

非凸混合范数误差编码人脸图像识别方法

郭俊博, 马祥

(长安大学信息工程学院, 陕西 西安 710064)

摘要: 针对人脸图像在复杂环境下存在噪声污染、光照变化和遮挡等情况, 提出一种新的人脸识别方法, 即基于非凸混合范数误差编码的人脸识别方法(NMN), 旨在统一基于向量和基于矩阵的回归方法于一个回归模型中, 以更好地应对多样化的识别挑战。在考虑重构图像的低秩性质的同时, 引入核范数约束捕捉图像的低秩特征。为缓解由异常值引起的偏差问题, 引入非凸函数提高模型的鲁棒性。为进一步提升性能, 充分考虑标签信息, 以更有效地区分不同类别之间的特征差异。在分类阶段, 综合考虑非连续误差和连续误差, 利用类重构误差来判别待识别图像。在 Extended Yale B、ORL 和 AR 数据集上进行了实验验证, 结果表明, 相较于其他对比方法, NMN 在遮挡人脸识别方面展现出更为卓越的性能。在 Extended Yale B 数据集上, 针对测试样本添加 40% 的“狒狒”图像遮挡块, 该方法的识别率达到 80.40%, 比其他对比方法至少高出 11.68 个百分点。

关键词: 人脸识别; 非凸函数; 核范数约束; 混合范数误差编码; 复杂环境

源代码链接: <https://github.com/Guounbo/NMN>

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0068913

Face Image Recognition Method Using Non-Convex Mixed Norm Error Coding

GUO Junbo, MA Xiang

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

【Abstract】 In response to the recognition challenges encountered by face images in complex environments with noise pollution, lighting variations, and occlusions, a face recognition method based on Non-convex Mixed-Norm error coding (NMN) is proposed. This method unifies the vector- and matrix-based regression approaches into a single-regression model. Recognizing the low-rank feature of the reconstructed images, nuclear norm constraints are applied to capture their intrinsic features. The introduction of non-convex functions mitigates the bias issues caused by outliers. To enhance the performance of the model, NMN considers label information and imposes constraints on interclass representations. Finally, in the classification phase, considering both noncontinuous and continuous errors, we utilized class reconstruction errors to discriminate against the to-be-recognized images. Experimental validation on the Extended Yale B, ORL, and AR datasets demonstrated that the proposed method exhibited superior recognition performance in the presence of occluded faces compared with the comparative methods. On the Extended Yale B dataset, the recognition rate of the NMN method achieved 80.40% when 40% of "baboon" image occlusion blocks were added to the test samples, surpassing other comparative methods by at least 11.68 percentage points.

【Key words】 face recognition; non-convex function; nuclear norm constraint; mixed norm error coding; complex environment

0 引言

人脸识别是计算机视觉和模式识别中的一项重要任务, 目前已有很多成功的方法被提出并得到广泛应用^[1-2]。WRIGHT 等^[3]提出了稀疏表示分类(SRC)算法, 该算法使用整个训练集作为字典, 并使用训练样本线性表示测试样本, 同时为了保证表示系数的稀疏性, 引入 l_1 范数来约束它们。很多研究者针对该理论框架做出了算法改进, 如协同表示分

类(CRC)^[4]、监督群稀疏编码(GSC)^[5]、判别多尺度稀疏编码(DMSC)^[6]、鲁棒稀疏编码(RSC)^[7]等。

上述回归方法都假设噪声是独立的, 采用了基于向量的误差模型。然而对于光照、口罩和墨镜等连续遮挡, 这种假设不成立。在连续遮挡的情况下, 误差是空间相关的, 并且包含丰富的结构信息。YANG 等^[8]提出了基于核范数的矩阵回归(NMR)方法, 使用核范数来近似求解矩阵的低秩问题, 该方法对围巾遮挡、眼镜遮挡等连续遮挡效果非常好。

收稿日期: 2023-11-27 修回日期: 2024-01-22

基金项目: 国家自然科学基金(61771075)。

通信作者 E-mail: 1925164174@qq.com

CHEN 等^[9]提出了稀疏正则化核范数(SR-NMR)算法,该算法对核范数框架表示施加 ℓ_1 范数约束,而不是 ℓ_2 范数约束,最后使用训练样本学习线性分类器实现高效分类。LI 等^[10]提出了基于增强核范数的矩阵回归(ENMR)模型。SU 等^[11]提出了双判别性低秩投影学习(DDLRL)算法,该算法使用 $\ell_{2,1}$ 范数作为正则化项保留子空间的判别信息。凸核函数在逼近秩函数的过程中会导致次优解^[12],鉴于此,XIE 等^[13]用非凸函数代替核范数来表征误差图像的低秩结构,提出了 2 种稳健的核规范模型:RMR 和 S-RMR。ZHANG 等^[14]提出了一种新的增强群稀疏正则化非凸回归(EGSNR)方法。ZHONG 等^[15]提出了基于加权非凸低秩与判别最小二乘回归(WNLRLSR)模型。ZHENG 等^[16]提出了一个加权混合范数回归(WMNR)模型,该模型结合了加权核范数和 ℓ_2 范数来处理图像损坏。

本文针对图像同时受到非连续像素噪声和连续结构噪声遮挡的情况,提出一种基于非凸混合范数误差编码的人脸识别方法(NMN)。该方法将基于向量的误差和基于矩阵的误差统一到一个损失函数中。将误差结构约束为低秩结构,同时注意到恢复出的“干净”图像也具有低秩结构,用非凸函数更好地逼近低秩结构。在分类阶段,根据获得的最优表示系数,利用各类重构误差得到测试样本最终所属

类别。最后,通过实验表明本文方法具有较高的准确率和较强的鲁棒性。

1 相关工作

1.1 基于核范数的矩阵回归

假设有 c 类样本, \mathbf{y} 表示一个测试样本, $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_c]$ 表示字典(一组基)。对于基于低秩表示的分类器和字典学习,表示模型可以转化为以下最小化问题:

$$\min_x \|\mathbf{y} - \mathbf{A}(\mathbf{x})\|_* + \frac{\lambda}{2} \|\mathbf{x}\|_2^2 \quad (1)$$

式中: λ 是一个正则化参数; $\|\cdot\|_*$ 表示用矩阵奇异值之和计算的核范数,也就是秩函数的凸近似; $\mathbf{A}(\mathbf{x}) = x_1 \mathbf{A}_1 + x_2 \mathbf{A}_2 + \dots + x_c \mathbf{A}_c$ 表示所有训练图像以矩阵形式表示的线性组合。由此,通过最小化表示误差的核范数,保证了低秩性。

1.2 稳健的核范数矩阵回归

稳健的核函数是非凸的,非凸函数作为秩函数的替代函数,能够取得比核函数更好的效果。受 RMR 模型启发,本文定义稳健的矩阵核范数为:

$$\|\mathbf{E}\|_{s,*} = \sum_{i=1}^v s_i g(\sigma_i) \quad (2)$$

式中: $\mathbf{s} = [s_1, s_2, \dots, s_v]^T$ 可以看作是 $g(\sigma_i)$ 的权重; $g(\cdot)$ 表示一个连续、非凸、非递减函数,可以更好地逼近秩函数。表 1 给出了几种常见的非凸函数。

表 1 常用的非凸函数和对应的次梯度

Table 1 Common non-convex functions and their corresponding subgradients

Function	$g(\sigma), \mu > 0$	$\partial g(\sigma)$
ℓ_p ^[17]	$\mu \sigma^p$	$\begin{cases} +\infty, & \sigma = 0 \\ \mu p \sigma^{p-1}, & \sigma > 0 \end{cases}$
atan ^[18]	$\text{atan}\left(\frac{\sigma}{\mu}\right)$	$\frac{\mu}{\sigma^2 + \mu^2}$
ETP ^[19]	$\frac{\mu}{1 - \exp(-p)}(1 - \exp(-p\sigma))$	$\frac{\mu p}{1 - \exp(-p)} \exp(-p\sigma)$
MCP ^[20]	$\begin{cases} \mu\sigma - \frac{\sigma^2}{2p}, & \sigma < p\mu \\ \frac{1}{2} p\mu^2, & \sigma \geq p\mu \end{cases}$	$\begin{cases} \mu - \frac{\sigma}{p}, & \sigma < p\mu \\ 0, & \sigma \geq p\mu \end{cases}$
LogExp ^[21]	$\mu \ln(2/(1 + \exp(-\sigma/p)))$	$\frac{\mu}{p(1 + \exp(\sigma/p))}$
Geman ^[22]	$\frac{\mu\sigma}{\sigma + p}$	$\frac{\mu\sigma}{(\sigma + p)^2}$
LogSum ^[23]	$\frac{\mu}{\ln 2} \ln(\sigma + 1)$	$\frac{\mu}{(\sigma + 1) \ln 2}$

2 本文方法

2.1 算法模型设计

受以上研究启发,同时为了应对过拟合的问题,

许多现有方法均添加正则化项来约束表示系数,如 $\|\mathbf{x}\|_1$ 和 $\|\mathbf{x}\|_2^2$,但是可以发现 $\{\mathbf{A}_i \mathbf{x}_i\}$ 与最终的识别紧密相关,正确类别的表示在整个表示空间中占据更显著的位置,相对于其他类别的表征而言更为突

出。基于这一认识,本文的算法模型可以表示为:

$$\min_{E,x} \|E\|_{s,*} + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2$$

$$\text{s. t. } y = A(x) + e \quad (3)$$

式中: α 为类权重参数; w_i 为第 i 类的权值; e 为误差项。令 r_i 表示第 i 类的残差, r_{\max} 表示 r_i 的最大值, σ 是一个常数,则 w_i 表示为:

$$w_i = \exp\left(\frac{S_{\text{Sim}_i}}{\sigma}\right), S_{\text{Sim}_i} = \frac{r_i}{r_{\max}} \quad (4)$$

考虑到复杂环境中存在多种噪声类型,为了有效处理连续性和非连续性噪声,同时用 ℓ_2 范数对误差进行约束,得到本文的算法模型为:

$$\min_{E,x} \|E\|_{s,*} + \|e\|_2^2 + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2$$

$$\text{s. t. } y = A(x) + e \quad (5)$$

值得注意的是,重构图像本身具有低秩性质。为了充分利用这一特性,本文引入了对重构图像进行稳健核范数约束的方法,从而构建了最终的算法模型:

$$\min_{E,x} \|E\|_{s,*} + \|e\|_2^2 + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2 + \|A(x)\|_{s,*}$$

$$\text{s. t. } y = A(x) + e \quad (6)$$

式中: $E = \text{Mat}(e)$; A_i 是训练集的第 i 类样本; $A(x)$ 表示重构图像。

对于本文算法模型,第 1 项使用稳健核范数约束误差矩阵,从而更好地逼近误差的低秩结构。考虑到复杂环境下噪声多样的问题,算法同时用 ℓ_2 范数对误差进行约束。第 3 项使用 $A_i x_i$ 作为正则化项。最后注意到重构图像具有低秩结构,也使用稳健核范数约束重构图像矩阵。

2.2 算法的优化过程

本文使用交替方向乘子法(ADMM)进行优化:

$$\|E\|_{s,*} + \|e\|_2^2 + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2 + \|A(x)\|_{s,*}$$

$$\text{s. t. } y = A(x) + e \quad (7)$$

引入辅助变量 D 使问题可分离:

$$\|E\|_{s,*} + \|e\|_2^2 + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2 + \|D\|_{s,*}$$

$$\text{s. t. } y = D + e, D = A(x) \quad (8)$$

构造增广拉格朗日函数:

$$L = \|E\|_{s,*} + \|e\|_2^2 + \frac{\alpha}{2} w_i \|A_i x_i\|_2^2 + \|D\|_{s,*} +$$

$$z_1(y - D - e) + z_2(D - A(x)) +$$

$$\frac{\mu}{2} (\|y - D - e\|_2^2 + \|D - A(x)\|_2^2) \quad (9)$$

式中: z_1 和 z_2 是拉格朗日乘数; $\mu > 0$ 是一个惩罚参数。使用 ADMM 更新变量的步骤如下:

$$e_{t+1} = \underset{e}{\text{argmin}} L(e, D_t, z_{1,t}) \quad (10)$$

$$D_{t+1} = \underset{D}{\text{argmin}} L(D, e_{t+1}, z_{1,t}, z_{2,t}) \quad (11)$$

$$x_{t+1} = \underset{x}{\text{argmin}} L(x, D_{t+1}, z_{2,t}) \quad (12)$$

$$z_{1,t+1} = z_{1,t} + \mu(y - D_{t+1} - E_{t+1}) \quad (13)$$

$$z_{2,t+1} = z_{2,t} + \mu(D_{t+1} - A(x_{t+1})) \quad (14)$$

1)更新 e_{t+1} 。

固定其他变量 $D_t, z_{1,t}$, 式(9)变为:

$$e_{t+1} = \underset{e}{\text{argmin}} \|E\|_{s,*} + \|e\|_2^2 +$$

$$\frac{\mu}{2} \|e - (y - D + z_{1,t}/\mu)\|_2^2 \quad (15)$$

更新 e_{t+1} 共分为 2 步:

第 1 步解决:

$$e_{t+1}^1 = \underset{e}{\text{argmin}} \|e\|_2^2 +$$

$$\frac{\mu}{2} \|e - (y - D + z_{1,t}/\mu)\|_2^2 \quad (16)$$

上述问题的解为:

$$e_{t+1}^1 = (I + 2/\mu)^{-1} (y - D_t + z_{1,t}/\mu) \quad (17)$$

式中: I 为单位矩阵。

第 2 步利用非凸函数对 E 的低秩性进行约束:

$$e_{t+1} = \underset{e}{\text{argmin}} \|E\|_{s,*} + \frac{\mu}{2} \|E - E_{t+1}^1\|_F^2 \quad (18)$$

式中: $E_{t+1}^1 = \text{Mat}(e_{t+1}^1)$ 。

利用奇异值收缩算子算法,上述问题的解为:

$$e_{t+1} = \tau_{1/\mu}(E_{t+1}^1) \quad (19)$$

2)更新 D_{t+1} 。

固定其他变量 $e_{t+1}, z_{1,t}, z_{2,t}$, 式(9)变为:

$$D_{t+1} = \underset{D}{\text{argmin}} \|D\|_{s,*} +$$

$$z_1(y - D - E) + z_2(D - A(x)) +$$

$$\frac{\mu}{2} (\|y - D - E\|_2^2 + \|(D - A(x))\|_2^2) =$$

$$\underset{D}{\text{argmin}} \|D\|_{s,*} + \mu \|D - M\|_F^2 = \tau_{\frac{1}{2\mu}}(M) \quad (20)$$

式中: $M = \frac{1}{2} \left(y - E + A(x) + \frac{z_1 - z_2}{\mu} \right)$ 。

3)更新 x_{t+1} 。

固定其他变量 $D_{t+1}, z_{2,t}$, 式(9)变为:

$$x_{t+1} = \underset{x}{\text{argmin}} \frac{\alpha}{2} \sum_{i=1}^c w_i \|A_i x_i\|_2^2 +$$

$$\frac{\mu}{2} \left\| D - A(x) + \frac{z_2}{\mu} \right\|_2^2 \quad (21)$$

首先,令 $f_1(x) = \mu/2 \|D - A(x) + z_2/\mu\|_2^2$, 计算它的导数:

$$\partial f_1(x)/\partial x = -\mu A^T(D - A(x) + z_2/\mu) \quad (22)$$

令 $f_2(\mathbf{x}) = \frac{\alpha}{2} \mathbf{w}_i \|\mathbf{A}_i \mathbf{x}_i\|_2^2$, 由于 $f_2(\mathbf{x})$ 不显含 \mathbf{x} , 构造 $\mathbf{H}_i = \text{diag}(0, \dots, 0, 1, \dots, 1, 0, \dots, 0)$, 其中第 i 类的元素为 1, 其他元素均为 0, 则 $\|\mathbf{A}_i \mathbf{x}_i\|_2^2 = \|\mathbf{A} \mathbf{H}_i \mathbf{x}\|_2^2$. 计算 $f_2(\mathbf{x})$ 的导数:

$$\frac{\partial f_2(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial}{\partial \mathbf{x}} \left(\frac{\alpha}{2} \sum_{i=1}^c \mathbf{w}_i \|\mathbf{A} \mathbf{H}_i \mathbf{x}\|_2^2 \right) = \alpha \sum_{i=1}^c \mathbf{w}_i \mathbf{H}_i \mathbf{A}^T \mathbf{A} \mathbf{H}_i \mathbf{x} \quad (23)$$

已经计算出 $\partial f_1(\mathbf{x})/\partial \mathbf{x}$ 和 $\partial f_2(\mathbf{x})/\partial \mathbf{x}$, 则目标函数 $f(\mathbf{x})$ 的导数为:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = -\mu \mathbf{A}^T (\mathbf{D} - \mathbf{A}(\mathbf{x}) + \mathbf{z}_2/\mu) + \alpha \sum_{i=1}^c \mathbf{w}_i \mathbf{H}_i \mathbf{A}^T \mathbf{A} \mathbf{H}_i \mathbf{x} \quad (24)$$

令 $\partial f(\mathbf{x})/\partial \mathbf{x} = 0$, 得到关于 \mathbf{x} 的解:

$$\mathbf{x}_{t+1} = \left(\mathbf{A}^T \mathbf{A} + \frac{\alpha}{\mu} \sum_{i=1}^c \mathbf{w}_i \mathbf{H}_i \mathbf{A}^T \mathbf{A} \mathbf{H}_i \right)^{-1} \mathbf{A}^T (\mathbf{D} + \frac{\mathbf{z}_2}{\mu}) \quad (25)$$

本文算法优化步骤如算法 1 所示。

算法 1 利用 ADMM 算法求解本文算法模型

输入 训练样本 \mathbf{A} , 测试样本 \mathbf{y} , 参数 α 和终止参数 ϵ

输出 最优回归系数向量 \mathbf{x}

初始化 $\mathbf{D} = \mathbf{A}(\mathbf{x})$, $\mathbf{z}_1 = \mathbf{z}_2 = 0$, $i_{\maxiter} = 100$, $\rho =$

1.01, $\mu = 10^{-4}$, $\mu_{\max} = 10^3$, $\epsilon = 10^{-6}$, $i_{\text{iter}} = 0$

重复:

通过式(17)和式(19)更新 \mathbf{e} ;

通过式(20)更新 \mathbf{D} ;

通过式(25)更新 \mathbf{x} ;

通过式(13)和式(14)更新拉格朗日乘数 $\mathbf{z}_1, \mathbf{z}_2$;

更新 μ : $\mu_{t+1} = \min(\mu_{\max}, \rho \mu_t)$;



图 1 Extended Yale B 数据集中部分人脸图像

Fig.1 Partial face images from the Extended Yale B dataset

首先对图像进行预处理。实验中所有图像的分辨率均调整到 32×32 像素, 在每幅人脸图像中随机选取每个个体的 10、12、14、16 张图像作为训练样本, 剩余图像作为测试样本。各方法在 Extended Yale B 数据集上的平均识别率如图 2 所示(彩色效果见《计算机工程》官网 HTML 版, 下同), 所有实验结果都是进行 10 次实验取平均值之后的结果。

由图 2 可知, 随着训练样本数增加, 各方法的识别率呈上升趋势。在大部分情况下, 本文方法的识

检查达到收敛条件: $\|\mathbf{y} - \mathbf{A}(\mathbf{x}) + \mathbf{e}\|_2 < \epsilon$, $\frac{\|\mathbf{D} - \mathbf{A}(\mathbf{x})\|_\infty}{\|\mathbf{A}(\mathbf{x})\|_\infty} < \epsilon$;

更新 $i_{\text{iter}}: i_{\text{iter}} = i_{\text{iter}} + 1$;

直到达到收敛条件或最大迭代次数。

2.3 分类函数

本文利用类重构误差来识别 \mathbf{y} 。当利用所提出的算法对公式进行优化后, 可以得到测试样本 \mathbf{y} 的最优表示系数 \mathbf{x} 。对于第 i 类样本, 其类重构误差为:

$$\mathbf{e}^{(i)} = \|\text{Mat}(\mathbf{A}(\mathbf{x}) - \mathbf{A}(\mathbf{x}_i))\|_* + \|\mathbf{A}(\mathbf{x}) - \mathbf{A}(\mathbf{x}_i)\|_2 \quad (26)$$

最终的分类规则为:

$$R_{\text{identity}}(\mathbf{y}) = \underset{i}{\text{argmin}} \mathbf{e}_i \quad (27)$$

3 实验

为了评估所提方法的有效性, 在几个公开的人脸数据集上进行实验, 包括 Extended Yale B^[24]、ORL^[25]、AR^[26], 同时, 与现有的方法进行对比, 包括 SRC^[3]、CRC^[4]、RBD-DPL^[27]、LCLRDL^[28]、NMR^[8]、SR-NMR^[9]、LDMR^[29] 和 DPL-SCSR^[30]。为确保公正比较, 将参考原文作者的建议来设置这些方法的参数。

3.1 光照变化实验

首先在 Extended Yale B 数据集上评估所提出的方法对于光照变化的性能。Extended Yale B 数据集是一个灰度人脸图像数据集, 包含 2 414 张正面面部图像, 每个个体在不同的光照条件下有 59~64 张图像, 这些图像是在不同的光照条件和不同的面部表情下拍摄的。Extended Yale B 数据集的部分人脸图像如图 1 所示。

别率高于其他对比方法。当训练样本数为 10 个时, 本文方法取得最高识别率, 验证了本文方法在训练样本数较少时, 对光照变化的鲁棒性。

3.2 随机遮挡实验

本节在 Extended Yale B 数据集上通过随机添加黑块遮挡和“狒狒”图像遮挡, 模拟不同程度的随机遮挡进行实验, 验证所提方法对于遮挡识别的识别性能, 数据预处理与 3.1 节相同。随机选取 25 张图像作为训练样本, 剩余图像作为测试样本, 给 Extended

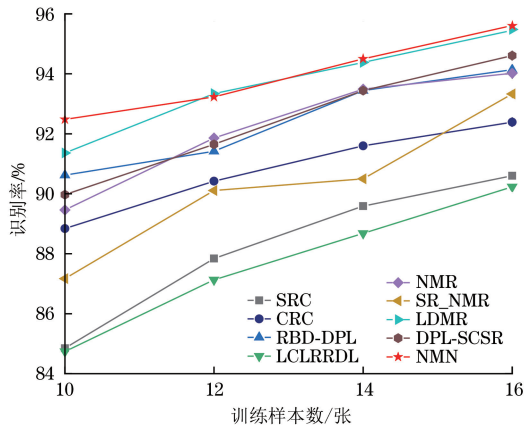


图 2 不同训练样本数下各方法的识别率

Fig.2 Recognition rates of various methods under different numbers of training samples

Yale B 数据集的测试集分别添加 10%、20%、30% 和 40% 的遮挡块,添加遮挡后的人脸图像如图 3 和图 4 所示,实验结果如表 2 和表 3 所示,所有实验结果都是进行 10 次实验取平均值之后的结果。




图 3 Extended Yale B 数据集中不同比例黑块遮挡

Fig.3 Different levels of occlusion by black blocks in the Extended Yale B dataset




图 4 Extended Yale B 数据集中不同比例“狒狒”图像遮挡

Fig.4 Different levels of occlusion by "baboon" image in the Extended Yale B dataset

由表 2 和表 3 可知,随着遮挡比例增加,各方法的识别率呈下降趋势,这是由于遮挡造成了部分特征信息丢失。对于以上情况,本文方法取得了较高的识别率,特别是在遮挡比例为 40% 时,本文方法识别率均在 80% 以上。对于“狒狒”图像遮挡,本文方法识别率比其他对比方法至少高出 10 百分点,验证了本文方法对遮挡的鲁棒性。

表 2 不同黑块遮挡比例下各方法的识别率

Table 2 Recognition rates of each method under different levels of occlusion by black blocks %

方法	平均识别率			
	10%黑块 遮挡	20%黑块 遮挡	30%黑块 遮挡	40%黑块 遮挡
SRC	93.46	89.67	83.20	71.23
CRC	92.28	87.42	79.78	69.52
RBD-DPL	94.95	91.35	86.48	77.04
LCLRRDL	92.02	86.93	78.95	66.66
NMR	84.98	79.11	75.80	74.86
SR_NMR	95.35	93.09	89.53	81.61
LDMM	95.27	92.41	89.26	81.29
DPL-SCSR	93.92	90.52	84.86	76.32
NMN	96.45	94.22	90.01	81.12

表 3 不同“狒狒”图像遮挡比例下各方法的识别率

Table 3 Recognition rates of each method under different levels of occlusion by "baboon" image %

方法	平均识别率			
	10%“狒狒” 图像遮挡	20%“狒狒” 图像遮挡	30%“狒狒” 图像遮挡	40%“狒狒” 图像遮挡
SRC	89.26	83.52	75.27	63.05
CRC	84.95	77.04	69.30	58.03
RBD-DPL	86.27	80.79	73.66	63.09
LCLRRDL	84.21	76.05	68.11	58.14
NMR	73.57	71.11	61.90	58.33
SR_NMR	90.05	84.40	77.00	68.72
LDMM	83.88	75.41	63.50	47.27
DPL-SCSR	87.21	80.80	72.01	63.02
NMN	94.13	90.51	86.53	80.40

3.3 自然场景实验

本小节采用 ORL 人脸数据集验证所提出的方法在自然场景下的识别性能。ORL 数据集是自然场景下的数据集,ORL 人脸数据集共包含 40 个不同人的 400 张图像,每个人有 10 张不同表情和角度的照片。ORL 数据集的部分人脸图像如图 5 所示。



图 5 ORL 数据集中部分人脸图像

Fig.5 Partial face images from the ORL dataset

将所有图像的分辨率均调整到 56×46 像素,随机选择每个个体图像中的 3、4、5、6 张图像作为训练样本,其余图像作为测试样本。表 4 给出了 ORL 数据集上各方法在不同训练样本数下的识别率。可以看出本文方法在不同训练样本情况下均取得最高的识别率。

表 4 不同训练样本数下各方法的识别率

Table 4 Recognition rates of each method under different numbers of training samples %

方法	平均识别率			
	3 张训练样本	4 张训练样本	5 张训练样本	6 张训练样本
SRC	90.64	94.58	96.15	96.50
CRC	90.21	91.75	94.10	94.75
RBD-DPL	89.86	93.17	95.80	96.50
LCLRRDL	88.64	92.38	93.25	95.12
NMR	88.29	92.67	94.70	95.12
SR_NMR	91.14	93.75	95.40	96.75
LDMR	87.21	90.58	93.50	95.31
DPL-SCSR	89.57	93.83	95.80	96.75
NMN	92.14	94.90	97.50	97.87

3.4 真实遮挡和添加随机噪声实验

在 AR 数据集上评估所提出的方法对于真实遮挡的性能。AR 数据集中共有 126 人(70 名男性和 56 名女性)的约 4 000 张人脸图像,所有图像的分辨率都调整到 50×40 像素。训练样本均选取每个个体的 8 张无遮挡图像,选取每个个体的 6 张太阳镜遮挡图像作为测试样本。给 AR 数据集的测试集分别添加 10%、20%、30% 和 40% 的随机噪声,添加遮挡后的人脸图像如图 6 所示。图 7 给出了实验结果。

由图 7 可知,对于不同的遮挡比例,本文方法均取得较高的识别率。同时注意到基于向量误差模型的方法如 SRC、CRC 均取得较高识别率,这是由于添加的随机噪声是独立的,基于向量误差模型的方

法对于非连续的噪声有较强的鲁棒性。




图 6 AR 数据集中添加不同比例随机噪声的图像

Fig. 6 Images by adding random noise at different levels in the AR dataset

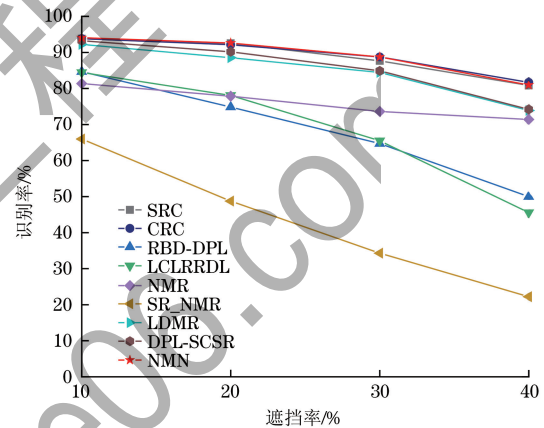


图 7 不同遮挡率下各方法的识别率

Fig. 7 Recognition rates of each method under different occlusion rates

3.5 敏感参数实验

本节在 Extended Yale B、ORL 和 AR 数据集上进行参数敏感性分析实验。对于 Extended Yale B 数据集,随机选择 10 张人像图像作为训练样本,剩余的图像作为测试样本。对于 ORL 数据集,随机选择 6 张人像图像作为训练样本,剩余的图像作为测试样本。对于 AR 数据集,选择每个个体的 8 张无遮挡图像作为训练样本,6 张戴太阳镜的图像作为测试样本。NMN 有一个参数 α ,定义 α 参数候选集 $\{10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1\}$,观察参数变化对识别率的影响。实验结果如图 8 所示。由图 8 可知, α 不同的取值会对识别率造成很大的影




图 8 Extended Yale B、ORL 和 AR 数据集上的参数敏感性分析

Fig. 8 Parameter sensitivity analysis on the Extended Yale B, ORL, and AR datasets

响,一般来说,对于 Extended Yale B、ORL 和 AR 数据集,当 α 分别取 $\{10^{-5}, 10^{-4}\}$ 、 $\{10^{-4}, 10^{-3}\}$ 、 $\{10^{-4}, 10^{-3}\}$ 时, NMN 能取得满意的性能。

3.6 消融实验

为了验证正则化项 $\mathbf{A}_i \mathbf{x}_i$ 、噪声稀疏约束模块 $\|\mathbf{e}\|_2$ 和重构图像低秩约束模块 $\|\mathbf{A}(\mathbf{x})\|_{s,*}$ 的有效性,本节在 ORL 数据集上进行消融实验。对于 ORL 数据集,随机选择 6 张人像图像作为训练样本,同时将剩余的图像用 40%“狒狒”图像遮挡处理,以构建测试样本。在构建基础模型时,移除各个模块。通过逐一添加这些模块,形成不同的模型,分别用 1~8 进行编号,用 \times 表示不添加, \checkmark 表示添加。各个模型的识别准确率如表 5 所示。由表 5 可知,当引入所有模块后,本文方法的识别率达到了最高的 89.62%,比基础模型提高了 18.75 个百分点,这表明在这些模块协同作用下,本文方法取得了显著的性能提升。

表 5 消融实验对比结果

实验	$\mathbf{A}_i \mathbf{x}_i$	$\ \mathbf{e}\ _2$	$\ \mathbf{A}(\mathbf{x})\ _{s,*}$	识别率
1	\times	\times	\times	70.87
2	\checkmark	\times	\times	84.63
3	\times	\checkmark	\times	73.38
4	\times	\times	\checkmark	73.44
5	\checkmark	\checkmark	\times	88.24
6	\checkmark	\times	\checkmark	86.12
7	\times	\checkmark	\checkmark	75.12
8	\checkmark	\checkmark	\checkmark	89.62

4 结束语

本文提出一种基于非凸混合范数误差编码的人脸识别方法。所提方法没有关注表示系数,而是对类间表示进行约束。使用稳健核范数对结构噪声和重构图像进行约束,以更好地捕捉低秩性。同时采用 ℓ_2 范数作为稀疏解的约束条件,放宽了表示系数的稀疏性要求。在此基础上,提出了一种求解优化问题的优化算法。在 Extended Yale B、ORL 和 AR 人脸数据集上进行了实验,结果验证了所提方法的有效性。今后的工作将聚焦于 2 个主要方面:1)优化算法以提高处理速度;2)将算法模型扩展到开放集人脸图像识别任务。

参考文献

[1] YANG M L, HUANG F H, LV X B. A feature learning approach for face recognition with robustness to noisy label based on top-N prediction[J]. Neurocomputing, 2019, 330:

48-55.
 [2] CHEN W S, LIU J M, PAN B B, et al. Face recognition using nonnegative matrix factorization with fractional power inner product kernel[J]. Neurocomputing, 2019, 348: 40-53.
 [3] 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.
 [4] ZHANG L, YANG M, FENG X C. Sparse representation or collaborative representation: which helps face recognition? [C]// Proceedings of the International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2011: 471-478.
 [5] HUANG J, NIE F P, HUANG H, et al. Supervised and projected sparse coding for image classification [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2013, 27(1): 438-444.
 [6] YU Y F, DAI D Q, REN C X, et al. Discriminative multi-scale sparse coding for single-sample face recognition with occlusion[J]. Pattern Recognition, 2017, 66: 302-312.
 [7] YANG M, ZHANG L, YANG J, et al. Robust sparse coding for face recognition [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2011: 625-632.
 [8] 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.
 [9] CHEN Z, WU X J, KITTLER J. A sparse regularized nuclear norm based matrix regression for face recognition with contiguous occlusion[J]. Pattern Recognition Letters, 2019, 125: 494-499.
 [10] LI Q, HE H H, LAI H, et al. Enhanced nuclear norm based matrix regression for occluded face recognition[J]. Pattern Recognition, 2022, 126: 108585.
 [11] SU T T, FENG D Z, WANG M, et al. Dual discriminative low-rank projection learning for robust image classification [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(12): 7708-7722.
 [12] XIE Y, GU S H, LIU Y, et al. Weighted Schatten p -norm minimization for image denoising and background subtraction [J]. IEEE Transactions on Image Processing, 2016, 25(10): 4842-4857.
 [13] XIE J C, YANG J, QIAN J J, et al. Robust nuclear norm-based matrix regression with applications to robust face recognition [J]. IEEE Transactions on Image Processing, 2017, 26(5): 2286-2295.
 [14] ZHANG C, LI H X, CHEN C L, et al. Enhanced group sparse regularized nonconvex regression for face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(5): 2438-2452.
 [15] ZHONG K Y, LIU J L. Image classification based on weighted nonconvex low-rank and discriminant least squares regression[J]. Applied Intelligence, 2023, 53(18): 20844-20862.
 [16] ZHENG J W, LOU K C, YANG X, et al. Weighted mixed-norm regularized regression for robust face identification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(12): 3788-3802.
 [17] LUO L, YANG J, QIAN J J, et al. Robust image regression based on the extended matrix variate power exponential distribution of dependent noise [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(9): 2168-2182.
 [18] GASSO G, RAKOTOMAMONJY A, CANU S. Recovering sparse signals with a certain family of nonconvex penalties

- and DC programming [J]. *IEEE Transactions on Signal Processing*, 2009, 57(12): 4686-4698.
- [19] GAO C X, WANG N Y, YU Q, et al. A feasible nonconvex relaxation approach to feature selection [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2011, 25(1): 356-361.
- [20] JIN Z F, WAN Z P, JIAO Y L, et al. An alternating direction method with continuation for nonconvex low rank minimization [J]. *Journal of Scientific Computing*, 2016, 66(2): 849-869.
- [21] MONTEFUSCO L B, LAZZARO D, PAPI S. A fast algorithm for nonconvex approaches to sparse recovery problems [J]. *Signal Processing*, 2013, 93(9): 2636-2647.
- [22] LU C Y, TANG J H, YAN S C, et al. Nonconvex nonsmooth low rank minimization via iteratively reweighted nuclear norm [J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2016, 25(2): 829-839.
- [23] FRIEDMAN J H. Fast sparse regression and classification [J]. *International Journal of Forecasting*, 2012, 28(3): 722-738.
- [24] GEORGHIADES A S, BELHUMEUR P N, KRIEGMAN D J. From few to many: illumination cone models for face recognition under variable lighting and pose [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(6): 643-660.
- [25] SAMARIA F S, HARTER A C. Parameterisation of a stochastic model for human face identification [C] // *Proceedings of 1994 IEEE Workshop on Applications of Computer Vision*. Washington D. C., USA: IEEE Press, 1994: 138-142.
- [26] MARTINEZ A, BENAVENTE R. The AR face database: CVC Tech. Rep. # 24 [R]. Barcelona, The Kingdom of Spain: Robot Vision Lab, 1999.
- [27] CHEN Z, WU X J, KITTLER J. Relaxed block-diagonal dictionary pair learning with locality constraint for image recognition [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(8): 3645-3659.
- [28] YIN H F, WU X J, KITTLER J. Face recognition via locality constrained low rank representation and dictionary learning [EB/OL]. [2023-10-02]. <https://arxiv.org/abs/1912.03145>.
- [29] ZHANG C, LI H X, QIAN Y H, et al. Locality-constrained discriminative matrix regression for robust face identification [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(3): 1254-1268.
- [30] CHEN Z, WU X J, XU T Y, et al. Discriminative dictionary pair learning with scale-constrained structured representation for image classification [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(12): 10225-10239.

编辑 金胡考