

基于低秩约束的极限学习机高效人脸识别算法

卢 涛 管英杰 潘兰兰 张彦锋

(武汉工程大学计算机科学与工程学院 武汉 430205)

(武汉工程大学智能机器人湖北省重点实验室 武汉 430205)

摘 要 复杂应用场景中,光照变化、遮挡和噪声等干扰使得将像素特征作为相似性度量的识别算法的图像类内差大于类间差,降低了人脸识别性能。针对这一问题,提出了一种低秩约束的极限学习机鲁棒性人脸识别算法,提升了复杂场景下的识别性能。首先,利用人脸图像分布的子空间线性假设,将待识别图像聚类到相对应的样本子空间;其次,将像素域分解为低秩特征子空间和稀疏误差子空间,依据图像子空间的低秩性对噪声鲁棒的原理,提取人脸图像的低秩结构特征训练极限学习机的前向网络;最后,实现对噪声干扰鲁棒的极限学习机人脸识别算法。实验结果表明,相比前沿的人脸识别算法,所提方法不仅识别精度高、算法时间复杂度低,且具有较好的实用性。

关键词 人脸识别,噪声鲁棒特性,低秩矩阵恢复,极限学习机

中图分类号 TP37 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.03.048

Low-rank Constrained Extreme Learning Machine for Efficient Face Recognition

LU Tao GUAN Ying-jie PAN Lan-lan ZHANG Yan-duo

(School of Computer Science and Engineering, Wuhan Institute of Technology, Wuhan 430205, China)

(Hubei Key Laboratory of Intelligent Robot (Wuhan Institute of Technology), Wuhan 430205, China)

Abstract In complex scenarios, illumination change, occlusion and noise make the image intra-variance of recognition algorithm (taking pixel feature as similarity measure) greater than the between-class variance, and reduce the performance of face recognition. To solve this problem, this paper proposed an low-rank supported extreme learning machine for robust face recognition to improve recognition performance. Firstly, the subspace linear assumption of face image distribution is used to make the image waiting to be recognized cluster to the corresponding sample subspace. Secondly, the pixel domain is resolved into low-rank feature subspace and sparse error subspace, and the forward network of low-rank structure characteristic of face image for training extreme learning machine is extracted, according to the low-rank principal of the image subspace for noise robustness. Finally, the extreme learning machine face recognition algorithm for noise robustness is realized. Experimental results show that, compared with the state-of-the-art face recognition algorithm, the proposed method not only has high recognition accuracy, but also has lower time complexity and better practicability.

Keywords Face recognition, Noise robust feature, Low-rank matrix recovery, Extreme learning machine

1 引言

人脸识别被广泛应用于信息安全、公共安全等各个领域,一直都是计算机视觉和模式识别的一个热门话题,具有极高的理论研究和应用价值。

人脸识别算法主要根据输入的人脸图像来推导其对应的身份信息。如图 1 所示,一般来讲,人脸识别算法主要分为 4 个步骤:前处理、特征提取、编码和分类。围绕这 4 个环节,近

年来有大量的文献开展了人脸识别领域的研究工作,并取得了良好的效果。根据技术的发展脉络将其主要分为 4 个不同的阶段:早期的模版几何匹配、子空间学习、稀疏分类和深度学习。

早期的模版匹配算法主要利用预定义的模版来弥补人脸图像多变性、算法效率高但识别精度有限等缺点。在此基础上提出的弹性图匹配(Elastic Graph Matching)、主动形状模型(ASM)和主动外观模型(AAM)等技术能够有效地从图像

到稿日期:2017-06-28 返修日期:2017-08-28 本文受国家自然科学基金项目(61502354,61501413,61671332,41501505),湖北省自然科学基金(2015CFB451,2014CFA130,2012FFA099,2012FFA134,2013CF125),武汉工程大学科研基金(K201713)资助。

卢涛(1980—),男,博士,副教授,主要研究方向为图像/视频处理、计算机视觉、人工智能,E-mail:lut@wit.edu.cn(通信作者);管英杰(1991—),女,硕士生,主要研究方向为图像处理、计算机视觉;潘兰兰(1991—),女,硕士生,主要研究方向为图像处理、机器视觉;张彦锋(1971—),男,教授,博士生导师,主要研究方向为人工智能、智能机器人。

或者视频中获得人脸的位置和区域,为人脸识别提供了更加精准的输入图像。受益于计算机视觉的理论发展,大量的手动设计的图像特征提取方法拥有了良好的识别性能,例如尺度不变特征变换(SIFT)^[1]、方向梯度直方图(HOG)^[2]、快速鲁棒特征(SURF)^[3]、局部二值模式(LBP)^[4]等特征提取方法

都可以直接应用于人脸识别领域,使得提取的人脸特征具有更强的稳健性。与此同时,利用人脸的结构特性,经典的基于子空间的学习方法(如特征脸方法(Eigenface)^[5]、fisherface^[6]、局部保持投影(LPP)^[7]等算法)也取得了相当好的识别效果,该类算法的计算量小且易于应用。




图 1 人脸识别算法的流程

Fig. 1 Flow chart of face recognition algorithm

近年来,稀疏表达理论在图像识别与恢复等领域获得了广泛的应用。Yang 等^[8]提出了基于稀疏表达的人脸识别算法,能够有效地提升人脸在噪声、遮挡等复杂输入条件下的识别率,该算法将稀疏表示和分类算法相结合,利用重建残差来预测类别信息从而获得了良好的识别性能。受到该算法的启发,基于协作表示的识别算法^[9]、基于局部约束表示^[10]的识别算法等都取得了良好的算法性能。受限于手动设计特征的表达能力,基于深度学习的人脸识别算法利用深度神经网络来拟合人类的认知过程,定义多层特征表达和提取框架,极大地提升了人脸识别的算法性能^[11]。Chan 等^[12]提出了一种简单的深度学习模型,利用主成分分析网络来提升识别任务的精度并取得了良好的算法性能,被认为是深度识别算法的基线。

的噪声敏感,即当训练样本或者测试样本中存在噪声时,ELM 的预测精度将大幅下降。

为了解决这一问题,本文提出了一种低秩约束的极限学习机高效人脸识别算法。首先,利用训练样本子空间的约束性,将输入样本聚类到样本空间;其次,利用低秩最小化获得对噪声鲁棒的结构化特征表达空间;最后,将获得的低秩特征通过极限学习机的网络训练权值来实现鲁棒性的人脸识别算法。本文的主要工作如下:1)利用低秩最小化将存在光照、遮挡和表情变化等噪声的人脸图像分解成低秩结构特征和稀疏误差项之和,从而实现人脸鲁棒性的特征提取;2)利用低秩结构特征约束极限学习机的训练过程和预测过程,在提升极限学习机的识别鲁棒性的同时,降低了计算的复杂度。

尽管上述算法在可控条件下所取得的识别性能令人印象深刻,但实际的人脸图像具有表情的多模态性、实际成像条件的变化性和成像过程中的噪声等因素的多样性以及实际应用的实时性,使得人脸识别算法仍然是具有挑战性的研究方向之一。特别是在复杂的成像条件下,研究针对各种噪声、遮挡、光照鲁棒的高效人脸识别算法仍然具有重要意义。斯坦福大学的 Candes 教授^[13]证明了在一定条件下低秩最小化能够补全观测矩阵的缺损值,低秩最小化理论发展因此迅速并成功地应用到了背景建模、运动检测图像分割等领域。低秩最小化将观测图像分解成干净的低秩空间和稀疏噪声空间,低秩空间代表了图像的结构信息,对噪声等具有较好的鲁棒性。在复杂的应用场景中,光照变化、遮挡和噪声变化等因素的干扰,降低了人脸识别的性能。Du 等^[14]提出了一种低秩稀疏表达的人脸识别算法,该算法将低秩和稀疏表示相结合来提升分类器对人脸变化的鲁棒性,取得了较好的识别率,但低秩和稀疏表达系数的计算复杂度较高。另一方面,传统的分类算法(如最近邻分类(K-Nearest Neighbor)、支持向量机(SVM)等)的效率较高,但是识别精度有限,极限学习机(ELM)是由反向传播(BP)神经网络发展而来的一种新型单隐层前馈网络(SLFNs),该算法的训练速度快、泛化能力强,日益受到研究者的关注。文献^[15]指出,极限学习机尽管有计算复杂度低、泛化能力强等优点,但是其预测精度对输入

2 基于低秩支持的极限学习机鲁棒性人脸识别

在复杂的应用场景下,由于人脸图像具有变化性(光照、遮挡、表情的变化),因此以像素特征为相似性度量的识别算法的图像类内差大于类间差,这降低了传统人脸识别算法的性能。本文提出一种低秩约束的极限学习机高效人脸识别算法,充分结合低秩矩阵恢复和极限学习机的优点,提升了人脸识别算法的鲁棒性,同时降低了时间开销。算法的流程如图 2 所示。

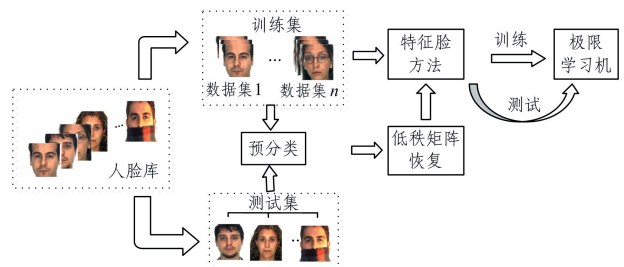


图 2 基于低秩约束的极限学习机人脸识别算法的流程

Fig. 2 Flow chart of low-rank constrained extreme learning machine for face recognition

2.1 局部支持矩阵

假设输入人脸图像 $x_j \in R^{d \times 1} (j=1, 2, 3, \dots, p)$, 一共有 p 张人脸;给定相对应的 n 类人脸图像,其中 $D = [D_1, D_2, \dots, D_n] \in R^{d \times l}$, $D_i \in R^{d \times n_i}$ 表示第 i 类人脸图像数据集,其中 $D_i =$

$[d_1, d_2, \dots, d_{n_i}]$, n_i 表示该类别人脸图像的样本个数。对于每个输入的测试样本, 采用以下公式获得局部距离权值:

$$\text{dist}(x_j, d_{i,p}) = \|x_j - d_{i,p}\|_2^2 \quad (1)$$

本文采用 ϵ -ball 的方法来找到 K 局部支持矩阵: 若 $\text{dist} \leq \epsilon$, 则满足条件的备选样本将形成新的集合 $B = \{d_{i,k}\}_{i=1, n, k=0, K}$, 集合 B 的下标表示的是满足条件的第 i 类样本的第 k 个样本, 计算落入到第 i 类中符合局部性规则的样本个数。取其最大值作为输入图像的类型信息, 将 x_j 放进对应的类别 i 中, 其中 $\epsilon > 0$ 是一个常数, 完成 p 张人脸的预分类, 将 x_j 与对应的 D_i 合并成增广矩阵 $X = [D_i, x_j] \in R^{d \times (n_i+1)}$ 。

2.2 低秩矩阵恢复

对于观测矩阵 X , 可以将观测到的图像分解成低秩子空间图像和稀疏误差项之和, 计算公式如下:

$$\min_{L,E} \text{rank}(L) + \lambda \|E\|_0 \quad \text{s. t. } X = L + E \quad (2)$$

其中, L 表示低秩矩阵, E 表示稀疏误差矩阵, λ 表示稀疏错误的百分比。由于式(2)是一种高度非凸优化问题, 没有有效的解决方案, 因此采用以下式子来代替(其中采用 l_1 范式和核范数来替代 l_0 范式):

$$\min_{L,E} \|L\|_* + \lambda \|E\|_1 \quad \text{s. t. } X = L + E \quad (3)$$

其中, $\|\cdot\|_*$ 表示矩阵的核范数, 即所有奇异值的和, $\|\cdot\|_1$ 表示 l_1 范数, 即矩阵中所有元素的绝对值。本文采用拉格朗日乘子方法来求解目标函数(3), 其拉格朗日乘算子如下:

$$L(E, Y, u) = \|L\|_* + \lambda \|E\|_1 + \text{tr}[Y'(X - L - E)] + \frac{u}{2} \|X - L - E\|_F^2 \quad (4)$$

其中, 常数 λ 用于控制低秩结构项和稀疏误差项的比例关系, 一般选用 $\lambda = \frac{1}{\sqrt{\max(m, n)}}$, m 和 n 是矩阵 X 的行数与列数; Y

是拉格朗日乘子向量; tr 是矩阵的迹。常采用交替迭代方法来求解该目标函数。在优化式(4)时, 通过固定 E 来求解 L , 通过固定 L 来求解 E , 通过下式可得到 L 和 E :

$$\begin{aligned} L &= \arg \min_L \|L\|_* + \text{tr}[Y'(X - L - E)] + \\ &\quad \frac{u}{2} \|X - L - E\|_F^2 \\ &= \arg \min_L \frac{1}{u} \|L\|_* + \|L - (\frac{1}{u}Y + X - E)\|_F^2 \end{aligned} \quad (5)$$

该目标函数可以使用软阈值收缩法来获得解析解^[16]。在获得 L 的值后, 使用如下方法来求解误差项:

$$\begin{aligned} E &= \arg \min_E \lambda \|E\|_1 + \text{tr}[Y'(X - L - E)] + \\ &\quad \frac{u}{2} \|X - L - E\|_F^2 \\ &= \arg \min_E \frac{\lambda}{u} \|E\|_1 + \frac{1}{2} \|E - (\frac{1}{u}Y + X - L)\|_F^2 \end{aligned} \quad (6)$$

该目标函数是典型的 l_1 范式的求解问题, 使用 SPAMS 软件包计算该目标函数。拉格朗日乘算子 u 采用下式进行更新:

$$u = \min(u * \rho, u_{\max}) \quad (7)$$

其中, ρ 通过满足条件 $\rho > 1$ 来控制 u 的增长, u_{\max} 的上限为 ρ 。因此基于低秩最小化的矩阵恢复算法如算法 1 所示。

算法 1 基于低秩最小化的矩阵恢复算法

输入: 矩阵 $X, \lambda, E=0, u>0, \gamma=10^{-7}$

输出: 低秩矩阵 L , 噪声误差项 E

步骤 1 通过式(5)计算 L_{k+1}

步骤 2 通过式(6)计算 E_{k+1}

步骤 3 通过式(7)更新 u

检查

算法的终止条件为: $\|X - L - E\|_{\infty} < \gamma$

2.3 特征脸学习

给定字典 $D, D = [D_1, D_2, \dots, D_n] \in R^{d \times l}, D_i \in R^{d \times n_i}$ 表示第 i 类人脸图像数据集, 其中 $D_i = [d_1, d_2, \dots, d_{n_i}]$, 通过主成分分析得到平均脸:

$$m = \frac{1}{n} \sum_{i=1}^n d_i \quad (8)$$

则可以得到每张人脸和平均人脸之间的距离:

$$N = [d_1 - m, d_2 - m, \dots, d_{n_i} - m] \quad (9)$$

一组特征向量, 也称为特征脸, 由整体协方差矩阵的特征向量计算:

$$C = \sum_{i=1}^n \{(d_i - m)(d_i - m)^T\} = NN^T \quad (10)$$

由于 C 是一个 d 阶矩阵, d 大于 l , 使用 SVD 奇异值分解的计算复杂度较高, 可以将其转化为另一个 l 阶矩阵 $R = NN^T$, 从而大大降低计算复杂度, 则可以得到:

$$N^T N V = V \Lambda \quad (11)$$

其中, V 为特征向量矩阵, Λ 为特征值矩阵, 在方程两边同时乘以 N 可得:

$$(NN^T) N V = N V \Lambda \quad (12)$$

因此, 特征脸的表达字典 F 可以通过下式计算得到:

$$F = N V \Lambda^{-\frac{1}{2}} \quad (13)$$

对于一个输入的测试样本 x_j , 可以通过将一个权重向量投影到特征脸上来求解权重向量:

$$q = F^T (x_j - m) \quad (14)$$

通过调整式(14)中主成分的取值, 可以实现对输入人脸图像的特征提取过程。

2.4 低秩结构特征支持的极限学习机人脸识别算法

极限学习机是典型的单隐层前馈神经网络(SLFNs), 被广泛应用于分类和回归的问题。与传统的神经网络模型不同, ELM 算法能自适应地设置隐层节点的数量, 并随机分配输入权重和隐含层节点数, 然后通过最小二乘算法来求解输出的权重。训练过程无需迭代, 因此训练速度相对于传统的 BP 算法和支持向量机(SVM)算法有显著提升。

$$L = \{(q_i, t_i) | q_i \in R^d, t_i \in R^m, i = 1, 2, \dots, N\}$$

其中, $q_i = (q_{i1}, q_{i2}, \dots, q_{id})^T \in R^d, t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in R^d, N$ 表示人脸图像的样本数。下式中, d 表示 x 的大小, m 表示人脸的类别数。下式中 k 表示 ELM 的隐藏节点数, 隐层激励函数为 $f(x)$ 。

$$\sum_{j=1}^k \beta_j f_j(q_i) = \sum_{j=1}^k \beta_j f_j(\omega_j \cdot q_i + b_j) = o_j, j = 1, 2, \dots, N \quad (15)$$

其中, $\omega_j = (\omega_{j1}, \omega_{j2}, \dots, \omega_{jd}), \omega_j$ 是隐含层中的 j 个神经元和输入层的特征之间的权重; $\beta_j = (\beta_{j1}, \beta_{j2}, \dots, \beta_{jm})^T, \beta_i$ 是第 i 个神经元和输出层之间的权值; $o_j = (o_{j1}, o_{j2}, \dots, o_{jm})^T, o_j$ 是

第 j 个输入所对应的目标向量; b_j 是第 j 个隐含层中的偏差; $\omega_j \cdot q_i$ 表示向量的内集。

单隐层神经网络学习的目的是使输出的误差最小,可以表示为:

$$\sum_{i=1}^N \| o_i - t_i \| = 0 \quad (16)$$

即存在 β_i, ω_j, b_j , 使得:

$$\sum_{j=1}^N \beta_j f(\omega_j \cdot q_i + b_i) = t_j, j=1, 2, \dots, N \quad (17)$$

也可以表示为:

$$\beta^T H = T \quad (18)$$

$H =$

$$\begin{bmatrix} f(\omega_1 \cdot q_1 + b_1) & \dots & f(\omega_1 \cdot q_N + b_1) \\ f(\omega_2 \cdot q_1 + b_2) & \dots & f(\omega_2 \cdot q_N + b_2) \\ \vdots & \vdots & \vdots \\ f(\omega_K \cdot q_1 + b_K) & \dots & f(\omega_K \cdot q_N + b_K) \end{bmatrix}_{K \times N}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_K^T \end{bmatrix}_{K \times m}, T = [t_1, t_2, \dots, t_N]_{m \times N}$$

Huang 等人指出:若隐藏节点的数目是足够的,则激活作用无限可微,而且不需要调整所有网络参数。在训练阶段,输入权重和隐层节点的偏差通过 SLFN 算法得到,根据参数和输入样本即可计算出与隐藏节点连接的输入权重、输出矩阵。一旦输入权重 ω_j 和隐层偏差 b_j 被随机确定,隐层输出矩阵 H 就被唯一确定,输出权值 β 可由下式得到:

$$\beta = \arg \min_{\beta} \| \beta^T H - T \|_2^2 = H^* T \quad (19)$$

其中, H^* 是矩阵 H 的 Moore-Penrose 广义逆。

综上所述,低秩支持的极限学习机鲁棒性人脸识别算法如下。

算法 2 低秩支持的极限学习机鲁棒性人脸识别算法

输入:训练样本库 $D=[D_1, D_2, \dots, D_n] \in R^{d \times 1}$ 及其对应的标签类别集合 T , 测试样本 x_j

输出:人脸图像的分类属性 t_j

训练部分:

- 步骤 1 准备训练样本库 D 和对应的类别标签;
- 步骤 2 建立极限学习网络结构,利用式(15)获得输出权值测试部分。

测试部分:

- 步骤 1 将利用算法 1 获得的测试集中经过低秩矩阵恢复后的人脸图像作为人脸识别的输出;
- 步骤 2 利用式(14)提取人脸图像的表达特征;
- 步骤 3 利用训练阶段获得的网络结果预测类别标签 t_j 。

3 实验结果分析

本次实验选取 AR 人脸数据库和 Extend Yale-B 人脸数据库作为数据集。AR 人脸数据库包括 100 个人共 2600 张人脸,每个人有 26 张图像,每幅图的大小为 160×120 像素,存在光照、表情和遮挡等变化。Extend Yale-B 人脸数据库包含 38 个人共 16128 张人脸,每幅图的大小为 192×168 像素,有 9 种不同姿态和 64 种不同光照变化情况,在实验中选择每个人 60 张在不同光照变化下的正面人脸图像,一共 2280 张

人脸。实验分别围绕鲁棒人脸特征提取、分类算法性能和深度学习算法性能这 3 方面展开,来测试所提算法在复杂条件下的算法性能。

3.1 低秩矩阵恢复

为了测试低秩矩阵恢复提取人脸特征的鲁棒性,首先设计了基于预分类的低秩人脸特征提取算法。受益于人脸训练样本的类别信息,在已知人脸识别样本类别信息的前提下,对测试图像进行预分类。首先从 AR 的人脸数据库的每一类中随机选择 6 张人脸,在 Extend Yale-B 人脸数据库的每一类中随机选择 20 张作为训练集,将剩余的所有图像作为测试集。预分类后的测试人脸和训练样本人脸图像构成新的数据集,以进行低秩恢复实验(见图 3),选取 8 张有表情变化或者是遮挡的低秩恢复的人脸图像,设置稀疏错误的百分比 $\lambda = 0.007$ 。



(a) 原始人脸图像



(b) 由(a)得到的低秩恢复图像



(c) 由(a)得到的稀疏误差图像

注:从左到右,前 5 列为 AR 人脸数据库,后 3 列为 Extend Yale-B 人脸数据库

图 3 低秩矩阵恢复图像

Fig. 3 Low-rank recovery images

由图 3 可以看出,在预分类准确的前提下,低秩矩阵恢复能够成功地将原始图像的表情变化和遮挡去除,将原始图像转换为低秩图像和稀疏噪声图像之和,即能够有效地将存在表情变化和遮挡的噪声分离。

3.2 人脸识别算法的性能

3.2.1 神经元个数对识别率的影响

ELM 是一种神经网络,它的特点是只需要通过设置神经元的个数就可以完成训练过程,本次实验是为了得到使分类器性能达到最优的神经元个数的参数值。首先从 AR 的人脸数据库的每一类中随机选择 6 张人脸作为训练样本,将其余的人脸图像经过低秩矩阵恢复后作为测试样本。图 4 为识别率随神经元个数变化的曲线。




图 4 识别率随神经元个数变化的曲线

Fig. 4 Relationship between recognition rate and the number of neurons

由图 4 可以看出,神经元个数过多或过少都会影响分类器的识别率,在神经元个数大于 1600 时 ELM 分类器的性能最优,但由于神经元个数增多时时间开销也会变大,因此本文设置神经元个数为 2000。

3.2.2 不同分类器下的识别率

为了研究训练样本对识别率的影响,本次实验根据训练样本的特征维数来进行。以训练集为训练样本,将经过低秩矩阵恢复后的人脸图像作为测试样本,对每幅人脸图像进行下采样,使每幅图像的大小为 45×50 像素,而且实验在不同的分类框架下对图像进行识别,在获得了一致的低秩人脸特征后对比不同的分类器的算法性能,对比算法主要有 LR+NN, LR+SVM, LSRC^[14], NN^[17], SVM^[18], SRC^[8], CRC^[9], 使用特征降方法来降低人脸图像的特征维数,结果如图 5、图 6 所示。




图 5 不同的人脸识别算法在 AR 人脸数据库上的识别率

Fig. 5 Recognition rate for different FR algorithms on AR database

由图 5 可以看出,随着特征维数的增加,识别率也逐渐增加,在不同特征维数下 ELM 的识别率明显高于 SVM, NN, SRC 的识别率,与 CRC 的识别率相当。ELM 分类器即使在样本数量少和特征维数少的情况下,仍然表现出了较好的识别性能。在低秩矩阵恢复处理过后,将表情变化、遮挡等噪声分离,识别率得到了明显提升。




图 6 不同的人脸识别算法在 Extend Yale-B 人脸数据库上的识别率

Fig. 6 Recognition rate for different FR algorithms on extend Yale-B database

由图 6 可以看出,随着特征维数的增加,识别率也在增加,在相同的特征维数下, LSELM 的识别率与 LSRC, LR+SVM 的识别率相当。在 Extend Yale-B 人脸数据库中,人脸表情变化较小,没有遮挡的影响,同类别的特征差异较小,只是略微有所提升。

在人脸识别中,分类效率也是一个重要的组成部分,本次

实验分别在 AR 人脸数据库中训练 6 张图片、在 Extended Yale-B 人脸数据库中训练 20 张图片的情况下进行,特征维数都为 100,分别计算了不同识别框架下的识别时间、训练时间和识别率。不同识别算法的时间复杂度对比如表 1 所列。不同的人脸识别算法在不同数据库上的识别率如图 7 所示。

表 1 不同识别算法的时间复杂度对比

Table 1 Comparison of time complexity of different recognition algorithms

方法	AR		Extended Yale-B	
	识别时间	训练时间	识别时间	训练时间
LSELM	0.14	0.07	0.17	0.13
LSRC	108.13	—	155.50	—
LR+SVM	27.54	34.12	3.95	13.65
LR+NN	5.92	—	8.05	—

(单位:s)




图 7 不同的人脸识别算法在不同数据库上的识别率

Fig. 7 Recognition rate for different FR algorithms on different databases

由表 1 可以看出,在 AR 人脸数据库和 Extended Yale-B 人脸数据库中 LSELM 的识别时间都是最短的,此时 LSELM 的训练时间分别为 0.07 和 0.13,其训练时间加上识别时间仍然比其他分类器所花费的时间短。由图 7 可以看出, LSELM 在分类效率上具有优势,而且识别率也高于 LSRC, LR+SVM, LR+NN 的识别率。注意,由于这些算法都是基于低秩矩阵恢复的,因此低秩矩阵恢复的时间没有被列出。考虑到特征提取也耗费时间,将低秩矩阵恢复的时间和 LBP 特征提取的时间进行比较,每张图片花费的时间为 0.29s 和 1.37s,因此可以知道在实际应用中高效的 ELM 在测试和训练中是非常有利的。总体来说,低秩支持的极限学习机人脸识别算法具有较好的识别鲁棒性和较低的计算复杂度。

3.3 识别算法和深度学习算法的对比

近年来,深度学习也被广泛地应用于人脸识别,为了研究算法识别的鲁棒性,LBP 特征在处理光照变化等因素上获得了良好的算法性能,本实验直接使用 LBP^[4] 特征算法进行对比,同时从鲁棒特征提取和深度学习分类两个方面对目前的深度学习算法 PCANet^[12] 进行对比。实验配置如下:AR 数据库中的人脸图像的大小为 160×120 像素,用无表情和正面光照的人脸图像作为训练集,测试集则分为以下几种情况:光照变化、表情变化、遮挡物,遮挡物和光照变化;Extended Yale-B 数据库中的人脸图像的大小为 192×168 像素,用无表情和正面光照的人脸图像作为训练集,有光照变化的人脸图像作为测试集。

表2 复杂条件下人脸识别算法的性能对比

Table 2 Performance comparison of FR algorithms under complicated conditions

测试集	AR				Extended Yale-B
	光照变化	表情变化	遮挡物	光照变化 & 遮挡物	
LBP ^[4]	0.9358	0.8156	0.9135	0.7958	0.7581
PCANet	0.9960	0.8500	0.9700	0.9500	0.9960
本文算法	0.9985	0.8470	0.9725	0.9587	0.9701

LBP特征在光照变化的情况下能够获得良好的分类性能,但在遮挡和光照变化的情况下算法性能下降,这表明LBP特征在复杂变化情况下的表达能力有限。PCANet是典型的基于深度学习的人脸识别算法,相比LBP特征在光照变化和遮挡情况下获得了更好的特征表达能力和分类能力。本文算法在光照变化、遮挡以及光照变化和遮挡3种情况下相比PCANet有提升,但在表情变化情况下低于PCANet的识别率而高于LBP算法的识别率,初步说明了本文提出的低秩支持的极限学习机人脸识别算法能够获得与前沿深度学习基准算法相当的性能,进一步证明了算法的有效性和其在复杂条件下识别的鲁棒性。

结束语 在复杂的应用场景中,往往会由于光照变化、遮挡和噪声变化等因素的干扰,使人脸识别性能降低,本文提出了一种基于低秩约束的极限学习机高效人脸识别算法。该算法首先利用人脸图像分布的子空间线性假设,将待识别图像聚类到相对应的样本子空间;然后通过低秩矩阵恢复将矩阵分解为低秩矩阵和稀疏误差矩阵,依据图像子空间的低秩性对噪声鲁棒的原理,提取人脸图像的低秩结构特征训练极限学习机的前向网络;最后实现了对噪声干扰鲁棒的极限学习机人脸识别算法。实验结果证明,本文算法在识别率和识别时间上都优于其他对比算法,表明了本文算法有较好的实用性。

参考文献

- [1] YOUSEF K M A, AL-TABANJAH M, HUDAIB E, et al. SIFT based automatic number plate recognition[C]//2015 6th International Conference on Information and Communication Systems (ICICS). IEEE, 2015: 124-129.
- [2] PANG Y, YUAN Y, LI X, et al. Efficient HOG human detection [J]. Signal Processing, 2011, 91(4): 773-781.
- [3] BAY H, ESS A, TUYTELAARS T, et al. Speeded-up robust features (SURF) [J]. Computer Vision and Image Understanding, 2008, 110(3): 346-359.
- [4] AHONEN T, HADID A, PIETIKAINEN M. Face description with local binary patterns: Application to face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(12): 2037-2041.
- [5] TURK M A, PENTLAND A P. Face recognition using eigenfaces[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE, 1991: 586-591.
- [6] BELHUMEUR P N, HESPAHHA J P, KRIEGMAN D J. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection [C]// European Conference on Computer Vision. Springer Berlin Heidelberg, 1996: 43-58.
- [7] HE X, YAN S, HU Y, et al. Face recognition using laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.
- [8] 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.
- [9] ZHANG L, YANG M, FENG X. Sparse representation or collaborative representation: Which helps face recognition? [C]//2011 IEEE International Conference on Computer Vision (ICCV). IEEE, 2011: 471-478.
- [10] JIANG J, HU R, WANG Z, et al. Noise robust face hallucination via locality-constrained representation[J]. IEEE Transactions on Multimedia, 2014, 16(5): 1268-1281.
- [11] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [12] CHAN T H, JIA K, GAO S, et al. PCANet: A simple deep learning baseline for image classification? [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.
- [13] AWRANGJEB M, LU G. Robust image corner detection based on the chord-to-point distance accumulation technique[J]. IEEE Transactions on Multimedia, 2008, 10(6): 1059-1072.
- [14] DU H S, HU Q P, QIAO D F, et al. Robust face recognition via low-rank sparse representation-based classification[J]. International Journal of Automation and Computing, 2015, 12(6): 579-587.
- [15] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1): 489-501.
- [16] CANDÈS E J, LI X, MA Y, et al. Robust principal component analysis? [J]. Journal of the ACM, 2009, 58(3): 11.
- [17] VEENMAN C J, REINDERS M J T. The nearest subclass classifier: A compromise between the nearest mean and nearest neighbor classifier[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(9): 1417-1429.
- [18] WISSEL T, PFEIFFER T, FRYSCH R, et al. Hidden Markov model and support vector machine based decoding of finger movements using electrocorticography[J]. Journal of Neural Engineering, 2013, 10(5): 056020.
- [19] TAN X, TRIGGS B. Enhanced local texture feature sets for face recognition under difficult lighting conditions[J]. IEEE Transactions on Image Processing, 2010, 19(6): 1635-1650.