

# 基于二进制标签松弛模型的遮挡人脸识别

韩肖,马祥

(长安大学信息工程学院,陕西西安 710064)

**摘要:**遮挡人脸识别是人脸识别系统面临的挑战之一。在自然场景下,人脸特征通常被口罩等物品遮挡,导致人脸特征不完整,从而无法正确提取人脸特征信息,严重影响最终的识别结果。针对有遮挡条件下人脸识别效果较差的问题,通过利用低秩技术和二进制标签松弛模型的优势,该文提出了一种新的基于二进制松弛标签的回归模型。该模型通过学习一个更松弛的标签矩阵来代替严格的0-1标签矩阵,从而扩大了样本之间的类间距离,同时对二进制松弛标签矩阵采用低秩约束,以提高样本的类内相似性。因此,该方法能够提取出更多具有判别性的特征,从而有利于遮挡条件下的人脸识别。此外,通过引入的正则化项,有效避免了该方法的过拟合问题。在Yale B、LFW和CMU PIE数据集上的实验结果表明,该方法不仅能在实验室环境下获得较高的识别率,在自然场景下仍然能取得较好的识别性能。

**关键词:**人脸识别;低秩技术;二进制松弛标签;特征提取;遮挡

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2022)01-0001-06

doi:10.3969/j.issn.1673-629X.2022.01.001

## Occlusion Face Recognition Based on Binary Label Relaxation

HAN Xiao, MA Xiang

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** Occlusion face recognition is one of the challenges faced by face recognition systems. In natural scenes, face features are usually occluded by masks and other items, resulting in incomplete face features, which cannot correctly extract facial feature information and seriously affect the final recognition results. Aiming at the problem of poor face recognition under occlusion, we propose a new regression model based on binary label relaxation by using the advantages of low-rank technology and binary label relaxation model. The model expands the inter-class distance between samples by learning a more relaxed label matrix instead of the strict 0-1 label matrix, and uses low-rank constraints on the binary relaxed label matrix to improve the intra-class similarity of the samples. Therefore, the proposed method can extract more discriminative features, which is beneficial to face recognition under occlusion. In addition, the introduced regularization term effectively avoids the over-fitting problem of the proposed method. The experimental results on the Yale B, LFW and CMU PIE datasets show that the proposed method can not only obtain a higher recognition rate in the laboratory environment, but also achieve better recognition performance in the natural scene.

**Key words:** face recognition; low rank technology; binary relaxation label; feature extraction; occlusion

## 0 引言

人脸识别<sup>[1-5]</sup>作为计算机视觉和生物统计学领域的热点研究方向,在生活中的应用越来越多,如人脸门禁考勤、社区出入管理、车站人脸闸机等。虽然人脸识别技术已经相当成熟,但是人脸识别性能常因各种干扰而受到不同程度的影响。自2019年底爆发新冠疫情以来,出门戴口罩成为人们日常生活中的一部分,戴口罩引起的遮挡让人脸识别变得困难。因此,研究如何提高遮挡情况下人脸识别方法的性能具有重要意义。

传统的人脸识别方法在实验室环境下可以获得很

高的识别率,如基于核范数的矩阵回归(norm based matrix regression, NMR)<sup>[6]</sup>和基于低秩表示的方法<sup>[7-9]</sup>,但当人脸图像存在遮挡时,其识别性能严重下降。近年来,针对人脸遮挡识别的研究越来越广泛,文献[10-11]针对有遮挡人脸识别方法进行了改进,虽然相比传统的特征提取方法提高了识别率,但在更复杂的场景下识别率仍然有待进一步提高。文献[12]提出了一种基于RPCA与低秩投影的有遮挡人脸识别方法,通过利用图像在低秩投影下产生的稀疏误差图像以及计算图像平滑度和边缘等鉴别信息,设计了基

于误差图像平滑度和边缘信息加权和的鉴别准则。该方法对人为连续遮挡的识别效果较好,但是对真实遮挡的识别效果较差,同时该方法的计算效率低。文献[13]基于普通的两阶段人脸识别方法,提出了一种基于稀疏表示的快速人脸识别方法。该方法能够提高第一阶段的识别效率,但是在处理聚合度较高的数据集时,识别率较差。文献[14]提出了一种扩展稀疏人脸识别方法,该方法能够将样本集非线性地映射到新的特征空间中,再根据每个样本对识别的贡献,给每个样本赋予一定的权重,同时利用类内变量矩阵共同表示测试样本。该方法在小样本情况下的识别率较好,但是在样本数较大的情况下,识别率还需要进一步提高。

在文献[15-16]研究的基础上,该文利用低秩技术和二进制标签松弛模型,提出了一种新的基于二进制松弛标签的回归模型。通过引入标签松弛模型获得一个有利于提取更多有用特征的变换矩阵,从而保证每类原子重构一类训练样本。

## 1 算法描述

### 1.1 算法改进方案

最小二乘回归(least squares regression, LSR)是图像分类领域中一种非常流行的方法。LSR 的主要思想是学习一个将原始训练样本映射到二进制标签空间的投影矩阵。LSR 的目标函数可以表示为:

$$\min_Z \|Z^T X - Y\|_F^2 + \lambda \|Z\|_F^2 \quad (1)$$

其中,  $X = [x_1, x_2, \dots, x_n] \in R^{d \times n}$  表示  $n$  个训练样本,  $d$  是样本的维度;  $X_i \in R^{d \times n_i}$  表示属于第  $i$  类的样本子集;  $Y = [y_1, y_2, \dots, y_n] \in R^{c \times n}$ , 其中  $c \geq 2$ ,  $Y$  表示  $X$  的二进制标签矩阵,  $y_i$  是  $Y$  的第  $i$  列;  $Z$  表示投影矩阵。

由于 LSR 方法在投影学习过程中没有考虑数据相关性和潜在的数据结构,这可能会使一些有用的结构信息丢失,从而导致过拟合。而且回归矩阵追求严格的 0-1 标签,不能反映每个样本的特征,特别是在多类情况下,很难实现准确分类。与 LSR 不同, DLSR (discriminative LSR)<sup>[17]</sup> 尝试学习松弛回归标签代替二进制标签  $Y$ , 利用  $\varepsilon$ -draggings 技术来扩大真类和假类之间的距离。其回归模型可以表述为:

$$\min_{Z, S} \|Z^T X - (Y + B \odot S)\|_F^2 + \lambda \|Z\|_F^2, \quad \text{s. t. } S \geq 0 \quad (2)$$

其中,  $\odot$  表示 Hadamard-product 算子;  $S \in R^{c \times n}$  是非负  $\varepsilon$ -draggings 标签松弛矩阵;  $B \in R^{c \times n}$  是一个常数矩阵, 定义为:

$$B_{ij} = \begin{cases} +1, & Y_{ij} = 1 \\ -1, & Y_{ij} = 0 \end{cases} \quad (3)$$

该方法将回归标签矩阵扩展为  $Y' = Y + B \odot S$ , 尽

管使用了松弛标签,但会引起过度拟合问题。为了解决这个问题,在 DLSR 模型的基础上,文献[15]提出了一个低秩判别最小二乘回归模型(low-rank DLSR, LRDLSR), 用公式表示为:

$$\min_{Z, D, S} \frac{1}{2} \|Z^T X - D\|_F^2 + \frac{\alpha}{2} \|D - (Y + B \odot S)\|_F^2 + \lambda_1 \sum_{i=1}^c \|D\|_* + \frac{\lambda_2}{2} \|D\|_F^2 + \frac{\lambda_3}{2} \|Z\|_F^2 \quad (4)$$

s. t.  $S \geq 0$

基于上述研究,发现将标签矩阵变得松弛更有利于分类,因此对上述方法进行如下改进:

$$\min_{Z, D, S} \frac{1}{2} \|Z^T X - D\|_F^2 + \frac{\alpha}{2} \|D - (((Y \odot T_{wo}) - O_{ne}) + ((Y \odot T_{wo}) - O_{ne}) \odot S)\|_F^2 + \lambda_1 \sum_{i=1}^c \|D\|_* + \frac{\lambda_2}{2} \|D\|_F^2 + \frac{\lambda_3}{2} \|Z\|_F^2 \quad (5)$$

s. t.  $S \geq 0$

其中,  $\alpha, \lambda_1, \lambda_2, \lambda_3$  是正则化参数;  $D$  表示松弛标签矩阵。第二项  $\|D - (((Y \odot T_{wo}) - O_{ne}) + ((Y \odot T_{wo}) - O_{ne}) \odot S)\|_F^2$  用来学习具有类间距离的松弛回归标

签。利用第三项  $\sum_{i=1}^c \|D_i\|_*$  学习相似的类内回归标签,对标签松弛矩阵采用低秩约束,可以提高类内相似性。利用第四项避免  $D$  的过拟合问题。与  $\varepsilon$ -draggings 技术相结合,该方法可以保留标签的类内相似性和类间可分性,从而产生判别投影。利用  $\|D\|_F^2$  项限制松弛标签  $D$  的能量。因为无限制的时候松弛矩阵  $S$  可能非常波动和离散,从而在很大程度上利用最大的类边距,导致过拟合问题。

接下来,将详细阐述如何将严格的二进制标签矩阵松弛为松弛标签矩阵。从  $Y \in R^{c \times n}$  中可以看出,  $Y$  包含  $n$  个样本的标签,  $Y$  中的每一列代表一个样本的标签。 $Y$  中的每个标签都属于  $R^{c \times 1}$ 。目的是发现不同类别样本之间的标签矩阵。为了便于理解,假设  $Y$  的第一列、第二列和第三列分别表示 tr1、tr2、tr3 的标签, tr1、tr2、tr3 分别属于第一类、第二类和第三类的训练样本。因此,二进制标签矩阵可以定义为:

$$Y = \begin{bmatrix} 1 & 0 & 0 & \dots \\ 0 & 1 & 0 & \dots \\ 0 & 0 & 1 & \dots \\ 0 & 0 & 0 & \dots \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots \end{bmatrix}_{c \times n} \quad (6)$$

显然,当不同类别的任意两个样本投影到标签空间时,它们之间均为  $\sqrt{2}$ , 例如 tr1 和 tr3 之间的距离为  $\sqrt{(1-0)^2 + (0-0)^2 + (0-1)^2 + \dots + (0-0)^2} =$

$\sqrt{2}$ 。这种严格的二进制标签不能反映每个样本的特征,例如 tr1 和 tr2 之间的标签距离等于 tr2 和 tr3 之间的标签距离,但是 tr1 和 tr2 之间的差异应该不同于 tr2 和 tr3 之间的差异。因此将回归标签矩阵扩展为  $\mathbf{Y}' = \mathbf{Y} + \mathbf{B} \odot \mathbf{S}$ 。

$$\mathbf{Y}' = \begin{bmatrix} 1 + s_{11} & -s_{12} & -s_{13} & \cdots \\ -s_{21} & 1 + s_{22} & -s_{23} & \cdots \\ -s_{31} & -s_{32} & 1 + s_{33} & \cdots \\ -s_{41} & -s_{42} & -s_{43} & \cdots \\ \vdots & \vdots & \vdots & \vdots \\ -s_{c1} & -s_{c2} & -s_{c3} & \cdots \end{bmatrix}_{c \times n} \quad (7)$$

此时 tr1 和 tr3 之间的距离为:

$$[(1 + s_{11} + s_{13})^2 + (-s_{21} + s_{23})^2 + (-s_{31} - 1 - s_{33})^2 + \cdots + (-s_{c1} + s_{c3})^2]^{\frac{1}{2}} \geq \sqrt{2}。$$

然而文中方法中  $\mathbf{Y}' = \tilde{\mathbf{Y}} + \tilde{\mathbf{Y}} \odot \mathbf{S}$ , 其中  $\tilde{\mathbf{Y}} = (((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S}$ 。因此,

$$\mathbf{Y}' = \begin{bmatrix} 1 + s_{11} & -1 - s_{12} & -1 - s_{13} & \cdots \\ -1 - s_{21} & 1 + s_{22} & -1 - s_{23} & \cdots \\ -1 - s_{31} & -1 - s_{32} & 1 + s_{33} & \cdots \\ -1 - s_{41} & -1 - s_{42} & -1 - s_{43} & \cdots \\ \vdots & \vdots & \vdots & \vdots \\ -1 - s_{c1} & -1 - s_{c2} & -1 - s_{c3} & \cdots \end{bmatrix}_{c \times n} \quad (8)$$

此时, tr1 和 tr2 之间的距离为:

$$d_{12} = \{[(1 + s_{11}) - (-1 - s_{12})]^2 + [(-1 - s_{21}) - (1 + s_{22})]^2 + \cdots + [(-1 - s_{c1}) - (-1 - s_{c2})]^2\}^{1/2} = [(2 + s_{11} + s_{12})^2 + (2 + s_{21} + s_{22})^2 + \cdots + (-s_{c1} + s_{c2})^2]^{1/2} \quad (9)$$

tr1 和 tr3 之间的距离为:

$$d_{13} = [(2 + s_{11} + s_{13})^2 + (-s_{21} + s_{23})^2 + (-2 - s_{31} - s_{33})^2 + \cdots + (-s_{c1} + s_{c3})^2]^{1/2} = [(2 + s_{11} + s_{13})^2 + (-s_{21} + s_{23})^2 + (2 + s_{31} + s_{33})^2 + \cdots + (-s_{c1} + s_{c3})^2]^{1/2} \quad (10)$$

很明显,在大多数情况下  $d_{12} \neq d_{13}$  且比式(7)中的差距更大,更有利于分类。

## 1.2 算法的优化过程

该文利用交替方向乘子法(ADMM)对算法进行优化。引入一个辅助变量  $\mathbf{P}$ , 使公式(5)变为:

$$\begin{aligned} \min_{\mathbf{Z}, \mathbf{D}, \mathbf{S}, \mathbf{P}} \quad & \frac{1}{2} \|\mathbf{Z}^T \mathbf{X} - \mathbf{D}\|_F^2 + \frac{\alpha}{2} \|\mathbf{D} - (((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S}\|_F^2 + \\ & \lambda_1 \sum_{i=1}^c \|\mathbf{P}_i\|_* + \frac{\lambda_2}{2} \|\mathbf{D}\|_F^2 + \frac{\lambda_3}{2} \|\mathbf{Z}\|_F^2 \\ \text{s. t.} \quad & \mathbf{D} = \mathbf{P}, \mathbf{S} \geq 0 \end{aligned} \quad (11)$$

进一步写出公式(11)的增广拉格朗日函数:

$$\begin{aligned} L(\mathbf{D}, \mathbf{Z}, \mathbf{S}, \mathbf{P}, \mathbf{Y}) = & \frac{1}{2} \|\mathbf{Z}^T \mathbf{X} - \mathbf{D}\|_F^2 + \frac{\alpha}{2} \|\mathbf{D} - (((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S}\|_F^2 + \\ & \lambda_1 \sum_{i=1}^c \|\mathbf{P}_i\|_* + \frac{\lambda_2}{2} \|\mathbf{D}\|_F^2 + \frac{\lambda_3}{2} \|\mathbf{Z}\|_F^2 + \frac{\mu}{2} \|\mathbf{D} - \mathbf{P} + \frac{\mathbf{Y}}{\mu}\|_F^2 \end{aligned} \quad (12)$$

其中,  $\mathbf{Y}$  是拉格朗日乘数,  $\mu > 0$  是惩罚因子, 接下来逐个更新变量。

(1)更新  $\mathbf{D}$ : 通过固定变量  $\mathbf{Z}, \mathbf{S}, \mathbf{P}$  和  $\mathbf{Y}$  可以得到如下最小化问题:

$$\begin{aligned} L(\mathbf{D}) = & \frac{1}{2} \|\mathbf{Z}^T \mathbf{X} - \mathbf{D}\|_F^2 + \frac{\alpha}{2} \|\mathbf{D} - (((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S}\|_F^2 + \\ & \frac{\lambda_2}{2} \|\mathbf{D}\|_F^2 + \frac{\mu}{2} \|\mathbf{D} - \mathbf{P} + \frac{\mathbf{Y}}{\mu}\|_F^2 \end{aligned} \quad (13)$$

解得:

$$\mathbf{D} = (1 + \alpha + \lambda_2 + \mu)^{-1} \times [\mathbf{Z}^T \mathbf{X} + \alpha(((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S} + \mu \mathbf{P} - \mathbf{Y}] \quad (14)$$

(2)更新  $\mathbf{P}$ : 给定变量  $\mathbf{Z}, \mathbf{S}, \mathbf{D}$  和  $\mathbf{Y}$  可以得到如下最小化问题:

$$L(\mathbf{P}) = \lambda_1 \sum_{i=1}^c \|\mathbf{P}_i\|_* + \frac{\mu}{2} \|\mathbf{D} - \mathbf{P} + \frac{\mathbf{Y}}{\mu}\|_F^2 \quad (15)$$

解得:

$$\mathbf{P}_i = \mathbf{I}_{\frac{\lambda_1}{\mu}}(\mathbf{D}_i + \frac{\mathbf{Y}_i}{\mu}) \quad (16)$$

其中,  $\mathbf{I}_{\frac{\lambda_1}{\mu}}(\Theta)$  是奇异值收缩算子。

(3)更新  $\mathbf{Z}$ : 给定变量  $\mathbf{P}, \mathbf{S}, \mathbf{D}$  和  $\mathbf{Y}$  可以得到如下最小化问题:

$$L(\mathbf{Z}) = \frac{1}{2} \|\mathbf{Z}^T \mathbf{X} - \mathbf{D}\|_F^2 + \frac{\lambda_3}{2} \|\mathbf{Z}\|_F^2 \quad (17)$$

解得:

$$\mathbf{Z} = (\mathbf{X} \mathbf{X}^T + \lambda_3 \mathbf{I}) \mathbf{X} \mathbf{D}^T \quad (18)$$

(4)更新  $\mathbf{S}$ : 更新  $\mathbf{Z}, \mathbf{P}, \mathbf{D}$  后, 可以通过以下方法更新非负松弛矩阵  $\mathbf{S}$ :

$$\begin{aligned} L(\mathbf{S}) = & \frac{\alpha}{2} \|\mathbf{D} - (((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}) + ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne})) \odot \mathbf{S}\|_F^2 \\ \text{令 } \mathbf{H}_1 = & ((\mathbf{Y} \odot \mathbf{T}_{wo}) - \mathbf{O}_{ne}), \mathbf{H}_2 = \mathbf{D} - \mathbf{H}_1, \text{ 此时} \end{aligned} \quad (19)$$

$$L(\mathbf{S}) = \frac{\alpha}{2} \|\mathbf{H}_2 - \mathbf{H}_1 \odot \mathbf{S}\|_F^2。$$

解得:

$$\mathbf{S} = \max(\mathbf{H}_1 \odot \mathbf{H}_2, 0) \quad (20)$$

### 1.3 分 类

一旦解出(5),就可以得到最优投影矩阵 $\mathbf{Z}$ 。利用 $\mathbf{Z}$ 可以获得训练样本的投影特征,即 $\mathbf{Z}^T\mathbf{X}$ 。假设 $\mathbf{y} \in R^d$ 为测试样本,则其投影特征为 $\mathbf{Z}^T\mathbf{y}$ 。该文采用 KNN 分类器实现分类。

## 2 实验与分析

在以下三个数据集上进行实验,这三个数据集中所有图像都预先调整到 $32 \times 32$ 。

(1)The Extended Yale B Dataset:扩展的 Yale B 数据集由 2 414 张人脸图像组成,这 2 414 张图像来自 38 个个体,其中每个个体有大约 59~64 张图像。随机选取每个个体的 10、15、20 和 25 张图像作为训练样本,剩余图像作为测试样本。

(2)The CMU PIE Dataset:本实验选择该数据集的一个子集,其中每个个体有 170 张图像。随机选取每个个体的 10、15、20 和 25 张图像作为训练样本,剩余图像作为测试样本。

(3)LFW Dataset:LFW 是自然场景下的数据集,本实验选择该数据集的一个子集,包含 62 个个体的 3 023 张图像,每个个体至少有 20 张图像。从每个个体中随机选择 7、8、9 和 10 张图像作为训练样本,其余图像作为测试样本。上述实验数据集的部分图像如图 1 所示。




图 1 实验数据集的部分图像

为了验证文中方法的识别性能,与一些现有方法进行对比。对比方法有 LRDLRS<sup>[15]</sup>、TSL\_LRSL<sup>[18]</sup>、RSLDA<sup>[19]</sup>、LRPP\_GRR<sup>[20]</sup>、EALPL<sup>[9]</sup>和 SALPL<sup>[9]</sup>。

### 2.1 无遮挡时的实验结果

无遮挡时的平均识别率如表 1 和表 2 所示,所有实验结果都是进行十次实验取平均值之后的结果。

由表 1 可知,与现有方法相比,文中方法能够取得较好的识别性能,这是因为文中方法能够提取更多的深层特征用于识别,从而提高识别率。由表 2 可知,文中方法在大多数情况下优于对比方法。特别的,与 EALPL<sup>[9]</sup>相比,文中方法的识别率提高了近 30%。并且随着训练样本数量的增加,表中所有方法的识别率都会增加。综上所述,无遮挡时文中方法具有较好的识别性能。

表 1 无遮挡时 Yale B 数据集的平均识别率 %

方法	不同训练样本数对应的平均识别率			
	10	15	20	25
LRDLRS <sup>[15]</sup>	90.06	93.94	95.86	97.05
TSL_LRSL <sup>[18]</sup>	89.01	93.50	95.38	96.37
RSLDA <sup>[19]</sup>	81.49	88.49	89.08	89.92
LRPP_GRR <sup>[20]</sup>	85.76	89.88	92.36	93.69
EALPL <sup>[9]</sup>	66.06	76.91	83.68	88.20
SALPL <sup>[9]</sup>	89.08	94.07	96.10	97.32
文中方法	90.37	94.64	96.69	97.55

表 2 无遮挡时 CMU PIE 数据集的平均识别率 %

方法	不同训练样本数对应的平均识别率			
	10	15	20	25
LRDLRS <sup>[15]</sup>	88.13	91.60	93.14	94.31
TSL_LRSL <sup>[18]</sup>	77.88	85.18	88.75	90.34
RSLDA <sup>[19]</sup>	69.77	73.08	73.95	74.46
LRPP_GRR <sup>[20]</sup>	68.46	76.44	82.09	84.39
EALPL <sup>[9]</sup>	50.73	61.51	68.85	74.11
SALPL <sup>[9]</sup>	86.52	91.24	93.43	94.44
文中方法	87.54	91.87	93.47	94.48

### 2.2 有遮挡时的实验结果

本小节在训练样本数为 25 时,给 Yale B 和 CMU PIE 数据集的测试集分别添加 10%、20%、30% 和 40% 的随机遮挡块。实验结果如表 3 和表 4 所示,所有实验结果都是进行十次实验取平均值之后的结果。并且本小节在 Yale B 和 CMU PIE 数据集上计算了不同方法的运行时间,评估了该方法的计算效率。所有方法都是使用 MatlabR2019b 在具有 i7-6700 八核 3.40 GHz CPU 的 PC 上实现的。

表 3 有遮挡时 Yale B 数据集的平均识别率(%)和平均运行时间(s)

方法	不同遮挡面积对应的平均识别率				运行时间
	10%	20%	30%	40%	
LRDLRS <sup>[15]</sup>	93.81	89.19	82.77	72.55	125
TSL_LRSL <sup>[18]</sup>	38.01	25.12	6.50	3.13	588
RSLDA <sup>[19]</sup>	82.19	72.10	58.23	41.46	253
LRPP_GRR <sup>[20]</sup>	76.16	52.03	36.90	26.58	440
EALPL <sup>[9]</sup>	74.41	59.28	45.43	31.55	819
SALPL <sup>[9]</sup>	92.48	84.19	73.07	58.93	692
文中方法	94.08	90.67	85.16	75.70	122

由表 3 可知,与现有方法相比,文中方法能够在最短的时间内取得最高的识别率。由表 4 可知,文中方法的识别性能在随机遮挡块大小为 10% 和 20% 时,略低于 SALPL<sup>[9]</sup>的方法,其他情况下均优于所采用的对比方法,但是文中方法所消耗的时间远远低于 SALPL<sup>[9]</sup>的方法。特别地,在添加随机遮挡块的情况



下,文中方法的识别性能远远高于 TSL\_LRSR<sup>[18]</sup> 的方法。综上所述,文中方法在添加随机遮挡块的情况下,仍然具有较好的识别性能。

表4 有遮挡时 CMU PIE 数据集的平均识别率(%) 和平均运行时间(s)

方法	不同遮挡面积对应的平均识别率				运行时间
	10%	20%	30%	40%	
LRDLSR <sup>[15]</sup>	70.13	52.16	39.90	27.26	245
TSL_LRSR <sup>[18]</sup>	45.75	29.83	4.97	2.70	5 366
RSLDA <sup>[19]</sup>	52.98	31.83	18.66	11.30	475
LRPP_GRR <sup>[20]</sup>	60.70	45.47	35.44	26.66	2 670
EALPL <sup>[9]</sup>	55.31	40.72	29.94	21.44	5 141
SALPL <sup>[9]</sup>	72.66	53.27	39.46	27.65	5 187
文中方法	71.74	52.53	41.50	29.69	269

### 2.3 自然场景下的实验结果

文中采用 LFW 人脸数据集验证所提出的方法在自然场景下的识别性能。实验结果如表5所示。由表5可以看出,在自然场景下,与现有方法相比,文中方法仍然具有较高的识别率。特别地,文中方法的识别率远远高于 LRPP\_GRR<sup>[20]</sup> 和 EALPL<sup>[9]</sup> 的识别率。

表5 LFW 数据集的平均识别率 %

方法	不同训练样本数对应的平均识别率			
	7	8	9	10
LRDLSR <sup>[15]</sup>	50.86	53.88	55.38	59.11
TSL_LRSR <sup>[18]</sup>	39.14	41.80	43.59	47.01
RSLDA <sup>[19]</sup>	28.32	30.14	30.71	30.57
LRPP_GRR <sup>[20]</sup>	9.46	10.23	10.37	11.13
EALPL <sup>[9]</sup>	13.67	13.43	4.08	15.52
SALPL <sup>[9]</sup>	39.69	42.81	46.45	48.29
文中方法	51.10	54.55	55.56	60.72


### 2.4 算法收敛性分析

本节验证了文中方法的收敛性。图2给出了文中方法的收敛性曲线。在三个不同的数据集中,目标函数的值随着迭代次数的增加而单调减小,证明了优化方法的有效性。


### 2.5 参数敏感性分析

目前,针对不同的数据集选择最优参数仍是一个尚未解决的问题。文中方法需要选择四个参数,即  $\alpha$ 、 $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$ 。其中  $\alpha$  和  $\lambda_1$  是平衡松弛标签学习项和类低秩标签项的权重,  $\lambda_2$  和  $\lambda_3$  用于避免学习标签矩阵  $D$  和投影矩阵  $Z$  的过拟合问题。为了考察参数的敏感性,首先将参数  $\lambda_1$  和  $\lambda_2$  固定在前一个网格研究阶段确定的最优值上( $\lambda_1 = 0.1$ ,  $\lambda_2 = 0.1$ ),重点观察参数  $\alpha$  和  $\lambda_3$  在  $\{0.0001, 0.001, 0.01, 0.1, 1\}$  范围内变化时识别性能的变化。因为  $\alpha$  对应于文中方法中最关键的一项,而在进行实验的过程中  $\lambda_3$  的变化对


实验结果的影响较大。在 Yale B 和 CMU PIE 数据集随机选择 25 个训练样本,在 LFW 数据集随机选择 10 个训练样本,图3给出了三个数据集上的参数敏感性分析效果图,可以看出选择合适的参数对实验结果有一定的影响。



(a) Yale B




(b) CMU PIE



(c) LFW

图2 目标函数收敛曲线



(a) Yale B

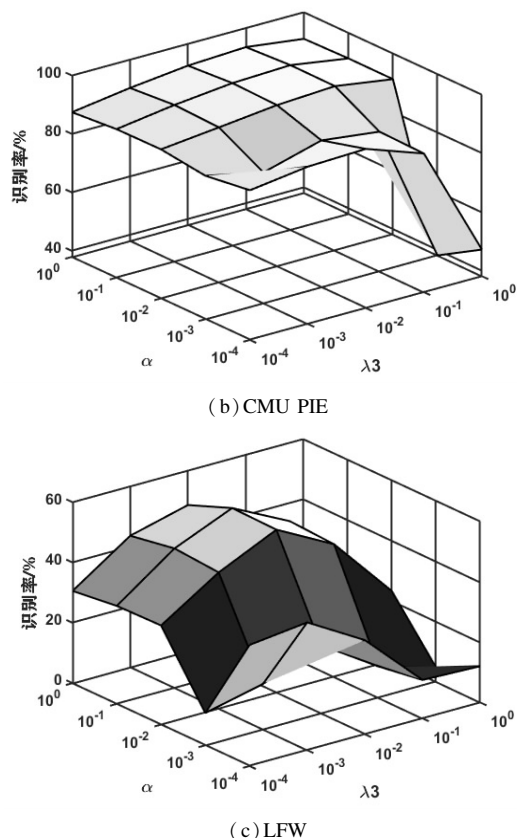


图 3 参数敏感性分析效果图

### 3 结束语

基于低秩技术和二进制标签松弛模型, 该文提出了一种新的基于二进制松弛标签的回归模型。实验结果表明, 该方法不仅对遮挡具有鲁棒性, 在自然场景下, 仍然能够取得较好的识别性能。

#### 参考文献:

- [1] DING C, TAO D. Trunk-branch ensemble convolutional neural networks for video-based face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 1002-1014.
- [2] NEVES J, PROENÇA H. A leopard cannot change its spots: improving face recognition using 3D-based caricatures[J]. IEEE Transactions on Information Forensics and Security, 2019, 14(1): 151-161.
- [3] GE S, ZHAO S, LI C, et al. Low-resolution face recognition in the wild via selective knowledge distillation[J]. IEEE Transactions on Image Processing, 2019, 28(4): 2051-2062.
- [4] GUO Y, JIAO L, WANG S, et al. Fuzzy sparse autoencoder framework for single image per person face recognition[J]. IEEE Transactions on Cybernetics, 2017, 48(8): 2402-2415.
- [5] SOHN K, LIU S, ZHONG G, et al. Unsupervised domain adaptation for face recognition in unlabeled videos[C]//2017 IEEE international conference on computer vision (ICCV). Venice, Italy: IEEE, 2017: 5917-5925.
- [6] YANG J, LUO L, QIAN J J, et al. Nuclear norm based matrix regression with applications to face recognition with occlusion and illumination changes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(1): 156-171.
- [7] WANG Z, RUAN Q, AN G, et al. A regularized low-rank representation model for facial expression recognition[C]//2016 IEEE 13th international conference on signal processing (ICSP). Chengdu: IEEE, 2016: 1072-1076.
- [8] WU F, JING X Y, YOU X. Multi-view low-rank dictionary learning for image classification[J]. Pattern Recognition, 2016, 50: 143-154.
- [9] FANG X Z, HAN N, WU J G. Approximate low-rank projection learning for feature extraction[J]. IEEE Transactions on Neural Networks & Learning Systems, 2018, 29(11): 5228-5241.
- [10] 张立亮, 王国中, 范涛, 等. 一种有遮挡人脸识别方法改进[J]. 电子测量技术, 2018, 41(22): 89-94.
- [11] 刘瑞钦. 一种基于 PCA 和 HOG 有遮挡的人脸识别方法[J]. 电脑知识与技术, 2019, 15(4): 171-173.
- [12] 曾璐, 鲁海荣, 罗璐, 等. 基于 RPCA 与低秩投影的有遮挡人脸识别[J]. 计算机仿真, 2015, 32(10): 420-425.
- [13] 刘伟, 葛洪伟. 一种基于稀疏表示的快速人脸识别方法[J]. 激光与光电子学进展, 2020, 57(18): 241-248.
- [14] 张泓, 范自柱, 王松, 等. 特征空间中的拓展稀疏人脸识别[J]. 重庆大学学报, 2020, 43(11): 21-28.
- [15] CHEN Z H, WU X J, KITTLER J. Low-rank discriminative least squares regression for image classification[J]. Signal Processing, 2020, 173: 107485.
- [16] LIAO M M, GU X D. Face recognition based on dictionary learning and subspace learning[J]. Digital Signal Processing, 2019, 90: 110-124.
- [17] XIANG S, NIE F, MENG G, et al. Discriminative least squares regression for multiclass classification and feature selection[J]. IEEE Transactions on Neural Networks & Learning Systems, 2012, 23(11): 1738-1754.
- [18] XU Y, FANG X, WU J, et al. Discriminative transfer subspace learning via low-rank and sparse representation[J]. IEEE Transactions on Image Processing, 2016, 25(2): 850-863.
- [19] WEN J, FANG X, CUI J, et al. Robust sparse linear discriminant analysis[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 29(2): 390-403.
- [20] WEN J, HAN N, FANG X, et al. Low-rank preserving projection via graph regularized reconstruction[J]. IEEE Transactions on Cybernetics, 2019, 49(4): 1279-1291.