

DOI:10.19651/j.cnki.cmt.2107386

基于 PCA 和 IGG 权函数的人脸图像 鲁棒线性回归分类方法*

吕开云^{1,2} 鞠厦轶^{1,2} 龚循强^{1,2} 鲁铁定^{1,2}

(1. 东华理工大学 测绘工程学院 南昌 330013; 2. 自然资源部 环鄱阳湖区域矿山环境监测与治理重点实验室 南昌 330013)

摘要: 在人脸识别中,线性回归分类是一种快速且有效的方法。然而,线性回归分类是基于图像向量进行识别,导致原始矩阵图像往往为高维数据,且人脸图像经常受到污染。为此,提出一种基于 PCA 和 IGG 权函数的鲁棒线性回归分类方法。首先通过 PCA 对人脸图像进行降维,再采用 IGG 权函数对被污染的人脸图像进行分类。选用公开的 ORL 和 Yale 人脸库,将线性回归分类、基于 IGG 权函数的鲁棒线性回归分类和基于 PCA 和 IGG 权函数的鲁棒线性回归分类进行比较。实验结果表明,在 ORL 和 Yale 人脸库中,在不加噪声和加入椒盐噪声和斑点噪声条件下,所提出方法的识别率均值都在 92.07% 以上,均高于另外两种方法。

关键词: 人脸识别;主成分分析(PCA);IGG 权函数;线性回归分类(LRC)

中图分类号: TP319.4 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Face recognition using robust linear regression classification based on PCA and IGG weight function

Lyu Kaiyun^{1,2} Ju Xiayi^{1,2} Gong Xunqiang^{1,2} Lu Tieding^{1,2}

(1. Faculty of Geomatics, East China University of Technology, Nanchang 330013, China; 2. Key Laboratory of Mine Environmental Monitoring and Improving around Poyang Lake, Ministry of Natural Resources, Nanchang 330013, China)

Abstract: Linear regression classification is a fast and effective method in face recognition. However, linear regression classification is based on image vector recognition, which leads to the fact that the original matrix image is often high-dimensional data, and the face image is often contaminated. In order to solve this problem, a robust linear regression classification algorithm based on PCA and IGG weight function is proposed in this paper. Firstly, PCA is used to reduce the dimensionality of the face image, then the IGG weight function is adopted to classify the contaminated face image. Linear regression classification, robust linear regression classification based on IGG weight function and robust linear regression classification based on PCA and IGG weight function methods are compared with the public ORL and Yale databases. The experimental results show that the average recognition rate of the proposed method is above 92.07% without noise and with salt and pepper noise and speckle noise, which are higher than the other two methods in the ORL and Yale databases.

Keywords: face recognition; principal component analysis (PCA); IGG weight function; linear regression classification (LRC)

0 引 言

人脸识别是生物鉴别领域中的重要分支,在身份识别、图像处理、电子支付等领域有广泛的应用^[1-2]。然而人脸图像容易受到光照条件、拍摄角度、人体姿态等的影响,导致

识别率降低^[3-4]。因此,如何提高复杂环境下人脸图像的识别率成为当下研究的热点^[5]。

为了提高识别率,近 20 年国内外学者提出了各种识别方法,其中线性回归分类(linear regression classification, LRC)较为突出^[6-7]。LRC 假设特定类别的人脸图像位于

收稿日期:2021-07-25

* 基金项目:国家自然科学基金(42101457,42061077)、江西省教育厅科学技术科技项目(H(GJJ150591)、东华理工大学放射性地质与勘探技术国防重点学科实验室开放基金(REGT1219)、2020 年度江西省研究生创新专项资金项目立项项目(DHYC-202019)资助

线性空间中,同一类别的测试样本可以用同一类别的训练样本线性表示,使用最小二乘求解 LRC 的回归系数,然后利用重构误差最小的类预测为测试样本的类别^[8-10]。根据文献[8]所述,当测试样本难以直接用训练样本线性表示时,LRC 识别率相对较低。Lu 等^[11]提出了核线性回归分类(kernel linear regression classification, KLRC),通过使用核函数对人脸图像进行非线性映射,将人脸图像映射到高维空间,提高人脸图像的线性可分性,从而提高 LRC 的识别率。此外,LRC 在人脸图像识别中不具有鲁棒性,文献[12-13]提出了线性判别回归分类(linear discriminant regression classification, LDRC),将线性判别分析(linear discriminate analysis, LDA)融入到 LRC 框架中,通过 LDA 使得类间距离最大,而类内距离最小,从而提高鲁棒性。与 LRC 相比,LDRC 为 人脸图像提供了一个子空间,能够提高识别率。但是,LDRC 将训练样本同等看待,忽略了训练样本对特征子空间的不同贡献,Huang 等^[14]提出了自适应线性判别回归分类(adaptive linear discriminant regression classification, ALDRC),利用惩罚函数获得权重,采用不同的权重来描述训练样本对自身类别的不同贡献,通过最大化类间重构误差与类内重构误差之比,获得具有代表性的特征子空间,提高人脸识别率。

然而,上述提及的诸多 LRC 方法利用下采样对高维人脸图像进行降维,不能很好地提取原始图像的特征,且人脸图像经常受到污染,从而影响最终的识别率。为此,本文提出基于主成分分析(principal component analysis, PCA)和 IGG 权函数的鲁棒线性回归分类(robust linear regression classification based on PCA and IGG weight function, PCA+RLRC-IGG)。通过选取 ORL 人脸库和 Yale 人脸库,采用 LRC、RLRC-IGG 和 PCA+RLRC-IGG 等 3 种方法进行人脸识别,预期 PCA+RLRC-IGG 在 ORL 人脸库和 Yale 人脸库中,在不加入噪声和加入噪声条件下,识别率都是最高的,从而验证 PCA+RLRC-IGG 在人脸识别中的有效性。

1 基本原理

通过 PCA+RLRC-IGG 对人脸图像进行识别,其中 LRC 是 PCA+RLRC-IGG 的基础,因此先熟悉一下 LRC 的基本原理。

1.1 线性回归分类方法

假设第 i 类的测试样本 y_i 可以用第 i 类的训练样本 X_i 线性表示,则有:

$$y_i = X_i \alpha_i, i = 1, 2, \dots, C \quad (1)$$

其中, $X_i = [x_i^1, x_i^2, \dots, x_i^{m_i}] \in R^{d \times m_i}$ 是第 i 类的训练样本, y_i 为第 i 类的测试样本, C 为类别数, α_i 是 LRC 的回归系数, m_i 为每类样本总数。当 $d \geq m_i$ 时,通过最小二乘可得 α_i 为:

$$\alpha_i = (X_i^T X_i)^{-1} X_i^T y_i \quad (2)$$

利用回归系数 α_i , 则有:

$$\hat{y}_i = X_i \alpha_i = X_i (X_i^T X_i)^{-1} X_i^T y_i \quad (3)$$

其中, \hat{y}_i 表示第 i 类测试样本 y_i 的重构样本。

1.2 基于 PCA 和 IGG 权函数的鲁棒线性回归分类方法

假设每张人脸图像表示为 $x_i^j \in R^{a \times b}$, 其中 $i = 1, 2, \dots, C$, $j = 1, 2, \dots, m_i$, 且有 $\sum_{i=1}^C m_i = m$ 。将人脸图像矩阵 $x_i^j \in R^{a \times b}$ 通过堆叠图像列的方式变为人脸图像向量即为 $x_i^j \in R^d$, 其中 $d = a \times b$ 为每张图像的维数,将图像矩阵变为图像向量,会造成数据冗余性,因此前人通常使用下采样对图像向量进行降维^[15],即 $x_i^j \in R^d \rightarrow x_{i,d}^j \in R^q$, 其中 $q \leq d$ 。而 PCA+RLRC-IGG 使用 PCA 对人脸图像进行降维,则有:

$$U_{\text{PCA}} = W^T X \quad (4)$$

其中, U_{PCA} 表示经过 PCA 降维后的人脸图像, $U_{\text{PCA}} = [U_{\text{PCA}_1}, U_{\text{PCA}_2}, \dots, U_{\text{PCA}_C}] \in R^{q \times C}$, 其中, $U_{\text{PCA}_i} = [u_{\text{PCA}_i}^1, u_{\text{PCA}_i}^2, \dots, u_{\text{PCA}_i}^{m_i}] \in R^{q \times m_i}$ ($1 \leq i \leq C$) 表示第 i 类经 PCA 降维后的所有样本, $u_{\text{PCA}_i}^j \in R^q$ 表示第 i 类的第 j 个样本, $1 \leq j \leq m_i$ 。 $W = [w_1, w_2, \dots, w_q] \in R^{d \times q}$ 为降维矩阵, $X = [X_1, X_2, \dots, X_C] \in R^{d \times C}$ 表示原始人脸图像。经过 PCA 降维后的 LRC 的回归系数估计值 $\hat{\alpha}_{\text{PCA}_i}$ 为:

$$\hat{\alpha}_{\text{PCA}_i} = (U_{\text{PCA}_i}^T U_{\text{PCA}_i})^{-1} U_{\text{PCA}_i}^T y_{\text{PCA}_i} \quad (5)$$

人脸图像容易受到传感器,光照、人体姿态等的干扰,在人脸图像上表现为类似斑点的噪声。若将人脸图像看作观测数据,那么人脸图像中存在的斑点噪声可以理解为人脸图像中的粗差,每一类别中的训练样本之间均存在一定程度的差别即为随机误差。为此,在 LRC 的基础上引入了 IGG 权函数,根据文献[16-17],IGG 权函数为:

$$Q_{ii} = \begin{cases} 1, & |\hat{e}_i/\sigma| < k_0 \\ \frac{k_0}{|\hat{e}_i/\sigma|}, & k_0 \leq |\hat{e}_i/\sigma| < k_1, i = 1, 2, \dots, C \\ 0, & |\hat{e}_i/\sigma| \geq k_1 \end{cases} \quad (6)$$

其中, Q_{ii} 为 IGG 的权函数, \hat{e}_i 是第 i 个样本的残差, σ 为标准差, k_0, k_1 为常数。在本次实验中,为了更有效地识别,式(6)中的“0”取 1.0×10^{-5} , 则 PCA+RLRC-IGG 的回归系数估计值 $\hat{\alpha}_{(\text{PCA}_i, Q_{ii})}$ 为:

$$\hat{\alpha}_{(\text{PCA}_i, Q_{ii})} = (U_{\text{PCA}_i}^T (Q_{ii} I) U_{\text{PCA}_i})^{-1} U_{\text{PCA}_i}^T (Q_{ii} I) y_{\text{PCA}_i}, i = 1, 2, \dots, C \quad (7)$$

其中, I 为单位矩阵,则有:

$$\hat{y}_{(\text{PCA}_i, Q_{ii})} = U_{\text{PCA}_i} \hat{\alpha}_{(\text{PCA}_i, Q_{ii})} = U_{\text{PCA}_i} (U_{\text{PCA}_i}^T (Q_{ii} I) U_{\text{PCA}_i})^{-1} U_{\text{PCA}_i}^T (Q_{ii} I) y_{\text{PCA}_i} \quad (8)$$

其中, $\hat{y}_{(\text{PCA}_i, Q_{ii})}$ 表示经过 PCA 和 IGG 权函数处理后的

第 i 类预测样本。则第 i 类的测试样本 $\mathbf{y}_{\text{pcq}_i}$ 和预测样本 $\hat{\mathbf{y}}_{(\text{pcq}_i)}$ 的距离为:

$$d_i = \|\mathbf{y}_{\text{pcq}_i} - \hat{\mathbf{y}}_{(\text{pcq}_i)}\|_2, i = 1, 2, \dots, C \quad (9)$$

其中, $\|\cdot\|_2$ 表示 l_2 范数, LRC 的决策是基于原始人脸图像向量与其预测向量之间的最小距离, 则有:

$$\min_i d_i(\mathbf{y}), i = 1, 2, \dots, C \quad (10)$$

因此, 基于 PCA 和 IGG 权函数的线性回归分类方法可以用算法 1 表示。

算法 1 PCA+RLRC-IGG 算法

输入: 训练样本 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C]$, 测试样本 $\mathbf{Y} = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_C]$ 。

输出: 测试样本的预测类别。

- 1) 通过式(4)和训练样本 \mathbf{X} 获得 PCA 降维后新的训练样本, 并进行归一化处理。
- 2) 通过式(4)和测试样本 \mathbf{Y} 获得 PCA 降维后新的测试样本, 并进行归一化处理。
- 3) 通过式(7)获得第 i 类 PCA+RLRC-IGG 的回归系数估计值 $\hat{\alpha}_{(\text{pcq}_i)}$ 。
- 4) 通过式(8)获得第 i 的预测样本 $\hat{\mathbf{y}}_{(\text{pcq}_i)}$ 。
- 5) 通过式(9)获得第 i 类测试样本 $\mathbf{y}_{\text{pcq}_i}$ 和预测样本 $\hat{\mathbf{y}}_{(\text{pcq}_i)}$ 误差最小的类。

2 实验设计

为了验证 PCA+RLRC-IGG 在人脸库中的识别率和鲁棒性, 选择 ORL 人脸库和 Yale 人脸库, 使用 LRC、RLRC-IGG 和 PCA+RLRC-IGG 对人脸图像进行识别。在每个人脸库中, 随机选择训练样本组成训练集, 每种方法重复 20 次。所有实验都是在 MATLAB2020a 上实现的, 采用 i7 处理器, CPU 为 10 875 H, 内存 16 GB。IGG 权函数中 $k_0 = 1.5, k_1 = 2.5$ 。通过 ORL 人脸库和 Yale 人脸库中的原始人脸图像, 验证 PCA+RLRC-IGG 的识别率, 给 ORL 人脸库和 Yale 人脸库同时分别加入密度为 5% 的斑点噪声和密度为 5% 的椒盐噪声来模拟复杂条件下得到的人脸图像, 验证 PCA+RLRC-IGG 的鲁棒性。

2.1 原始人脸图像

ORL 人脸库有 40 个受试者, 每位受试者有 10 张图像, 每张人脸图像像素大小为 112×92 。图 1 所示为 ORL 人脸库中部分图像。



图 1 ORL 人脸库部分人脸图像

Yale 人脸库由 15 位受试者, 每位 11 张图像组成。每张人脸图像像素大小为 100×100 。图 2 所示为 Yale 人脸库中部分图像。




图 2 Yale 人脸库部分人脸图像

2.2 添加噪声的人脸图像

在获取图像过程中容易受到拍摄角度、光照条件、人体姿态等因素的影响。通过加入不同的噪声来模拟复杂条件下获得的人脸图像, 因此, 在 ORL 人脸库中分别加入密度为 5% 的椒盐噪声和密度为 5% 的斑点噪声, 如图 3 所示。图 3(a) 是 ORL 人脸库的原始图像, 图 3(b) 是加入椒盐噪声的图像, 图 3(c) 是加入斑点噪声的图像。同样地, Yale 人脸库的结果如图 4 所示。



图 3 ORL 人脸库

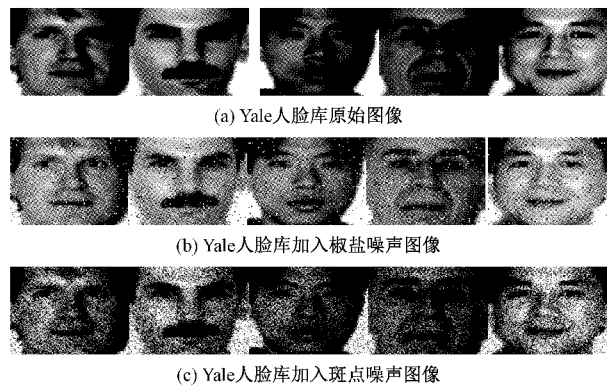


图 4 Yale 人脸库

3 实验结果与分析

分别使用 LRC、RLRC-IGG 和 PCA+RLRC-IGG 对 ORL 人脸库和 Yale 人脸库进行识别。由于是随机选择的训练样本组成训练集, 回归系数估计值会有所差异, 为了使实验结果具有说服力, 在所有的实验中, 每种方法都重复实

验20次,最后取20次实验结果的平均值和标准差作为最终结果^[18]。

3.1 原始图像的结果与分析

在ORL人脸库中,每位受试者的训练样本均从1~9进行变化,剩余的为相应的测试样本。使用PCA时,维数不同,识别率也不同。因此在本次实验中,选择最佳维数对应的识别率作为实验结果。实验结果如图5所示,在ORL人脸库中,随着训练样本的增加,LRC、RLRC-IGG和PCA+RLRC-IGG的识别率整体呈现上升趋势。其中,PCA+RLRC-IGG的识别率整体上高于LRC和RLRC-IGG。究其原因,前人采用下采样对高维人脸图像进行降维,使得识别率相对较低。以训练样本为6,维数为240、200、150、100、40和30为例,LRC的识别率依次为93.75%、93.12%、92.50%、91.88%、85.63%和80.63%,RLRC-IGG的识别率依次为93.75%、92.50%、91.25%、90.63%、85.50%和78.13%,如图6所示。可知,随着维数的降低,LRC和RLRC-IGG的识别率整体上是不断降低的。这是因为下采样是按照一定的间隔选取特征点来获得人脸特征,因此,识别率的高低主要取决于维数的大小。与PCA相比,下采样会导致低维训练样本不能很好地表达原始图像的主要特征。而PCA+RLRC-IGG通过PCA进行降维,其识别率依次为94.38%、93.75%、94.38%、94.38%、95.00%和93.13%,均在93.13%以上,并且识别率相对最稳定。尤其在维数小于100时,PCA+RLRC-IGG的识别率是远远高于LRC和RLRC-IGG的识别率。这是因为PCA通过与原始人脸图像密切相关的正交坐标轴实现降维,能够较好地保留原始图像的主要特征。




图5 ORL人脸库中原始图像的识别率

在Yalc人脸库中,每位受试者的训练样本均从1~10进行变化,剩余的图像为相应的测试样本,实验结果如图7所示。本次实验中,通过使用伪逆来解决利用最小二乘求解回归系数估计值时出现奇异值的问题。在Yale人脸库中,随着训练样本的增加,LRC、RLRC-IGG和PCA+RLRC-IGG的识别率整体呈上升趋势,PCA+RLRC-IGG的识别率依次为56.00%、80.71%、82.50%、82.86%、86.67%、94.67%、96.68%、93.33%、100.00%和




图6 每类训练样本为6时不同维数的识别率

100.00%。剔除训练样本为1时,比LRC的识别率高5.93%、5.00%、10.48%、4.44%、8.00%、1.67%、2.22%、10.00%和6.67%。比RLRC-IGG的识别率高7.41%、7.50%、12.38%、4.44%、9.33%、1.67%、4.44%、10.00%和0.00%。图8所示为降维后的结果,按照从左往右的顺序依次为原始图像,经过下采样降维的图像和经过PCA降维的图像。经过PCA降维的人脸图像仍然保持原始图像的主要特征,而经下采样降维的人脸图像得到的特征比较差。




图7 Yalc人脸库中原始图像的识别率




图8 Yale人脸库降维结果图像输出示例

3.2 添加噪声的图像的结果与分析

加入密度为5%的椒盐噪声的ORL人脸库的结果如表1所示。当训练样本从5~9时,PCA+RLRC-IGG的识别率分别为82.98%、91.97%、94.42%、96.00%和95.00%,比LRC的识别率高7.50%、6.31%、6.29%、5.88%和3.63%,比RLRC-IGG的识别率高5.32%、5.50%、4.50%、5.63%和3.50%。加入密度为5%的斑点

噪声的结果如表 2 所示。PCA+RLRC-IGG 的识别率分别为 87.83%、94.31%、95.08%、96.69%和 95.00%，比 LRC 的识别率高 2.13%以上，比 RLRC-IGG 的识别率高 2.88%以上。

表 1 加入密度为 5%椒盐噪声的 ORL 人脸库的识别率 (均值±标准差(维数))

训练样本	LRC	RLRC-IGG	PCA+RLRC-IGG
5	77.65±2.22 (200)	75.48±2.33 (200)	82.98±0.83 (30)
6	86.47±2.19 (240)	85.66±2.26 (240)	91.97±0.71 (30)
7	89.92±1.27 (250)	88.13±1.75 (250)	94.42±0.72 (40)
8	90.36±2.78 (250)	90.13±3.14 (300)	96.00±0.96 (40)
9	91.50±2.49 (360)	91.38±3.29 (250)	95.00±0.00 (40)

表 2 加入密度为 5%斑点噪声的 ORL 人脸库的识别率 (均值±标准差(维数))

训练样本	LRC	RLRC-IGG	PCA+RLRC-IGG
5	80.28±1.86 (200)	80.80±1.63 (200)	87.83±0.85 (40)
6	90.09±1.79 (240)	90.16±1.58 (240)	94.31±0.40 (40)
7	91.63±1.31 (250)	92.00±1.25 (250)	95.08±0.46 (40)
8	93.56±1.36 (250)	93.63±2.18 (250)	96.69±0.73 (40)
9	92.88±1.68 (250)	92.13±1.68 (250)	95.00±0.00 (30)

在 Yale 人脸库中,加入密度为 5%的椒盐噪声的结果如表 3 所示。当训练样本从 6~10 时,PCA+RLRC-IGG 的识别率分别为 87.60%、87.50%、92.44%、99.00%和 99.33%，比 LRC 的识别率高 9.47%、12.75%、7.56%、12.33%和 17.00%，比 RLRC-IGG 的识别率高 2.87%、

2.92%、5.56%、9.33%和 18.33%。加入密度为 5%的斑点噪声的结果如表 4 所示。PCA+RLRC-IGG 的识别率分别为 95.47%、94.33%、92.78%、99.33%和 100.00%，比 LRC 的识别率高 4.11%以上，比 RLRC-IGG 的识别率高 5.00%以上。

表 3 加入密度为 5%椒盐噪声的 Yale 人脸库的识别率 (均值±标准差(维数))

训练样本	LRC	RLRC-IGG	PCA+RLRC-IGG
6	78.13±3.68 (90)	84.73±2.43 (90)	87.60±1.07 (33)
7	74.75±4.16 (105)	84.58±2.91 (105)	87.50±2.68 (55)
8	84.89±4.12 (120)	86.89±2.15 (120)	92.44±1.33 (88)
9	86.67±6.40 (135)	89.67±3.23 (135)	99.00±2.19 (33)
10	82.33±9.98 (110)	81.00±6.59 (150)	99.33±2.05 (77)

表 4 加入斑点噪声密度为 0.05 的 Yale 人脸数据库的识别率 (均值±标准差(维数))

训练样本	LRC	RLRC-IGG	PCA+RLRC-IGG
6	83.47±2.84 (90)	82.93±2.35 (90)	95.47±0.67 (33)
7	86.17±2.76 (105)	86.83±3.62 (105)	94.33±1.47 (55)
8	88.67±2.03 (120)	87.78±1.97 (120)	93.22±0.50 (120)
9	91.67±4.65 (77)	91.33±4.38 (77)	99.33±1.37 (33)
10	92.00±4.64 (77)	87.67±4.97 (77)	100.00±0.00 (33)

根据表 1 和 2 可得,LRC 和 RLRC-IGG 在维数 200 以上时,才能获得 77.65%以上的识别率,而当维数在 30~40 之间时,PCA+RLRC-IGG 的识别率在 82.98%以上。根据表 3 和 4 可得,当维数在 77 以上时,LRC 和 RLRC-IGG 的识别率在 74.75%以上,当维数在 33 以上时,PCA+RLRC-IGG 的识别率在 87.50%以上。根据表 1~4 可得,PCA+RLRC-IGG 不仅能提高效率而且能提高识别率。究

其原因,PCA 通过协方差矩阵获得特征值和特征向量,按照特征值从大到小的顺序进行排列,选择对应的特征向量作为坐标轴,将高维的人脸矩阵投影到选择的特征向量上,去除图像的部分噪声。根据 IGG 权函数,当 $|\hat{e}_i/\sigma| < 1.5$ 时,权函数 $Q_{ii} = 1$, $\hat{\alpha}_{(pca,p)_i} = \hat{\alpha}_{pca_i} = (\mathbf{U}_{pca_i}^T \mathbf{U}_{pca_i})^{-1} \mathbf{U}_{pca_i}^T \mathbf{y}_{pca_i}$, 训练样本不受噪声的影响,当 $1.5 \leq |\hat{e}_i/\sigma| < 2.5$ 时,权函数

$Q_{ii} = 1.5 / (|\hat{e}_i / \sigma|)$, 权函数 $0.6 < Q_{ii} < 1$, $\hat{\alpha}_{(\text{pca}, q)_i} = (\mathbf{U}_{\text{pca}_i}^T (1.5 / (|\hat{e}_i / \sigma|) \mathbf{I}) \mathbf{U}_{\text{pca}_i})^{-1} \mathbf{U}_{\text{pca}_i}^T (1.5 / (|\hat{e}_i / \sigma|) \mathbf{I}) \mathbf{y}_{\text{pca}_i}$, 其中 \mathbf{I} 为单位矩阵, 通过降维后的训练样本与权函数的乘积作为新的训练样本, 减少噪声的影响, 增强鲁棒性, 当 $|\hat{e}_i / \sigma| > 2.5$, 权函数 $Q_{ii} = 0$, $\hat{\alpha}_{(\text{pca}, q)_i} = (\mathbf{U}_{\text{pca}_i}^T (Q_{ii} \mathbf{I}) \mathbf{U}_{\text{pca}_i})^{-1} \mathbf{U}_{\text{pca}_i}^T (Q_{ii} \mathbf{I}) \mathbf{y}_{\text{pca}_i} = 0$, 剔除训练样本。通过不断地迭代 PCA+RLRC-IGG 回归系数估计值 $\hat{\alpha}_{(\text{pca}, q)_i}$, 直到 $|\hat{\alpha}_{(\text{pca}, q)_i}^k - \hat{\alpha}_{(\text{pca}, q)_i}^{k-1}| \leq \epsilon$ ($\epsilon = 1.0 \times 10^{-5}$) 时, 迭代结束。

4 结 论

本文提出了 PCA+RLRC-IGG 算法, 通过 PCA 进行降维, 降低计算的复杂度, 提高了效率, 将 IGG 权函数引入到 LRC 基本框架下, 该权函数对拍摄的角度、光照条件、是否有遮挡等各种变化都有较强的鲁棒性。实验结果表明, 在 ORL 人脸库中, PCA+RLRC-IGG 的识别率平均值均在 92.07% 以上, 高于 LRC 和 RLRC-IGG。在 Yale 人脸库中, PCA+RLRC-IGG 的识别率平均值均在 93.18% 以上, 高于 LRC 和 RLRC-IGG。本文提出的算法主要应用在拍摄角度难、光照不均匀、有遮挡等复杂条件下获取的人脸图像。然而, 本次实验使用的人脸库相对比较简单, 数量和类别较少, 因此, 下一步的研究重点将侧重于海量数据下的人脸识别。

参考文献

- [1] 张棋森, 肖香苏, 喻晓斌, 等. 基于人脸比例特征提取与匹配的身份鉴别[J]. 电子测量技术, 2020, 43(1): 137-140.
- [2] 周先春, 周杰, 许瑞. 多样本扩充的常规协同与逆线性回归结合的人脸识别算法[J]. 电子测量与仪器学报, 2018, 32(6): 96-101.
- [3] ZHU Y, ZHU C, LI X. Improved principal component analysis and linear regression classification for face recognition[J]. Signal Processing, 2018, 145: 175-182.
- [4] 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): 95-100.
- [5] 张娜, 刘坤, 韩美林, 等. 一种基于 PCA 和 LDA 融合的人脸识别算法研究[J]. 电子测量技术, 2020, 43(13): 72-75.
- [6] GAO X, SUN Q, XU H, et al. Sparse and collaborative representation based kernel pairwise linear regression for image set classification[J]. Expert Systems with Application, 2020, 140: 1-15.
- [7] LI Z Q, SUN J, WU X J, et al. Score level fusion in representation-based classification method for face recognition[J]. Journal of Algorithms & Computational

Technology, 2020, 14: 1-11.

- [8] NASEEM I, TOGNERI R, BENNAMOUN M. Linear regression for face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106-2112.
- [9] 龚循强, 鲁铁定, 刘星雷, 等. 高分辨率遥感图像场景线性回归分类[J]. 东华理工大学学报:自然科学版, 2019, 42(4): 425-432.
- [10] LU Y W, LAI Z H, WONG W K, et al. Low-rank discriminative regression learning for image classification[J]. Neural Networks, 2020, 125(7): 245-257.
- [11] LU Y W, FANG X Z, XIE B L. Kernel linear regression for face recognition[J]. Neural Computing and Applications, 2014, 24(7-8): 1843-1849.
- [12] HUANG S M, YANG J F. Linear discriminant regression classification for face recognition[J]. IEEE Signal Processing Letters, 2013, 20(1): 91-94.
- [13] 杨明莉, 范玉刚, 李宝芸. 基于 LDA 和 ELM 的高光谱图像降维与分类方法研究[J]. 电子测量与仪器学报, 2020, 34(5): 190-196.
- [14] HUANG P, LAI Z, GAO G, et al. Adaptive linear discriminant regression classification for face recognition[J]. Digital Signal Processing, 2016, 55: 78-84.
- [15] FENG Q, ZHOU Y. Iterative linear regression classification for image recognition[C]. 2016 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), 2016: 1566-1570.
- [16] GONG X Q, LI Z L. A robust weighted total least-squares solution with Lagrange multipliers[J]. Survey Review, 2017, 49(354): 176-185.
- [17] 龚循强, 李志林. 稳健加权总体最小二乘法[J]. 测绘学报, 2014, 43(9): 888-894, 901.
- [18] WRN 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.

作者简介

吕开云, 博士, 副教授, 主要研究方向为数字图像处理。

E-mail: kyly@ecut.edu.cn

鞠厦轶(通信作者), 硕士研究生, 主要研究方向为数字图像处理。

E-mail: XiayiJu1995@163.com

龚循强, 博士, 副教授, 主要研究方向为数字图像处理。

E-mail: xqgong1988@ecut.edu.cn.

鲁铁定, 博士, 教授, 主要研究方向为数字图像处理。

E-mail: tdlu@ecut.edu.cn