  $F(2)$  的同等实验条件下,我们将 RBDM+TT 算法、传统算法和一些先进的深度学习算法进行了对比,结果如表 12 所示.

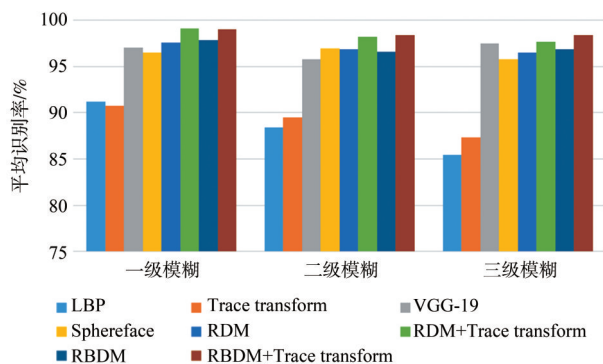


图 13 模糊人脸数据集上的平均识别率对比

AR 数据集中不同光照、不同遮挡的模糊人脸图

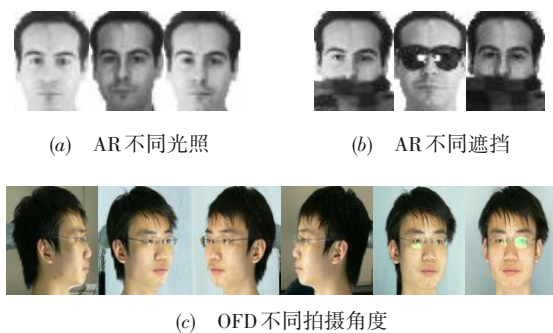


图 14 不同光照、不同遮挡和不同拍摄角度示例

表 9 RBDM+TT 在不同光照强度的 AR 上的识别率(%)

算法	灰度级	AR					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RBDM+TT	256	96.38	95.17	95.44	98.65	98.62	98.56
	128	96.21	95.69	95.35	98.24	98.45	96.45
	64	<b>98.46</b>	96.42	95.14	99.02	<b>99.05</b>	97.23
	32	97.03	<b>97.82</b>	<b>96.23</b>	<b>99.35</b>	99.02	<b>99.04</b>

像实验结果表明, RBDM+TT 对不同光照、不同遮挡下的模糊人脸图像具有较好的识别性能, 并没有出现因光照、遮挡、模糊等级变化导致识别性能较大波动的现象, 更进一步地说明本文算法在模糊场景下的

表 12 模糊数据集下 RBDM+TT 与其他算法的识别率(%)对比

算法	AR						OFD		
	不同光照			不同遮挡			不同拍摄角度		
	B(1)	B(2)	B(3)	B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
LBP	93.05	89.33	86.76	91.03	87.23	86.16	90.17	86.29	83.31
Trace transform <sup>[18]</sup>	89.71	88.26	87.39	88.91	87.16	87.01	90.29	91.56	90.18
VGG19 <sup>[28]</sup>	97.84	96.02	96.05	96.84	95.82	95.85	96.15	95.33	96.25
ResNet101 <sup>[29]</sup>	98.25	96.59	95.72	97.85	97.59	95.79	97.26	97.62	96.34
DenseNet <sup>[30]</sup>	97.23	96.16	97.27	97.49	96.58	96.17	96.15	95.32	95.38
SE-ResNeXt <sup>[31]</sup>	98.22	97.65	97.96	98.02	97.05	97.46	96.98	97.01	97.25
DPN <sup>[32]</sup>	98.29	98.02	97.32	98.29	97.02	97.22	97.89	<b>98.25</b>	98.15
RBDM+TT(ours)	<b>99.35</b>	<b>99.05</b>	<b>99.04</b>	<b>99.45</b>	<b>98.21</b>	<b>97.85</b>	<b>99.29</b>	98.23	<b>98.25</b>

OFD 数据集中的不同拍摄角度的模糊人脸图像的实验结果表明, 特征值个数为  $F(1)$ 、 $F(2)$  情况下, RBDM+TT 对不同拍摄角度下的模糊人脸图像具有较好的性能. RBDM+TT 在进行特征提取时, 通过迹线旋转对图像进行扫描, 且基于迹变换获得的特征具有 RST 不变性, 因而对不同角度的人脸图像具有较好的效果. 同时间隔采样描述了较大距离的像素对关系, 含有图像的空间信息, 更有利于提高模糊人脸图像的识别性能.

不同的光照、遮挡和拍摄角度下, 相较于 LBP 和迹变换算法, RBDM+TT 算法的模糊人脸识别性能有较大提升, 相较于基于深度学习的算法也具有一定的优势,

表 10 RBDM+TT 在不同遮挡类型的 AR 上的识别率(%)

算法	灰度级	AR					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RBDM+TT	256	97.67	96.37	96.32	<b>98.45</b>	97.62	96.53
	128	97.23	97.69	96.25	98.19	97.87	<b>97.85</b>
	64	<b>98.25</b>	97.07	<b>97.46</b>	97.96	98.05	97.03
	32	97.17	<b>97.89</b>	97.33	98.33	<b>98.21</b>	97.33

表 11 RBDM+TT 在不同拍摄角度的 OFD 上的识别率(%)

算法	灰度级	OFD					
		F(1)			F(2)		
		B(1)	B(2)	B(3)	B(1)	B(2)	B(3)
RBDM+TT	256	97.17	97.33	97.32	98.96	98.23	98.25
	128	97.19	96.39	97.17	97.32	97.25	98.24
	64	<b>98.22</b>	98.17	<b>97.65</b>	98.96	97.33	<b>98.36</b>
	32	97.96	<b>98.75</b>	96.96	<b>99.23</b>	<b>99.17</b>	98.07

鲁棒性. 此外, 本文算法在模糊场景下对不同光照的人脸图像的识别比遮挡类型的人脸图像的识别更具有优势, 这与模糊图像、遮挡图像本身特点一致, 遮挡造成了连续信息的改变, 因而即使间隔采样也无法得到未遮挡原图的有效特征信息, 影响了识别效果.

该算法在进行特征提取时, 采用了间隔采样的方式, 对于虽然是模糊图像, 但间隔采样点的相关属性相对于清晰图像依然有较好的保持, 因此这种采样方式更利于模糊人脸图像的识别, 而基于深度学习的算法, 由于模糊等不利因素的影响, 提取的特征有效性减弱, 导致识别能力出现一定程度的下降.

## 6 结论

本文提出了基于迹变换和增量调制编码的旋转增量调制特征提取方法及其变种, 能从多尺度多角度及多维度上提取出图像的纹理特征. 通过大量比对实验, 结

果显示本文提出的算法在几个主流人脸模糊数据集上均表现出更优的识别性能,在 OFD 模糊人脸库中识别率达到 99.29%, CASIA-Webface 模糊人脸图像库上达到 98.95%, AR 模糊人脸库上达到 99.36%, 均高出现有的先进方法和传统方法,说明本文算法获得的具有全局结构性、旋转不变性及多维度的有序特征能更好地描述模糊人脸图像,具有更高的精确性和更好的鲁棒性。在现实生活中的实时监控领域,摄像头所获取的视频流图像通常质量不佳,容易有分辨率低及模糊等现象,在此类应用场合中本文算法更具优势。因此,本文提出的旋转增量调制特征提取算法具有更好的鲁棒性与泛化能力,实际应用价值高,有益于后续的研究工作。

#### 参考文献

- [1] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules[A]. Ulrike von Luxburg. Proceedings of the 31st International Conference on Neural Information Processing Systems[C]. New York: Curran Associates Inc, 2017. 3859 – 3869.
- [2] Kim K I, Kwon Y. Single-image super-resolution using sparse regression and natural image prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(6): 1127 – 1133.
- [3] Li J D, Chen Z X, Liu C Y. Low-resolution face recognition of multi-scale blocking CS-LBP and weighted PCA[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2016, 30(8):1656005:1–1656005:13.
- [4] Xing X L, Wang K J. Couple manifold discriminant analysis with bipartite graph embedding for low – resolution face recognition[J]. Signal Processing, 2016, 125: 329 – 335.
- [5] Biswas S, Aggarwal G, Flynn P J, et al. Pose-robust recognition of low-resolution face images[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(12): 3037 – 3049.
- [6] 陈松灿,伍艳莲. 图像的模糊识别方法研究与实现[J]. 电子学报, 2000, 28(11): 50 – 54.  
Chen S C, Wu Y L. Studies and implementation of fuzzy recognition methods for image[J]. Acta Electronica Sinica, 2000, 28(11): 50 – 54. (in Chinese)
- [7] Zafeiriou S, Atkinson G A, Hansen M F, et al. Face recognition and verification using photometric stereo: The photo-face database and a comprehensive evaluation[J]. IEEE Transactions on Information Forensics and Security, 2013, 8(1): 121 – 135.
- [8] Masi I, Traaen A T, Hassner T, et al. Do we really need to collect millions of faces for effective face recognition?[A]. European Conference on Computer Vision[C]. Amsterdam: Springer, 2016. 579 – 596.
- [9] Taigman Y, Yang M, Ranzato M A, Wolf L. et al. Deep-Face: closing the gap to human-level performance in face verification[A]. 2014 IEEE Conference on Computer Vision and Pattern Recognition[C]. Columbus, OH, USA: IEEE Computer Society, 2014. 1701 – 1708.
- [10] Sun Y, Wang X G, Tang X O. Deep learning face representation from predicting 10,000 classes[A]. 2014 IEEE Conference on Computer Vision and Pattern Recognition [C]. Columbus, OH, USA: IEEE Computer Society, 2014. 1891 – 1898.
- [11] Liu J T, Deng Y F, Bai T, et al. Targeting ultimate accuracy: Face recognition via deep embedding [EB/OL]. <https://arxiv.org/ftp/arxiv/papers/1506/1506.07310.pdf>, 2019-11-08.
- [12] Sun Y, Wang X, Tang X. Deep learning face representation by joint identification-verification[A]. Advances in Neural Information Processing Systems[C]. Montreal, Quebec, Canada: the MIT Press, 2014. 1988 – 1996.
- [13] Sun Y, Wang X G, Tang X O. Deeply learned face representations are sparse, selective, and robust[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Boston, USA: IEEE Computer Society, 2015. 2892 – 2900.
- [14] Schroff F, Kalenichenko D, Philbin J. FaceNet: A unified embedding for face recognition and clustering [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Boston, USA: IEEE Computer Society, 2015. 815 – 823.
- [15] Liu W Y, Wen Y D, Yu Z D, et al. SpheroFace: Deep hypersphere embedding for face recognition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Hawaii, USA: IEEE Computer Society, 2017. 212 – 220.
- [16] Heinssohn D, Villalobos E, Prieto L, et al. Face recognition in low-quality images using adaptive sparse representations[J]. Image and Vision Computing, 2019, 85: 46 – 58.
- [17] Wang Z F, Miao Z J, Wu Q M J, et al. Low-resolution face recognition: a review[J]. The Visual Computer, 2014, 30(4): 359 – 386.
- [18] Kadyrov A, Petrou M. The trace transform and its applications[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(8): 811 – 828.
- [19] 施展, 杜明辉, 梁亚玲. 基于 2DNPP 和 Trace 变换的平面内旋转人脸识别[J]. 华南理工大学学报(自然科学版),

- 2012, 40(8): 46 – 50.
- Shi Z, Du M H, Liang Y L. In-plane rotary face recognition based on 2DNPP and trace transform[J]. Journal of South China University of Technology (Natural Science Edition), 2012, 40(8): 46 – 50. (in Chinese)
- [20] Wu N, Li Y, Tian Y N, et al. Trace-transform-based time-frequency filtering for seismic signal enhancement in Northeast China[J]. Comptes Rendus Geoscience, 2016, 348(5): 360 – 367.
- [21] 汪宇玲, 黎明. 圆迹变换及图像纹理分析[J]. 电子学报, 2018, 46(10): 2351 – 2358.  
Wang Y L, Li M. Circular trace transform and its applications to image texture analysis[J]. Acta Electronica Sinica, 2018, 46(10): 2351 – 2358. (in Chinese)
- [22] Wang Y L, Li M, Zhong G Y, et al. Circular trace transform and its PCA-based fusion features for image representation[J]. IET Image Processing, 2018, 12(10): 1797 – 1806.
- [23] Albukhanajer W A, Jin Y C, Briffa J A. Classifier ensembles for image identification using multi-objective Pareto features[J]. Neuro- computing, 2017, 238: 316 – 327.
- [24] Ordentlich O, Erez U. Performance analysis and optimal filter design for sigma-delta modulation via duality with DPCM[J]. IEEE Transactions on Information Theory, 2019, 65(2): 1153 – 1164.
- [25] Yi D, Lei Z, Liao S C, et al. Learning face representation from scratch[EB/OL]. <https://arxiv.org/pdf/1411.7923v1.pdf>, 2019-11-13.
- [26] Frías-Velázquez A, Ortiz C, Pižurica A, Philips W, et al. Object identification by using orthonormal circus functions from the trace transform[A]. IEEE International Conference on Image Processing[C]. FL, USA: IEEE. 2012. 2153 – 2156.
- [27] Liu W Y, Wen Y D, Yu Z D, et al. Spheroface: Deep hypersphere embedding for face recognition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Hawaii, USA: IEEE Computer Society, 2017. 212 – 220.
- [28] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[EB/OL]. <https://arxiv.org/pdf/1409.1556.pdf>, 2014
- [29] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Location: Las Vegas, NV, USA: IEEE Computer Society. 2016. 770 – 778.
- [30] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, HI, USA: IEEE Computer Society, 2017. 4700 – 4708.
- [31] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Salt Lake City, UT, USA: IEEE Computer Society, 2018. 7132 – 7141.
- [32] Chen Y P, Li J N, Xiao H X, et al. Dual path networks[A]. Ulrike von Luxburg. Proceedings of the 31st International Conference on Neural Information Processing Systems [C]. New York: Curran Associates Inc, 2010. 4470 – 4478.

### 作者简介



汪宇玲 女, 1976年生于江西抚州. 现为东华理工大学信息工程学院副教授, 硕士生导师, 主要研究方向为模式识别、计算机视觉.  
E-mail: ylwang@ecut.edu.cn



陈立 男, 1995年出生于河南开封. 现为东华理工大学信息工程学院研究生, 主要研究方向为图像处理与模式识别.  
E-mail: 873499635@qq.com



黎明(通信作者) 男, 1965年生于江西樟树. 现为南昌航空大学信息工程学院教授, 博士生导师, 主要研究方向为模式识别与智能计算.  
E-mail: liming@nchu.edu.cn



钟国韵 男, 1979年生于浙江浦江, 现为东华理工大学信息工程学院副教授, 硕士生导师, 主要研究方向为图像处理、视频处理和编码.  
E-mail: gyzhong55@163.com